

UNIVERSIDADE DE SÃO PAULO
ESCOLA DE ENGENHARIA DE SÃO CARLOS

LIGIA MARIA BARRIOS CAMPANHÃO

Influência do padrão da paisagem na qualidade da água: contribuições para a conservação dos
serviços ambientais hidrológicos

São Carlos

2022

LIGIA MARIA BARRIOS CAMPANHÃO

Influência do padrão da paisagem na qualidade da água: contribuições para a conservação dos serviços ambientais hidrológicos

Versão corrigida

Tese apresentada à Escola de Engenharia de São Carlos, Universidade de São Paulo, como parte dos requisitos para obtenção do título de Doutora em Ciências.

Área de concentração: Ciências da Engenharia Ambiental

Orientador: Prof. Dr. Victor Eduardo Lima Ranieri

São Carlos

2022

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO,
POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS
DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Ficha catalográfica elaborada pela Biblioteca Prof. Dr. Sérgio Rodrigues Fontes da
EESC/USP com os dados inseridos pelo(a) autor(a).

C186i Campanhão, Ligia Maria Barrios
Influência do padrão da paisagem na qualidade da
água: contribuições para a conservação dos serviços
ambientais hidrológicos / Ligia Maria Barrios
Campanhão; orientador Victor Eduardo Lima Ranieri. São
Carlos, 2022.

Tese (Doutorado) - Programa de Pós-Graduação e
Área de Concentração em Ciências da Engenharia
Ambiental -- Escola de Engenharia de São Carlos da
Universidade de São Paulo, 2022.

1. Ecologia da paisagem. 2. Desenho da paisagem. 3.
Heterogeneidade da paisagem. 4. Modelagem. 5. Modelos
neutros. 6. Produção de sedimentos. I. Título.

FOLHA DE JULGAMENTO

Candidata: Licenciada **LÍGIA MARIA BARRIOS CAMPANHÃO**.

Título da tese: "Influência do padrão da paisagem na qualidade da água: contribuições para a conservação dos serviços ambientais hidrológicos".

Data da defesa: 14/06/2022.

Comissão Julgadora

Resultado

Prof. Associado **Victor Eduardo Lima Ranieri** (Orientador)
(Escola de Engenharia de São Carlos/EESC-USP)

Aprovada

Prof. Associado **Silvio Frosini de Barros Ferraz**
(Escola Superior de Agricultura "Luiz de Queiroz"/ESALQ-USP)

Aprovada

Prof. Titular **Gerd Sparovek**
(Escola Superior de Agricultura "Luiz de Queiroz"/ESALQ-USP)

Aprovada

Prof. Dr. **Luciano Elsinor Lopes**
(Universidade Federal de São Carlos/UFSCar)

Aprovada

Dra. **Maria José Brito Zakia**
(Prática Assessoria Socioambiental)

Aprovada

Coordenador do Programa de Pós-Graduação em Ciências da Engenharia Ambiental:

Prof. Titular **Marcelo Zaiat**

Presidente da Comissão de Pós-Graduação:

Prof. Titular **Murilo Araujo Romero**

AGRADECIMENTOS

Muito obrigada a todas as pessoas e instituições que de alguma forma tornaram possível a conclusão deste trabalho:

À Universidade de São Paulo, Escola de Engenharia de São Carlos e Centro de Recursos Hídricos e Estudos Ambientais (CRHEA), pelo oferecimento do programa de Pós-Graduação em Ciências da Engenharia Ambiental (PPGSEA) e dos recursos necessários para o desenvolvimento da pesquisa;

Às pessoas que compõem essas instituições, em especial os funcionários responsáveis pelo almoço diário, pela limpeza e pela gestão da vida acadêmica dos pós-graduandos;

Ao meu orientador, Prof. Dr. Victor Eduardo Lima Ranieri, pela orientação, paciência, confiança e aprendizado compartilhado;

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pelo financiamento da pesquisa;

Aos professores e colegas do Programa de Pós-Graduação em Ciências da Engenharia Ambiental (PPGSEA), pelo companheirismo e aprendizado;

Aos amigos do antigo LabSIG e do atual Laboratório de Gestão Ambiental, pela companhia, pelos risos compartilhados, pelo apoio e parceria e pelas contribuições à pesquisa: Arthur, Bartira, Carol, Eleri, Érica, Gabi Nunes, Gabi Pegler, Lauro, Lucas, Karina, Mariana, Maridelia, Marcio, Moema, Renan Dias, Rhennan Mecca e Stella;

Ao Arthur Fendrich, pelas conversas sobre estatística e pela ajuda com o uso do R;

Ao Phelipe da Silva Anjinho, pelas contribuições durante o processo de calibração e execução do modelo *InVEST Sediment Delivery Ratio*;

Aos amigos feitos em Guariba, Ribeirão Preto e São Carlos, alguns distantes fisicamente, mas sempre presentes de alguma forma em minha rotina;

Ao André, pelo amor, paciência, compreensão, generosidade e companheirismo em todos os aspectos da minha vida;

À minha família, especialmente meus pais Júlio e Izilda, por apoiar as minhas escolhas e propiciar que eu pudesse atingir os meus objetivos.

*O Tejo é mais belo que o rio que corre pela minha aldeia,
Mas o Tejo não é mais belo que o rio que corre pela minha aldeia
Porque o Tejo não é o rio que corre pela minha aldeia.*

*O Tejo tem grandes navios
E navega nele ainda,
Para aqueles que veem em tudo o que lá não está,
A memória das naus.*

*O Tejo desce de Espanha
E o Tejo entra no mar em Portugal.
Toda a gente sabe isso.
Mas poucos sabem qual é o rio da minha aldeia
E para onde ele vai
E donde ele vem.
E por isso, porque pertence a menos gente,
É mais livre e maior o rio da minha aldeia.*

*Pelo Tejo vai-se para o Mundo.
Para além do Tejo há a América
E a fortuna daqueles que a encontram.
Ninguém nunca pensou no que há para além
Do rio da minha aldeia.*

*O rio da minha aldeia não faz pensar em nada.
Quem está ao pé dele está só ao pé dele.*

RESUMO

CAMPANHÃO, L. M. B. **Influência do padrão da paisagem na qualidade da água: contribuições para a conservação dos serviços ambientais hidrológicos.** 2022. Tese (Doutorado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2022.

As evidências sobre como o padrão dos usos e coberturas do solo na paisagem influenciam a qualidade da água ainda são incipientes. O esclarecimento sobre essa relação padrão-processo pode contribuir para o planejamento e gestão de instrumentos de conservação destinados à proteção dos serviços hidrológicos. O objetivo geral deste trabalho foi compreender quais aspectos do padrão da paisagem em escala de bacia hidrográfica e zona ripária se relacionam com a qualidade da água. A motivação da pesquisa foi contribuir com conhecimento sobre essa relação padrão-processo de forma a fornecer evidências que possam subsidiar a implementação de instrumentos de conservação aplicados à escala de paisagem. Duas abordagens foram adotadas para atingir esse objetivo: uma revisão sistemática da literatura e um experimento de simulação. A revisão sistemática da literatura indicou que a base de evidências sobre a relação padrão-processo se encontra em estágio inicial. Maior proporção de florestas se associou com melhor qualidade da água, enquanto usos urbanos e agrícolas foram relacionados com pior qualidade. Por outro lado, há poucas evidências sobre a influência da configuração das florestas. Ambas as escalas de bacia e zona ripária se mostraram relevantes para a predição da qualidade da água, e fatores sazonais e físicos podem modular a relação padrão-processo. O experimento de simulação foi baseado em réplicas de uma bacia hidrográfica real com diferentes quantidades e configurações de floresta. Uma modelagem da produção de sedimentos foi utilizada para caracterizar a qualidade da água nessas réplicas. Os resultados indicaram que implementar uma faixa ripária florestal contínua é uma ação prioritária, embora diferentes estratégias possam ser combinadas para atingir metas satisfatórias para as cargas de sedimentos. A porcentagem de floresta na bacia e na zona ripária foi o preditor mais importante da qualidade da água. A localização dos fragmentos florestais paralelamente às zonas ripárias se mostrou o fator mais importante da configuração. Em níveis intermediários de cobertura florestal, manchas de floresta mais desagregadas podem ter um efeito benéfico na qualidade da água. As evidências obtidas a partir das duas abordagens acrescentaram ao conhecimento sobre a relação padrão-processo e podem contribuir para o planejamento, gestão e monitoramento de instrumentos de conservação dos serviços hidrológicos em escala de paisagem.

Palavras-chave: Ecologia da paisagem. Desenho da paisagem. Heterogeneidade da paisagem. Modelagem. Modelos neutros. Produção de sedimentos.

ABSTRACT

CAMPANHÃO, L. M. B. **Influence of landscape pattern on water quality: contributions to the conservation of watershed services.** 2022. Dissertation (Doctoral) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2022.

Evidence on how the pattern of land use and land cover (LULC) in the landscape influence water quality is scarce. Understanding this pattern-process relationship can contribute to the planning and management of conservation mechanisms aimed at protecting watershed services. This study aimed to understand how landscape patterns at the watershed and riparian zone scales influence water quality. The motivation for this research was to provide knowledge on the pattern-process relationship to support policy mechanisms implemented at the landscape scale. Two approaches were adopted to achieve this goal: a systematic literature review and a simulation experiment. The systematic review indicated that evidence on the pattern-process relationship is at an early stage. Higher percentages of the landscape occupied by forests were associated with better water quality, while urban and agricultural uses were associated with worse water quality. On the other hand, there are few studies on the influence of forest configuration. Both watershed and riparian scales were relevant for water quality prediction, and seasonal and physical factors can modulate the pattern-process relationship. The simulation experiment was based on replicas of a watershed landscape with different amounts and forest configurations. Modeled sediment yields represented water quality for these replicas. The results indicated that implementing continuous forest buffers along the riparian zone is a priority action, although different strategies can be combined to achieve reasonable goals for sediment export. The percentage of forests in the watershed and the riparian zone was the most important predictor of water quality. The location of forest patches parallel to riparian zones was the most relevant configuration aspect. At intermediate levels of forest cover, disaggregated forest patches can have a positive effect on water quality. The results from the review and the simulation experiment added to the knowledge on the pattern-process relationship and can contribute to the planning, management, and monitoring of instruments aimed at conserving watershed services at the landscape scale.

Keywords: Landscape Ecology. Landscape design. Landscape heterogeneity. Modeling. Neutral landscape models. Sediment yield.

LISTA DE FIGURAS

Figura 1 – Classificação dos serviços ambientais e sua relação com o bem-estar humano	41
Figura 2 – Esquema do processo de filtragem para seleção dos trabalhos na revisão sistemática	48
Figura 3 – Trabalhos selecionados, analisados e excluídos pelos filtros da revisão sistemática	65
Figura 4 – Número de trabalhos incluídos na revisão sistemática por data de publicação	67
Figura 5 – Localização das áreas de estudo dos artigos incluídos na revisão sistemática	68
Figura 6 – Número de bacias analisadas pelos estudos incluídos na revisão sistemática	69
Figura 7 – Áreas das bacias analisadas pelos estudos incluídos na revisão sistemática	69
Figura 8 – Quantidade de anos de dados de qualidade da água analisados pelos estudos incluídos na revisão sistemática	70
Figura 9 – Quantidade de estudos da revisão sistemática que empregaram as técnicas estatísticas	71
Figura 10 – Relações entre indicadores de qualidade da água e métricas da paisagem consideradas significativas ($p < 0,05$) pelo teste do sinal aplicado aos resultados da revisão sistemática	73
Figura 11 – Número de resultados para a relação entre fósforo total e métricas da paisagem extraídos da revisão sistemática	75
Figura 12 – Largura dos <i>buffers</i> dos resultados para as relações métrica-parâmetro incluídas na revisão sistemática	78
Figura 13 – Três exemplos de modelos neutros de paisagem gerados a partir da mesma proporção de uma classe ($p = 0,33$)	101
Figura 14 – Localização da área de estudo em relação à bacia hidrográfica do rio Corumbataí e ao estado de São Paulo	110
Figura 15 – Uso e cobertura do solo da sub-bacia do Alto Corumbataí em 2019	112
Figura 16 – Precipitação e temperatura médias na sub-bacia do Alto Corumbataí para o período entre 2005 e 2019	113
Figura 17 – Ilustração do funcionamento do algoritmo de deslocamento do ponto médio	115
Figura 18 – Modelos neutros em escala contínua gerados a partir de diferentes valores de <i>roughness</i> pela função <i>nlm_mpd*</i> do pacote <i>NLMR</i>	115
Figura 19 – Representação espacial dos componentes D_{up} e D_{dn} no cálculo do IC pelo modelo SDR do InVEST	118

Figura 20 – Localização das estações pluviométricas e pontos CHIRPS utilizados para obtenção de dados de precipitação.....	123
Figura 21 – Fator erosividade da chuva (R) para a sub-bacia do Alto Corumbataí no período entre 2005 e 2019.....	125
Figura 22 – Erodibilidade do solo (K) na sub-bacia do Alto Corumbataí.....	126
Figura 23 – Fator comprimento da rampa e declividade (LS) para a sub-bacia do Alto Corumbataí.....	128
Figura 24 – Fatores de uso e manejo do solo e práticas conservacionistas (CP) para a sub-bacia do Alto Corumbataí no ano de 2019.....	130
Figura 25 – Hidrografia gerada pelo InVEST comparada à hidrografia mapeada da sub-bacia do Alto Corumbataí.....	131
Figura 26 – Delineamento da geração de paisagens artificiais a partir do algoritmo de deslocamento do ponto médio para a sub-bacia do Alto Corumbataí.....	141
Figura 27 – Ilustração da geração de paisagens planejadas para a sub-bacia do Alto Corumbataí em que a floresta (preto) se concentra em faixas ripárias de diferentes larguras	142
Figura 28 – Ilustração da geração de paisagens planejadas para a sub-bacia do Alto Corumbataí em que a floresta (preto) se concentra nas áreas de maior declividade	143
Figura 29 – Valores observados (barras) e simulados (linhas) da carga anual de sedimentos na sub-bacia do Alto Corumbataí para diferentes valores do parâmetro de calibração k_b e $IC0 = 0,5$	157
Figura 30 – Valores observados (barras) e simulados (pontos) da carga anual de sedimentos na sub-bacia do Alto Corumbataí para diferentes valores dos parâmetros de calibração k_b e $IC0$	158
Figura 31 – <i>Dotplot</i> de Cleveland ilustrando a carga anual calculada a partir de dados mensurados de qualidade da água na sub-bacia do Alto Corumbataí.....	159
Figura 32 – Valores observados (barras) e simulados (pontos) da carga anual de sedimentos na sub-bacia do Alto Corumbataí considerando $k_b = 1,3$ e $IC0 = 2$	160
Figura 33 – Ajuste entre dados simulados e observados de produção de sedimentos considerando $k_b = 0,8$ e $IC0 = 0,25$	161
Figura 34 – Perda potencial de solo anual (2019) por pixel calculada por meio da RUSLE para a sub-bacia do Alto Corumbataí.....	163
Figura 35 – Produção de sedimentos anual (2019) por pixel calculada pelo modelo SDR para a sub-bacia do Alto Corumbataí.....	163

Figura 36 – Proporção da perda de solo por pixel que atinge a água (2019) calculada pelo modelo SDR para a sub-bacia do Alto Corumbataí	164
Figura 37 – Histogramas da produção de sedimentos para paisagens de modelos neutros e planejadas	165
Figura 38 – <i>Boxplot</i> e médias (ponto vermelho) da produção de sedimentos para paisagens de modelos neutros e planejadas	166
Figura 39 – Índice de conectividade para o solo exposto calculado pelo modelo SDR para a sub-bacia do Alto Corumbataí.....	167
Figura 40 – Carga anual de sedimentos por largura de faixa ripária florestal (A) e porcentagem da bacia coberta por florestas por largura de faixa ripária florestal (B) para as paisagens do grupo PRipária	168
Figura 41 – Carga anual de sedimentos por declividade inicial (A) e porcentagem da bacia coberta por florestas por declividade inicial (B) para as paisagens do grupo PDeclividade..	169
Figura 42 – Produção de sedimentos (tons/ano) por porcentagem de floresta na bacia hidrográfica para os grupos de paisagens de modelos neutros e planejadas	171
Figura 43 – Gráficos de violino e medianas (pontos pretos) das cargas anuais das paisagens (A) MN e (B) MNRipária por porcentagem de floresta	172
Figura 44 – Gráficos de violino e medianas (pontos pretos) das cargas anuais das paisagens (A) MN e (B) MNRipária por valor de autocorrelação espacial (<i>roughness</i>).....	173
Figura 45 – Gráfico de densidade das cargas anuais das paisagens (A) MN e (B) MNRipária por porcentagem de floresta em relação à média (linha vermelha).....	174
Figura 46 – Gráfico de densidade das cargas anuais das paisagens (A) MN e (B) MNRipária por valor de autocorrelação espacial (<i>roughness</i>) em relação à média (linha vermelha).....	175
Figura 47 – Suavizador LOESS adicionado à relação entre proporção de floresta e carga anual nas paisagens (A) MN – escala de bacia hidrográfica, (B) MNRipária, e (C) MN – escala de zona ripária	176
Figura 48 – Médias e desvios padrão das cargas anuais das paisagens (A) MN e (B) MNRipária por porcentagem de floresta	177
Figura 49 – Médias e desvios padrão das cargas anuais das paisagens (A) MN e (B) MNRipária por valor de autocorrelação espacial (<i>roughness</i>)	178
Figura 50 – Mapa de calor das médias das cargas anuais (tons) por porcentagem de floresta e rugosidade para as paisagens MN (A) e MNRipária (B).....	179

Figura 51 – <i>Boxplots</i> das cargas anuais das paisagens (A) MN e (B) MNRipária para cada nível de autocorrelação espacial de acordo com diferentes classes de porcentagem de floresta	181
Figura 52 – <i>Boxplots</i> das cargas anuais das paisagens (A) MN e (B) MNRipária para cada classe de porcentagem de floresta de acordo com diferentes níveis de autocorrelação espacial	182
Figura 53 – Tamanhos de efeito e intervalos de confiança a 95% (barras de erro) da autocorrelação espacial por classes de porcentagem de floresta.....	183
Figura 54 – Tamanhos de efeito e intervalos de confiança a 95% (barras de erro) da porcentagem de floresta por níveis de autocorrelação espacial	184
Figura 55 – Correlações de Spearman entre métricas de paisagem em nível de classe e paisagem com a carga anual de sedimentos para os grupos MN e MNRipária	185
Figura 56 – Gráficos de dispersão das métricas em nível de classe que tiveram correlação (ρ) média ou forte com as cargas anuais das paisagens MN e que não correlacionaram fortemente com a porcentagem de floresta.....	189
Figura 57 – Gráficos de dispersão das métricas em nível de classe e paisagem (CONTAG) que tiveram correlação (ρ) média ou forte com as cargas anuais das paisagens MNRipária e que não correlacionaram fortemente com a porcentagem de floresta	191
Figura 58 – Gráfico de dispersão e estimador LOESS para a métrica SHAPE_AM vs. as cargas anuais das paisagens (A) MN e (B) MNRipária	192
Figura 59 – Gráficos de dispersão da métrica SHAPE_AM vs. as cargas anuais das paisagens MNRipária por porcentagem de floresta.....	193
Figura 60 – Correlações de Spearman entre métricas de paisagem em nível de classe e paisagem com a carga anual de sedimentos calculadas por percentuais de floresta para os grupos MN e MNRipária	194
Figura 61 – Correlações de Spearman entre métricas de paisagem e carga de sedimentos para as paisagens MN por percentuais de floresta	195
Figura 62 – Correlações de Spearman entre métricas de paisagem e carga de sedimentos para as paisagens MNRipária por percentuais de floresta	196
Figura 63 – Gráficos de dispersão e suavizadores LOESS para a métrica PLADJ vs. as cargas anuais das paisagens MN do grupo geral (A) e por percentuais de floresta (B).....	200
Figura 64 – Erro de predição (OOB) em função do número de árvores de regressão nas florestas aleatórias das paisagens MN (A) e MNRipária (B).....	202

Figura 65 – Importância das métricas da cobertura florestal para a predição das cargas anuais (tons) das paisagens MN	203
Figura 66 – Importância das métricas da cobertura florestal para a predição das cargas anuais (tons) das paisagens MNRipária.....	204
Figura 67 – Árvore de regressão para a variável dependente produção de sedimentos ($\text{tons}\cdot\text{ha}^{-1}\cdot\text{ano}^{-1}$) em função das métricas de paisagem para o grupo MN	205
Figura 68 – Representação dos seis grupos homogêneos de paisagens MN obtidos pela divisão binária recursiva realizada pela árvore de regressão.....	207
Figura 69 – Árvore de regressão para a variável dependente produção de sedimentos ($\text{tons}\cdot\text{ha}^{-1}\cdot\text{ano}^{-1}$) em função das métricas de paisagem para o grupo MNRipária.....	208

LISTA DE QUADROS

Quadro 1 – Expressões booleanas utilizadas na busca dos trabalhos científicos na etapa de revisão sistemática.....	48
Quadro 2 – Critérios de elegibilidade para seleção dos estudos da revisão sistemática	51
Quadro 3 – Parâmetros de qualidade da água analisados na síntese dos dados da revisão sistemática	57
Quadro 4 – Classes de uso e cobertura do solo analisadas na síntese dos dados da revisão sistemática	59
Quadro 5 – Métricas de paisagem empregadas pelos estudos incluídos na revisão sistemática	61
Quadro 6 – Características dos estudos incluídos na revisão sistemática	66
Quadro 7 – Dados de entrada e parâmetros utilizados na calibração do modelo SDR	132
Quadro 8 – Dados de entrada e parâmetros do modelo SDR utilizados no experimento de simulação	144
Quadro 9 – Métricas de paisagem empregadas para quantificar a composição e configuração das paisagens geradas no experimento de simulação	146
Quadro 10 – Algoritmos de divisão binária recursiva aplicados a árvores de regressão (algoritmo 1) e florestas aleatórias (algoritmo 2)	151
Quadro 11 – Sinal e magnitude das correlações de Spearman entre métricas e produção de sedimentos para todas as paisagens (Geral) e para classes de percentual de floresta (Perc.).	197

LISTA DE TABELAS

Tabela 1 – Resultados da busca por estudos da revisão sistemática da literatura	65
Tabela 2 – Número de estudos da revisão sistemática por periódico	68
Tabela 3 – Proporção das classes de relevo na sub-bacia do Alto Corumbataí.....	111
Tabela 4 – Estações de monitoramento pluviométrico utilizadas para obtenção de dados de precipitação.....	122
Tabela 5 – Coordenadas dos pontos utilizados para obtenção da precipitação da base de dados CHIRPS	123
Tabela 6 – Valor do fator erodibilidade do solo (K) atribuído às classes de solo na sub-bacia do Alto Corumbataí	126
Tabela 7 – Valores dos fatores C e P atribuídos a cada classe de uso e cobertura do solo na área de estudo	129
Tabela 8 – Classificação do desempenho do modelo SDR considerando os indicadores <i>NSE</i> , <i>Pbias</i> , <i>RSR</i> e <i>R²</i>	137
Tabela 9 – Cinco melhores combinações de k_b e $IC0$ que levaram a um ajuste ao menos satisfatório entre as cargas anuais simuladas pelo InVEST e as observadas.....	161
Tabela 10 – Estatísticas descritivas e intervalos de confiança para a média da produção de sedimentos (tons/ano) para os grupos de paisagens de modelos neutros e planejadas.....	167
Tabela 11 – Produção de sedimentos para os grupos de paisagens de modelos neutros e planejadas considerando uma quantidade fixa (20%) de floresta na bacia hidrográfica.....	170
Tabela 12 – Tamanhos de efeito e intervalos de confiança a 95% da proporção de floresta e da rugosidade nas cargas anuais das paisagens MN e MNRipária	180
Tabela 13 – Correlações de Spearman da porcentagem de florestas e rugosidade com as métricas que apresentaram correlação média e forte com a produção de sedimentos para as paisagens MN e MNRipária	186

LISTA DE ABREVIATURAS E SIGLAS

AEE	Área sob efeito de borda
AI	Índice de agregação
ANA	Agência Nacional de Águas
ANOVA	Análise de variância
APA	Área de Proteção Ambiental
APPS	Proximidade da mancha até o riacho
AREA	Área da mancha
ASCII	<i>American Standard Code for Information Interchange</i>
CETESB	Companhia Ambiental do Estado de São Paulo
CHIRPS	<i>Climate Hazards Group InfraRed Precipitation with Station data</i>
CIRCLE	Círculo circunscrito relacionado
CLUMPY	Índice de aglomeração
COHESION	Índice de coesão de manchas
CONTAG	Índice de contágio
CONTIG	Índice de contiguidade
DAEE	Departamento de Águas e Energia Elétrica
DBO	Demanda Bioquímica de Oxigênio
DFS	Distância média da floresta até o riacho
DIVISION	Índice de divisão da paisagem
DQO	Demanda Química de Oxigênio
ECON	Índice de contraste de borda
ED	Densidade de borda
EI	Índice de erosividade
ENN	Distância euclidiana do vizinho mais próximo
FC/FS	Razão coliformes fecais/estreptococos fecais
FF	Fragmentação da floresta - Índice de Matheron
FP	Posição da floresta – próxima, intermediária, distante
FRAC	Índice de dimensão fractal
GYRATE	Raio de rotação
IAC	Instituto Agrônomo de Campinas
IBI	Índice de Integridade Biótica

IC	Índice de Conectividade
IJI	Índice de intercalação e justaposição
INVEST	<i>Integrated Valuation of Ecosystem Services and Tradeoffs</i>
IPD	Inverso da Potência da Distância
LASSO	<i>Least absolute shrinkage and selection operator</i>
LD	Distância da maior mancha
LOESS	<i>Locally weighted regression</i>
LPI	Índice da maior mancha
LSI	Índice de forma da paisagem
LULC	Uso e cobertura do solo
MDE	Modelo Digital de Elevação
MESH	Tamanho efetivo da malha
MN	Paisagens de modelos neutros
MNRipária	Paisagens planejadas com uma combinação de paisagens de modelos neutros e faixa ripária florestal fixa de 30 m
MPD	<i>Midpoint displacement</i>
MPE	Comprimento de borda médio
MUSLE	Equação modificada de perda de solo
NLSI	Índice de forma da paisagem padronizado
NP	Número de manchas
NSE	Coefficiente de eficiência de Nash-Sutcliffe
OOB	<i>Out-of-bag</i>
PA	Área da mancha
PAFRAC	Dimensão fractal perímetro-área
PARA	Razão perímetro-área
Pbias	Porcentagem de viés
PCJ	Piracicaba, Capivari e Jundiaí
PD	Densidade de manchas
PDeclividade	Paisagens planejadas com valores progressivos de cobertura florestal nas áreas de maior declividade
PLADJ	Porcentagem de adjacências semelhantes
PLAND	Porcentagem da paisagem
PRD	Densidade de riqueza de manchas

PRipária	Paisagens planejadas com valores progressivos de faixa ripária florestal
PRISMA	<i>Preferred Reporting Items for Systematic Reviews and Meta-Analyses</i>
PSA	Pagamentos por Serviços Ambientais
RMSE	Raiz do erro quadrático médio
RSR	Razão da raiz do erro quadrático médio pelo desvio padrão dos dados observados
RUSLE	Equação revisada de perda de solo
SDR	<i>Sediment Delivery Ratio</i>
SHAPE	Índice de forma
SHDI	Índice de diversidade de Shannon
SHEI	Índice de equabilidade de Shannon
SIG	Sistema de informação geográfica
SIRGAS	Sistema de Referência Geocêntrico para as Américas
SPLIT	Índice de cisão
SWAT	<i>Soil Water Assessment Tool</i>
TCA	Área central total
TE	Comprimento de borda total
TNC	<i>The Nature Conservancy</i>
UGRHI	Unidade de Gerenciamento de Recursos Hídricos
USLE	Equação universal de perda de solo
UTM	<i>Universal Transverse Mercator</i>
VIF	Fator de inflação da variância
WEPP	Water Erosion Prediction Project
WWF	<i>World Wildlife Fund</i>

SUMÁRIO

INTRODUÇÃO DA TESE	31
CAPÍTULO 1	35
REVISÃO SISTEMÁTICA DA LITERATURA SOBRE A RELAÇÃO ENTRE PADRÃO DA PAISAGEM E QUALIDADE DA ÁGUA	35
1 INTRODUÇÃO	35
1.1 Referencial teórico	36
1.1.1 Métricas de paisagem como descritores do padrão espacial	37
1.1.2 Provisão dos serviços hidrológicos em diferentes usos e coberturas do solo	40
2 MATERIAL E MÉTODOS	45
2.1 Definição da pergunta, termos de busca e bases de dados	47
2.2 Triagem dos estudos	48
2.3 Extração dos dados	51
2.4 Síntese e apresentação dos resultados	56
3 RESULTADOS	65
3.1 Características dos estudos incluídos	66
3.2 Características do conjunto de dados	71
3.3 Teste do sinal	72
3.4 Importância relativa de métricas de composição e configuração.....	75
3.5 Limiares ecológicos	76
3.6 Escalas espaciais de bacia hidrográfica e <i>buffer</i>	77
3.7 <i>Buffers</i> de diferentes larguras.....	78
3.8 Influência de variáveis sazonais.....	79
3.9 Influência de outros fatores físicos	80
4 DISCUSSÃO	85
5 CONCLUSÃO.....	95
CAPÍTULO 2	97
INFLUÊNCIA DA COMPOSIÇÃO E CONFIGURAÇÃO DA PAISAGEM NA PRODUÇÃO DE SEDIMENTOS: UM EXPERIMENTO DE SIMULAÇÃO	97
1 INTRODUÇÃO	97
1.1 Referencial teórico	99
1.1.1 Modelos neutros de paisagem.....	100
1.1.2 Modelo de produção de sedimentos.....	103

2 MATERIAL E MÉTODOS.....	109
2.1 Área de estudo	109
2.2 Modelo neutro de paisagem.....	113
2.3 Modelo de produção de sedimentos (<i>Sediment Delivery Ratio</i> – SDR)	115
2.4 Determinação dos dados de entrada do modelo SDR	119
2.4.1 Área de drenagem.....	121
2.4.2 Erosividade da chuva (R).....	121
2.4.3 Erodibilidade do solo (K)	125
2.4.4 Comprimento da rampa e declividade (LS)	126
2.4.5 Coeficientes uso e manejo do solo (C) e práticas conservacionistas (P).....	128
2.4.6 Limiar de acumulação de fluxo, k_b , IC_0 e SDR_{max}	130
2.5 Calibração do modelo SDR	131
2.5.1 Estimativa das cargas médias anuais na bacia hidrográfica	132
2.5.2 Indicadores de avaliação do desempenho do modelo	134
2.5.3 Parametrização e calibração.....	137
2.6 Delineamento experimental das simulações.....	139
2.6.1 Paisagens de modelos neutros.....	139
2.6.2 Paisagens planejadas	141
2.6.3 Cálculo da produção de sedimentos.....	143
2.7 Quantificação do padrão da paisagem	144
2.8 Análise da relação padrão-processo	146
2.8.1 Diferenças entre paisagens de modelos neutros e planejadas.....	147
2.8.2 Diferença nas cargas anuais médias entre as paisagens de modelos neutros com e sem faixa ripária florestal	147
2.8.3 Correlação entre métricas de paisagem e produção de sedimentos em paisagens de modelos neutros	149
2.8.4 Métricas de paisagem como variáveis preditoras da produção de sedimentos	150
3 RESULTADOS.....	157
3.1 Calibração do modelo SDR	157
3.2 Comparação entre paisagens de modelos neutros e paisagens planejadas	164
3.3 Diferença na produção de sedimentos de acordo com a proporção de floresta e autocorrelação espacial.....	171
3.4 Correlação entre produção de sedimentos e métricas de paisagem	184

3.5 Correlação entre produção de sedimentos e métricas de paisagem por percentual de cobertura florestal.....	193
3.6 Métricas de paisagem como variáveis preditoras da produção de sedimentos.....	201
4 DISCUSSÃO	209
5 CONCLUSÃO.....	221
CONSIDERAÇÕES FINAIS.....	223
RECOMENDAÇÕES.....	227
REFERÊNCIAS	229
APÊNDICE A – Parâmetros de qualidade da água	255
APÊNDICE B – Métricas de paisagem	265
APÊNDICE C – Resultados da revisão sistemática	283
APÊNDICE D – <i>Scripts</i> utilizados no experimento de simulação	307
APÊNDICE E – Resultados das análises estatísticas	317

INTRODUÇÃO DA TESE

As alterações no uso do solo provocadas pelo homem para suprir sua demanda por alimento, água, madeira, fibras e combustível têm comprometido a capacidade dos ecossistemas naturais em fornecer serviços ambientais ou ecossistêmicos¹ (FOLEY et al., 2005). Esses serviços podem ser definidos como os benefícios que a humanidade obtém dos ecossistemas (DAILY, 1997), tais como ciclagem de nutrientes, regulação climática, mitigação de enchentes, recreação, entre outros (MEA, 2005). Embora sejam componentes direta e indiretamente condicionantes do bem-estar humano, sua degradação e uso insustentável observados nos últimos anos tendem a se intensificar (MEA, 2005). Os serviços relacionados ao ciclo hidrológico estão particularmente ameaçados por esses impactos. Em 2000, por exemplo, cerca de 80% da população mundial vivia em áreas de alto risco à segurança hídrica (VÖRÖSMARTY et al., 2010). Segundo Rockström et al. (2009), uma grande quantidade de nitrogênio usado na agricultura atinge todos os anos os corpos d'água, impactando a resiliência desses sistemas e exacerbando o risco de uma alteração ambiental drástica. Outros sistemas, como o ciclo do fósforo, a conversão do uso do solo e o consumo de água, também se aproximam de um patamar que não é seguro para garantir o bem-estar humano (ROCKSTRÖM et al., 2009). Alterações nos padrões de aporte de sedimentos ou nutrientes podem levar à redução da claridade da água, à floração de cianobactérias e afetar a abundância de peixes e parasitas (KEELER et al., 2012). Consequentemente, os serviços valorizados pela sociedade que são afetados por esses fatores são impactados, como recursos pesqueiros, navegação, provisão de água potável e geração de energia elétrica (KEELER et al., 2012).

Para reverter esse quadro, os serviços ambientais devem ser considerados pelas políticas, instituições e práticas (MEA, 2005; DAILY et al., 2009), por meio de estratégias que busquem mitigar esses impactos negativos de forma compatível com a manutenção dos benefícios socioeconômicos decorrentes do uso alternativo do solo (FOLEY et al., 2005). Nesse sentido, a política ambiental fornece o arcabouço necessário para controlar esses impactos e garantir a provisão dos serviços ambientais por meio de suas metas e instrumentos regulatórios, econômicos e de comunicação. Apesar desses esforços, a literatura acerca da efetividade dos instrumentos de conservação ainda é escassa, havendo poucas evidências sobre os fatores de falha ou sucesso (CARPENTER et al., 2009; MITEVA; PATTANAYAK; FERRARO, 2012;

¹ Embora alguns autores conceituem esses termos de forma diferente (SHELLEY, 2011), aqui eles serão usados como sinônimos.

MCINTOSH et al., 2017). Um dos motivos para essa disparidade é a escassez de estudos rigorosos direcionados à avaliação dos instrumentos (KLEIJN; SUTHERLAND, 2003; FERRARO et al., 2012; MITEVA; PATTANAYAK; FERRARO, 2012; CURZON; KONTOLEON, 2016). No caso de programas e políticas voltados para a provisão de serviços ambientais, as avaliações de efetividade são ainda mais raras (FERRARO et al., 2012; 2015), sendo que as melhores evidências empíricas nesse sentido têm influenciado pouco o discurso científico e político (FERRARO et al., 2012). No entanto, é essencial que esses instrumentos e práticas sejam implementados e avaliados de forma robusta visando ao aprimoramento de seu desenho e para expandir a base de evidências de como afetam a conservação dos sistemas socioecológicos (CARPENTER et al., 2009; WHITE, 2009; FERRARO et al., 2015; MCINTOSH et al., 2017). Ainda, identificar a efetividade das intervenções e gerir suas incertezas inerentes é um esforço necessário para prevenir retrocessos no financiamento da conservação (ADAMS; GAME; BODE, 2014).

A maioria das avaliações de efetividade que são voltadas para as modificações no uso e cobertura do solo foca na comparação antes/depois da intervenção ou com/sem intervenção (MITEVA; PATTANAYAK; FERRARO, 2012; CURZON; KONTOLEON, 2016). Apesar de utilizar indicadores como taxa de desmatamento e degradação para analisar o impacto das estratégias de conservação, informações sobre a área espacial afetada, a configuração resultante da paisagem e o atingimento de limiares mínimos para provisão dos serviços ambientais continuam sendo pouco contemplados nessas avaliações (MITEVA; PATTANAYAK; FERRARO, 2012). No caso dos instrumentos de proteção dos serviços hidrológicos, considerar somente a quantidade da cobertura florestal se mostra inadequado, visto que tais serviços variam espacialmente e não linearmente (FERRARO et al., 2015). Consequentemente, é imperativo considerar a estrutura espacial das coberturas do solo na avaliação do impacto de uma política direcionada à sua conservação (FERRARO et al., 2015). A compreensão dos aspectos da estrutura espacial que se relacionam com a provisão ou fluxo dos serviços ambientais pode contribuir para a implementação de políticas de conservação mais efetivas (MITCHELL et al., 2015).

A ecologia da paisagem é uma área de conhecimento interdisciplinar que busca estudar “a interação entre o padrão espacial e os processos ecológicos – isto é, as causas e consequências da heterogeneidade espacial através de várias escalas” (TURNER; GARDNER, 2015, p. 2, tradução nossa). Tradicionalmente, esta disciplina tem buscado analisar essa relação padrão-processo-escala com foco na biodiversidade. Recentemente, a pauta dos serviços ambientais tem emergido gradualmente neste campo, possivelmente em razão de sua relevância para a

sociedade e tomada de decisão (WU, 2013a). Devido ao foco na investigação da relação padrão-processo-escala, a ecologia da paisagem pode contribuir para a compreensão do padrão espacial dos serviços hidrológicos identificando quando e como a heterogeneidade do uso e cobertura do solo influencia sua provisão, além de indicar a alocação espacial de intervenções (TURNER; DONATO; ROMME, 2013). Para isso, a disciplina dispõe de métodos e princípios espacialmente explícitos, tais como as métricas de paisagem que podem ser empregadas para realizar comparações temporais e espaciais (MAYER et al., 2016). Um conceito procedente desta disciplina são os “serviços de paisagem”, que amplia o conceito de serviços ambientais de forma a incorporar o paradigma padrão-processo aos atributos valorizados pela sociedade, especialmente em paisagens fragmentadas e multifuncionais (TERMORSHUIZEN; OPDAM, 2009). A adoção desse conceito pode permitir uma coprodução de conhecimento direcionada a subsidiar o planejamento colaborativo em paisagens locais, onde a tomada de decisão ocorre (TERMORSHUIZEN; OPDAM, 2009).

A ecologia da paisagem tem posição relevante para o desenvolvimento de teorias e metodologias aplicáveis ao planejamento espacial voltado para a conservação (MILOVANOVIĆ; RODIĆ; MARUNA, 2020). A compreensão da conexão entre padrão da paisagem e processos ecológicos permite avaliar como mudanças no uso e cobertura do solo irão afetá-los, o que resulta em relevância direta para a implementação de estratégias como esquemas de certificação, implantação de boas práticas de manejo e Pagamentos por Serviços Ambientais (PSA) (MAYER et al., 2016). Este último, por exemplo, tem se tornado popular entre tomadores de decisão e profissionais da conservação (MURADIAN et al., 2010). Conseqüentemente, espera-se que esses programas, notadamente aqueles com financiamento público, distribuam adequadamente as suas ações na paisagem de forma a favorecer a geração dos serviços desejados.

Nesta direção, questões que podem ser respondidas de forma a subsidiar o desenho de paisagens heterogêneas para a provisão de serviços ambientais são: quais características e elementos devem ser manejados e em que local da paisagem eles devem ser implantados para sustentar o fornecimento dos serviços (JONES et al., 2012). Um conjunto de evidências baseadas em pesquisas teóricas, empíricas e de modelagem derivadas da ecologia da paisagem pode contribuir para a compreensão da influência desses padrões espaciais (EIGENBROD, 2016). Entretanto, a base de evidências sobre a relação entre padrão da paisagem e serviços ambientais, especialmente os hidrológicos, ainda não se encontra consolidada na literatura (JONES et al., 2012; QIU, 2019).

Diante dos questionamentos acerca da efetividade dos instrumentos de política ambiental voltados para a conservação dos serviços hidrológicos, e a lacuna de pesquisa sobre a influência da estrutura da paisagem na provisão desses serviços, os objetivos desta pesquisa foram direcionados a compreender quais aspectos do padrão da paisagem se relacionam com a qualidade da água. Mais especificamente, a motivação desta pesquisa foi contribuir para o conhecimento sobre os efeitos que a composição e a configuração exercem na qualidade da água de forma a subsidiar instrumentos de planejamento e gestão aplicados em escala de paisagem.

Para isso, a investigação foi baseada no arcabouço teórico-metodológico da ecologia da paisagem e conduzida utilizando duas abordagens de pesquisa que podem contribuir para esse objetivo: i) uma revisão sistemática da literatura, um método robusto que fornece uma síntese da evidência disponível sobre uma determinada pergunta de pesquisa, ii) simulação e modelagem, em que é possível desenvolver réplicas de paisagens e controlar variáveis de confusão de forma a avaliar a influência da estrutura da paisagem em um processo de interesse. Dessa forma, espera-se que os resultados obtidos a partir desses dois procedimentos de pesquisa acrescentem ao corpo de evidências sobre a relação entre padrão da paisagem e qualidade da água de forma a subsidiar desenhos mais efetivos de instrumentos de conservação dos serviços ambientais hidrológicos.

A tese está dividida em dois capítulos, sendo o primeiro destinado a i) identificar as evidências na literatura sobre a relação entre padrão da paisagem e qualidade da água, bem como a influência de fatores espaciais, sazonais e físicos nessa relação padrão-processo; e o segundo a ii) avaliar a influência da quantidade e configuração das florestas nas escalas de bacia hidrográfica e zona ripária na produção de sedimentos utilizando paisagens simuladas e modelagem. Os resultados e discussões dos capítulos 1 e 2 forneceram reflexões e evidências que foram retomadas em uma seção de considerações finais e confrontadas com a motivação da pesquisa.

CAPÍTULO 1

REVISÃO SISTEMÁTICA DA LITERATURA SOBRE A RELAÇÃO ENTRE PADRÃO DA PAISAGEM E QUALIDADE DA ÁGUA

1 INTRODUÇÃO

Os ecossistemas associados aos recursos hídricos fornecem diversos bens e serviços essenciais para o bem-estar humano, tais como a provisão de água potável e alimento, regulação da vazão e infiltração da água, drenagem e irrigação natural, proteção contra enchentes, retenção do solo e prevenção da erosão e sedimentação dos corpos d'água, proteção dos aquíferos contra a salinização, recreação, paisagens cênicas, usos religiosos e culturais, entre outros (COSTANZA et al., 1997; DE GROOT et al., 2002; HEIN et al., 2006; BRAUMAN et al., 2007). Esses serviços são influenciados por atributos hidrológicos de quantidade, qualidade, localização e temporalidade do fluxo que, por sua vez, são modulados pelos processos executados pelos diversos ecossistemas presentes na área de contribuição da bacia hidrográfica (BRAUMAN et al., 2007).

A conversão dos ecossistemas naturais em usos do solo de manejo intensivo afeta a provisão desses serviços ambientais na bacia hidrográfica (MARTÍNEZ et al., 2009; DE GROOT et al., 2010), pois modifica as propriedades, processos e componentes que os geram (DE GROOT et al., 2010). Quando a área da bacia hidrográfica se torna dominada por usos mais intensivos como a agricultura, a exportação de nutrientes, sedimentos e agroquímicos é intensificada (CULLEN, 2007). Para reverter esse quadro, os serviços ambientais devem ser incorporados às políticas, instituições e práticas (MEA, 2005; DAILY et al., 2009), por meio de estratégias que busquem mitigar esses impactos negativos de forma compatível com a manutenção dos benefícios socioeconômicos decorrentes do uso alternativo do solo (FOLEY et al., 2005).

Devido à sua relevância para a sociedade e tomada de decisão, os serviços ambientais têm sido incorporados gradualmente na ecologia da paisagem (WU, 2013a) por meio de conceitos como a sustentabilidade da paisagem. Segundo Wu (2013b, p. 1013, tradução nossa), esse conceito é definido como a “capacidade de uma paisagem em fornecer consistentemente serviços ecossistêmicos específicos de paisagem e de longo prazo, essenciais para manter e melhorar o bem-estar humano em um contexto regional, apesar das mudanças ambientais e socioculturais”. Nesse sentido, a ecologia da paisagem tem o potencial de subsidiar o desenho

de paisagens heterogêneas capazes de prover múltiplos serviços ambientais (JONES et al., 2012; WU, 2013a), pois dispõe de princípios e métodos espacialmente explícitos (WU, 2013a; MAYER et al., 2016). Ao estudar a relação padrão-processo é possível compreender a estrutura espacial dos serviços hidrológicos e apontar quando e como a heterogeneidade do uso do solo influencia sua provisão, além de indicar o posicionamento de elementos da paisagem para maximizar a provisão dos serviços (JONES et al., 2012; TURNER; DONATO; ROMME, 2013). O conhecimento sobre a relação padrão-processo é uma das questões centrais de pesquisa em sustentabilidade da paisagem (WU, 2021). A partir disso, é possível subsidiar o planejamento e desenho da paisagem de forma a maximizar suas múltiplas funcionalidades (NASSAUER; OPDAM, 2008; WU, 2021). Todavia, pouco se sabe sobre como o padrão da paisagem se relaciona com a provisão dos serviços hidrológicos, pois os resultados presentes na literatura são mistos e escassos (JONES et al., 2012; VERHAGEN et al., 2016).

Perante o exposto, o **objetivo geral** deste capítulo foi identificar as evidências na literatura sobre a relação entre padrão da paisagem e qualidade da água, bem como a influência de fatores espaciais, sazonais e físicos. Para isso foi empregada uma revisão sistemática da literatura, método metódico para produzir sínteses da informação disponível sobre uma determinada pergunta de pesquisa (LAU; ROTHSTEIN; STEWART, 2013) e capaz de gerar uma base de evidências adequada para a tomada de decisão em conservação (WOODCOCK; PULLIN; KAISER, 2014). Os **objetivos específicos** foram:

- 1) Prover um panorama das pesquisas sobre o assunto;
- 2) Sintetizar quantitativa e qualitativamente as relações entre indicadores de qualidade da água e métricas de paisagem;
- 3) Verificar a importância relativa da composição e configuração para a qualidade da água;
- 4) Investigar a existência de limiares para a qualidade da água;
- 5) Avaliar como diferentes escalas espaciais podem modular a relação padrão-processo;
- 6) Levantar a influência de variáveis sazonais e fatores físicos na relação padrão-processo.

1.1 Referencial teórico

Este capítulo baseia-se na revisão de estudos que procuraram relacionar as quantidades de coberturas e seus arranjos espaciais em uma determinada escala com parâmetros diversos de qualidade da água. O padrão da paisagem foi mensurado por meio de métricas, que são

conceituadas a seguir. Além disso, é apresentada uma breve revisão de como os diferentes usos e coberturas do solo se relacionam com a provisão dos serviços hidrológicos dependentes da qualidade da água.

1.1.1 Métricas de paisagem como descritores do padrão espacial

A abordagem metodológica da ecologia da paisagem contemplada neste trabalho deriva principalmente da escola ecológica ou norte-americana, que apresenta algumas diferenças em relação à escola geográfica, também chamada de europeia. Ambas as abordagens foram inspiradas pelas primeiras definições de ecologia da paisagem, no entanto, a geográfica se desenvolveu a partir de uma perspectiva da paisagem mais holística e centrada na sociedade, com vistas principalmente ao ordenamento territorial (WU; HOBBS, 2007). Por outro lado, a escola ecológica tem suas origens na ecologia de ecossistemas e foca no estudo de paisagens visando à conservação da biodiversidade e gestão dos recursos naturais (METZGER, 2001). No entanto, as duas abordagens não podem ser caracterizadas como opostas (WU; HOBBS, 2007), e uma visão contemporânea para a ecologia da paisagem é de uma disciplina transdisciplinar (WU, 2021).

A ecologia da paisagem estuda a relação entre o padrão espacial e os processos ecológicos em múltiplas escalas com foco nos efeitos observados na biodiversidade, funções ecossistêmicas e serviços ambientais (WU, 2021). A sua escala de estudo é definida pelo foco do observador considerando a melhor representação da heterogeneidade da paisagem e dos processos de interesse (TURNER; GARDNER, 2015). A escala depende da resolução e da extensão adotadas e é um conceito crucial para a ecologia da paisagem, visto que a representação da heterogeneidade espacial irá variar de acordo com esses fatores (WU; QI, 2000). Desse modo, é esperado que padrão e processo interajam de formas diversas e causem consequências variadas em diferentes escalas (WIENS, 2002). Três são as principais escalas de mensuração da estrutura da paisagem em estudos relacionados à qualidade da água: bacia hidrográfica, *buffer* de zona ripária, e *buffer* do ponto de coleta das amostras de água (e.g., KING et al. 2005, NASH et al., 2009; DING et al., 2016; SHI et al., 2017). Para os serviços hidrológicos, o padrão na escala de bacia hidrográfica (SYRBE; WALZ, 2012) e na zona ripária (GERGEL et al., 2002) são adequados para serem relacionados com a sua provisão. Ainda que a estrutura espacial na escala de ponto amostral tenha influenciado a qualidade da água em alguns estudos (e.g., DING et al., 2009; NASH et al., 2009), sua consideração no planejamento

dos instrumentos de conservação é controversa, visto que favorece a gestão em nível de propriedade rural em vez da gestão em nível de bacia hidrográfica.

Um dos primeiros modelos descritivos e conceituais para a interpretação da heterogeneidade espacial das paisagens foi desenvolvido na década de 1980 e recebeu a alcunha de “mancha-corredor matriz” (FORMAN; GODRON, 1986). Deste modelo derivam alguns dos métodos utilizados na ecologia da paisagem. Sua proposição é que a heterogeneidade da paisagem pode ser particionada em três elementos: mancha, corredor e matriz. As manchas são áreas homogêneas na paisagem que diferem do ambiente que as circundam, corredores são faixas estreitas que também diferem dos seus arredores, e a matriz é a área extensa e conectada em que esses elementos estão inseridos (TURNER; GARDNER, 2015). Tendo em vista que foi proposto visando à conservação de espécies, o modelo prevê que o arranjo desses elementos irá determinar os fluxos através da paisagem (FORMAN, 1995). Dessa forma, ao reduzir a heterogeneidade em poucos elementos internamente homogêneos e bem delimitados, é possível quantificar o seu arranjo espacial e sua diversidade (LAUSCH et al., 2015). Este modelo teve grande importância para o desenvolvimento da ecologia da paisagem, e sua simplicidade e facilidade de aplicação proporcionada pelas atuais geotecnologias fez com que o paradigma mancha-corredor-matriz fosse transposto para além de seu propósito inicial de conservação de espécies (LAUSCH et al., 2015).

O arcabouço metodológico da ecologia da paisagem dispõe de teorias e métodos espacialmente explícitos. As métricas de paisagem são uma dessas ferramentas, e seu desenvolvimento foi largamente impulsionado pelo modelo mancha-corredor-matriz (LAUSCH et al., 2015). Esses índices espaciais são utilizados para quantificar o padrão, especialmente dos diferentes usos e coberturas do solo – também chamados de classes ou tipos de mancha – em uma paisagem (TURNER; GARDNER, 2015). De acordo com McGarigal (2014), as métricas disponíveis descrevem a estrutura espacial de uma paisagem de forma sumarizada levando em conta duas características principais: a composição e a configuração. A composição computa os tipos e quantidades de classes observadas na paisagem por meio de medidas de abundância proporcional, riqueza, equabilidade e diversidade. Já a configuração mensura o arranjo espacial das classes por meio de medidas de i) área e perímetro; ii) forma, que indica a complexidade das manchas por meio de sua geometria; iii) área central, que é aquela considerada livre do efeito de borda (Cf. Laurance et al., 2011); iv) contraste, que mensura o grau de diferença entre as manchas que se encontram adjacentes na paisagem; e v) agregação, que engloba os aspectos de dispersão de cada classe; intercalação, i.e., mistura de diferentes classes; subdivisão das classes em unidades; e isolamento, i.e., quão distantes as

manchas se encontram. O cálculo das métricas de paisagem a partir de imagens matriciais é obtido principalmente para cada mancha, para cada classe de uso e cobertura do solo (i.e., em nível de classe), ou para a paisagem em geral englobando todas as manchas e classes presentes (i.e., em nível de paisagem). Uma ferramenta amplamente utilizada no cômputo das métricas de paisagem é o programa de acesso gratuito *Fragstats* desenvolvido pelo *Landscape Ecology Lab* da Universidade de Massachussetts-Amherst (MCGARIGAL; CUSHMAN; ENE, 2012). Recentemente, as métricas deste programa, juntamente com outras, foram reimplementadas em um pacote para a linguagem de programação R chamado *landscapemetrics* (HESELBARTH et al., 2021). Alternativas para o cálculo dessas métricas são os plugins para *softwares* de sistemas de informação geográfica (SIG) como o QGIS (e.g., JUNG, 2016).

Os principais determinantes para a seleção de métricas para sumarizar o padrão da paisagem são as motivações e hipóteses do estudo, i.e., quais aspectos do padrão são de interesse e por quê, e quais métricas podem mensurá-los apropriadamente (TISCHENDORF, 2001; MCGARIGAL, 2014; TURNER; GARDNER, 2015; GUSTAFSON et al., 2019). Os índices também devem ter uma relativa amplitude de mensuração e ser independentes entre si (TURNER; GARDNER, 2015). O método de classificação das coberturas, bem como a extensão e resolução espacial das paisagens, também devem ser congruentes com o processo estudado (TURNER; GARDNER, 2015). As métricas de paisagem se baseiam em medidas simples como área, borda e características dos vizinhos, o que faz com que muitas sejam colineares (MCGARIGAL, 2014). Consequentemente, métricas que são utilizadas para mensurar aspectos diferentes (e.g., área, forma e isolamento) na verdade exibem comportamento similar e podem estimar a configuração de forma redundante (NEEL; MCGARIGAL; CUSHMAN, 2004). Além disso, algumas métricas são fortemente influenciadas pela proporção da classe na paisagem (e.g., índice da maior mancha, área das manchas), não fornecendo informação além daquela já provida pela porcentagem da paisagem ocupada pelo tipo de cobertura (NEEL; MCGARIGAL; CUSHMAN, 2004). Um estudo desenvolvido por Cushman, McGarigal e Neel (2008) detectou que poucos componentes são necessários para explicar o padrão da paisagem, portanto, analisar as correlações entre as métricas pode auxiliar na detecção de um subconjunto mais parcimonioso de medidas. Apesar disso, uma única métrica não é capaz de resumir todos os aspectos estruturais da paisagem (WANG; MALANSON, 2007), e índices redundantes podem ter diferentes utilidades dependendo da sua facilidade de interpretação e comunicação (NEEL; MCGARIGAL; CUSHMAN, 2004).

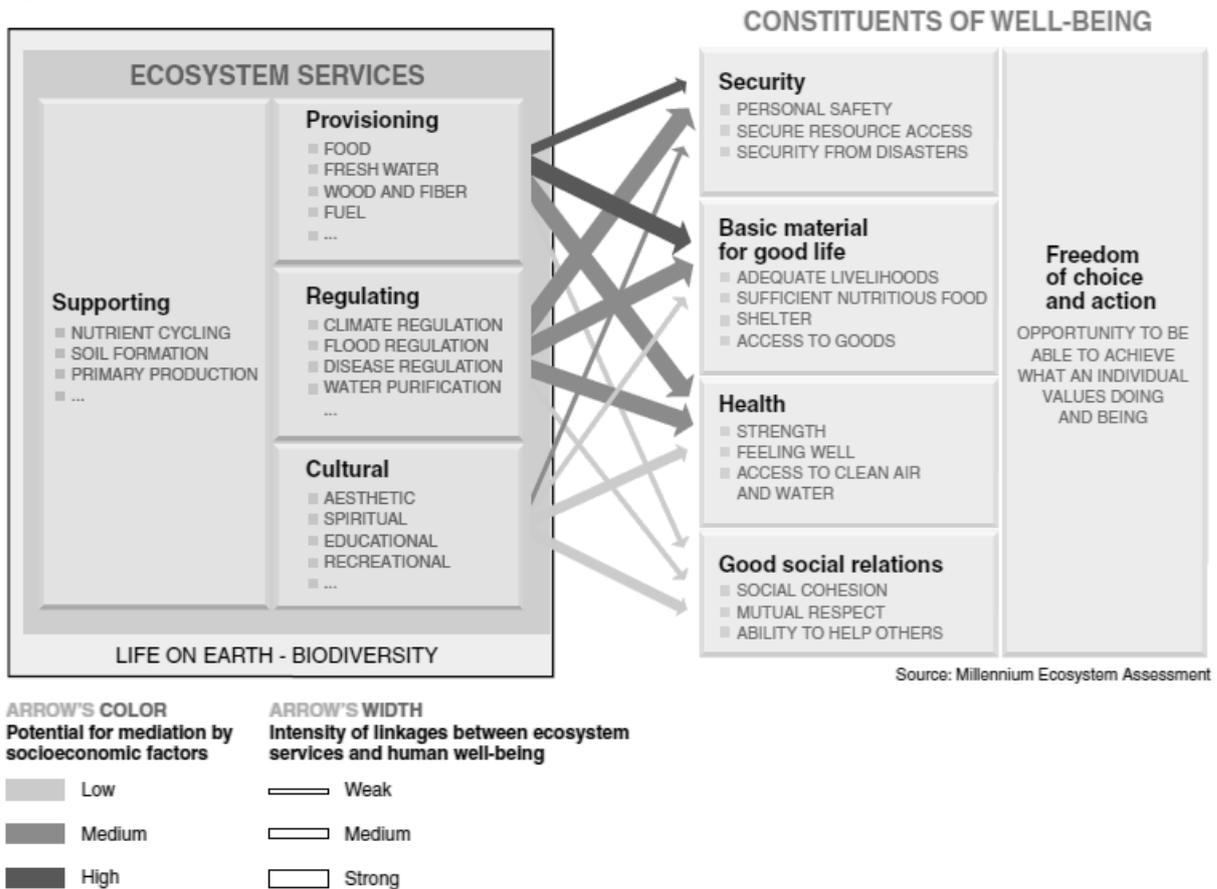
O modelo mancha-corredor-matriz possui algumas fraquezas no que se refere à representação de padrões que são caracterizados melhor por superfícies contínuas em vez de elementos discretos na paisagem (LAUSCH et al., 2015). Outras limitações incluem questionamentos acerca da sua capacidade em representar processos complexos ou mesmo o fato de as métricas transformarem a heterogeneidade em medidas discretas (FRAZIER; KEDRON, 2017). Outras abordagens, como o modelo de gradiente (LAUSCH et al., 2015), ou métricas baseadas em teorias dos grafos, caminhos de menor custo e superfícies de resistência (KUPFER, 2012) podem ser mais adequadas para associar o padrão espacial ao processo de interesse. A adequação de diferentes modelos para retratar a estrutura espacial pode depender do nível de influência antropogênica na paisagem. Paisagens urbanas ou rurais geralmente possuem manchas mais homogêneas e bem delimitadas, podendo então ter sua estrutura representada pelo modelo mancha-corredor-matriz (LAUSCH et al., 2015).

As métricas de paisagem têm potencial para quantificar estruturas espaciais e relacioná-las com os processos ecológicos responsáveis pela geração dos serviços ambientais (SYRBE; WALZ, 2012). No caso dos serviços hidrológicos, métricas como a área total convertida em uso alternativo do solo ou a distância das manchas da rede hidrográfica têm potencial de associação com indicadores de qualidade da água (GERGEL et al., 2002). Outros índices, como densidade de manchas e métricas de contraste, podem ser úteis para a mensuração dos serviços de prevenção à erosão do solo (SYRBE; WALZ, 2012). A real utilidade dessas medidas irá depender da força de associação com a variável resposta, bem como da influência de variáveis de confusão, como as topográficas e climáticas (GERGEL et al., 2002).

1.1.2 Provisão dos serviços hidrológicos em diferentes usos e coberturas do solo

Os serviços ambientais são produzidos pelas funções ecossistêmicas, que são simplificações das complexas interações entre os componentes bióticos e abióticos dos ecossistemas que ocorrem por meio de fluxos de matéria e energia (DE GROOT; WILSON; BOUMANS, 2002). Uma classificação amplamente divulgada desses serviços é a provida por MEA (2005), que os divide em serviços de provisão, de suporte, de regulação e culturais. A Figura 1 apresenta alguns serviços de cada categoria, bem como sua relação com o bem-estar humano.

Figura 1 – Classificação dos serviços ambientais e sua relação com o bem-estar humano



Fonte: MEA (2005).

Os ecossistemas associados aos recursos hídricos fornecem vários serviços ambientais, tais como a provisão de água potável, provisão de alimento, regulação da vazão e infiltração da água, drenagem e irrigação natural, proteção contra enchentes, retenção do solo e prevenção da erosão e sedimentação dos corpos d'água, proteção dos aquíferos contra a salinização, recreação, paisagens cênicas, usos religiosos e culturais, entre outros (COSTANZA et al., 1997; DE GROOT; WILSON; BOUMANS, 2002; HEIN et al., 2006; BRAUMAN et al., 2007). Esses serviços são influenciados por atributos hidrológicos de quantidade, qualidade, localização e temporalidade do fluxo que, por sua vez, são modulados pelos processos realizados pelos diversos ecossistemas presentes na área de contribuição da bacia hidrográfica (BRAUMAN et al., 2007). A quantidade de água disponível à jusante é modulada pelo seu uso, transporte e realocação realizados pelos ecossistemas (BRAUMAN et al., 2007) por meio de processos como a drenagem, tamponamento e regulação da vazão dos rios (DE GROOT; WILSON; BOUMANS, 2002). A cobertura vegetal composta pelas folhas, galhos e serapilheira atua como barreira ao impacto da chuva no solo, facilitando a infiltração gradual e reduzindo o escoamento da água (BRAUMAN et al., 2007). Em geral, a maioria dos ecossistemas, especialmente as

florestas, reduz o volume de água disponível à jusante por causa do processo de transpiração (CULLEN, 2007). Nas florestas, as taxas de infiltração e armazenamento de água no solo são altas, o que torna o regime hidrológico dessas áreas moderado em termos de vazão máxima e vazão de estiagem (NEARY; ICE; JACKSON, 2009). Portanto, a remoção desses ecossistemas está correlacionada com um aumento na vazão (BRUIJNZEEL, 2004; ZHANG et al., 2017), embora, em longo prazo, leve à uma redução durante a estação seca, por causa das taxas de infiltração insuficientes para recarregar os aquíferos (BRUIJNZEEL, 2004). Com a perda de vegetação e consequente aumento da vazão, o risco e frequência de inundações à jusante aumentam, influenciando a ocorrência de eventos catastróficos (BRADSHAW et al., 2007). Ainda, a cobertura vegetal evita a compactação e erosão superficial por meio da estabilização do solo pelas raízes (DE GROOT; WILSON; BOUMANS, 2002; BRUIJNZEEL, 2004; NEARY; ICE; JACKSON, 2009), contribuindo para mitigar deslizamentos causadores de desastres (BRAUMAN et al., 2007).

A qualidade da água é um atributo hidrológico importante não só para a provisão de água potável, mas também para vários outros serviços ambientais. Os ecossistemas terrestres são capazes de adicionar ou remover componentes químicos, patógenos, nutrientes, sais e sedimentos dos fluxos de água (BRAUMAN et al., 2007). Alguns dos processos associados à manutenção da qualidade da água superficial e subterrânea são a diluição, estabilização dos solos, redução na velocidade de infiltração, retenção de poluentes e sedimentos, absorção de nutrientes pelas raízes e transformação bioquímica de resíduos orgânicos e inorgânicos (DE GROOT; WILSON; BOUMANS, 2002; BRAUMAN et al., 2007). Além da estrutura da comunidade vegetal, essas funções também dependem de outros processos realizados pela biota associada (DE GROOT; WILSON; BOUMANS, 2002; BRAUMAN et al., 2007), tal como a desnitrificação exercida por macrófitas aquáticas e micro-organismos (BRAUMAN et al., 2007). As faixas de vegetação (*buffers*) localizadas na área de contribuição de uma bacia são barreiras eficazes aos materiais carregados até os corpos d'água (BRAUMAN et al., 2007), especialmente aquelas associadas à zona ripária (DOSSKEY et al., 2010). Os *buffers* situados em áreas agrícolas podem ajudar a reduzir os impactos negativos dessa prática ao prevenir a erosão do solo pela água ou vento, remover fertilizantes e pesticidas e prover habitat para as espécies (LOVELL; SULLIVAN, 2006). Diante do fato de que as florestas e outros ecossistemas maduros são associados a uma melhor qualidade da água, a proteção e restauração dos mesmos são práticas comumente executadas em planos de proteção e recuperação de corpos hídricos degradados (BRAUMAN et al., 2007; CULLEN, 2007).

As zonas ripárias são áreas de transição entre os ecossistemas terrestres e aquáticos (LAKE, 2007) e mediam a conexão entre a área de drenagem e os corpos hídricos (CULLEN, 2007). Quando vegetadas, essas zonas proveem material vegetal que serve de habitat para os organismos aquáticos, regulam a temperatura da água por meio do sombreamento, filtram o aporte de material no corpo hídrico e protegem suas margens contra a erosão (CULLEN, 2007; LAKE, 2007). Além de prevenir a entrada de poluentes de fontes difusas, em áreas com florestas ciliares há o processamento de uma maior quantidade de matéria orgânica do que em áreas sem esses ecossistemas (SWEENEY et al., 2004). Nesse sentido, por ser uma zona de fronteira entre ecossistemas aquáticos e terrestres, essas faixas vegetadas podem ser bastante eficazes em mitigar os impactos causados pelos usos do solo a montante (CULLEN, 2007). Portanto, a perda e fragmentação dessas áreas compromete a biodiversidade e as funções ecossistêmicas dos corpos hídricos (CULLEN, 2007; LAKE, 2007).

A conversão dos ecossistemas naturais em uso alternativo do solo altera o escoamento superficial, a evapotranspiração e a infiltração na bacia hidrográfica, afetando a rota dos contaminantes até a água (DELKASH; AL-FARAJ; SCHOLZ, 2018). As áreas naturais são consideradas sumidouros, pois são associadas com a retenção dos poluentes, enquanto as coberturas antropogênicas são consideradas fontes de contaminantes (DELKASH; AL-FARAJ; SCHOLZ, 2018). Os poluentes adentram os corpos hídricos via fontes pontuais e difusas, sendo que as primeiras se caracterizam por pontos facilmente identificáveis, como lançamentos de efluentes, enquanto as últimas são de difícil identificação, pois o carreamento dos poluentes é feito através da bacia hidrográfica. Atualmente, a maior fonte de poluição difusa é a agricultura, que em muitos países é considerada o principal fator degradante da qualidade da água (MATEO-SAGASTA; ZADEH; TURRAL, 2017). As atividades agrícolas estão associadas com o aporte de sedimentos nos cursos d'água, bem como com a entrada de contaminantes e nutrientes especialmente via fertilizantes e pesticidas (CULLEN, 2007). O transporte dos contaminantes de forma difusa é feito basicamente pelo fluxo da água na bacia hidrográfica. A precipitação na área urbana está associada a uma maior taxa de escoamento superficial, visto que essas áreas estão impermeabilizadas, o que contribui para o aporte de poluentes difusos na água (DELKASH; AL-FARAJ; SCHOLZ, 2018). Quando a precipitação excede a infiltração, os contaminantes tendem a ser mobilizados, dissolvidos e carregados, podendo atingir a água por meio do escoamento superficial ou pelos fluxos subsuperficial e subterrâneo (ZHANG, 2014).

Diante do exposto, é possível depreender que o uso do solo na bacia hidrográfica é um importante fator mediador da integridade ecológica dos ecossistemas aquáticos, sendo que a cobertura vegetal na área de drenagem determina o volume de água e o tipo de material que

aporta no corpo hídrico (CULLEN, 2007). A conversão dos ecossistemas naturais em usos do solo de manejo intensivo afeta a provisão dos serviços hidrológicos na bacia (MARTÍNEZ et al., 2009; DE GROOT et al., 2010), pois modifica as propriedades, processos e componentes que os geram (DE GROOT et al., 2010). Quando a área da bacia hidrográfica se torna dominada por estes usos mais intensivos, como a agricultura, a exportação de nutrientes, sedimentos e agroquímicos é intensificada (CULLEN, 2007).

Embora esteja claro que a presença de diferentes usos e coberturas do solo na bacia hidrográfica afeta as funções ecossistêmicas dos recursos hídricos, pouco se sabe sobre as características da estrutura da paisagem relacionadas com os serviços ambientais hidrológicos. Turner e Gardner (2015) afirmam que os elementos da paisagem influenciam a integridade dos corpos d'água à medida que atuam como fontes, sumidouros ou transformadores das cargas de nutrientes, sedimentos e poluentes. Por outro lado, os autores destacam que outros fatores como a declividade na bacia e a erodibilidade dos solos podem afetar o aporte de matéria na água. Além disso, as diferentes práticas de manejo executadas nas coberturas também podem influenciar os processos ecológicos. Os serviços ambientais podem apresentar respostas não lineares à perda de cobertura nativa (MITCHELL; BENNETT; GONZALEZ, 2015), o que pode indicar a existência de limiares em que há uma mudança abrupta no estado dos ecossistemas a partir de determinado percentual de cobertura (ANDERSEN et al., 2009). Ainda, há a hipótese de que serviços ambientais que dependem de certo deslocamento de matéria ou energia através das manchas na paisagem possam ser favorecidos por algum nível de fragmentação (MITCHELL; BENNETT; GONZALEZ, 2015). Os efeitos dos usos e coberturas do solo na qualidade da água também podem variar de acordo com a escala analisada, e.g., bacia hidrográfica ou zona ripária (URIARTE et al., 2011). Do ponto de vista da ecologia da paisagem, as evidências mistas e escassas na literatura indicam que ainda são necessários mais estudos para elucidar a relação entre os padrões exibidos pelos ecossistemas na paisagem e os processos hidrológicos em diferentes escalas (JONES et al., 2012; VERHAGEN et al., 2016).

2 MATERIAL E MÉTODOS

A revisão das evidências disponíveis sobre determinado assunto para apoiar a ciência e a prática tem sido popular e útil no campo da medicina, mas escassamente utilizada na conservação (SCOTT; TEAR, 2007). Entretanto, esse tipo de método tem se mostrado eficiente para criar uma base de evidências para subsidiar a tomada de decisão e guiar futuros investimentos (GARG; HACKAM; TONELLI, 2008; PULLIN; KNIGHT; WATKINSON, 2009; BILOTTA; MILNER, BOYD, 2014; WOODCOCK; PULLIN; KAISER, 2014), pois muitas vezes os tomadores de decisão não possuem os recursos e treinamento necessários para interpretar e sintetizar toda a literatura primária para posterior uso (LAU; ROTHSTEIN; STEWART, 2013).

Para isso, revisões sistemáticas da literatura e meta-análises podem ser empregadas. A revisão sistemática visa “coletar evidências que atendam aos critérios de elegibilidade pré-definidos para responder a uma pergunta de pesquisa específica” (CHANDLER et al., 2019, tradução nossa). Tal método é capaz de produzir sínteses e avaliações críticas de toda a informação disponível (LAU; ROTHSTEIN; STEWART, 2013), gerando resultados e conclusões menos enviesados do que uma revisão narrativa, pois esta última nem sempre explicita os critérios de busca e inclusão das evidências (COOK; MULROW; HAYNES, 1997). A revisão sistemática permite avaliar se os efeitos estudados são generalizáveis em diferentes contextos, identificar se há lacunas relativas ao objeto de pesquisa (GARG; HACKAM; TONELLI, 2008; LAU; ROTHSTEIN; STEWART, 2013), além de explorar condições impossíveis de serem analisadas em estudos primários (LAU; ROTHSTEIN; STEWART, 2013). Para fazer recomendações explícitas acerca do desenho de paisagens, Hof e Flather (2007) recomendam que seja capturado o estado da arte sobre a relação padrão-processo-escala estudada.

A técnica de revisão sistemática se caracteriza por (LASSERSON; THOMAS; HIGGINS, 2019, tradução nossa):

- a) especificação a priori de uma pergunta de pesquisa;
- b) clareza sobre o escopo da revisão e quais estudos são elegíveis para inclusão;
- c) fazer todos os esforços para encontrar toda pesquisa relevante e assegurar que questões de viés em estudos sejam considerados;
- d) analisar os estudos incluídos para tirar conclusões com base em todas as pesquisas identificadas de forma imparcial e objetiva.

A meta-análise, uma extensão da revisão sistemática, é uma combinação estatística dos resultados numéricos de um ou mais estudos incluídos (MOHER et al., 2009; DEEKS; HIGGINS; ALTMAN, 2019). Esse método se baseia na extração dos tamanhos de efeito (*effect sizes*) de cada um dos estudos ou resultados, os quais são posteriormente sintetizados em um efeito sumário (*summary effect*), um tipo de “média ponderada” dos efeitos individuais considerando o tamanho amostral de cada estudo (BORENSTEIN et al., 2009), e uma medida de variância (LAU; ROTHSTEIN; STEWART, 2013). O tamanho de efeito é uma estatística que representa a relação entre duas variáveis medidas em uma amostra (LIPSEY; WILSON, 2000; BORENSTEIN et al., 2009). Esse parâmetro pode caracterizar tanto a magnitude quanto a direção da relação (LIPSEY; WILSON, 2000). O coeficiente de correlação de Pearson (r), por exemplo, é um tamanho de efeito que indica ambas as propriedades (DURLAK, 2009). Por outro lado, o coeficiente de determinação (R^2) fornece apenas a magnitude e não a direção (DURLAK, 2009).

A meta-análise permite avaliar com precisão se os resultados de uma revisão sistemática são consistentes e generalizáveis em diferentes escalas espaço-temporais, populações e contextos (GARG; HACKAM; TONELLI, 2008; STEWART, 2010). A opção por essa técnica deve ser feita quando o pesquisador visa sumarizar as evidências da revisão sistemática por meio da estimativa de um tamanho de efeito da relação entre as variáveis estudadas (ROTHSTEIN et al., 2013). A técnica permite explorar a variação, evitando a extrapolação de resultados de contextos específicos (STEWART, 2010). A meta-análise é restrita a resultados quantitativos, e estes devem ser conceitualmente e estatisticamente similares para serem comparados (LIPSEY; WILSON, 2000; BORENSTEIN et al., 2009). Geralmente há uma diversidade inerente aos estudos, o que não necessariamente é um empecilho à análise, mas sim desejável (BORENSTEIN et al., 2009). Porém, em casos como: ausência de tamanhos de efeito, baixa qualidade dos artigos, natureza multivariada da pergunta e desenhos complexos, a meta-análise pode ser de difícil aplicação (ROTHSTEIN et al., 2013). Embora os estudos possam fornecer tamanhos de efeito de naturezas distintas ou mesmo omitir dados, a meta-análise é viável caso haja informação suficiente para estimar ou converter um tamanho de efeito (BORENSTEIN et al., 2009).

Uma revisão sistemática foi conduzida visando atingir o objetivo geral deste capítulo, ou seja, extrair da literatura científica as evidências acerca da relação entre estrutura da paisagem e qualidade da água. Esse processo seguiu as diretrizes e orientações para revisões sistemáticas encontradas em Higgins et al. (2019), CEE (2018) e Bilotta, Milner e Boyd (2014). A primeira referência consiste no “Manual Cochrane para revisões sistemáticas de

intervenções”, um guia para revisão sistemática produzido pela *Cochrane Collaboration*, uma organização de referência na elaboração, organização e disponibilização de revisões sistemáticas sobre intervenções de saúde. A segunda referência é o “Diretrizes para revisão sistemática e síntese de evidências em Gestão Ambiental” produzido pela *Collaboration for Environmental Evidence* (CEE), um guia adaptado à área ambiental.

A revisão sistemática envolve três passos básicos descritos por CEE (2018): o planejamento, a execução e o relato da revisão. O planejamento envolve a elaboração do protocolo de busca, ou seja, o caminho metodológico a ser seguido durante todo o processo e o seu consequente teste em uma amostra. A etapa de execução envolve a busca, triagem, análise crítica, extração de dados e síntese das evidências dos estudos. Finalmente, o relato apresenta a interpretação das evidências, as conclusões da revisão, e as implicações para políticas e para futuras pesquisas.

2.1 Definição da pergunta, termos de busca e bases de dados

A primeira tarefa de uma revisão sistemática é definir a pergunta, ou seja, a questão a ser elucidada. Ela deve ser feita de forma precisa, especificando a população e as condições de interesse (THOMAS et al., 2019). Nesse sentido, a pergunta “Quais características da composição e configuração da paisagem têm sido relacionadas com a qualidade da água?” orientou todo o processo de revisão. Após a definição da pergunta, é preciso especificar os termos ou expressões de busca, bem como as bases de dados a serem investigadas (LEFEBVRE et al., 2019). Foram selecionadas previamente as bases de dados *Scopus* e *Web of Science*, que apresentam uma boa cobertura de periódicos para a área de Ciências Naturais e Engenharia (MONGEON; PAUL-HUS, 2016). O uso de ambas as bases se justifica pela sua complementaridade, visto que quase metade dos periódicos abrangidos pelas duas bases são indexados somente por uma ou outra (MONGEON; PAUL-HUS, 2016). Um teste prévio de termos de busca baseados em referências consultadas foi feito de forma a definir as combinações de palavras-chave mais produtivas para a pesquisa, tendo sido escolhidas as expressões em inglês do Quadro 1. Na base *Scopus* a varredura de estudos foi feita no título, resumo e palavras-chave, ao passo que na base *Web of Science* foi feita por “tópico”.

Quadro 1 – Expressões booleanas utilizadas na busca dos trabalhos científicos na etapa de revisão sistemática

“landscape ecology”	AND	“water quality”
“landscape metrics”		“water quality”
“landscape pattern”		“water quality”
“landscape structure”		“water quality”

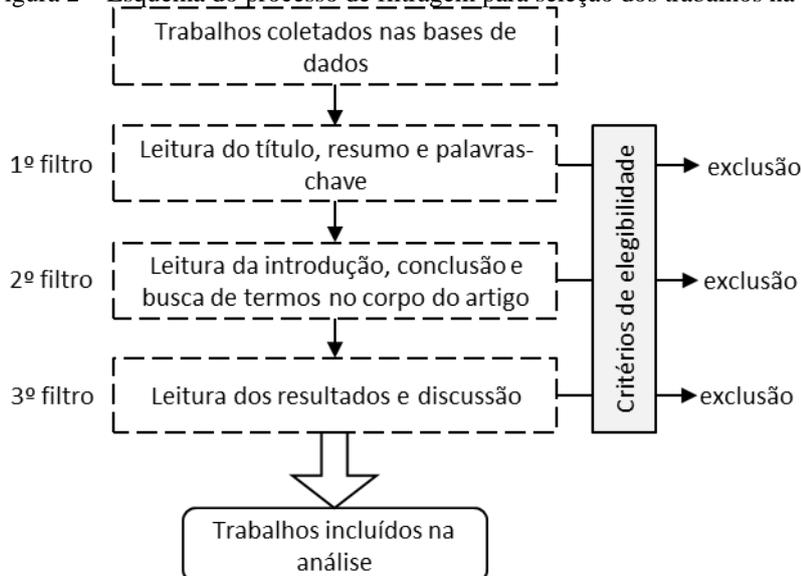
Fonte: elaborado pela autora.

Notas: “” = utilizado para agrupar as palavras, ou seja, a busca será feita pela expressão.

2.2 Triagem dos estudos

Após as buscas nas duas bases de dados, todos os estudos encontrados foram transferidos para um *software* gerenciador de referências a fim de mesclar os registros repetidos. A fase posterior envolveu a triagem dos estudos em etapas de forma a identificar os trabalhos de interesse segundo critérios de elegibilidade, ou seja, critérios que determinam a inclusão ou exclusão do material (LEFEBVRE et al., 2019). Para isso foi adotado um sistema de filtragem para leitura dos estudos em etapas, desde o título, resumo e palavras-chave até a leitura integral do documento (Figura 2). Em cada um dos filtros, cada trabalho foi excluído ou incluído de acordo com os critérios de elegibilidade (Quadro 2). Os resultados desse processo de filtragem foram apresentados em um diagrama baseado na diretriz *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* (PRISMA), que inclui orientações para relatar resultados de revisões sistemáticas e meta-análises (MOHER et al., 2009).

Figura 2 – Esquema do processo de filtragem para seleção dos trabalhos na revisão sistemática



Fonte: elaborado pela autora.

A qualidade da água pode ser definida como “características físicas, químicas e biológicas da água necessárias para sustentar os usos da água desejados” (NIEDERLÄNDER et al., 1996, p. 11, tradução nossa), o que engloba as variáveis mais comuns avaliadas em estudos, como pH, turbidez, nitrogênio e fósforo, sólidos, indicadores biológicos (e.g., macroinvertebrados), entre outros. Desse modo, esse estudo se ateve a esses parâmetros, tendo como base a publicação *Standard Methods for the Examination of Water and Wastewater* (BAIRD; EATON; RICE, 2017), que apresenta e descreve os parâmetros e técnicas adequadas para a análise da qualidade da água.

Com relação ao critério de elegibilidade “análise estatística”, foram excluídos estudos que:

a) Utilizaram como variável dependente ou independente componentes ortogonais obtidos por meio de técnicas de ordenação, visto que o tamanho de efeito é obtido considerando o componente² em vez das variáveis originais;

b) Forneceram resultados de regressões com termos quadráticos, o que indica que a resposta da variável Y em função de X é uma parábola e, portanto, não-monotônica (LEGENDRE; LEGENDRE, 2012);

c) Apresentaram resultados de regressão geograficamente ponderada, pois esta técnica visa explorar a não estacionariedade espacial, ou seja, a variação entre os locais em uma área de estudo (THAPA; ESTOQUE, 2012). Uma equação de regressão é fornecida para cada local onde foram feitas as observações, e são estimados parâmetros locais em vez de globais (THAPA; ESTOQUE, 2012). Portanto, esses parâmetros são úteis para explorar a variação espacial da relação estudada dentro de determinada área de estudo;

d) Apresentaram resultados de análises multivariadas do tipo ordenação ou análise canônica (i.e., Análise de Componentes Principais, Análise de Redundância, Análise de Correspondência Canônica) na forma de *biplots/triplots*. A maioria dos estudos que empregaram essas técnicas proviam apenas o *biplot/triplot* resultante das análises, e alguns poucos forneciam a tabela com as cargas ou correlações das variáveis em relação aos eixos principais. Além disso, nem todos os trabalhos forneceram a variação explicada pelos eixos representados.

Os *biplots/triplots* são representações gráficas geralmente bidimensionais de dados existentes em um espaço multidimensional (GOWER; LUBBE; ROUX, 2011). Pela análise visual do *biplot* é possível entender a relação entre os descritores originais e sua importância na

² O componente é uma nova variável obtida pela combinação linear dos múltiplos descritores originais usados na análise (LEGENDRE; LEGENDRE, 2012).

formação dos eixos principais (LEGENDRE; LEGENDRE, 2012). Os *biplots* geralmente são dimensionados como i) *biplots* de distância (*scaling* 1); e ii) *biplots* de correlação (*scaling* 2) (LEGENDRE; LEGENDRE, 2012). O *biplot* de correlação tem como foco a relação entre as variáveis originais, que são geralmente representadas por vetores (ZUUR; IENO; SMITH, 2007). Neste caso, a covariância ou correlação entre duas variáveis originais pode ser aproximada pelo cosseno do ângulo (0 a 180°) ou, mais precisamente, pelo produto escalar entre os vetores (GRAFFELMAN, 2005). Portanto, um ângulo agudo entre os vetores determina uma correlação positiva, um ângulo obtuso significa correlação negativa, e um ângulo reto indica ausência de correlação (LEGENDRE; LEGENDRE, 2012).

Entretanto, o ângulo extraído a partir do *biplot* é uma projeção dos ângulos reais entre os descritores no espaço multidimensional e podem não refletir com precisão a sua correlação (LEGENDRE; LEGENDRE, 2012). Neste caso, seria importante considerar apenas os descritores bem representados no plano (LEGENDRE; LEGENDRE, 2012). Se os dados foram padronizados, o comprimento do vetor indica quão bem a variável está retratada no espaço bidimensional (ZUUR; IENO; SMITH, 2007). Vetores longos estão bem representados pelo plano, enquanto vetores curtos estão mal representados e devem ser interpretados com cautela (ZUUR; IENO; SMITH, 2007). A qualidade da reprodução das variáveis no *biplot* também faz menção à qualidade da representação bidimensional no geral, ou seja, qual porcentagem da variância nos dados está capturada pelos eixos principais (HÄRDLE; SIMAR, 2015). Caso o *biplot* não retrate bem a variação nos dados, interpretações equivocadas podem ser feitas (HÄRDLE; SIMAR, 2015). Neste caso, não só a magnitude, mas também a direção do tamanho do efeito pode ser incorretamente extraída. Portanto, a obtenção das relações bivariadas a partir de um *biplot* pode ser imprecisa, principalmente quando a variação dos dados não está bem representada. Neste sentido, a melhor solução seria acessar os dados originais ou a respectiva matriz de correlação ou covariância.

Os autores dos artigos que se encaixavam na limitação descrita acima foram contatados por e-mail para envio da matriz de correlação das variáveis analisadas nos estudos. De dez grupos de autores contatados, três disponibilizaram os dados. No caso da não obtenção dessas matrizes, os resultados dessas análises, ou todo o trabalho, foram excluídos da revisão sistemática.

Alguns estudos apresentaram resultados que se encaixavam nos itens acima (a-d), mas foram incluídos pois forneciam dados de outras técnicas estatísticas. Nesse sentido, as informações que se enquadraram nos itens acima foram excluídas da revisão durante o processo de extração dos dados (seção 2.3).

De forma a manter a qualidade dos estudos selecionados, a avaliação crítica foi feita para identificar informações que poderiam estar incorretas (CEE, 2018). Alguns estudos foram excluídos devido à inconsistência, i.e., erros gráficos ou contradição na apresentação dos resultados. No caso de trabalhos divulgados em mais de uma publicação, apenas o registro mais recente foi mantido.

Quadro 2 – Critérios de elegibilidade para seleção dos estudos da revisão sistemática

Aspecto	Critério de inclusão	Critério de exclusão
Idioma	Textos em inglês	Textos em outros idiomas
Acessibilidade	O texto completo do trabalho foi acessado	O texto completo do trabalho não estava disponível
Tipo de documento	Artigos de periódicos e capítulos de livros	Artigos de conferências
Objeto de estudo	Trabalhos originais que analisaram a relação entre estrutura da paisagem e qualidade da água	Trabalhos de revisão; estudos que analisaram outra relação ou processo ecológico
Parâmetros Paisagem	Qualidade da água superficial Paisagens terrestres, rurais, naturais, ou na interface urbano-rural	Qualidade da água subterrânea Paisagens exclusivamente aquáticas, marinhas ou urbanas
Tamanho amostral	O estudo indicou o tamanho amostral utilizado	O estudo não forneceu o tamanho amostral
Classes de uso e cobertura do solo	O trabalho analisou uma classe de cobertura natural do solo do tipo arbóreo-arbustivo	O trabalho não analisou uma classe de cobertura natural do solo do tipo arbóreo-arbustivo; o estudo não diferenciou entre coberturas do solo arbóreo-arbustivas e herbáceas
Escala	Bacia de drenagem e <i>buffers</i> de lagos, reservatórios e rios completos da bacia de drenagem considerada	<i>Buffers</i> de lagos, reservatórios e rios que não correspondem a toda a área de drenagem considerada, <i>buffers</i> de ponto amostral
Mapeamento do padrão da paisagem	Empregou métricas de composição e/ou configuração para as unidades da paisagem	Não empregou métricas de padrão da paisagem
Análise estatística	Utilizou algum método estatístico que permite inferir a relação entre pelo menos uma métrica de paisagem e um parâmetro de qualidade da água, apresentando um tamanho de efeito que indique pelo menos a direção da relação	Não empregou método estatístico que permite inferir a direção da relação entre pelo menos uma métrica de paisagem e um parâmetro de qualidade da água; não forneceu a direção da relação

Fonte: elaborado pela autora.

2.3 Extração dos dados

Após a seleção dos estudos da revisão sistemática é preciso proceder à sua análise, extração dos dados, organização e síntese dos resultados. Embora a meta-análise seja indicada para a sistematização de dados quantitativos, algumas características dos estudos incluídos e seus respectivos resultados impediram a aplicação dessa técnica. Primeiramente, os tamanhos de efeito mais comuns e para os quais os procedimentos de meta-análise estão bem estabelecidos são a diferença de médias, razão de possibilidades (*odds ratio*) e correlação (BORENSTEIN et al., 2009). O coeficiente de correlação de Pearson (r) se mostrou o tamanho de efeito mais adequado à pergunta da revisão sistemática, e diversos trabalhos incluídos empregaram essa medida. No entanto, foi comum o uso de outras técnicas, tanto bivariadas quanto multivariadas, em especial a regressão múltipla. Portanto, houve uma diversidade de tamanhos de efeito além do coeficiente de correlação de Pearson.

Não há um consenso quanto à abordagem universal para lidar com dados de modelos como a regressão múltipla, sendo que alguns autores optam por excluir os estudos que usam essa técnica (ALOE; BECKER, 2012). Por outro lado, é possível computar ou converter para o tamanho de efeito desejado utilizando outras estatísticas fornecidas e equações que já foram propostas para este fim (ALOE; BECKER, 2012; LAJEUNESSE, 2013). No caso da regressão múltipla, os tamanhos de efeito podem ser extraídos da matriz de correlação, que é raramente reportada pelos estudos (LIPSEY; WILSON, 2000). Uma alternativa é utilizar o valor t da variável preditora para obter o coeficiente de correlação parcial (NAGAKAWA; CUTHILL, 2007) ou semiparcial para a variável de interesse (ALOE; BECKER, 2012). Rosenthal e Rubin (2003) fornecem uma medida que permite obter uma correlação equivalente com base apenas no valor- p e no tamanho amostral ou nos graus de liberdade. Entretanto, a maioria dos estudos da revisão sistemática que apresentaram tamanhos de efeito distintos do coeficiente de correlação não forneceram estatísticas como o valor- p , valor t , ou mesmo o erro padrão associado aos coeficientes. Portanto, o cômputo de correlações com base apenas nos resultados reportados pelos estudos se mostrou inviável.

Diante da variabilidade de tamanhos de efeito encontrados e dos empecilhos para seu cômputo e conversão, optou-se por descartar a meta-análise e utilizar outro método estatístico válido para análise quantitativa dos dados. Além disso, devido à natureza exploratória do tópico desta pesquisa, julgou-se que a compilação da direção dos tamanhos de efeito seria suficiente para prover hipóteses sobre a relação padrão-processo que subsidiassem as próximas etapas desta pesquisa. No entanto, os procedimentos da meta-análise para extração e codificação dos resultados foram seguidos sistematicamente.

A codificação das informações sobre os estudos e os tamanhos de efeito é uma forma de capturar a variação entre as pesquisas, que abrange desde características mais gerais até métodos e procedimentos específicos (LIPSEY; WILSON, 2000). Cada estudo incluído na revisão recebeu um identificador (ID), e as seguintes informações foram extraídas: ano de publicação; periódico de publicação; país; localização das áreas de estudo (bem como um par de coordenadas inserido na área); escala de investigação (i.e., bacia de drenagem ou *buffers* de rios ou lagos ou outra área correlata); tamanho amostral (i.e., número de bacias ou de *buffers* de rios ou lagos estudados); área das bacias, os anos de análise dos parâmetros de água; se os dados analisados são primários ou secundários; se o estudo examinou a qualidade da água de rios, lagos, reservatórios, ou áreas úmidas; se a pesquisa considerou diferentes períodos de medição dos parâmetros de água (e.g., estações climáticas); precipitação e temperatura médias na área de estudo; *software* de cálculo de métricas de paisagem usado (e.g., SIGs, *Fragstats*); e técnica estatística empregada para obter os tamanhos de efeito. Além disso, os estudos foram classificados de acordo com a existência de resultados: a) para composição ou configuração da paisagem; e b) para florestas, se relativos à composição ou configuração. Informações como declividade e tipo de solo foram fornecidas por poucos estudos e, portanto, não foram apresentadas na seção de resultados.

Foram extraídos como descritores dos tamanhos de efeito: tamanho amostral, a escala de investigação, o parâmetro de água, a métrica de paisagem e a respectiva classe de uso do solo, o tamanho de efeito ou somente a sua direção, a estação climática ou o subgrupo de medição, e qual a tipologia de efeito e sua unidade (e.g., correlação de Pearson, coeficiente de regressão). Cada tamanho de efeito expressa a relação entre um parâmetro de água e uma métrica de paisagem, focando em sua direção. No que se refere às métricas da paisagem, foram considerados quaisquer usos e coberturas do solo além da cobertura arbórea-arbustiva, incluindo agricultura, pastagem, urbano e florestal. Qualquer resultado que se enquadrasse nos critérios já descritos foi incluído independentemente da sua respectiva significância estatística. No caso de estudos que apresentaram um ou mais testes que descartaram as métricas para a classe de florestas das análises, esses resultados não foram incluídos. No caso de análises idênticas presentes em dois ou mais estudos que também empregaram outros testes, foram extraídos os resultados duplicados de apenas um registro.

A extração dos tamanhos de efeito ocorreu da seguinte forma: Para os testes de correlação foram extraídos os respectivos coeficientes de Pearson (r) e de postos de Spearman (ρ) de cada uma das relações bivariadas. No caso das regressões lineares simples e múltipla, foi extraído o coeficiente de regressão, padronizado (β) ou não (b) associado à variável

independente de interesse. Da mesma forma, para modelos baseados em regressão, tais como modelos lineares mistos e lineares generalizados mistos, também se coletou os coeficientes. Não foram extraídos resultados de interação entre variáveis independentes destes modelos. Para análises com mais de uma variável independente que forneceram mais de um modelo para uma mesma variável dependente, foram compilados os resultados de todos os modelos. Para a técnica de árvore de regressão, a direção do tamanho de efeito foi obtida para cada nó de decisão por meio da comparação das médias da variável resposta de cada um dos grupos resultantes da divisão binária ditada por um limiar da variável preditora.

Uma questão crucial que deve ser definida previamente à síntese estatística dos resultados é a multiplicidade dos tamanhos de efeito (BENDER et al., 2008; LÓPEZ-LÓPEZ et al., 2018). A meta-análise pressupõe que cada estudo forneça um único tamanho de efeito, de forma que os resultados sejam estatisticamente independentes (MENGERSEN; JENNIONS; SCHMID, 2013). Na realidade, pode haver dependência entre os trabalhos ou eles podem fornecer múltiplos resultados não independentes (MENGERSEN; JENNIONS; SCHMID, 2013). Tamanhos de efeito provenientes de amostras que se sobrepõem (ROTHSTEIN et al., 2013) e de estudos desenvolvidos no mesmo local (MENGERSEN; JENNIONS; SCHMID, 2013) são estatisticamente dependentes. Essa multiplicidade fere o pressuposto da independência, que é fundamental para a maioria das análises estatísticas (LIPSEY; WILSON, 2000). Portanto, é preciso eliminar os fatores de multiplicidade de forma a realizar uma combinação estatística dos resultados (LIPSEY; WILSON, 2000) e apresentar de forma transparente os critérios de decisão adotados (LÓPEZ-LÓPEZ et al., 2018). Mesmo que a meta-análise tenha sido descartada neste trabalho, a multiplicidade foi solucionada visto que outro teste estatístico foi utilizado para a síntese dos resultados.

Os casos mais comuns de multiplicidade são: múltiplos grupos, múltiplas variáveis dependentes, múltiplas variáveis independentes, medidas tomadas em tempos diferentes, e estimativas resultantes de técnicas estatísticas distintas (LÓPEZ-LÓPEZ et al., 2018). Embora existam modelos qualificados para lidar com a dependência de dados, como os modelos mistos (HAIR et al., 2019), diversos casos de multiplicidade foram encontrados nos resultados da revisão. Há duas estratégias para lidar com essa questão: reducionista ou integrativa. A abordagem reducionista diminui o volume de dados para o mínimo possível, enquanto a integrativa considera a multiplicidade e a dependência estatística usando técnicas suplementares à meta-análise (LÓPEZ-LÓPEZ et al., 2018). A abordagem reducionista foi escolhida, pois se mostrou apropriada ao método de síntese a ser utilizado (i.e., não meta-análise). Nesta abordagem, um tamanho de efeito é escolhido dentre os múltiplos, o que

aumenta a independência estatística dos dados do conjunto, embora a acurácia e poder estatístico possam ser diminuídos (LÓPEZ-LÓPEZ et al., 2018). A possível não independência entre estudos distintos conduzidos pelo mesmo time de pesquisadores ou em áreas de estudo que poderiam se sobrepor não foi corrigida nesta pesquisa. Portanto, a multiplicidade foi tratada dentro de cada estudo de acordo com os seguintes critérios:

a) Múltiplas variáveis dependentes e independentes e escalas:

Foi comum a representação da qualidade da água por diferentes parâmetros e do padrão da paisagem por diferentes métricas. Considerou-se que todos os resultados dessas variáveis são relevantes, portanto, foi feita uma análise separada para cada variável dependente e independente (LÓPEZ-LÓPEZ et al., 2018).

As análises também foram segmentadas de acordo com a escala espacial analisada, i.e., escala de bacia ou *buffers* dos ambientes aquáticos. No caso de resultados para *buffers* de diferentes larguras, o mais relevante, ou seja, de maior magnitude, foi considerado (LÓPEZ-LÓPEZ et al., 2018). Na ausência da magnitude, foi retido o resultado com menor valor-*p*. Na ausência da significância ou no caso de mesma significância entre os tamanhos de efeito, foi retido aquele obtido na faixa de menor largura.

b) Múltiplos grupos:

Adotou-se o seguinte procedimento no caso de análises com grupos e subgrupos cujas unidades amostrais foram incluídas em mais de um agrupamento, podendo se sobrepor. Para análises feitas com subgrupos independentes, foram mantidos os tamanhos de efeito para cada um deles. No caso de tamanhos de efeito calculados a partir de um grande grupo e subgrupos com sobreposição de unidades amostrais, foi escolhido aquele relativo à maior amostra (LÓPEZ-LÓPEZ et al., 2018). Isso foi feito de forma a reter os resultados obtidos da amostra possivelmente mais heterogênea, indo ao encontro dos outros resultados da revisão que não consideraram subgrupos ou covariáveis.

c) Múltiplas medidas temporais:

Para tamanhos de efeito medidos em uma mesma amostra em diferentes períodos (e.g., anos, estações climáticas), foi escolhido o resultado mais relevante, ou seja, de maior magnitude (LÓPEZ-LÓPEZ et al., 2018). No caso de dois ou mais tamanhos de efeito de mesma magnitude, mas com sinais diferentes, a significância estatística foi selecionada como critério. Quando a significância dos tamanhos de efeito era igual ou não era apresentada, foi então

extraída a média aritmética de todas as medidas temporais nos casos possíveis (i.e., correlações). Para dois ou mais tamanhos de efeitos idênticos, i.e., em termos de magnitude, direção e significância estatística, foi selecionado apenas um de forma aleatória.

Nesse sentido, para análises bivariadas, como correlação e regressão simples, foram escolhidos os resultados com maior $|r|$ e R^2 , respectivamente. Para análises com mais de uma variável independente (e.g., regressões múltiplas, modelos lineares mistos), foi selecionado o resultado do modelo com melhor ajuste ou qualidade com base nos critérios de seleção de modelos fornecidos pelo estudo, e.g., R^2 ajustado, Critério de Informação de Akaike.

d) Múltiplas análises estatísticas e modelos:

Foi escolhido apenas um resultado quando o estudo forneceu tamanhos de efeito calculados a partir de técnicas estatísticas diferentes. López-López et al. (2018) recomendam a seleção da metodologia mais apropriada no contexto da revisão. Portanto, considerou-se as análises bivariadas como prioritárias, especialmente as correlações, cujos tamanhos de efeito são a medida mais comum utilizada por *softwares* e outras ferramentas específicas para meta-análise. A regra de decisão para multiplicidade de técnicas estatísticas seguiu a seguinte ordem: 1) correlações parciais (i.e., Pearson ou Spearman); 2) correlações (i.e., Pearson ou Spearman); 3) regressões simples; 4) regressões múltiplas, modelos lineares mistos ou lineares generalizados mistos; 5) árvores de regressão. No caso de múltiplos modelos, foi adotado o procedimento descrito na alínea anterior.

2.4 Síntese e apresentação dos resultados

Devido à presença de múltiplos parâmetros de qualidade da água e de múltiplas classes de uso e cobertura do solo, algumas decisões foram tomadas para apresentar os dados de forma sintetizada e buscando respeitar o princípio da independência entre os resultados.

O agrupamento dos dados seguiu a seguinte hierarquia: escala (i.e., bacia ou *buffer*), tipo de parâmetro de água, classe de uso e cobertura do solo, e tipo de métrica de paisagem. Os parâmetros de água foram agrupados de acordo com sua semelhança, buscando respeitar a independência estatística dos resultados, mas também visando sintetizar o extenso conjunto de dados. Dessa forma, alguns indicadores foram agrupados na apresentação dos resultados, enquanto outros foram apresentados separadamente (Quadro 3). Resultados de análises de isótopos de nitrogênio ($\delta^{15}\text{N}$, $\delta^{15}\text{N}\text{-NO}_3$, $\delta^{18}\text{O}\text{-NO}_3$) foram incluídos, porém, se o mesmo trabalho fornecia um tamanho de efeito considerando o nitrato ou o nitrogênio total sem

distinção dos isótopos como variável dependente, estes foram retidos e descartaram-se as análises para isótopos. Esse procedimento foi adotado para evitar o cômputo de múltiplos resultados de uma relação métrica-parâmetro por estudo.

No APÊNDICE A são apresentadas as definições de cada parâmetro de qualidade da água e suas unidades de medição, além de eventuais implicações para o ambiente e vida aquática.

Quadro 3 – Parâmetros de qualidade da água analisados na síntese dos dados da revisão sistemática

Grupo de parâmetros	Indicadores incluídos
Compostos de nitrogênio	
Amônia	NH ₃ -N, NH ₄ ⁺ -N
Nitrato	NO ₃ -N, NO ₃ ⁻ -N, NO ₂ ⁺ NO ₃ -N, δ ¹⁵ N-NO ₃ , δ ¹⁸ O-NO ₃
Nitrito	NO ₂ -N, NO ₂ ⁻ -N
Nitrogênio total	Nitrogênio total, nitrogênio Kjeldahl, nitrogênio dissolvido total, razão <i>input/output</i> de nitrogênio, δ ¹⁵ N
Nitrogênio orgânico	Nitrogênio orgânico total, nitrogênio orgânico dissolvido
Compostos de fósforo	
Fósforo total	Fósforo total, fosfato, ortofosfato, razão <i>input/output</i> de fósforo
Fósforo aderido ao sedimento	Fósforo aderido ao sedimento
Fósforo orgânico	Fósforo orgânico
Fósforo solúvel	Fósforo solúvel
Macro/micronutrientes e elementos	
Elementos traço	Alumínio (Al), Berílio (Be), Cádmio (Cd), Ferro (Fe), Chumbo (Pb), Titânio (Ti), Ítrio (Y), Zinco (Zn), Urânio (U), Tálcio (Tl), Selênio (Se), Arsênio (As), Mercúrio (Hg), Bário (Ba), Gálio (Ga), Escândio (Sc), Vanádio (V), Cobre (Cu), Rubídio (Rb)
Cálcio	Cálcio total (Ca)
Potássio	Potássio total (K)
Sódio	Sódio total (Na)
Cloro	Cloro total (Cl), cloreto (Cl ⁻)
Sulfato	Sulfato (SO ₄)
Dióxido de carbono	Dióxido de carbono (CO ₂)
Sólidos	
Sólidos suspensos totais	Sólidos suspensos totais
Sólidos dissolvidos totais	Sólidos dissolvidos totais
Sólidos suspensos orgânicos	Sólidos suspensos orgânicos
Carbono	
Carbono total	Carbono total
Carbono orgânico total	Carbono orgânico total
Carbono inorgânico total	Carbono inorgânico total
DBO	Demanda Bioquímica de Oxigênio
DQO	Demanda Química de Oxigênio

Oxigênio dissolvido	Oxigênio dissolvido
Condutividade	Condutividade
Alcalinidade	Alcalinidade, bicarbonato (HCO ₃)
Salinidade	Salinidade
pH	pH
Temperatura	Temperatura
Cor	Absorbância a 254 nm, absorbância a 420 nm, cor
Turbidez e claridade	Turbidez e profundidade de Secchi (claridade)
Acidez	Acidez
Herbicidas	Metolacloro e atrazina
Óleos e graxas	Óleos
Fenol volátil	Fenol volátil
Biológicos	
Densidade de macroinvertebrados	Densidade da assembleia taxonômica de Coleoptera, Amphipoda, Diptera, Ephemeroptera, Gastropoda, Oligochaeta, Plecoptera e Trichoptera
Índices bióticos	Índice Biótico da Carolina do Norte (<i>NC Biotic Index</i>), Índice Biótico Ephemeroptera, Plecoptera e Trichoptera (<i>EPT Biotic Index</i>), Índice de Diatomáceas do leste do Canadá (<i>Índice Diatomées de l'Est du Canada - IDEC</i>), Índice de Integridade Biótica bentônica (B-IBI), Índice de Integridade Biótica de assembleias de peixes (<i>fish IBI</i>)
Coliformes totais	Coliformes totais - teste presuntivo
Coliformes fecais	Coliformes fecais, enterococos, <i>E. coli</i> , <i>E. coli</i> - teste presuntivo, enterococos - teste presuntivo, razão coliformes fecais/estreptococos fecais
Clorofila a	Clorofila a
Outros parâmetros	
Índice de Potencial Poluidor	Índice de Potencial Poluidor (JOHNSON; MYERS; PATIL, 2001)
Índice de Qualidade da Água	Índice de Qualidade da Água (YUNUS; NAKAGOSHI; IBRAHIM, 2003)

Fonte: elaborado pela autora.

Com relação às métricas de paisagem, os tamanhos de efeito foram agrupados em seis principais classes de uso e cobertura do solo (Quadro 4). A classe “floresta” inclui formações florestais e arbustivas, que podem ser manejadas. Em alguns casos não foi possível identificar se as florestas analisadas nos trabalhos eram formações naturais ou seminaturais, manejadas ou não. A classe “agricultura” engloba todo tipo de área cultivada, inclusive pomares e arrozais, estes últimos muito comuns nas áreas de estudo na China. Embora as áreas de pastagem tenham sido analisadas separadamente neste trabalho, em alguns estudos a classe “agricultura” incluiu pastagens. A classe “pastagem” engloba formações predominantemente herbáceas, naturais ou cultivadas, exploradas ou não. A classe “área urbana” engloba formações residenciais, comerciais e industriais, em grandes centros urbanos ou pequenos assentamentos rurais. Outra

categoria, que foi dissociada da classe de área urbana, é “estradas”, que inclui métricas exclusivamente para essas estruturas lineares. Foi comum que os artigos apresentassem métricas de configuração mensuradas em nível de paisagem, e não para uma classe específica de uso e cobertura do solo. Nesse sentido, esses resultados também foram analisados separadamente. Outras áreas como corpos d’água, solo exposto, áreas úmidas e de mineração, não foram exploradas na síntese. Alguns resultados foram excluídos da revisão, pois não se encaixavam apropriadamente em nenhuma das categorias descritas no Quadro 4.

Quadro 4 – Classes de uso e cobertura do solo analisadas na síntese dos dados da revisão sistemática

Classe	Usos e coberturas do solo incluídos
Floresta	<i>Forests, managed forest land, woody savanna, natural forest, forested land, shrubland, green land (forests and shrubs), broadleaved forest, mixed forest, young forest.</i>
Agricultura	<i>Agriculture, agricultural land, cropland, farmland, dry farmland, paddy land, row crop agriculture, non-rowcrop agriculture, small grains, horticultural crops, agriculture and pasture, orchard, cultivated land, cultivated crops, annual herbaceous (cropland), arable, tea gardens, agriculture/grassland, arable, non-wood forest (tea, chestnut, citrus), sugarcane.</i>
Pastagem	<i>Grassland, pasture, rangeland, grassland and forage, perennial herbaceous (grassland), shrub/herb, improved grassland, rough pasture, natural grassland, grassland without trees.</i>
Área urbana	<i>Urban land, built-up land, urban areas, developed areas, terrestrial unvegetated (urban), residential areas, urban fabric, industrial areas, low intensity development, high intensity development, residential/commercial.</i>
Estradas	<i>Road, impervious surfaces based on roads</i>
Total	Todos os usos e coberturas. Inclui apenas métricas de configuração mensuradas em nível de paisagem.
Outros	<i>Água (water, water bodies); solo exposto (bareland, man-made barren land, natural barren land); áreas úmidas (wetlands); mineração (mine waste area, mining area).</i>

Fonte: elaborado pela autora.

Antes da agregação dos resultados foi necessário eliminar mais algumas fontes de multiplicidade de forma a garantir a independência estatística. Alguns estudos avaliaram mais de uma classe de floresta (e.g., formação florestal, arbustiva, ou uma mistura das duas), agricultura (e.g., agricultura com ou sem plantio em linhas) ou áreas urbanas (e.g., área industrial, área residencial). Nesses casos, foi retido apenas um tamanho de efeito considerando os seguintes critérios. Para a classe de florestas, no caso de formações florestais ou arbustivas medidas em um mesmo estudo, foi retido o resultado para a formação florestal. Para formações florestais de tipos distintos e de outras classes de uso e cobertura do solo, foi retido o resultado de maior magnitude (LÓPEZ-LÓPEZ et al., 2018). No caso de dois ou mais tamanhos de efeito

de mesma magnitude, mas com sinais diferentes, a significância estatística foi selecionada como critério. Quando a significância dos tamanhos de efeito era igual ou não era apresentada, foi então extraída a média aritmética de todas as medidas nos casos possíveis (i.e., correlações). Para dois ou mais tamanhos de efeitos idênticos (i.e., em termos de magnitude, direção e significância estatística), foi selecionado apenas um de forma aleatória³.

As métricas de paisagem foram organizadas para apresentação em duas categorias principais: composição e configuração (Quadro 5). A primeira inclui métricas de abundância proporcional de uma classe, riqueza, equabilidade e diversidade. A segunda abrange métricas de área e borda, forma, área central, contraste e agregação, além de outros índices que contemplam o arranjo espacial. Dentro da categoria “agregação” estão incluídas medidas que abordam conceitos de dispersão, intercalação, subdivisão e isolamento (MCGARIGAL, 2015). Além disso, a categoria “outras métricas” contém um índice que combina configuração, declividade e elevação. Uma descrição mais completa de todas as métricas pode ser encontrada no APÊNDICE B.

³ Para o estudo de Walters, Brody e Highfield (2018) foi adotado mais um critério: no caso de diferentes classes de uso urbano, deu-se preferência para a classe de alta intensidade de desenvolvimento após o esgotamento das opções para eliminação de resultados múltiplos. Para o trabalho de Nash et al. (2009), que utilizou duas classes de agricultura (i.e., *cropland+pasture*, *cropland*), deu-se preferência para o resultado de “*cropland*” em casos de multiplicidade. Ainda, Su, Ahern e Chang (2016) forneceram medidas de *buffer* de reservatório e *buffer* ripário, tendo sido dada preferência ao último nos casos de multiplicidade para uma relação métrica-parâmetro.

Quadro 5 – Métricas de paisagem empregadas pelos estudos incluídos na revisão sistemática

Métrica	Nome e sigla em inglês
Composição	
Porcentagem da paisagem	<i>Percentage of Landscape</i> – PLAND (%)
Densidade de riqueza de manchas	<i>Patch Richness Density</i> – PRD (n/100 ha)
Índice de equabilidade de Shannon	<i>Shannon's Evenness Index</i> – SHEI
Índice da maior mancha	<i>Largest Patch Index</i> – LPI (%)
Índice de diversidade de Shannon	<i>Shannon's Diversity Index</i> – SHDI
Índice de poluição da cobertura do solo	<i>Land Cover Pollution Index</i> – LCPI
Configuração	
Área da mancha	<i>Patch Area</i> – PA (ha)
Comprimento de borda total e médio	<i>Total Edge</i> – TE, <i>Mean Patch Edge</i> – MPE (m)
Densidade de borda	<i>Edge Density</i> – ED (m/ha)
Razão perímetro-área	<i>Perimeter-Area Ratio</i> – PARA
Índice de forma	<i>Shape Index</i> – SHAPE
Índice de dimensão fractal	<i>Fractal Dimension Index</i> – FRAC
Círculo circunscrito relacionado	<i>Related Circumscribing Circle</i> – CIRCLE
Índice de contiguidade	<i>Contiguity Index</i> – CONTIG
Área central total e área sob efeito de borda	<i>Total Core Area</i> – TCA, <i>Area under Edge Effect</i> – AEE (ha)
Índice de contraste de borda	<i>Edge Contrast Index</i> – ECON (%)
Índice de intercalação e justaposição	<i>Interspersion & Juxtaposition Index</i> – IJI (%)
Porcentagem de adjacências semelhantes	<i>Percentage of Like Adjacencies</i> – PLADJ (%)
Índice de agregação	<i>Aggregation Index</i> – AI (%)
Índice de forma da paisagem	<i>Landscape Shape Index</i> – LSI
Índice de coesão de manchas	<i>Patch Cohesion Index</i> – COHESION
Número de manchas	<i>Number of Patches</i> – NP
Densidade de manchas	<i>Patch Density</i> – PD (n/100 ha)
Índice de divisão da paisagem	<i>Landscape Division Index</i> – DIVISION (proporção)
Distância euclidiana do vizinho mais próximo	<i>Euclidean Nearest Neighbor Distance</i> – ENN (m)
Índice de contágio	<i>Contagion Index</i> – CONTAG (%)
Fragmentação da floresta - Índice de Matheron	<i>Forest Fragmentation - Matheron Index</i> – FF
Distância da maior mancha	<i>Largest Patch Distance</i> – LD (m)
Posição da floresta – próxima, intermediária, distante	<i>Forest Position</i> – near, intermediate, distant – FP (%)
Proximidade da mancha até o riacho	<i>Average Proximity of Patch to Streams</i> – APPS (km)
Distância média da floresta até o riacho	<i>Mean Distance of Forest to Stream</i> – DFS (m)
Outras métricas	
Índice de paisagem ponderado por localização	<i>Location-weighted Landscape Index</i> – LWLI

Fonte: elaborado pela autora.

Finalmente, a revisão sistemática pressupõe a apresentação dos resultados, ou seja, um resumo sintético das informações extraídas dos estudos. Para isso podem ser utilizadas sínteses de caráter narrativo, quantitativo e qualitativo (CEE, 2018). Tabelas chamadas de “resumo dos resultados” proveem as informações-chave sobre a síntese, tais como uma lista dos resultados encontrados, o efeito e a magnitude verificados, o número de estudos que forneceram o resultado, entre outras (SCHÜNEMANN et al., 2019).

Devido às questões descritas na seção 2.3 sobre a não viabilidade da meta-análise no contexto desta pesquisa, foram escolhidas outras estratégias para síntese e análise estatística dos dados. Uma tabela com a análise quantitativa dos resultados foi construída a partir dos seguintes descritores: escala, parâmetro de qualidade de água, uso e cobertura do solo e respectiva métrica, e direção do tamanho de efeito. Foram computados o número de resultados que indicaram uma relação negativa ou positiva com os parâmetros de qualidade da água (i.e., o sinal do tamanho de efeito) e foram incluídas as suas respectivas referências. Dependendo do parâmetro avaliado e do contexto de análise, uma relação negativa ou positiva pode apontar uma melhora ou piora na qualidade da água. Em geral, relações negativas indicam uma influência benéfica na qualidade da água, pois muitos parâmetros são mensurados na forma de concentração (e.g., nutrientes, sólidos, DBO, DQO) (APÊNDICE A). Em poucos casos, uma relação positiva determina uma melhoria na qualidade da água (e.g., oxigênio dissolvido, densidade de macroinvertebrados, índices bióticos). Essa condição foi observada na agregação dos dados de forma a manter um único significado para uma relação positiva ou negativa entre um parâmetro e uma métrica. Nesse sentido, em alguns poucos casos foi necessário inverter o sinal da relação antes da agregação com outros resultados.

Decidiu-se testar a hipótese nula de que não há relação entre a métrica de paisagem e o parâmetro de qualidade da água por meio de um teste do sinal (*sign test*). Nesta técnica, o número de resultados com direção negativa é comparado com o número de resultados com direção positiva, sem considerar a magnitude do efeito, a significância estatística ou o tamanho amostral (BORENSTEIN et al., 2009). A técnica é adequada quando os tamanhos de efeito são de diferentes tipos e não podem ser combinados diretamente, mas a direção é relevante para o pesquisador (BORENSTEIN et al., 2009). O teste do sinal avalia por meio de um teste binomial a probabilidade de a distribuição de sinais positivos e negativos ocorrer considerando que a hipótese nula é verdadeira (ZAR, 2010). O teste unicaudal e bicaudal foi realizado por meio da função *DISTR.BINOM* do Excel, considerando que a frequência de sinais positivos e negativos é equivalente ($p = 0,50$) na hipótese nula e adotando $\alpha = 0,05$ (ZAR, 2010).

Além da síntese quantitativa dos resultados para as diferentes relações métrica-parâmetro identificadas, as informações sobre os descritores extraídos dos estudos e dos tamanhos de efeito foram sintetizadas por meio de tabelas, gráficos e mapas. Para sumarizar os dados sobre a quantidade de bacias examinadas, foram consideradas separadamente análises de subgrupos e análises com tamanhos amostrais diferentes em um mesmo trabalho. Foram computadas as áreas de todas as bacias investigadas, quando disponíveis, para obter a sua distribuição. Na ausência dessa informação, foram coletados os valores médios ou mínimos e máximos. Os estudos também foram classificados de acordo com as seguintes categorias relativas à técnica estatística usada: regressão múltipla, correlação de Pearson, regressão linear simples, correlação de Spearman, modelo linear misto, modelo linear generalizado misto, árvore de regressão e regressão por mínimos quadrados parciais. Os modelos categorizados como de “regressão múltipla” incluem: modelo econométrico de efeito fixo, regressão com dados em painel, regressão espacial, regressão não linear e regressão linear. A “correlação de Pearson” inclui coeficientes de correlação parcial. Para artigos que se encaixaram no descrito na alínea d) da seção 2.2, foram computados os dados de correlação disponibilizados pelos autores, e esses trabalhos foram classificados nas categorias de “correlação”. Uma pesquisa pode ter empregado mais de um método estatístico, sendo que todos eles foram observados nesta síntese. No sumário das temperaturas das áreas de estudo, foi utilizado o valor médio, e se mais de um valor médio fosse fornecido, o maior entre eles foi coletado. Os elementos gráficos foram elaborados no ambiente de *software* e linguagem de *script* para análises estatísticas e gráficas R (R CORE TEAM, 2021) utilizando as funções básicas e o pacote *ggplot2* (WICKHAM et al., 2021). Os mapas apresentados foram produzidos utilizando o *software* de SIG QGIS 3.16.4 e ferramentas externas integradas dos programas GRASS 7.8.5 e SAGA 2.3.2 (QGIS.org, 2021).

Além disso, de forma a cumprir os objetivos específicos, uma síntese narrativa foi elaborada considerando as evidências que os estudos incluídos na revisão sistemática forneceram sobre a importância relativa das métricas de composição e configuração, existência de limiares de provisão do serviço hidrológico, diferenças de resultados em escala de bacia e *buffer*, efeitos de diferentes larguras de *buffers*, influência de variáveis sazonais e outros fatores físicos.

3 RESULTADOS

A busca pelos estudos da revisão sistemática utilizando as palavras-chave (Quadro 1) foi executada em agosto/2018. Os resultados foram copiados para o *software* Zotero de gerenciamento de referências e os registros duplicados foram excluídos (Tabela 1), totalizando uma amostra de 498 documentos que foram analisados de acordo com os filtros descritos na seção 2.2.

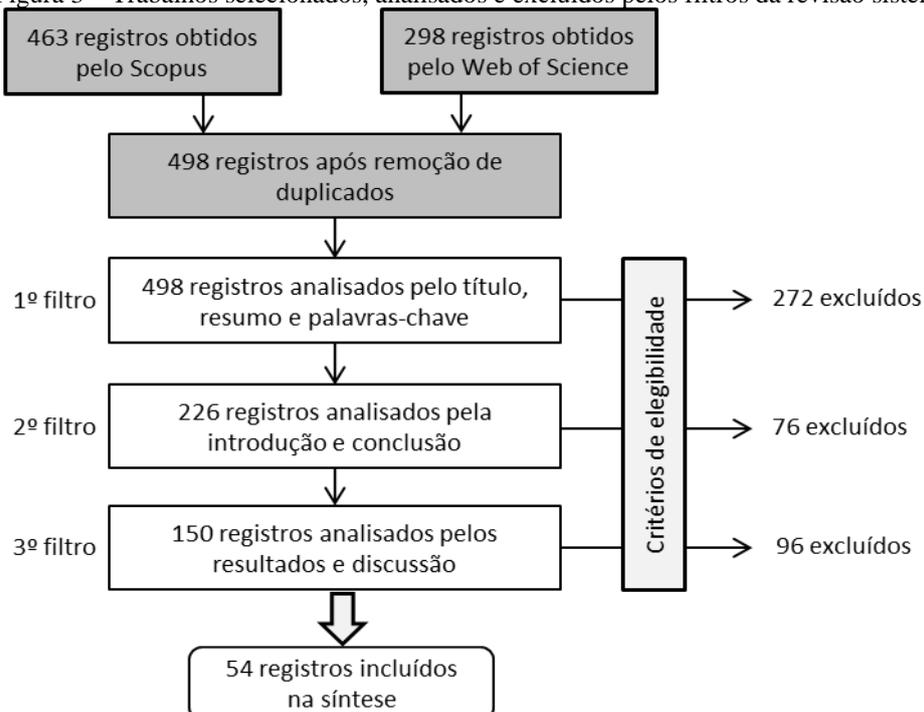
Tabela 1 – Resultados da busca por estudos da revisão sistemática da literatura

	Scopus	Web of Science	Total
“ <i>landscape ecology</i> ” AND “ <i>water quality</i> ”	163	77	
“ <i>landscape metrics</i> ” AND “ <i>water quality</i> ”	71	86	
“ <i>landscape pattern</i> ” AND “ <i>water quality</i> ”	129	85	
“ <i>landscape structure</i> ” AND “ <i>water quality</i> ”	100	50	
Total	463	298	761
		Registros duplicados	263
		Amostra	498

Fonte: elaborado pela autora.

A Figura 3 sumariza o processo de seleção, análise e exclusão dos registros por meio de um diagrama baseado na estratégia PRISMA (MOHER et al., 2009).

Figura 3 – Trabalhos selecionados, analisados e excluídos pelos filtros da revisão sistemática



Fonte: elaborado pela autora.

3.1 Características dos estudos incluídos

Os estudos incluídos (n = 54) estão apresentados no Quadro 6. Todos correspondem a artigos de periódicos científicos escritos em língua inglesa, sendo que o trabalho mais antigo foi divulgado em 1997. Poucos estudos foram publicados por ano até 2010, e esse número aumenta a partir de 2011, sendo 2018 o ano com maior quantidade de publicações (Figura 4).

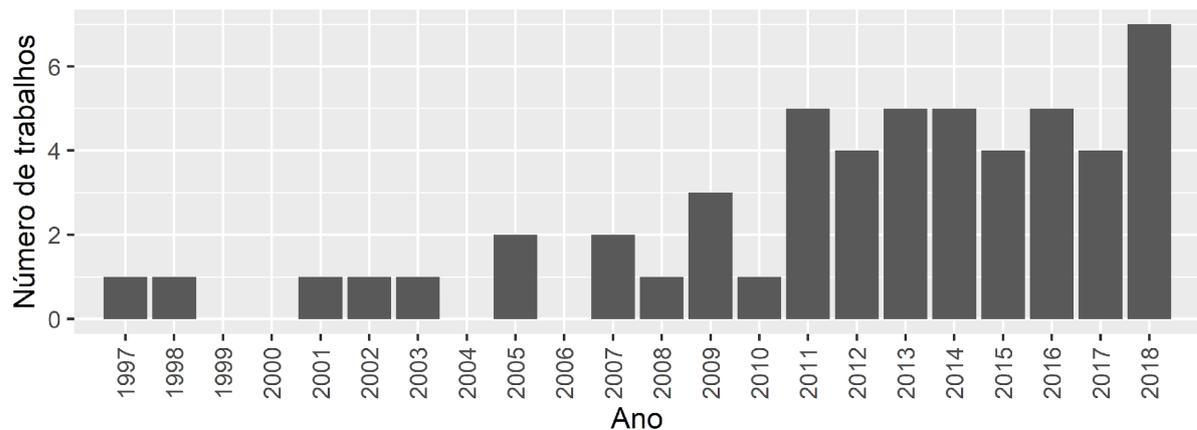
Quadro 6 – Características dos estudos incluídos na revisão sistemática

ID	Autores	Ano	País	Região
4	Batani, Fakherani e Soffianian	2013	Irã	Bacia do rio Zayandehroud
9	Bu et al.	2016	China	Bacia do rio Haicheng
11	Chang e Psaris	2013	EUA	Bacia do rio Columbia
13	Clément et al.	2017	Canadá	Bacia do rio St Lawrence
14	Mello et al.	2018	Brasil	Bacia do rio Sarapuí
15	De Oliveira, Maillard e Pinto	2017	Brasil	Bacia do rio das Velhas
16	Ding et al.	2016	China	Bacia do rio Dongjiang
22	Haidary et al.	2013	Japão	Distrito Higashi-Hiroshima
24	Hively et al.	2011	EUA	Bacia do rio Choptank
26	Huang et al.	2013	China	Bacia do lago Chaohu
27	Huang et al.	2016	China	Bacia do rio Heigou
28	Jager et al.	2011	EUA	Fort Stewart, GA
29	Jiang et al.	2017	China	Bacia do rio Le'an
30	Johnson, Myers e Patil	2001	EUA	Estado da Pensilvânia
31	Johnson et al.	1997	EUA	Bacia de Saginaw Bay
33	Kay et al.	2005	Inglaterra	Bacia do Holland Brook, Clacton
35	King et al.	2005	EUA	Coastal Plain, Maryland
36	Klauda et al.	1998	EUA	Estado de Maryland
38	Lee et al.	2009	Coreia do Sul	Reservatórios na Coreia do Sul
39	Li et al.	2018	China	Bacia Yuqiao
40	Li, Liu e Ji	2015	China	Bacia do rio Jinjing
42	Li, Zhang e Zhang	2012	China	Bacia do rio Han superior
43	Liu et al.	2018	China	Bacia do rio Beiyun
44	Liu, Shen e Chen	2018	China	Bacia do rio Beiyun
46	Liu e Yang	2018	China	Shenzhen
47	Lopez et al.	2008	EUA	Cabeceiras do rio White, Ozark Mountains
48	Łowicki	2012	Polônia	Bacia Warta, região Wielkopolska
49	Lucas e Medley	2002	EUA	Bacia Marshall's Branch, condado Preble, Ohio
55	Mori et al.	2015	Brasil	Bacia do rio Corumbataí
57	Nash et al.	2009	EUA	Bacias no estado de Oregon
58	Nielsen et al.	2012	Dinamarca	-

59	Ou e Wang	2011	China	Bacia do reservatório Miyun
63	Ouyang et al.	2014	China	Sangjiang Plain
64	Paula et al.	2018	Brasil	Bacia do rio Corumbataí
65	Potter, Cubbage e Schaberg	2005	EUA	Bacias na Carolina do Norte
66	Qiu e Turner	2015	EUA	Bacia Yahara, Wisconsin
70	Roberts e Prince	2010	EUA	Bacia de Chesapeake Bay
71	Rose et al.	2017	EUA	Lagos em Wisconsin
73	Shen et al.	2014	China	Bacia do rio Beiyun
77	Su, Ahern e Chang	2016	Taiwan	-
78	Sun et al.	2013	China	Bacia do rio Haihe
79	Sun et al.	2014	China	Xiamen
80	Tang	2015	EUA	Bacia do rio Choptank
81	Teixeira e Marques	2016	Portugal	Bacia do rio Mondego
83	Törnblom et al.	2011	Romênia, Ucrânia e Polônia	Região Carpathian Mountains
85	Uriarte et al.	2011	-	Porto Rico
88	Walters, Brody e Highfield	2018	EUA	Galveston Bay Estuary, Texas
93	Xiao e Ji	2007	EUA	Tri-State Mining District, Missouri, Kansas e Oklahoma
94	Ye et al.	2014	China	Bacias do reservatório Dahuofang
96	Yunus, Nakagoshi e Ibrahim	2003	Malásia	Bacia do rio Pinang
97	Zhou, Wu e Peng	2012	China	Bacia do rio Dongjiang
99	Margriter et al.	2014	EUA	Ilhas O'ahu, Hawai'i e Maui, Hawaii
101	Alberti et al.	2007	EUA	Região Puget Sound
102	Shandas e Alberti	2009	EUA	Região Puget Sound

Fonte: elaborado pela autora.

Figura 4 – Número de trabalhos incluídos na revisão sistemática por data de publicação



Fonte: elaborado pela autora.

Notas: n = 54

Os artigos incluídos foram publicados em 28 periódicos com diferentes escopos, como ecologia, política, gestão e monitoramento ambiental, e recursos hídricos (Tabela 2).

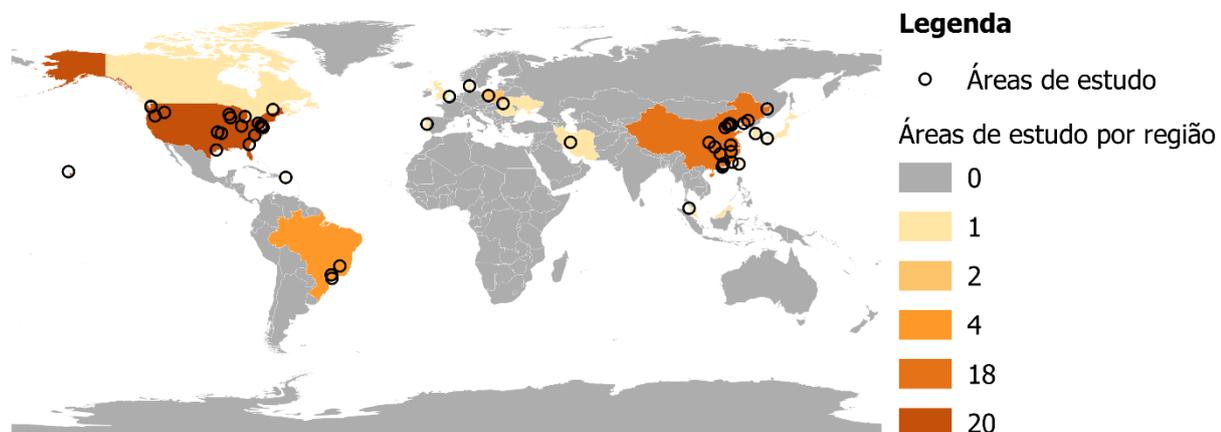
Tabela 2 – Número de estudos da revisão sistemática por periódico

Periódico	Número de publicações
<i>Ecological Indicators</i>	7
<i>Landscape and Urban Planning</i>	6
<i>Environmental Monitoring and Assessment</i>	5
<i>Science of the Total Environment</i>	5
<i>Environmental Management</i>	4
<i>Ecological Applications</i>	3
<i>Catena</i>	2
<i>Landscape Ecology</i>	2
Outros	20
Total	54

Fonte: elaborado pela autora.

Em relação à localização das áreas de estudo, há uma predominância de dois países: Estados Unidos ($n = 20$) e China ($n = 18$). O Brasil se destaca em terceiro lugar com quatro trabalhos. O restante das áreas de estudo está distribuído por outros países da Ásia (5), Europa (5), América do Norte (1) e América Central (1) (Figura 5). De acordo com a classificação climática de Köppen-Geiger (PEEL; FINLAYSON; MCMAHON, 2007; WORLD MAPS OF KÖPPEN-GEIGER CLIMATE CLASSIFICATION, 2020), a maioria das áreas de estudo apresenta clima temperado e continental (91%) e com ausência de estação seca (57%). Apenas três estudos foram desenvolvidos em áreas de clima tropical.

Figura 5 – Localização das áreas de estudo dos artigos incluídos na revisão sistemática

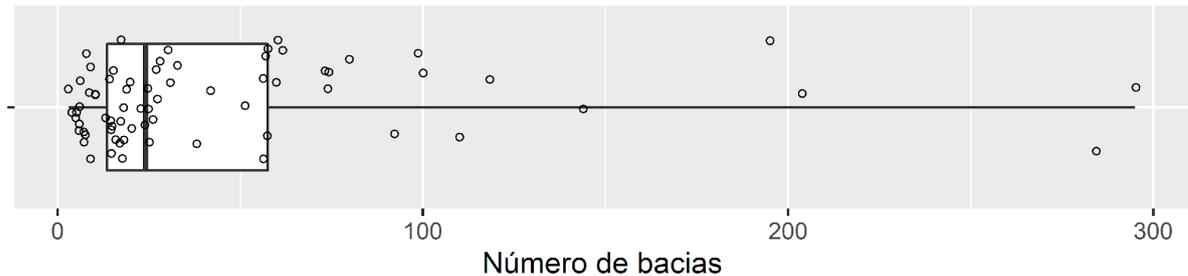


Fonte: elaborado pela autora.

Notas: $n = 54$

Cinquenta e três estudos analisaram o padrão da paisagem em escala de bacia hidrográfica e, destes, 22 analisaram dados também em escala de *buffer* de ambientes aquáticos. Apenas um trabalho considerou exclusivamente o padrão da paisagem no *buffer*. O número de bacias investigadas pelos estudos variou de três até 5.002, com média de 151 e mediana de 25. Apesar dessa amplitude, a maior parte dos artigos examinou até 60 bacias (Figura 6).

Figura 6 – Número de bacias analisadas pelos estudos incluídos na revisão sistemática

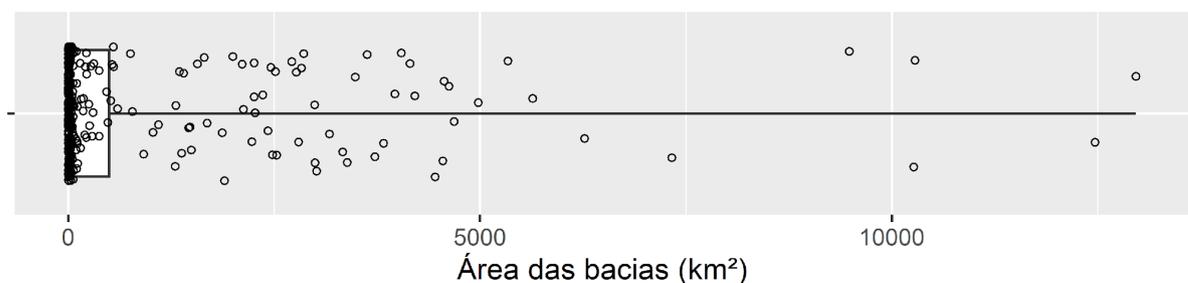


Fonte: elaborado pela autora.

Notas: n = 74. Os *outliers* 590, 2.339 e 5.002 foram omitidos. Mais informações consultar a seção 2.4.

Apenas 24 estudos (44%) forneceram informações sobre a área das bacias investigadas. Esse dado variou bastante, desde menos de 1 km² (=0,0253 km²) até 12.965 km² (Figura 7). Entretanto, poucas foram as bacias analisadas que possuíam mais de 500 km².

Figura 7 – Áreas das bacias analisadas pelos estudos incluídos na revisão sistemática

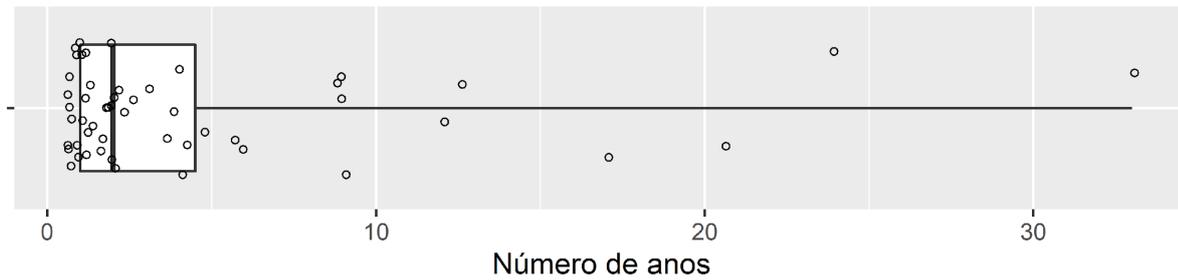


Fonte: elaborado pela autora.

Notas: n = 279. Mais informações consultar a seção 2.4.

Os artigos incluídos examinaram séries de dados de qualidade da água menores que um ano (≤ 1 ano) até 33 anos, com mediana de dois anos (Figura 8). Entretanto, a maioria dos trabalhos utilizou séries de dados de até cinco anos, valor próximo da média (= 4,7). Não foi possível identificar a série temporal dos dados em três estudos.

Figura 8 – Quantidade de anos de dados de qualidade da água analisados pelos estudos incluídos na revisão sistemática



Fonte: elaborado pela autora.

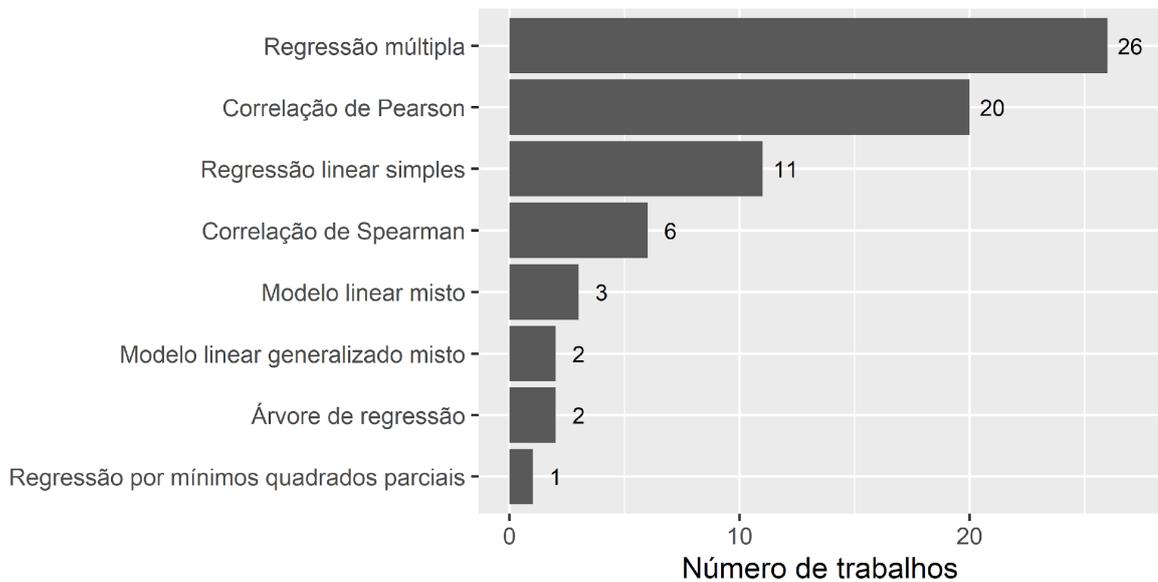
Notas: n = 51

A maioria dos estudos analisou dados primários que foram coletados ($n = 28$) em pontos de monitoramento em rios, lagos, reservatórios ou áreas úmidas. Outros artigos ($n = 21$) utilizaram dados de fontes secundárias, enquanto apenas quatro trabalhos obtiveram os parâmetros de qualidade da água por meio de modelos de simulação. A maioria dos trabalhos analisou indicadores de qualidade da água de rios ($n = 43$), sete analisaram dados de lagos e reservatórios, e quatro examinaram dados de qualidade de água obtidos por simulação cuja saída é geralmente expressa como carga de sedimentos ou nutrientes em $\text{kg}\cdot\text{ha}^{-1}\cdot\text{ano}^{-1}$. Apenas dois artigos trabalharam com indicadores de qualidade da água em áreas úmidas (*wetlands*).

Informações sobre precipitação e temperatura nas áreas de estudo foram providas por 27 e 19 trabalhos, respectivamente. A precipitação, que foi fornecida em valores médios, mínimos e máximos, apresentou uma amplitude desde 500 até 2.000 mm/ano. Apenas uma área de estudo, na Malásia, apresentou padrões de precipitação acima desse valor. A temperatura média variou de 1,91 até 29,7°C. Considerando os valores médios máximos fornecidos pelos artigos, a média para este parâmetro foi 14,7°C e a mediana 13,4°C. A maioria das pesquisas foi executada em áreas com temperaturas médias de até 18,25°C.

Foi possível identificar o *software* de cálculo das métricas em 83% dos estudos. Embora diferentes *softwares* de SIG tenham sido usados, o *Fragstats* foi adotado por 46% dos trabalhos. As técnicas estatísticas mais empregadas foram as análises de regressão múltipla e correlações de Pearson (Figura 9), sendo que foi comum que os artigos utilizassem duas ou três técnicas diferentes.

Figura 9 – Quantidade de estudos da revisão sistemática que empregaram as técnicas estatísticas



Fonte: elaborado pela autora.

Notas: n = 71. Mais informações consultar a seção 2.4.

Todos os artigos forneceram resultados sobre a relação entre a qualidade da água e a composição da paisagem, enquanto 31 (57%) apresentaram resultados sobre a influência da configuração. Por outro lado, dos 54 trabalhos, 48 (89%) forneceram resultados sobre a relação com o padrão de florestas na paisagem, sendo 44 (81%) relativos ao papel de métricas de composição e apenas 16 (30%) sobre a influência de métricas de configuração.

3.2 Características do conjunto de dados

Após a compilação dos dados brutos de cada artigo, os dados líquidos foram obtidos após a eliminação de fatores de multiplicidade de acordo com os procedimentos descritos na seção de Material e Métodos. Não foi possível remover todos os casos de multiplicidade em certas situações, portanto, a independência dos resultados não está garantida para algumas relações envolvendo os indicadores: elementos traço, cor, herbicidas, densidade de macroinvertebrados, índices bióticos e coliformes fecais. Foram obtidos 1.514 tamanhos de efeito, sendo 1.237 em escala de bacia e 277 em escala de *buffer*. Após a eliminação dos dados excluídos e daqueles que não se referem a uma das classes analisadas neste trabalho (i.e., floresta, agricultura, pastagem, área urbana e estradas), foram obtidos 954 resultados em escala de bacia e 233 em escala de *buffer*, totalizando 1.187 tamanhos de efeito.

O APÊNDICE C apresenta os resultados agrupados de acordo com a escala, parâmetro de água, métrica de paisagem, o número de tamanhos de efeito com sinal negativo ou positivo,

o valor- p resultante do teste do sinal, e as referências (Quadro 6) que apontam essas relações. Os valores $p < 0,05$ estão destacados em negrito. Os resultados onde há possível dependência dos dados estão indicados por um asterisco (*) na coluna do valor- p . Nesses casos, a interpretação do valor- p do teste do sinal deve ser feita com cautela, pois o princípio da independência está violado.

Foram extraídos 43 parâmetros de qualidade da água e 85 métricas de composição e configuração abrangendo as classes floresta, agricultura, pastagem, área urbana e estradas. Pelo menos cinco resultados foram coletados para a maioria (70%) dos parâmetros avaliados. Os indicadores mais frequentes foram os nutrientes (N e P), elementos traço, oxigênio dissolvido, DBO, DQO, condutividade e coliformes fecais. Por outro lado, apenas 47% das métricas computaram pelo menos cinco resultados. A maioria dos tamanhos de efeito se refere a uma relação com uma métrica de composição da paisagem, notadamente PLAND (610 resultados, 51%), mas também SHDI, LPI e SHEI. Para os estudos que obtiveram resultados considerando a configuração, foi comum o uso de índices em nível de paisagem em vez de classes de uso e cobertura do solo específicas. As métricas de configuração mais frequentes foram PD, CONTAG e ED. ED pastagem e ED floresta (13 resultados cada) foram as métricas de configuração em nível de classe mais utilizadas.

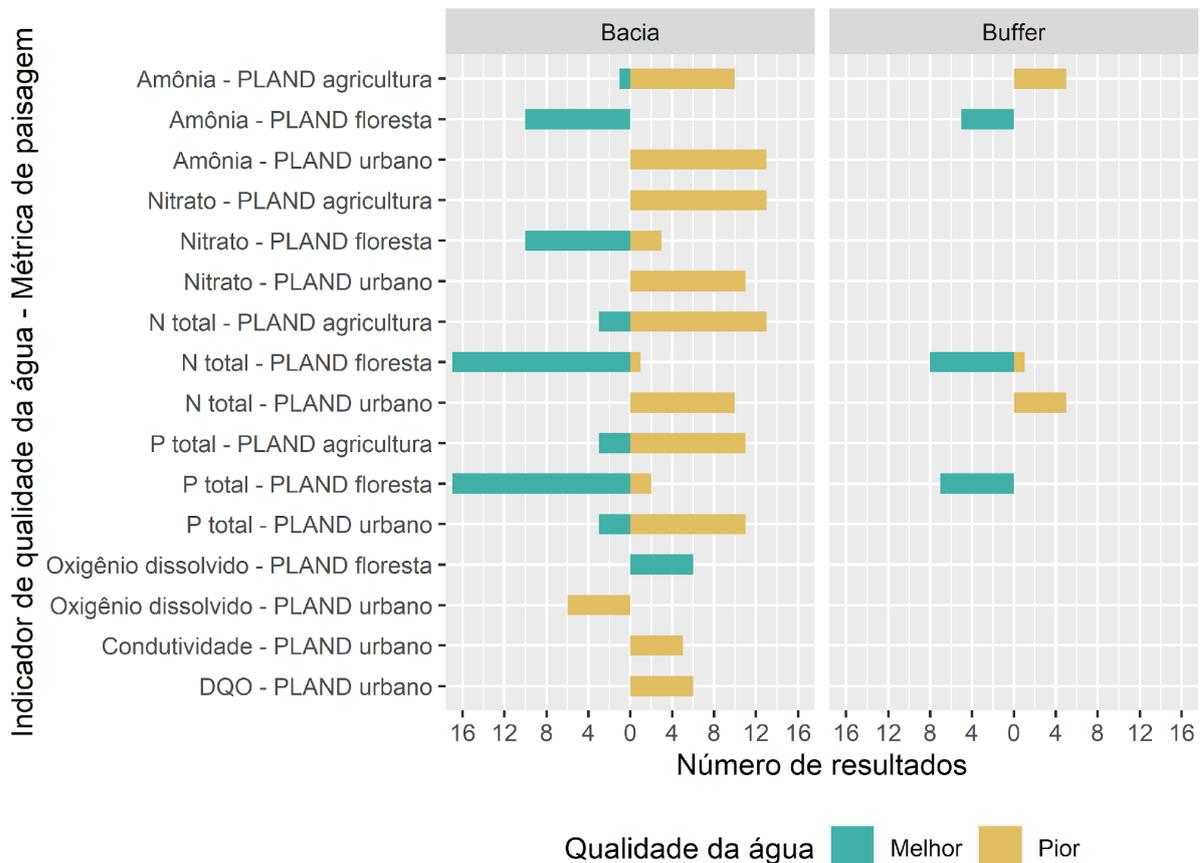
3.3 Teste do sinal

A diferença entre resultados com sinais negativos e positivos foi significativa para os parâmetros amônia, nitrato, N total, P total, elementos traço, DQO, oxigênio dissolvido, condutividade e coliformes fecais (APÊNDICE C). No caso dos elementos traço e dos coliformes fecais, alguns resultados foram derivados de um único estudo, o que compromete a independência dos dados. Portanto, a apresentação e discussão dos resultados se concentra nos seis parâmetros restantes.

Os resultados para os indicadores citados exibiram um padrão em que só foi possível obter uma relação significativa ($p < 0,05$) com a porcentagem da paisagem ocupada por floresta, agricultura e área urbana. Houve mais resultados significativos para a escala de bacia, o que pode ser um reflexo do número maior de evidências coletadas nessa escala. Portanto, algumas relações foram significativas em escala de bacia, mas não na de *buffer* possivelmente devido ao número insuficiente de tamanhos de efeito obtidos nesta escala. A seguir são apresentados um gráfico que sumariza todos os resultados significativos (Figura 10) e um gráfico para o indicador P total (Figura 11). Neste último, as relações significativas ($p < 0,05$) são

representadas por barras de cor mais escura, enquanto as não significativas possuem barras mais claras, com 50% de transparência. Para cada relação métrica-parâmetro detectada na escala de bacia ou *buffer* é indicado o número de resultados com direção negativa ou positiva. As cores das barras refletem o efeito na qualidade da água: melhora (ciano) ou piora (bege). O significado da sigla das métricas pode ser consultado no Quadro 5 ou no APÊNDICE B. A palavra à direita da métrica indica a qual uso e cobertura do solo ela se refere.

Figura 10 – Relações entre indicadores de qualidade da água e métricas da paisagem consideradas significativas ($p < 0,05$) pelo teste do sinal aplicado aos resultados da revisão sistemática



Fonte: elaborado pela autora.

Notas: as barras à esquerda e à direita do zero indicam, respectivamente, o número de resultados com sinal negativo e positivo.

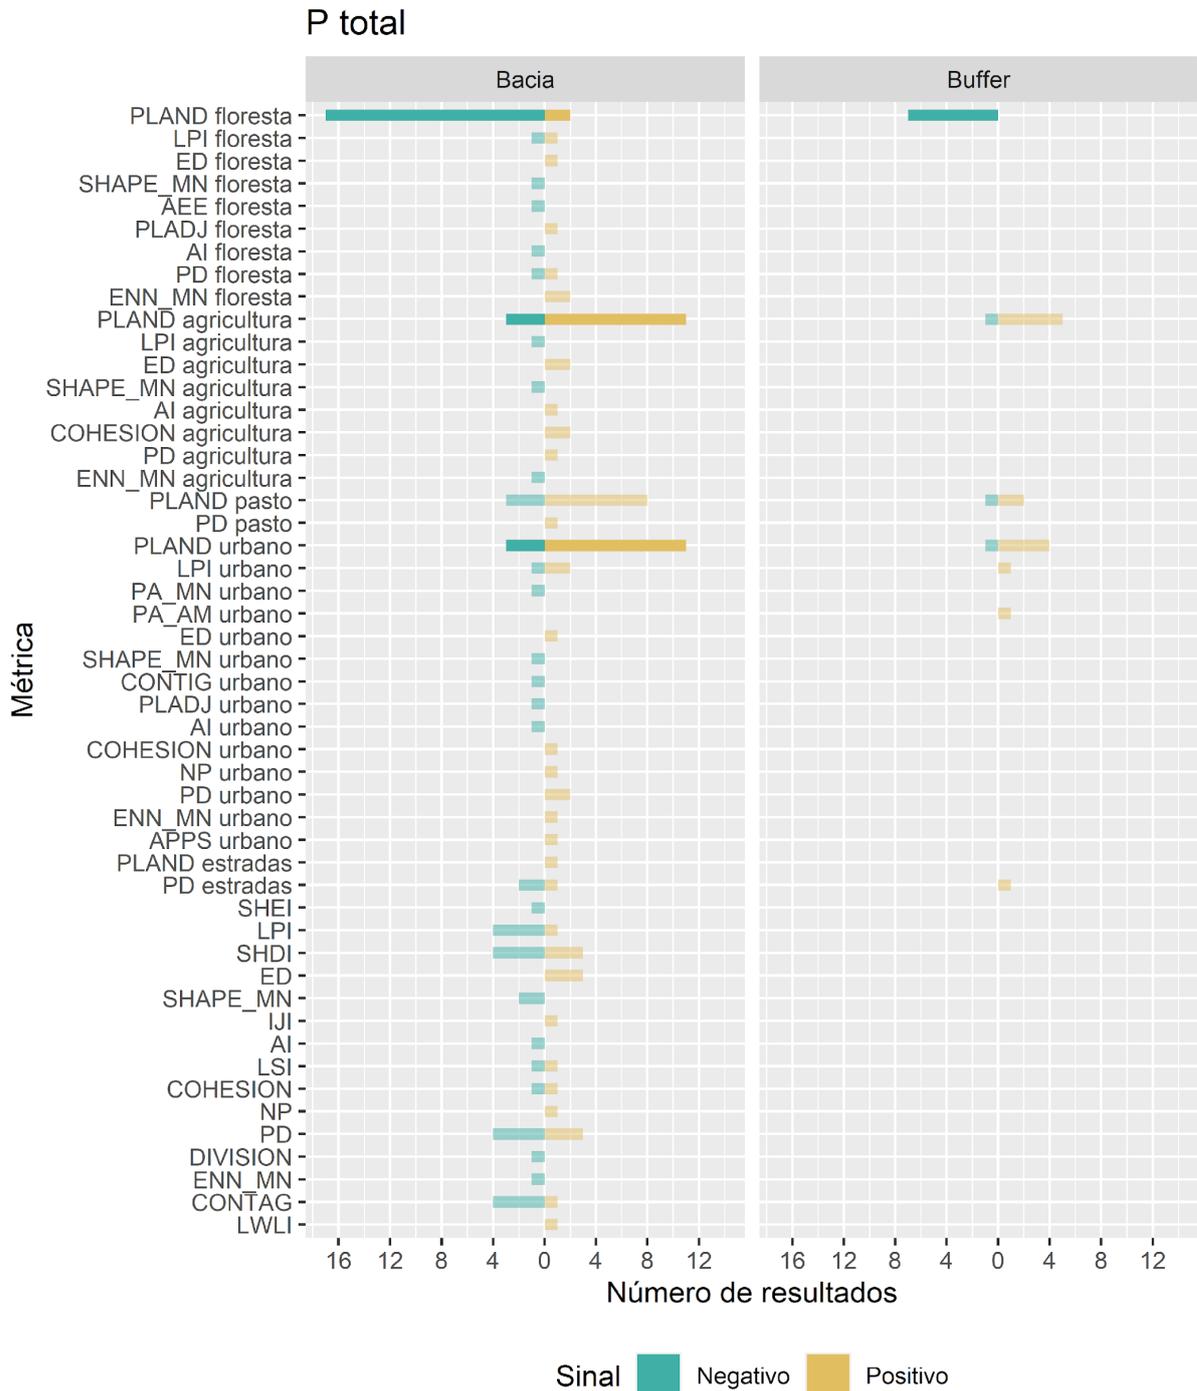
Na escala de bacia hidrográfica, houve relação negativa dos parâmetros amônia, nitrato, N total e P total com PLAND floresta e positiva com PLAND agricultura e PLAND urbano. Isso indica que a presença de florestas na bacia hidrográfica está relacionada com um menor aporte desses nutrientes na água, enquanto a agricultura e área urbana estão relacionadas com maior aporte. Ainda, o oxigênio dissolvido correlacionou positivamente com PLAND floresta, apontando uma maior concentração em áreas com maior cobertura florestal. Somente amônia,

N total e P total correlacionaram com alguma métrica mensurada na escala de *buffer*. Maiores PLAND de agricultura e área urbana se relacionaram com uma maior concentração dos compostos de nitrogênio, enquanto PLAND floresta correlacionou negativamente com os três indicadores, sugerindo que esta cobertura está associada a uma menor concentração desses nutrientes na água.

Somente a relação entre amônia e PLAND agricultura e PLAND floresta, N total e PLAND floresta e PLAND urbano, e P total e PLAND floresta foram significativas em ambas as escalas tendo apresentado a mesma tendência na direção do tamanho de efeito. PLAND urbano foi a métrica que teve mais relações significativas com parâmetros de água na escala de bacia e, em geral, foi associada a uma piora da qualidade da água. Não foram identificadas relações significativas entre os parâmetros de água e PLAND pastagem na bacia e/ou *buffer*, visto que houve uma distribuição balanceada de resultados com sinal negativo e positivo, principalmente para os indicadores com maior quantidade de dados (i.e., nitrogênio e fósforo) (APÊNDICE C). Ainda, a proporção de agricultura teve relação significativa apenas com nitrogênio e fósforo.

A Figura 11 ilustra bem o quadro geral obtido a partir da revisão sistemática – um grande volume de métricas de paisagem estudadas; uma alta variedade de métricas para um aspecto da paisagem (i.e., área e borda, forma, área central, contraste ou agregação), muitas delas avaliadas por um mesmo estudo; e um elevado número de índices de configuração calculados em nível de paisagem. Porém, mesmo diante da variedade de associações métrica-parâmetro encontradas, não foi possível identificar relações significativas além da influência da proporção de floresta, agricultura e área urbana na qualidade da água. Algumas relações métrica-parâmetro, apesar de exibirem mais de cinco resultados, tiveram uma distribuição de tamanhos de efeito com sinal positivo e negativo que não indicou uma diferença significativa. A métrica SHDI, por exemplo, apresentou mais de sete resultados para N total e P total, mas com distribuição equitativa de sinais negativos e positivos.

Figura 11 – Número de resultados para a relação entre fósforo total e métricas da paisagem extraídos da revisão sistemática



Fonte: elaborado pela autora.

3.4 Importância relativa de métricas de composição e configuração

Ambas métricas de composição e configuração foram sugeridas como preditores relevantes da qualidade da água (XIAO; JI, 2007; SHEN et al., 2014; SUN et al., 2014; LI; LIU; JI, 2015; QIU; TURNER, 2015). Alguns estudos indicaram que a composição teria maior

importância em explicar a provisão desse serviço (XIAO; JI, 2007; SHEN et al., 2014; QIU; TURNER, 2015), com destaque para as métricas PLAND (SHEN et al., 2014; QIU; TURNER, 2015; CLÉMENT et al., 2017), SHDI (SUN et al., 2014; CLÉMENT et al., 2017), LPI e SHEI (SUN et al., 2014). Por outro lado, outros autores afirmaram que as métricas de configuração foram mais relevantes para o contexto estudado (DING et al., 2016; CLÉMENT et al., 2017; LIU et al., 2018), especialmente PD (SUN et al., 2014; LI; LIU; JI, 2015; DING et al., 2016; HUANG et al., 2016), AI (DING et al., 2016) e ED (LI; LIU; JI, 2015).

Segundo Qiu e Turner (2015), a composição isoladamente foi capaz de explicar 82% da variação na qualidade da água superficial, e as métricas de composição e configuração juntas explicaram 86%. Já Shen et al. (2014) obtiveram que somente a composição explicou 47%, enquanto a composição e configuração juntas explicaram 60% da variação. Clément et al. (2017) constataram que os índices de configuração explicaram sozinhos a maior parte (i.e., 6%) da variação em um índice biótico. Porém, em paisagens com proporções muito altas ou muito baixas de coberturas que são fonte de poluentes, a porcentagem da paisagem pode ser suficiente para explicar a variação na qualidade da água (QIU; TURNER, 2015; CLÉMENT et al., 2017). As métricas de configuração seriam mais relevantes para explicar a variação na qualidade da água em bacias com porcentagens intermediárias de coberturas fonte de poluentes (CLÉMENT et al., 2017).

3.5 Limiares ecológicos

Poucos estudos se propuseram a analisar a existência de limiares ecológicos para a degradação da qualidade da água. Portanto, a seguir são descritos resultados obtidos em escalas de bacia, *buffer* de ambientes aquáticos e *buffers* de ponto amostral. Três trabalhos detectaram limiares da proporção do uso e cobertura do solo na paisagem com a qualidade da água. Ye et al. (2014) analisaram a faixa em torno de um ponto de coleta da água, onde a floresta era contínua e a área agrícola fragmentada. Os autores identificaram que é esperado que a concentração de nitrato na água tenha um aumento acentuado à medida que a paisagem atinge menos que 37% de área florestal (YE et al., 2014). Qiu e Turner (2015) demonstraram que a concentração de fósforo pode reduzir acentuadamente quando a paisagem contém acima de 3% de áreas úmidas. Em se tratando de usos antropogênicos, King et al. (2005) identificaram um limiar de 21% para PLAND de área urbana na bacia hidrográfica, e Qiu e Turner (2015) e Ye et al. (2014) obtiveram um limiar de 62% e 54% de PLAND agricultura, respectivamente. Esses

resultados indicam que é esperada uma piora acentuada na qualidade da água quando a proporção desses usos e coberturas na paisagem ultrapassa esses limiares.

3.6 Escalas espaciais de bacia hidrográfica e *buffer*

Estudos que pesquisaram a relação entre métricas de paisagem e parâmetros de água em ambas as escalas de bacia e *buffer* fornecem a oportunidade de analisar a variação dessas relações nessas escalas. Em geral, estes trabalhos verificaram que ambas as escalas influenciam a qualidade da água nos ambientes aquáticos (JOHNSON et al., 1997; POTTER; CUBBAGE; SCHABERG, 2005; ALBERTI et al., 2007; NASH et al., 2009; OU; WANG, 2011; URIARTE et al., 2011; CHANG; PSARIS, 2013; MARGRITER et al., 2014; DING et al., 2016; DE OLIVEIRA; MAILLARD; DE ANDRADE PINTO, 2017; MELLO et al., 2018), sendo que a diferença na variação dos dados explicada pelas duas escalas foi muito pequena (JOHNSON et al., 1997; POTTER; CUBBAGE; SCHABERG, 2005; ALBERTI et al., 2007; CHANG; PSARIS, 2013), não podendo ser considerada significativa (ALBERTI et al., 2007). Apesar de haver pouca diferença, vários autores afirmaram que as métricas em escala de bacia têm um desempenho ligeiramente superior em explicar a variação na qualidade da água (POTTER; CUBBAGE; SCHABERG, 2005; OU; WANG, 2011; SUN et al., 2014; DING et al., 2016; DE OLIVEIRA; MAILLARD; DE ANDRADE PINTO, 2017; MELLO et al., 2018). Por outro lado, alguns autores indicaram que os índices em escala de *buffer* são melhores preditores da qualidade da água (JOHNSON et al., 1997; NASH et al., 2009; CHANG; PSARIS, 2013; YE et al., 2015; JIANG et al., 2017).

A importância de uma métrica pode variar de acordo com a escala em que ela é mensurada e com fatores sazonais. Ou e Wang (2011) identificaram que as métricas em escala de bacia foram mais fortemente associadas com a qualidade da água após a estação chuvosa. Pesquisas desenvolvidas nos Estados Unidos mostraram que a porcentagem da paisagem ocupada por usos antropogênicos, como a pastagem (CHANG; PSARIS, 2013) e a área construída (POTTER; CUBBAGE; SCHABERG, 2005), são preditores importantes em escala de bacia, enquanto a proporção de floresta é relevante na escala de *buffer* (POTTER; CUBBAGE; SCHABERG, 2005; CHANG; PSARIS, 2013).

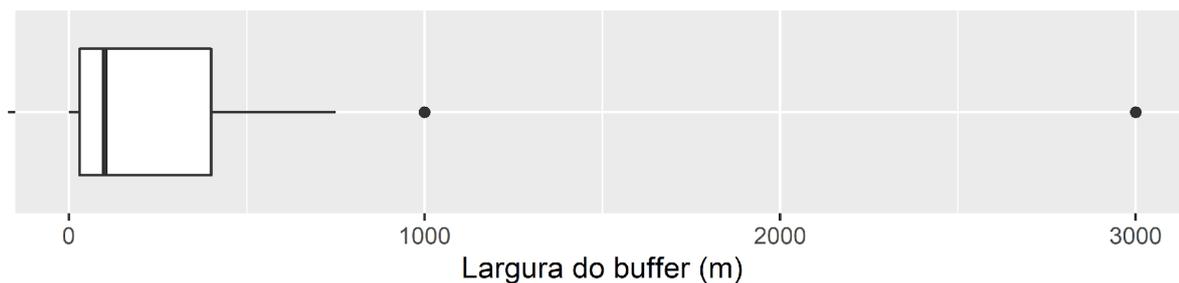
A influência de uma métrica em uma determinada escala na qualidade da água pode variar de acordo com o indicador estudado. Turbidez (URIARTE et al., 2011), oxigênio dissolvido (URIARTE et al., 2011; MELLO et al., 2018), sólidos suspensos totais, fósforo total e coliformes fecais (MELLO et al., 2018) se mostraram mais correlacionados com a

composição da bacia. Por outro lado, a concentração de nitrogênio foi indicada por alguns estudos como sendo explicada melhor pelo padrão, em especial a composição, do *buffer* (NASH et al., 2009; URIARTE et al., 2011; DING et al., 2016; MELLO et al., 2018). A presença proporcional no *buffer* de usos que são considerados fontes ou sumidouros de nutrientes pode ser um preditor relevante. Segundo De Oliveira, Maillard e De Andrade Pinto (2017), ao usar a razão fonte/sumidouro como variável independente em vez de métricas de PLAND, os modelos em escala de *buffer* tiveram melhor desempenho em prever as concentrações de oxigênio dissolvido e nitrogênio na água.

3.7 Buffers de diferentes larguras

Entre os trabalhos que fizeram análises em escala de *buffer*, 52% (12) utilizaram uma largura fixa, enquanto 48% (11) investigaram faixas de diferentes larguras. Estes últimos avaliaram desde duas até seis larguras de amplitude zero até 5.000 m. Os resultados coletados da revisão sistemática foram obtidos considerando *buffers* de largura zero até 3.000 metros. A faixa de largura de zero metros indica a porcentagem de uma classe de uso e cobertura do solo adjacente aos corpos d'água em relação ao comprimento total de ambas as suas margens. Após o processo de eliminação dos fatores de multiplicidade, verificou-se que a maioria dos resultados e, conseqüentemente, os de maior magnitude, foram obtidos em *buffers* de até 400 m de largura, sendo a mediana 100 m e a média 233 m (Figura 12).

Figura 12 – Largura dos *buffers* dos resultados para as relações métrica-parâmetro incluídas na revisão sistemática



Fonte: elaborado pela autora.

Notas: n = 233.

Embora várias larguras de *buffers* tenham sido associadas com a qualidade da água, a sua capacidade preditiva foi semelhante, visto que houve pouca variação no tamanho de efeito obtido para as diferentes larguras estudadas (ALBERTI et al., 2007; LOPEZ et al., 2008; NASH et al., 2009; ROBERTS; PRINCE, 2010; LI; LIU; JI, 2015; JIANG et al., 2017). Nos estudos que avaliaram múltiplas larguras, os resultados de maior magnitude foram obtidos para faixas

de até 1.000 m (ALBERTI et al., 2007; LOPEZ et al., 2008; NASH et al., 2009; ROBERTS; PRINCE, 2010; LI; ZHANG; ZHANG, 2012; NIELSEN et al., 2012; ZHOU; WU; PENG, 2012; MARGRITER et al., 2014; SUN et al., 2014; LI; LIU; JI, 2015; DE OLIVEIRA; MAILLARD; DE ANDRADE PINTO, 2017; JIANG et al., 2017), embora tenha havido alguma discrepância entre as larguras analisadas pelos artigos (e.g., estudos que avaliaram *buffers* de no mínimo 500 m, enquanto outros consideraram essa largura como máxima).

Assim como para a escala de bacia e *buffer*, alguns trabalhos sugeriram que a importância de uma métrica de paisagem pode variar de acordo com a largura do *buffer* onde ela foi mensurada. Evidências apontam que a PLAND floresta tem relação mais forte com a qualidade da água em *buffers* de até 500 m, especialmente naqueles entre 100 e 250 m (ALBERTI et al., 2007; LOPEZ et al., 2008; LI; ZHANG; ZHANG, 2012; LI; LIU; JI, 2015; DE OLIVEIRA; MAILLARD; DE ANDRADE PINTO, 2017). Esse resultado é típico para a concentração de compostos de nitrogênio (LOPEZ et al., 2008; LI; ZHANG; ZHANG, 2012; LI; LIU; JI, 2015) e fósforo (LOPEZ et al., 2008). Por outro lado, alguns estudos identificaram que, em *buffers* mais largos (i.e., 300 a 900 m), a proporção de usos antropogênicos, como área urbana e agricultura, se torna a principal variável preditora da qualidade da água (NIELSEN et al., 2012; ZHOU; WU; PENG, 2012; LI; LIU; JI, 2015; DE OLIVEIRA; MAILLARD; DE ANDRADE PINTO, 2017).

3.8 Influência de variáveis sazonais

Rose et al. (2017) indicaram a importância de variáveis climáticas na predição da qualidade da água, visto que temperatura e precipitação isoladamente explicaram a maior variação na claridade de lagos. Relações entre métricas de paisagem e qualidade da água foram verificadas tanto na estação seca quanto na chuvosa (LI; LIU; JI, 2015; MORI et al., 2015; BU et al., 2016; LIU et al., 2018; PAULA et al., 2018). Porém, os tamanhos de efeito de maior magnitude foram obtidos a partir de dados da estação chuvosa (JOHNSON et al., 1997; KAY et al., 2005; OU; WANG, 2011; SHEN et al., 2014; YE et al., 2014; LI; LIU; JI, 2015; MORI et al., 2015; BU et al., 2016; JIANG et al., 2017; LIU et al., 2018), particularmente para a escala de bacia (KAY et al., 2005; LI; LIU; JI, 2005; OU; WANG, 2011; SHEN et al., 2014; YE et al., 2014; MORI et al., 2015; BU et al., 2016; HUANG et al., 2016; JIANG et al., 2017; LIU et al., 2018; LIU; SHEN; CHEN, 2018), mas também de *buffer* (OU; WANG, 2011; YE et al., 2014; MORI et al., 2015; JIANG et al., 2017). Esse padrão foi mais evidente para métricas de composição, principalmente PLAND (SHEN et al., 2014; BU et al., 2016), e para compostos

de nitrogênio (LI; ZHANG; ZHANG, 2012; BU et al., 2016). Por outro lado, Rose et al. (2017) identificaram o período seco como a época em que o uso e cobertura do solo explicou melhor a variação da claridade da água de lagos. Uma justificativa é que houve pouca variação desse indicador no período úmido em Wisconsin, EUA (ROSE et al., 2017). Esses dados sugerem que a influência do uso e cobertura do solo pode ser modulada pela vazão dos riachos (URIARTE et al., 2011).

As diferenças sazonais para os tamanhos de efeito podem ser explicadas pela elevada concentração de poluentes na água na estação chuvosa (JOHNSON et al., 1997; LI; ZHANG; ZHANG, 2012; YE et al., 2014; HUANG et al., 2016; LIU et al., 2018), que pode ser cerca de três a quatro vezes maior do que na estação seca (LI et al., 2018), e pela maior variabilidade espacial (YE et al., 2014; LIU et al., 2018). Essa situação é mais evidente para as concentrações de nitrogênio e fósforo (JOHNSON et al., 1997; YE et al., 2014; HUANG et al., 2016; LI et al., 2018; LIU et al., 2018). A maior concentração e variabilidade dos indicadores são reflexos da mobilização e transporte dos poluentes na bacia hidrográfica (HUANG et al., 2016) que ocorrem devido à precipitação típica da época chuvosa (LI; LIU; JI, 2015; JIANG et al., 2017) e consequente maior vazão na bacia (KAY et al., 2005; LI; ZHANG; ZHANG, 2012; LI; LIU; JI, 2015; MELLO et al., 2018). De fato, Li, Shen e Chen (2018) constataram que a interação entre usos do solo antropogênicos e a chuva explicou melhor a concentração dos parâmetros de água, sugerindo um efeito de lavagem causado pela precipitação.

Segundo alguns estudos, a associação da proporção de usos antropogênicos com a concentração de fósforo e nitrogênio na estação seca pode indicar a contribuição de fontes pontuais de poluição (YE et al., 2014; BU et al., 2016; LIU et al., 2018). Além disso, o nitrato pode atingir a água não somente por meio do escoamento causado pela chuva, mas também pelo fluxo subsuperficial durante a estação seca (MORI et al., 2015). Fatores agrícolas relacionados à sazonalidade também podem influenciar esses resultados. Em algumas regiões, as associações mais fortes foram identificadas na época de cultivo, quando há intenso uso de fertilizantes e pesticidas, o que resulta em maior mobilização e aporte de poluentes na água (LEE et al., 2009; OU; WANG, 2011; JIANG et al., 2017). Durante o inverno no centro-sul da China, por exemplo, os solos expostos podem contribuir acentuadamente para um maior aporte de nutrientes na água (LI; LIU; JI, 2015).

3.9 Influência de outros fatores físicos

Diversos estudos analisaram e constataram o papel dos fatores físicos como variáveis preditoras da qualidade da água, seja de forma isolada ou pela interação com o uso e cobertura do solo. Entre os fatores físicos que se relacionaram com a qualidade da água, destacam-se a declividade (JOHNSON et al., 1997; OU; WANG, 2011; CHANG; PSARIS, 2013; SUN et al., 2014; MORI et al., 2015; DING et al., 2016; TEIXEIRA; MARQUES, 2016; CLÉMENT et al., 2017; JIANG et al., 2017; PAULA et al., 2018), área da bacia de drenagem (JOHNSON et al., 1997; KING et al., 2005; POTTER; CUBBAGE; SCHABERG, 2005; HAIDARY et al., 2013; CLÉMENT et al., 2017; PAULA et al., 2018), elevação (JOHNSON et al., 1997; POTTER; CUBBAGE; SCHABERG, 2005; SUN et al., 2014; MORI et al., 2015; TEIXEIRA; MARQUES, 2016; PAULA et al., 2018), tipo de solo e depósitos superficiais (JOHNSON et al., 1997; HAIDARY et al., 2013; MORI et al., 2015; CLÉMENT et al., 2017; ROSE et al., 2017; PAULA et al., 2018), densidade de drenagem (LOPEZ et al., 2008; NASH et al., 2009; OU; WANG, 2011; HAIDARY et al., 2013), ordem do riacho (CHANG; PSARIS, 2013; HAIDARY et al., 2013), e morfometria dos lagos (NIELSEN et al., 2012; ROSE et al., 2017).

Maiores declividades na bacia se relacionaram com temperaturas mais baixas (CHANG; PSARIS, 2013) e menor concentração de nutrientes (MORI et al., 2015; TEIXEIRA; MARQUES, 2016), carbono e metais (SUN et al., 2014). Porém, houve associação entre maior declividade e pior qualidade da água antes da estação chuvosa (OU; WANG, 2011). Alguns estudos indicaram a relação entre maior elevação média e melhor qualidade da água (MORI et al., 2015; PAULA et al., 2018), embora Sun et al. (2014) tenham verificado o efeito contrário considerando nutrientes e oxigênio dissolvido. Ainda, o desvio padrão da elevação se relacionou com uma melhor qualidade da água (POTTER; CUBBAGE; SCHABERG, 2005; TEIXEIRA; MARQUES, 2016). A influência da declividade e elevação na qualidade da água pode ser um reflexo do padrão de uso e ocupação do solo que é moldado por esses fatores. Áreas mais íngremes, de maior elevação ou variação na elevação são cobertas principalmente por florestas, que são associadas a um menor aporte de nutrientes (POTTER; CUBBAGE; SCHABERG, 2005; TEIXEIRA; MARQUES, 2016; JIANG et al., 2017). Por outro lado, regiões mais planas e com pouca variação na elevação estão correlacionadas com a presença de áreas agrícolas e urbanas (POTTER; CUBBAGE; SCHABERG, 2005; DING et al., 2016; TEIXEIRA; MARQUES, 2016; JIANG et al., 2017). O efeito prejudicial da declividade na qualidade da água poderia ser explicado pela presença de fontes de poluentes como sítios de mineração (JIANG et al., 2017). De fato, a distribuição da proporção dos usos e coberturas do solo varia de acordo com os gradientes de declividade. Jiang et al. (2017) notaram uma mudança acentuada na composição da paisagem em declividades acima de 15°. Em declividades maiores

a influência da floresta e da agricultura foi, respectivamente, mais forte e mais fraca (JIANG et al., 2017).

Poucos estudos trouxeram evidências sobre a relação entre área da bacia e qualidade da água, sendo alguns exemplos a correlação negativa com a turbidez e positiva com a temperatura (PAULA et al., 2018) e com nitrito (HAIDARY et al., 2014). De acordo com Clément et al. (2017), os modelos preditivos para bacias maiores (50-250 km²) apresentaram melhor desempenho do que os modelos para bacias menores que 10 km². Uma justificativa é o fato de os dados espaciais com resolução de 30 m não serem adequados para análise de bacias pequenas. Da mesma forma, King et al. (2015) também verificaram que o modelo que melhor explicou a variação do nitrato em função da proporção de agricultura se refere às bacias maiores que 26 km², seguida pelas bacias médias (6 a 26 km²) e menores que 6 km². Ainda, outros estudos indicaram que as principais variáveis preditoras em bacias menores são a composição e configuração de florestas (POTTER; CUBBAGE; SCHABERG, 2005; CLÉMENT et al., 2017), enquanto nos modelos para bacias maiores predominaram as métricas relativas à agricultura (CLÉMENT et al., 2017).

Os artigos apontaram efeitos mistos da densidade de drenagem (NASH et al., 2009; OU; WANG, 2011; HAIDARY et al., 2013), embora essa variável tenha sido capaz de explicar entre 17 e 22% da variação na concentração de nutrientes e enterococos no estudo de Nash et al. (2009), e tenha correlacionado negativamente com a concentração de fósforo e *E. coli* no trabalho de Lopez et al. (2008). Uma maior densidade de drenagem pode aumentar a probabilidade de captura dos contaminantes, mas também pode ter um efeito favorável por meio dos processos de diluição e depuração (LOPEZ et al., 2008). O tipo de solo pode ser importante para prever parâmetros como sólidos, nutrientes (HAIDARY et al., 2013; MORI et al., 2015), turbidez (MORI et al., 2015) e índice de diatomáceas (CLÉMENT et al., 2017). Dois artigos indicaram relação positiva da ordem do riacho com nitrito (HAIDARY et al., 2013) e com a temperatura máxima no riacho (CHANG; PSARIS, 2013). Uma hipótese sobre a influência na concentração de nutrientes é que, quanto maior a ordem do riacho, menor a declividade e, conseqüentemente, maior a probabilidade de presença de atividades agrícolas (HAIDARY et al., 2013). A morfometria do lago, i.e., área, profundidade e existência de barragens, foi definida como um preditor da claridade de lagos em Wisconsin, EUA, sendo o terceiro fator mais importante após as variáveis climáticas e de uso e cobertura do solo (ROSE et al., 2017). Nielsen et al. (2012) também confirmaram, ao estudar lagos na Dinamarca, que as métricas em escala de bacia e *buffer* têm melhor performance como variáveis preditoras de nutrientes e clorofila *a* em lagos profundos.

Os fatores físicos tiveram influência mais destacada na qualidade da água no período antes da estação chuvosa, quando há menor aplicação de fertilizantes e escoamento superficial (JOHNSON et al., 1997; OU; WANG, 2011). Nessa época, as variáveis físicas podem isoladamente explicar cerca de 15 a 17% da variação (JOHNSON et al., 1997; PAULA et al., 2018). Durante a estação chuvosa, os fatores físicos ainda têm importância, porém, o efeito do uso e cobertura do solo se torna preponderante (JOHNSON et al., 1997; OU; WANG, 2011). Alguns autores reforçam que o fator mais relevante é a interação entre as variáveis físicas e de uso e cobertura do solo, que explicaria a maior parte da variação na qualidade da água (JOHNSON et al., 1997; CLÉMENT et al., 2017). Ainda, Sun et al. (2014) destacaram que as características topográficas foram essenciais para prever a qualidade da água na escala de *buffer*, mas na escala de bacia predominou a influência das métricas de paisagem.

4 DISCUSSÃO

Os resultados da revisão sistemática reforçam que, embora incipiente, a relação entre padrão da paisagem e qualidade da água tem sido mais pesquisada na última década, havendo uma tendência no aumento no número de publicações (UUEMAA; MANDER; MARJA, 2013; QIU, 2019). Entretanto, a pesquisa está distribuída globalmente de forma desigual, pois os estudos se concentram em áreas de clima temperado e continental, especialmente nos Estados Unidos e China, dois países líderes no estudo de métricas da paisagem como indicadores de funções ecológicas (UUEMAA; MANDER; MARJA, 2013). Isso significa que os resultados apresentados, discussões e conclusões derivadas podem estar sujeitos às particularidades dos ambientes estudados nesses locais. É necessário um esforço para produzir pesquisas em ambientes de clima tropical, com destaque para a América do Sul, África e sul e sudeste asiáticos, de forma a complementar as evidências que constam na literatura.

Alguns trabalhos da revisão empregaram séries temporais de parâmetros de qualidade da água, porém foi raro o uso de séries abrangendo mais de 10 anos de informação, indicando que as variações espaciais têm sido enfatizadas e as temporais pouco estudadas (KŘOVÁKOVÁ et al., 2015). Uma justificativa para a escassez de estudos em longo prazo é a carência de séries de dados de qualidade e que abrangem vários anos (KŘOVÁKOVÁ et al., 2015). Poucos estudos utilizaram modelos de simulação para obter as variáveis de qualidade da água e relacioná-las com o padrão da paisagem. Esse dado reforça a importância de explorar tais métodos para testar diferentes cenários de paisagem, sendo uma alternativa aos experimentos de campo que podem ser longos e dispendiosos (LI; WU, 2004; MAYER et al., 2016). Acoplar modelos espacialmente explícitos com modelos neutros fornece ainda a possibilidade de testar diferentes hipóteses em desenhos experimentais únicos (ZHANG; YANG, 2013). Outra característica do conjunto de trabalhos foi a falta de algumas informações sobre o delineamento das pesquisas, e.g., apenas 44% dos estudos forneceram a área das bacias analisadas. Considerar a extensão espacial é muitas vezes indispensável, visto que, em ecologia da paisagem, a estrutura da paisagem e os processos ecológicos podem ser sensíveis à escala de observação (WIENS, 2002). Conforme é discutido mais adiante, os efeitos do uso e cobertura do solo na qualidade da água são múltiplos e dependentes da escala (LIU et al., 2017).

Embora uma grande diversidade de parâmetros e métricas tenha sido coletada dos estudos incluídos, houve pouca sobreposição das métricas avaliadas, pois apenas 47% delas foram relacionadas a um indicador com no mínimo cinco resultados. Foi comum que um único artigo analisasse um componente da paisagem (e.g., agregação) utilizando múltiplas métricas,

que muitas vezes são redundantes (NEEL; MCGARIGAL; CUSHMAN, 2004; CUSHMAN; MCGARIGAL; NEEL, 2008). Consequentemente, houve um grande volume de relações métrica-parâmetro, mas poucos resultados para cada uma delas e uma dependência inerente entre os tamanhos de efeito extraídos de amostras que se sobrepõem, o que dificulta o desenvolvimento de meta-análises (ROTHSTEIN et al., 2013). Para sintetizar múltiplos resultados em um único ou poucos efeitos sumários pode-se adotar as estratégias reducionista ou integrativa (LÓPEZ-LÓPEZ et al., 2018), sendo que a primeira foi usada neste trabalho. Dentro da abordagem integrativa há métodos que são capazes de lidar com a dependência dos tamanhos de efeito e gerar um efeito sumário a partir de múltiplos resultados (LÓPEZ-LÓPEZ et al., 2018). Porém, alguns desses métodos, como a meta-análise multivariada e a estimação robusta da variância, requerem em seus cálculos as correlações entre os tamanhos de efeito estimados a partir de uma amostra (LÓPEZ-LÓPEZ et al., 2018), que raramente são reportadas pelos estudos (MENGERSEN; JENNIONS; SCHMID, 2013). Por conseguinte, futuras pesquisas devem focar em utilizar poucas métricas, não redundantes, e que sejam representativas de aspectos diferentes do padrão da paisagem (NEEL; MCGARIGAL; CUSHMAN, 2004). É preciso explorar a relação da estrutura da paisagem com outros indicadores além dos nutrientes, visto que estes foram largamente avaliados pelos trabalhos incluídos. Ainda, o fornecimento da matriz de correlação das variáveis deve ser imperativo de forma a propiciar o desenvolvimento tanto de meta-análises tradicionais quanto de modelos que acomodam a não independência dos tamanhos de efeito.

A composição, em especial a proporção da paisagem, foi extensivamente analisada pelos artigos e relacionada com a qualidade da água. Por outro lado, a configuração foi pouco estudada, e ainda menos a configuração das florestas. Este resultado confirma a predominância na literatura de análises composicionais, enquanto a configuração da paisagem, e menos ainda a configuração das florestas, têm sido negligenciadas pelos estudos de processos hidrológicos (KEARNS et al., 2005; VERHAGEN et al., 2016; QIU, 2019; MELLO et al., 2020). Embora haja um grande volume na literatura sobre o assunto, o entendimento dos efeitos da configuração da paisagem nos serviços ambientais permanece em estágio embrionário (EIGENBROD, 2016). Kearns et al. (2005) já haviam constatado a dificuldade em conectar padrão da paisagem e qualidade da água devido à existência de resultados contrastantes na literatura. Um dos motivos seria a variação inerente ao uso de diferentes áreas de estudo e delineamentos metodológicos (KEARNS et al., 2005). De fato, questões metodológicas relativas aos trabalhos incluídos foi um fator que dificultou a síntese quantitativa dos dados nesta revisão da literatura.

O uso de métricas da paisagem na tomada de decisão envolve não só a relevância ecológica e a fundamentação dos índices, mas também sua facilidade de interpretação por não especialistas, i.e., políticos, gestores e o público em geral (KUPFER, 2012). Muitos estudos afirmaram que seus resultados podem fornecer informações para gestão da paisagem aos tomadores de decisão, porém sem analisar explicitamente se as métricas utilizadas têm potencial para isso, principalmente se são fáceis de interpretar e se possuem habilidade em comunicar a informação ao público (DRAMSTAD, 2009). Foi comum nos trabalhos desta revisão a análise da configuração em nível de paisagem em vez da configuração de diferentes classes. Porém, utilizar índices mensurados em nível de paisagem na orientação de políticas de planejamento e gestão é dificultoso, pois não há especificação sobre o arranjo dos usos e coberturas que são mais fáceis de serem manejados (i.e., florestas, áreas agrícolas e pastagens). Portanto, estudos voltados para a provisão de orientações de planejamento e gestão da paisagem devem avaliar métricas que atendam aos requisitos para serem utilizadas pelos tomadores de decisão. Mais especificamente, recomenda-se a análise de métricas de configuração dos diferentes usos e coberturas do solo de forma a indicar precisamente quais classes podem ser manejadas para melhorar a qualidade da água.

O padrão da paisagem pode impactar positivamente ou negativamente a provisão dos serviços ambientais (CHEN; CHI; LI, 2020). O quadro geral obtido pela revisão sistemática indica que a composição, basicamente representada pela porcentagem de floresta, agricultura e área urbana, se relaciona com a qualidade da água em escala de bacia e *buffer*. Entretanto, essas evidências vêm sendo obtidas e divulgadas desde o fim da década de 1990, quando estudos relacionando o uso e cobertura do solo com a qualidade da água, tendo nitrogênio e fósforo como principais indicadores, começaram a surgir (GRIFFITH, 2002). Considerando diferentes contextos e ambientes, a literatura aponta que a proporção de florestas está associada a um menor aporte de poluentes na água, enquanto os usos agrícolas e urbanos são prejudiciais (DELKASH; AL-FARAJ; SCHOLZ, 2018). De fato, esses usos antropogênicos são fortes preditores da concentração de nutrientes na água independentemente da capacidade de transporte das bacias hidrográficas (FRATERRIGO; DOWNING, 2008).

Embora uma maior porcentagem de floresta tenha sido associada a uma melhor qualidade da água, essa correlação pode ter ocorrido devido a uma menor proporção dos usos agrícola e urbano na escala de análise e, conseqüentemente, menor carga de contaminantes (GERGEL, 2005; WANG et al., 2014). Portanto, é uma prioridade de pesquisa explorar a configuração das florestas de forma a capturar e entender possíveis funções de interceptação e absorção de poluentes, especialmente em escalas menores. Em alguns estudos da revisão, a

quantidade de floresta correlacionou positivamente com a concentração de nutrientes na água, especialmente o nitrato. Uma possível explicação para esse resultado é que a classe “floresta” extraída dos estudos abrangeu formações seminaturais com florestas plantadas e/ou manejadas. Fatores que regulam a lixiviação do nitrogênio de florestas temperadas abrangem a deposição atmosférica, uso de fertilizantes e plantas fixadoras de N, perturbações devido ao manejo das florestas por corte raso e desbaste, e mineralização do N do solo por ações de preparo do solo, calagem e drenagem em ecossistemas florestais (GUNDERSEN; SCHMIDT; RAULUND-RASMUSSEN, 2006). Além disso, outros fatores relatados incluem o uso intenso de fertilizantes em outras coberturas na bacia, como a cana-de-açúcar no Brasil, e a degradação e fragmentação das florestas remanescentes (MORI et al., 2015).

A influência da poluição difusa, que pode ser maior ou menor de acordo com os outros usos e coberturas presentes na bacia, muitas vezes é superada pelo efeito da poluição pontual em bacias altamente urbanizadas. O uso urbano foi a classe que se relacionou de forma adversa com o maior número de indicadores, se firmando como um dos principais preditores da qualidade da água em diferentes escalas espaciais (LIU et al., 2017). Em regiões densamente urbanizadas, o nitrogênio advém majoritariamente de efluentes domésticos (BU et al., 2016; LIU et al., 2018), sendo que as estações de tratamento de águas residuais também podem introduzir poluentes na água (LIU; SHEN; CHEN, 2018). Além do acentuado efeito da poluição pontual, a impermeabilização do solo pode intensificar a poluição difusa (NOVOTNY et al., 2005). Embora tenha se relacionado com a qualidade da água, a proporção de área urbana pode ter pouca utilidade para o planejamento e gestão hídrica, visto que a área impermeabilizada muitas vezes é irreversível e tende a aumentar com o tempo (NOVOTNY et al., 2005). Portanto, são necessárias mais pesquisas sobre a configuração da área urbana de forma a identificar se há diferentes padrões de ocupação relacionados a um menor impacto da poluição difusa. Por outro lado, a relação entre a qualidade da água e o padrão da paisagem é mais complexa em bacias menos urbanizadas (SUN et al., 2014), tornando-as locais essenciais para o estudo da estrutura de outros usos e coberturas que são mais simples de serem manejados, i.e., agricultura, pastagem e florestas.

Enquanto a área urbana teve efeito prejudicial na qualidade da água considerando múltiplos parâmetros, a agricultura foi relacionada somente com nitrogênio e fósforo. Os nutrientes são os principais poluentes em grandes bacias no mundo (GIRI, 2021) e advêm principalmente dos fertilizantes, cuja aplicação nas áreas agrícolas aumentou drasticamente desde a década de 1960 (SCANLON et al., 2007). Como resultado, ao atingir a água, esses nutrientes podem levar à eutrofização, cujas principais consequências são a proliferação de

cianobactérias e depleção do oxigênio dissolvido (GIRI, 2021). De fato, em muitos países, a agricultura ultrapassou as indústrias e assentamentos humanos como principal fator de degradação da qualidade da água (MATEO-SAGASTA; ZADEH; TURRAL, 2017). Em uma análise em escala nacional nos Estados Unidos, Paudel e Crago (2020) concluíram que um aumento de 10% no uso (kg) e intensidade (kg/acre) de aplicação de fertilizantes eleva em cerca de 1 até 1,5% a concentração de nitrogênio e fósforo na água superficial. Ainda que reduzir a proporção de áreas cultivadas seja uma ação a ser adotada por instrumentos de política e gestão, é preciso buscar medidas para reduzir a carga de fertilizantes que é utilizada nas culturas, visto que ela se relaciona diretamente com o aporte de nutrientes (HOU et al., 2020). São necessárias pesquisas que explorem o arranjo da área agrícola em combinação com diferentes taxas de aplicação de fertilizantes, de forma a identificar se a configuração pode mitigar o aporte de poluentes na água. Para compreender melhor a relação da agricultura com a qualidade da água e explorar possíveis soluções, recomenda-se que futuros estudos reportem os tipos de cultura, práticas de manejo, uso de fertilizantes e pesticidas, bem como outras informações como períodos de plantio, cultivo e colheita (MELLO et al., 2020).

Ao contrário das áreas urbana e agrícola, a proporção de pastagem não se relacionou significativamente com os indicadores, sugerindo que essa cobertura pode não ter um papel claro como fonte ou sumidouro de poluentes. Nesta revisão, essa categoria abrangeu tanto campos nativos quanto pastagens plantadas, com diferentes sistemas de manejo, exploradas ou não. Nesse sentido, a influência da pastagem pode ser modulada pela intensidade do manejo aplicado a essas áreas. Em estudo no Brasil, Mello et al. (2018) verificaram que a pastagem não apresentou relação adversa com a qualidade da água, possivelmente porque na área de estudo predominavam os pastos abandonados. Portanto, o tipo de cobertura, a taxa de aplicação de fertilizantes e a densidade de cabeças podem ser fatores cruciais para que as pastagens tenham efeito degradante na qualidade da água (MELLO et al., 2020; TANIWAKI et al., 2017). De fato, coberturas gramíneas ou herbáceas podem ter efeito benéfico ou menor impacto quando comparadas às áreas agrícolas de culturas anuais. A revisão da literatura feita por Cole, Stockan e Helliwell (2020) aponta que *buffers* de gramíneas são bastante eficientes em reter a poluição difusa. Ha e Wu (2015) identificaram que a conversão de plantações de milho e soja pouco produtivas em cultivos de uma herbácea perene nativa destinada à produção de biocombustível reduziu o aporte de nutrientes e sedimentos na água, com destaque para a eficácia da herbácea na zona ripária. Por outro lado, a conversão de pastagem em áreas de agricultura intensiva pode ser prejudicial aos ecossistemas aquáticos, especialmente em regiões tropicais devido à precipitação (TANIWAKI et al., 2017). Taniwaki et al. (2017) constataram que a concentração

de nitrato e sólidos suspensos foi quatro vezes maior em bacias com cana-de-açúcar do que em bacias com pastagem. Portanto, futuros estudos visando investigar a capacidade preditiva de métricas de composição para a pastagem devem levar em conta as diferentes coberturas e seu manejo associado. Ainda, se torna imprescindível a implementação de boas práticas nas propriedades rurais paralelamente às políticas voltadas para o manejo da composição e configuração da paisagem.

Outras métricas também apresentaram um número suficiente de resultados, mas não tiveram relação clara com a qualidade da água, sendo um destaque a métrica SHDI. Assim como a proporção de pastagem, esse índice pode não ser uma variável preditora útil. Nesse sentido, são necessárias mais pesquisas de forma a aumentar o número de evidências para avaliar a contribuição dessa e outras métricas. Paralelamente, recomenda-se que políticas voltadas para o planejamento e gestão da paisagem visando à qualidade da água empreguem PLAND em vez de métricas em nível de paisagem, como a SHDI. Como já discutido, há um maior número de evidências que indicam uma correlação clara da proporção dos usos agrícola, urbano e florestal com a qualidade da água.

Embora a composição tenha sido apontada como crucial para a predição da qualidade da água, o papel da configuração ainda precisa ser explorado. Os trabalhos corroboraram que, embora a composição pareça exercer um papel preponderante, a configuração pode explicar uma parte da variação nos dados, ainda que pequena (LAMY et al., 2016; RIEB; BENNETT, 2020). Portanto, métricas relacionadas a essa característica da paisagem são importantes para prever a qualidade da água, e alguns estudos sugerem essa relevância especialmente em paisagens com porcentagens intermediárias de fontes de poluentes (GERGEL, 2005; CLÉMENT et al., 2017). A maior probabilidade de a configuração influenciar um processo ecológico em porcentagens intermediárias já havia sido indicada por outros estudos, porém voltados para riqueza e abundância de espécies e deslocamento de animais através da paisagem (e.g., PARDINI et al., 2010; VILLARD; METZGER, 2014). Devido à sua influência na provisão dos serviços ambientais, alterações na configuração devem ser levadas em conta pelos tomadores de decisão (RIEB; BENNETT, 2020) juntamente com a composição e considerando múltiplas escalas espaciais (LAMY et al., 2016). Porém, devido ao efeito majoritário da composição, modificar a configuração pode não ser suficiente para atingir os objetivos relativos à qualidade da água, sendo necessária a alteração dos tipos e quantidades de coberturas na paisagem (QIU; TURNER, 2015). Ainda, futuras pesquisas podem avaliar em quais contextos (e.g., paisagens com diferentes proporções de usos e coberturas, padrões de precipitação,

características topográficas) a configuração da paisagem pode ter maior relevância para a predição da qualidade da água.

Os poucos trabalhos que analisaram limiares ecológicos indicaram que há uma piora brusca na qualidade da água em bacias com pouca proporção de floresta (< 37%), com valores dominantes de área agrícola (> 54 ou 62%), ou com área urbanizada mesmo que em baixa proporção (> 21%). De fato, é esperado que efeitos não lineares ocorram quando há pouca cobertura natural na paisagem e quando as zonas ripárias estão impermeabilizadas (CHAPLIN-KRAMER et al., 2016). Segundo Qiu (2019), poucos estudos têm investigado como o padrão da paisagem se relaciona com a probabilidade de exceder determinados limiares ecológicos, mesmo daqueles já conhecidos (e.g., limiar de fósforo para eutrofização). Embora dinâmicas lineares possam causar mudanças abruptas nos ecossistemas, estas geralmente resultam de processos não lineares (ANDERSEN et al., 2009). Esta revisão confirmou que a maioria dos estudos tende a usar modelos lineares, indicando a necessidade de se reconhecer a não linearidade e possíveis limiares associados à resposta dos serviços ambientais (QIU, 2019). A identificação de limiares ecológicos associados à proporção dos usos e coberturas do solo pode ser de grande valia para subsidiar práticas de gestão mais efetivas. Modificar ligeiramente o padrão da paisagem em torno desses limiares pode resultar em uma melhoria significativa na qualidade da água, proporcionando assim o atingimento de metas específicas de forma eficiente (QIU; TURNER, 2015).

Com relação à escala espacial, os estudos apontaram pouca diferença na variação da qualidade da água explicada pelas métricas em escala de bacia ou *buffer*, o que sugere que ambas são importantes para a gestão da paisagem. Diferentes índices podem se relacionar com uma melhor qualidade da água de acordo com a escala considerada, e.g., maior porcentagem de florestas no *buffer* e menor porcentagem de áreas urbana e agrícola na bacia. Ainda, para cada indicador da água diferentes métricas podem ser relevantes, e.g., a importância da estrutura do *buffer* na retenção dos nutrientes. A importância da estrutura da paisagem na zona ripária durante a estação chuvosa e da bacia hidrográfica durante a estação seca podem ser parcialmente explicadas pela contribuição sazonal relativa das fontes de poluição (LIU et al., 2017). Essas diferenças podem ser um reflexo da prevalência da poluição pontual na estação seca, e da difusa na estação chuvosa (LIU et al. 2017). Portanto, para entender os impactos da paisagem na qualidade da água é preciso adotar uma abordagem multiescala (URIARTE et al., 2011). Os *buffers* dos ambientes aquáticos têm papel fundamental na mitigação da poluição difusa, mas podem não ser suficientes (POTTER; CUBBAGE; SCHABERG, 2005), especialmente em bacias altamente urbanizadas (DIEBEL et al., 2009). Assim, além do padrão

dos *buffers* dos corpos d'água, a consideração do uso e cobertura do solo na bacia hidrográfica deve ser essencial para o planejamento e gestão hídrica (DING et al., 2016; LIU et al., 2017; MELLO et al., 2018).

Apenas 20% dos resultados deste trabalho foram obtidos em escala de *buffer*, revelando que as métricas nessa escala precisam ser exploradas por futuros estudos. Os *buffers*, em especial as faixas ripárias cobertas com florestas ou gramíneas e herbáceas, são mecanismos importantes para a regulação da poluição difusa (COLE; STOCKAN; HELLIWELL, 2020), sendo capazes de reter a maior parte de nutrientes e sedimentos que atingiria os corpos d'água (DIEBEL et al., 2009). Com relação à largura das faixas, os resultados indicaram que *buffers* florestais com largura entre 100 e 250 m e, mais seguramente, até 500 m, são eficientes em reter os poluentes, principalmente nutrientes. Um estudo desenvolvido no Brasil por Valera et al. (2019) determinou que as faixas ripárias têm maior capacidade de retenção quando são mais largas que 50 m, embora a qualidade da água resultante ainda seja ruim. Em paisagens com cerca de 31 a 53% de floresta nativa, os autores afirmam que *buffers* de 90 a 205 m estariam associados a uma qualidade da água regular. Além disso, é importante não só implementar faixas largas, mas também manter uma elevada proporção de vegetação nativa na bacia (VALERA et al., 2019). Esses resultados sugerem que o *buffer* ripário de 30 m proposto pela Lei de Proteção à Vegetação Nativa (Lei nº 12.651/2012) pode não ser suficiente para proteger a qualidade da água (VALERA et al., 2019). Nesse sentido, recomenda-se avaliar faixas de vegetação nativa menores que 100 m e em paisagens com diferentes percentuais de coberturas, principalmente em ecossistemas tropicais.

O padrão da paisagem influenciou a qualidade da água tanto na estação seca quanto na chuvosa, embora seu efeito tenha se destacado durante esta última, quando a precipitação é responsável pela mobilização e transporte dos poluentes. Devido a esse fenômeno, a composição na escala de bacia sobressai como importante preditor durante esse período, e na estação seca destaca-se a relevância das fontes pontuais de poluição. De fato, na estação seca o nitrogênio advém predominantemente de efluentes domésticos, enquanto na estação chuvosa há adição do nitrogênio advindo do solo e de fertilizantes (LIU et al., 2018). Os efluentes provenientes das fontes pontuais podem mascarar o efeito da poluição difusa, dificultando tanto os estudos da paisagem quanto as ações de gestão. Ao estudar lagos na Dinamarca, Nielsen et al. (2012) verificaram que a exclusão de lagos que comprovadamente recebiam poluição pontual resultou em maior variação explicada pelas porcentagens de agricultura e floresta na bacia. Portanto, as fontes pontuais precisam ser controladas, e as variações sazonais podem auxiliar na gestão do risco de contaminação da água (LIU et al., 2017). Ainda, estudos voltados

para analisar a relação entre o padrão da paisagem e a qualidade da água devem se atentar para a presença de fontes pontuais, de forma que o delineamento da pesquisa seja capaz de detectar corretamente o papel da poluição difusa.

A distribuição dos serviços ambientais na paisagem resulta de uma ação combinada de agentes antropogênicos e sistemas naturais (CHEN; CHI; LI, 2020). Deste modo, além do padrão das coberturas naturais, é preciso considerar explicitamente fatores biofísicos, culturais e sociais (EIGENBROD, 2016). Neste trabalho, foi evidenciado que as características físicas têm influência isolada e combinada por meio da interação com o uso e cobertura do solo. O efeito isolado das variáveis físicas é mais perceptível durante a estação seca, sendo que durante a chuvosa o uso e cobertura do solo predomina como preditor da variação na qualidade da água. A maioria das variáveis físicas apontadas pelos trabalhos da revisão já haviam sido sugeridas como influenciadoras da integridade das águas superficiais (NOVOTNY et al., 2005). A precipitação e outras características como tamanho, forma e declividade na bacia podem ter papel central na predição dos impactos dos usos e coberturas (DELKASH; AL-FARAJ; SCHOLZ, 2018). Esses aspectos também podem ser variáveis relevantes em bacias hidrográficas com alta capacidade de transporte (FRATERRIGO; DOWNING, 2008). Portanto, futuros estudos devem reconhecer o papel desses fatores e propor desenhos de pesquisa que sejam capazes de lidar com possíveis interações entre variáveis físicas e uso e cobertura do solo.

A área da bacia, um fator que se relaciona com a escala de análise em ecologia da paisagem, pode modular os efeitos da poluição difusa na qualidade da água. Em riachos de alta ordem, a quantidade dos usos e coberturas pode ser um melhor preditor, enquanto em riachos de menor ordem as variações locais no uso e cobertura do solo podem ser mais relevantes (BUCK; NIYOGI; TOWNSEND, 2004). A área urbana, por exemplo, tem relação forte com a qualidade da água em bacias maiores (WANG et al., 2014). Alguns artigos recomendaram o uso de bacias maiores que 10 km² em estudos sobre a relação da paisagem e das florestas com a qualidade da água, pois os modelos preditivos costumam ter melhor desempenho quando aplicados em bacias a partir desse tamanho. Os resultados também sugerem que o efeito da configuração pode ser mais evidente em escalas menores. Zhang e Yang (2013) demonstraram que modelos baseados na composição tiveram melhor desempenho em explicar a variação de nitrogênio em bacias maiores, enquanto a configuração teve maior influência nas bacias pequenas. Portanto, recomenda-se que o planejamento e gestão em escala regional enfatizem a composição, e em escala local observem a configuração da paisagem (ZHANG; YANG, 2013).

5 CONCLUSÃO

A revisão da literatura permitiu a elaboração de uma base de evidências sistematizada sobre a relação entre estrutura da paisagem e qualidade da água, considerando também a influência de outros fatores espaciais, temporais e físicos. O panorama obtido indicou que as pesquisas sobre essa relação padrão-processo têm sido mais frequentes na última década, embora se concentrem basicamente em áreas de clima continental e temperado situadas nos EUA e na China. Os estudos deram destaque para a avaliação da influência da composição da paisagem, principalmente da proporção ocupada pelos diferentes usos e coberturas do solo. Entretanto, esta relação se encontra relativamente consolidada na literatura, visto que uma maior proporção de coberturas consideradas fontes, e.g., agrícolas e urbanas, está associada com a poluição da água, enquanto coberturas consideradas sumidouros, e.g., florestas, se associam a uma melhor qualidade da água. Por outro lado, o papel da configuração foi pouco explorado, e menos ainda a configuração das florestas. Conseqüentemente, só foi possível observar relação significativa de parâmetros de água com métricas de composição.

Ambas as escalas de bacia hidrográfica e *buffers* aquáticos foram apontadas como importantes para a regulação da qualidade da água. O teste do sinal indicou que uma maior proporção da paisagem ocupada por florestas está relacionada a uma melhor qualidade da água. Por outro lado, maiores proporções de áreas agrícolas e urbanas se associaram a uma pior qualidade da água, sendo que esta última se relacionou com um maior número de indicadores. A proporção de pastagem não despontou como um preditor importante, provavelmente porque seu papel pode ser modulado por outras variáveis como o tipo de cobertura e a intensidade do pastejo. Além disso, constatou-se que as características sazonais e físicas da bacia de drenagem podem modular o efeito que o padrão da paisagem exerce na qualidade da água, exigindo que sejam consideradas durante o planejamento e gestão. Os resultados sintetizados neste capítulo podem ser agregados ao conhecimento sobre a provisão de outros serviços ambientais de forma a subsidiar o planejamento e gestão de paisagens multifuncionais.

Recomenda-se que estudos futuros investiguem a existência de limiares ecológicos e o papel da configuração, especialmente das florestas, em regular a qualidade da água. Ademais, indica-se explorar o papel da composição em combinação com diferentes configurações de coberturas, intensidade de manejo, e variáveis físicas e sazonais. Para isso, métricas não redundantes e que representem adequadamente as diferentes configurações da paisagem devem ser empregadas. Além disso, de forma a subsidiar futuras políticas e ações de gestão,

recomenda-se investigar a configuração de usos e coberturas do solo que são mais fáceis de manejar, como a agricultura, pastagem e floresta.

CAPÍTULO 2

INFLUÊNCIA DA COMPOSIÇÃO E CONFIGURAÇÃO DA PAISAGEM NA PRODUÇÃO DE SEDIMENTOS: UM EXPERIMENTO DE SIMULAÇÃO

1 INTRODUÇÃO

O conhecimento sobre como o padrão da paisagem, ou seja, as quantidades e configurações dos usos e coberturas do solo, se relaciona com os processos ecológicos pode subsidiar o planejamento e gestão de paisagens voltadas para a provisão de múltiplos serviços ambientais (JONES et al., 2012; WU, 2013a). Por meio da análise de causas, consequências e interações provocadas pelos vetores de degradação em múltiplas escalas, estudos baseados na disciplina de ecologia da paisagem podem fornecer subsídios para a tomada de decisão (MAYER et al., 2016). Para que isso se concretize, entretanto, é preciso que a conexão entre estrutura da paisagem e provisão dos serviços esteja esclarecida (MITCHELL; BENNETT; GONZALEZ, 2013).

Do ponto de vista dos serviços ambientais hidrológicos, esta relação não se encontra consolidada na literatura, parte porque os estudos têm enfatizado análises da influência da composição e negligenciado o papel que o arranjo espacial dos usos e coberturas do solo pode desempenhar (JONES et al., 2012; QIU, 2019; MELLO et al., 2020). Alguns autores sugerem que, embora a composição da paisagem tenha uma função preponderante, a configuração pode influenciar a provisão dos serviços ambientais que dependem do atributo de qualidade da água (QIU; TURNER, 2015; VERHAGEN et al., 2016; RIEB; BENNETT, 2020). Além disso, a escala de bacia hidrográfica tem sido enfatizada nas análises, enquanto poucos estudos se atêm ao papel que a estrutura na zona ripária pode desempenhar (MELLO et al., 2020). Porém, alguns autores afirmam que, para compreender a influência das alterações na paisagem na qualidade da água, múltiplas escalas espaciais devem ser consideradas, i.e., a bacia hidrográfica e a zona ripária (URIARTE et al., 2011; DING et al., 2016).

A provisão de serviços ambientais dependentes da qualidade da água tem se mostrado intrinsecamente relacionada com a proteção da cobertura florestal na paisagem (BU et al., 2014; MELLO et al., 2020). Diversos estudos apontaram a influência benéfica da quantidade de floresta em ambas as escalas de bacia e zona ripária em múltiplos indicadores de qualidade da água (LOPEZ et al., 2008; URIARTE et al., 2011; DING et al., 2016; DE OLIVEIRA;

MAILLARD; DE ANDRADE PINTO, 2017; MELLO et al., 2018). Por outro lado, poucos estudos têm avaliado como o arranjo da cobertura florestal nessas escalas pode influenciar a qualidade da água (QIU, 2019).

Uma alternativa para o estudo do papel de diferentes arranjos espaciais em um processo ecológico são os experimentos de simulação baseados em réplicas de paisagens. O uso de paisagens artificiais, como as geradas por modelos neutros, possibilita a avaliação de uma miríade de diferentes cenários de uso e cobertura do solo (LI; WU, 2004; WANG; MALANSON, 2008), facilitando estudos teóricos sobre o efeito do padrão espacial nos processos ecológicos (TISCHENDORF, 2001). Os experimentos com paisagens artificiais permitem ao pesquisador controlar variáveis de confusão, que são comuns em bacias hidrográficas reais (SPAKE et al., 2017). Conseqüentemente, ao isolar fatores de complexidade como o tipo de solo e a declividade, é possível discriminar a influência dos processos afetados pelo arranjo espacial e que são o objeto de investigação (WANG; MALANSON, 2008).

O uso de modelagens tem se mostrado uma ferramenta relevante para que cientistas e tomadores de decisão possam contemplar diferentes cenários que irão subsidiar o planejamento e gestão espaciais (MAYER et al., 2016; SYNES et al., 2016). Modelos que fornecem réplicas de paisagens podem ser combinados a modelos espacialmente explícitos que simulem múltiplos processos ecológicos de interesse (ZHANG; YANG, 2013; SYNES et al., 2016). Conseqüentemente, essas projeções sobre como os sistemas ecológicos respondem a essas mudanças no uso e cobertura do solo podem auxiliar na compreensão de sistemas dinâmicos e complexos, facilitando o seu gerenciamento (SYNES et al., 2016). Uma vantagem dos experimentos de simulação consiste na possibilidade de estudar estruturas espaciais que seriam difíceis ou impossíveis de replicar em experimentos de campo, que geralmente dependem de tempo e recursos para serem executados (MAYER et al., 2016).

Para se testar hipóteses sobre a relação entre padrão da paisagem e qualidade da água, modelos espacialmente explícitos que se baseiam na perda de solo e no transporte dos sedimentos através da bacia hidrográfica podem ser utilizados (HAMEL et al., 2015). Ao estimar a produção de sedimentos, ou seja, a quantidade de solo erodido que de fato atinge a água, é possível determinar como diferentes cenários de mudança no uso e cobertura do solo irão impactar a qualidade da água e, conseqüentemente, os serviços ambientais dependentes deste atributo (KEELER et al., 2012; HAMEL et al., 2015). Modelos hidrológicos que requerem poucos dados de entrada, como aqueles baseados na equação universal de perda de solo (USLE) combinada a um algoritmo de razão de entrega de sedimentos, possuem valor para os tomadores de decisão ainda que não forneçam estimativas absolutas precisas (HAMEL et al., 2020).

Estimativas de cargas anuais de sedimentos podem ser derivadas para diferentes intervenções, subsidiando decisões de gestão aplicadas na escala de bacia hidrográfica (HAMEL et al., 2020).

Diante da necessidade de se gerar mais evidências sobre a influência da configuração das florestas em escala de bacia hidrográfica e zona ripária na provisão dos serviços ambientais hidrológicos, um experimento de simulação foi executado neste capítulo. Por meio de um acoplamento de modelos neutros de paisagem com um modelo de simulação de cargas anuais de sedimentos, múltiplos cenários de quantidade e arranjo espacial das florestas foram avaliados. Mais especificamente, cenários planejados e não planejados foram concebidos de forma a verificar as consequências na qualidade da água e como eles podem ser considerados em um contexto de planejamento e gestão das paisagens.

Portanto, o **objetivo geral** deste capítulo foi avaliar a influência da quantidade e configuração das florestas nas escalas de bacia hidrográfica e zona ripária na produção de sedimentos. Como **objetivos específicos** foram definidos:

- 1) Obter um modelo calibrado de produção de sedimentos para uma bacia hidrográfica real;
- 2) Modelar a produção de sedimentos em réplicas simuladas desta bacia hidrográfica com diferentes quantidades e configurações de cobertura florestal;
- 3) Comparar a produção de sedimentos de paisagens com disposição planejada e não planejada da cobertura florestal;
- 4) Identificar a influência da proporção e configuração das florestas na produção de sedimentos nas réplicas de paisagens simuladas;
- 5) Sugerir métricas de paisagem da cobertura florestal que podem explicar a produção de sedimentos nas réplicas de paisagens simuladas.

1.1 Referencial teórico

Os modelos representam abstratamente de forma simplificada um sistema ou um processo real, sendo úteis para explorar consequências e hipóteses em um ambiente controlado (TURNER; GARDNER, 2015). Especialmente em ecologia da paisagem, os modelos espaciais têm sido vantajosos, visto que muitas vezes é difícil conduzir experimentos nas escalas ideais ou selecionar paisagens que exibam combinações das condições espaciais que se deseja estudar (TURNER; GARDNER, 2015). Além dos conceitos apresentados no capítulo anterior, este capítulo está baseado em dois modelos desenvolvidos em disciplinas diferentes e em contextos diferentes, que foram integrados para atingir o objetivo geral: modelos neutros de paisagem e

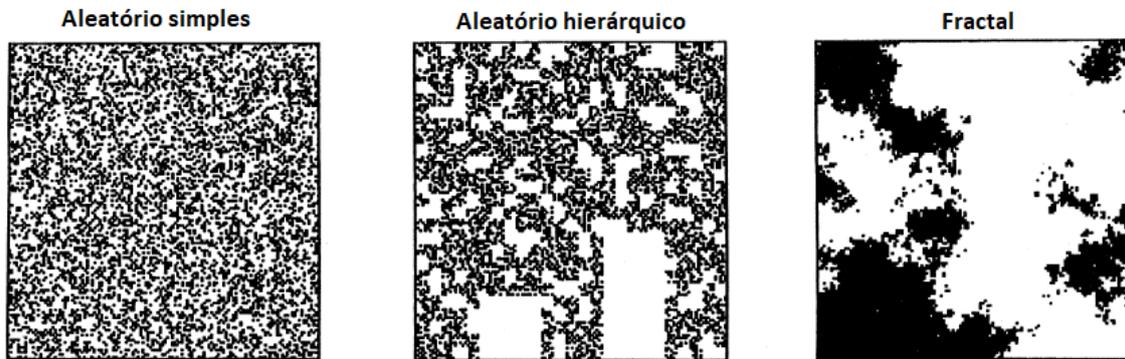
modelos de produção de sedimentos. A seguir, uma breve contextualização de ambos é fornecida.

1.1.1 Modelos neutros de paisagem

Os modelos neutros são ferramentas para a geração de paisagens matriciais artificiais em que as condições que determinam o padrão espacial em sistemas reais são inexistentes, portanto, “neutras” (LI et al., 2004; SYNES et al., 2016). Assim, esses modelos simulam o padrão espacial na ausência de certos processos, sendo adequados para testar hipóteses nulas (TURNER; GARDNER, 2015). Ao eliminar esses fatores que restringem as estruturas espaciais na realidade – como tipo de solo, topografia, rede hidrográfica e padrões de ocupação humana – é possível isolar a importância dos aspectos da estrutura da paisagem e avaliar seus efeitos nos processos ecológicos (FORTIN et al., 2003; WANG; MALANSON, 2008). Os modelos neutros são baseados geralmente em processos estocásticos com pelo menos um argumento gerador – a porcentagem de presença de uma determinada classe – e eventualmente algum parâmetro de autocorrelação espacial que indique a probabilidade de duas células vizinhas terem características iguais (FORTIN et al., 2003).

Os primeiros modelos neutros propostos eram baseados na teoria da percolação, portanto, geravam paisagens bidimensionais com distribuição totalmente aleatória (GUSTAFSON et al., 2019). Em seguida, foram introduzidos os modelos hierárquicos e os fractais, em que a configuração depende de certo grau de aglomeração das manchas (WITH; KING, 1997). A diferença entre eles é como as manchas estão agregadas – o segundo apresenta uma configuração que varia por blocos, enquanto o terceiro tem uma configuração menos sistemática e mais contínua (Figura 13). Os modelos totalmente aleatórios possuem suas aplicações, como a geração de hipóteses nulas ou a investigação de processos que podem não depender do padrão espacial (WITH; KING, 1997). Desvantagens desses modelos simples são a binaridade e seu caráter totalmente aleatório, que podem não ser adequados para representar paisagens com feições mais realísticas (WANG; MALANSON, 2008).

Figura 13 – Três exemplos de modelos neutros de paisagem gerados a partir da mesma proporção de uma classe ($p = 0,33$)



Fonte: adaptado de With e King (1997).

O modelo hierárquico pode ser útil para retratar paisagens influenciadas por uma ocupação humana mais sistemática, em que padrões geométricos específicos podem representar determinados usos de interesse, como blocos de culturas agrícolas (WANG; MALANSON, 2008). Entretanto, as mudanças de gradiente deste modelo podem ser consideradas mais abruptas do que as existentes em paisagens reais (WANG; MALANSON, 2008). O mecanismo de agregação presente no modelo fractal permite a geração de paisagens com configuração mais diversa dada uma quantidade fixa da classe, característica importante para o estudo das consequências da configuração nos processos ecológicos (WITH; KING, 1997).

Os principais usos dos modelos neutros são: i) determinar o grau em que as propriedades de uma paisagem desviam de uma distribuição teórica; ii) avaliar como processos ecológicos são afetados por uma estrutura espacial pré-definida (TURNER; GARDNER, 2015). Os modelos neutros contribuíram para o desenvolvimento de vários tópicos de pesquisa em ecologia da paisagem, como a criação de métricas de paisagem e interpretação de seu comportamento, bem como identificação de limiares (WITH; KING, 1997). Mais recentemente, eles têm sido utilizados para estudar o efeito do padrão da paisagem em processos sociais, biogeoquímicos e biofísicos (SYNES et al., 2016).

Os modelos neutros têm grande utilidade para o planejamento de paisagens, pois permitem replicações de diversos cenários (LI et al., 2004; WANG; MALANSON, 2008), proporcionam a geração de hipóteses a serem testadas em paisagens reais (WITH; KING, 1997), e não exigem dados de entrada (SYNES et al., 2016). O uso de paisagens simuladas tem o potencial para gerar e testar hipóteses que seriam difíceis de se estudar em paisagens reais sem a replicação espacial ou sem abranger escalas extensas (WITH; KING, 1997). Experimentos de simulação com apoio de modelos neutros levam ao isolamento das variáveis de confusão e focalizam o padrão espacial, sendo uma alternativa a experimentos de campo

longos e dispendiosos (WANG; MALANSON, 2008). Variações na extensão, resolução, padrões e tipos de coberturas podem ser gerados visando atender a delineamentos experimentais específicos (WANG; MALANSON, 2008). Consequentemente, o uso de modelos neutros se mostra uma alternativa para o estudo da relação entre padrão da paisagem e processos ecológicos, especialmente da perspectiva da configuração dos tipos de coberturas. Outro potencial dessa ferramenta é a possibilidade de ser integrada a outros modelos dinâmicos, permitindo o estudo de outros fluxos (e.g., disseminação do fogo ou transporte de nutrientes) além da dispersão de organismos (WANG; MALANSON, 2008). Devido ao seu potencial para explorar uma variedade de processos resultantes de um mesmo padrão espacial, os modelos neutros devem conservar-se como ferramenta essencial do arcabouço metodológico da ecologia da paisagem (SYNES et al., 2016).

Exemplos de ferramentas para geração de modelos neutros são os programas RULE e QRULE que, mesmo implementados há décadas, ainda são utilizados (GUSTAFSON et al., 2019). A partir de poucos dados de entrada, como a dimensão das matrizes e o número de classes, os algoritmos produzem diferentes paisagens como as da Figura 13. Outros algoritmos, como os fractais, dependem de um gerador de números pseudoaleatório para introduzir perturbações que irão resultar em diferentes configurações (GARDNER, 1999). Neste caso, além da proporção de cobertura, outro argumento é introduzido para mensurar a autocorrelação espacial entre dois pontos na paisagem. Outro método para geração de modelos neutros com aspecto mais realístico é o algoritmo de *clusters* aleatórios chamado Simmap criado por Saura e Martínez-Millán (2000). No entanto, Li et al. (2004) observaram que as matrizes geradas pelo algoritmo fractal do RULE têm aparência menos “estocástica” do que as matrizes geradas pelo Simmap. Sciaini et al. (2018) desenvolveram um pacote para a linguagem de programação R contendo diversos modelos neutros propostos pela literatura ao longo de duas décadas. Os 16 algoritmos reunidos pelos autores fornecem produtos diferentes em função da autocorrelação espacial, que é controlada por um único ou vários parâmetros. Diversos algoritmos estão disponíveis, desde modelos binários totalmente aleatórios até modelos de mosaico discretos. Consequentemente, diversas implementações podem ser escolhidas pelo usuário de acordo com as suas necessidades de modelagem.

Algumas recomendações para a aplicação dos modelos neutros no estudo da relação padrão-processo são pertinentes. Dependendo do tipo de comparação a ser feita, é preciso que as paisagens tenham resolução e extensão compatíveis, bem como tamanho suficiente para amenizar efeitos de fronteira (i.e., evitar matrizes menores que 100x100) (GARDNER, 1999). Comparações entre paisagens de forma a interpretar o efeito da configuração devem considerar

a proporção de classe utilizada, visto que este argumento tem se mostrado a variável mais importante para explicar o padrão nesses modelos (GARDNER, 1999). Além disso, paisagens com padrões bem diferentes podem exibir métricas com valores iguais, enquanto paisagens com padrões semelhantes podem apresentar métricas com valores divergentes (FORTIN et al., 2003). Os resultados de análises de modelos neutros não são diretamente transpostos para paisagens reais, embora sejam adequados para gerar hipóteses que podem ser testadas nestes contextos (WITH; KING, 1997). Paisagens de modelos neutros fractais costumam apresentar mais manchas, especialmente as pequenas, e as manchas maiores tendem a ser mais complexas e retorcidas (NEEL; MCGARIGAL; CUSHMAN, 2004). Consequentemente, métricas calculadas a partir desses modelos não capturam todas as características que permeiam uma paisagem real (LI et al., 2004). No entanto, este fato é justamente o que torna essas paisagens “neutras”, ou seja, a exclusão dos processos que governam o padrão espacial (LI et al., 2004). De forma a fornecer evidências consistentes a partir de experimentos de simulação, Tischendorf (2001) recomenda que paisagens de modelos neutros sejam geradas de forma a contemplar um arranjo espacial mais realístico e considerando diferentes classes de percentuais de cobertura.

1.1.2 Modelo de produção de sedimentos

Diversos modelos de erosão do solo e produção de sedimentos de base física estão disponíveis, sendo que eles são diferentes entre si em complexidade, requerimento de dados e processos considerados (PANDEY et al., 2016). Esses modelos são baseados em equações que abarcam em seus cálculos atributos de topografia, geologia, uso do solo, clima, vegetação, entre outros (PANDEY et al., 2016). Modelos empíricos para a predição da erosão do solo costumam ser baseados na equação universal de perda de solo (USLE) (DE VENTE et al., 2013), da qual derivam também a equação revisada de perda de solo (RUSLE) e a equação modificada de perda de solo (MUSLE). A USLE é uma equação empírica desenvolvida no fim da década de 1960 nos Estados Unidos com vistas ao planejamento de propriedades rurais para combater a perda de solo via práticas de controle de erosão (RENARD et al., 1991). Apesar de a equação ter sido desenvolvida para o contexto norte-americano, modelos baseados na USLE já foram aplicados em mais de 100 países e nos últimos 20 anos têm sido cada vez mais utilizados (ALEWELL et al., 2019).

Uma síntese histórica do desenvolvimento dessa equação segundo Renard et al. (1997) é apresentada a seguir. A USLE foi desenvolvida a partir de esforços distribuídos ao longo de anos de pesquisa matemática sobre a predição de erosão. Na década de 1930, fatores cruciais

para a perda de solo foram identificados, como a suscetibilidade do solo à erosão e a influência de coberturas vegetais. Em seguida, a adição de fatores relacionados aos sistemas de cultivo agrícola tornou explícito o seu papel na erosão. Interesses voltados para a possibilidade de modelar matematicamente a erosão fizeram com que essas equações fossem exportadas para outras regiões dos EUA. Por conseguinte, a utilidade dessas equações regionalizadas despertou um interesse em desenvolver uma equação de generalização nacional para a perda de solo. Um centro de dados foi implementado pela agência governamental de pesquisas agrícolas (*Agricultural Research Service*) na Universidade de Purdue, Indiana, onde dados experimentais de perdas de solo e escoamento em parcelas foram gerenciados. Análises de regressão derivadas desses experimentos formaram então a base para a proposta da equação. Os fatores da USLE são representados por um número que pode ser facilmente calculado a partir de dados de pesquisa e que não são associados a uma escala geográfica específica.

A USLE estima a perda de solo causada pela erosão hídrica em sulcos e entressulcos considerando cinco fatores (equação 1) que foram empiricamente relacionados à erosão (RENARD et al., 1991).

$$usle_i = R_i \cdot K_i \cdot LS_i \cdot C_i \cdot P_i \quad (1)$$

Onde:

R_i = erosividade da chuva (MJ.mm.(ha.h)⁻¹);

K_i = erodibilidade do solo (ton.ha.h.(MJ.ha.mm)⁻¹);

LS_i = fator comprimento da rampa e declividade (adimensional);

C_i = fator uso e manejo do solo (adimensional);

P_i = fator práticas conservacionistas (adimensional).

A USLE tem baixo requerimento de dados e cálculo direto, o que a torna útil em determinadas situações diante da disponibilidade de dados, objetivo de aplicação e facilidade de interpretação (ALEWELL et al., 2019). O modelo pode ser aplicado em contextos de outros países, basta que o cálculo dos seus fatores seja adaptado para as condições locais (ALEWELL et al., 2019). As principais incertezas associadas à USLE se referem ao fato de a equação não considerar erosão por ravinas, erosão fluvial e movimentos de massa (DE VENTE et al., 2013), e modelar perdas de solo apenas em escala anual e em condições médias (RENARD et al.,

1991). Em bacias hidrográficas onde esses processos não são considerados de importância, a equação pode gerar estimativas mais precisas (DE VENTE et al., 2013). Além disso, outras incertezas sobre a sua acurácia se referem à simplicidade inerente ao modelo empírico e à disponibilidade de dados para parametrização e calibração (BENAVIDEZ et al., 2018). Apesar de ser uma equação simplificada, certa complexidade é adicionada à USLE durante o processo de cálculo dos fatores de entrada, os quais podem ser estimados por diversos métodos (BENAVIDEZ et al., 2018). Apesar disso, os modelos baseados na USLE não têm exibido grau de incerteza superior à de modelos mais complexos que requerem um número maior de dados de entrada, como o *Water Erosion Prediction Project* (WEPP) (KINNELL, 2010; ALEWELL et al., 2019). De fato, a flexibilidade, parametrização parcimoniosa, existência de literatura extensa e comparabilidade dos resultados explicam a popularidade dessa equação para mensuração das perdas de solo (ALEWELL et al., 2019).

De acordo com a equação 1, os fatores considerados no cálculo da erosão hídrica são a erosividade da chuva, a erodibilidade do solo, a topografia e o uso e manejo das coberturas do solo. O fator erosividade exprime o poder erosivo do clima por meio da erosividade da chuva, que se relaciona com a quantidade e intensidade da precipitação (RENARD et al., 1991). A proposição original da USLE indica que o fator erosividade é computado a partir do índice de erosividade (EI_{30}), que é calculado para eventos de chuvas erosivas e se baseia no produto da energia cinética ($MJ.ha^{-1}.mm^{-1}$) pela máxima intensidade da chuva em 30 minutos ($mm.h^{-1}$) (equação 2) (OLIVEIRA; WENDLAND; NEARING, 2012).

$$EI_{30} = E_c \times I_{30} \quad (2)$$

Onde:

E_c = energia cinética ($MJ.ha^{-1}.mm^{-1}$);

I_{30} = intensidade máxima da chuva em 30 minutos ($mm.h^{-1}$).

O fator erosividade é computado pela média desses índices EI_{30} considerando a quantidade de anos no registro e o número de eventos erosivos em cada ano (OLIVEIRA; WENDLAND; NEARING, 2012). No entanto, a erosividade é geralmente obtida a partir de dados publicados, visto que seu cálculo é moroso e depende da existência de registros pluviográficos para a área (SHARP et al., 2020). Devido à escassez desses dados, alguns pesquisadores fizeram esforços para relacionar esses índices de erosividade com informações mais facilmente acessíveis, como a precipitação. Equações derivadas da correlação entre os

índices de erosividade e a precipitação anual ou o índice modificado de Fournier desenvolvidas para uma determinada região proporcionam que o fator erosividade seja inferido indiretamente (OLIVEIRA; WENDLAND; NEARING, 2012). Oliveira, Wendland e Nearing (2012) fornecem um compilado de equações desenvolvidas para o Brasil, principalmente para a região sudeste, que podem ser usadas para estimar o fator erosividade em locais com condições climáticas semelhantes a partir de dados de precipitação.

O fator erodibilidade do solo se refere à facilidade com que o solo se desprende pela ação da chuva e do escoamento devido às suas propriedades (RENARD et al., 1997). Esse fator pode ser determinado experimentalmente para diferentes classes de solo, o que demanda tempo e recursos, ou de forma indireta (MANNIGEL et al., 2002). Um dos métodos indiretos é o proposto por Wischmeier, Johnson e Cross (1971), em que são computadas as frações (%) de silte, areia muito fina e argila, bem como o teor de matéria orgânica, a classe de estrutura do solo e a sua permeabilidade (RENARD et al., 1997). Conseqüentemente, os valores de erodibilidade do solo para parametrização de modelos costumam ser obtidos da literatura especializada.

O fator topográfico considera a influência do comprimento da rampa (L) e do gradiente de declividade (S) na erosão. Em razão de críticas ao cálculo original desse fator pela RUSLE, que se mostrou inadequado para topografias complexas, métodos alternativos baseados na área de contribuição ou acumulação de fluxo foram propostos (BENAVIDEZ et al., 2018). Com o avanço de SIGs, esse fator passou a ser facilmente calculado utilizando um modelo digital de elevação (MDE) (OLIVEIRA et al., 2013).

Os últimos fatores se referem ao uso e manejo do solo e à presença de práticas conservacionistas. O fator C se mostra o mais importante no estudo da erosão, pois permite indicar como as perdas de solo podem ser reduzidas pelo uso e manejo do solo na área (RENARD et al., 1991). Valores específicos para diferentes coberturas do solo podem ser encontrados na literatura e inseridos na equação. No entanto, deve-se considerar preferencialmente valores calculados para a mesma área ou região, visto que a caracterização das diferentes coberturas pode variar entre as localidades (BENAVIDEZ et al., 2018). O fator P exprime como práticas conservacionistas implementadas na área, i.e., terraceamento, plantio em nível, entre outros, podem afetar os fluxos hidrológicos na bacia (RENARD et al., 1991). Sua estimativa na equação é útil para estudos que visam inferir como as práticas conservacionistas podem ser positivas para a proteção do solo (BENAVIDEZ et al., 2018).

A USLE modela apenas a perda de solo, não fornecendo dados sobre a deposição do solo erodido nas vertentes ou a exportação de sedimentos, ou seja, o solo erodido que foi

transportado para determinado ponto, como a rede hidrográfica (RENARD et al., 1997). Dado que perda de solo e produção de sedimentos são medidas distintas, para obter esta última é preciso acoplar uma razão ou taxa de entrega de sedimentos (*Sediment Delivery Ratio* - SDR) às estimativas absolutas da USLE (BENAVIDEZ et al., 2018). Esta taxa indica a proporção da erosão que foi transportada entre dois pontos na bacia, o que se relaciona com a quantidade de sedimento que de fato atinge a água (SHARP et al., 2020) e com a conectividade sedimentológica na bacia hidrográfica (VIGIAK et al., 2012). Tradicionalmente essa taxa tem sido considerada constante para todas as parcelas em uma bacia hidrográfica, porém, há métricas que definem a SDR como espacialmente variável nas parcelas a depender de características como a declividade e a resistência ao escoamento (VIGIAK et al., 2012). Algumas dessas medidas espacialmente explícitas são o tempo de viagem (FERRO; MINACAPILLI, 1995) e o índice de conectividade proposto por Borselli, Cassi e Torri (2008).

Alguns dos modelos derivados da USLE incluem o *Soil Water Assessment Tool* (SWAT), que é baseado na MUSLE (ARNOLD et al., 1998), e o *Integrated Valuation of Ecosystem Services and Tradeoffs - Sediment Delivery Ratio* (InVEST SDR). Este último faz parte da iniciativa InVEST que fornece modelos voltados para o mapeamento e a valoração de bens e serviços ambientais. O InVEST SDR é baseado no acoplamento da RUSLE com um índice para o cálculo da taxa de entrega de sedimentos, o que gera estimativas anuais médias da produção de sedimentos (NATURAL CAPITAL PROJECT, 2021a).

Ao se utilizar modelos hidrológicos e de qualidade da água, algumas boas práticas devem ser buscadas (ASABE, 2017): i) determinar o uso pretendido do modelo; ii) selecionar o modelo que se adequa ao uso pretendido; iii) processar os dados de entrada e dados de calibração; iv) identificar medidas e critérios para avaliar a performance do modelo; v) parametrizar e calibrar o modelo; vi) refinar o modelo e/ou reexaminar os dados de entrada e de calibração; vii) reavaliar a performance do modelo; viii) documentar o processo e reportar os resultados.

Segundo Harmel et al. (2014), dependendo do uso pretendido do modelo, diferentes requisitos associados às incertezas dos valores observados usados para calibração e validação e associados aos valores preditos podem ser exigidos. Segundo os autores, caso a finalidade seja exploratória, ou seja, avaliar implicações de modelos conceituais, comparações aproximadas são adequadas e não há necessidade de estimativas muito precisas. Modelos com finalidades de planejamento podem admitir incertezas, desde que estas sejam reportadas na análise dos cenários. Por outro lado, modelos voltados para implicações regulatórias exigem alta acurácia e baixa incerteza dos valores observados e preditos.

Uma etapa importante da aplicação dos modelos é sua calibração, que consiste em ajustar os parâmetros de entrada de forma a obter valores simulados que se aproximam dos valores observados (ASABE, 2017). A calibração pode compensar erros associados à estimativa da erosão bruta ou deficiências estruturais do modelo (VIGIAK et al., 2012; HAMEL et al., 2015). Nesse sentido, um modelo calibrado está mais propenso a fornecer valores simulados que se aproximam das condições reais do sistema. ASABE (2017) e Harmel et al. (2014) fornecem orientações para a calibração, que são descritas a seguir. Primeiramente, o ideal é separar um conjunto de dados para calibração e outro para validação. A validação é um processo à parte da calibração cujo objetivo é verificar se o modelo tem bom desempenho em condições diferentes daquelas para o qual foi calibrado. A seguir, medidas estatísticas de performance absolutas e relativas devem ser selecionadas, bem como os critérios para avaliar a aceitabilidade do modelo. Após o primeiro ajuste, é possível reavaliar o modelo considerando a presença de *outliers* e valores extremos, cuja exclusão pode ser feita se justificável. O viés do modelo e incertezas sobre os valores observados e preditos podem ser reportados. Em seguida, o modelo pode ser recalculado e reavaliado pelas mesmas medidas de performance. Ao fim da calibração e validação, o processo deve ser documentado e o modelo deve ser interpretado conforme a finalidade definida na primeira etapa.

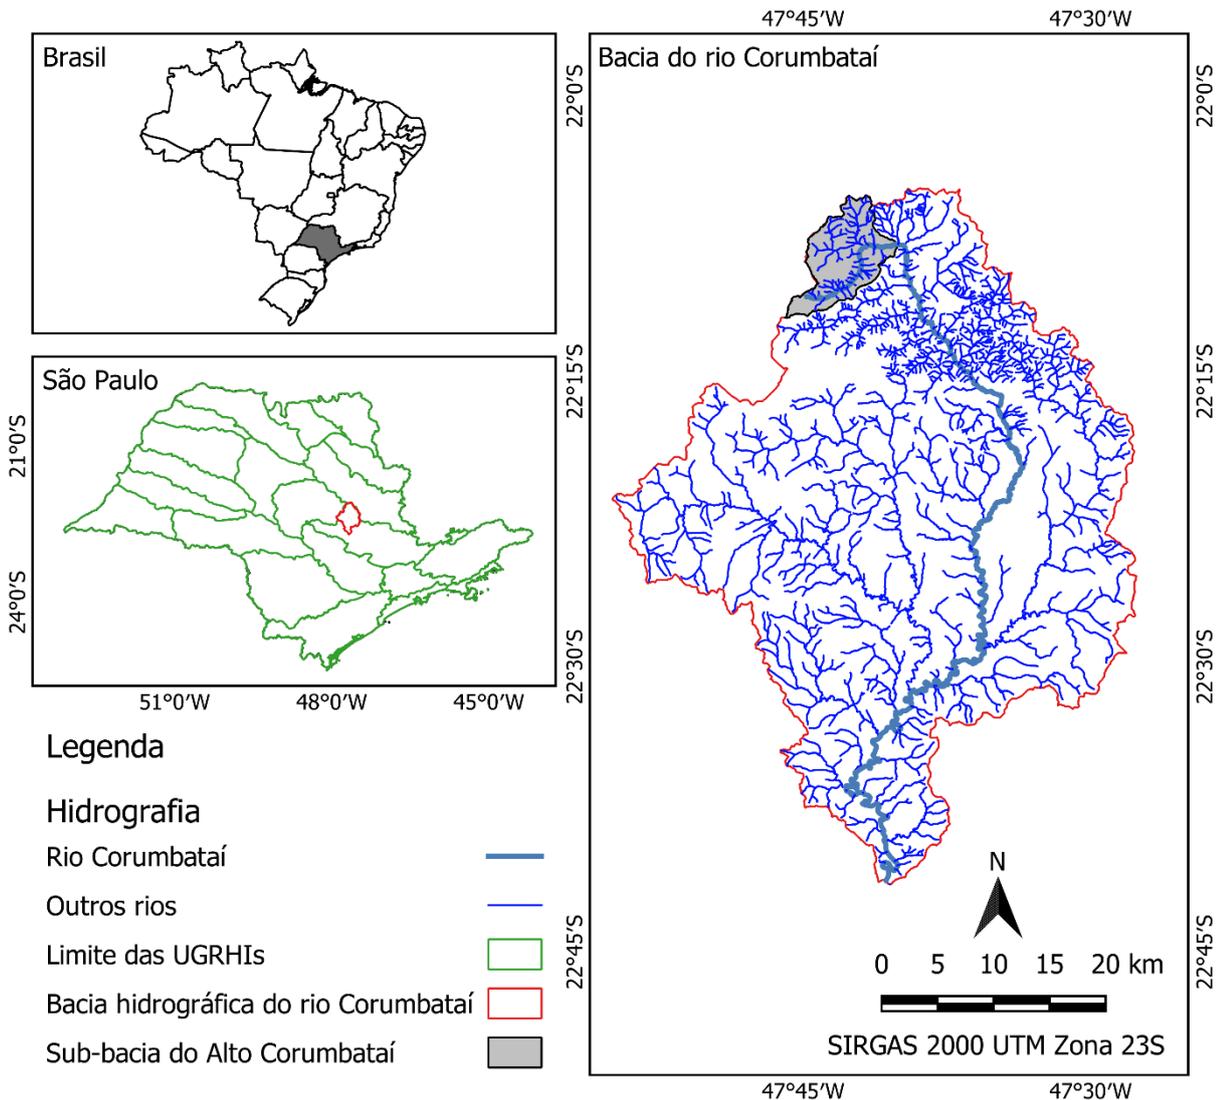
2 MATERIAL E MÉTODOS

Para atingir os objetivos propostos neste capítulo, um experimento de simulação foi desenvolvido utilizando réplicas de paisagens de uma bacia hidrográfica real e um modelo hidrológico para estimar a qualidade da água para cada uma dessas paisagens. A seguir são apresentados a bacia hidrográfica selecionada e os materiais e procedimentos adotados para a execução do experimento de simulação, a saber: i) o modelo neutro de paisagem usado para geração das paisagens binárias de entrada; ii) descrição do modelo de produção de sedimentos utilizado; iii) determinação dos dados de entrada e método de calibração do modelo; iv) desenho do experimento de simulação; v) método de quantificação do padrão da paisagem; vi) técnicas de análise de dados empregadas para relacionar a composição e a configuração da floresta nas réplicas de paisagens com a qualidade da água mensurada pelo modelo hidrológico.

2.1 Área de estudo

A bacia hidrográfica selecionada para o experimento de simulação se situa na porção centro-leste do estado de São Paulo a 221 km da capital entre os paralelos 22° 05' 05" S e 22° 11' 40" S e meridianos 47° 40' 02" O e 47° 45' 57" O (Figura 14). Ela está inserida na porção superior da bacia do rio Corumbataí conhecida como Alto Corumbataí e pertence à Unidade de Gerenciamento de Recursos Hídricos (UGRHI) 5 - Piracicaba, Capivari e Jundiá (PCJ). A sub-bacia abriga a nascente do rio Corumbataí, que deságua no rio Piracicaba, um dos afluentes do rio Tietê. Neste texto, a área de estudo será referenciada como sub-bacia do Alto Corumbataí.

Figura 14 – Localização da área de estudo em relação à bacia hidrográfica do rio Corumbataí e ao estado de São Paulo



Fonte: elaborado pela autora.

A sub-bacia possui uma área de drenagem de 57,3 km² e está inserida no município de Analândia-SP e nas Áreas de Proteção Ambiental (APAs) Corumbataí-Botucatu-Tejupá e Piracicaba e Juqueri-Mirim. Analândia é uma estância climática e a área de estudo se destaca por feições como escarpas de *cuestas* basálticas, cavernas, morros testemunho e quedas d'água (PERINOTTO, 2008). No exutório da bacia (22° 07' 43" S, 47° 40' 05" O) há um ponto de monitoramento da qualidade da água (CRUM02050) da Companhia Ambiental do Estado de São Paulo (CETESB) e uma estação fluviométrica (4D-023) gerenciada pelo Departamento de Águas e Energia Elétrica (DAEE). A altitude na área varia de 654 até 1023 m, com média e mediana de 806 m e 796 m, respectivamente. A declividade varia de 0 até 64%, com média e mediana de 11% e 8%, respectivamente. O relevo predominante na bacia é plano e suave ondulado, embora haja algumas áreas de relevo forte ondulado e montanhoso (Tabela 3).

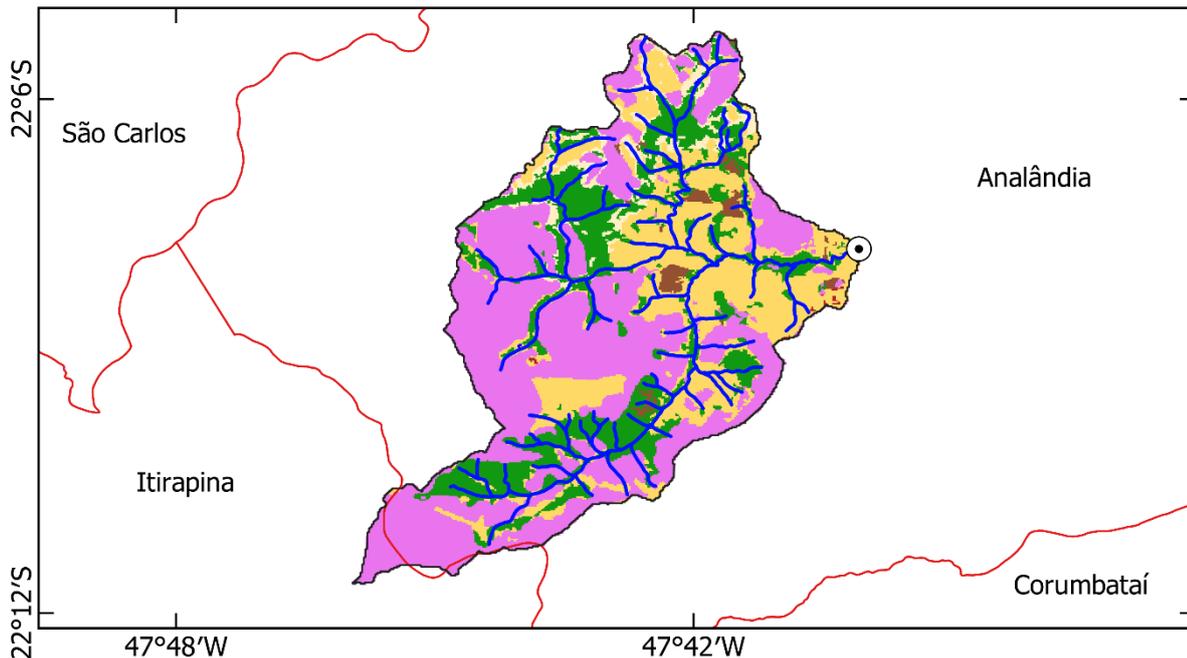
Tabela 3 – Proporção das classes de relevo na sub-bacia do Alto Corumbataí

Declividade (%)				
Mínimo	Máximo	Classe de relevo	Área (km²)	Porcentagem da área (%)
0	3	Plano	21,77	38
3	8	Suave ondulado	16,46	29
8	20	Ondulado	10,69	19
20	45	Forte ondulado	8,05	14
45	75	Montanhoso	0,38	1

Fonte: elaborado pela autora com dados de São Paulo (2013) e Embrapa (2018).

Segundo dados de 2019 fornecidos por MapBiomas (2021), a sub-bacia é predominantemente rural, com 78% do território coberto por áreas de pastagem, florestas plantadas, culturas perenes e temporárias, e 22% de vegetação nativa remanescente (Figura 15). A maior parte da sub-bacia consiste em plantações de cana-de-açúcar (44%), seguida por pastagens (26%). Originalmente uma área de contato entre os biomas Cerrado e Mata Atlântica, atualmente a área de estudo engloba alguns remanescentes majoritariamente de floresta estacional semidecidual em estágio médio de regeneração (INSTITUTO FLORESTAL, 2020).

Figura 15 – Uso e cobertura do solo da sub-bacia do Alto Corumbataí em 2019



Legenda

⊙ Estação de monitoramento da qualidade da água e vazão

— Hidrografia

□ Limites municipais

□ Sub-bacia do Alto Corumbataí

Uso e cobertura do solo (MAPBIOMAS, 2019)

■ Área urbana e áreas não vegetadas

■ Agricultura

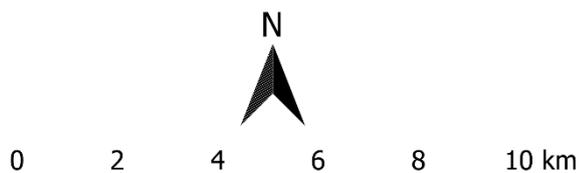
■ Pastagem

■ Mosaico de agricultura e pastagem

■ Floresta plantada

■ Formação florestal e savânica

■ Rios e lagos



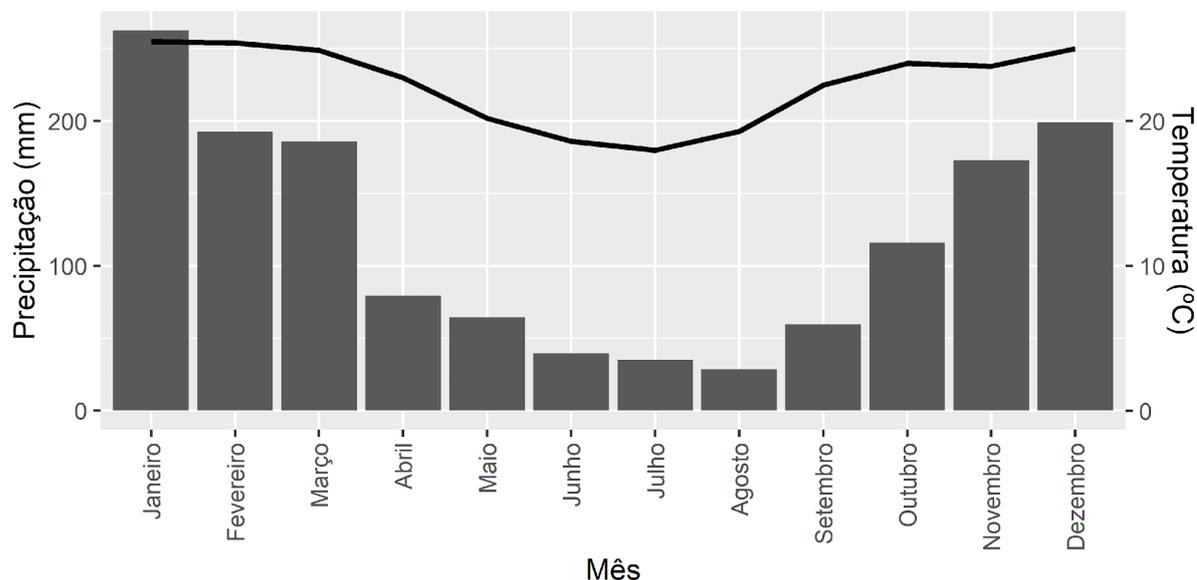
SIRGAS 2000 UTM Zona 23S

Fonte: elaborado pela autora a partir de MapBiomass (2021).

A área de estudo apresenta clima subtropical úmido com inverno seco, abrangendo as classificações climáticas Cwa e Cwb de Köppen-Geiger que indicam, respectivamente, verão quente e verão temperado (ALVARES et al., 2013). A precipitação anual média entre 2005 e 2019 no exutório da bacia é de 1436 mm, sendo que o período chuvoso ocorre entre outubro e março, abrangendo a primavera e verão, e o período seco ocorre entre abril e setembro, no outono e inverno (Figura 16). O período chuvoso na área de estudo compreende cerca de 79%

das chuvas anuais. A temperatura média mensal no mesmo período variou entre 18 e 25,5°C, sendo a média anual 22,5°C (CIIAGRO, 2021).

Figura 16 – Precipitação e temperatura médias na sub-bacia do Alto Corumbataí para o período entre 2005 e 2019



Fonte: elaborado pela autora a partir de dados de CIIAGRO (2021) e DAEE (2021).

2.2 Modelo neutro de paisagem

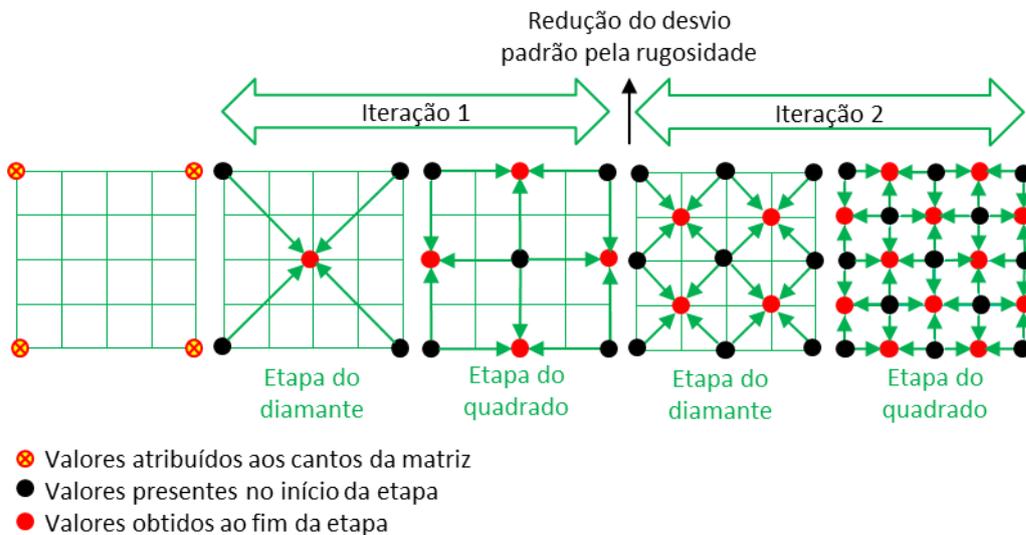
Para produção das réplicas da paisagem na área de estudo foi selecionada a função *nlm_mpd* disponível no pacote *NLMR* (SCIAINI et al., 2020b) do ambiente de *software* e linguagem de *script* para análises estatísticas e gráficas R (R CORE TEAM, 2021). Tal pacote é o primeiro que permite a geração de modelos neutros na forma de imagens matriciais bidimensionais diretamente no ambiente do R (SCIAINI et al., 2018). A função é uma implementação do algoritmo de deslocamento do ponto médio (*midpoint displacement* - MPD) (SAUPE, 1988), também conhecido como algoritmo diamante-quadrado (*diamond-square algorithm*), o mesmo utilizado pelos *softwares* RULE (GARDNER, 1999) e QRULE (GARDNER; URBAN, 2007) que até recentemente vêm sendo usados na geração de modelos neutros (GUSTAFSON, 2019). Este algoritmo foi popularizado a partir do trabalho de Fournier, Fussell e Carpenter (1982), que o propuseram como uma forma eficiente de geração de terrenos naturais realistas na computação gráfica. O algoritmo se baseia no movimento browniano fractal, que pode ser aplicado na simulação de processos unidimensionais e multidimensionais (FOURNIER; FUSSELL; CARPENTER, 1982). Vantagens incluem a simplicidade e rapidez nos cálculos das matrizes (HALLEY et al., 2004).

A função *nlm_mpd* tem como principais argumentos o número de colunas (*ncol*) e número de linhas (*nrow*) que formam a matriz, a resolução espacial, *roughness* (0-1) e *rand_dev*. *Roughness* controla o nível de autocorrelação espacial, enquanto *rand_dev* determina o desvio padrão inicial, se relacionando diretamente com a variância geral no raster⁴ de saída. O argumento que controla a autocorrelação espacial está diretamente relacionado à dimensão fractal da paisagem (WANG; MALANSON, 2008), sendo um fator determinante da configuração obtida (FORTIN et al., 2003). O processo de criação das paisagens matriciais envolve divisão, interpolação e perturbação aleatória (GARDNER, 1999).

O algoritmo de deslocamento do ponto médio implementado na função *nlm_mpd* funciona da seguinte forma: A partir do número de linhas e colunas, é calculado o número de iterações necessárias para construção do raster, o tamanho ideal da matriz com base no número de iterações, e é feita a atribuição de números aleatórios aos quatro cantos da matriz. Em seguida, cada iteração envolve a execução do passo do diamante e do quadrado, nesta sequência. Na primeira iteração, durante o passo do diamante calcula-se a média dos valores dos cantos da matriz e soma-se a ela uma variável aleatória. Esta é definida a partir de uma distribuição gaussiana de média zero e desvio padrão igual a *rand_dev*. O resultado é atribuído ao centro da matriz tendo os quatro pontos iniciais como “vértices”. Durante o passo do quadrado, o processo de obtenção do valor médio somado a uma variável aleatória se repete. Terminada a primeira iteração, *rand_dev* multiplicado pela rugosidade (*roughness*), e o valor resultante é utilizado na próxima iteração. Esses processos se repetem até que todos os pontos da matriz tenham valores atribuídos. A Figura 17 ilustra a execução do algoritmo considerando uma matriz de cinco linhas e colunas, com duas iterações.

⁴ Raster neste trabalho se refere a dados espaciais em formato matricial formados por células (pixels).

Figura 17 – Ilustração do funcionamento do algoritmo de deslocamento do ponto médio



Fonte: elaborado pela autora.

Como citado, o valor de *roughness* controla a autocorrelação espacial das células do raster de saída. A Figura 18 demonstra a influência deste fator, destacando como valores maiores para a rugosidade resultam em paisagens mais “fragmentadas”, enquanto valores menores significam uma maior autocorrelação espacial entre os valores dos pixels.

Figura 18 – Modelos neutros em escala contínua gerados a partir de diferentes valores de *roughness* pela função *nlm_mpd** do pacote *NLMR*



Fonte: elaborado pela autora.

Notas: * *ncol* = 100, *nrow* = 100, *resolution* = 10, *rand_dev* = 1, *rescale* = F.

2.3 Modelo de produção de sedimentos (*Sediment Delivery Ratio* – SDR)

A finalidade do uso do modelo de qualidade da água nesta pesquisa é exploratória e de planejamento, ou seja, explorar implicações de modelos conceituais e, caso possível, indicar medidas de planejamento de bacias hidrográficas (HARMEL et al., 2014). Ainda que deva capturar bem a diferença entre cenários alternativos, certo grau de incerteza inerente ao modelo e às medidas usadas para calibração e validação é permitido (HARMEL et al., 2014).

O modelo utilizado para mensurar a produção de sedimentos foi o *Sediment Delivery Ratio* (SDR), que faz parte do *software* InVEST 3.9.0 disponibilizado pelo *Natural Capital*

Project, uma parceria entre *Stanford University*, *Chinese Academy of Sciences*, *the University of Minnesota*, *the Stockholm Resilience Centre*, *The Nature Conservancy (TNC)*, e *World Wildlife Fund (WWF)*. O *software* é gratuito e de código aberto e permite o mapeamento e valoração de bens e serviços ambientais a partir de diversos modelos (NATURAL CAPITAL PROJECT, 2021a). Estes são baseados em funções que predizem o efeito da estrutura ecossistêmica nos serviços a partir de dados espaciais de entrada, sendo flexíveis para aplicação desde a escala local até global (NATURAL CAPITAL PROJECT, 2021a). Os modelos do InVEST têm baixa requisição de dados, tendo sido desenhados especialmente para indicar como alterações nos ecossistemas podem afetar os serviços ambientais, auxiliando assim a tomada de decisão (SHARP et al., 2020). A ferramenta já foi usada em mais de 60 países pelo *Natural Capital Project* em contextos de tomada de decisão, incluindo projetos no Brasil em colaboração com programas de PSA voltados para a provisão de serviços hidrológicos (NATURAL CAPITAL PROJECT, 2021a).

O modelo SDR é espacialmente explícito, ou seja, a configuração espacial dos dados de entrada influencia os resultados obtidos (HAMEL et al., 2015; QIU; TURNER, 2015; VERHAGEN et al., 2016). Após o processamento dos dados de entrada associados a uma escala de bacia hidrográfica, o modelo produz resultados em escala anual, sendo os principais a carga de sedimento que atinge a água, bem como a quantidade de sedimento erodido e retido pela vegetação e topografia (SHARP et al., 2020).

Embora em algumas regiões o modelo possa ter um bom desempenho sem estar calibrado (HAMEL et al., 2015), a calibração permite obter valores absolutos mais precisos (HAMEL et al., 2017, 2020). Por outro lado, as diferenças relativas na exportação de sedimentos em diferentes cenários são bem capturadas (HAMEL et al., 2015, 2017). Portanto, valores absolutos obtidos do modelo não calibrado devem ser interpretados com cautela, enquanto diferenças relativas entre cenários podem ser utilizadas para ranquear paisagens de acordo com o nível de exportação de sedimentos, auxiliando na priorização de medidas de manejo (HAMEL et al., 2015, 2017).

O modelo é baseado em dois principais cálculos (SHARP et al., 2020): i) perda de solo anual; ii) taxa de entrega de sedimentos. O primeiro é obtido a partir da Equação Universal de Perda de Solo Revisada (RUSLE) (RENARD et al., 1997) e o segundo mensura a proporção do solo erodido que de fato atinge o corpo d'água.

A perda de solo anual ($\text{ton} \cdot \text{ha}^{-1} \cdot \text{ano}^{-1}$) é calculada em escala de pixel pela equação 3:

$$rusle_i = R_i \cdot K_i \cdot LS_i \cdot C_i \cdot P_i \quad (3)$$

Onde:

R_i = erosividade da chuva ($MJ.mm.(ha.h)^{-1}$);

K_i = erodibilidade do solo ($ton.ha.h.(MJ.ha.mm)^{-1}$);

LS_i = fator comprimento da rampa e declividade (adimensional);

C_i = fator uso e manejo do solo (adimensional);

P_i = fator práticas conservacionistas (adimensional).

Após obter a perda de solo por pixel, a taxa de entrega de sedimentos (SDR) é calculada a partir do índice de conectividade (IC) proposto por Borselli, Cassi e Torri (2008), que indica a conexão hidrológica entre a fonte dos sedimentos e o sumidouro (e.g., os riachos). A inserção do IC no cálculo da SDR é uma forma de tornar essa taxa espacialmente variável, ou seja, reconhecer que seu valor depende dos fatores físicos da paisagem (VIGIAK et al., 2012). Esquemáticamente, o IC é deduzido a partir das características associadas a um ponto A na vertente (i.e., fonte), o qual recebe a contribuição do sedimento de uma área acima, e o caminho até um ponto B, que representa o sumidouro (BORSELLI; CASSI; TORRI, 2008). O IC é calculado por pixel a partir de uma função que considera um componente acima (D_{up}), que representa os processos de contribuição, e abaixo (D_{dn}), que caracteriza os processos de retenção (equação 4).

$$IC = \log_{10} \left(\frac{D_{up}}{D_{dn}} \right) \quad (4)$$

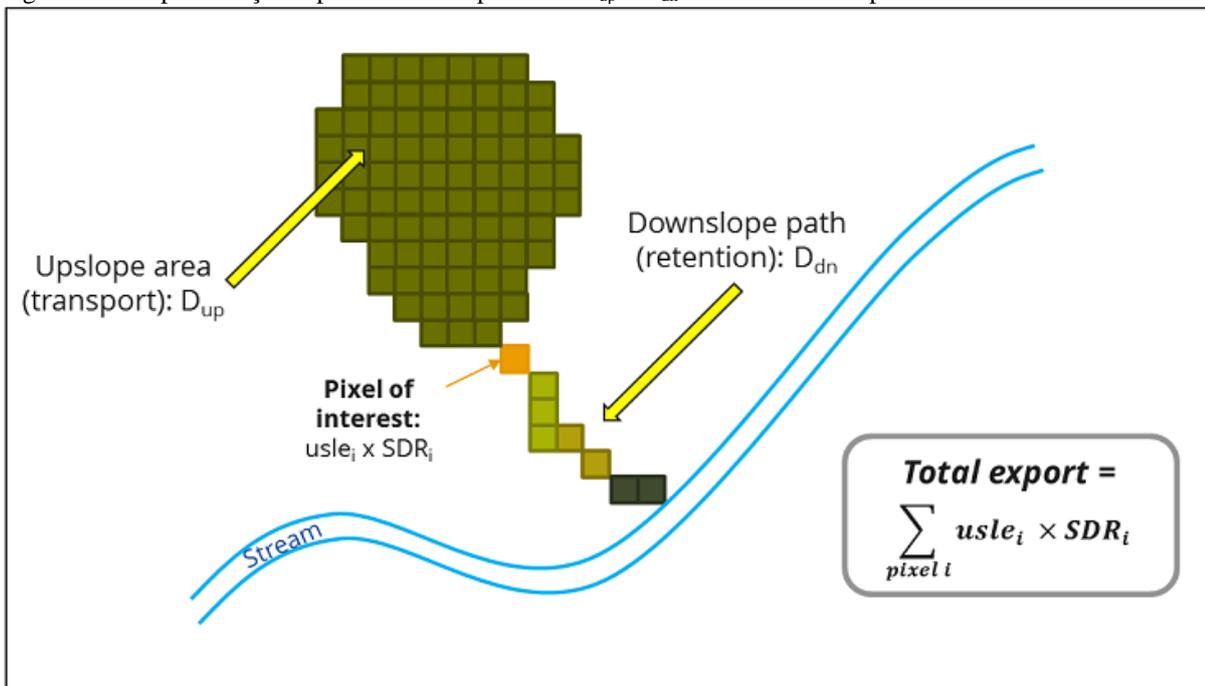
Borselli, Cassi e Torri (2008) assumem que os principais fatores que determinam a probabilidade de o sedimento atingir o riacho são o gradiente de declividade e as condições de uso e cobertura do solo. Portanto, o fator C extraído da RUSLE foi adotado pelo InVEST para representar a resistência ao deslocamento dos sedimentos associados ao uso e cobertura do solo (BORSELLI; CASSI, TORRI, 2008). O componente D_{up} (equação 5) engloba os valores médios dos fatores uso e manejo do solo (Fator C) e gradiente de declividade (Fator S, $m.m^{-1}$) e a área de contribuição acima (A , m^2) obtida pelo algoritmo de múltiplas direções de fluxo. O componente D_{dn} (equação 6) considera os valores de C e S para os pixels da fonte até o sumidouro e o comprimento da rampa de escoamento de maior declividade abaixo (d_i , m). De acordo com Sharp et al. (2020), se a área acima for grande, tiver baixa declividade e boa

cobertura vegetal, o valor de D_{up} será baixo, indicando um menor potencial de o sedimento atingir o riacho. Se o caminho entre o pixel e o riacho for longo, tiver baixa declividade e boa cobertura vegetal, D_{dn} também terá valor baixo. A Figura 19 ilustra o cômputo dos dois componentes para calcular o IC.

$$D_{up} = \bar{C} \bar{S} \sqrt{A} \quad (5)$$

$$D_{dn} = \sum_i \frac{d_i}{C_i S_i} \quad (6)$$

Figura 19 – Representação espacial dos componentes D_{up} e D_{dn} no cálculo do IC pelo modelo SDR do InVEST



Fonte: Sharp et al. (2020)

O valor de IC varia de $-\infty$ a $+\infty$, sendo que a conectividade aumenta à medida que o índice cresce na direção positiva (BORSELLI; CASSI; TORRI, 2008). Portanto, valores maiores indicam que a erosão é mais provável de atingir o sumidouro, enquanto valores menores apontam o contrário (SHARP et al., 2020). O IC foi considerado por Vigiak et al. (2012) como uma métrica eficiente para prever a produção de sedimentos, pois captura funcionalidades da paisagem não abarcadas no cálculo da erosão bruta. A influência de fatores relacionados ao uso e cobertura do solo e a topologia é bem representada pelo IC, que é independente da escala e adequado para bacias de tamanho pequeno a médio (VIGIAK et al., 2012).

Após a obtenção do IC_i , tal valor é inserido na equação 7 para obter a taxa de entrega de sedimentos naquele pixel. Dois parâmetros de calibração são utilizados para definir a forma da relação entre a SDR e IC, que é uma função crescente. Esses parâmetros não têm base física, e sua determinação pode ser feita a partir da literatura (SHARP et al., 2020).

$$SDR_i = \frac{SDR_{max}}{1 + \exp\left(\frac{IC_0 - IC_i}{k_b}\right)} \quad (7)$$

Onde:

SDR_{max} = valor máximo teórico para a taxa de entrega de sedimentos, cujo padrão é 0,8;

IC_0 = parâmetro de calibração;

k_b = parâmetro de calibração.

O sedimento exportado de um dado pixel (E_i , ton.ha⁻¹.ano⁻¹) é o produto entre a perda anual de solo (*rusle*) e a taxa de entrega de sedimentos (*SDR*), e representa a quantidade de sedimento erodido naquele pixel que atinge o riacho (equação 8). O valor para toda a bacia hidrográfica corresponde ao somatório de todos os valores por pixel (equação 9).

$$E_i = rusle_i \cdot SDR_i \quad (8)$$

$$E = \sum_i E_i \quad (9)$$

2.4 Determinação dos dados de entrada do modelo SDR

O modelo SDR requer dados de entrada que consistem em uma tabela biofísica, arquivos vetoriais e matriciais e outros parâmetros. Os dados de entrada obrigatórios são (SHARP et al., 2020):

- a) Diretório de trabalho: local que receberá os dados de saída (*outputs*);
- b) Modelo Digital de Elevação (MDE): arquivo matricial contendo um valor de elevação para cada pixel (m);

- c) Índice de erosividade da chuva (R): arquivo matricial contendo um valor de erosividade para cada pixel ($\text{MJ.mm.}(\text{ha.h.ano})^{-1}$);
- d) Erodibilidade do solo (K): arquivo matricial contendo um valor de erodibilidade do solo para cada pixel ($\text{ton.ha.h.}(\text{ha.MJ.mm})^{-1}$);
- e) Uso e cobertura do solo (LULC): arquivo matricial contendo um valor inteiro para cada classe de uso e cobertura do solo;
- f) Bacias hidrográficas: arquivo vetorial contendo polígonos que representam as bacias que contribuem a um ponto de interesse onde será analisada a qualidade da água;
- g) Tabela biofísica: tabela em formato .csv contendo dados para o modelo relativos a cada uma das classes de uso e cobertura do solo do arquivo LULC. Contém os seguintes campos:
 - lrcode = valor inteiro para cada uma das classes de uso e cobertura do solo, iguais aos valores do arquivo raster LULC;
 - usle_c = valor do fator C (0-1) para cada uso e cobertura do solo do raster LULC;
 - usle_p = valor do fator P (0-1) para cada uso e cobertura do solo do raster LULC.
- h) Limiar de acumulação de fluxo (*threshold flow accumulation*): número de pixels a montante que devem fluir em um pixel antes que ele seja considerado parte do riacho;
- i) k_b e IC_0 : parâmetros de calibração que definem a forma da relação entre SDR e IC. Valores padrão são $k_b = 2$ e $IC_0 = 0,5$;
- j) SDR_{\max} : valor máximo da taxa de entrega de sedimentos para um pixel. Valor padrão é 0,8.

Além dos dados de entrada obrigatórios, o usuário pode definir um sufixo, que será acrescentado no final dos nomes dos arquivos de saída, e um arquivo matricial de drenagem com valores 0 e 1, sendo o último correspondente à drenagem artificial da área.

Sempre que possível, os parâmetros da RUSLE devem ser computados com base nas características locais, por meio de trabalhos e estimativas produzidos para adaptar a equação à realidade local (SHARP et al., 2020). A seguir são descritos os métodos utilizados para produção dos dados de entrada e suas respectivas fontes. Todos os procedimentos foram executados no QGIS 3.16.4 e ferramentas externas integradas do GRASS 7.8.5 e SAGA 2.3.2 (QGIS.org, 2021). Quando necessário, todos os dados foram reprojatados para o sistema de coordenadas geográficas SIRGAS 2000 e projeção SIRGAS 2000/UTM Zona 23S. Todos os arquivos matriciais foram processados ou gerados em resolução espacial de 30 x 30 m.

2.4.1 Área de drenagem

Para produzir o arquivo vetorial da área da bacia hidrográfica foi empregado o Modelo Digital de Elevação (MDE) para o estado de São Paulo com resolução horizontal de 30 m (0,0002777 graus decimais). Tal arquivo foi elaborado a partir das curvas de nível extraídas de cartas topográficas em escala 1:50.000 reunidas pelo projeto GISAT do DAEE (SÃO PAULO, 2013).

Primeiramente foi feito um recorte abrangendo a extensão da área de estudo, que foi reprojetoado utilizando o método de reamostragem bilinear e resolução de 30 m. A delimitação da bacia hidrográfica foi feita por meio das ferramentas *r.watershed*, que elabora a direção de drenagem e segmento de fluxo usando um algoritmo de menor custo; e *r.water.outlet*, que produz a área de drenagem a partir da direção de drenagem e das coordenadas do exutório. Neste trabalho foi utilizado como exutório o ponto mais próximo das coordenadas do local de monitoramento da qualidade da água e da vazão. Após obtenção do arquivo matricial, a área de drenagem foi convertida para o formato vetorial.

2.4.2 Erosividade da chuva (R)

A *World Meteorological Organization* (WMO, 2008) recomenda que uma densidade mínima de postos pluviométricos em áreas continentais deva abranger 575 km² por estação. Nesse sentido, foi gerado um círculo de raio 13,529 km em torno de cada estação para identificar aquelas que poderiam influenciar o cálculo da erosividade na área de estudo. A partir da base de dados da Agência Nacional de Águas (ANA, 2021), foram identificadas oito estações com séries históricas que abrangiam o período estudado, i.e., 2005 a 2019 (Tabela 4). As séries de dados pluviométricos foram obtidas do banco de dados hidrológicos do DAEE (DAEE, 2021) e do Portal Hidroweb da ANA (ANA, 2021). Ao examinar as séries, foi identificado que seis estações possuíam falhas, ou seja, dados mensais e/ou diários de precipitação incompletos ou ausentes.

Tabela 4 – Estações de monitoramento pluviométrico utilizadas para obtenção de dados de precipitação

Código Hidroweb	Código DAEE	Nome	Latitude	Longitude	Altitude (m)
2247004	D4-035	Analândia	22°07'47"S	47°40'03"O	660
2247010	D4-043	Corumbataí	22°12'58"S	47°37'12"O	600
2247198		Fazenda Pequena Holanda	22°10'48"S	47°47'05"O	780
2147043	C4-071	Fazenda Santa Rita	21°58'36"S	47°42'11"O	780
2247015	D4-036R	Graúna	22°18'01"S	47°44'38"O	610
2247180		Itirapina	22°14'57"S	47°49'36"O	739
2247182		Ribeirão do Feijão	22°09'08"S	47°53'11"O	676
2247006	D4-037R	Visconde de Rio Claro	22°08'54"S	47°47'42"O	740

Fonte: elaborado pela autora a partir de dados de ANA (2021) e DAEE (2021).

Para o preenchimento dessas falhas foram utilizados os recursos da iniciativa *Climate Hazards Group InfraRed Precipitation with Station data* (CHIRPS), que reúne um banco de dados de precipitação com resolução espacial de 0,05 x 0,05 graus. Para o Brasil, esse conjunto apresentou grande concordância com os valores mensurados por estações pluviométricas, principalmente no Sudeste, tendo se mostrado fidedigno para uso em pesquisas com diversas finalidades (COSTA et al., 2019). Os dados CHIRPS foram obtidos para o período entre 01/01/2005 e 31/12/2019 do servidor *ClimateSERV* (CLIMATESERV, 2021), e tiveram correlação forte com a precipitação mensal mensurada pelas estações pluviométricas ($0,84 \leq \rho \leq 0,93$, $p < 0,001$).

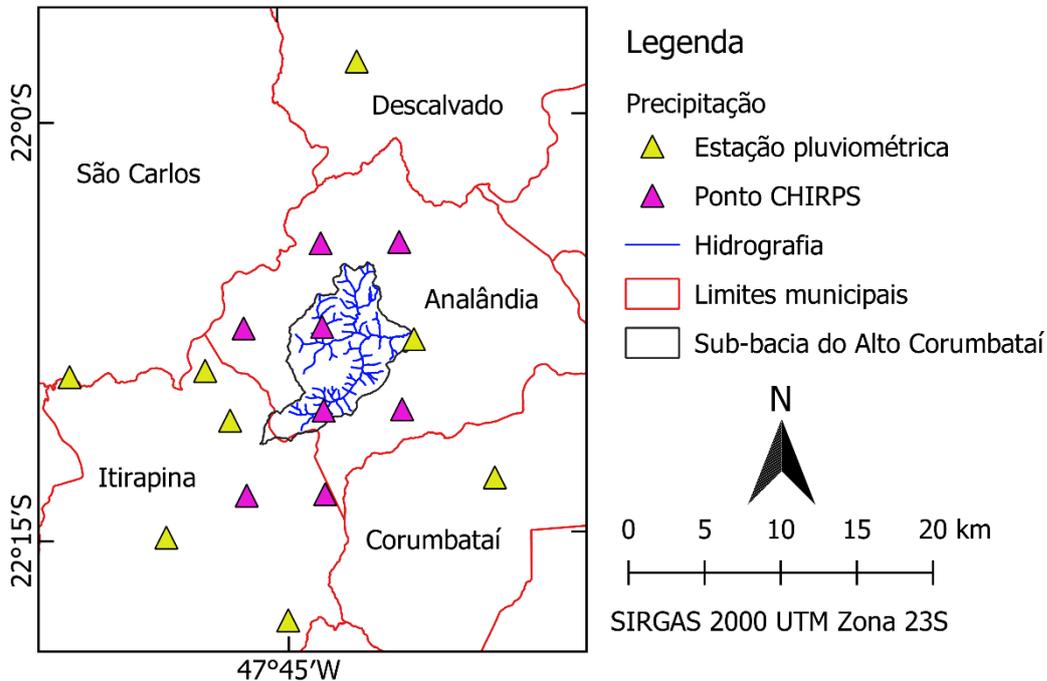
Os dados diários de precipitação na área de estudo foram obtidos em formato matricial, e as precipitações acumuladas mensal e anual foram calculadas por meio da ferramenta *Cell statistics* do QGIS. Em seguida, a precipitação mensal foi utilizada para preencher as falhas no registro das estações. Optou-se por empregar a precipitação mensal como unidade de preenchimento em vez da precipitação diária, visto que os dados de satélite se mostraram mais precisos e menos variáveis quando mensurados naquela escala. Nos casos em que a precipitação mensal nos registros incompletos foi superior à dos dados CHIRPS optou-se por manter o valor mensurado no posto pluviométrico. Além disso, os dados CHIRPS foram utilizados para substituir quatro registros da estação Ribeirão do Feijão considerados *outliers* provavelmente devido a erros de medição. Para complementar a série pluviométrica na bacia, a precipitação acumulada de pontos extraídos dos centroides dos pixels dos dados CHIRPS (Tabela 5, Figura 20) foi usada no cálculo da erosividade.

Tabela 5 – Coordenadas dos pontos utilizados para obtenção da precipitação da base de dados CHIRPS

ID	Latitude	Longitude
8	22°04'30"S	47°43'30"O
9	22°04'30"S	47°40'30"O
12	22°07'30"S	47°46'30"O
13	22°07'30"S	47°43'30"O
18	22°10'30"S	47°43'30"O
19	22°10'30"S	47°40'30"O
22	22°13'30"S	47°46'30"O
23	22°13'30"S	47°43'30"O

Fonte: elaborado pela autora.

Figura 20 – Localização das estações pluviométricas e pontos CHIRPS utilizados para obtenção de dados de precipitação



Fonte: elaborado pela autora.

Após a obtenção da precipitação mensal e anual a partir de registros das estações pluviométricas e da base de dados CHIRPS, a erosividade foi calculada para cada ano entre 2005 e 2019 e para todo o período de análise (i.e., 15 anos) segundo a equação 10 formulada por Lombardi Neto e Moldenhauer (1992) para Campinas-SP:

$$EI = 68,730 \times \left(\frac{p^2}{P} \right)^{0,841} \quad (10)$$

Onde:

EI = média mensal do índice de erosão em MJ.mm.(ha.h.ano)⁻¹;

p = precipitação total média mensal em milímetros (mm);

P = precipitação total média anual em milímetros (mm).

O EI é calculado para cada mês do período estudado, e o fator erosividade corresponde à soma desses valores mensais. Esta equação permite estimar com precisão valores médios da erosividade em um local considerando séries temporais longas (e.g., 20 anos ou mais) (LOMBARDI NETO; MOLDENHAUER, 1992).

Após obter o fator erosividade para os postos pluviométricos e para os pontos CHIRPS, foi feita uma interpolação para obter os mapas de erosividade, em que cada célula possui um valor associado. Para isso, foi utilizado o interpolador Inverso da Potência da Distância (IPD), com ponderação 2 (equação 11). Segundo Teixeira (2019), quando comparado a outros interpoladores, o IPD com potência 2 se mostrou a melhor opção para espacialização da erosividade da chuva anual no estado de São Paulo. Neste método, o valor desconhecido em um local é obtido a partir de uma ponderação dos valores conhecidos dos pontos vizinhos, sendo que o peso de cada um diminui à medida que sua distância do ponto a ser interpolado aumenta (SUTTON; DASSAU; SUTTON, 2009).

$$Z_i = \frac{\sum_{j=1}^n \left(\frac{Z_j}{d_{ij}^p} \right)}{\sum_{j=1}^n \left(\frac{1}{d_{ij}^p} \right)} \quad (11)$$

Onde:

Z_i = valor interpolado do ponto i ;

Z_j = valor mensurado no ponto j ;

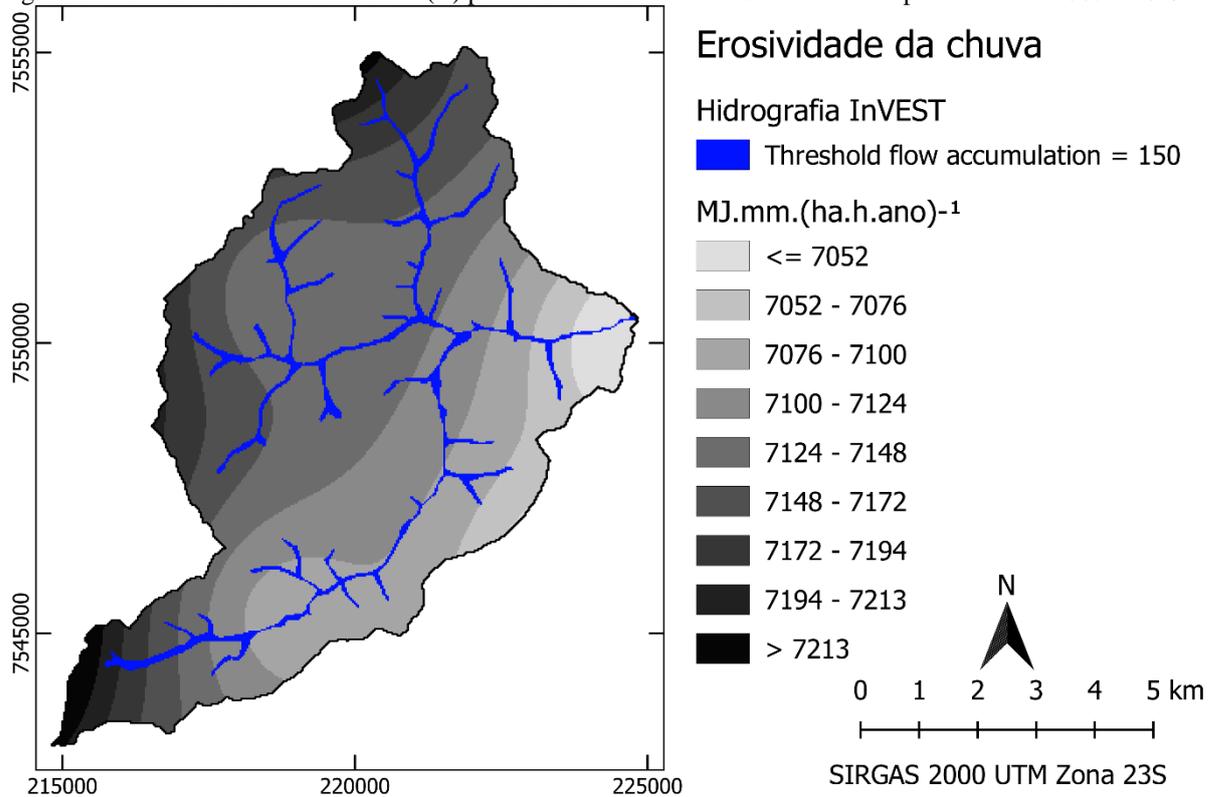
d_{ij} = distância euclidiana entre os pontos i (interpolado) e j (amostrado);

p = potência;

n = número de pontos utilizados na interpolação.

Após o processo de interpolação, a erosividade média na bacia para o período entre 2005 e 2019 foi estimada em $7128,36 \text{ MJ.mm(ha.h.ano)}^{-1}$, valor condizente com os obtidos por Teixeira (2019) e pelo *software* NetErosividade SP (MOREIRA et al., 2006). A Figura 21 ilustra a erosividade média para o período de 15 anos na área de estudo. Valores maiores ocorrem nas nascentes mais à leste e norte na bacia, enquanto o menor valor ocorre no seu exutório, próximo aos postos de monitoramento.

Figura 21 – Fator erosividade da chuva (R) para a sub-bacia do Alto Corumbataí no período entre 2005 e 2019



Fonte: elaborado pela autora.

2.4.3 Erodibilidade do solo (K)

Para produzir esse dado de entrada foi utilizado o mapa pedológico do estado de São Paulo (ROSSI, 2017), cujo delineamento da área de estudo foi compilado a partir da carta de solo produzida pelo Instituto Agrônomo de Campinas (IAC) em escala 1:100.000 – quadrícula de São Carlos (PRADO; OLIVEIRA; ALMEIRA, 1981).

Após o recorte do arquivo pedológico no formato da bacia hidrográfica, oito unidades de mapeamento do solo foram obtidas. As unidades foram agrupadas até o nível de subordem e o fator K para cada classe de solo foi extraído de Di Raimo et al. (2019), que forneceram valores médios a partir de uma revisão da literatura. Devido à impossibilidade de identificar com certeza a classe de solo em um polígono de área urbana, a essa área foi atribuído valor zero ao fator K. A Tabela 6 indica a classe de solo, as unidades de mapeamento incluídas em cada classe, e o valor do fator K. Após a atribuição dos valores, o arquivo vetorial foi rasterizado (Figura 22).

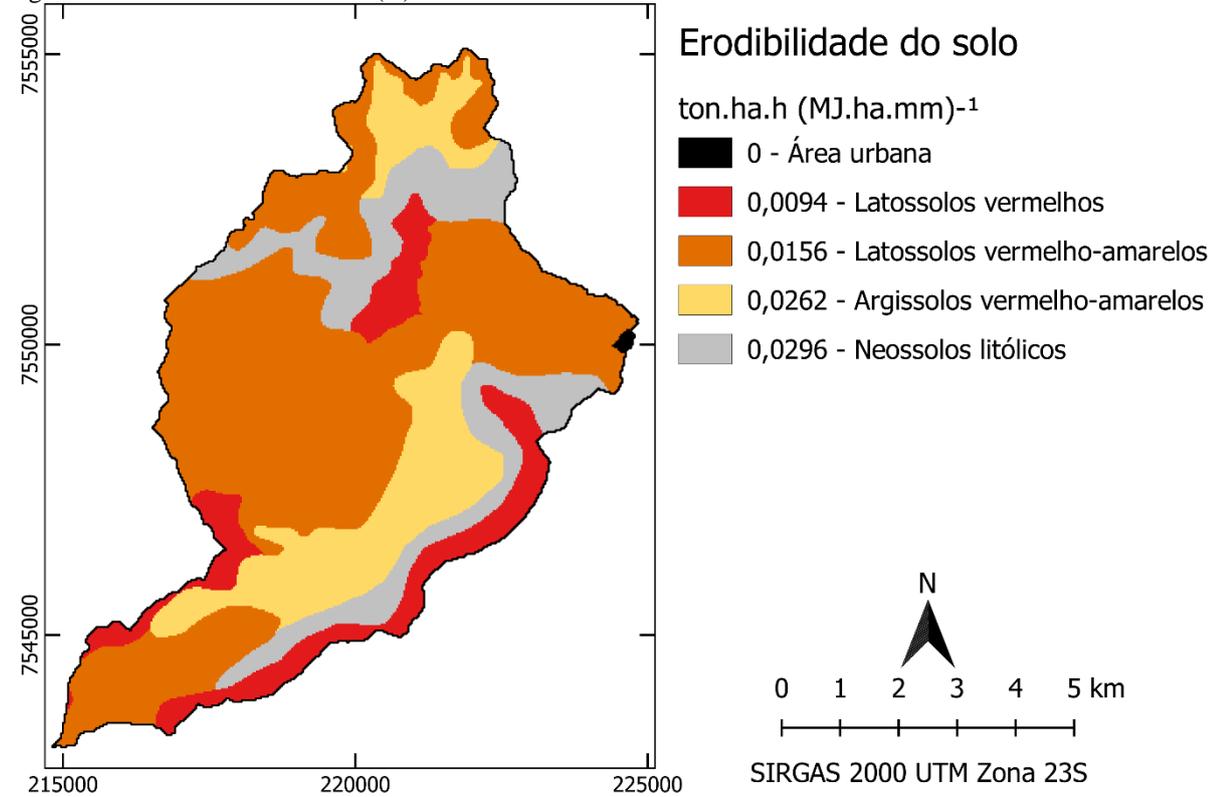
Tabela 6 – Valor do fator erodibilidade do solo (K) atribuído às classes de solo na sub-bacia do Alto Corumbataí

Unidades de mapeamento*	Classe de solo	Fator K (ton.ha.h (MJ.ha.mm) ⁻¹)
LV11, LV3	Latossolos vermelhos	0,0094
LVA5, LVA6	Latossolos vermelho-amarelos	0,0156
PVA19, PVA21	Argissolos vermelho-amarelos	0,0262
RL1, RL12	Neossolos litólicos	0,0296
Área urbana		0

Fonte: adaptado de Di Raimo et al. (2019)

Notas: * Siglas conforme Rossi (2017).

Figura 22 – Erodibilidade do solo (K) na sub-bacia do Alto Corumbataí



Fonte: elaborado pela autora

2.4.4 Comprimento da rampa e declividade (LS)

O fator topográfico foi calculado pelo próprio InVEST a partir de um MDE (Figura 23). O MDE descrito na subseção 2.4.1 foi submetido a um procedimento de preenchimento de depressões por meio da ferramenta *Fill sinks* (Wang e Liu). Em seguida, foi feito um recorte utilizando um arquivo vetorial da bacia hidrográfica expandido com um *buffer* +90, pois recomenda-se que o MDE seja um pouco maior que a área da bacia para que o cálculo da direção de fluxo pelo InVEST seja correto (SHARP et al., 2020).

O cálculo do fator topográfico (LS_i) pelo modelo SDR seguiu a abordagem proposta por Desmet e Govers (1996) para superfícies bidimensionais (equação 12).

$$LS_i = S_i \frac{(A_{i-in} + D^2)^{m+1} - A_{i-in}^{m+1}}{D^{m+2} \cdot x_i^m \cdot (22,13)^m} \quad (12)$$

Onde:

S_i = fator de declividade para cada pixel, calculado a partir da declividade em radianos;

A_{i-in} = área de contribuição do pixel (m^2) computada pelo algoritmo de múltiplas direções de fluxo;

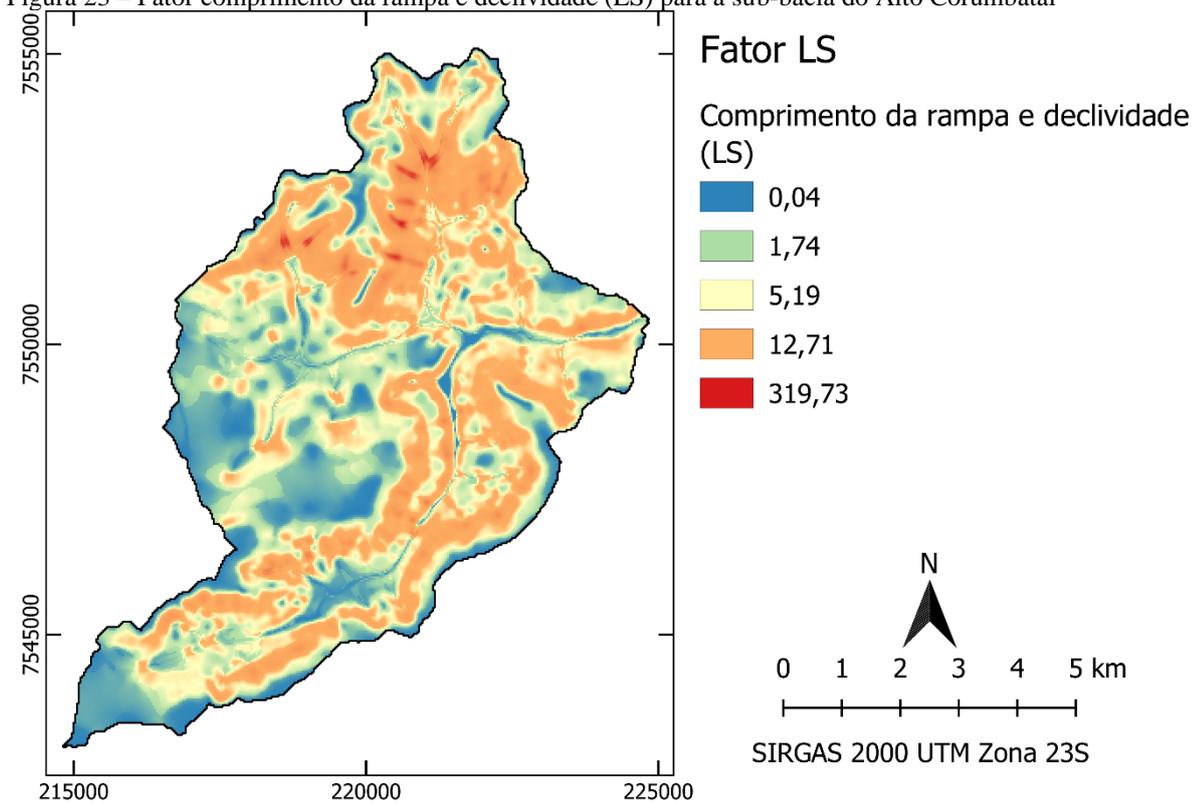
D = tamanho do pixel (m);

x = valor da direção do fluxo, calculado pela média do aspecto ponderado pelo fluxo proporcional do pixel determinado pelo algoritmo de múltiplas direções de fluxo;

m = expoente do comprimento da encosta (adimensional).

O fator S_i da equação 12 é calculado em função da declividade em radianos θ , sendo i) $S = 10,8 \cdot \text{sen}\theta + 0,03$ quando $\theta < 9\%$; e ii) $S = 16,8 \cdot \text{sen}\theta - 0,50$ quando $\theta \geq 9\%$. O valor de m na equação 12 é calculado de acordo com as regras (OLIVEIRA et al., 2013): i) $m = 0,2$ para declividades $\leq 1\%$; ii) $m = 0,3$ quando $1\% < \text{declividade} \leq 3,5\%$; iii) $m = 0,4$ quando $3,5\% < \text{declividade} \leq 5\%$; iv) $m = 0,5$ quando $5\% < \text{declividade} \leq 9\%$; v) $m = \beta/(1+\beta)$ em que $\beta = (\text{sen}\theta/0,0896)/(3 \cdot \text{sen}\theta^{0,8} + 0,56)$ quando a declividade $\geq 9\%$.

Figura 23 – Fator comprimento da rampa e declividade (LS) para a sub-bacia do Alto Corumbataí



Fonte: elaborado pela autora.

2.4.5 Coeficientes uso e manejo do solo (C) e práticas conservacionistas (P)

O uso e cobertura do solo foi obtido da Coleção 5 do projeto MapBiomias (MAPBIOMAS, 2021), que realiza o mapeamento anual no Brasil por meio de classificação automática aplicada a imagens de satélite. Os mapas são fornecidos em formato matricial com pixel quadrado de 30 m, sendo que a acurácia geral nos biomas Mata Atlântica e Cerrado varia de 83,8% a 90,7% no nível menos detalhado de mapeamento. Foram extraídos os mapas da sub-bacia no período entre 2005 e 2019 por meio da Ferramenta *Google Earth Engine*, tendo sido obtidas 13 classes de uso e cobertura do solo no nível mais detalhado da classificação.

A principal fonte de dados para o fator C foi o trabalho de Silva et al. (2010), que forneceu valores para vários usos e coberturas na região de São Carlos-SP. Foi mantida a classificação original do MapBiomias, porém, foi atribuído um único valor para as formações florestal e savânica, assim como para a “formação campestre” e “pastagem”. A classe “mosaico de agricultura e pastagem” corresponde a áreas onde não foi possível distinguir o uso agropecuário do solo, sendo que na sub-bacia abrange principalmente regiões próximas de riachos onde há uma transição entre áreas de agricultura e pastagem, pasto sujo ou em regeneração. Nesse sentido, a essa classe foi atribuído o valor correspondente à pastagem.

“Outras áreas não vegetadas” compreendem superfícies impermeáveis que não foram distinguidas em classes específicas, sendo que na bacia de estudo essas áreas abrangem principalmente rodovias pavimentadas. Portanto, essa classe recebeu o mesmo valor atribuído à infraestrutura urbana. No caso da classe “outras lavouras temporárias” foi adotado o valor para a cana de açúcar devido à impossibilidade de distinguir todas as culturas temporárias existentes na sub-bacia.

Para identificar a adoção de práticas agrícolas conservacionistas na bacia e, conseqüentemente, os valores do fator P, foi feita uma consulta ao Censo Agropecuário de 2017 (IBGE, 2017). A maioria da área destinada às lavouras temporárias (> 97%) e perenes (68% a 74%) nos municípios que abrangem a bacia empregava o plantio em nível. Em Analândia, 81% da área de produção pecuária fazia plantio em nível, sendo que 97% das pastagens plantadas se encontravam em boas condições. Por outro lado, não havia informação suficiente sobre as florestas plantadas, e outras práticas como rotação de culturas eram menos empregadas. Portanto, adotou-se o valor 0,5 para as lavouras perenes, temporárias e pastagens, o que indica o emprego de práticas conservacionistas do tipo plantio em contorno (BERTONI; LOMBARDI NETO, 1990), enquanto manteve-se o valor 1 para as outras classes. Para “rio, lago e oceano” foi atribuído valor zero aos fatores C e P. A Tabela 7 apresenta a extensão de cada uso e cobertura na bacia, bem como os valores atribuídos aos fatores C e P. A Figura 24 ilustra o fator CP calculado para o ano de 2019 a partir da multiplicação dos coeficientes C e P (Tabela 7) pelo InVEST.

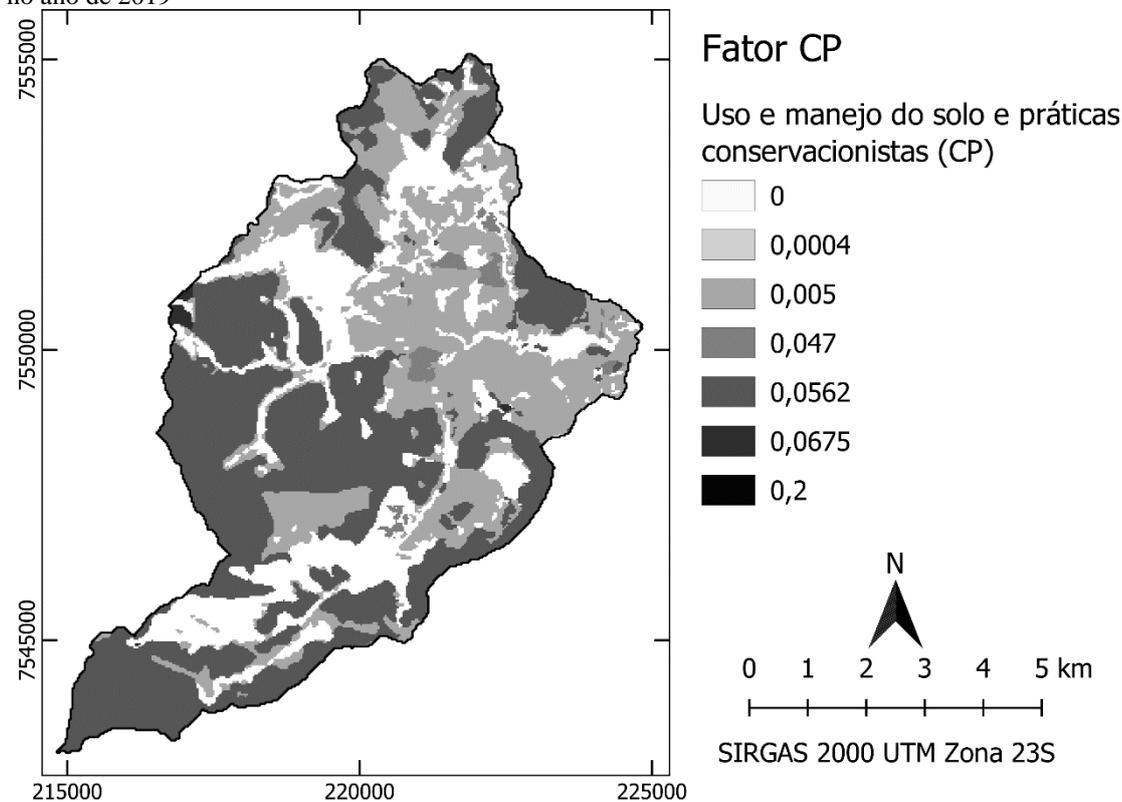
Tabela 7 – Valores dos fatores C e P atribuídos a cada classe de uso e cobertura do solo na área de estudo

ID*	Classe de uso e cobertura do solo	Fator C	Fator P	Área em 2019 (ha)^d
3	Formação florestal	0,0004 ^a	1 ^c	1030,83 (18%)
4	Formação savânica	0,0004 ^a	1 ^c	256,76 (4%)
9	Floresta plantada	0,047 ^a	1 ^c	95,42 (2%)
12	Formação campestre	0,01 ^a	0,5 ^c	14,19 (0,2%)
15	Pastagem	0,01 ^a	0,5 ^c	1495,71 (26%)
20	Cana de açúcar	0,1124 ^a	0,5 ^c	2548,56 (44%)
21	Mosaico de agricultura e pastagem	0,01 ^a	0,5 ^c	264,88 (5%)
24	Infraestrutura urbana	0,2 ^b	1 ^c	0,083 (0,001%)
25	Outras áreas não vegetadas	0,2 ^b	1 ^c	6,30 (0,1%)
33	Rio, lago e oceano	0	0	3,15 (0,1%)
36	Lavoura perene	0,135 ^a	0,5 ^c	20,16 (0,3%)
39	Soja	0,206 ^a	0,5 ^c	0 (0%)
41	Outras lavouras temporárias	0,1124 ^a	0,5 ^c	65,62 (1%)

Fonte: ^a Silva et al. (2010); ^b Morgan (1995); ^c Bertoni e Lombardi Neto (1990), ^d MapBiomass (2021).

Notas: * identificador usado pela coleção 5 do MapBiomass (2021).

Figura 24 – Fatores de uso e manejo do solo e práticas conservacionistas (CP) para a sub-bacia do Alto Corumbataí no ano de 2019



Fonte: elaborado pela autora.

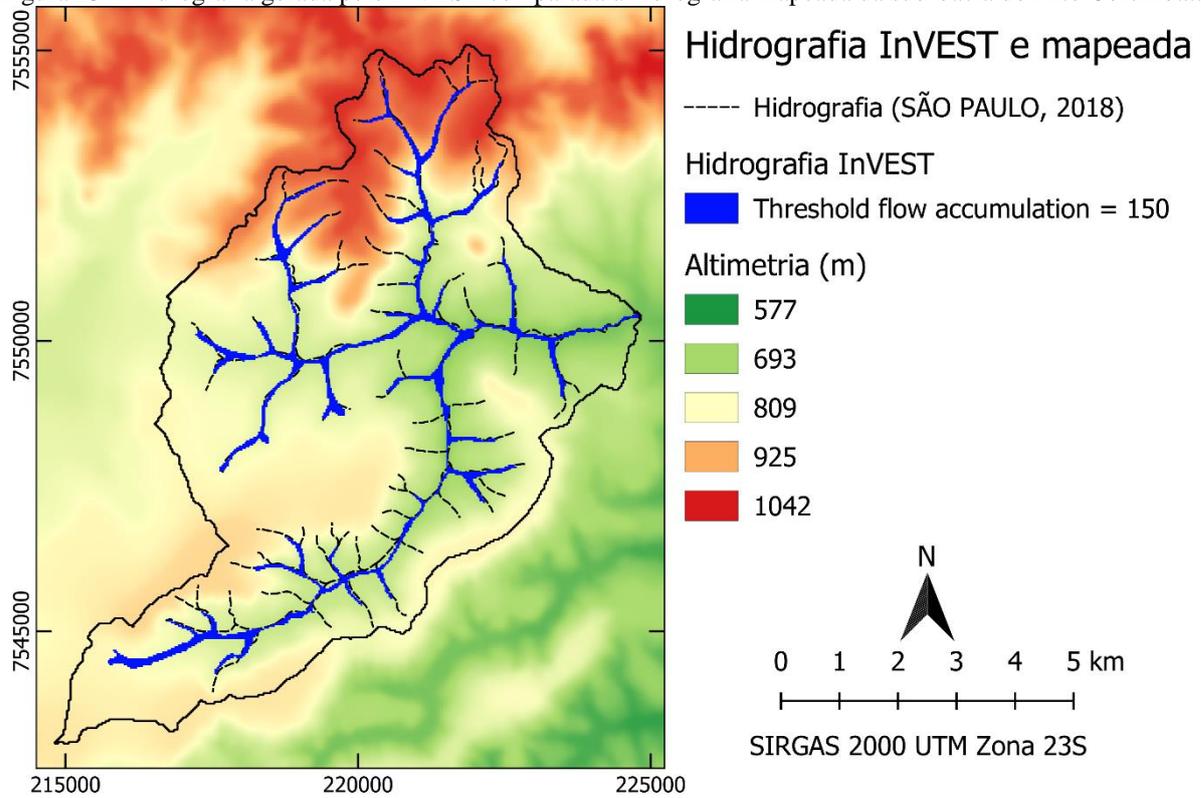
2.4.6 Limiar de acumulação de fluxo, k_b , IC_0 e SDR_{max}

O limiar de acumulação de fluxo (*threshold flow accumulation*) foi definido por meio da comparação da rede hidrográfica gerada pelo modelo com aquela existente na sub-bacia. A hidrografia considerada real foi aquela obtida a partir das cartas topográficas do IBGE em escala 1:50.000 pelo projeto GISAT, coordenado pelo DAEE (SÃO PAULO, 2018). Um valor que leva à geração de uma rede hidrográfica mais semelhante à rede mapeada é considerado o mais indicado para o modelo (SHARP et al., 2020). Conforme orientação do manual do InVEST, uma primeira tentativa foi feita utilizando o valor padrão de 1.000 e, em seguida, os valores foram ajustados de forma a obter uma drenagem satisfatória quando comparada à mapeada.

O valor 1.000 gerou uma rede hidrográfica não satisfatória, pois vários tributários não foram identificados. Nesse sentido, o valor foi decrescido de forma a obter uma rede hidrográfica com mais tributários e, conseqüentemente, mais semelhante à mapeada. Após testes com valores entre 50 e 150, optou-se por usar o valor 150, pois foi o que mais se assemelhou à rede hidrográfica de São Paulo (2018) (Figura 25). Valores menores que 150 em

geral não geravam mais tributários ou alongavam seu comprimento, mas levavam a um alargamento dos canais já identificados.

Figura 25 – Hidrografia gerada pelo InVEST comparada à hidrografia mapeada da sub-bacia do Alto Corumbataí



Fonte: elaborado pela autora.

O parâmetro SDR_{max} representa o maior valor teórico que a taxa de entrega de sedimentos para um pixel pode assumir, sendo que se adotou o valor padrão 0,8 recomendado por Sharp et al. (2020). Os parâmetros k_b e $IC0$ são utilizados para a calibração do modelo, portanto, os valores adotados na calibração e no experimento de simulação são apresentados na seção seguinte.

2.5 Calibração do modelo SDR

A calibração envolveu o processamento dos dados e valores de entrada, identificação das medidas e critérios para avaliar o desempenho do modelo, parametrização e calibração inicial, refinamento, reavaliação do desempenho do modelo e apresentação dos resultados (ASABE, 2017). A validação, ou seja, o processo de verificar se o modelo calibrado é capaz de gerar valores simulados semelhantes aos observados de um conjunto de dados diferente do usado para a calibração (MORIASI et al., 2007), não foi feita neste trabalho. Devido à escassez

de dados observados para a área de estudo, optou-se por fazer apenas a calibração do modelo com a série temporal disponível.

Inicialmente foi adotado o período de 2005 a 2019 para a calibração, totalizando 15 anos de dados de qualidade da água observados para a área de estudo. Os dados de entrada foram gerados conforme os procedimentos detalhados na seção 2.4 e são apresentados no Quadro 7. A obtenção e processamento dos dados observados está descrita na próxima seção.

Quadro 7 – Dados de entrada e parâmetros utilizados na calibração do modelo SDR

Argumento	Valor ou referência
Sufixo	“ano” + ano + _ + k + _ + ic
Modelo Digital de Elevação (raster)	Seção 2.4.4
Índice de erosividade da chuva (raster)	Índice de erosividade para cada ano entre 2005 e 2019 (seção 2.4.2)
Erodibilidade do solo (raster)	Figura 22
Uso e cobertura do solo (raster)	Uso e cobertura do solo para cada ano entre 2005 e 2019 (seção 2.4.5)
Bacias hidrográficas (vetor)	Seção 2.4.1
Tabela biofísica (.csv)	Tabela 7
Limiar de acumulação de fluxo	150 (seção 2.4.6)
k_b	0,5 - 2
IC0	0,25 - 2
SDR_{max}	0,8

Fonte: elaborado pela autora.

2.5.1 Estimativa das cargas médias anuais na bacia hidrográfica

Foram obtidos 93 dados observados de qualidade da água e vazão média diária para o período entre 2005 e 2019 da CETESB (CETESB, 2021) e do DAEE (DAEE, 2021), respectivamente. Os indicadores de qualidade da água foram mensurados em frequência bimestral nos meses de janeiro, março, maio, julho, setembro e novembro, totalizando seis coletas por ano, com exceção de 2019, quando houve nove coletas. Os indicadores necessários para se comparar a produção de sedimentos simulada pelo modelo são os sólidos suspensos totais (SST). Visto que a CETESB fornece apenas os sólidos totais e sólidos dissolvidos totais, os SST foram obtidos pela diferença entre os dois primeiros (equação 13).

$$SST = ST - SDT \quad (13)$$

Onde:

SST = sólidos suspensos totais (mg/L);

ST = sólidos totais (mg/L);

SDT = sólidos dissolvidos totais (mg/L).

Em algumas observações do período, não foi possível obter diretamente os valores para os SST por meio da subtração, visto que ao menos um dos indicadores apresentou concentração abaixo do limite de quantificação definida geralmente como 50 mg/L. Além disso, a série histórica só apresentou medidas de sólidos totais e dissolvidos para o período entre 2009 e 2019. Nesse sentido, optou-se por tratar esses registros como incompletos e ausentes e utilizar um método de preenchimento para obter uma série histórica completa para o período. Foram empregadas as técnicas de regressão e média aritmética para determinação dos valores ausentes na série temporal (GAO et al., 2018).

As observações que continham dados completos para sólido total, sólido dissolvido total, turbidez e vazão foram analisadas de forma a obter uma equação de regressão que relacionasse uma dessas variáveis com os sólidos suspensos ou dissolvidos. Optou-se por utilizar uma equação de regressão linear simples que relaciona sólidos suspensos com a turbidez (equação 14), visto que essas duas medidas costumam estar correlacionadas (GIPPEL, 1995; JONES et al., 2011). Além disso, o modelo obtido se mostrou o mais satisfatório para o propósito, pois teve um bom ajuste ($R^2 = 0,70$), coeficiente da variável preditora estatisticamente significativo ($p < 0,001$) e atendeu aos pressupostos da regressão linear (i.e., normalidade e homoscedasticidade dos resíduos).

$$SST = 0,8862 TU - 5,6825 \quad (14)$$

Onde:

SST = sólidos suspensos totais (mg/L);

TU = turbidez (UNT).

A equação 14 foi utilizada para obter os valores de sólidos suspensos totais para o período entre 2005 e 2008 e para preencher os dados incompletos do período entre 2009 e 2019. Ao adotar esse procedimento, foi possível preencher a maioria dos dados incompletos de forma satisfatória, ou seja, o modelo previu os dados de sólidos suspensos de forma que os dissolvidos não ultrapassassem 50 mg/L por coleta. Porém, em seis observações a equação não previu adequadamente os sólidos suspensos, pois o valor de sólidos dissolvidos resultante da subtração

foi maior que 50 mg/L, contrariando os valores observados em razão do limite de quantificação. Nestes casos, optou-se por selecionar as observações da série histórica que forneceram valor de sólidos dissolvidos totais menores que 50 mg/L ($n = 11$), extrair a média mensal e atribuir o valor obtido considerando o mês de coleta do dado ausente.

A obtenção das cargas médias anuais (tons/ano) na bacia foi feita com apoio do *software* FLUX32 (FLUX32, 2019), que utiliza como dados de entrada, além da concentração de um determinado indicador, a vazão média diária (m^3/s) e a vazão instantânea (m^3/s), ou seja, aquela medida no momento da coleta. Visto que a CETESB só disponibilizou a vazão instantânea para os anos entre 2015 e 2018 ($n = 18$), nas outras observações a vazão instantânea foi considerada igual à vazão média diária. Para o cálculo da carga anual de sólidos em suspensão foi utilizado o método mais simples do *software*, que é a estimativa direta da carga média (WALKER, 1999). Neste método, a equação 15 é aplicada para cada observação e a carga média anual é obtida pela média das cargas calculadas para as observações do período.

$$Q_{SST} = 31,5576 \cdot Q \cdot SST \quad (15)$$

Onde:

Q_{SST} = descarga sólida (tons/ano);

Q = vazão instantânea (m^3/s);

SST = sólidos suspensos totais (mg/L).

2.5.2 Indicadores de avaliação do desempenho do modelo

A avaliação do desempenho do modelo foi feita por meio de medidas gráficas relacionando valores observados e simulados (i.e., gráficos de dispersão e séries temporais) e medidas estatísticas (HARMEL et al., 2014; ASABE, 2017). As medidas estatísticas adotadas foram o coeficiente de eficiência de Nash-Sutcliffe (*NSE*) (NASH; SUTCLIFFE, 1970), porcentagem de viés (*Pbias*) (GUPTA; SOROOSHIAN; YAPO, 1999), razão da raiz do erro quadrático médio pelo desvio padrão dos dados observados (*RSR*) (MORIASI et al., 2007), e o coeficiente de determinação (R^2).

O coeficiente de eficiência de Nash-Sutcliffe (equação 16) é uma medida normalizada que considera a proporção da variância residual em relação à variância dos dados observados (NASH; SUTCLIFFE, 1970). Este indicador varia de $-\infty$ a 1, sendo este último o valor

considerado ótimo. Valores positivos de *NSE* são aceitáveis, enquanto valores negativos denotam uma performance inaceitável do modelo (MORIASI et al., 2007).

$$NSE = 1 - \frac{\left[\sum_{i=1}^n (O_i - S_i)^2 \right]}{\left[\sum_{i=1}^n (O_i - \bar{O})^2 \right]} \quad (16)$$

Onde:

O_i = i-ésimo valor observado do indicador;

S_i = i-ésimo valor simulado do indicador;

\bar{O} = média do valor observado do indicador;

n = número total de observações.

O estimador *Pbias* (%) mede a tendência média dos dados simulados de serem maiores ou menores do que os dados observados, sendo que valores próximos de zero são preferíveis (GUPTA; SOROOSHIAN; YAPO, 1999). Este indicador varia de $-\infty$ a $+\infty$, e valores negativos e positivos determinam, respectivamente, uma superestimação e subestimação por parte do modelo (GUPTA; SOROOSHIAN; YAPO, 1999). O *Pbias* é calculado como (equação 17):

$$Pbias = \left[\frac{\sum_{i=1}^n (O_i - S_i) \times 100}{\sum_{i=1}^n (O_i)} \right] \quad (17)$$

Onde:

O_i = i-ésimo valor observado do indicador;

S_i = i-ésimo valor simulado do indicador;

n = número total de observações.

A partir das recomendações de Singh, Knapp e Demissie (2004) sobre a avaliação da raiz do erro quadrático médio (*RMSE*), Moriasi et al. (2007) desenvolveram a estatística *RSR*, que normaliza o *RMSE* usando o desvio padrão dos dados observados (equação 18). Este indicador varia de zero a $+\infty$, sendo que zero indica um modelo perfeitamente ajustado. Quanto menor o *RSR*, menor o *RMSE* e, conseqüentemente, melhor o desempenho do modelo de simulação (MORIASI et al., 2007).

$$RSR = \frac{RMSE}{STDEV_{obs}} = \frac{\sqrt{\sum_{i=1}^n (O_i - S_i)^2}}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2}} \quad (18)$$

Onde:

O_i = i-ésimo valor observado do indicador;

S_i = i-ésimo valor simulado do indicador;

\bar{O} = média do valor observado do indicador;

n = número total de observações.

O coeficiente de determinação varia de zero a 1 e indica a relação de colinearidade entre os valores simulados e observados, sendo que 1 aponta um perfeito ajuste do modelo à amostra (MORIASI et al., 2007). Uma das formas de obter este índice é calcular o quadrado do coeficiente de correlação (equação 19).

$$R^2 = \left[\frac{\sum_{i=1}^n (O_i - \bar{O})(S_i - \bar{S})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2} \sqrt{\sum_{i=1}^n (S_i - \bar{S})^2}} \right]^2 \quad (19)$$

Onde:

O_i = i-ésimo valor observado do indicador;

S_i = i-ésimo valor simulado do indicador;

\bar{O} = média do valor observado do indicador;

\bar{S} = média do valor simulado do indicador;

n = número total de observações.

A performance do modelo para determinar o melhor ajuste foi avaliada segundo critérios propostos por Moriasi et al. (2007) e Moriasi et al. (2015). Devido à ausência de faixas de valores estabelecidas para avaliação do desempenho de modelos de sedimentos em escala anual, foram adotados os critérios definidos para modelos em escala mensal (Tabela 8).

Tabela 8 – Classificação do desempenho do modelo SDR considerando os indicadores *NSE*, *Pbias*, *RSR* e *R²*

Classificação	<i>NSE</i>	<i>Pbias</i> (%)	<i>RSR</i>	<i>R²</i>
Muito bom	$NSE > 0,8$	$Pbias \leq \pm 1$	$0 \leq RSR \leq 0,50$	$R^2 > 0,8$
Bom	$0,7 \leq NSE \leq 0,8$	$\pm 1 < Pbias < \pm 10$	$0,50 < RSR \leq 0,60$	$0,65 \leq R^2 \leq 0,80$
Satisfatório	$0,45 < NSE < 0,70$	$\pm 10 \leq Pbias \leq \pm 20$	$0,60 < RSR \leq 0,70$	$0,40 < R^2 < 0,65$
Insatisfatório	$NSE \leq 0,45$	$Pbias > \pm 20$	$RSR > 0,70$	$R^2 \leq 40$

Fonte: Moriasi et al. (2007) e Moriasi et al. (2015).

2.5.3 Parametrização e calibração

Visto que o modelo SDR possui poucos parâmetros de calibração, foi feito o ajuste manual destes parâmetros até se obter um desempenho ao menos satisfatório do modelo segundo os critérios de performance (ASABE, 2017). Seguindo as recomendações de Sharp et al. (2020), o valor padrão de SDR_{max} recomendado pelo modelo foi mantido (VIGIAK et al., 2012), e apenas os parâmetros k_b e $IC0$ foram variados de forma a obter um ajuste satisfatório entre valores observados e simulados. Os trabalhos que utilizam o SDR geralmente variam o parâmetro k_b e mantêm o valor padrão de 0,5 para o $IC0$, pois o modelo parece ser mais sensível ao primeiro (VIGIAK et al., 2012; HAMEL et al., 2015), e $IC0$ parece ser independente da paisagem (VIGIAK et al., 2012). No entanto, neste trabalho foi feita uma análise de sensibilidade para verificar a influência dos dois parâmetros na produção de sedimentos e, conseqüentemente, alterá-los de forma a obter o melhor desempenho possível. Essa etapa consistiu em variar os dois parâmetros no intervalo [0,5; 2] com incrementos de 0,5 e comparar os valores simulados com os valores observados calculados na seção 2.5.1. A partir dos resultados obtidos, a calibração foi feita novamente utilizando um novo conjunto de valores $k_b = \{0,5, 0,6, 0,7, 0,8, 0,9, 1, 1,1, 1,2, 1,3, 1,4, 1,5, 2\}$ e $IC0 = \{0,25, 0,5, 0,75, 1, 1,25, 1,5, 1,75, 2\}$. A avaliação do desempenho do modelo nessa etapa foi feita por meio das medidas gráficas e estatísticas descritas na seção 2.5.2.

Em seguida, os resultados gráficos e estatísticos foram analisados de forma a identificar possíveis *outliers* ou valores extremos. A avaliação da influência do viés e de valores extremos é importante quando o modelo apresenta valores insatisfatórios para o *NSE* (MCCUEN; KNIGHT; CUTTER, 2006). Este índice pode ser drasticamente afetado por *outliers* e valores extremos, visto que alteram desproporcionalmente as estatísticas de ajuste, dificultando o julgamento do modelo (MCCUEN; KNIGHT; CUTTER, 2006; RITTER; MUÑOZ-CARPENA, 2013). Caso *outliers* ou valores extremos sejam detectados, sua exclusão do conjunto de dados pode ser justificada em algumas situações, como no caso de modelos e/ou projetos que buscam avaliar condições médias (HARMEL et al., 2014). Como resultado,

estatísticas mais representativas podem ser obtidas, bem como um melhor ajuste do modelo (HARMEL et al., 2014). Além da análise de *outliers* e valores extremos, o viés do modelo (equação 20), ou seja, o erro médio associado à magnitude dos valores preditos, foi calculado de forma a suportar a avaliação correta do *NSE* (MCCUEN; KNIGHT; CUTTER, 2006). Ao fim dessas etapas, o modelo foi reavaliado para obter a combinação de k_b e $IC0$ que permitiu o melhor ajuste entre dados simulados e observados. Visando garantir a transparência no processo de aplicação e calibração, as incertezas associadas aos dados observados e valores simulados foram discutidas para subsidiar a apreciação das partes interessadas sobre a confiança do modelo e de seus resultados.

$$\bar{e} = \frac{1}{n} \sum_{i=1}^n (S_i - O_i) \quad (20)$$

Onde:

S_i = i -ésimo valor simulado do indicador;

O_i = i -ésimo valor observado do indicador;

n = número total de observações.

O procedimento de calibração consistiu em rodar o InVEST considerando os diferentes dados de entrada para cada ano (i.e., erosividade da chuva e uso e cobertura do solo) e as diferentes combinações de k_b e $IC0$, obter a produção de sedimento e compará-la com o valor observado. Para automatizar essa etapa foi feito o processamento em lote no Windows utilizando a linguagem Python segundo as orientações disponíveis em InVEST (2021). Além do Python versão 3.8.10, foram instalados os pacotes necessários para operação do InVEST, bem como o pacote *natcap.invest* disponibilizado pelos desenvolvedores do *software*. Uma versão atualizada do tutorial para processamento em lote e uma relação das dependências necessárias podem ser encontradas no repositório do projeto no GitHub (NATURAL CAPITAL PROJECT, 2021b). Após a preparação do ambiente, um *script* em linguagem Python, ou seja, um texto com instruções para execução da tarefa pela máquina de forma automatizada, foi elaborado e executado diretamente no prompt de comando (APÊNDICE D). Os comandos indicaram as mudanças necessárias nos caminhos dos arquivos de uso e cobertura do solo, erosividade da chuva, parâmetros de calibração e sufixo.

Após o processamento em lote, foi usado um *script* em linguagem R para extrair a quantidade de sedimento gerado que atingiu os riachos disponível na tabela de atributos do

arquivo vetorial “watershed_results_sdr_[sufixo].shp”. Para isso, foi empregado o pacote *foreign* (R CORE TEAM, 2020) que permite a leitura do banco de dados associado ao arquivo vetorial (extensão .dbf). Após esse processo, uma lista com os valores de produção de sedimentos para cada uma das paisagens foi salva em formato .csv.

2.6 Delineamento experimental das simulações

Após a definição e calibração do modelo hidrológico e definição do algoritmo de geração de modelos neutros, o experimento de simulação foi planejado de forma a subsidiar a análise da relação padrão-processo estudada. Visando distinguir os efeitos da composição e da configuração da paisagem na variável resposta, o experimento foi baseado no trabalho de Gergel (2005). Neste estudo, a autora empregou modelos heurísticos para verificar a importância da configuração da paisagem em determinar a carga de um poluente hipotético em um curso d’água. Para isso, foram geradas paisagens quadradas em formato matricial de dimensão 100 x 100, binárias (i.e., cobertura fonte ou sumidouro), com relevo uniforme e fluxo superficial unidirecional. No trabalho de Gergel (2005), a composição e configuração foram variadas por meio da geração de 10.000 paisagens aleatórias para cada classe de proporção de fonte na paisagem.

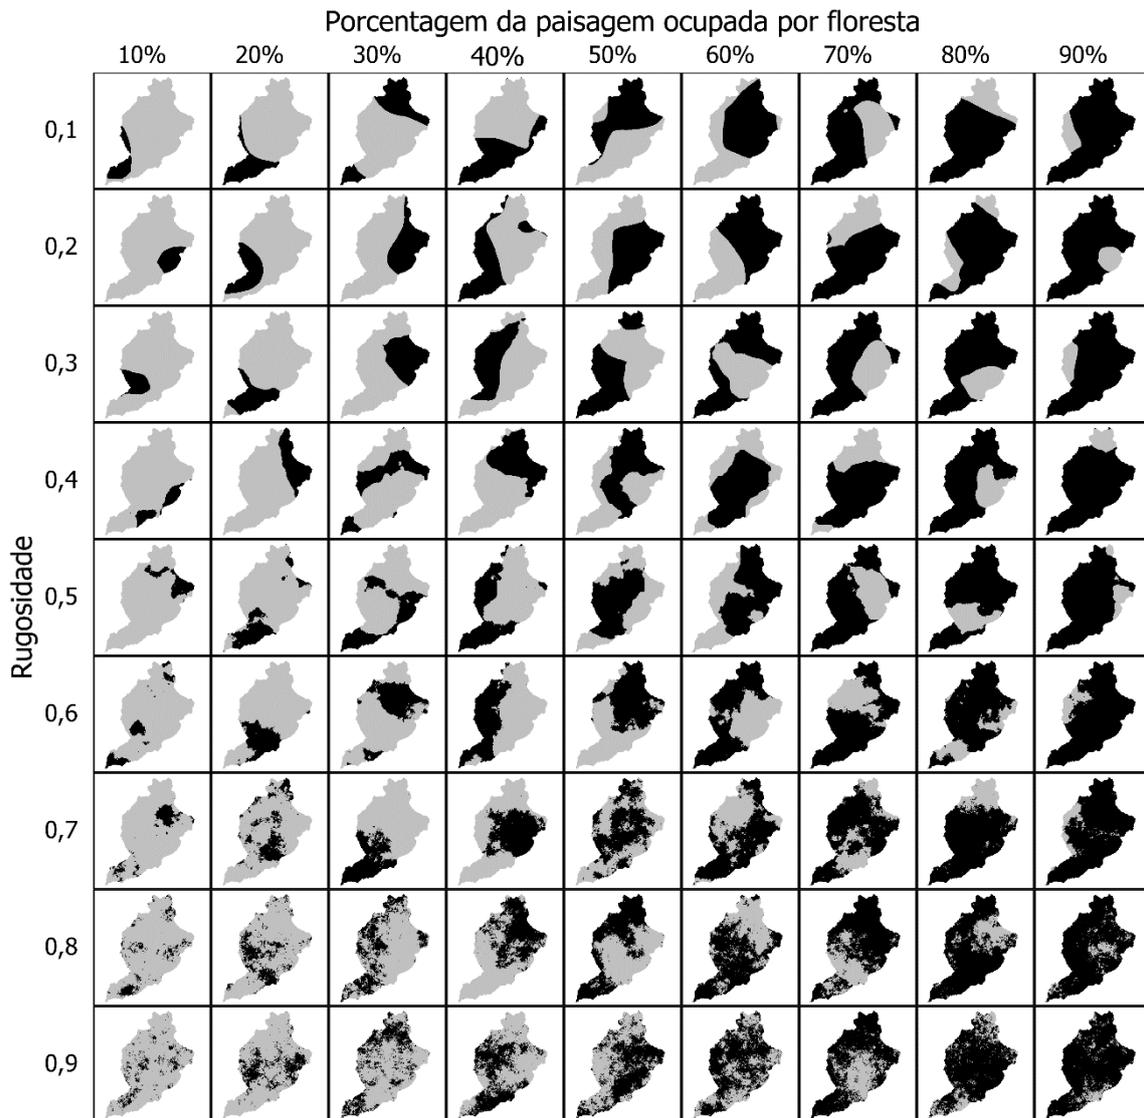
O desenho experimental proposto seguiu os princípios do trabalho de Gergel (2005), porém, foi aplicado a uma bacia hidrográfica real, com solo, clima e relevo característicos, bem como fluxo multidirecional. De acordo com o conhecimento disponível no momento de elaboração desta pesquisa, essa extensão do trabalho de Gergel (2005) utilizando uma bacia real, um modelo calibrado e paisagens artificiais fractais, se mostrava inédita na literatura. Foram produzidos dois tipos de paisagens: as de modelos neutros e as planejadas. O primeiro grupo abrange paisagens com disposição quase aleatória da floresta geradas pelo algoritmo de modelos neutros. No segundo, a cobertura do solo foi distribuída intencionalmente segundo critérios de proximidade com a zona ripária e declividade. Em ambos os cenários foram adotadas apenas duas classes de uso e cobertura do solo: floresta e agricultura.

2.6.1 Paisagens de modelos neutros

Neste tipo de cenário, a composição foi variada por meio do controle da porcentagem da paisagem ocupada pela classe floresta, e a configuração foi variada pelo argumento *roughness* da função *nlm_mpd* do pacote *NLMR* disponível em linguagem R (seção 2.2). Foram

adotados os seguintes valores de porcentagem (%) ocupada pela floresta $p = \{10, 20, 30, 40, 50, 60, 70, 80, 90\}$ e os seguintes valores para o argumento *roughness* = $\{0,1, 0,2, 0,3, 0,4, 0,5, 0,6, 0,7, 0,8, 0,9\}$. Oitenta e uma combinações de variação na composição foram obtidas considerando as nove classes de porcentagem e os nove níveis de autocorrelação espacial, e 100 réplicas foram produzidas para cada uma dessas combinações (Figura 26). Como resultado, 8.100 paisagens em formato matricial foram geradas por meio de um *script* escrito em linguagem R (APÊNDICE D). Além do pacote *NLMR*, responsável por gerar as paisagens de modelos neutros, foram utilizados os pacotes *landscapetools* (SCIAINI et al., 2020a), *igraph* (AMESTOY et al., 2020), *raster* (HIJMANS et al., 2021) e *rgdal* (BIVAND et al., 2021). Estes pacotes foram necessários para o processamento de toda a rotina de trabalho, o que inclui a geração das paisagens em formato raster, definição da extensão e projeção, recorte no formato da bacia, classificação, visualização e gravação do arquivo no disco rígido.

Figura 26 – Delineamento da geração de paisagens artificiais a partir do algoritmo de deslocamento do ponto médio para a sub-bacia do Alto Corumbataí



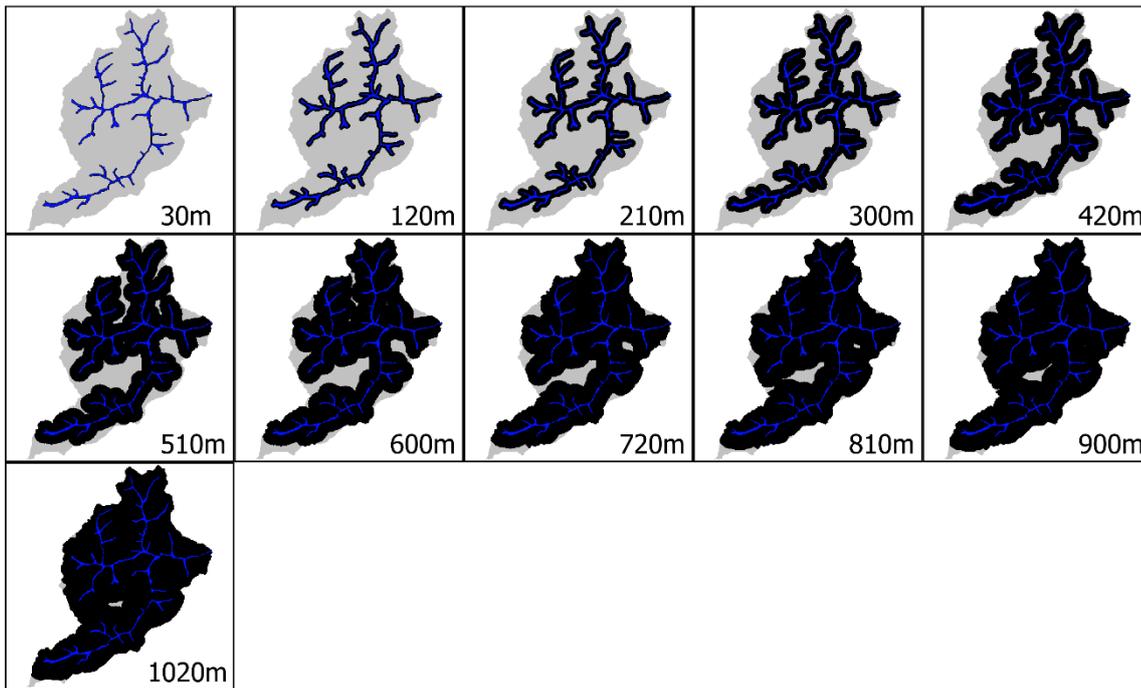
Fonte: elaborado pela autora.

2.6.2 Paisagens planejadas

Além das paisagens de modelos neutros, foram gerados cenários planejados da estrutura da paisagem na sub-bacia do rio Corumbataí. A partir dos resultados da revisão sistemática, que indicaram essas áreas como relevantes para modular o aporte de poluentes na água, foram propostas paisagens em que a floresta se concentrou nas zonas ripárias e nas áreas de maior declividade. No primeiro caso, faixas ripárias de diferentes larguras e cobertas com floresta foram geradas no entorno da hidrografia criada pelo InVEST. Essas faixas variaram de 30 a 1.020 m, com incrementos de 30 m entre cada, devido à resolução do pixel adotada. No segundo caso, primeiro calculou-se a declividade em porcentagem para a sub-bacia do Alto Corumbataí.

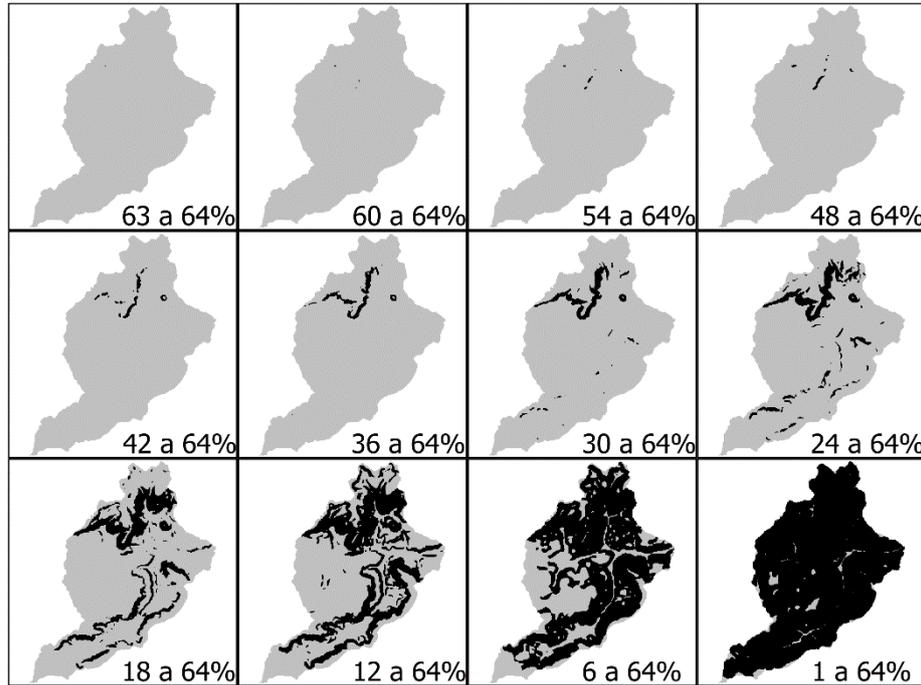
Para isso foi utilizado o MDE descrito na seção 2.4.4 e a ferramenta *r.slope.aspect* disponível no QGIS. Em seguida, foram geradas paisagens com diferentes classes de declividade cobertas por floresta, considerando um incremento de 1% entre cada paisagem. A Figura 27 e Figura 28 trazem exemplos, respectivamente, das paisagens com planejamento focado nas zonas ripárias e nas áreas de maior declividade.

Figura 27 – Ilustração da geração de paisagens planejadas para a sub-bacia do Alto Corumbataí em que a floresta (preto) se concentra em faixas ripárias de diferentes larguras



Fonte: elaborado pela autora.

Figura 28 – Ilustração da geração de paisagens planejadas para a sub-bacia do Alto Corumbataí em que a floresta (preto) se concentra nas áreas de maior declividade



Fonte: elaborado pela autora.

Além desses dois tipos de paisagens planejadas, foi elaborado um terceiro grupo em que se combinou uma faixa ripária florestal fixa com a disposição aleatória da floresta no restante da bacia. Foram geradas paisagens de modelos neutros da mesma forma que a descrita no item 2.6.1, porém, uma faixa de 30 m com cobertura florestal ao longo da drenagem gerada pelo InVEST foi adicionada em todas as paisagens elaboradas.

Foram obtidas 34 paisagens com concentração da floresta na zona ripária, 63 paisagens com concentração da floresta nas áreas de maior declividade e 8.100 paisagens de modelos neutros com faixa ripária florestal fixa de 30 m. A geração das paisagens planejadas também ocorreu no ambiente R utilizando um *script* escrito para esse propósito (APÊNDICE D).

2.6.3 Cálculo da produção de sedimentos

Após a geração das paisagens com e sem disposição planejada da cobertura florestal, calculou-se a produção de sedimentos para cada uma delas utilizando o modelo SDR. Para isso foram usados os mesmos dados de entrada da calibração, com exceção da erosividade, em que foi empregada a erosividade média calculada para um período de 15 anos (2005-2019), e o uso e cobertura do solo (Quadro 8). Visto que estas paisagens são binárias, os valores de C e P adotados correspondem aos das classes de formação florestal e savânica (i.e., floresta) e cana-

de-açúcar com emprego de plantio em contorno (i.e., agricultura) (seção 2.4.5). Além disso, os valores de k_b e IC0 foram definidos após a calibração.

Quadro 8 – Dados de entrada e parâmetros do modelo SDR utilizados no experimento de simulação

Argumento	Valor ou referência												
Modelo Digital de Elevação (raster)	Seção 2.4.4												
Índice de erosividade da chuva (raster)	Erosividade média calculada para o período 2005-2019 (Figura 21)												
Erodibilidade do solo (raster)	Figura 22												
Uso e cobertura do solo (raster)	8.100 paisagens de modelos neutros 34 paisagens planejadas – zona ripária 63 paisagens planejadas – declividade 8.100 paisagens planejadas – paisagens de modelos neutros com faixa ripária de 30 m												
Bacias hidrográficas (vetor)	Seção 2.4.1												
Tabela biofísica (.csv)	<table border="1"> <thead> <tr> <th>description</th> <th>lucode</th> <th>usle_c</th> <th>usle_p</th> </tr> </thead> <tbody> <tr> <td>floresta</td> <td>1</td> <td>0,0004</td> <td>1</td> </tr> <tr> <td>agri_cana</td> <td>2</td> <td>0,1124</td> <td>0,5</td> </tr> </tbody> </table>	description	lucode	usle_c	usle_p	floresta	1	0,0004	1	agri_cana	2	0,1124	0,5
description	lucode	usle_c	usle_p										
floresta	1	0,0004	1										
agri_cana	2	0,1124	0,5										
Limiar de acumulação de fluxo	150												
k_b	0,8												
IC0	0,25												
SDR_{max}	0,8												

Fonte: elaborado pela autora.

Definidos estes dados de entrada, a produção de sedimentos foi calculada pelo InVEST de forma automatizada variando apenas o arquivo do uso e cobertura do solo. Essa etapa foi feita por meio do mesmo processamento em lote utilizado na calibração e que se encontra descrito na seção 2.5.3. Um *script* em linguagem Python contendo os comandos para execução do InVEST considerando a mudança apenas do arquivo de uso e cobertura do solo e do sufixo foi elaborado e executado no prompt de comando do Windows. Em seguida, foi empregado um *script* em linguagem R (APÊNDICE D) para extrair o valor que indica a quantidade de sedimento gerado na bacia que atingiu os riachos, conforme descrito na seção 2.5.3.

2.7 Quantificação do padrão da paisagem

De forma a caracterizar a composição e configuração, métricas de paisagem foram calculadas pelo *software Fragstats* (MCGARIGAL; CUSHMAN; ENE, 2012) para as paisagens geradas por meio dos modelos neutros com e sem a faixa ripária florestal fixa. Para isso, foi empregado o processamento em lote disponibilizado pelo *Fragstats*, que permite uma única análise de vários arquivos utilizando as mesmas métricas de paisagem. O lote, um arquivo

ASCII delimitado por vírgulas, foi gerado por meio de um *script* escrito em linguagem R, salvo com a extensão “.fbt” (APÊNDICE D) e carregado no *software*. Neste lote, cada linha indica o caminho do arquivo de entrada e outras informações necessárias para leitura dos arquivos. Cada linha foi elaborada segundo o formato “Caminho do arquivo, tamanho da célula, valor do *background*, número de linhas, número de colunas, banda do raster, valor do *NoData*, formato do arquivo de entrada”.

Visto que a literatura sobre a configuração da paisagem se mostrou incipiente (Capítulo 1), optou-se por calcular um amplo número de métricas e executar uma análise exploratória da correlação entre elas e delas com a produção de sedimentos. Nesse sentido, foi assumida a hipótese de que a produção de sedimentos poderia ser relacionada com atributos de área, perímetro, forma e agregação das manchas florestais. Esse método foi adotado para explorar possíveis padrões de correlação em função da quantidade de floresta na paisagem. Ainda, as métricas do *Fragstats* foram escolhidas justamente para avaliar se esses índices, que tradicionalmente têm sido utilizados em análises da biodiversidade, poderiam ter alguma utilidade para a predição da qualidade da água. Foram calculadas 54 métricas em nível de classe e oito métricas em nível de paisagem em escala de bacia hidrográfica, e duas métricas em nível de classe em escala de zona ripária para avaliação preliminar (Quadro 9). A floresta foi a única cobertura analisada em nível de classe. As métricas para escala de zona ripária foram calculadas em uma faixa de 30 m ao longo da drenagem gerada pelo InVEST somente para as paisagens de modelos neutros sem a faixa ripária fixa. Para diferenciá-las das métricas em escala de bacia hidrográfica, foi adicionado o sufixo “_zrip”.

Quadro 9 – Métricas de paisagem empregadas para quantificar a composição e configuração das paisagens geradas no experimento de simulação

Métrica	Nome e sigla em inglês	Nível	
		Classe	Paisagem
Composição			
Porcentagem da paisagem*	<i>Percentage of Landscape</i> – PLAND (%)	x	
Índice da maior mancha	<i>Largest Patch Index</i> – LPI (%)	x	
Configuração			
Área da mancha	<i>Patch Area</i> – AREA (ha)	x	
Densidade de borda	<i>Edge Density</i> – ED (m/ha)	x	
Raio de rotação	<i>Radius of Gyration</i> – GYRATE (m)	x	
Razão perímetro-área	<i>Perimeter-Area Ratio</i> – PARA	x	
Índice de forma	<i>Shape Index</i> – SHAPE	x	
Índice de dimensão fractal	<i>Fractal Dimension Index</i> – FRAC	x	
Círculo circunscrito relacionado	<i>Related Circumscribing Circle</i> – CIRCLE	x	
Índice de contiguidade	<i>Contiguity Index</i> – CONTIG	x	
Dimensão fractal perímetro-área	<i>Perimeter-Area Fractal Dimension</i> – PAFRAC	x	
Distância euclidiana do vizinho mais próximo	<i>Euclidean Nearest Neighbor Distance</i> – ENN (m)	x	
Porcentagem de adjacências semelhantes	<i>Percentage of Like Adjacencies</i> – PLADJ (%)	x	x
Índice de agregação	<i>Aggregation Index</i> – AI (%)	x	x
Índice de aglomeração	<i>Clumpiness Index</i> – CLUMPY (%)	x	
Índice de forma da paisagem	<i>Landscape Shape Index</i> – LSI	x	x
Índice de forma da paisagem padronizado	<i>Normalized Landscape Shape Index</i> – NLSI	x	
Índice de coesão de manchas	<i>Patch Cohesion Index</i> – COHESION	x	x
Densidade de manchas*	<i>Patch Density</i> – PD (n/100 ha)	x	
Índice de divisão da paisagem	<i>Landscape Division Index</i> – DIVISION (proporção)	x	x
Índice de cisão	<i>Splitting Index</i> – SPLIT	x	x
Tamanho efetivo da malha	<i>Effective Mesh Size</i> – MESH (ha)	x	x
Índice de contágio	<i>Contagion Index</i> – CONTAG (%)		x

Fonte: elaborado pela autora.

Notas: as métricas em nível de classe foram obtidas por meio de equação específica ou por meio dos parâmetros estatísticos média, média ponderada pela área, mediana, desvio padrão e coeficiente de variação.

* Essas métricas foram calculadas em escala de bacia hidrográfica e em escala de zona ripária de 30 m para as paisagens de modelos neutros.

2.8 Análise da relação padrão-processo

A partir dos dados simulados para a qualidade da água e as métricas de composição e configuração da paisagem, a relação padrão-processo foi investigada utilizando métodos estatísticos e de aprendizagem de máquina. Deu-se preferência às análises exploratórias,

descritivas e cálculos de tamanhos de efeito e intervalos de confiança, bem como análises não paramétricas. Essa decisão foi tomada visto que o objetivo da pesquisa foi verificar a existência de padrões de produção de sedimentos para diferentes estruturas da paisagem, bem como a força do efeito ou da associação entre a estrutura espacial e a carga anual. Além disso, o uso de testes frequencistas em dados de simulação é criticado por alguns autores, visto que ao se adotar amostras grandes os valores- p são pouco informativos, pois quase sempre irão indicar uma diferença significativa (WHITE, 2014; HOFMANN, 2015). Por outro lado, os tamanhos de efeito gerados pelos testes mensuram quantitativamente a magnitude da diferença, o que geralmente é o foco de experimentos de simulação (WHITE, 2014). Ainda que a ênfase das análises seja os tamanhos de efeito, os valores- p não foram omitidos e são apresentados ao longo do texto e no APÊNDICE E.

2.8.1 Diferenças entre paisagens de modelos neutros e planejadas

A partir dos dados simulados de produção de sedimentos e o padrão da paisagem para cada réplica, foi possível investigar a relação entre essas variáveis utilizando ferramentas da estatística descritiva e inferencial. As paisagens de modelos neutros (MN), paisagens planejadas com valores progressivos de faixa ripária florestal (PRipária), paisagens planejadas com valores progressivos de cobertura florestal nas áreas de maior declividade (PDeclividade), e paisagens de modelos neutros com faixa ripária florestal fixa de 30 m (MNRipária) foram comparadas por meio de medidas descritivas e gráficas. Foram analisadas as médias, medianas, desvios padrão, mínimos e máximos de cada um desses grupos, bem como histogramas e *boxplots*. A produção de sedimentos em função da porcentagem de floresta também foi gerada graficamente para cada cenário de forma a compará-los.

2.8.2 Diferença nas cargas anuais médias entre as paisagens de modelos neutros com e sem faixa ripária florestal

Padrões de produção de sedimentos em função dos argumentos porcentagem e rugosidade, que estão associados à geração dos modelos neutros, foram investigados para as paisagens MN e MNRipária por meio de médias e variâncias, gráficos de violino, gráficos de densidade e mapas de calor. A diferença nas médias da produção de sedimentos entre os grupos MN e MNRipária foi avaliada graficamente por *boxplots* e intervalos de confiança a 95%. Uma Análise de Variância (ANOVA) robusta foi empregada de forma a obter um tamanho de efeito

da proporção e da autocorrelação espacial nas médias populacionais. Testes a posteriori foram utilizados para as comparações pareadas de grupos. A ANOVA clássica foi preterida em favor da ANOVA robusta visto que esta última é mais adequada quando há violações dos pressupostos dos testes estatísticos clássicos (MAIR; WILCOX, 2020). Os pressupostos foram checados pelo cômputo da ANOVA clássica e pela análise das observações, tendo sido detectada a heterogeneidade das variâncias dos grupos a serem testados, tanto pelo teste de Levene ($p < 0,05$) quanto pela comparação dos valores. Além disso, para alguns testes, especialmente aqueles voltados para o efeito da autocorrelação espacial, verificou-se a não normalidade dos resíduos por meio dos gráficos Q-Q (quantil-quantil).

O pacote *WRS2* publicado por Mair, Wilcox e Patil (2021) foi utilizado para esse propósito. A função *tlway* foi empregada para computar uma ANOVA *one-way* para grupos independentes utilizando médias aparadas. Essa função não assume homogeneidade das variâncias, pois emprega uma generalização da aproximação de Welch (WILCOX, 2012). Foi adotada uma apara de 20% das observações em ambas as extremidades conforme indicado por Wilcox (2010) e 599 amostras para o cálculo do intervalo de confiança a 95% dos tamanhos de efeito por meio de um *bootstrap*. Este tamanho amostral segundo Wilcox (2012) é suficiente para controlar a probabilidade de erro tipo I ao se adotar $\alpha = 0,05$. Os testes a posteriori foram executados por meio da função *lincon* utilizando o método de Hochberg (HOCHBERG, 1988) para correção dos valores-*p* associados às múltiplas comparações.

Para detectar uma diferença significativa entre grupos, adotou-se $p < 0,05$ para os resultados da ANOVA robusta e verificou-se a inclusão do valor zero nos intervalos de confiança a 95% para as comparações múltiplas. A medida explicativa de tamanho de efeito ζ proposta por Wilcox e Tian (2011), que é robusta, heteroscedástica e apropriada para comparações entre mais que dois grupos, também foi observada. Esta estatística indica a força da associação entre a variável explicativa categórica e a variável resposta quantitativa e reflete a proporção da variância explicada (WILCOX; TIAN, 2011). Para julgar a sua magnitude foi adotada a classificação de Mair e Wilcox (2020), em que $\zeta = 0,10, 0,30$ e $0,50$ correspondem, respectivamente, a um tamanho de efeito pequeno, médio e grande. Dois tamanhos de efeito foram considerados diferentes quando não houve a sobreposição dos respectivos intervalos de confiança a 95%.

A ANOVA robusta foi utilizada para comparar as cargas anuais médias de acordo com as porcentagens de floresta e os níveis de autocorrelação espacial. Além disso, foram comparadas as médias para os níveis de autocorrelação espacial dentro de cada classe de porcentagem (i.e., 10, 20, 30, 40, 50, 60, 70, 80, e 90%) e as médias para as classes de

porcentagem dentro de cada nível de autocorrelação espacial (i.e., 0,1, 0,2, 0,3, 0,4, 0,5, 0,6, 0,7, 0,8 e 0,9). Os testes a posteriori não foram aplicados neste contexto, mas sim apenas para comparações múltiplas entre as classes de porcentagem de floresta e entre os níveis de autocorrelação espacial descritos acima.

2.8.3 Correlação entre métricas de paisagem e produção de sedimentos em paisagens de modelos neutros

Para investigar a relação entre métricas de paisagem e produção de sedimentos, foi feita uma análise exploratória e descritiva a partir de gráficos de dispersão e coeficientes de correlação de postos de Spearman, uma medida não paramétrica e padronizada da relação entre duas variáveis (FIELD; MILES; FIELD, 2012). Os coeficientes de correlação para a associação entre carga anual de sedimentos e métricas de paisagem foram calculados e classificados de acordo com sua força, segundo critério proposto por Cohen (1992), em que $\rho = |0,10|$, $|0,30|$ e $|0,50|$ correspondem, respectivamente, a uma correlação fraca, média e forte.

Os coeficientes de correlação entre métricas de paisagem e aporte de sedimentos foram examinados considerando o grupo total de paisagens sem (MN) e com (MNRipária) faixa ripária florestal fixa. Além disso, foram examinados os coeficientes de correlação obtidos para cada percentual de cobertura florestal analisado (i.e., de 10 a 90% de florestas). Foram quantificados o número de correlações por grupo e por classes de percentuais de acordo com o critério de força de Cohen (1992). Os tamanhos de efeito de magnitude média e forte foram examinados com mais detalhe tanto para o grupo geral quanto para as classes de percentual. Possíveis padrões de interdependência foram identificados por meio da mudança de sinal e magnitude do coeficiente entre os grupos geral e de percentuais e entre as classes de percentuais de floresta.

De forma a auxiliar a interpretação da linearidade das relações bivariadas, um suavizador LOESS foi adicionado em alguns dos gráficos de dispersão apresentados. Segundo Cleveland e Devlin (1988), LOESS é a abreviação em inglês para *locally weighted regression* e consiste em um método não paramétrico de regressão localmente ponderada que estima uma curva ou superfície suavizada da relação entre a variável dependente e as independentes. Suas aplicações principais são a exploração de dados, diagnóstico de modelos paramétricos e geração de superfícies de regressão não paramétricas (CLEVELAND; DEVLIN, 1988). Dado que mudanças abruptas nos sistemas podem ser verificadas pela presença de dinâmicas não lineares (ANDERSEN et al., 2009), o suavizador LOESS também foi empregado para avaliar

preliminarmente a existência de possíveis limiares associados à proporção de florestas na bacia e na zona ripária. As análises estatísticas e gráficas foram conduzidas no ambiente R utilizando as funções nativas e os pacotes *GGally* (SCHLOERKE et al., 2021) e *psych* (REVELLE, 2021).

2.8.4 Métricas de paisagem como variáveis preditoras da produção de sedimentos

As técnicas não paramétricas de “floresta aleatória” e “árvore de regressão” foram empregadas para investigar o potencial das métricas de paisagem em explicar a variação na produção de sedimentos. Ambas são alternativas adequadas para a exploração interativa, descrição e predição de dados ecológicos e ambientais (DE’ATH; FABRICIUS, 2000; PRASAD; IVERSON; LIAW, 2006; CUTLER et al., 2007). Exemplos de estudos que utilizaram florestas aleatórias para identificação de preditores importantes da qualidade da água incluem Clément et al. (2017) e Rose et al. (2017), que também empregaram árvores de regressão individuais, e Alnahit, Mishra e Khan (2022). Estudos que utilizaram apenas árvores de regressão incluem os de Franklin et al. (2013), Moncayo-Estrada et al. (2017) e Nobre et al. (2020). Esses métodos de análise de dados baseados em aprendizado de máquina têm se mostrado oportunos para a predição da qualidade da água tendo em vista a não linearidade, multicolinearidade, e heteroscedasticidade dos preditores (GIRI, 2021).

A floresta aleatória (*Random Forest*) é um algoritmo de aprendizado de máquina supervisionado aplicado a problemas de classificação e regressão (CUTLER; CUTLER; STEVENS, 2012). Esta técnica foi introduzida por Leo Breiman em 2001 como uma forma de aprimorar a acurácia de árvores de decisão para predição. O algoritmo cria uma coleção de árvores de decisão aleatorizadas em que cada uma prediz um valor para a variável resposta (BREIMAN, 2001). A combinação dos resultados de cada árvore fornece uma estimativa mais acurada e estável para a variável resposta quando comparada a uma estimativa fornecida por uma única árvore (BREIMAN, 2001). Dessa forma, o algoritmo permite explorar estruturas de dados multidimensionais sem considerar pressupostos sobre a distribuição da variável resposta ou dos preditores ou sobre a relação entre eles (CUTLER et al., 2007). Do ponto de vista computacional e estatístico, esse algoritmo tem algumas vantagens, como a facilidade e rapidez em treinar e prever, poucos parâmetros de ajuste, e o fornecimento de uma medida da importância das variáveis explicativas para a predição da variável resposta (CUTLER; CUTLER; STEVENS, 2012). Essas medidas de importância permitem avaliar a relevância de múltiplas variáveis e facilitam a seleção de um subconjunto para ajuste de um modelo (CUTLER; CUTLER; STEVENS, 2012). Neste trabalho, empregou-se esse algoritmo com o

objetivo de verificar quais métricas de paisagem candidatas têm maior importância para a produção de sedimentos.

A base de aprendizagem da floresta aleatória são as árvores de decisão, que são empregadas para explorar a relação entre uma variável resposta e múltiplas explicativas (ZUUR; IENO; SMITH, 2007). A descrição deste método a seguir se baseia em Cutler, Cutler e Stevens (2012). A variável resposta pode ser categórica ou contínua e suas árvores são chamadas, respectivamente, de classificação ou regressão. As árvores de regressão são formadas pela divisão binária recursiva dos dados a partir de um critério definido por uma variável preditora que se associa fortemente com a variável resposta. As árvores são visualizadas por meio de um gráfico com um nó raiz no topo que se divide sucessivamente em outros nós até terminar em nós-folha, os grupos finais de partição dos dados. Em cada etapa de divisão, ou seja, em cada nó, todas as variáveis preditoras são testadas e aquela que resulta em grupos mais homogêneos é escolhida como critério de particionamento. No momento da divisão, observações cujos valores para a variável preditora sejam menores ou maiores que o de corte são particionadas em dois grupos distintos. O processo continua até que se alcance um critério de parada, como o atingimento de um número mínimo de observações em um nó. Para prever um valor para a variável resposta a partir de uma nova observação, basta percorrer a árvore observando os valores das variáveis explicativas até atingir um dos nós folha. O Quadro 10 apresenta os algoritmos usados para a geração das árvores de regressão e das florestas aleatórias.

Quadro 10 – Algoritmos de divisão binária recursiva aplicados a árvores de regressão (algoritmo 1) e florestas aleatórias (algoritmo 2)

Algoritmo 1 – Árvore de regressão

Dado um conjunto de treinamento D onde p é o número de preditores e y é a variável resposta.

1. Iniciar com todas as observações em um nó;
2. Repetir os passos a seguir recursivamente para cada nó não dividido até o atingimento do critério de parada:
 - a. Encontrar a melhor divisão entre todas as divisões binárias possíveis nos p preditores;
 - b. Dividir o nó em dois nós descendentes usando a divisão determinada no passo 2a.
3. Para uma predição em x , percorrer a árvore no sentido descendente até atingir um nó-folha. Sendo k o nó-folha e y_{k_1}, \dots, y_{k_n} os valores para a variável resposta dos dados de treinamento em um nó k , os valores preditos para a variável resposta são dados por:

$$\hat{h}(x) = \bar{y}_k = \frac{1}{n} \sum_{i=1}^n y_{k_i}$$

Algoritmo 2 – Florestas aleatórias utilizando árvores de regressão

Dado um conjunto de treinamento D onde p é o número de preditores e y é a variável resposta, repetir os passos a seguir até obter um determinado número de árvores de decisão J .

1. Gerar uma amostra *bootstrap* com reposição de tamanho igual ao conjunto original dos dados de treinamento D ;
2. Usando a amostra *bootstrap* gerada em (1) como dados de treinamento, ajustar uma árvore de regressão usando a divisão binária recursiva:
 - a. Iniciar com todas as observações em um nó;
 - b. Repetir os passos a seguir recursivamente para cada nó não dividido até o atingimento do critério de parada:
 - i) Selecionar m preditores aleatoriamente a partir de p preditores disponíveis;
 - ii) Encontrar a melhor divisão entre todas as divisões binárias possíveis nos m preditores determinados no passo (i);
 - iii) Dividir o nó em dois nós descendentes usando a divisão determinada no passo (ii).

Para fazer uma predição para uma nova observação x :

$$\hat{f}(x) = \frac{1}{J} \sum_{j=1}^J \hat{h}_j(x)$$

Onde:

\hat{h}_j = predição da variável resposta em x usando a j -ésima árvore

Fonte: adaptado de Cutler, Cutler e Stevens (2012).

Como visto, a floresta aleatória utiliza um conjunto de diferentes árvores aleatorizadas para predição, enquanto o algoritmo de árvore de regressão prediz a partir de uma única árvore. Cada árvore da floresta aleatória é treinada a partir de amostras independentes extraídas por *bootstrap* com reposição a partir do conjunto original de dados e um subconjunto m de variáveis preditoras em cada divisão em vez de todos os preditores (STROBL; MALLEY; TUTZ, 2009). Essa randomização tanto dos dados de treinamento quanto dos preditores testados permite que diferentes variáveis tenham a chance de serem incluídas em alguma árvore, facilitando a compreensão de seus efeitos na variável resposta (STROBL; MALLEY; TUTZ, 2009). Ainda, acrescentar essa variabilidade aleatória leva à construção de árvores descorrelacionadas e independentes entre si, resultando em predições menos variáveis e mais confiáveis (JAMES et al., 2021).

Ao utilizar o *bootstrap* com reposição para obter a amostra de treinamento no primeiro passo do algoritmo, cerca de 1/3 dos dados não são incluídos e são chamados de *out-of-bag* (OOB) (BREIMAN, 2001). Esses dados não empregados na construção das árvores são usados na estimativa do erro de predição da floresta aleatória e da importância das variáveis, o que dispensa a necessidade de um conjunto de teste (CUTLER; CUTLER; STEVENS, 2012). Uma dessas medidas se baseia na permutação dos dados OOB para obter a importância das variáveis

da seguinte forma (CUTLER; CUTLER; STEVENS, 2012): i) as observações OOB são corridas pela árvore e os valores preditos são computados; ii) os valores de uma variável k são permutados aleatoriamente no conjunto OOB enquanto as outras variáveis permanecem inalteradas; iii) o novo conjunto OOB com a variável permutada é corrido pela árvore e obtêm-se os valores preditos. A permutação resulta em uma modificação da relação com a variável resposta, portanto, uma queda na acurácia após a permutação demonstra que a variável testada é importante para a predição (STROBL; MALLEY; TUTZ, 2009).

As florestas aleatórias foram geradas utilizando as funções do pacote *randomForest* para o ambiente R (LIAW, 2022), que é baseado nos códigos desenvolvidos por Leo Breiman e Adele Cutler, proponentes do algoritmo. Antes dos cálculos, uma pré-seleção de métricas de paisagem foi feita em razão da colinearidade dos índices. Ainda que não seja necessária, uma pré-seleção baseada em hipóteses sobre o processo estudado pode ser importante para desenvolver uma floresta aleatória interpretável (FOX et al., 2017). A entrada de variáveis correlacionadas no algoritmo prejudica a interpretação das medidas de importância, visto que a permutação tende a identificar todos os preditores correlacionados como importantes quando um deles se mostra relevante (CUTLER; CUTLER; STEVENS, 2012). O uso de variáveis correlacionadas em árvores de regressão também é desencorajado, pois sua inclusão em múltiplos nós complica a interpretação do diagrama (CUTLER; CUTLER; STEVENS, 2012). A seleção das métricas ocorreu da seguinte forma. Primeiramente, só foram consideradas métricas em nível de classe, ou seja, métricas mensuradas para a cobertura florestal. Em seguida, métricas que não apresentaram valores observados para todas as réplicas de paisagens foram excluídas⁵, assim como o índice NLSI, que não é recomendado para avaliar paisagens de formato irregular e com altas porcentagens de uma determinada classe (MCGARIGAL, 2015). Devido à correlação das métricas entre si e com os argumentos de geração dos modelos neutros (i.e., porcentagem e rugosidade), optou-se por fixar PLAND como métrica de composição e eliminar aquelas com correlação forte com a proporção de florestas. Uma exceção foi PLAND_zrip, que foi incluída nas análises do grupo MN. Foi especificado o critério de $\rho \leq -0,70$ ou $\rho \geq 0,70$ para classificar os pares de métricas fortemente colineares, conforme proposto por Dormann (2013). Essa medida foi tomada de modo a evitar que métricas fortemente correlacionadas com a porcentagem de floresta dificultassem a interpretação dos gráficos de importância das variáveis. Consequentemente, foram considerados 42 e 36 preditores para geração das florestas aleatórias para as paisagens MN e MNRipária, respectivamente.

⁵ Algumas métricas, como PAFRAC e ENN, exigem um número mínimo de manchas na paisagem para seu cômputo, o que resultou em algumas réplicas com valores NA devido ao não atendimento desse critério.

Os seguintes parâmetros de geração da floresta aleatória podem ser ajustados de forma a aprimorar a sua acurácia e a estabilidade da importância das variáveis (STROBL; MALLEY; TUTZ, 2009): o número de árvores geradas para o conjunto (*ntree*), o número de preditores amostrados aleatoriamente em cada nó (*mtry*) e o tamanho das árvores, que pode ser definido pelo número máximo de nós-folha (*maxnodes*). Entretanto, o algoritmo parece ser mais sensível a *mtry* (CUTLER; CUTLER; STEVENS, 2012; PROBST; WRIGHT; BOULESTEIX, 2019) e seu ajuste não é crucial visto que apresenta bom desempenho mesmo usando valores padrão para os parâmetros (STROBL; MALLEY; TUTZ, 2009; CUTLER; CUTLER; STEVENS, 2012). Liaw e Wiener (2002) indicam que, quando um conjunto dispõe de vários preditores, mas espera-se que poucos tenham importância, um valor maior de *mtry* pode aprimorar a performance das florestas. Nesse sentido, foram testados o valor padrão (i.e., $p/3$), a metade do padrão e o dobro do padrão para *mtry* conforme orientações de Leo Breiman em Liaw e Wiener (2002). O valor de *mtry* que resultou no menor erro OOB foi então escolhido (equação 21). As florestas aleatórias para MN e MNRipária foram geradas utilizando os valores padrão para *ntree* = 500 e *nodesize* = 5 (LIAW, 2022).

$$MSE_{oob} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i^{oob})^2 \quad (21)$$

Onde:

\hat{y}_i^{oob} = média do valor predito OOB para a i-ésima observação

y_i = valor observado para a i-ésima observação

n = número de observações

Duas medidas de importância das variáveis são fornecidas pelo pacote *randomForest*: i) a diminuição média da acurácia, e ii) a diminuição média da impureza do nó. Para obter a primeira, os dados *out-of-bag* são utilizados. Para cada árvore, são obtidas três medidas de erro quadrático médio: o erro de predição da porção OOB, o mesmo erro OOB obtido após a permutação da variável k , e a diferença entre eles. A média dessa diferença para todas as árvores é então apresentada em valores brutos ou normalizada pelo desvio padrão da diferença. A segunda medida indica a redução total da impureza dos nós, em média para todas as árvores, ao se utilizar a variável preditora para divisão. É aferida pela soma dos quadrados dos resíduos. Conforme recomendação de Strobl, Malley e Tutz (2009), a importância das variáveis foi avaliada pelo ranqueamento dos valores absolutos das medidas.

Ainda que a floresta aleatória tenha maior acurácia de predição, ela é pouco interpretável, pois não é fornecido um dado de saída como uma fórmula ou um gráfico que sumarie a função de regressão para os dados analisados (CUTLER et al., 2007). Por outro lado, uma única árvore de regressão é instável a pequenas mudanças nos dados de treinamento, gerando predições variáveis (STROBL; MALLEY; TUTZ, 2009). Apesar disso, tem como vantagem permitir a exploração, descrição e predição com visualização gráfica facilmente interpretável de resultados complexos que podem envolver interações entre variáveis (DE'ATH; FABRICIUS, 2000). Nesse sentido, árvores de regressão individuais foram elaboradas para as paisagens MN e MNRipária tendo como preditores candidatos as métricas utilizadas na construção das florestas aleatórias. Para isso foi empregado o pacote *rpart* (THERNEAU; ATKINSON; RIPLEY, 2022) que é baseado no algoritmo de árvores de classificação e regressão descrito em Breiman et al. (1984). Nesta função, o critério de particionamento é a minimização da soma dos resíduos quadrados (equação 22) (THERNEAU; ATKINSON, 2022).

$$SS_T - (SS_E + SS_D)$$

$$SS = \sum (y_i - \bar{y})^2 \quad (22)$$

Onde:

SS_T = soma dos quadrados em um nó superior;

SS_E = soma dos quadrados no nó descendente esquerdo;

SS_D = soma dos quadrados no nó descendente direito;

y_i = valor observado para a i -ésima observação;

\bar{y} = média do valor observado no nó.

Uma questão frequente na construção de uma árvore de regressão é o seu tamanho ideal. Essa dimensão varia de acordo com a natureza dos dados analisados, visto que árvores grandes resultam em sobreajuste e árvores pequenas podem não capturar os padrões existentes nos dados (HASTIE; TIBSHIRANI; FRIEDMAN, 2001). Uma estratégia para geração de uma árvore de regressão é crescê-la até atingir um critério de parada e “podá-la” utilizando uma medida de custo-complexidade. Esta abordagem é baseada em um parâmetro de ajuste α que controla o *trade-off* entre a complexidade da árvore e seu ajuste aos dados (JAMES et al., 2021). Quando $\alpha = 0$, não há uma penalização para o número de nós-folha, portanto, a árvore mais

longa é obtida. Ao adotar $\alpha > 0$, árvores com menos nós-folha são geradas. O valor para α pode ser determinado a partir de dados de teste ou por validação cruzada (JAMES et al., 2021).

Neste trabalho, optou-se por utilizar a função *rpart* que por padrão executa internamente uma pré-poda das árvores por meio do argumento de complexidade *cp* e uma validação cruzada de 10 partes (*10-fold*)⁶. Portanto, as árvores foram crescidas utilizando os parâmetros pré-definidos da função, particularmente, $cp = 0,01$. Esse argumento varia de zero a 1 e tem uma interpretação direta no caso de árvores de regressão, pois se associa à melhoria do ajuste em função do crescimento da árvore. Ao adotar $cp = 0,01$, se assume que uma divisão binária dos dados que não resulta em um incremento de pelo menos 0,01 no valor de R^2 do modelo não é relevante e é descartada (THERNEAU; ATKINSON; 2022). Os resultados da validação cruzada são visualizados principalmente por uma tabela e um gráfico que auxiliam na definição da melhor poda. Na tabela, diferentes intervalos para *cp*, que resultam em uma sequência de subárvores com menos nós-folha, são apresentados junto com seus respectivos erros médios e desvios padrão obtidos pela validação cruzada. O gráfico plota esses erros e desvios padrão em função de *cp* e do tamanho da árvore, além de exibir uma linha horizontal pontilhada que delimita o menor valor de erro obtido somado ao seu desvio padrão. Essa linha simboliza a regra do “um erro padrão” (1-SE) proposta por Breiman et al. (1984), que pode ser usada na seleção da melhor poda. O tamanho da árvore, que é controlado pelo valor de *cp*, é determinado a partir do menor erro calculado pela validação cruzada ou pelo menor erro situado logo abaixo da linha do 1-SE (ZUUR; IENO; SMITH, 2007). Neste sentido, para cada grupo de paisagens foi gerada uma única árvore considerando $cp = 0,01$ e a necessidade de poda foi avaliada por meio dos resultados das validações cruzadas executadas pelo pacote *rpart*. As árvores de regressão foram apresentadas graficamente utilizando o pacote *rpart.plot* (MILBORROW, 2021).

⁶ Uma descrição mais detalhada do processo de poda e de validação cruzada em árvores de regressão pode ser encontrada em De'Ath e Fabricius (2000) e no capítulo 7 do livro de Zuur, Ieno e Smith (2007). Já o capítulo 7 em Hastie, Tibshirani e Friedman (2017) fornece uma visão mais geral sobre a validação cruzada.

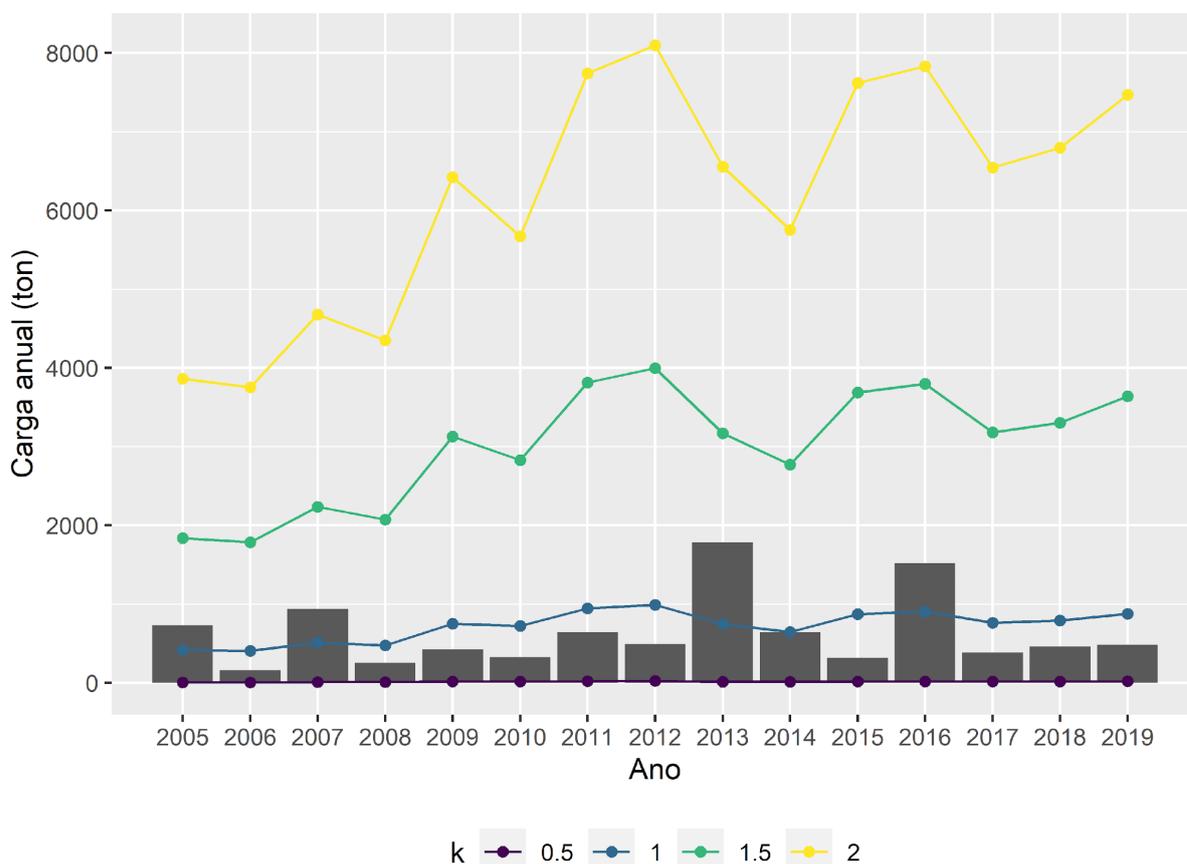
3 RESULTADOS

Esta seção descreve primeiramente os resultados do processo de calibração do modelo SDR para a sub-bacia do Alto Corumbataí. Em seguida, são apresentados os resultados das análises aplicadas para a elucidação da relação entre a estrutura das paisagens e as cargas de sedimentos associadas a elas.

3.1 Calibração do modelo SDR

A primeira etapa da calibração envolveu a análise da sensibilidade do modelo aos parâmetros de calibração k_b e $IC0$. Conforme pode ser observado na Figura 29, o valor padrão $k_b = 2$ indicado pelo InVEST levou a uma superestimação da produção de sedimentos em todos os anos avaliados. Em média, os valores simulados foram 13 vezes maiores que os valores observados. Também é possível constatar que a diferença entre os valores simulados para cada ano parece seguir um padrão, pelo menos para aqueles cujo $k_b \geq 1$.

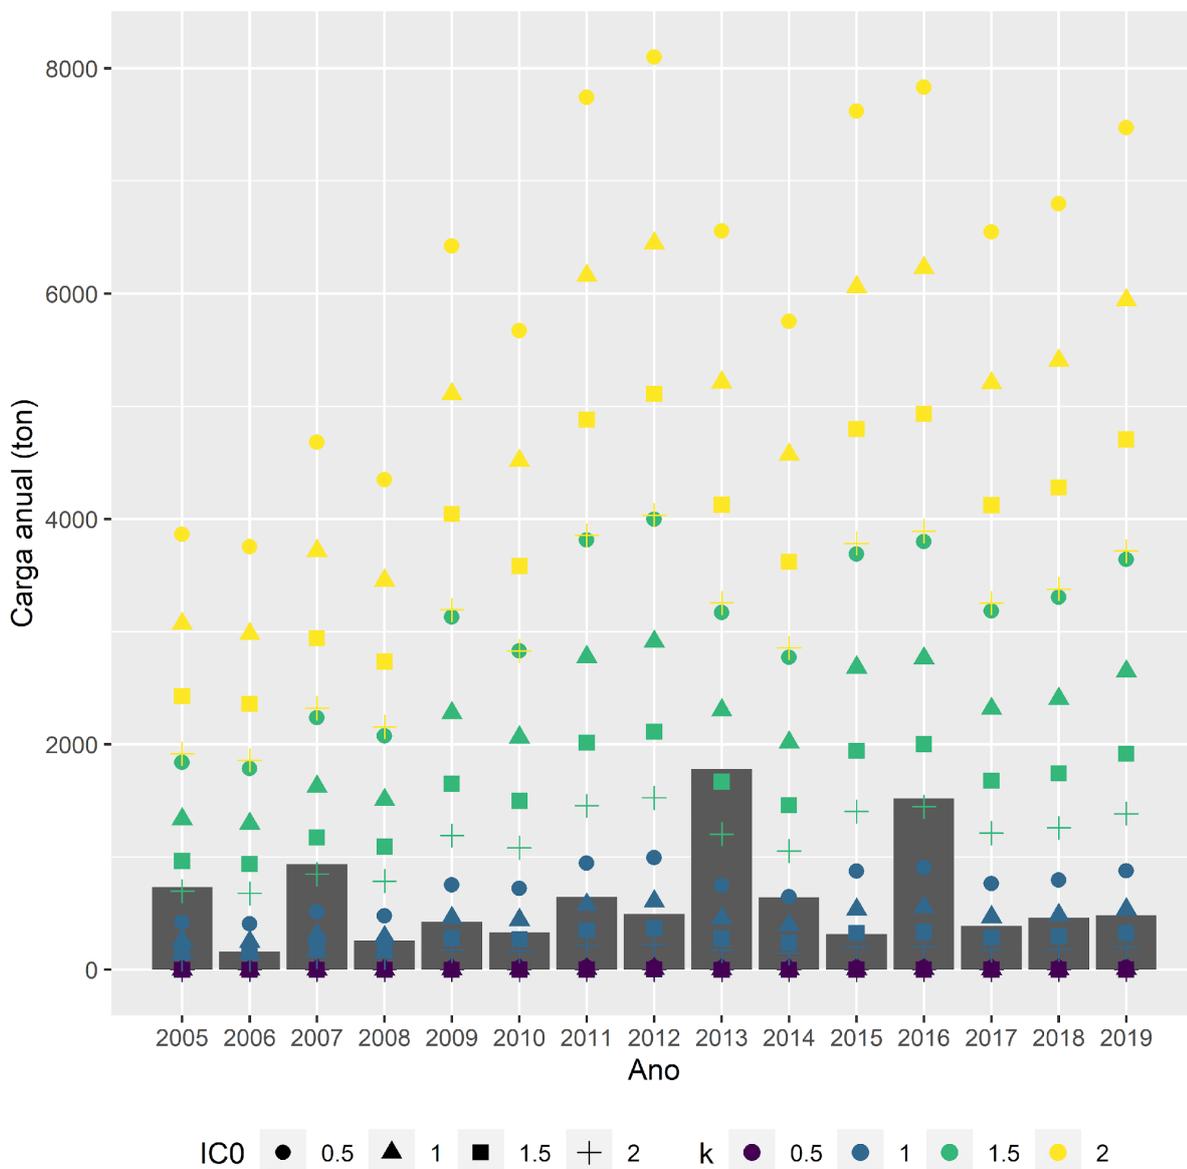
Figura 29 – Valores observados (barras) e simulados (linhas) da carga anual de sedimentos na sub-bacia do Alto Corumbataí para diferentes valores do parâmetro de calibração k_b e $IC0 = 0,5$



Fonte: elaborado pela autora.

A partir da Figura 30, pode-se observar que o modelo é sensível aos parâmetros k_b e $IC0$, portanto, este último poderia ser utilizado para um ajuste mais fino do modelo. Além disso, verifica-se que o valor de k_b para ajuste aos dados observados se situa em torno de $k_b = 1$. Diante desses resultados, a segunda etapa compreendeu a calibração do modelo a partir de um novo conjunto de valores, sendo $k_b = \{0,5, 0,6, 0,7, 0,8, 0,9, 1, 1,1, 1,2, 1,3, 1,4, 1,5, 2\}$ e $IC0 = \{0,25, 0,5, 0,75, 1, 1,25, 1,5, 1,75, 2\}$, totalizando 96 combinações de k_b e $IC0$.

Figura 30 – Valores observados (barras) e simulados (pontos) da carga anual de sedimentos na sub-bacia do Alto Corumbataí para diferentes valores dos parâmetros de calibração k_b e $IC0$

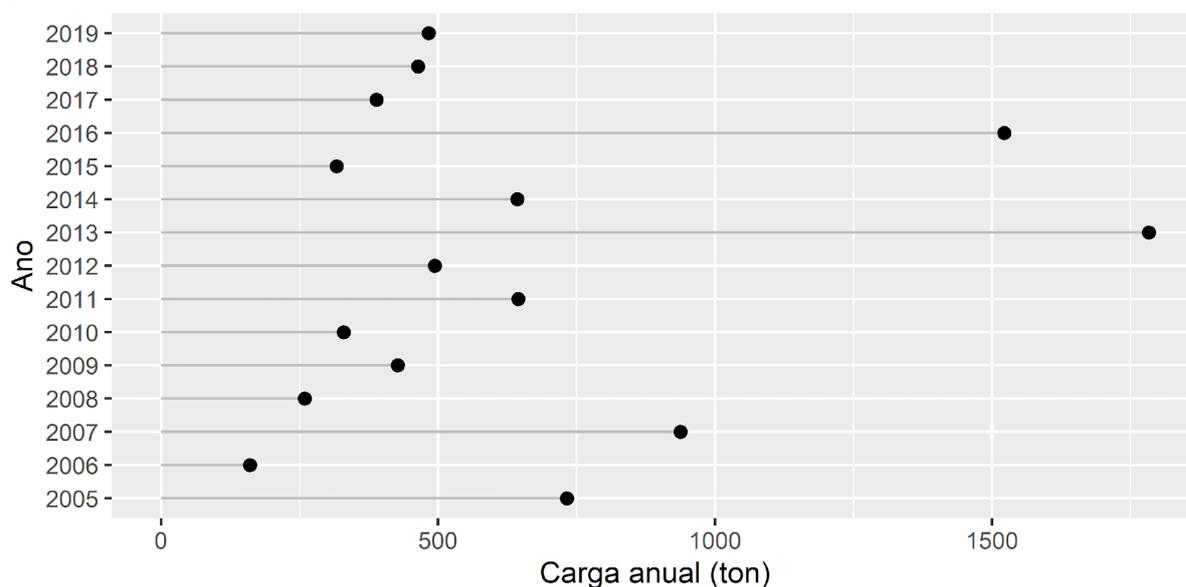


Fonte: elaborado pela autora.

Após a segunda etapa de calibração, as combinações de valores de k_b e $IC0$ foram avaliadas utilizando os indicadores NSE , $Pbias$, RSR e R^2 . No entanto, não houve nenhum desempenho “satisfatório” segundo todos os critérios estabelecidos (Tabela 8). Embora algumas combinações tivessem apresentado valor satisfatório para o indicador $Pbias$, foi obtido apenas um valor positivo de NSE , considerado insatisfatório ($NSE = 0,0099$), e o melhor valor obtido para o RSR foi 0,96. Além disso, o coeficiente de determinação apontou um ajuste pobre entre dados simulados e ajustados, pois o melhor valor obtido foi $R^2 = 0,047$. Considerando a sensibilidade do NSE a *outliers* e valores extremos e ao viés de magnitude (MCCUEN; KNIGHT; CUTTER, 2006), os dados de entrada foram reavaliados de forma a refinar o modelo (HARMEL et al., 2014).

O *dotplot* de Cleveland (Figura 31) representa as cargas anuais calculadas a partir dos valores de sólidos totais e turbidez mensurados na sub-bacia do Alto Corumbataí. É possível constatar que, em alguns anos (e.g., 2005, 2007, 2013 e 2016), o valor da carga anual observada pode ser considerado extremo⁷ dentro do conjunto dos dados, o que pode influenciar drasticamente as análises (ZUUR; IENO; SMITH, 2007).

Figura 31 – *Dotplot* de Cleveland ilustrando a carga anual calculada a partir de dados mensurados de qualidade da água na sub-bacia do Alto Corumbataí



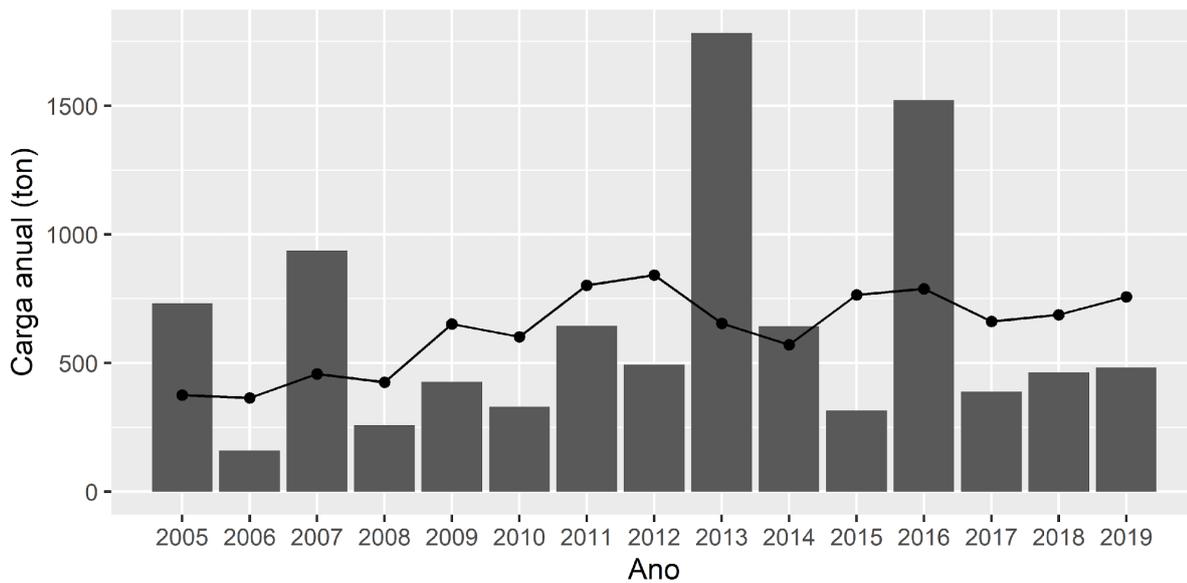
Fonte: elaborado pela autora.

Ao plotar o ajuste dos dados considerando o conjunto de valores k_b e $IC0$ que gerou o ajuste menos insatisfatório, pode-se observar que as cargas anuais simuladas foram bem

⁷ O termo “valor extremo” aqui utilizado equivale ao conceito estatístico de *outlier*, i.e., uma observação que difere substancialmente do restante do conjunto de dados (ZUUR; IENO; SMITH, 2007).

menores do que as cargas anuais observadas nestes mesmos anos (Figura 32). Consequentemente, o *RMSE* associado a esses anos é alto, dificultando a obtenção de um ajuste adequado segundo os indicadores *NSE*, *Pbias* e *RSR*. Portanto, mesmo adotando uma ampla variação e combinação de valores dos parâmetros de calibração, foi impossível obter um ajuste satisfatório com todos os anos da série histórica.

Figura 32 – Valores observados (barras) e simulados (pontos) da carga anual de sedimentos na sub-bacia do Alto Corumbataí considerando $k_b = 1,3$ e $IC0 = 2$



Fonte: elaborado pela autora.

Devido à sensibilidade dos indicadores, particularmente o *NSE*, a valores extremos, optou-se por excluir da calibração os anos cujos valores observados foram considerados extremos (i.e., 2005, 2007, 2013 e 2016). Esse procedimento é justificado quando tais valores resultam de falhas de mensuração de dados (ZUUR; IENO; ELPHICK, 2010), como a amostra pouco representativa das condições anuais médias que foi usada neste estudo. Após obter um novo ajuste, o ano 2014 também foi excluído, pois apresentou alto valor de *RMSE*, impedindo um ajuste aceitável. Esse procedimento foi adotado visando obter um novo conjunto de dados para a calibração que fosse mais representativo das condições médias da bacia e, consequentemente, possibilitasse um ajuste ao menos satisfatório do modelo.

Após a exclusão dos pares de dados observados e simulados para cinco anos, foi possível obter ajustes satisfatórios segundo todos os indicadores de desempenho (Tabela 9). O melhor ajuste foi obtido adotando $k_b = 0,8$ e $IC0 = 0,25$ (Figura 33), valores estes utilizados no cálculo da produção de sedimentos durante o experimento de simulação. Tendo em vista os critérios de classificação disponíveis na Tabela 8, o modelo teve desempenho bom segundo os índices

P_{bias} , RSR e R^2 , e satisfatório segundo o NSE . O viés do modelo foi de -21,71 ton. Portanto, em média, o modelo ajustado tende a subestimar os valores observados.

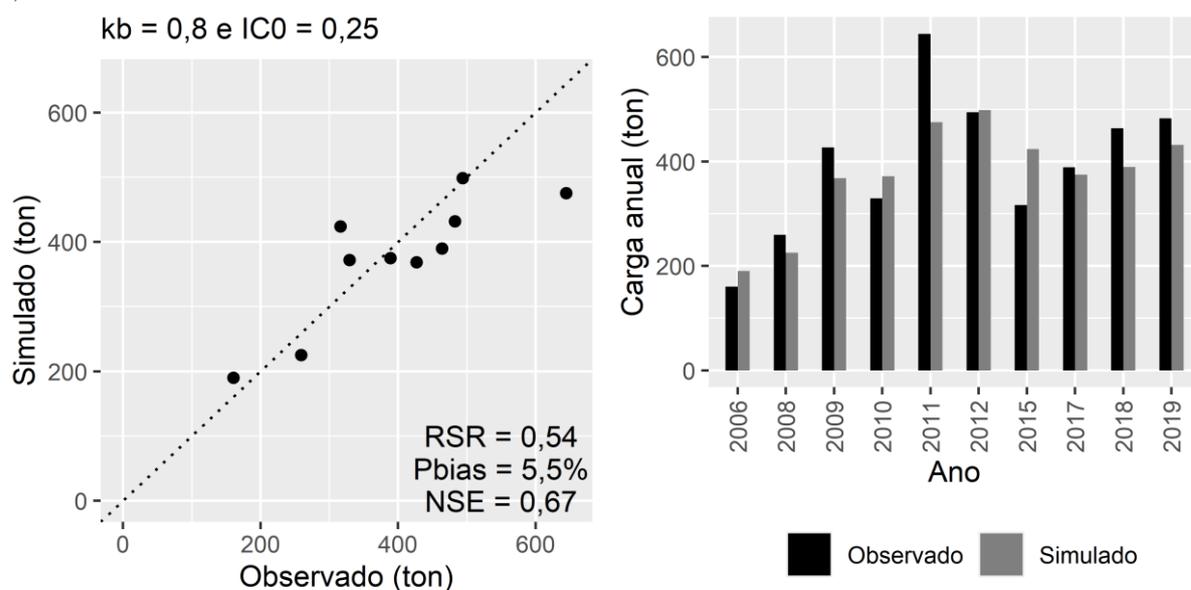
Tabela 9 – Cinco melhores combinações de k_b e $IC0$ que levaram a um ajuste ao menos satisfatório entre as cargas anuais simuladas pelo InVEST e as observadas

Parâmetros de calibração			Indicadores de desempenho		
k_b	$IC0$	NSE	P_{bias} (%)	RSR	R^2
0,8	0,25	0,67	5,5	0,54	0,71
0,9	0,75	0,63	7,6	0,58	0,71
1	1,25	0,61	8,3	0,59	0,70
1,1	1,75	0,60	8,1	0,60	0,70
1,2	2	0,52	-13,7	0,66	0,69

Fonte: elaborado pela autora.

Notas: n = 10.

Figura 33 – Ajuste entre dados simulados e observados de produção de sedimentos considerando $k_b = 0,8$ e $IC0 = 0,25$



Fonte: elaborado pela autora.

Notas: n = 10

Considerando o período utilizado na calibração⁸, a perda de solo e a produção de sedimentos anuais simuladas na área de estudo foram estimadas em 99.690,27 tons e 374,97 tons em média, respectivamente. Ao executar o modelo calibrado utilizando os arquivos de uso do solo mais recente (i.e., 2019) e erosividade média para um período de 15 anos, verificou-se que a perda de solo e a produção de sedimentos na bacia foi de 107.288,67 tons/ano e 401,17 tons/ano, respectivamente. Consequentemente, a perda potencial de solo na sub-bacia é de 18,7

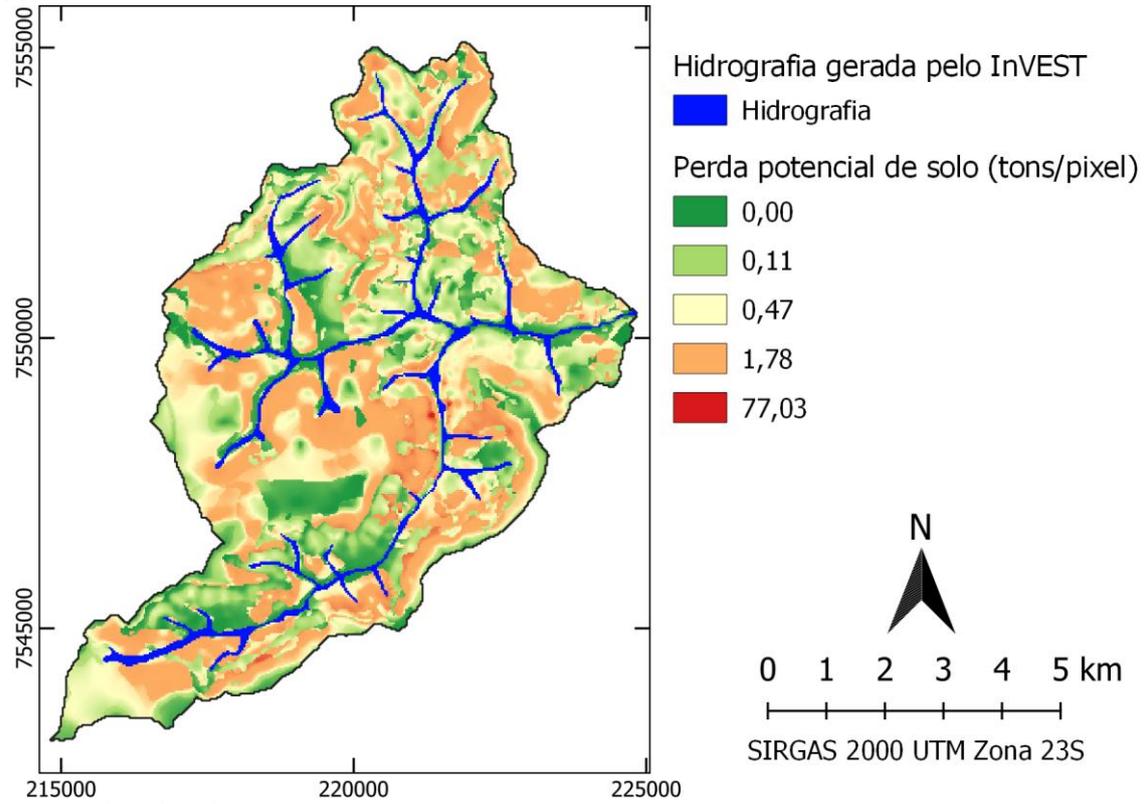
⁸ Período de 10 anos compreendendo 2006, 2008 a 2012, 2015, 2017 a 2019.

tons.ha⁻¹.ano⁻¹, e a produção de sedimentos é cerca de 0,07 tons.ha⁻¹.ano⁻¹, ou 7 tons.km²⁻¹.ano⁻¹. Nesse sentido, estima-se que em média apenas 0,37% do solo erodido atinja os corpos d'água na sub-bacia. A perda de solo simulada está acima da considerada tolerável⁹ para as subordens latossolos vermelhos, latossolos vermelho-amarelos e argissolos vermelho-amarelos, que foi estimada entre 7 e 11,5 tons.ha⁻¹.ano⁻¹ por Mannigel et al. (2002) em São Paulo.

A perda de solo por pixel variou de 0 a 77 tons, sendo a média 1,68 tons e desvio padrão 3,57 tons (Figura 34). A maioria da área da bacia (75%) contribuiu com valores baixos de perda de solo, de até 1,78 tons/pixel, e 90% das células tiveram perda de solo de até 4,16 tons. As poucas células com valores maiores foram classificadas como *outliers*. Por outro lado, a entrega de sedimentos, ou seja, a quantidade de solo erodido que atingiu a água, variou de 0 a 1,56 tons/pixels, sendo a média 0,006 tons/pixel e o desvio padrão 0,03 tons/pixel (Figura 35). Esses resultados ocorreram devido aos baixos valores para a taxa de entrega de sedimentos na área de estudo, que variou por pixel de 0 a 0,067, sendo a média 0,0019 e o desvio padrão 0,0032 (Figura 36). Essas proporções baixas para a entrega de sedimentos são um reflexo dos valores dos parâmetros k_b e $IC0$ obtidos com a calibração, pois quanto menor o valor de k_b , menor a proporção da perda de solo que atingirá a água.

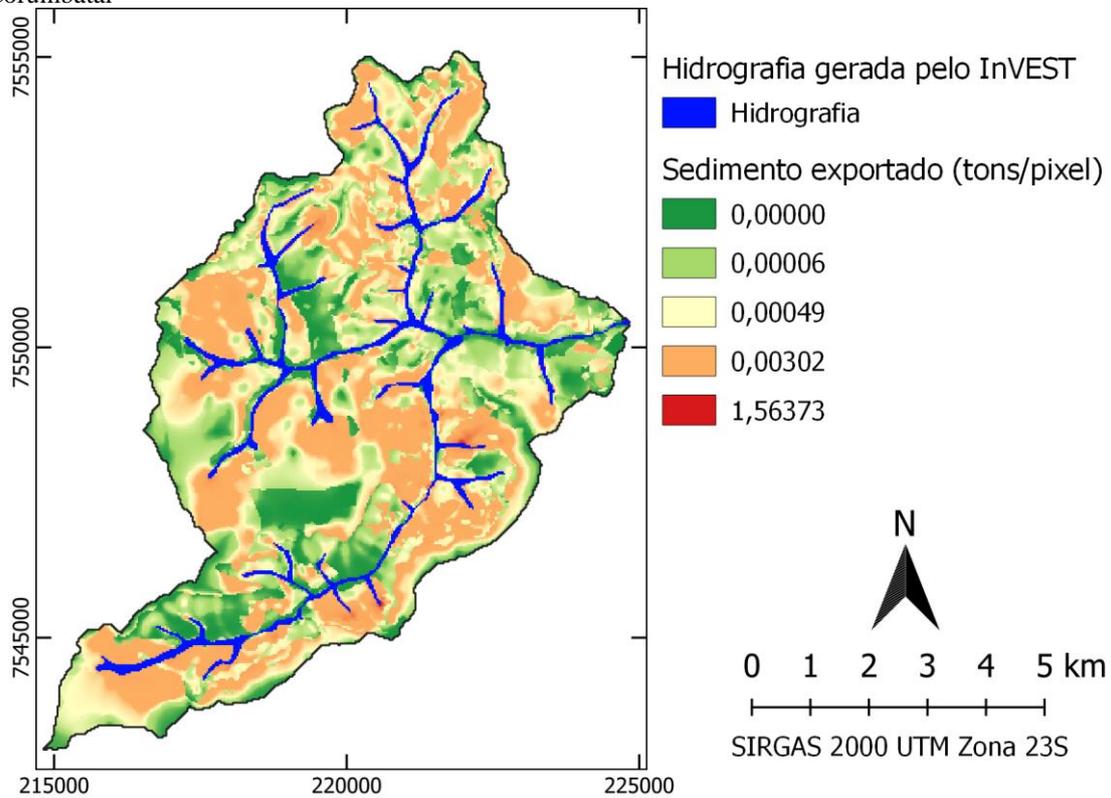
⁹ A perda de solo tolerável é aquela taxa máxima que pode ocorrer sem que afete a produtividade das culturas em longo prazo (WISCHMEIER; SMITH, 1965).

Figura 34 – Perda potencial de solo anual (2019) por pixel calculada por meio da RUSLE para a sub-bacia do Alto Corumbataí



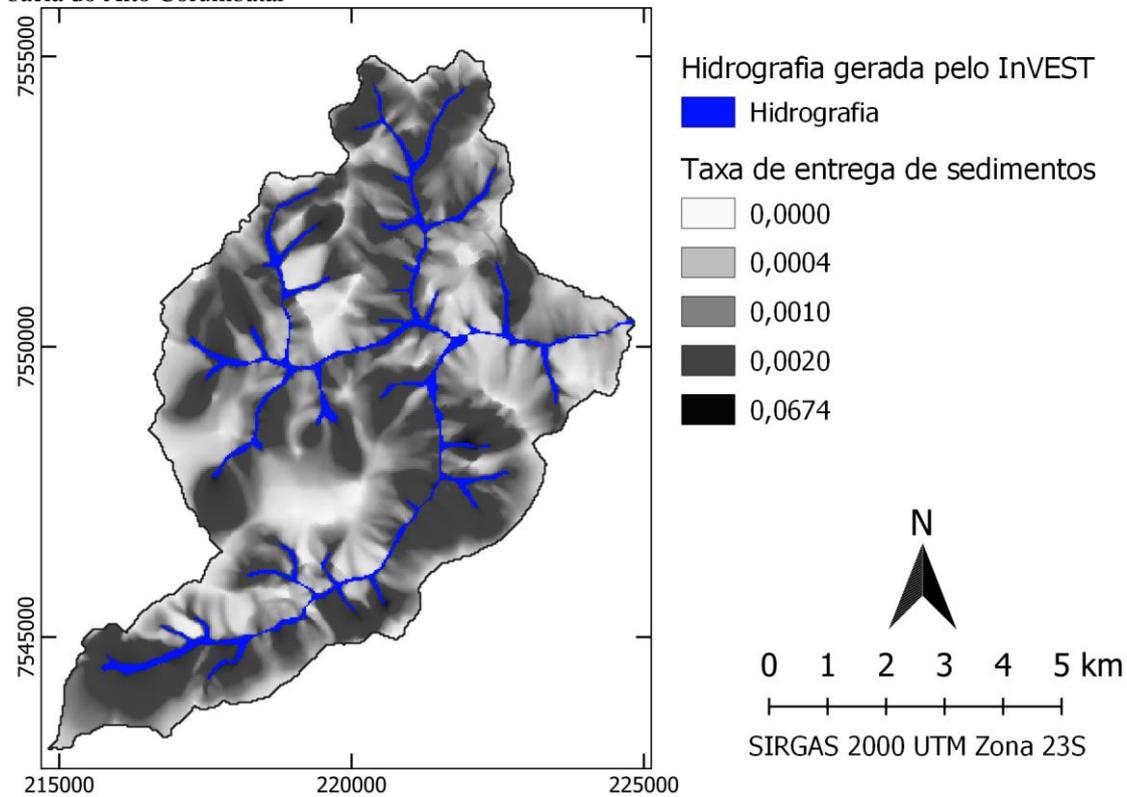
Fonte: elaborado pela autora.

Figura 35 – Produção de sedimentos anual (2019) por pixel calculada pelo modelo SDR para a sub-bacia do Alto Corumbataí



Fonte: elaborado pela autora.

Figura 36 – Proporção da perda de solo por pixel que atinge a água (2019) calculada pelo modelo SDR para a sub-bacia do Alto Corumbataí

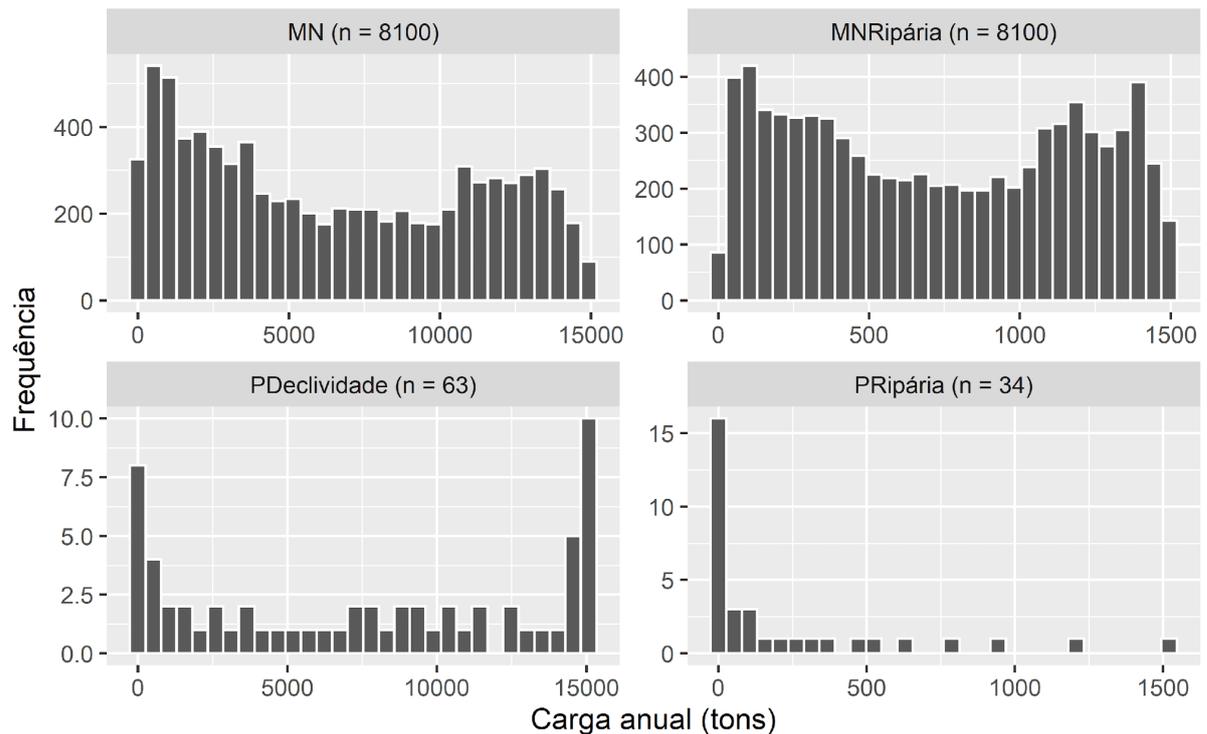


Fonte: elaborado pela autora.

3.2 Comparação entre paisagens de modelos neutros e paisagens planejadas

Os histogramas abaixo representam a distribuição dos quatro grupos de paisagens analisados – modelos neutros (MN), paisagens planejadas com faixas ripárias florestais de largura progressiva (PRipária), paisagens planejadas com cobertura gradual de floresta nas áreas de maior declividade (PDeclividade), e paisagens planejadas com uma combinação de modelos neutros e faixa ripária florestal fixa de 30 m (MNRipária). É possível verificar que nenhuma delas segue uma distribuição normal (Figura 37). As paisagens geradas pelo modelo neutro e as com planejamento voltado para a declividade exibem distribuições semelhantes à multimodal. Nesse sentido, observa-se uma maior frequência de valores baixos e altos de carga de sedimentos, e uma menor frequência de valores intermediários. Por outro lado, o grupo de paisagens com planejamento focado somente na faixa ripária apresenta uma distribuição assimétrica, com maior frequência de cargas baixas. Ainda, a distribuição de MNRipária parece ser mais simétrica do que a de MN, que apresenta um pequeno deslocamento para a esquerda, em direção aos valores mais baixos.

Figura 37 – Histogramas da produção de sedimentos para paisagens de modelos neutros e planejadas

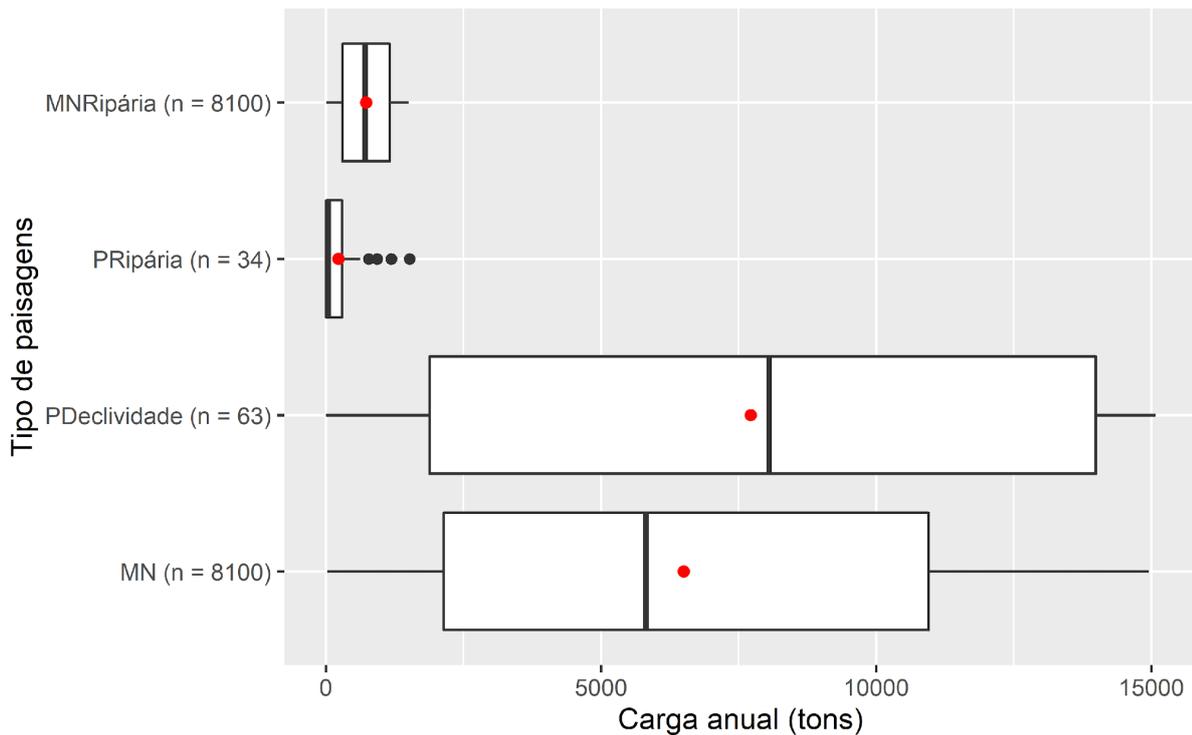


Fonte: elaborado pela autora.

Notas: os eixos X e Y não possuem a mesma escala para todos os gráficos.

Ao observar a variação dos dados (Figura 38, Tabela 10), verifica-se que os grupos MN e PDeclividade exibiram a maior amplitude para a produção de sedimentos, que atinge até 15.000 toneladas por ano. Por outro lado, os grupos em que foi implementada uma faixa ripária florestal de ao menos 30 m ao longo da drenagem exibiram uma amplitude bem menor, em que a produção de sedimentos máxima foi cerca de 1.500 toneladas por ano. Conseqüentemente, a carga máxima para os grupos PRipária e MNRipária é cerca de 10 vezes menor que as cargas máximas para MN e PDeclividade. Ainda, 75% das paisagens dos grupos MN e PDeclividade tiveram produção de sedimentos maior que o máximo obtido nos grupos com proteção ripária. As medidas de posição (i.e., mediana e média) também acompanham esse padrão, havendo menores cargas para as paisagens dos grupos PRipária e MNRipária, e maiores para os grupos MN e PDeclividade. Entretanto, o coeficiente de variação indica que em todos os cenários houve grande variação em relação à média.

Figura 38 – *Boxplot* e médias (ponto vermelho) da produção de sedimentos para paisagens de modelos neutros e planejadas



Fonte: elaborado pela autora.

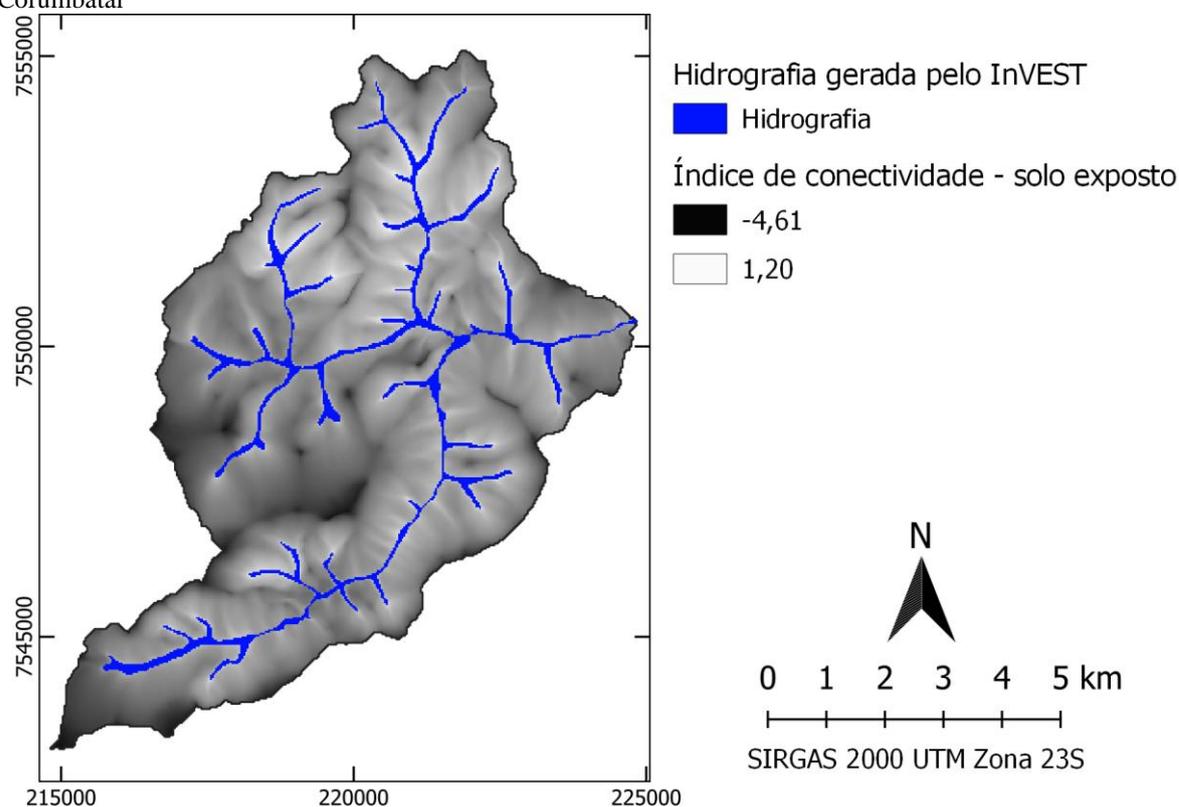
Ao considerar os grupos em que há proteção da zona ripária, i.e., PRipária e MNRipária, observa-se que a média e mediana são menores para o primeiro. Em média, as paisagens do tipo MN geraram nove vezes mais sedimentos que as paisagens do tipo MNRipária, uma diferença significativa (Tabela 10). Tomando valores médios e máximos, constata-se que a introdução da faixa ripária pode reduzir em cerca de 90% o aporte de sedimentos. Portanto, considerando o modelo adotado e a área de estudo, o planejamento focado na concentração da floresta nas zonas próximas aos riachos se mostrou mais efetivo em evitar o aporte de sedimentos do que a estratégia de distribuição aleatória da vegetação na bacia (MN). Esse resultado aponta que as áreas mais críticas para a produção de sedimentos se localizam nos pontos mais próximos à drenagem. Conforme a Figura 39, que ilustra o índice de conectividade para o solo exposto na bacia, as áreas de maior IC se concentram no entorno da drenagem. Consequentemente, essas áreas estão naturalmente associadas a uma maior probabilidade de o solo erodido atingir o riacho. A estratégia PRipária se destacou como a mais efetiva devido à proteção das zonas ripárias com cobertura florestal, o que causa uma diminuição não só da perda potencial do solo, mas também da conectividade hidrológica e, consequentemente, da taxa de entrega de sedimentos.

Tabela 10 – Estatísticas descritivas e intervalos de confiança para a média da produção de sedimentos (tons/ano) para os grupos de paisagens de modelos neutros e planejadas

Medida	Tipo de paisagens			
	MN	PDeclividade	PRipária	MNRipária
Tamanho amostral	8.100	63	34	8.100
Média	6.503,69	7.721,46	231,13	729,38
Intervalo de confiança (95%)	6.402 – 6.605			719 - 739
Mediana	5.815,32	8.052,49	36,87	707,32
Desvio padrão	4.648,35	5.658,97	375,14	459,33
Coefficiente de variação (%)	71,47	73,29	162,30	62,97
Mínimo	24,82	1,21	1,03	6,93
Máximo	14.950,56	15.075,68	1.521,80	1.502,41

Fonte: elaborado pela autora.

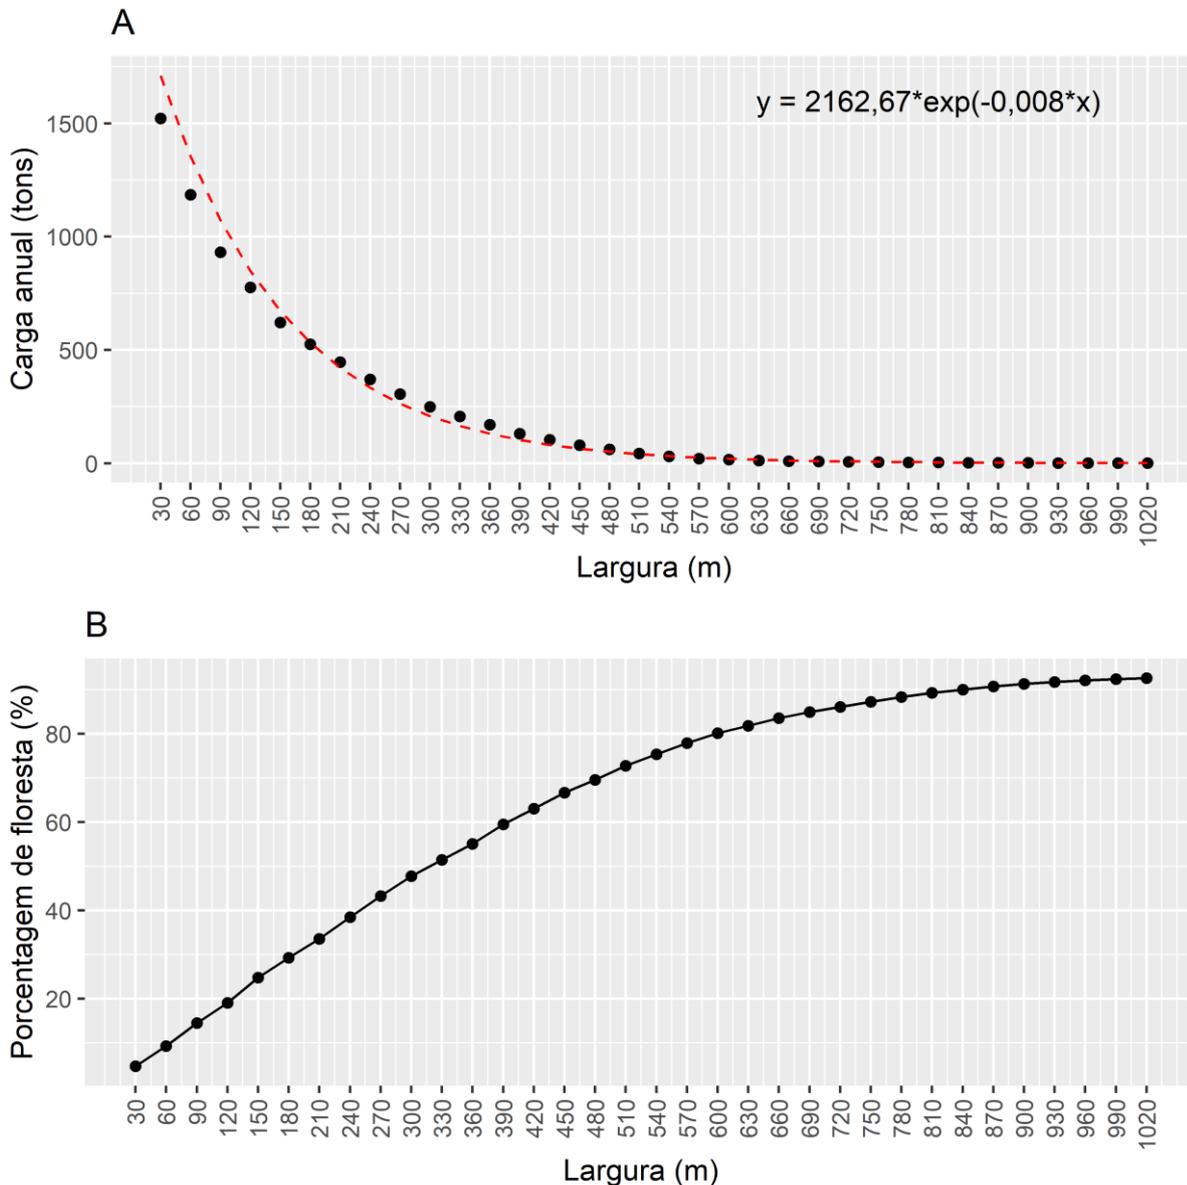
Figura 39 – Índice de conectividade para o solo exposto calculado pelo modelo SDR para a sub-bacia do Alto Corumbataí



Fonte: elaborado pela autora.

A maior produção de sedimentos para o grupo PRipária ocorreu para a paisagem com a faixa mais estreita (30 m), o que corresponde a 4,6% da bacia protegida por florestas. Esse valor decaiu à medida que a faixa ripária florestal alarga, se estabilizando quando esta atinge cerca de 600 m de largura, o que equivale a 80% da bacia coberta por florestas (Figura 40). A relação entre a largura da faixa ripária e a carga anual em toneladas pode ser descrita por uma função exponencial.

Figura 40 – Carga anual de sedimentos por largura de faixa ripária florestal (A) e porcentagem da bacia coberta por florestas por largura de faixa ripária florestal (B) para as paisagens do grupo PRipária



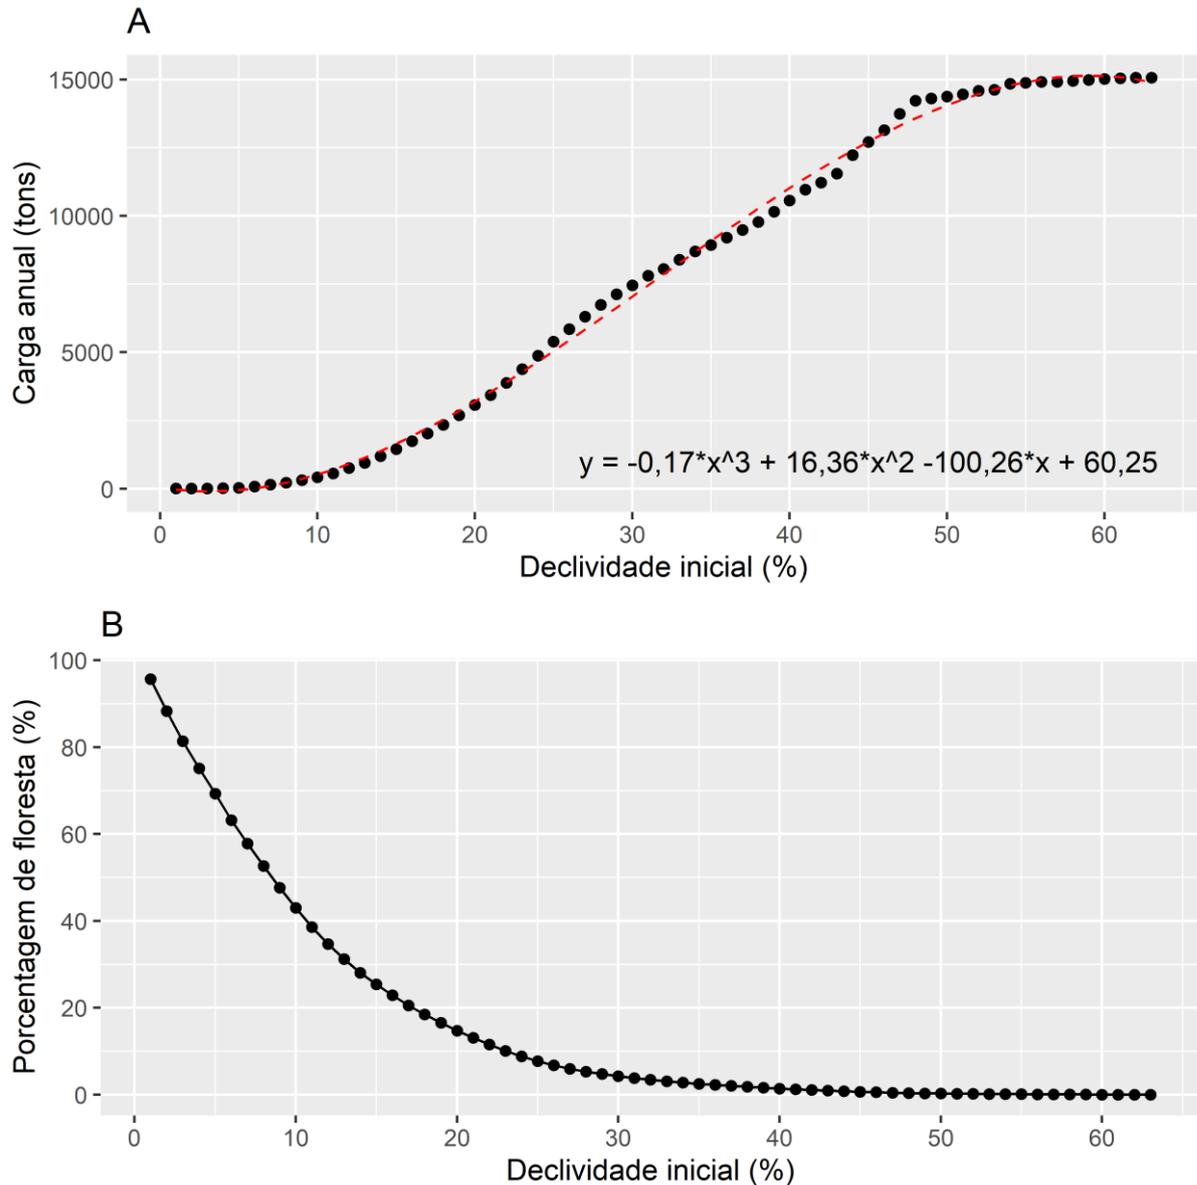
Fonte: elaborado pela autora.

Notas: o cálculo da porcentagem de floresta em B considerou a área da bacia sem o riacho de forma a produzir uma medida mais precisa.

As paisagens com planejamento focado na declividade apresentaram um comportamento que pode ser descrito por uma função polinomial de terceiro grau. À medida que as áreas de maior declividade são protegidas, menor é a carga de sedimentos, embora não pareça haver um limiar crítico (Figura 41). Ao se proteger o relevo forte-ondulado e montanhoso (i.e., com declividade > 20%) da bacia hidrográfica, o que resulta em 15% de cobertura florestal, cerca de 3.000 tons/ano são exportadas. Esse valor é 20% do máximo

esperado nesse cenário, porém superior ao obtido pela estratégia PRipária, no qual implantar uma faixa contínua de apenas 30 m levou à geração de 1.500 tons/ano.

Figura 41 – Carga anual de sedimentos por declividade inicial (A) e porcentagem da bacia coberta por florestas por declividade inicial (B) para as paisagens do grupo PDeclividade



Fonte: elaborado pela autora.

Os gráficos a seguir (Figura 42) exibem a produção de sedimentos em função da porcentagem de floresta na bacia hidrográfica resultante em cada um dos cenários analisados. Como já mencionado, as paisagens PRipária e MNRipária se mostraram mais efetivas do que as paisagens PDeclividade e MN. No entanto, dependendo do objetivo, é possível planejar a paisagem combinando essas estratégias de acordo com metas a serem atingidas ou recursos disponíveis. Por exemplo, o reflorestamento de 20% da bacia hidrográfica com florestas pode

gerar diferentes resultados a depender do planejamento adotado. Em termos de valores relativos, executar essa estratégia no cenário PDeclividade resulta em 1/6 da produção de sedimentos máxima observada. No caso de PRipária, a carga obtida é cerca de metade da máxima observada. Há grande variação nos resultados obtidos para MN e MNRipária, porém, é possível alcançar cargas até 1/3 e 2/3 da carga máxima, respectivamente.

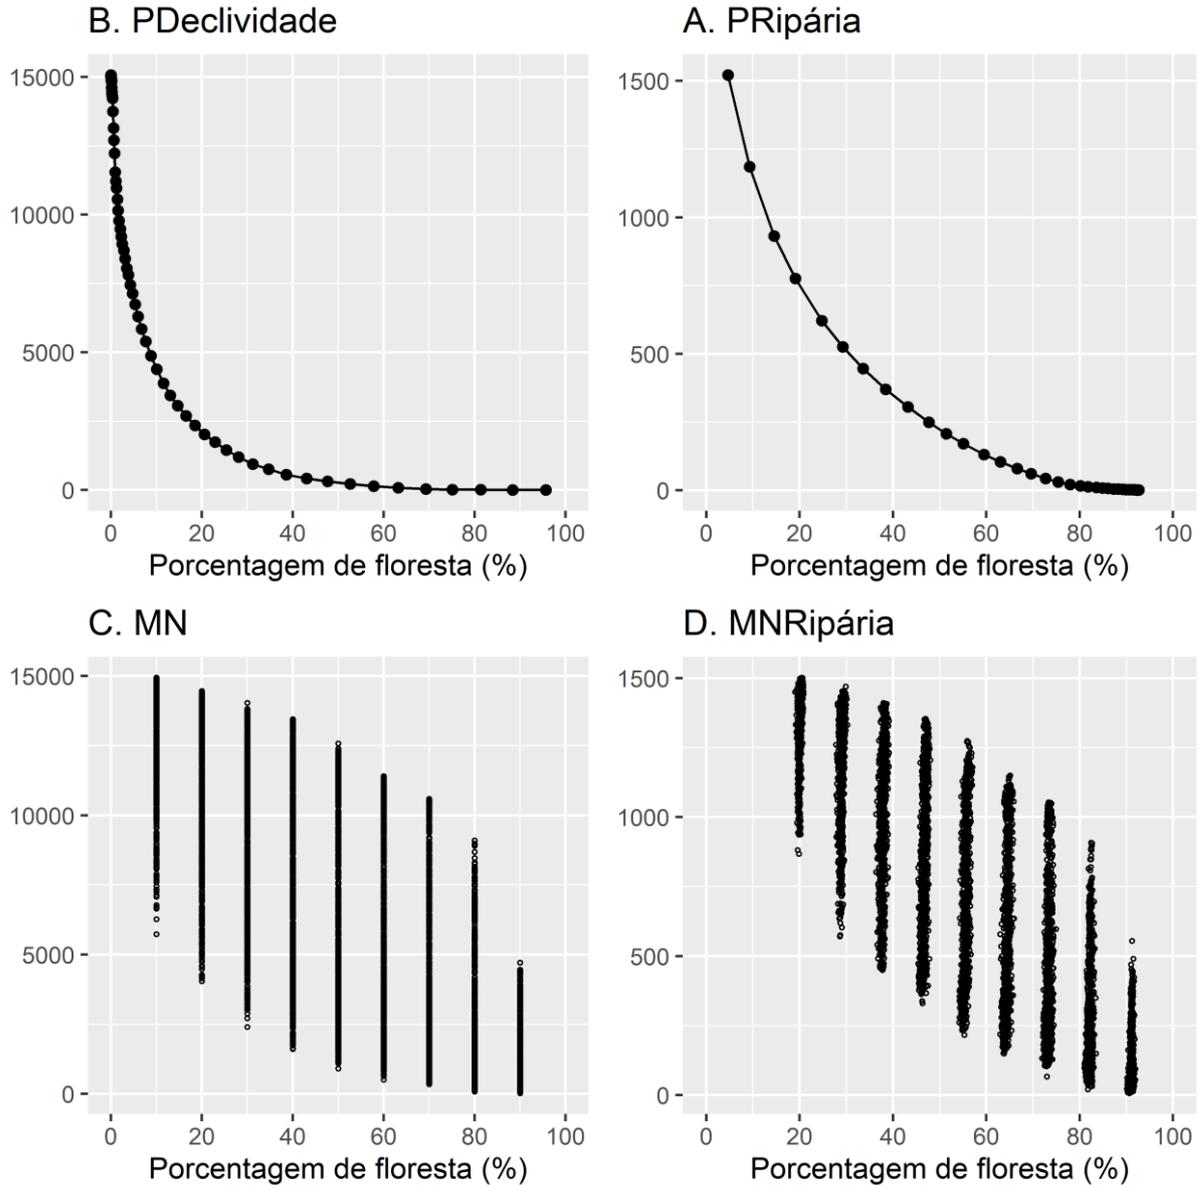
Considerando as mensurações absolutas, as diferenças entre os cenários se mostram mais marcantes (Tabela 11). Distribuir 20% de florestas somente nos locais de maior declividade exige a proteção das áreas com declividade maiores que 17%, o que resulta em uma carga de 2.023 tons/ano. Aplicar a mesma estratégia somente por meio do reflorestamento das zonas ripárias resulta em 776 tons/ano, mas exige uma faixa de pelo menos 120 m em todos os cursos d'água. No caso dos grupos de modelos neutros, a carga resultante varia, mas todas as paisagens MN e MNRipária exibiram cargas acima de 4.048 e 938 tons/ano, respectivamente. Portanto, implantar uma faixa ripária de vegetação de 30 m e distribuir o restante na bacia hidrográfica de forma não planejada permite obter resultados próximos ao do cenário com a floresta totalmente concentrada em 120 m ao redor dos cursos d'água.

Tabela 11 – Produção de sedimentos para os grupos de paisagens de modelos neutros e planejadas considerando uma quantidade fixa (20%) de floresta na bacia hidrográfica

Tipo de paisagens	Distribuição da floresta (20% da bacia)	Carga anual (tons/ano)
PRipária	Faixa de 120 m	776
PDeclividade	Declividades > 17%	2.023
MN	Distribuição aleatória	4.048 a 14.461
MNRipária	Faixa de 30 m + distribuição aleatória	938 a 1.502

Fonte: elaborado pela autora.

Figura 42 – Produção de sedimentos (tons/ano) por porcentagem de floresta na bacia hidrográfica para os grupos de paisagens de modelos neutros e planejadas



Fonte: elaborado pela autora.

Notas:

O eixo Y não possui a mesma escala para todos os gráficos.

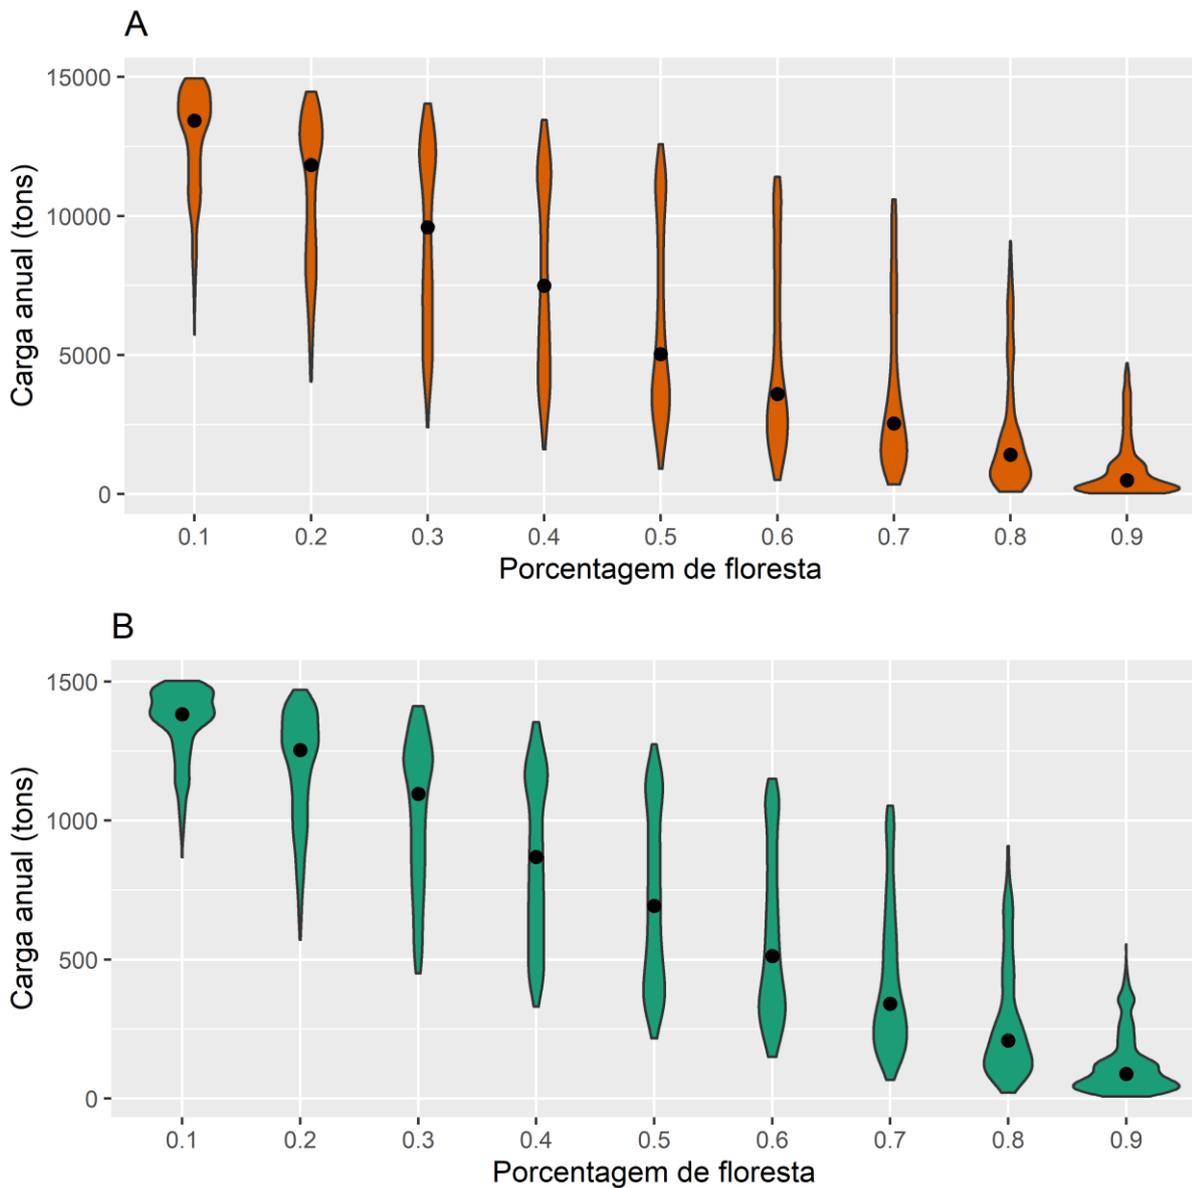
O título do eixo Y, que representa carga anual (tons), foi omitido por razões de apresentação gráfica.

3.3 Diferença na produção de sedimentos de acordo com a proporção de floresta e autocorrelação espacial

Apesar de haver uma grande variação na produção de sedimentos dentro das classes de porcentagem de floresta, porcentagens baixas possuem frequência maior de cargas altas, enquanto porcentagens altas apresentam frequência maior de cargas baixas (Figura 43). Nas porcentagens intermediárias (30 a 60%), a carga anual exibe uma distribuição bimodal, ou seja,

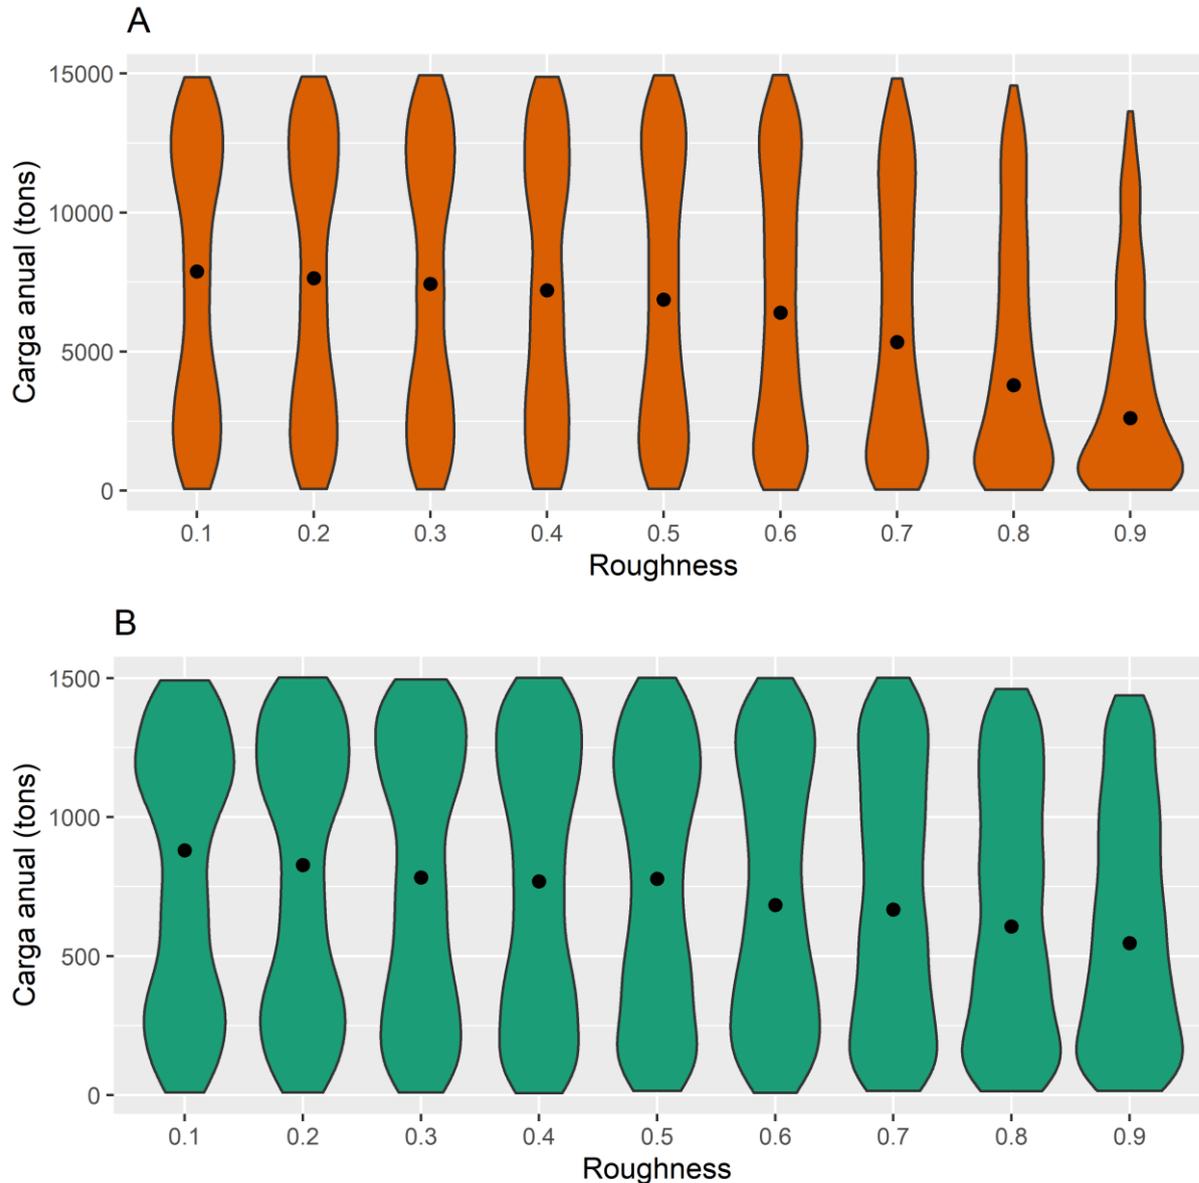
há uma maior frequência de valores baixos e altos, enquanto os valores intermediários aparecem em menor proporção. Para a rugosidade as distribuições são bimodais e semelhantes entre si nos valores de 0,1 a 0,7 para ambos os grupos de paisagens de modelos neutros (Figura 44).

Figura 43 – Gráficos de violino e medianas (pontos pretos) das cargas anuais das paisagens (A) MN e (B) MNRipária por porcentagem de floresta



Fonte: elaborado pela autora.

Figura 44 – Gráficos de violino e medianas (pontos pretos) das cargas anuais das paisagens (A) MN e (B) MNRipária por valor de autocorrelação espacial (*roughness*)

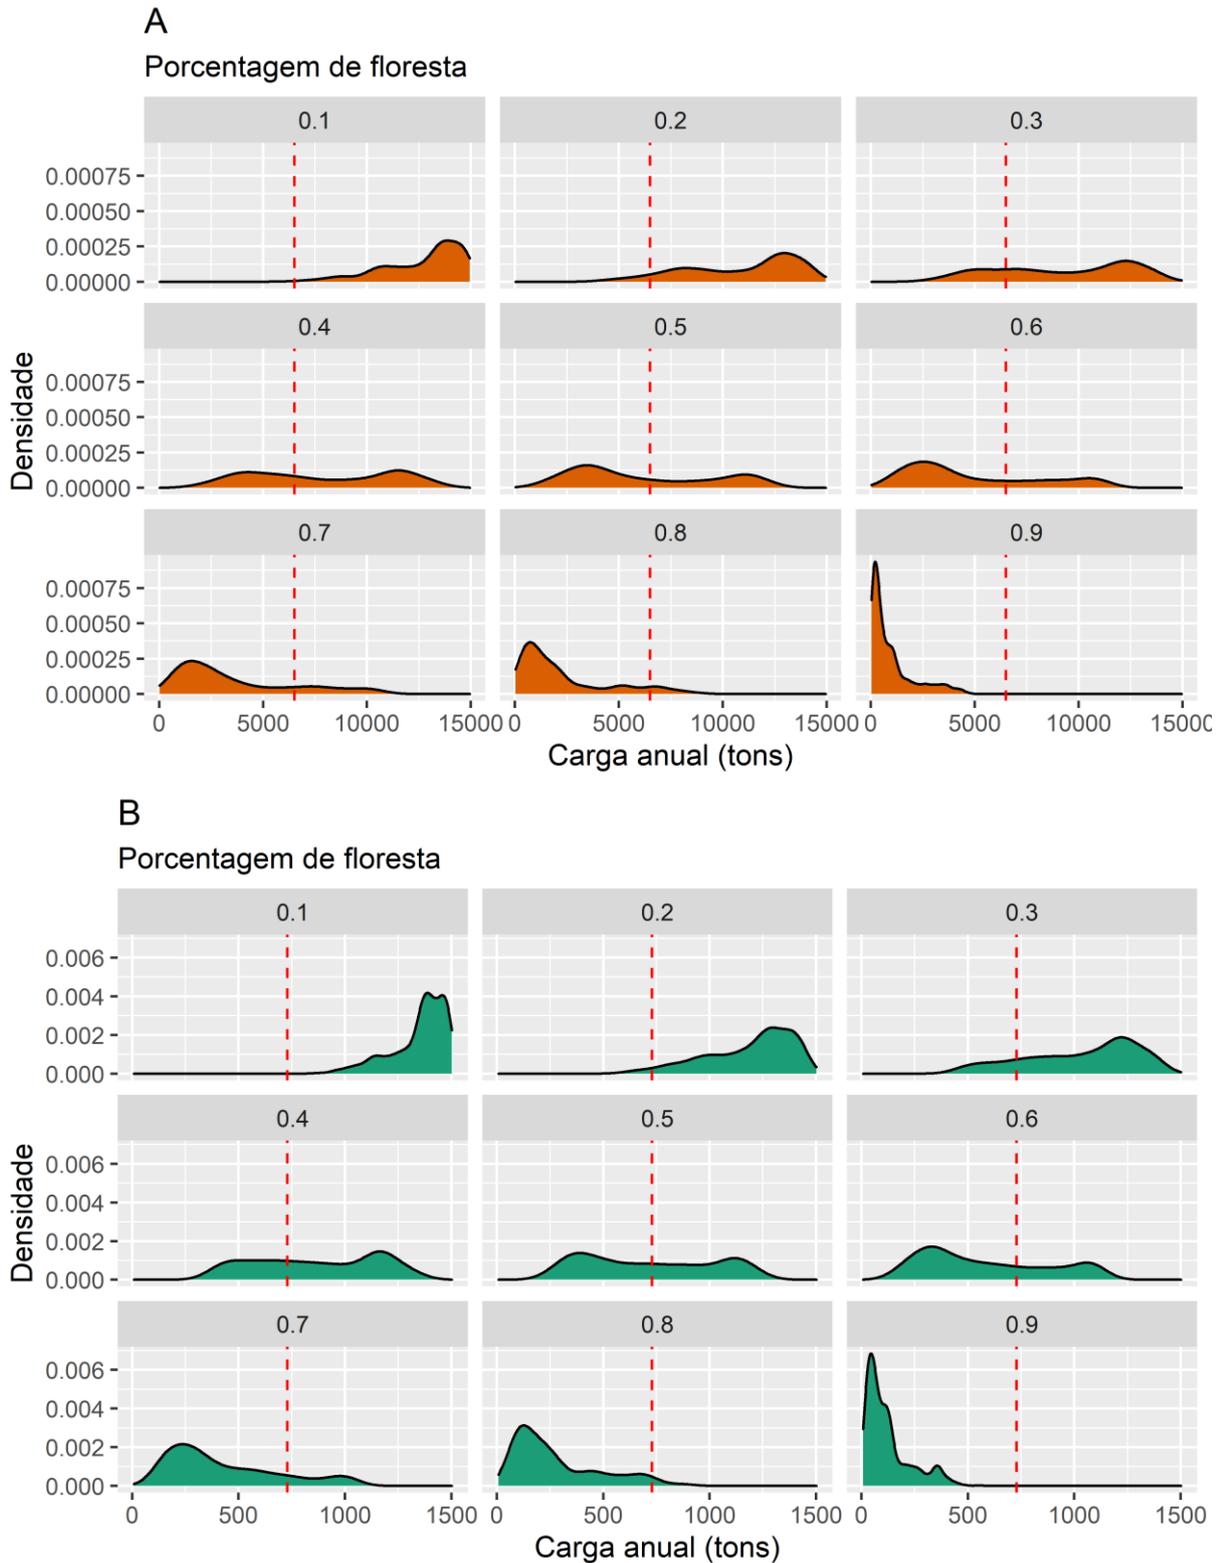


Fonte: elaborado pela autora.

Os gráficos de densidade para as diferentes classes de percentual indicam que a produção de sedimentos é acima da média em porcentagens de 10 a 30% de floresta e abaixo da média em porcentagens de 70 a 90% de floresta (Figura 45). As cargas anuais dos valores entre 40 e 60% se distribuem de forma mais uniforme e apresentam dois picos situados abaixo e acima da média, enquanto os valores no entorno da média são menos frequentes. A distribuição da carga anual por valores de rugosidade exibe um padrão diferente, se mantendo simétrica nos valores de 0,1 a 0,6, em que cargas altas e baixas são mais frequentes que cargas intermediárias (Figura 46). Quando a rugosidade assume valores maiores que 0,7, a curva se

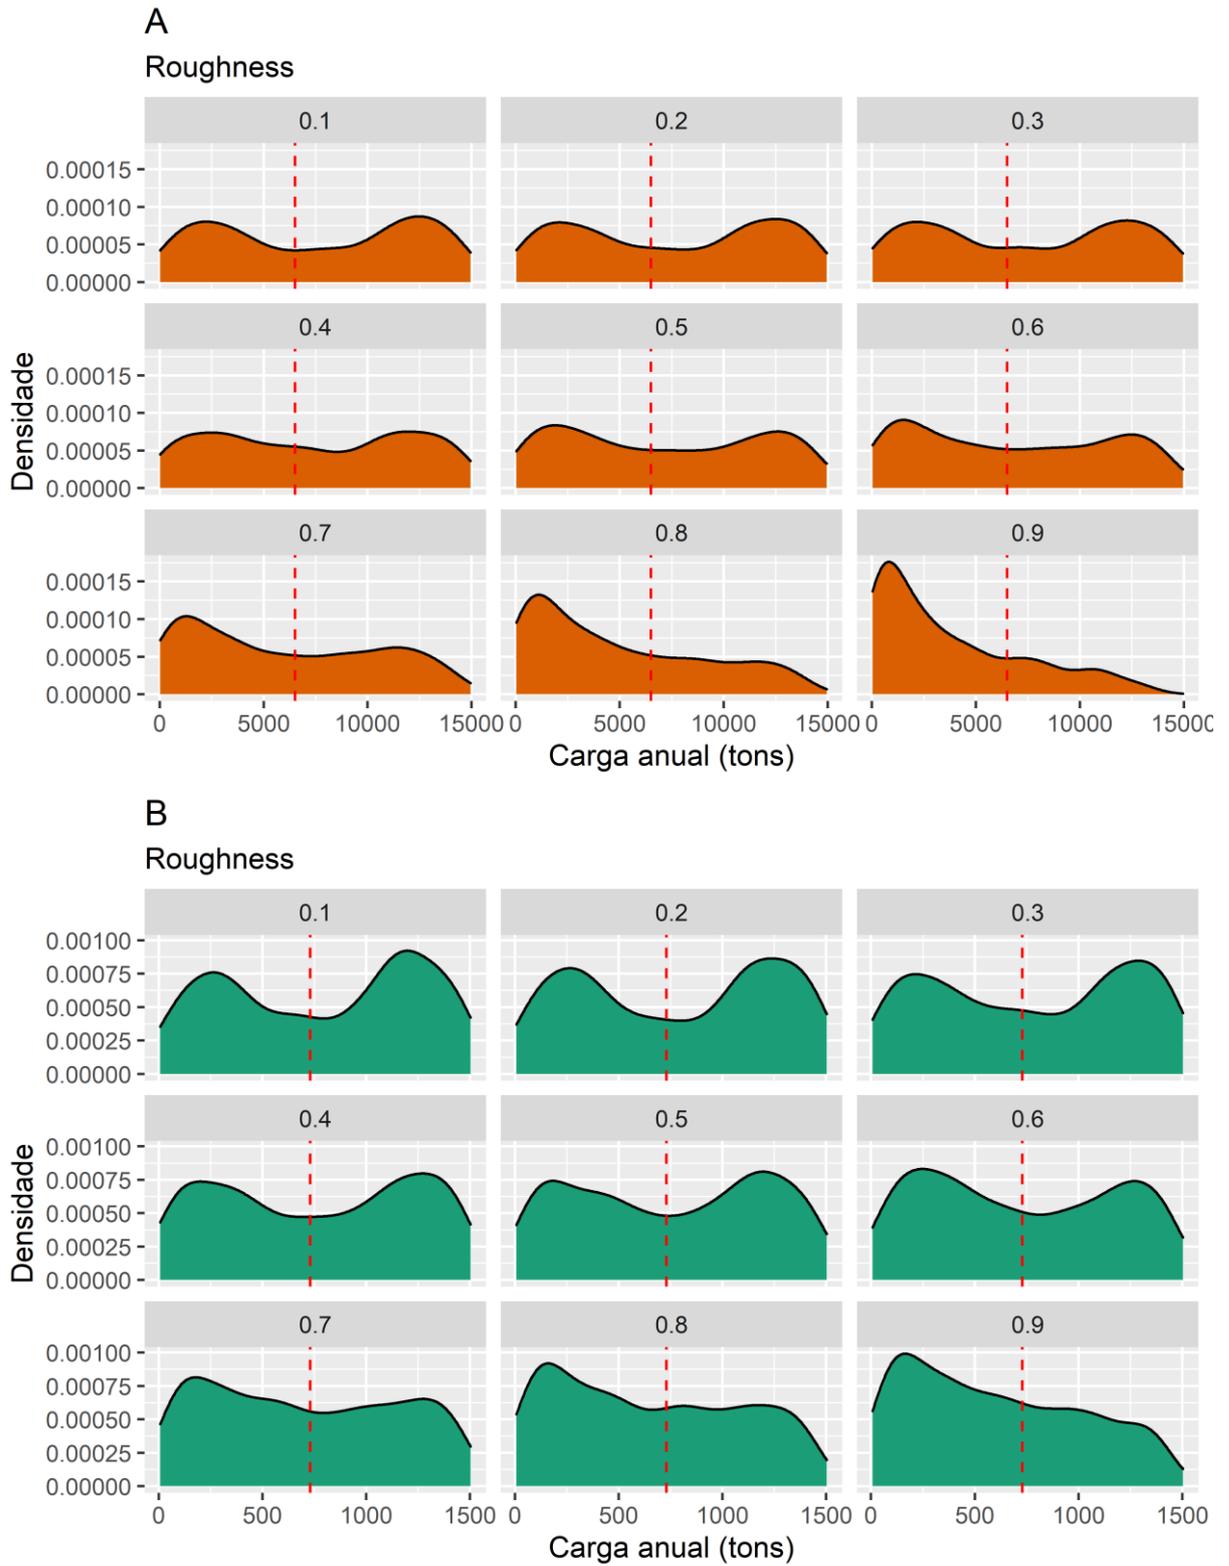
desloca para a esquerda e as cargas baixas de produção de sedimentos passam a ser mais frequentes.

Figura 45 – Gráfico de densidade das cargas anuais das paisagens (A) MN e (B) MNRipária por porcentagem de floresta em relação à média (linha vermelha)



Fonte: elaborado pela autora.

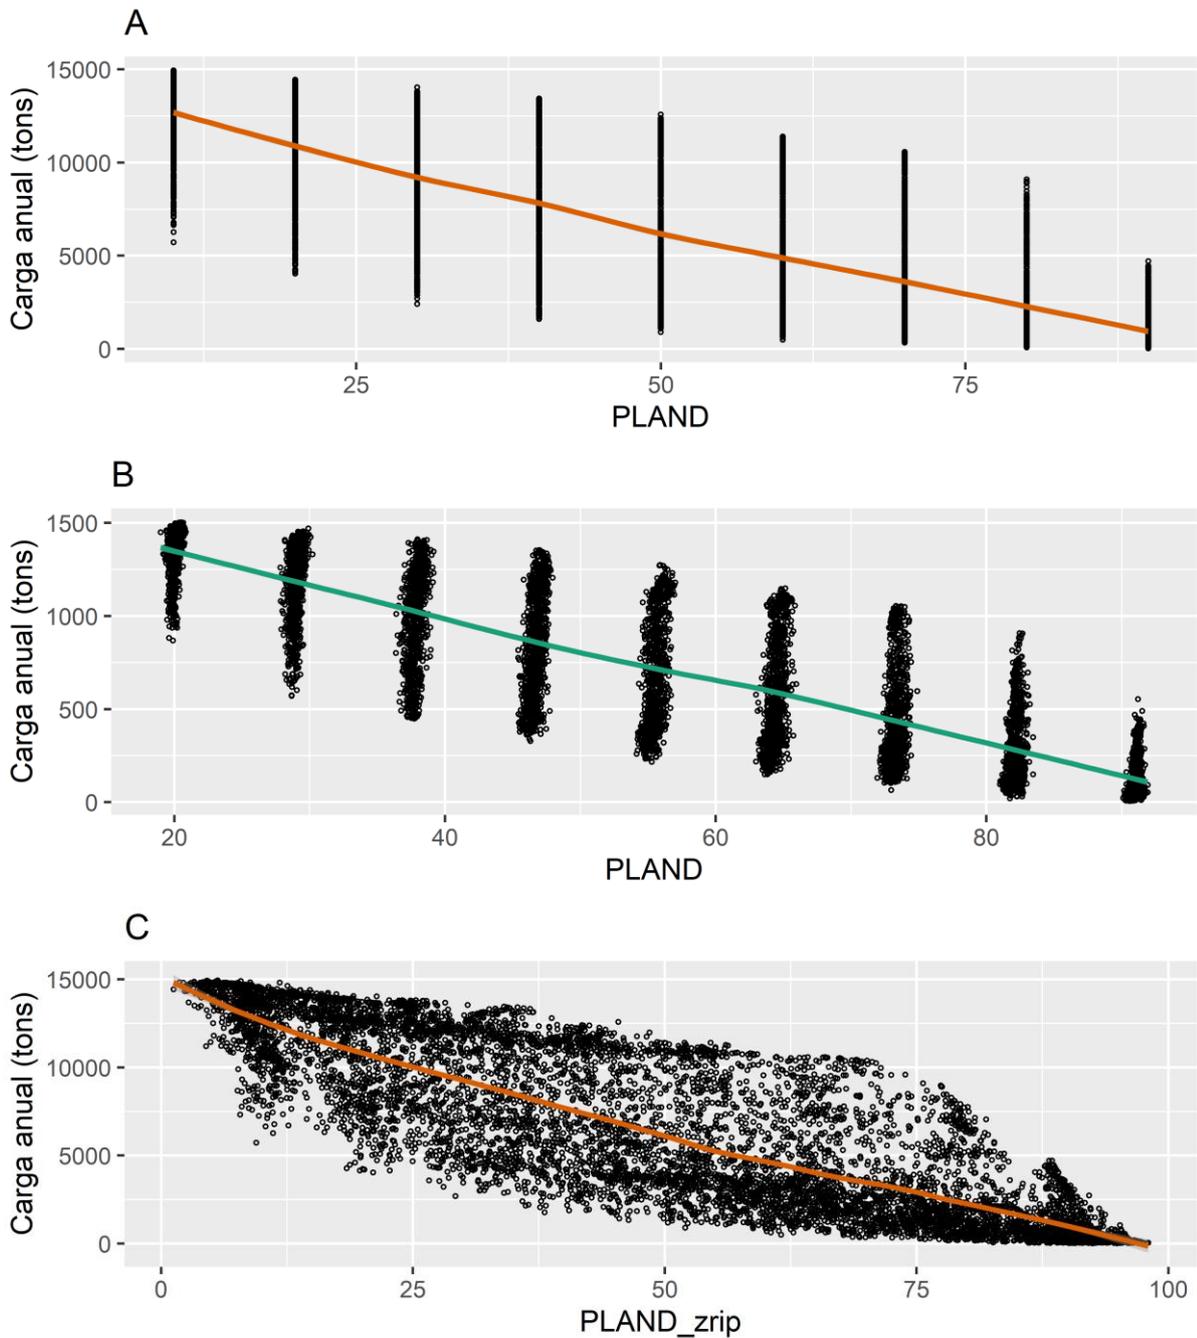
Figura 46 – Gráfico de densidade das cargas anuais das paisagens (A) MN e (B) MNRipária por valor de autocorrelação espacial (*roughness*) em relação à média (linha vermelha)



Fonte: elaborado pela autora.

Ao adicionar as curvas geradas pelo suavizador LOESS ao gráfico de dispersão da produção de sedimentos por porcentagem de floresta na bacia hidrográfica e na zona ripária (Figura 47), nenhum padrão não linear desponta, o que sugere que não há limiares associados à porcentagem de floresta nas paisagens com e sem faixa ripária florestal.

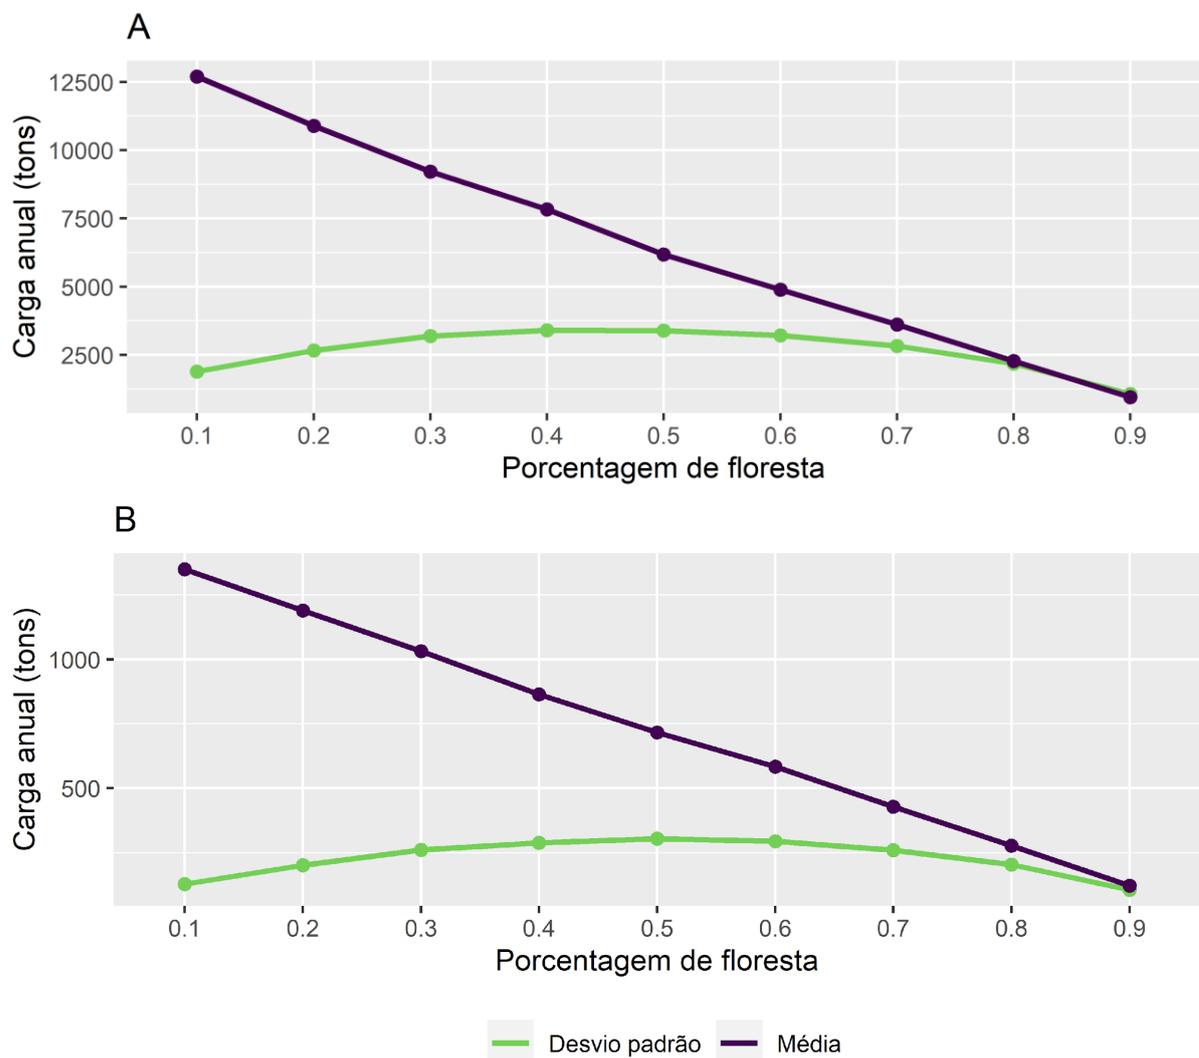
Figura 47 – Suavizador LOESS adicionado à relação entre proporção de floresta e carga anual nas paisagens (A) MN – escala de bacia hidrográfica, (B) MNRipária, e (C) MN – escala de zona ripária



Fonte: elaborado pela autora.

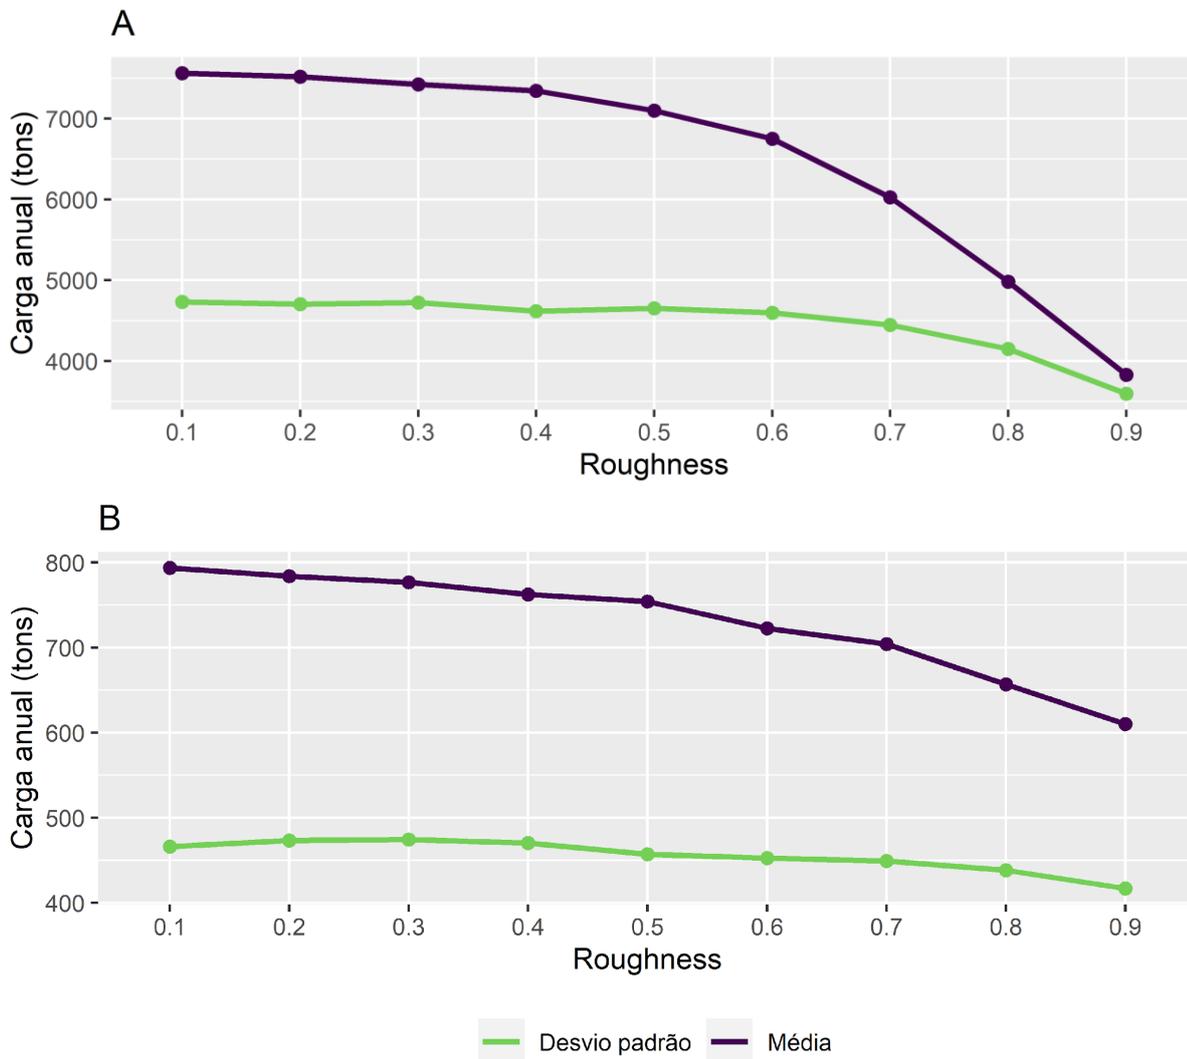
As médias e desvios padrão das cargas anuais demonstraram um comportamento semelhante para as paisagens sem e com faixa ripária florestal fixa (Figura 48). Enquanto a média de produção de sedimentos decai linearmente em função do aumento da proporção de floresta, a variação na produção de sedimentos segue uma função quadrática. Percentuais baixos e altos de floresta possuem os menores desvios padrão da média, enquanto os percentuais intermediários exibem as maiores variações, cujo pico ocorre em 40 e 50% de floresta para os grupos MN e MNRipária, respectivamente. A média da produção de sedimentos também decai à medida que a fragmentação da floresta aumenta, ainda que de forma mais suave do que a observada para os percentuais (Figura 49). Por outro lado, o desvio padrão permanece pouco alterado ao longo de diferentes níveis de rugosidade, apresentando uma queda mais evidente em valores acima de 0,7.

Figura 48 – Médias e desvios padrão das cargas anuais das paisagens (A) MN e (B) MNRipária por porcentagem de floresta



Fonte: elaborado pela autora.

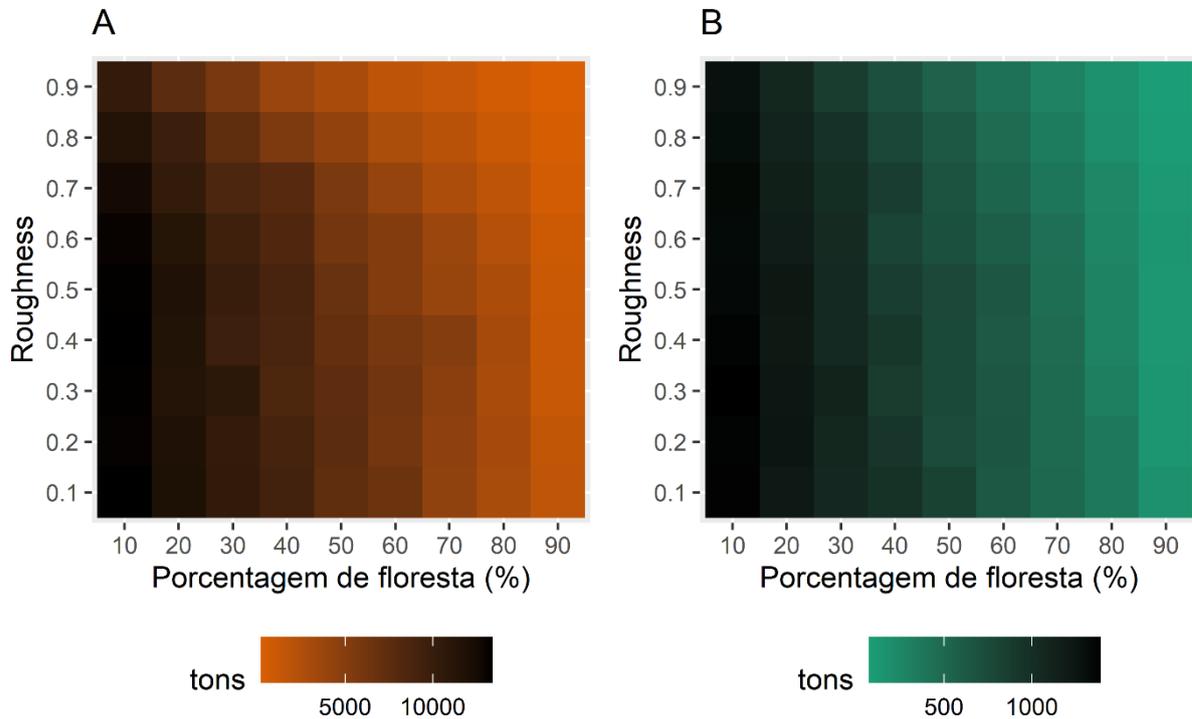
Figura 49 – Médias e desvios padrão das cargas anuais das paisagens (A) MN e (B) MNRipária por valor de autocorrelação espacial (*roughness*)



Fonte: elaborado pela autora.

Os mapas de calor (Figura 50) para as médias das cargas anuais indicam que as paisagens com menor porcentagem de floresta concentram as maiores cargas anuais médias, independentemente do grau de autocorrelação espacial. Em contrapartida, a carga média pode variar bastante em função da porcentagem de floresta, mesmo que se mantenha fixo um certo nível de autocorrelação espacial, como pode-se observar para as paisagens com rugosidade = 0,9 ou 0,1.

Figura 50 – Mapa de calor das médias das cargas anuais (tons) por porcentagem de floresta e rugosidade para as paisagens MN (A) e MNRipária (B)



Fonte: elaborado pela autora.

A seguir são apresentados os resultados da ANOVA robusta, cujas saídas se encontram no APÊNDICE E. Um efeito significativo da proporção de floresta na produção de sedimentos foi verificado tanto para o grupo MN ($p < 0,001$, $\zeta = 0,7$), quanto para o grupo MNRipária ($p < 0,001$, $\zeta = 0,74$). Esses resultados indicam um tamanho de efeito grande da porcentagem de floresta ($\zeta \geq 0,5$) de acordo com os critérios de Mair e Wilcox (2020). O tamanho de efeito é ligeiramente maior no grupo onde há proteção da zona ripária, pois os intervalos de confiança de ζ para os dois grupos não se sobrepõem (Tabela 12). Visto que o tamanho de efeito se relaciona com o poder explicativo (WILCOX; TIAN, 2011), a proporção de floresta explica cerca de 49% e 54,8% da variação na produção de sedimentos nos grupos MN e MNRipária, respectivamente. Além disso, os testes a posteriori apresentaram $p < 0,001$ para todas as combinações pareadas de porcentagens de floresta para ambos os grupos, determinando uma diferença significativa na produção de sedimentos entre essas classes.

Embora a rugosidade tenha exibido graficamente uma relação menos evidente com a produção de sedimentos, foi detectado um efeito significativo para os grupos MN ($p < 0,001$, $\zeta = 0,26$) e MNRipária ($p < 0,001$, $\zeta = 0,13$). No entanto, esse efeito foi considerado pequeno ($0,10 \leq \zeta < 0,30$) e ligeiramente maior no grupo sem proteção da zona ripária, visto que os intervalos de confiança de ζ para os dois grupos não se sobrepõem (Tabela 12).

Consequentemente, a autocorrelação espacial explica cerca de 6,8% e 1,7% da variação na produção de sedimentos nos grupos MN e MNRipária, respectivamente. Ao contrário do observado para as classes de porcentagem, nem todas as diferenças entre classes de autocorrelação espacial foram consideradas estatisticamente significativas. Em geral, não houve diferença entre as médias dos níveis de rugosidade baixo (i.e., 0,1, 0,2, 0,3, 0,4 e 0,5) e entre as médias dos níveis intermediários (i.e., 0,5 e 0,6). Com relação aos valores maiores de rugosidade, nas paisagens MN houve diferença entre todas as classes em que *roughness* \geq 0,6. Por outro lado, apenas as diferenças de 0,6 vs. 0,9 e 0,7 vs. 0,9 foram significativas para as paisagens MNRipária.

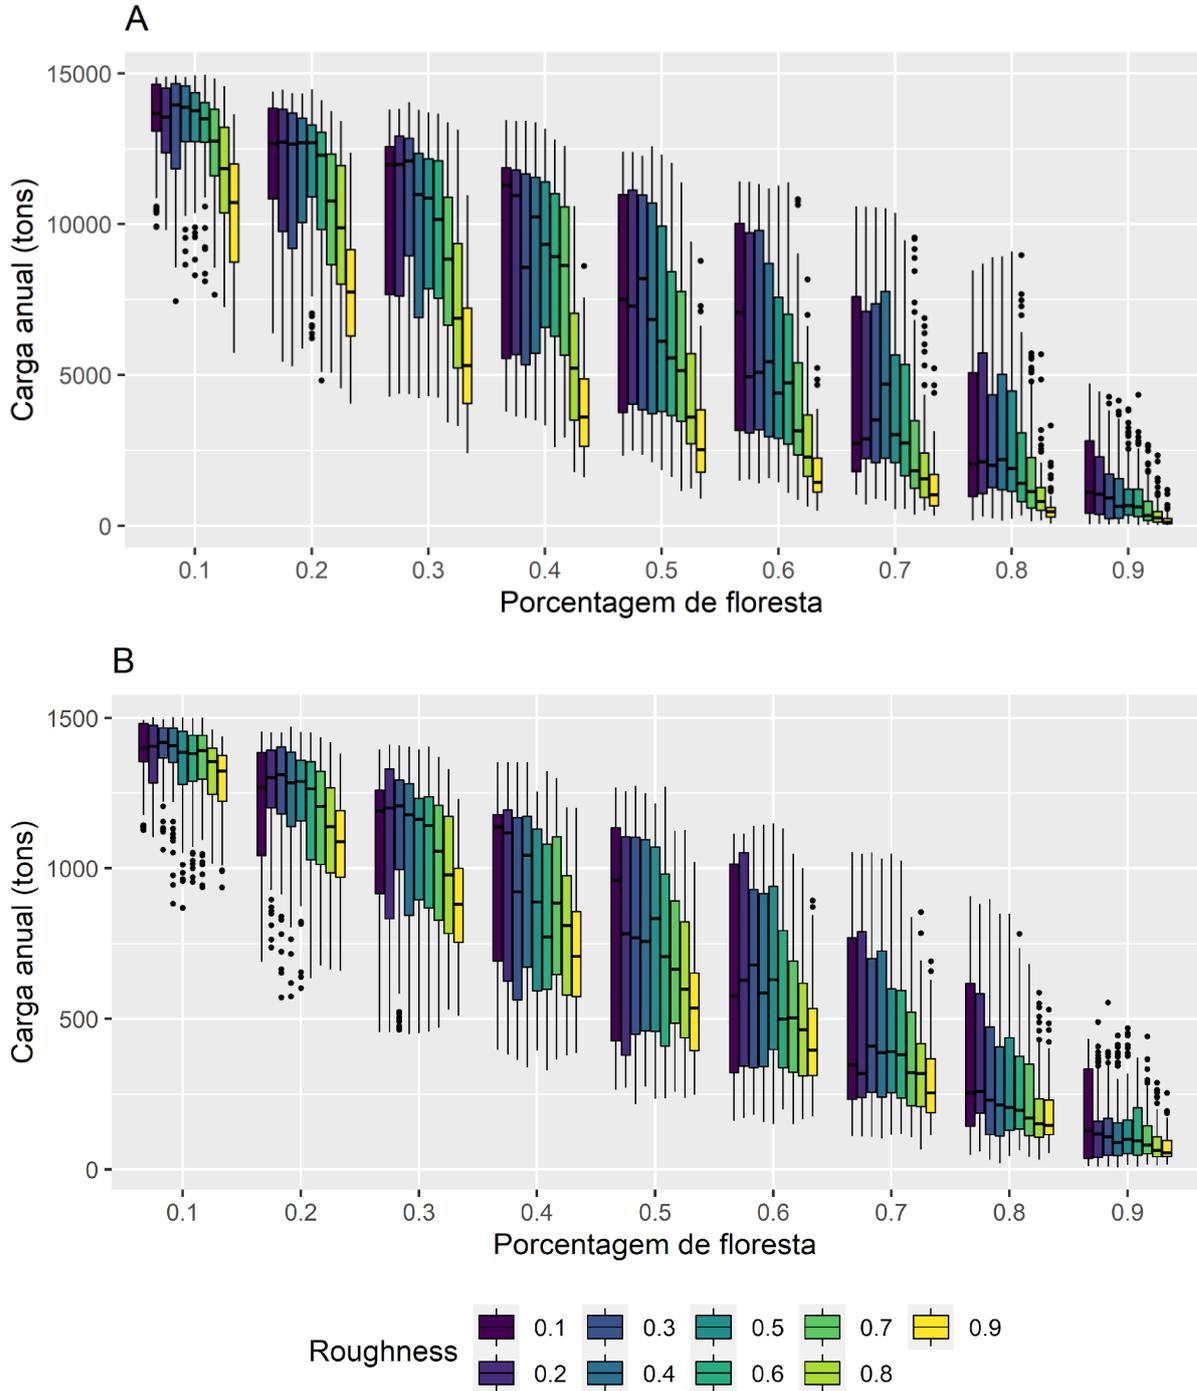
Tabela 12 – Tamanhos de efeito e intervalos de confiança a 95% da proporção de floresta e da rugosidade nas cargas anuais das paisagens MN e MNRipária

Proporção de floresta	Tamanho de efeito	Intervalo de confiança (95%)
MN	0,70	0,696 – 0,709
MNRipária	0,74	0,735 – 0,745
Rugosidade	Tamanho de efeito	Intervalo de confiança (95%)
MN	0,26	0,247 – 0,284
MNRipária	0,13	0,116 – 0,159

Fonte: elaborado pela autora.

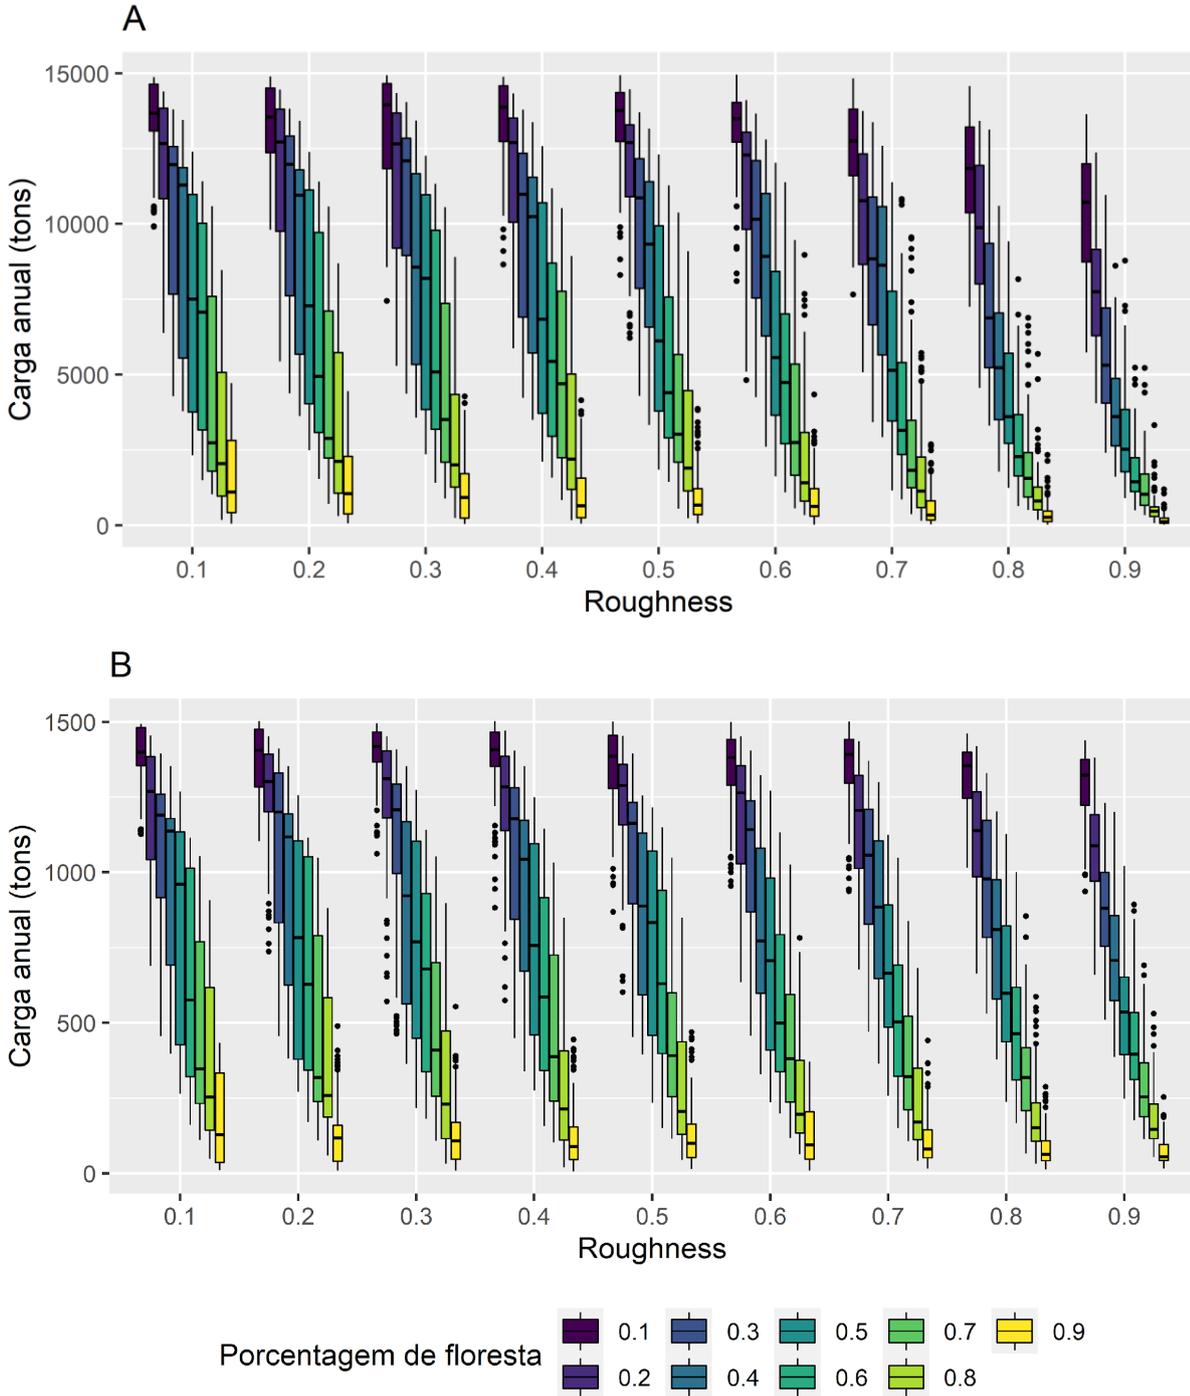
Os *boxplots* a seguir ilustram a variação da produção de sedimentos por nível de rugosidade dentro de classes de porcentagem de floresta (Figura 51), e por porcentagem de floresta dentro de níveis de rugosidade (Figura 52). Houve efeito significativo da autocorrelação espacial na produção de sedimentos em todas as classes de porcentagem de floresta e da porcentagem de floresta em todos os níveis de rugosidade, para as paisagens MN e MNRipária ($p < 0,001$).

Figura 51 – *Boxplots* das cargas anuais das paisagens (A) MN e (B) MNRipária para cada nível de autocorrelação espacial de acordo com diferentes classes de porcentagem de floresta



Fonte: elaborado pela autora.

Figura 52 – *Boxplots* das cargas anuais das paisagens (A) MN e (B) MNRipária para cada classe de porcentagem de floresta de acordo com diferentes níveis de autocorrelação espacial

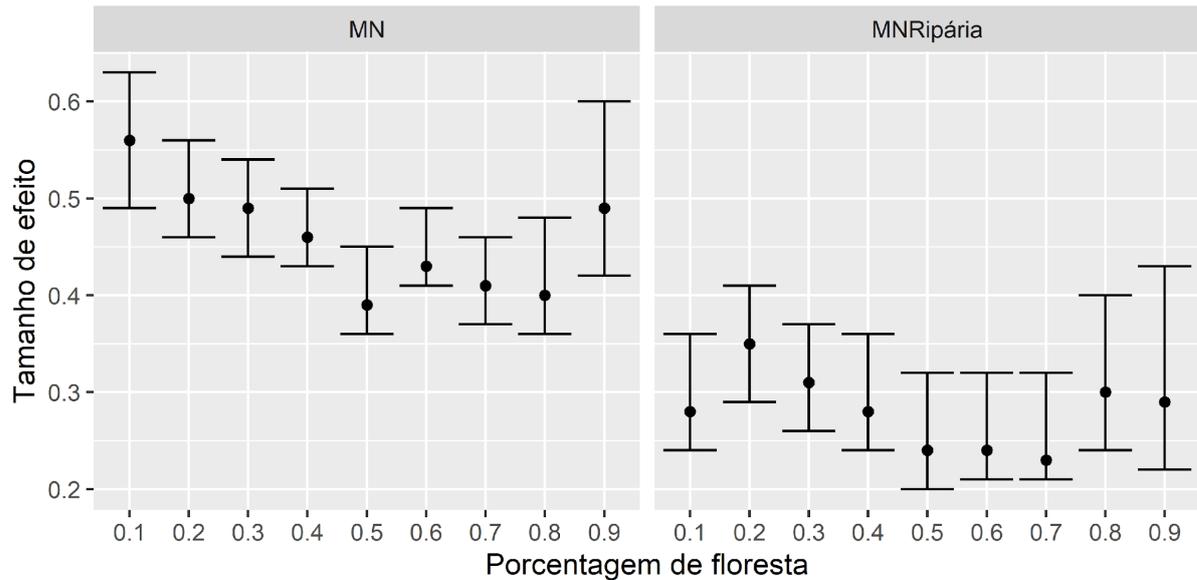


Fonte: elaborado pela autora.

Ao observar os tamanhos de efeito da autocorrelação espacial por classe de porcentagem de floresta (Figura 53), verifica-se que o grupo MN abrange tamanhos de efeito de magnitude média ($0,30 \leq \zeta < 0,50$) e grande ($\zeta \geq 0,50$), enquanto os tamanhos de efeito do grupo MNRipária possuem magnitude pequena ($0,10 \leq \zeta < 0,30$) e média ($0,30 \leq \zeta < 0,50$). Os maiores tamanhos de efeito estão associados às menores e maiores porcentagens de floresta, enquanto

as porcentagens intermediárias apresentam tamanhos de efeito de menor magnitude. Pela comparação dos intervalos de confiança a 95% é possível inferir que, para o grupo MN, apenas os pares 0,1 vs. 0,5, 0,7 e 0,8; e 0,2 vs. 0,5 apresentaram diferença estatisticamente significativa. Por outro lado, não houve diferença entre os tamanhos de efeito do grupo MNRipária.

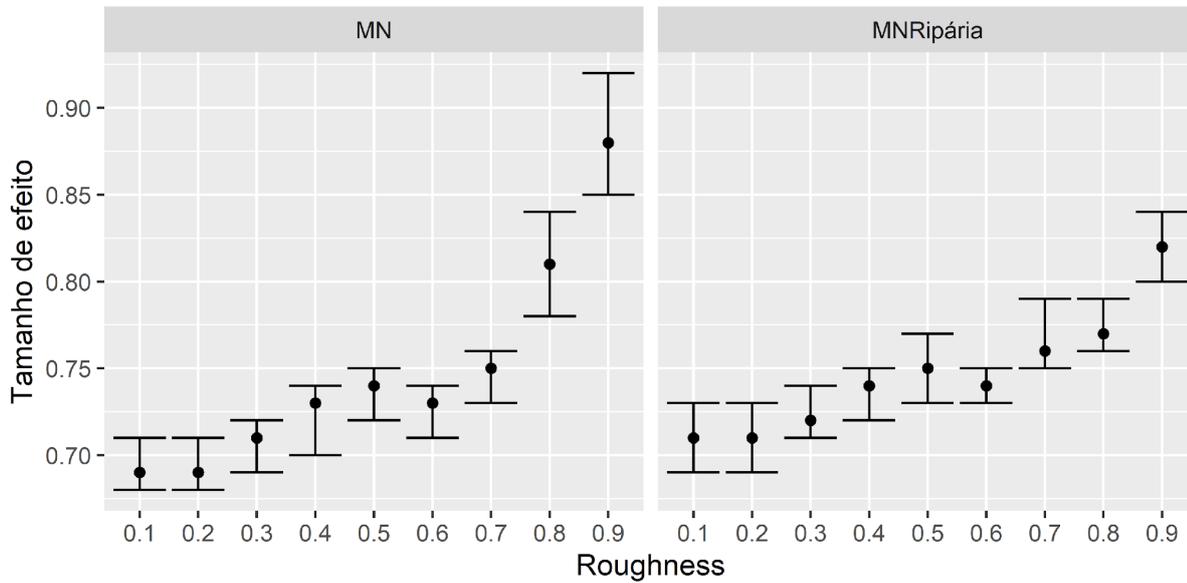
Figura 53 – Tamanhos de efeito e intervalos de confiança a 95% (barras de erro) da autocorrelação espacial por classes de porcentagem de floresta



Fonte: elaborado pela autora.

Os tamanhos de efeito da porcentagem por classe de autocorrelação espacial exibiram magnitude grande ($\zeta \geq 50$) para ambos os grupos MN e MNRipária (Figura 54). À medida que aumenta a fragmentação, maior é a magnitude do tamanho de efeito da porcentagem de floresta. Houve diferença estatisticamente significativa entre os tamanhos de efeito em 20 e 16 pares dos grupos MN e MNRipária, respectivamente, segundo os intervalos de confiança a 95%. Em geral, houve diferença entre os conjuntos de valores baixos e altos de rugosidade, e entre os valores altos (i.e., 0,6, 0,7, 0,8 e 0,9).

Figura 54 – Tamanhos de efeito e intervalos de confiança a 95% (barras de erro) da porcentagem de floresta por níveis de autocorrelação espacial

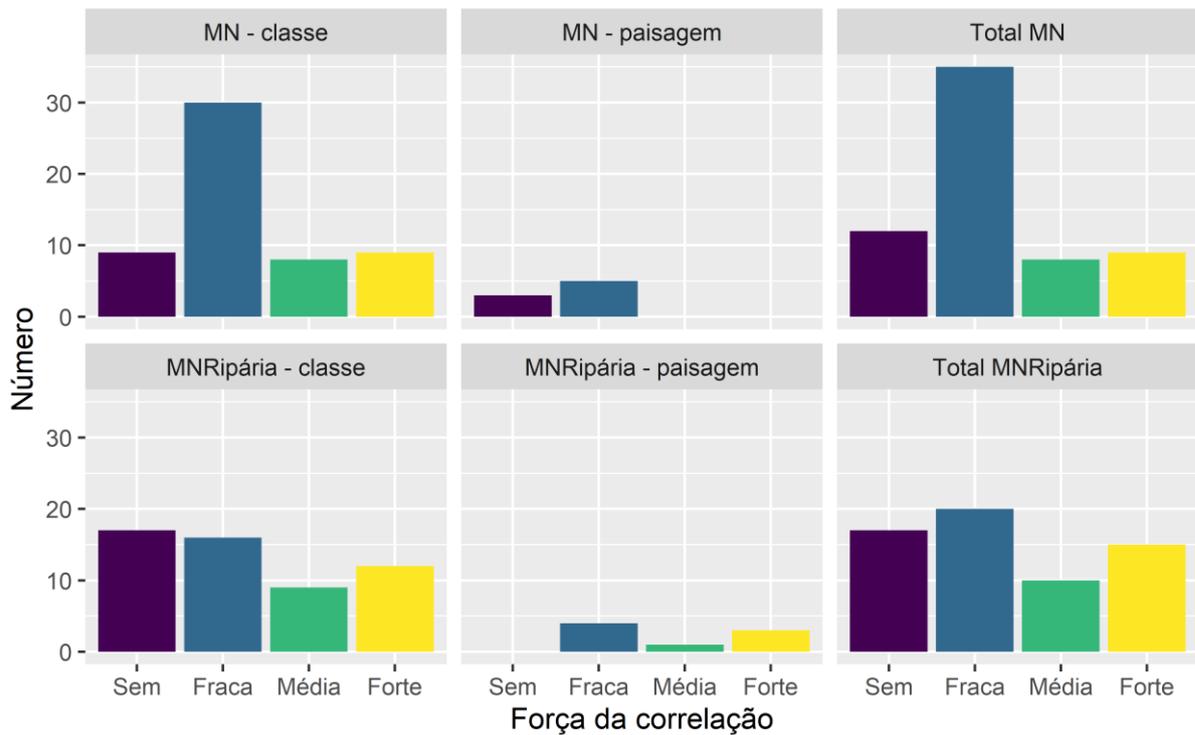


Fonte: elaborado pela autora.

3.4 Correlação entre produção de sedimentos e métricas de paisagem

O cálculo da correlação entre a produção de sedimentos e as métricas de paisagem (APÊNDICE E) indicou que o maior número de correlações fortes ocorre no grupo MNRipária, enquanto as correlações fracas ocorrem em maioria no grupo MN. Por outro lado, as paisagens MNRipária concentraram o maior número de pares sem correlação (Figura 55).

Figura 55 – Correlações de Spearman entre métricas de paisagem em nível de classe e paisagem com a carga anual de sedimentos para os grupos MN e MNRipária



Fonte: elaborado pela autora.

Notas: * Sem correlação: $-0,10 < \rho < 0,10$; Fraca: $\rho = |0,10|$; Média: $\rho = |0,30|$; Forte: $\rho = |0,50|$.

A partir desses resultados, a associação entre produção de sedimentos e 17 métricas de classe para o grupo MN, 21 métricas de classe e quatro métricas em nível de paisagem para o grupo MNRipária, foi analisada graficamente e por meio do coeficiente de correlação (Tabela 13). A maioria das métricas selecionadas são classificadas como métricas de configuração, e apenas PLAND e LPI caracterizam a composição (MCGARIGAL, 2014, 2015). Apesar de serem enquadradas como medidas de configuração, algumas métricas tiveram correlação média e forte com a porcentagem de florestas e fraca com o índice de rugosidade (e.g., AREA_AM, CIRCLE_AM, COHESION, DIVISION, MESH, SPLIT). Outras exibiram correlação forte apenas com o índice de rugosidade e não com a porcentagem de florestas (e.g., CLUMPY, ENN_MN, NLSI, PAFRAC, SHAPE_AM). No caso das métricas em nível de paisagem, somente CONTAG apresentou correlação média com o índice de rugosidade, tendo as outras se associado fortemente com a porcentagem de floresta. Algumas métricas tiveram correlação forte com ambas porcentagem e rugosidade, como os índices de agregação e forma calculados a partir da média ponderada pela área (e.g., AI, CONTIG_AM, FRAC_AM, LSI, PARA_AM, PLADJ, SHAPE_AM).

Todas as métricas que correlacionaram negativamente com a carga anual exibiram correlação positiva com a proporção de floresta na bacia, e vice-versa. Consequentemente, as

métricas de configuração associadas fortemente com a porcentagem de floresta apresentaram os tamanhos de efeito de maior magnitude para ambos os grupos de paisagens simuladas.

Tabela 13 – Correlações de Spearman da porcentagem de florestas e rugosidade com as métricas que apresentaram correlação média e forte com a produção de sedimentos para as paisagens MN e MNRipária

Tipo de paisagem e métrica	Coeficiente de correlação de Spearman*		
	MN - classe	Carga anual (tons)	% de floresta
PLAND	-0,82	1,00	0,00
LPI	-0,75	0,97	-0,12
PLAND_zrip	-0,85	0,99	0,00
MESH	-0,77	0,98	-0,11
AREA_AM	-0,72	0,96	-0,16
GYRATE_AM	-0,68	0,88	-0,12
COHESION	-0,62	0,89	-0,33
NLSI	-0,38	0,15	0,86
GYRATE_CV	-0,32	0,18	0,82
SHAPE_AM	-0,32	0,10	0,88
ENN_SD	0,33	-0,29	-0,11
ENN_MD	0,36	-0,23	-0,70
CLUMPY	0,40	-0,17	-0,88
ENN_MN	0,47	-0,32	-0,76
ENN_AM	0,49	-0,44	-0,63
DIVISION	0,77	-0,98	0,11
SPLIT	0,77	-0,98	0,11
MNRipária - classe			
PLAND	-0,83	0,99	0,00
LPI	-0,83	0,99	-0,07
MESH	-0,83	0,99	-0,07
AREA_AM	-0,83	0,99	-0,08
COHESION	-0,76	0,94	-0,28
CONTIG_AM	-0,56	0,74	-0,58
PLADJ	-0,54	0,72	-0,60
AI	-0,53	0,71	-0,61
GYRATE_AM	-0,32	0,36	0,00
SHAPE_SD	0,30	-0,38	0,34
PAFRAC	0,32	-0,46	0,81
ENN_MN	0,32	-0,28	-0,63
SHAPE_MN	0,33	-0,25	-0,86
ENN_AM	0,39	-0,41	-0,40
LSI	0,40	-0,57	0,72
SHAPE_AM	0,41	-0,58	0,69
FRAC_AM	0,46	-0,63	0,66
PARA_AM	0,54	-0,72	0,60
CIRCLE_AM	0,83	-0,96	-0,01

DIVISION	0,83	-0,99	0,07
SPLIT	0,83	-0,99	0,07
MNRipária – paisagem			
MESH	-0,60	0,70	-0,21
CONTAG	-0,30	0,42	-0,47
SPLIT	0,60	-0,70	0,21
DIVISION	0,60	-0,70	0,21

Fonte: elaborado pela autora.

Notas: * Sem correlação: $-0,10 < \rho < 0,10$; Fraca (cinza claro): $\rho = |0,10|$; Média (cinza médio): $\rho = |0,30|$; Forte (cinza escuro): $\rho = |0,50|$.

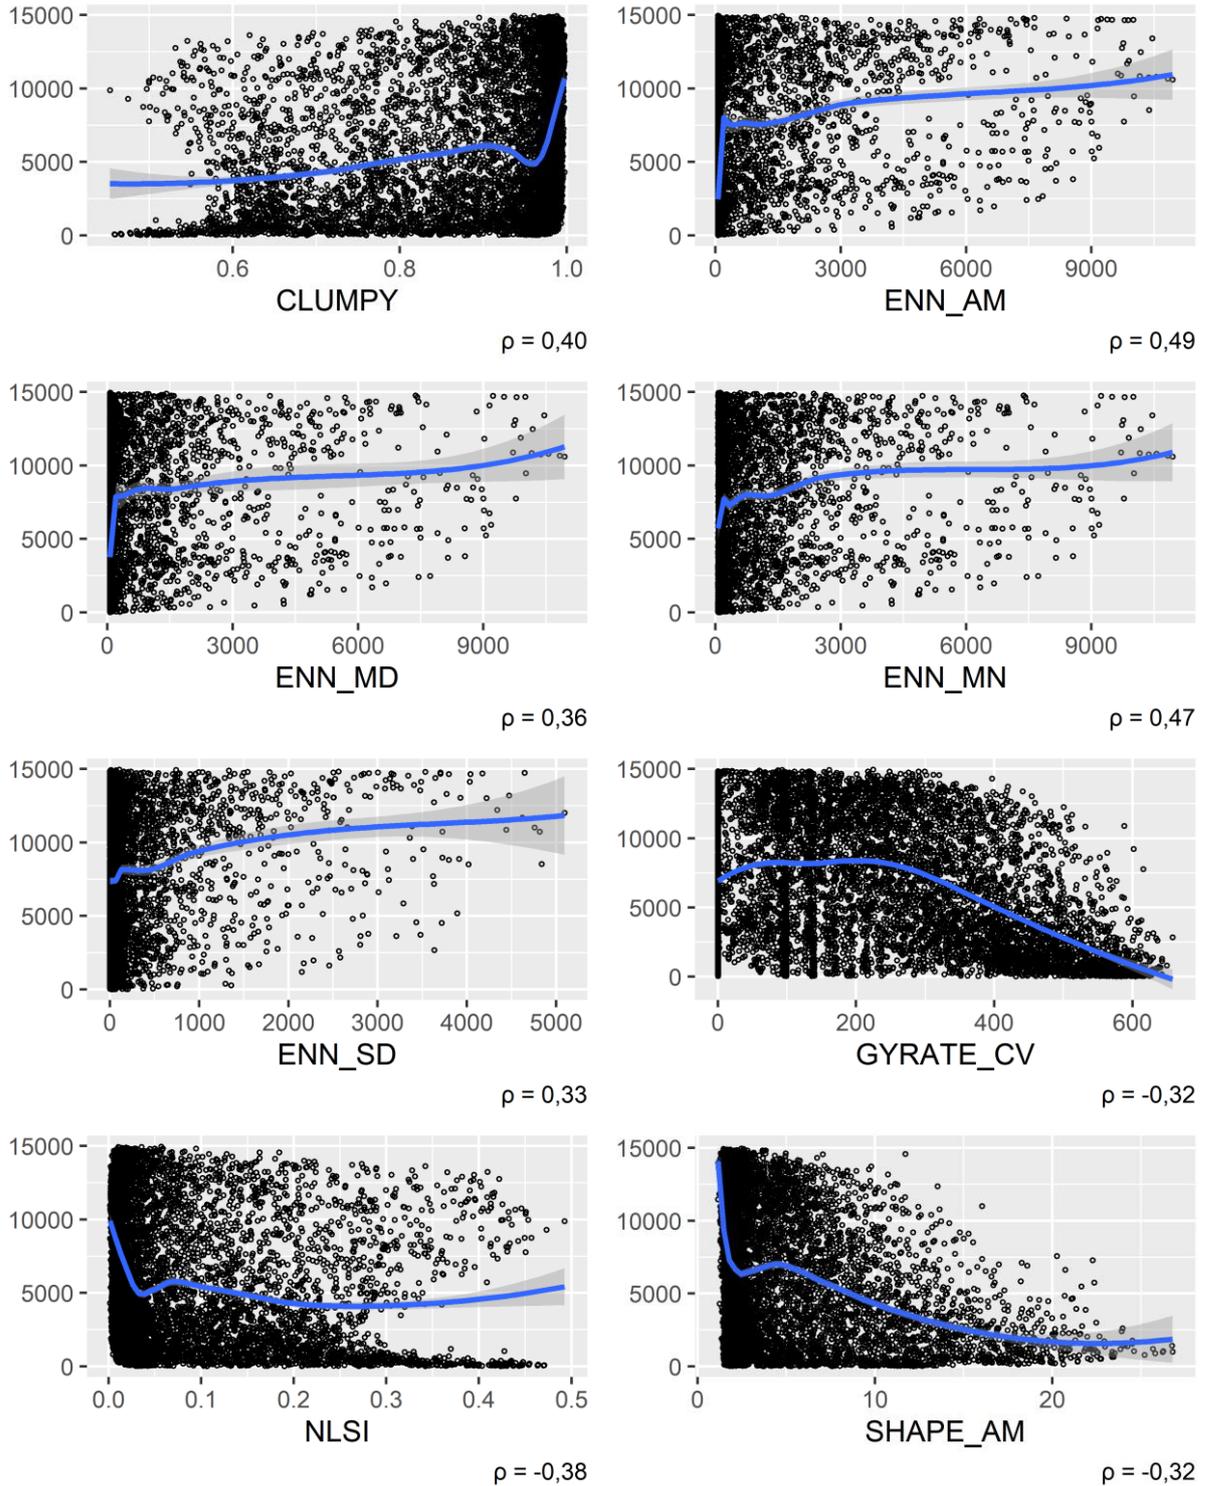
Onze métricas de classe correlacionaram com a produção de sedimentos em ambas as paisagens MN e MNRipária. Além das métricas de composição PLAND e LPI, incluem-se as métricas de área e borda (i.e., AREA_AM, GYRATE_AM), forma (i.e., SHAPE_AM) e agregação (i.e., COHESION, DIVISION, ENN_AM, ENN_MN, MESH, SPLIT). Todos esses índices tiveram a mesma direção de tamanho de efeito para ambos os grupos, com exceção de SHAPE_AM, que correlacionou negativamente e positivamente com a carga anual das paisagens MN e MNRipária, respectivamente. Por outro lado, cinco e três métricas em nível de classe e paisagem demonstraram correlação forte em MNRipária, mas fraca ou sem força em MN – AI, CIRCLE_AM, CONTIG_AM, PARA_AM e PLADJ (classe); e DIVISION, MESH e SPLIT (paisagem). No entanto, todos esses índices correlacionaram de modo forte e fraco-médio com a proporção de florestas de MNRipária e MN, respectivamente, o que sugere que essa correlação é derivada do papel da composição.

As métricas de configuração AREA_AM, COHESION, DIVISION, GYRATE_AM, MESH e SPLIT correlacionaram fortemente ($\rho \geq 0,88$) com a porcentagem de florestas nas paisagens MN. Nas paisagens MNRipária, esse número de índices foi ainda maior, incluindo AI, CIRCLE_AM, CONTIG_AM, FRAC_AM, LSI, PARA_AM, PLADJ e SHAPE_AM ($\rho \geq 0,56$). Por outro lado, a métrica GYRATE_AM foi a única que apresentou correlação forte com a porcentagem de florestas no grupo MN, mas média no grupo MNRipária.

Em suma, os resultados do conjunto MN reforçam a associação de áreas com alta proporção de florestas na bacia hidrográfica e na zona ripária com menor aporte de sedimentos. Além desse atributo composicional, paisagens com alta proporção de florestas também costumam possuir a maior mancha florestal ocupando a maior parte da paisagem (LPI), manchas maiores (AREA_AM, MESH), extensas (GYRATE_AM), e agregadas (COHESION). Considerando as métricas de configuração que não exibiram correlação forte com a proporção de florestas (i.e., SHAPE_AM), verifica-se uma associação entre paisagens com manchas mais complexas e menor carga de sedimentos. CLUMPY, que parece não ser

influenciada pela porcentagem, indicou uma associação entre paisagens com florestas mais agregadas e maior carga anual. Além disso, uma maior distância euclidiana do vizinho mais próximo exibiu associação positiva com o aporte de sedimentos na água, tanto da perspectiva de medidas de tendência central (i.e., mediana, média e média ponderada pela área), como de dispersão (i.e., desvio padrão). Apesar de terem sido associadas com as cargas anuais, os gráficos de dispersão para as métricas que não correlacionaram fortemente com a porcentagem de floresta (Figura 56) sugerem que para algumas delas não há um padrão claro para o conjunto total de paisagens. Ao se adicionar a curva de suavização LOESS, alguns padrões despontam, como uma ascendência ou descendência acentuada da curva em valores extremos (i.e., baixos ou altos) desses índices. Portanto, as relações bivariadas podem se mostrar mais claras se o percentual de floresta for considerado.

Figura 56 – Gráficos de dispersão das métricas em nível de classe que tiveram correlação (ρ) média ou forte com as cargas anuais das paisagens MN e que não correlacionaram fortemente com a porcentagem de floresta



Fonte: elaborado pela autora.

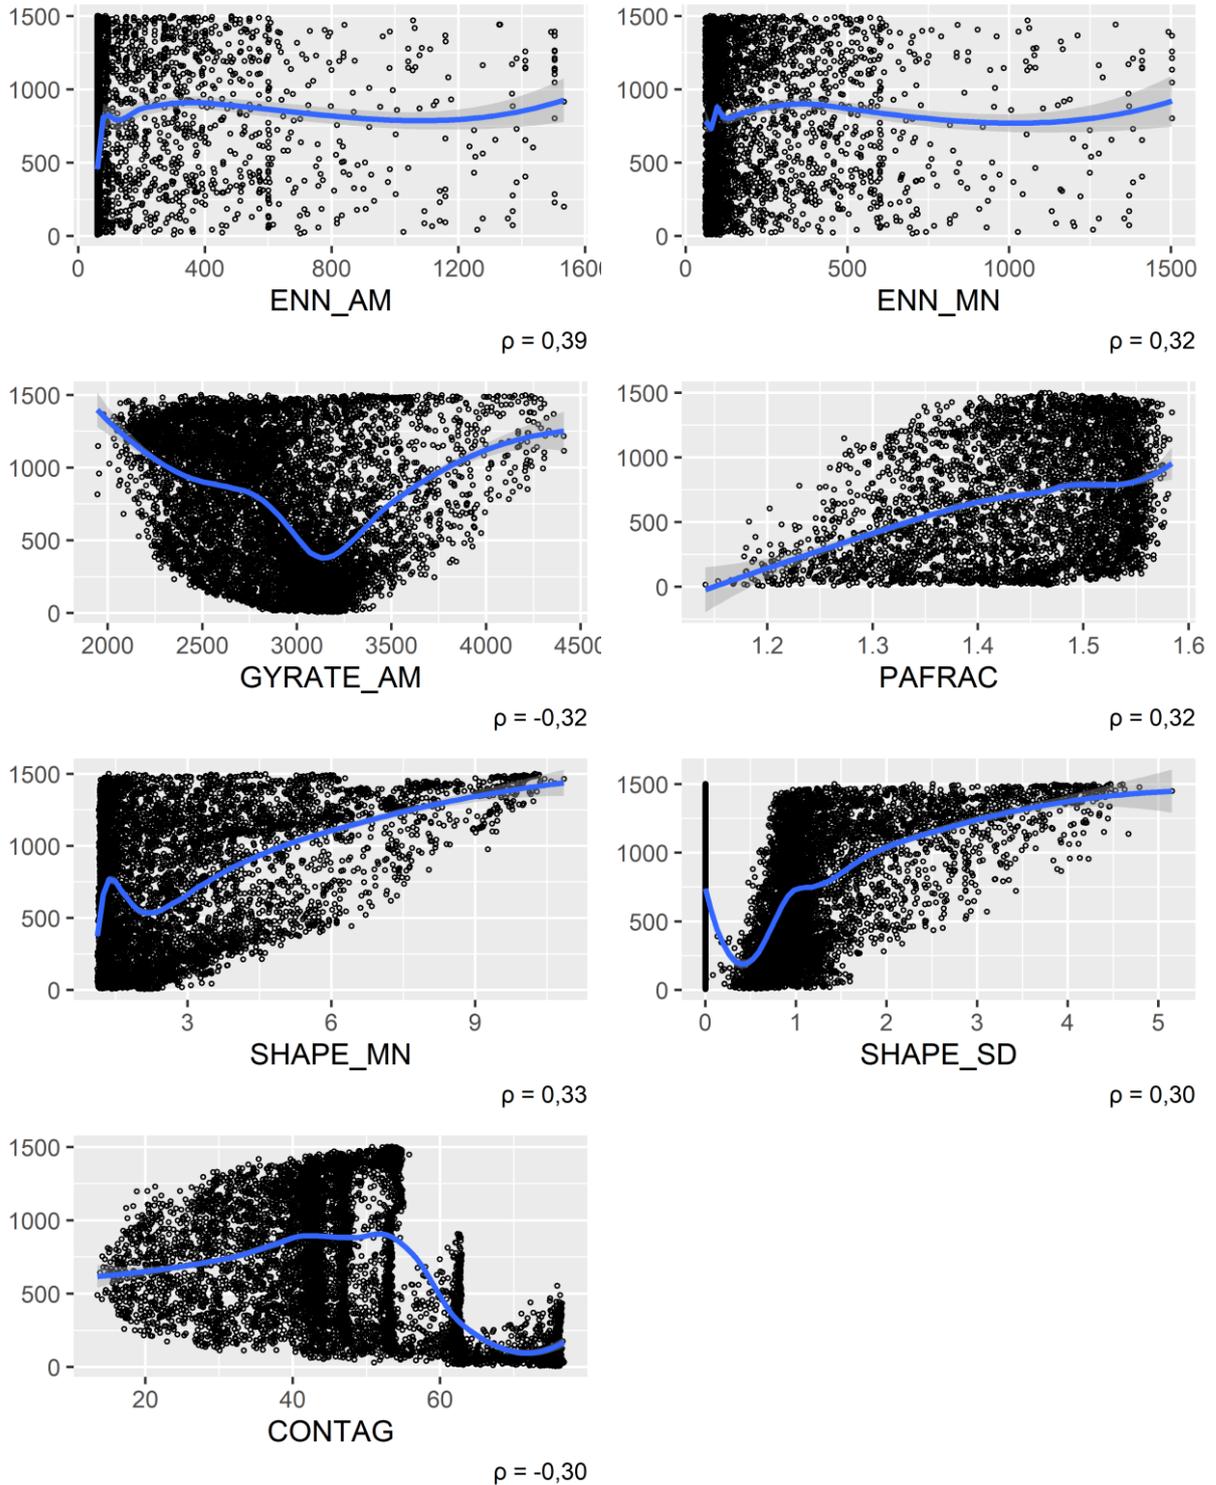
Notas: o título do eixo Y, que representa carga anual (tons), foi omitido por razões de apresentação gráfica. O suavizador LOESS ($span = 0,4$) está representado pela curva azul.

O conjunto MNRipária exibiu padrão muito semelhante, indicando uma melhor qualidade da água em paisagens com alta proporção de florestas que, conseqüentemente,

possuem a maior mancha florestal ocupando a maior parte da paisagem (LPI), manchas maiores (AREA_AM, MESH), extensas (GYRATE_AM), e agregadas (COHESION). O padrão percebido para o isolamento das manchas florestais na paisagem também foi encontrado no grupo MNRipária, embora somente medidas de tendência central da distância euclidiana do vizinho mais próximo (i.e., ENN_AM e ENN_MN) tenham correlacionado positivamente com a carga de sedimentos. Enquanto no grupo MN a única métrica de forma relevante foi SHAPE_AM, um número maior desses índices correlacionou com a carga anual nas paisagens MNRipária (CIRCLE_AM, FRAC_AM, PAFRAC, PARA_AM, SHAPE_AM, SHAPE_MN). Em nível de paisagem, todas as métricas, com exceção de CONTAG, exibiram correlação forte com a proporção de florestas.

Assim como nas paisagens MN, os gráficos de dispersão das métricas que não correlacionaram fortemente com a porcentagem de floresta (Figura 57) não sugerem um padrão claro para algumas delas, especialmente ENN e GYRATE_AM. A curva de suavização LOESS demonstra a existência de alguns padrões e relações não-lineares. Para GYRATE_AM, por exemplo, a curva obtida aponta uma diminuição seguida por um aumento da carga anual à medida que o valor da métrica aumenta. Nesse sentido, é preciso explorar essas relações bivariadas considerando os percentuais de floresta.

Figura 57 – Gráficos de dispersão das métricas em nível de classe e paisagem (CONTAG) que tiveram correlação (ρ) média ou forte com as cargas anuais das paisagens MNRipária e que não correlacionaram fortemente com a porcentagem de floresta



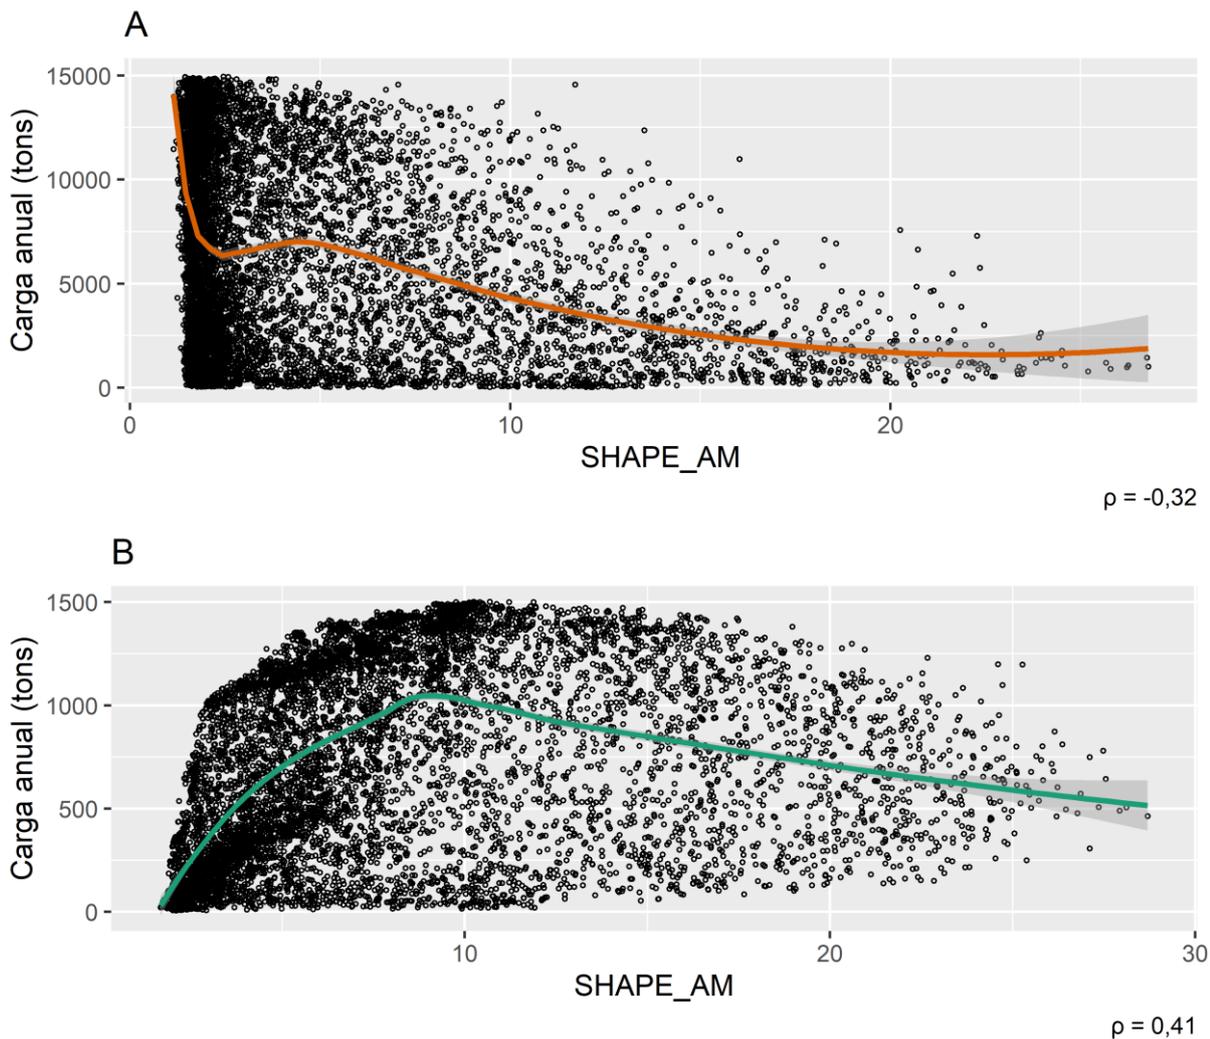
Fonte: elaborado pela autora.

Notas: o título do eixo Y, que representa carga anual (tons), foi omitido por razões de apresentação gráfica.

Como já descrito, a métrica SHAPE_AM apresentou correlações divergentes com a carga anual para as paisagens MN e MNRipária. De fato, os gráficos de dispersão mostram uma

mudança na direção da correlação quando a faixa ripária florestal é adicionada às paisagens (Figura 58). Embora a curva LOESS indique uma relação negativa a partir de $SHAPE_AM = 10$ para ambos os grupos de paisagens, a relação em valores menores que 10 nas paisagens MNRipária é positiva. Nas paisagens MN, este índice teve correlação fraca e forte com a porcentagem e rugosidade, respectivamente. Por outro lado, houve correlação forte tanto com a porcentagem quanto com a rugosidade nas paisagens MNRipária.

Figura 58 – Gráfico de dispersão e estimador LOESS para a métrica $SHAPE_AM$ vs. as cargas anuais das paisagens (A) MN e (B) MNRipária

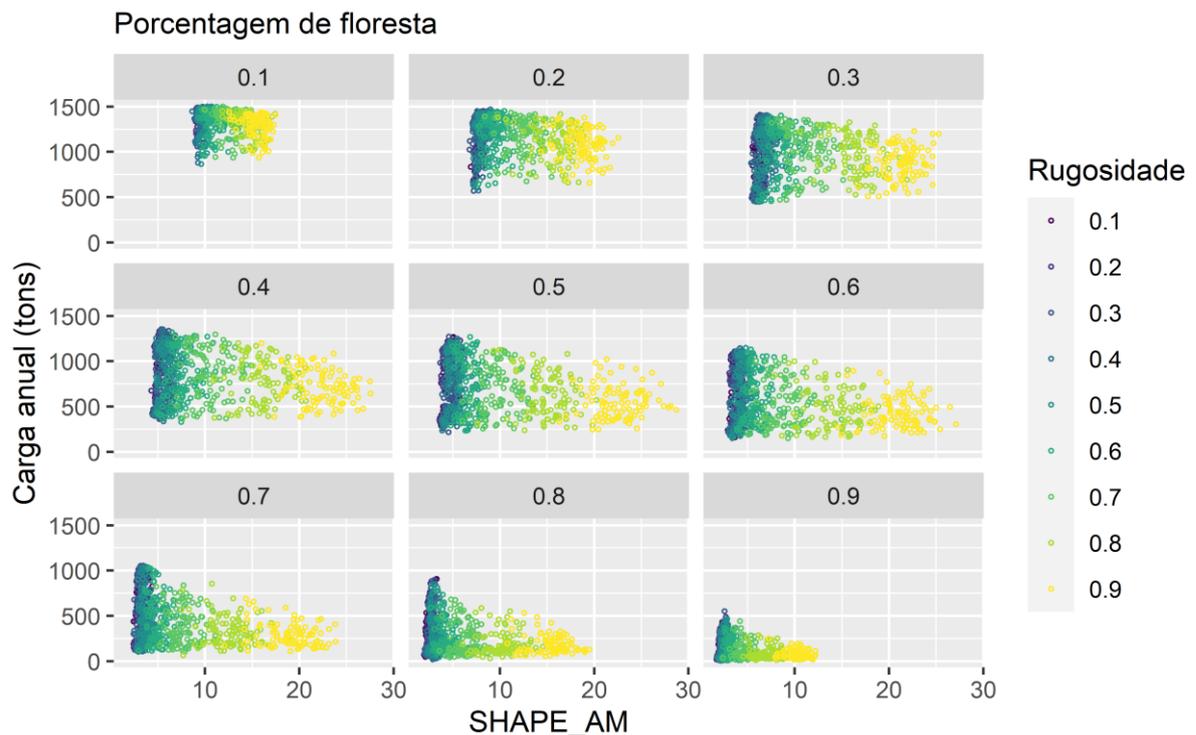


Fonte: elaborado pela autora.

O valor médio de $SHAPE_AM$ para as paisagens MN e MNRipária é 4,6 e 8,3, respectivamente. Portanto, os fragmentos florestais no segundo grupo são em média mais complexos, o que é resultado da existência das faixas ripárias, que são naturalmente alongadas e ramificadas. Nas bacias MNRipária com pouca cobertura florestal, $SHAPE_AM$ apresenta

valores maiores¹⁰, visto que boa parte da vegetação se concentra nas margens dos riachos. Por outro lado, em paisagens mais florestadas a vegetação na bacia tem maior probabilidade de estar unida à vegetação ripária, o que resulta em manchas menos complexas e menores valores para SHAPE_AM (Figura 59). Por esse motivo, a correlação entre PLAND e SHAPE_AM nas paisagens MNRipária é negativa e forte.

Figura 59 – Gráficos de dispersão da métrica SHAPE_AM vs. as cargas anuais das paisagens MNRipária por percentagem de floresta



Fonte: elaborado pela autora.

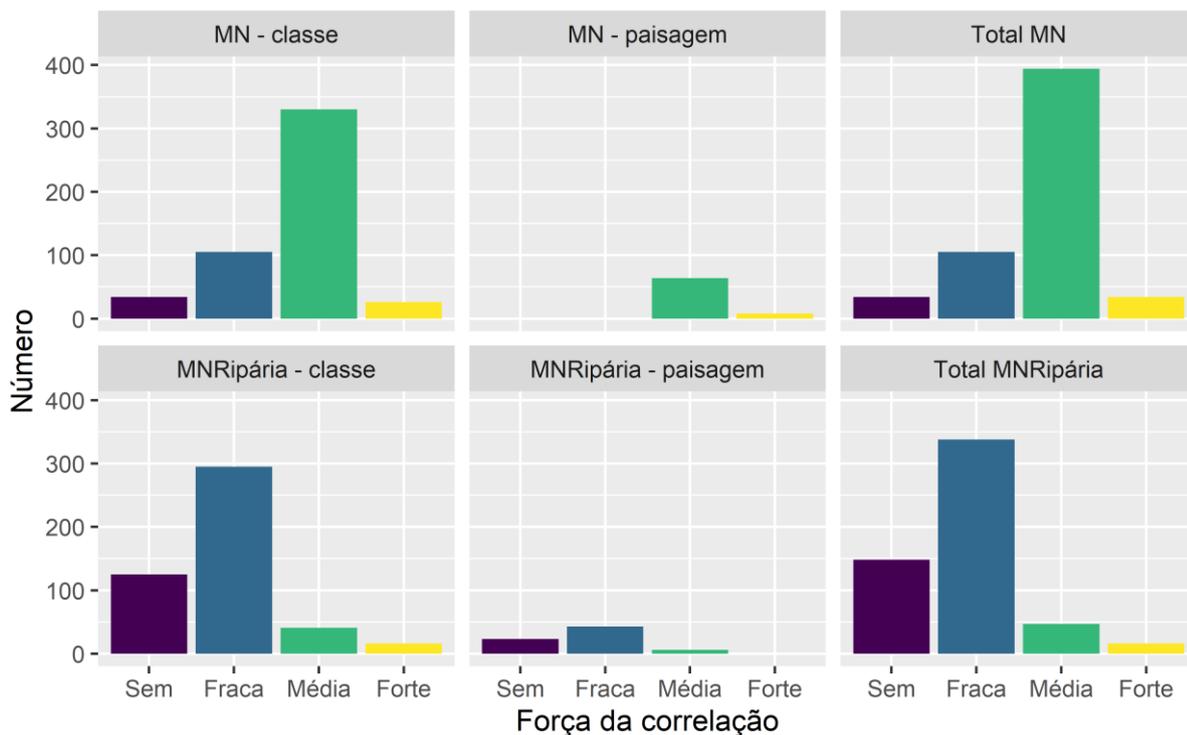
3.5 Correlação entre produção de sedimentos e métricas de paisagem por percentual de cobertura florestal

Nesta seção, os resultados obtidos incluindo todas as paisagens nos cálculos serão referidos como “grupo geral”, enquanto os obtidos tomando as paisagens inseridas em cada classe de percentual de floresta serão chamados de “grupos de percentuais”. Diante da influência da composição da paisagem na produção de sedimentos constatada pela ANOVA robusta, e da sua correlação com várias métricas de configuração, é imperativo analisar a relação padrão-processo por percentuais de floresta. Nesta abordagem, o grupo MN apresentou

¹⁰ Médias de SHAPE_AM de MNRipária por percentual de floresta: 10% = 11,34; 20% = 10,76; 30% = 10,10; 40% = 9,42; 50% = 8,7; 60% = 7,79; 70% = 6,84; 80% = 5,60; 90% = 4,11.

a maioria das correlações classificadas como médias (Figura 60), um padrão contrário do observado para o grupo geral, em que a maioria das correlações foram fracas. No caso de MNRipária, houve uma maior proporção de correlações fracas tanto em nível de classe quanto no total. Neste sentido, um padrão despontou: a maioria das correlações obtidas para MN são médias e fortes, enquanto a maioria das correlações obtidas para MNRipária são fracas e sem força.

Figura 60 – Correlações de Spearman entre métricas de paisagem em nível de classe e paisagem com a carga anual de sedimentos calculadas por percentuais de floresta para os grupos MN e MNRipária

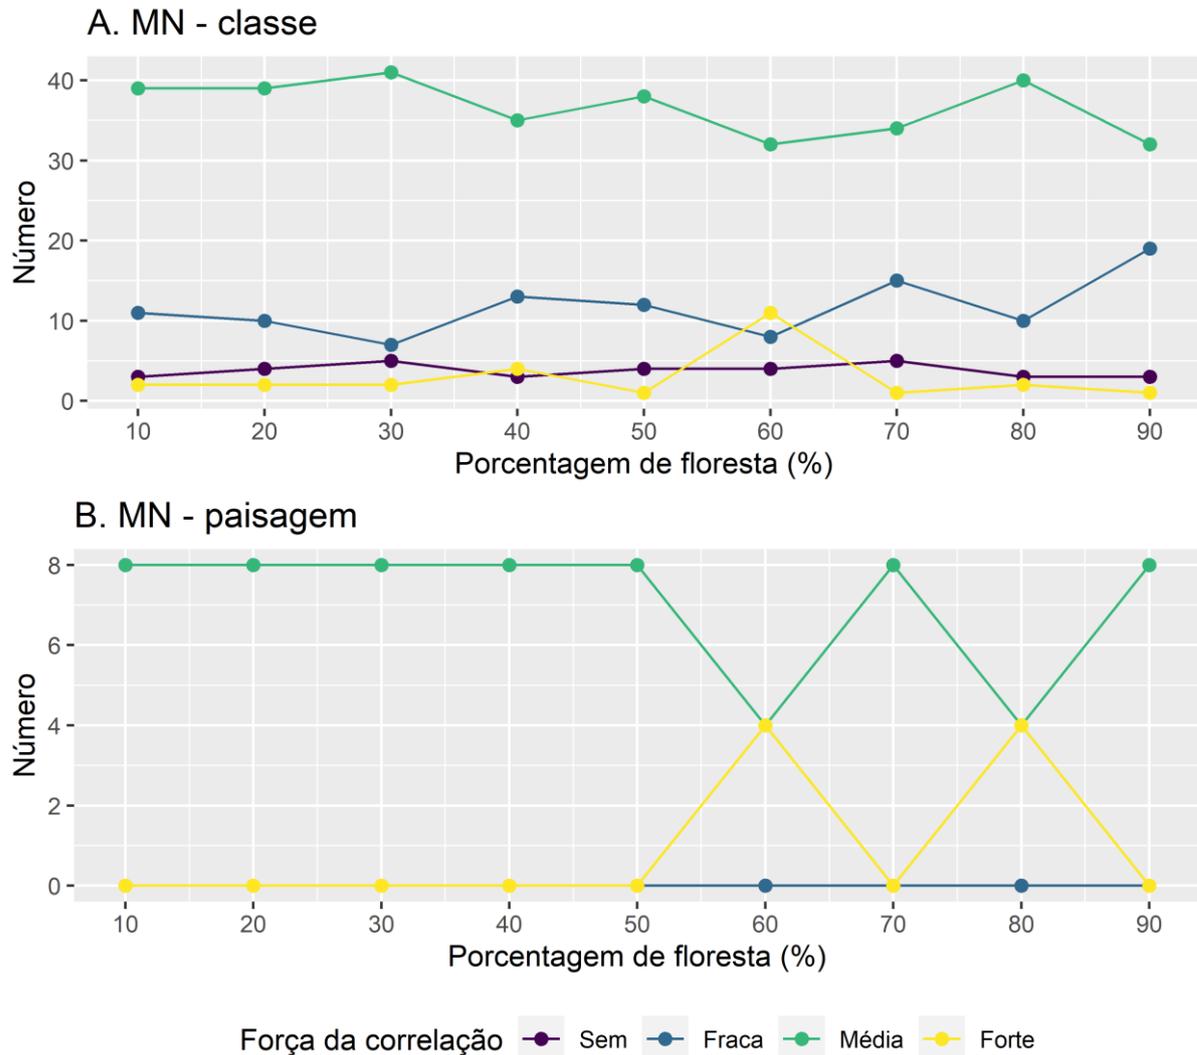


Fonte: elaborado pela autora.

Notas: * Sem correlação: $-0,10 < \rho < 0,10$; Fraca: $\rho = |0,10|$; Média: $\rho = |0,30|$; Forte: $\rho = |0,50|$.

Ao observar o número de correlações de diferentes forças por percentual de floresta, nota-se que as correlações médias prevalecem em todas as porcentagens para as paisagens MN (Figura 61.A). A 60% de floresta há um pico no número de correlações fortes. Em todas as outras classes esse número permanece abaixo de quatro, mas chega a 11 nesse nível de percentual. Estas 11 métricas mensuram principalmente a forma e agregação das florestas (i.e., AI, CLUMPY, CONTIG_AM, ED, FRAC_AM, LSI, NLSI, PAFRAC, PARA_AM, PLADJ, SHAPE_AM). Para as métricas em nível de paisagem, há correlações fortes apenas em 60 e 80% de floresta na bacia (Figura 61.B).

Figura 61 – Correlações de Spearman entre métricas de paisagem e carga de sedimentos para as paisagens MN por percentuais de floresta



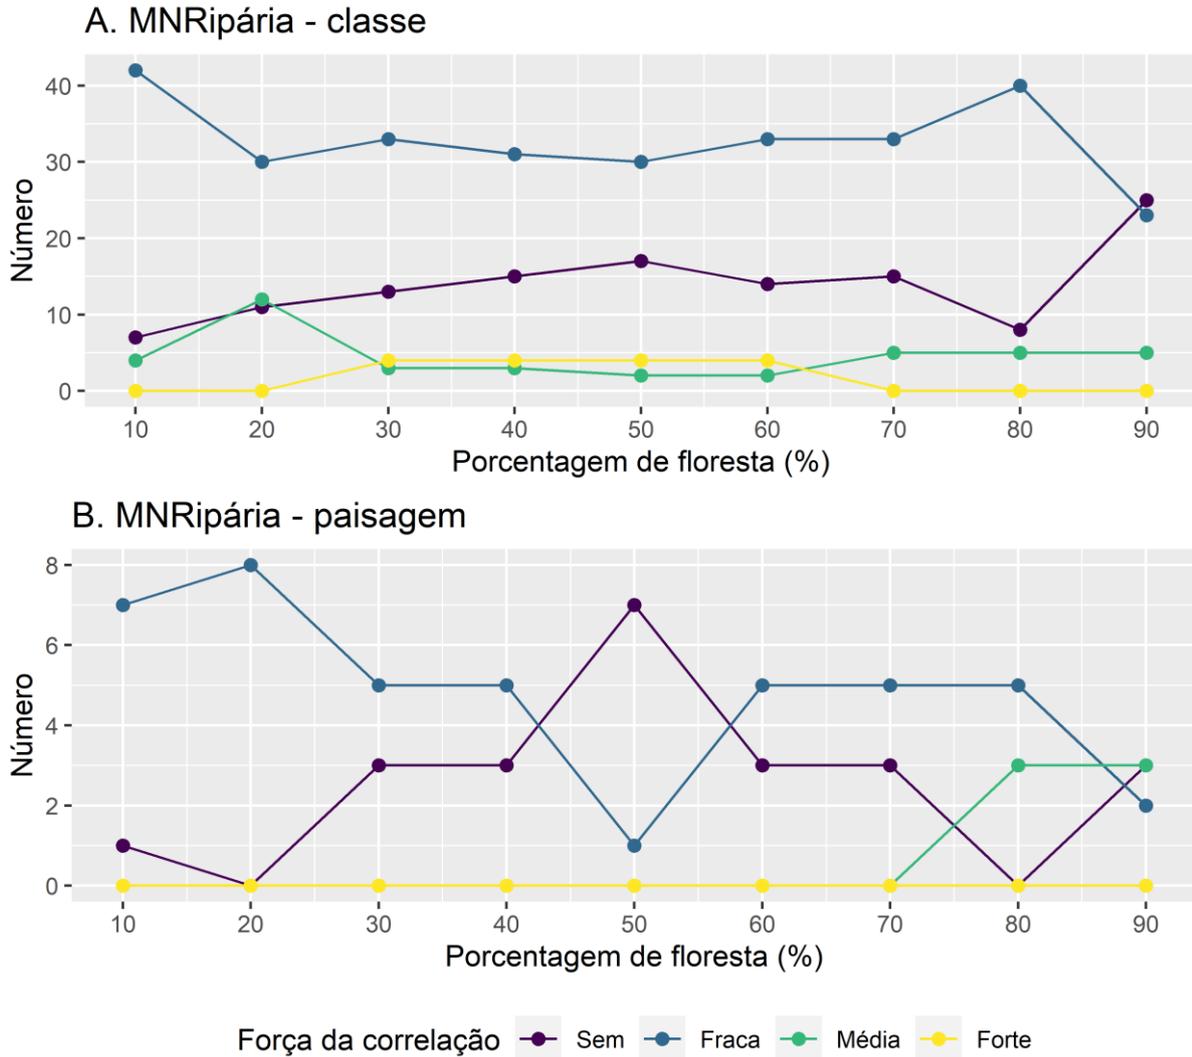
Fonte: elaborado pela autora.

Notas: * Sem correlação: $-0,10 < \rho < 0,10$; Fraca: $\rho = |0,10|$; Média: $\rho = |0,30|$; Forte: $\rho = |0,50|$.

No gráfico B as linhas “sem” e “fraca” estão sobrepostas pelas outras linhas pois apresentaram valor zero em todas as classes.

Para o grupo MNRipária - classe, não há muita variação no número de correlações médias e fortes por percentual de floresta, exceto a 20% quando há um pico no número de correlações médias (Figura 62.A). Para as métricas em nível de paisagem, verifica-se um pico no número de correlações sem força a 50%, enquanto as correlações médias e fortes se mantêm em baixa quantidade em todas as classes. No entanto, em 80 e 90% houve o maior número de correlações médias (Figura 62.B), que se referem aos índices DIVISION, MESH e SPLIT, três métricas que são perfeitamente correlacionadas entre si e que caracterizam a agregação dos tipos de cobertura na paisagem.

Figura 62 – Correlações de Spearman entre métricas de paisagem e carga de sedimentos para as paisagens MNRipária por percentuais de floresta



Fonte: elaborado pela autora.

Notas: * Sem correlação: $-0,10 < \rho < 0,10$; Fraca: $\rho = |0,10|$; Média: $\rho = |0,30|$; Forte: $\rho = |0,50|$.

No gráfico B a linha “média” está sobreposta pelas outras linhas pois apresentou valor zero em quase todas as classes.

Vários índices que na seção anterior não tiveram correlação ou que exibiram correlação fraca apresentaram ao menos correlação média com a produção de sedimentos a depender do percentual de floresta (APÊNDICE E, Quadro 11). Esse padrão foi bastante evidente para as paisagens MN, visto que 46 (82%) métricas em nível de classe e todas de paisagem apresentaram pelo menos correlação média em algum percentual. Por outro lado, apenas 13 (24%) métricas de classe e três (37%) em nível de paisagem do grupo MNRipária exibiram tal comportamento.

Quadro 11 – Sinal e magnitude das correlações de Spearman entre métricas e produção de sedimentos para todas as paisagens (Geral) e para classes de percentual de floresta (Perc.)

Métrica	MN – classe				MNRipária – classe			
	Sinal		Magnitude		Sinal		Magnitude	
	Geral	Perc.	Geral	Perc.	Geral	Perc.	Geral	Perc.
AI	-	+	s	MF	-	+	F	s
AREA_AM	-	+	F	M	-	+	F	M
AREA_CV	-	-	s	M	-	-	s	M
AREA_MD	+	+	s	M	-	+	s	s
AREA_MN	-	+	s	M	-	+	s	M
AREA_SD	-	+	s	s	-	-/+	s	s
CIRCLE_AM	+	-/+	s	s	+	-/+	F	M
CIRCLE_CV	-	-	s	M	-	-	s	s
CIRCLE_MD	+	+	s	M	+	+	s	s
CIRCLE_MN	+	+	s	M	+	+	s	s
CIRCLE_SD	-	-	s	M	+	-	s	s
CLUMPY	+	+	M	MF	-	+	s	s
COHESION	-	+	F	M	-	+	F	M
CONTIG_AM	-	+	s	MF	-	+	F	s
CONTIG_CV	-	-	s	M	-	-	s	s
CONTIG_MD	+	+	s	M	-	+	s	s
CONTIG_MN	+	+	s	M	+	+	s	s
CONTIG_SD	+	-/+	s	s	+	-/+	s	s
DIVISION	+	-	F	M	+	-	F	MF
ED	-	-	s	MF	+	-	s	s
ENN_AM	+	+	M	s	+	-/+	M	s
ENN_CV	+	-/+	s	s	+	-/+	s	s
ENN_MD	+	+	M	M	+	+	s	s
ENN_MN	+	+	M	M	+	+	M	s
ENN_SD	+	+	M	s	+	-/+	s	s
FRAC_AM	-	-	s	MF	+	-	M	s
FRAC_CV	-	-	s	M	+	-/+	s	s
FRAC_MD	+	+	s	M	+	+	s	s
FRAC_MN	+	+	s	M	+	+	s	s
FRAC_SD	-	-	s	M	+	-/+	s	s
GYRATE_AM	-	-/+	F	M	-	-/+	M	M
GYRATE_CV	-	-	M	M	-	-	s	s
GYRATE_MD	+	+	s	M	+	+	s	s
GYRATE_MN	+	+	s	M	+	+	s	M
GYRATE_SD	-	+	s	s	+	-/+	s	s
LPI	-	+	F	M	-	+	F	MF
LSI	-	-	s	MF	+	-	M	s
MESH	-	+	F	M	-	+	F	MF
NLSI	-	-	M	MF	-	-	s	s
PAFRAC	-	-	s	MF	+	-	M	s

PARA_AM	+	-	s	MF	+	-	F	s
PARA_CV	+	+	s	s	+	-/+	s	s
PARA_MD	-	-	s	M	+	-	s	s
PARA_MN	-	-	s	M	-	-	s	s
PARA_SD	+	-/+	s	s	+	-/+	s	s
PD	-	-	s	M	-	-	s	M
PD_zrip	-	-	s	MF	x	x	x	x
PLADJ	-	+	s	MF	-	+	F	s
PLAND	-	x	F	x	-	x	F	x
PLAND_zrip	-	-	F	MF	x	x	x	x
SHAPE_AM	-	-	M	MF	+	-	M	s
SHAPE_CV	-	-	s	M	+	-/+	s	s
SHAPE_MD	+	+	s	M	+	+	s	s
SHAPE_MN	+	+	s	M	+	+	M	M
SHAPE_SD	-	-	s	M	+	-/+	M	s
SPLIT	+	-	F	M	+	-	F	MF
	MN – paisagem				MNRipária – paisagem			
AI	+	+	s	MF	-	+	s	s
COHESION	+	+	s	M	-	-/+	s	s
CONTAG	+	+	s	MF	-	+	M	s
DIVISION	-	-	s	M	+	-/+	F	M
LSI	-	-	s	MF	+	-	s	s
MESH	+	+	s	M	-	-/+	F	M
PLADJ	+	+	s	MF	-	+	s	s
SPLIT	-	-	s	M	+	-/+	F	M

Fonte: elaborado pela autora.

Notas:

- = negativo

+ = positivo

-/+ = negativo e positivo

s = sem correlação ou correlação fraca

M = média

F = forte

MF = média e forte

x = não calculada

Destas métricas, 32 (57%) e quatro (7,4%) em nível de classe para MN e MNRipária, respectivamente, haviam apresentado correlação fraca ou inexistente quando todas as paisagens foram consideradas no cálculo. Já em nível de paisagem, todas as oito métricas de MN passaram a exibir correlação média ou forte, enquanto as métricas de MNRipária já haviam apresentado correlação forte no grupo geral. Considerando essas métricas de classe que tiveram correlação relevante somente nos grupos de percentuais, a maioria delas (81% de MN e 100% de MNRipária) correlaciona muito fortemente ($\rho = |0,8|$) com a autocorrelação espacial no grupo geral. Apenas duas métricas de classe que tiveram correlação média ou forte no grupo geral

MN exibiram correlação fraca ou inexistente nos grupos de percentuais, por outro lado, esse fenômeno ocorreu para 11 métricas em nível de classe e para CONTAG no grupo MNRipária.

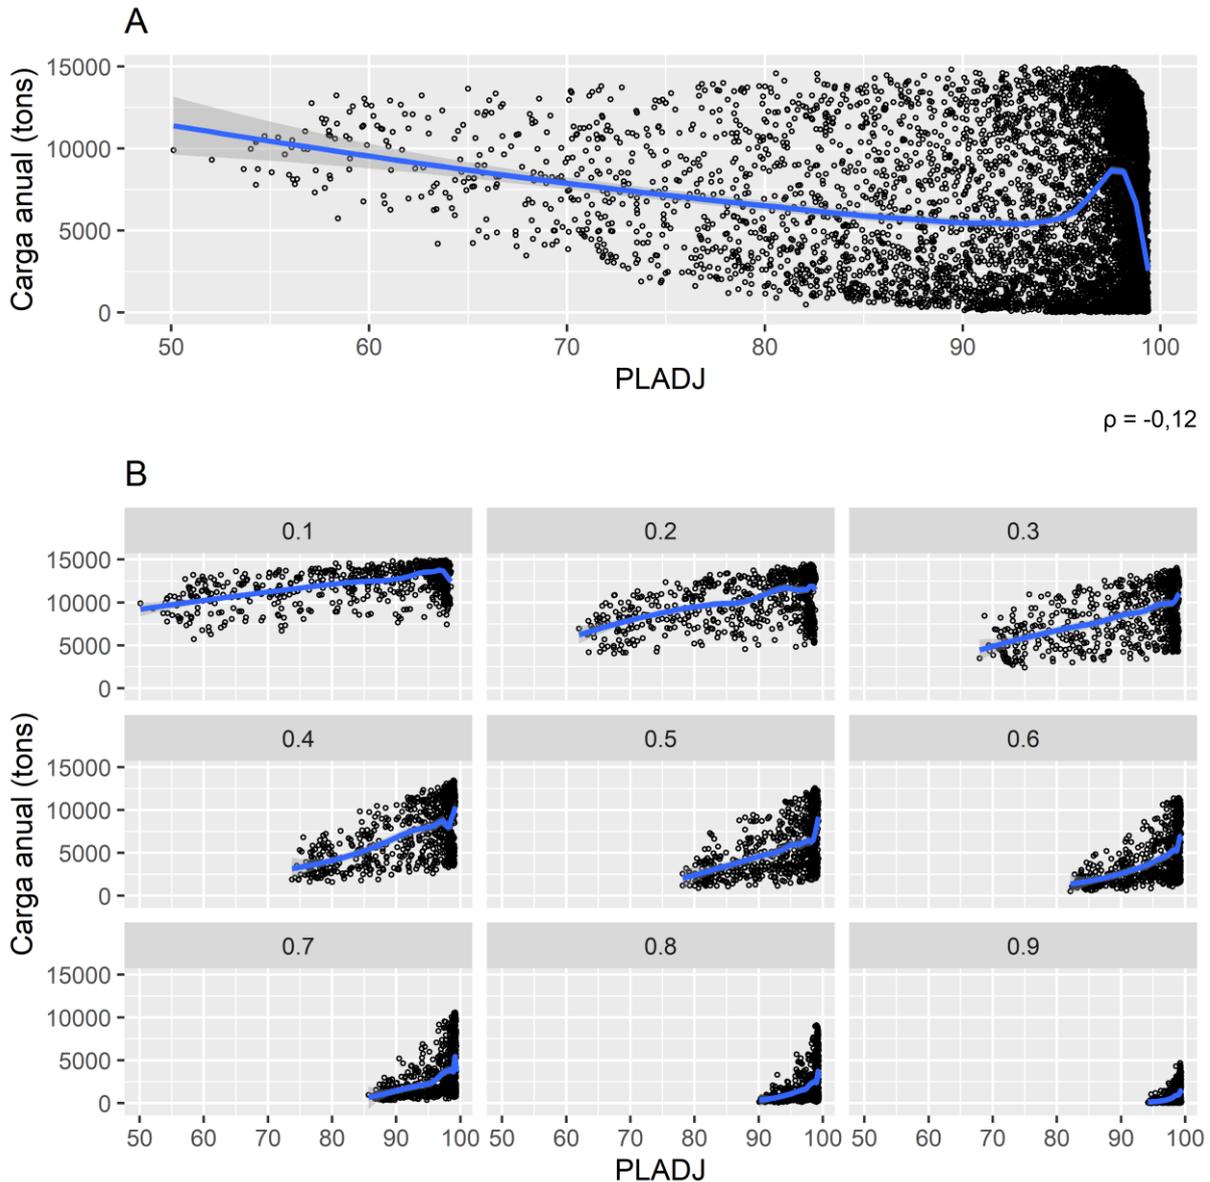
Treze métricas em nível de classe e quatro em nível de paisagem para o grupo MN apresentaram correlação forte ($\rho = |0,5|$) com a produção de sedimentos em pelo menos uma classe de percentual de floresta. Todas elas, com exceção de PLAND_zrip, exibiram um aumento na magnitude do grupo geral para os grupos de percentuais. Tiveram correlação positiva (classe) AI, CLUMPY, CONTIG_AM e PLADJ; e negativa ED, FRAC_AM, LSI, NLSI, PAFRAC, PARA_AM, PD_zrip, PLAND_zrip e SHAPE_AM. As métricas (paisagem) AI, CONTAG e PLADJ exibiram correlação positiva e LSI mostrou correlação negativa. Por outro lado, dentre as métricas de classe MNRipária, LPI e MESH apresentaram correlação positiva e DIVISION e SPLIT correlação negativa. Todas elas já haviam exibido correlação forte no grupo geral. Houve uma diminuição da magnitude das métricas em nível de paisagem do grupo geral para os grupos de percentuais, o contrário do observado nas paisagens MN.

Esses resultados indicam que a configuração pode exibir interdependência mais clara com a qualidade da água em paisagens sem a proteção florestal ripária e com quantidades fixas de floresta. Portanto, certos padrões associados à configuração em paisagens sem floresta ripária (MN) só podem ser observados ao se comparar paisagens com a mesma proporção de floresta. Por exemplo, as métricas ED e LSI exibiram correlação negativa e forte com a produção de sedimentos em paisagens com 60% de floresta, embora tenham tido correlação fraca no grupo geral. Isso significa que, em paisagens intermediárias sem proteção ripária, maior densidade de bordas está associada a melhor qualidade da água. A métrica PAFRAC, que apresentou correlação fraca no grupo geral, exibiu correlações negativas e fortes com a produção de sedimentos em sete dos nove níveis de percentuais de floresta. Consequentemente, manchas mais complexas e convolutas se associam com menor carga anual quando o fator composição é isolado. As métricas AI e PLADJ, que não se mostraram relevantes no grupo geral, correlacionaram positivamente com a carga anual em todas as classes de percentuais, indicando que uma floresta mais agregada está associada a um maior aporte de sedimentos.

A Figura 63 exemplifica como determinadas interdependências só são percebidas ao se isolar o elemento composicional, e como relações aparentemente não lineares se mostram lineares quando observadas por classes de percentual. No conjunto geral, PLADJ exibiu uma correlação negativa fraca com a carga anual. O gráfico de dispersão mostra que, ainda que a correlação seja negativa, há grande dispersão dos dados em torno de valores altos da métrica (Figura 63.A). Nesta região, a curva de suavização se torna ascendente antes de voltar ao padrão descendente. Por outro lado, ao se analisar a mesma relação por percentuais de floresta na

paisagem (Figura 63.B), a métrica exibe correlação positiva com a carga anual em todos os níveis.

Figura 63 – Gráficos de dispersão e suavizadores LOESS para a métrica PLADJ vs. as cargas anuais das paisagens MN do grupo geral (A) e por percentuais de floresta (B)



Fonte: elaborado pela autora.

Outro comportamento observado ao se avaliar as relações bivariadas foi a existência de sinais diferentes dos coeficientes obtidos para o grupo geral de paisagens e para os grupos de percentuais. Aqui foram destacadas apenas as métricas que exibiram correlação média ou forte em ambas as situações. No caso das métricas em nível de classe, AREA_AM, COHESION, LPI e MESH tiveram correlação negativa com a carga anual, porém positiva nos grupos de percentual de floresta. Por outro lado, DIVISION e SPLIT tiveram correlação positiva no grupo

geral, mas negativa nos grupos de percentual. GYRATE_AM apresentou correlação negativa e forte no grupo geral, mas ambas correlações positivas e negativas apareceram nos grupos de percentual. CIRCLE_AM teve comportamento semelhante ao de GYRATE_AM, mas somente no conjunto MNRipária. Para as métricas em nível de paisagem, DIVISION, MESH e SPLIT do grupo MNRipária apresentaram sinais diferentes entre grupo geral e grupos de percentual.

Esses resultados sugerem que, considerando todos os níveis de percentual e rugosidade, paisagens com manchas maiores correlacionam fortemente com menor carga de sedimentos. Porém, ao se manter a quantidade de floresta constante, paisagens com manchas maiores passam a ser associadas com maior carga de sedimentos. Da mesma forma, o índice COHESION evidencia que uma floresta agrupada se associa com menor produção de sedimentos, enquanto o oposto ocorre quando a proporção de floresta se mantém constante - floresta agrupada passa a ser associada com maior carga anual. No grupo geral, à medida que a maior mancha ocupa a maior parte da paisagem, menor é a produção de sedimentos, porém, o oposto é verificado nos grupos de percentuais. O comportamento de DIVISION, MESH E SPLIT, que são perfeitamente correlacionadas, mostra que no grupo geral uma paisagem mais subdividida em manchas menores está associada a maior carga de sedimentos. Porém, nas classes de percentuais, as paisagens mais subdivididas estão associadas a menor carga. Novamente, a influência da composição é destacada, e constata-se que determinados padrões de configuração só poderiam ser observados com clareza em paisagens com a mesma quantidade de floresta.

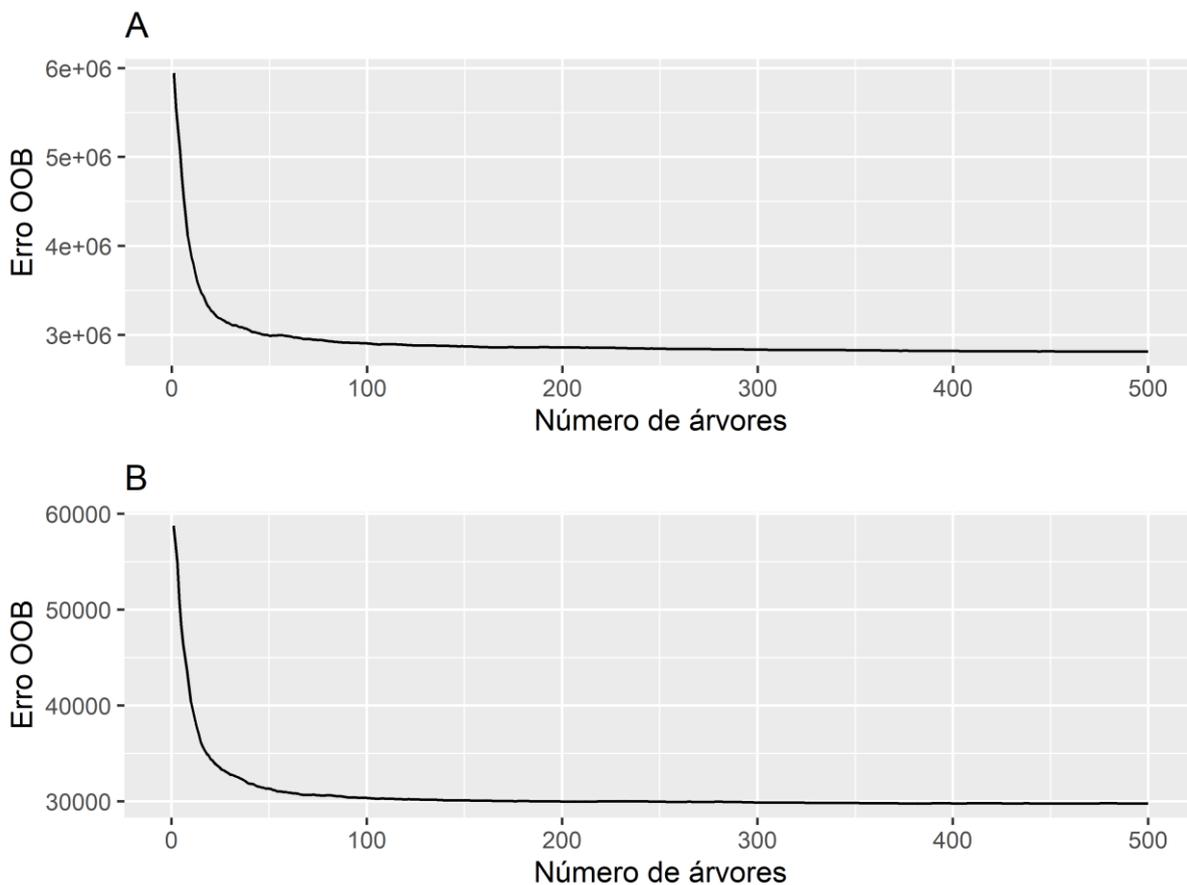
Em suma, os resultados para esta abordagem por percentual de floresta sugerem que, quando a quantidade de floresta na bacia é fixa, estão associadas a uma menor carga de sedimentos as paisagens MN cuja floresta está menos agregada, possui maior densidade de borda, manchas de forma mais irregular e menos contígua, e cuja zona ripária possui maior proporção de florestas e maior número de fragmentos. Quando a quantidade de floresta é fixa, paisagens MNRipária com a menor porcentagem da sua área ocupada pela maior mancha e com floresta menos agregada estão associadas a um menor aporte de sedimentos. Esses resultados reforçam a necessidade de se avaliar a relação entre padrão da paisagem e qualidade da água tendo em vista as quantidades de coberturas.

3.6 Métricas de paisagem como variáveis preditoras da produção de sedimentos

Após testar diferentes números de preditores selecionados aleatoriamente para divisão binária recursiva no algoritmo de floresta aleatória, o valor que resultou em menor erro OOB

foi $mtry = 2*(p/3)$. Nesse sentido, 28 e 24 preditores selecionados aleatoriamente foram utilizados na geração das árvores das florestas aleatórias para MN e MNRipária, respectivamente. Os gráficos a seguir (Figura 64) representam o erro de predição, calculado por meio das observações OOB, em função do número de árvores criadas para o conjunto das florestas aleatórias. Como pode-se observar, o erro de predição decai à medida que mais árvores são adicionadas ao conjunto e se estabiliza em torno de 300, o que demonstra que a quantidade de árvores geradas em cada floresta aleatória foi suficiente.

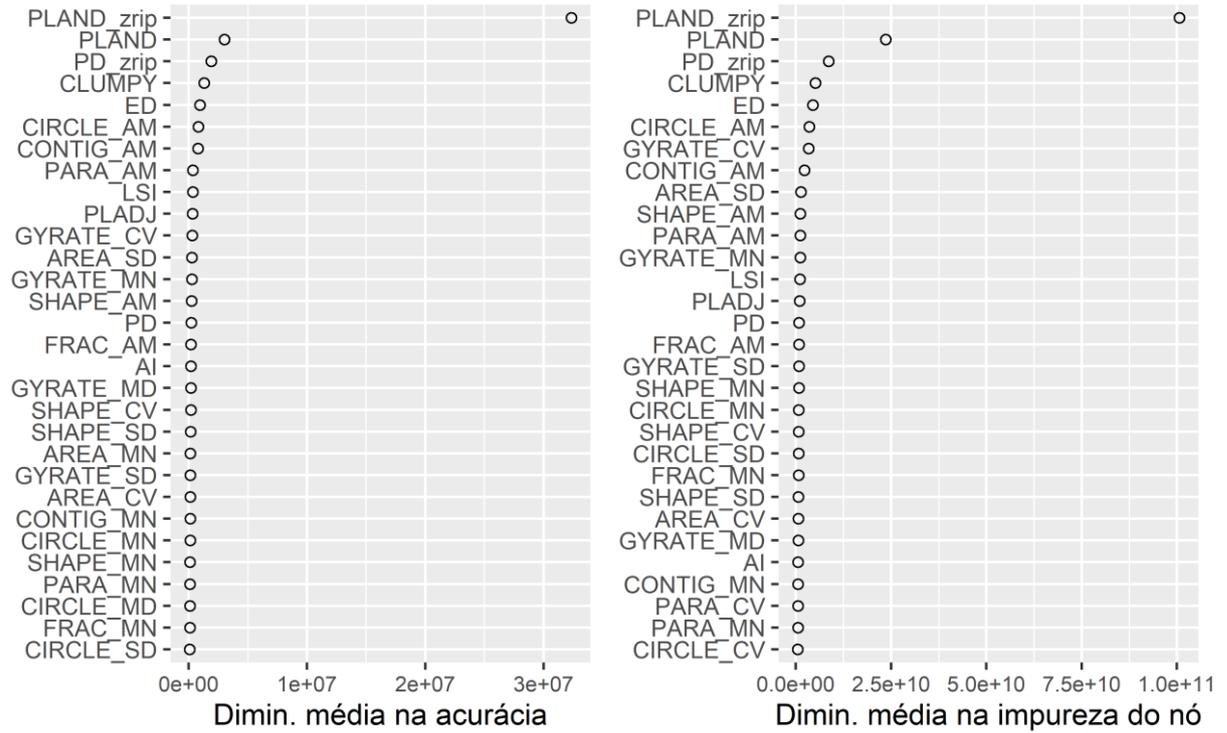
Figura 64 – Erro de predição (OOB) em função do número de árvores de regressão nas florestas aleatórias das paisagens MN (A) e MNRipária (B)



Fonte: elaborado pela autora.

As medidas de importância das variáveis indicam que, para MN, a proporção de floresta na zona ripária e na bacia hidrográfica é o fator mais relevante para a predição da carga anual de sedimentos (Figura 65). Em seguida, aparecem as métricas de configuração em menor grau de importância e com desempenho semelhante como preditores. Destacaram-se as métricas de configuração PD_zrip, CLUMPY e ED como possíveis variáveis predictoras.

Figura 65 – Importância das métricas da cobertura florestal para a predição das cargas anuais (tons) das paisagens MN

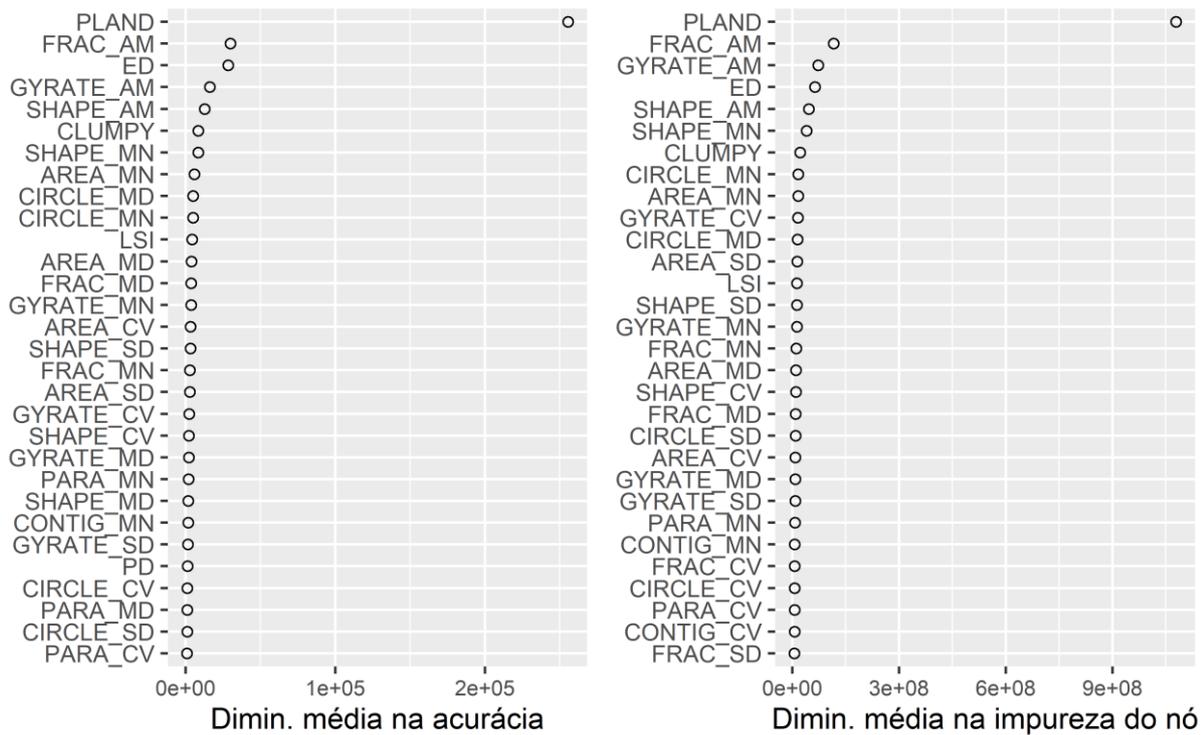


Fonte: elaborado pela autora.

Notas: são exibidas apenas 30 métricas em ordem decrescente de importância.

O quadro foi semelhante para as paisagens MNRipária, em que houve uma importância destacada da porcentagem de paisagem e uma menor importância das métricas de configuração (Figura 66). As medidas apresentaram resultados semelhantes, e as posições superiores do ranqueamento são ocupadas pelas métricas de configuração FRAC_AM, ED e GYRATE_AM.

Figura 66 – Importância das métricas da cobertura florestal para a predição das cargas anuais (tons) das paisagens MNRipária



Fonte: elaborado pela autora.

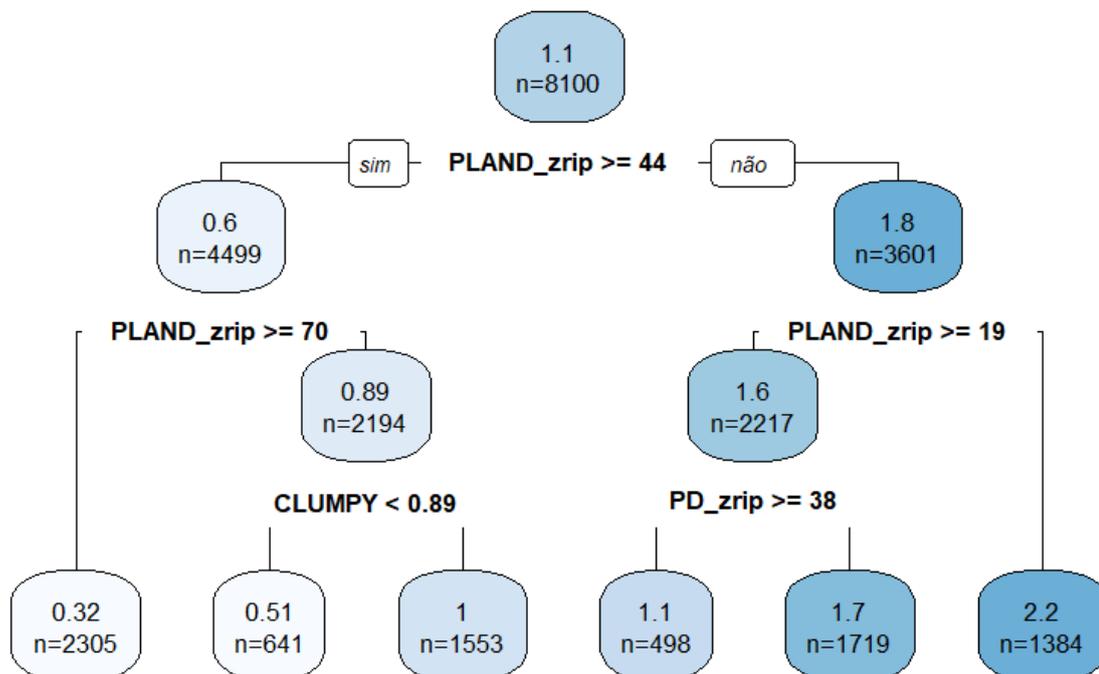
Notas: são exibidas apenas 30 métricas em ordem decrescente de importância.

As árvores de regressão obtidas para as paisagens MN e MNRipária se encontram na Figura 67 e Figura 69, respectivamente. As árvores mais completas foram apresentadas, visto que a abordagem de poda por custo-complexidade determinou que as árvores com maior número de nós-folha tiveram melhor desempenho (APÊNDICE E). As caixas azuis representam os nós, onde estão inseridos os valores médios da carga anual em tons/ha e a quantidade de paisagens em cada grupo. À medida que as cargas anuais médias aumentam, a cor azul fica mais escura. O nó no topo da árvore (i.e., o nó-raiz) inclui todas as paisagens ($n = 8.100$), enquanto os nós terminais (i.e., os nós-folha) representam os grupos mais homogêneos obtidos pelo algoritmo. A variável preditora e o valor de corte utilizado para divisão dos dados se encontram logo abaixo de cada nó. Para interpretar a árvore, basta avaliar como a observação atende ao critério de divisão (i.e., sim ou não) que consta no nó-raiz e seguir o fluxo de decisão para a esquerda ou direita até atingir um dos nós-folha.

Para a árvore de MN foram obtidos seis nós-folha, ou seja, o conjunto de dados foi particionado em seis grupos em que as paisagens de cada um exibem valores mais semelhantes para as cargas anuais. As divisões binárias foram ditadas por três métricas, PLAND_zrip e PD_zrip, que são medidas em escala de zona ripária, e CLUMPY, medida em escala de bacia

hidrográfica. Essas métricas também exibiram alta posição de importância para a predição das cargas anuais segundo o algoritmo de floresta aleatória (Figura 65). Os índices de configuração não apresentaram correlação média ou forte com a proporção de florestas na bacia e na zona ripária – $\rho = -0,17$ e $\rho = -0,01$ para CLUMPY e PD_zrip, respectivamente – embora sejam correlacionados entre si ($\rho = -0,85$). PLAND_zrip é fortemente correlacionada com PLAND na bacia, enquanto PD_zrip correlaciona forte com ED na bacia. Ambas PLAND e ED foram consideradas pelo algoritmo como variáveis substitutas (*surrogates*) (STROBL; MALLEY; TUTZ, 2009). Isso significa que, na ausência de valores para PLAND_zrip, a proporção na bacia pode ser utilizada para predição das observações no nó. Da mesma forma, na ausência de valores para PD_zrip, ED para a bacia pode ser utilizada na predição. Segundo a interpretação de CLUMPY, valores menores e maiores indicam, respectivamente, uma classe menos e mais agregada. Por outro lado, quanto maior a densidade de manchas (PD_zrip), mais desagregada a classe se encontra.

Figura 67 – Árvore de regressão para a variável dependente produção de sedimentos ($\text{tons} \cdot \text{ha}^{-1} \cdot \text{ano}^{-1}$) em função das métricas de paisagem para o grupo MN



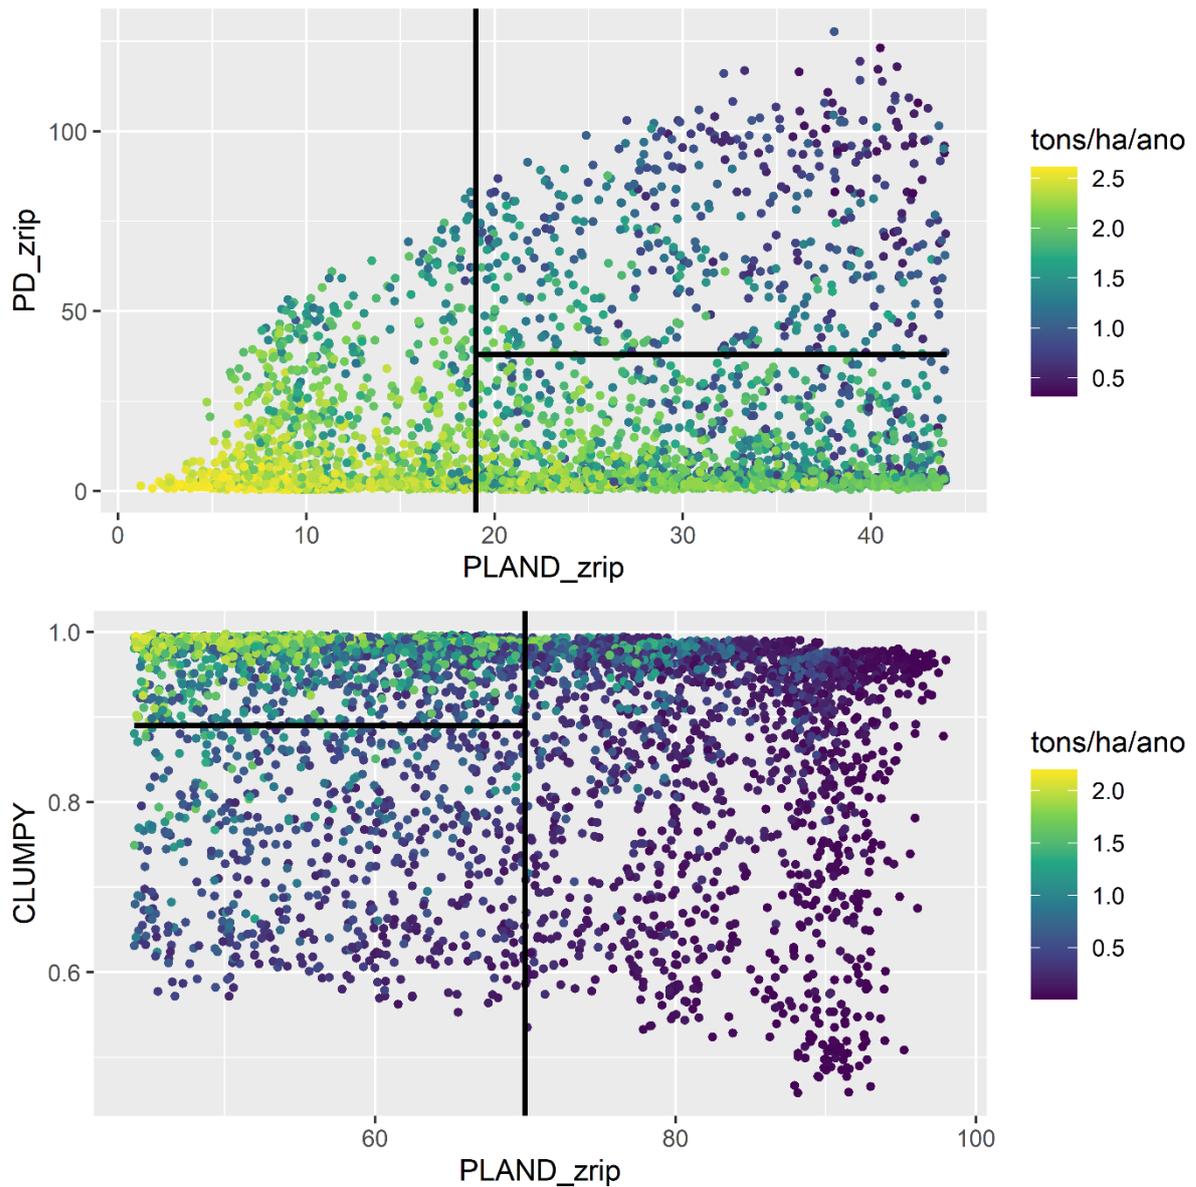
Fonte: elaborado pela autora.

Segundo a árvore de regressão para o grupo MN, o preditor mais importante é PLAND_zrip, que está situado no nó-raiz e particiona os dados em dois grupos com porcentagens de floresta na zona ripária maiores e menores que 44%. Em paisagens cuja zona

ripária está coberta com floresta em porcentagens acima de 70%, este índice é suficiente para predição do valor médio das cargas anuais, que é o menor do conjunto ($0,32 \text{ tons.ha}^{-1}.\text{ano}^{-1}$). Da mesma forma, para paisagens com porcentagens de floresta na zona ripária inferiores a 19%, esse índice também é suficiente para predição, e as cargas anuais apresentam a maior média do conjunto ($2,2 \text{ tons.ha}^{-1}.\text{ano}^{-1}$). A importância das métricas de configuração CLUMPY e PD_zrip, que representam a agregação das florestas, despontou nas paisagens com coberturas florestais intermediárias, isto é, entre 44% e 69% e entre 19% e 43%. Uma maior desagregação das florestas está associada a menores cargas anuais ($0,51$ e $1,1 \text{ tons.ha}^{-1}.\text{ano}^{-1}$, respectivamente) em ambos os intervalos percentuais. O pacote *rpart* também forneceu um gráfico em que um valor de R^2 aproximado é plotado em função das divisões na árvore (APÊNDICE E). Verifica-se que a primeira divisão, situada no nó raiz, fornece a maior fonte de informação para explicar a produção de sedimentos, pois $R^2 = 0,55$ de um total de $R^2 = 0,73$ para toda a árvore.

A Figura 68 abaixo ilustra os seis grupos obtidos pela partição binária recursiva dos dados de cargas anuais para as paisagens MN. Os segmentos de reta pretos delimitam o limiar de divisão para o preditor e os pontos representam as paisagens escalonadas por cor conforme a carga anual observada em tons/ha.

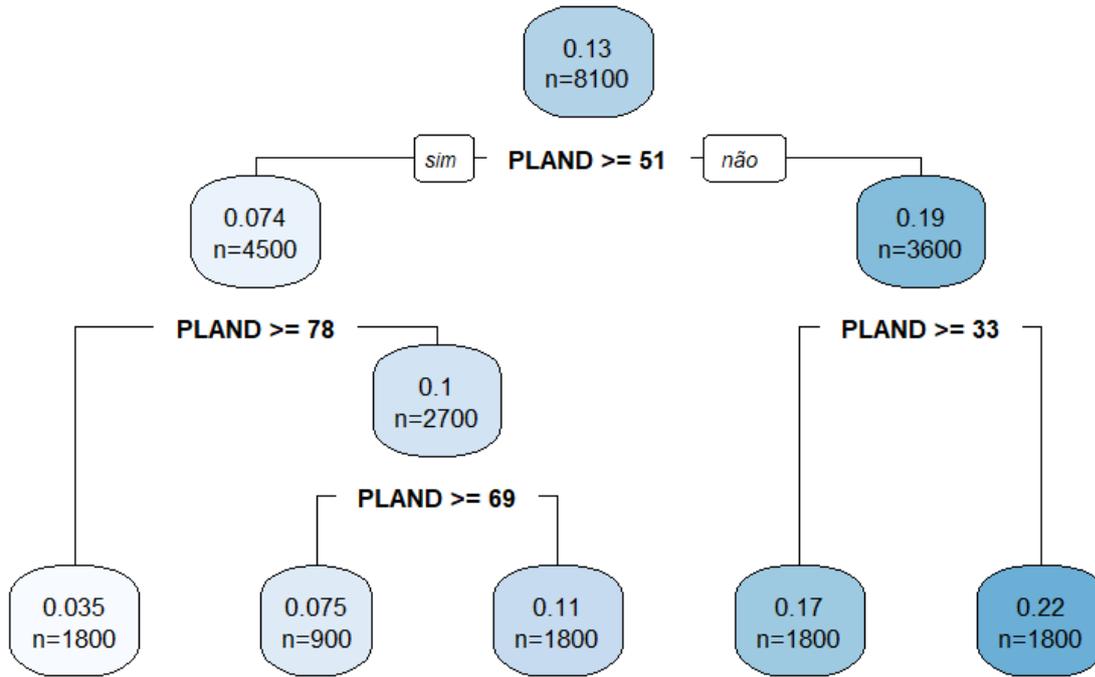
Figura 68 – Representação dos seis grupos homogêneos de paisagens MN obtidos pela divisão binária recursiva realizada pela árvore de regressão



Fonte: elaborado pela autora.

Foram obtidos cinco nós-folha para a árvore de MNRipária, porém, somente a métrica PLAND foi estimada como critério de particionamento das paisagens em grupos homogêneos de cargas anuais (Figura 69). Isso indica que a proporção de florestas na bacia hidrográfica é suficiente para prever a qualidade da água quando há uma faixa ripária florestal fixa.

Figura 69 – Árvore de regressão para a variável dependente produção de sedimentos ($\text{tons}\cdot\text{ha}^{-1}\cdot\text{ano}^{-1}$) em função das métricas de paisagem para o grupo MNRipária



Fonte: elaborado pela autora.

4 DISCUSSÃO

A calibração satisfatória do modelo SDR foi obtida utilizando os parâmetros $k_b = 0,8$ e $IC0 = 0,25$, valores inferiores ao padrão sugerido pelo modelo (i.e., $k_b = 2,0$ e $IC0 = 0,5$) e aos usados por outros estudos como Hamel et al. (2015) e Hamel et al. (2020)¹¹. Consequentemente, a taxa de entrega de sedimentos na sub-bacia do Alto Corumbataí em 2019 foi relativamente baixa¹², o que resultou em 0,37% do solo erodido atingindo o estuário, ou seja, 7 tons/km². O valor reduzido para a taxa de entrega de sedimentos pode ser devido: i) às propriedades topográficas da bacia e à configuração dos usos e coberturas do solo em 2019; ii) a uma superestimação da perda potencial do solo na bacia pela RUSLE, ou iii) a uma subestimação dos valores observados utilizados na calibração. Dada a natureza negativa do IC na área de estudo, a redução do valor de parâmetro de calibração k_b foi feita de forma a atingir uma equivalência entre valores observados e simulados.

As incertezas na estimação da RUSLE se devem à dificuldade em capturar as interações complexas que modulam a perda do solo, a baixa disponibilidade de dados de qualidade em longo prazo para a modelagem, e falta de dados observados para validação do modelo (BENAVIDEZ et al., 2018). É importante destacar que a RUSLE não é explicitamente baseada em processos hidrológicos e erosivos, mas sim uma equação empírica derivada de dados experimentais (RENARD et al., 1991) e apropriada para prever a perda de solo anual em condições médias e de longo prazo (RENARD; FREIMUND, 1994). Por ser simples e baseada em poucos parâmetros, é demasiadamente sensível aos dados de entrada, podendo gerar diferentes valores preditos (SHARP et al., 2020). O modelo InVEST SDR em especial se mostra bem sensível aos fatores erosividade da chuva e erodibilidade do solo (SÁNCHEZ-CANALES et al., 2015; HAN et al., 2020). A definição dos valores de entrada foi feita a partir da literatura, onde foi verificada uma grande variação destes parâmetros entre os estudos, principalmente da erodibilidade e do coeficiente de uso e manejo do solo. Dessa forma, optou-se por utilizar dados de um mínimo de fontes possível (i.e., trabalhos de revisão e situados em regiões próximas à área de estudo) de forma a manter a proporcionalidade entre as medidas. Ainda assim, esses valores introduzem incerteza às predições, inclusive por meio da resolução das informações

¹¹ Valores reportados por estes estudos para k_b variaram de 1,6 a 3,5.

¹² Para fins comparativos, estimativas para outros estudos com o InVEST SDR foram de 3,6% a 26% para sub-bacias na Etiópia (áreas de 48 km² a 192 km² e 1426 km²) (ANESEYEE et al., 2020; DEGIFE; WORKU; GIZAW, 2021), 7,7% para uma microbacia (75 km²) em São Pedro – SP (ROSÁRIO; GUIMARÃES; VIANI, 2019), e 6,1% até 10,5% utilizando diferentes parametrizações para a sub-bacia das Posses (12 km²) em Extrema – MG (SAAD et al., 2018).

utilizadas como dados de entrada (SHEN et al., 2013). A quantidade de estações pluviométricas empregadas no cálculo da erosividade em uma área e a resolução do MDE, por exemplo, despontam como fatores introdutores de incerteza (WANG; WU; HU, 2015). A erosividade, que originalmente é derivada a partir da quantidade e intensidade da chuva (RENARD, 1991), é difícil de se estimar em razão da escassez de dados pluviográficos no Brasil. Nesta pesquisa, uma equação que relaciona o índice de erosividade com a precipitação em outra localidade foi empregada, o que pode gerar mensurações super ou subdimensionadas (OLIVEIRA; WENDLAND; NEARING, 2012).

A escassez de dados observados para validação não ocorre somente na área de estudo, visto que apenas 30% das aplicações da RUSLE estudadas por Benavidez et al. (2018) fizeram a comparação com os dados observados. Além da escassez, há fontes de incerteza na mensuração de dados observados de qualidade da água no que se refere à medição da vazão, coleta e preservação das amostras, análise laboratorial e processamento e gestão dos dados (HARMEL et al., 2009). Neste trabalho, os procedimentos utilizados para o cálculo da carga anual observada a partir dos sólidos suspensos constitui uma das maiores fontes de incerteza. Como a RUSLE estima a produção de sedimentos anual média, o valor observado deve representar bem essas condições em um determinado ano. No entanto, as cargas anuais foram estimadas a partir de seis coletas, número insuficiente para representar adequadamente as condições médias de produção de sedimentos na bacia (BENAVIDEZ et al., 2018). Períodos curtos de medição podem deixar de fora ou abranger um excesso de eventos extremos (ALEWELL et al., 2019). Nestes casos, as estimativas da RUSLE parecerão superestimadas ou subestimadas em relação aos valores observados, respectivamente (ALEWELL et al., 2019). Além disso, devido à ausência da medida de vazão no momento da coleta, para muitas observações a carga foi calculada considerando a vazão média diária, o que pode ter levado à sua super ou subestimação. Conseqüentemente, a discrepância observada na série temporal prejudicou a calibração do modelo SDR, o que exigiu a eliminação de alguns anos com valores extremos para se obter um ajuste ao menos satisfatório. Entretanto, esse procedimento é justificável no caso de problemas com a mensuração dos dados (ZUUR; IENO; ELPHICK, 2010), fato que ocorreu para a série histórica da sub-bacia do Alto Corumbataí.

Mesmo diante das incertezas descritas acima, o modelo se mostrou aceitável para o propósito da pesquisa, isto é, a exploração e, eventualmente, o planejamento. Para essas finalidades as incertezas são admissíveis, desde que apreciadas, visto que a meta é comparar cenários e não necessariamente obter estimativas com acurácia e precisão (HARMEL et al., 2014). O InVEST SDR foi capaz de capturar diferenças nas quantidades e configurações dos

usos e coberturas do solo, assim como observado por Hamel et al. (2015). Consequentemente, a modelagem se confirmou como adequada para testar teorias e comparar cenários de estratégias de conservação (DE VENTE et al., 2013; ALEWELL et al., 2019). No entanto, ainda que os dados relativos sejam adequados para comparações de paisagens, a tomada de decisão poderá exigir estimativas brutas mais próximas da realidade (REDHEAD et al., 2018).

Ao se comparar diferentes cenários da paisagem, foi verificada uma maior amplitude de cargas anuais para os grupos sem faixa ripária florestal fixa. Logo, o modelo sugere que a implantação dessas faixas ao longo da drenagem da bacia estudada poderia reduzir em até 90% o aporte de sedimentos na água, sendo a estratégia mais vantajosa. A diferença entre as médias dos grupos sem e com faixa ripária de 30 m foi significativa mesmo para os grupos em que houve disposição da floresta de forma aleatória. De fato, os *buffers* ripários são importantes preditores do aporte de sedimentos, ainda mais do que da concentração de nutrientes (DIEBEL, 2009). No entanto, esse resultado se deve a uma particularidade do modelo, visto que as áreas mais críticas para a entrega de sedimentos se situam no entorno da drenagem, e muitas apresentam valores extremos. Por conseguinte, a proteção dessas áreas leva à redução desses valores, neutralizando sua influência na exportação de sedimentos. Chaplin-Kramer et al. (2016) utilizaram o modelo SDR e constataram que um cenário sem proteção ripária exporta cerca de 80-90% a mais de sedimentos. Por outro lado, dados experimentais coletados por Gumiere et al. (2011) apontam uma eficiência de remoção entre 24% e 100%, e Diebel (2009) estimou em média que 70% da carga de sedimentos poderia ser barrada por *buffers* ripários. Nesse sentido, esse potencial de retenção irá variar localmente de acordo com outros fatores que também influenciam a taxa de entrega de sedimentos, como a topografia, tipo e umidade do solo, presença de vegetação nativa, intensidade e quantidade da chuva, e práticas de manejo (GUMIERE et al., 2011).

Esses resultados não só reforçam o papel dessas faixas de vegetação nas zonas ripárias como elementos filtrantes da poluição difusa (DOSSKEY et al., 2010; COLE; STOCKAN; HELLIWELL, 2020), mas fornecem evidências sobre a configuração das florestas que não são mensuradas diretamente por métricas tradicionais da ecologia da paisagem. A localização das faixas de vegetação em uma bacia é um dos fatores cruciais que determinam a conectividade sedimentológica, ou seja, o padrão de transferência física de sedimentos na bacia (GUMIERE et al., 2011). Evidências sugerem que, quanto maior a distância das florestas até o riacho, maior a concentração de sedimentos na água (MORI et al., 2015). Chaplin-Kramer et al. (2016) detectaram que a conversão da vegetação natural em agricultura feita a partir das margens dos riachos gerou cinco vezes mais sedimentos do que aquela feita a partir das áreas mais altas.

Além disso, o cenário com proteção ripária contava com um *buffer* de apenas um pixel de 90 m, sugerindo que pouca quantidade de vegetação pode ter um desempenho satisfatório para a retenção dos sedimentos (CHAPLIN-KRAMER et al., 2016). Gumiere et al. (2011) não notaram relação significativa entre largura dos *buffers* e sua eficiência, sugerindo também que uma pequena quantidade de vegetação seria capaz de capturar a maior parte do solo erodido. De fato, revisões bibliográficas têm mostrado que faixas estreitas, e.g., de 10 até 30 m, seriam capazes de regular eficientemente a concentração de sedimentos e nutrientes na água (SWEENEY; NEWBOLD, 2014; LIND; HASSELQUIST; LAUDON, 2019). No entanto, Pissarra et al. (2019) e Valera et al. (2019) notaram que, para as condições brasileiras, *buffers* menores que 45 a 90 m podem ser insuficientes para garantir uma boa qualidade da água considerando múltiplos indicadores. Dessa forma, a variação no aporte de sedimentos poderia ser explicada melhor pela localização da expansão agrícola na bacia hidrográfica do que pela configuração da vegetação mensurada em termos globais para a bacia. Mais especificamente, é essencial considerar a distância das fontes de sedimentos em relação à água. Os resultados para o grupo de planejamento focado somente na zona ripária revelaram que, de fato, quanto mais próxima da drenagem, maior a relevância da parcela para a retenção de sedimentos (GUMIERE et al., 2011). Gergel (2005) já havia sugerido que indicadores de paisagem deveriam se basear mais em processos, como as rotas de fluxo na paisagem ou a capacidade de retenção das coberturas, em vez de somente na composição.

Ainda que a implantação da faixa florestal na zona ripária tenha se destacado como a medida mais efetiva, os dados simulados mostraram o potencial de se agregar diferentes estratégias para atingir cargas anuais satisfatórias, como o florestamento da bacia de forma aleatória ou das superfícies mais íngremes. Esse exercício pode ser incorporado ao processo de desenho de paisagens, em que alterações intencionais são executadas buscando a provisão e conservação de serviços ambientais desejados e em consonância com as necessidades e valores da sociedade (NASSAUER; OPDAM, 2008). Neste processo, o conhecimento científico e das partes interessadas são agregados, transferidos para o contexto local e apreciados para definir de forma transparente um conjunto de estratégias a serem implementadas em uma paisagem visando atingir metas específicas (NASSAUER; OPDAM, 2008). A inclusão das partes interessadas é essencial para agregar não só o conhecimento local, mas também para compatibilizar as estratégias com as outras funções desenvolvidas na área rural (STEINGRÖVER; GEERTSEMA; VAN WINDERGEN, 2010), visto que o melhor desenho da paisagem não é aquele definido apenas pelo critério ecológico (VOS et al., 2007). Bartuszevige et al. (2016) aplicaram uma série de passos para o desenho de paisagens que

podem ser adaptados para o contexto da retenção de sedimentos: i) definir em conjunto com a rede de partes interessadas uma meta a ser atingida; ii) avaliar o cenário atual, considerando processos e vetores que influenciam o padrão da paisagem; iii) fazer previsões com apoio das partes interessadas sobre quais processos e vetores serão de importância no futuro; iv) modelar esses fatores e projetar essa paisagem futura de forma a identificar áreas e prioridades de ação; v) selecionar as estratégias a serem aplicadas com base nos dados do cenário atual e futuro; vi) executar o desenho da paisagem.

É importante destacar que as recomendações para o planejamento das paisagens concebidas neste trabalho consideram apenas os benefícios para a qualidade da água do ponto de vista do aporte de sedimentos e não abrangem outros serviços ambientais prestados pelas florestas. Os requisitos da paisagem para aprimorar os serviços prestados pela biodiversidade podem ser diferentes ou mesmo contrários aos indicados neste trabalho. As faixas ripárias, por exemplo, possuem múltiplas funções e fornecem diversos benefícios com mais eficiência quando são mais largas (COLE; STOCKAN; HELLIWELL, 2020). Ainda que faixas ripárias estreitas sejam capazes de mitigar eficientemente o aporte de nutrientes e sedimentos, a proteção de outros serviços ambientais e da biodiversidade irão exigir faixas mais largas (LIND; HASSELQUIST; LAUDON, 2019; LUKE et al., 2019). A partir de uma revisão bibliográfica, Lind, Hasselquist e Laudon (2019) sugerem *buffers* de pelo menos 25 m para a proteção da flora, peixes e insetos; 53 m para mamíferos e anfíbios; e 144 m em média para proteção de aves. Cole et al. (2015) identificaram que *buffers* ripários mais largos favorecem positivamente a diversidade e abundância de insetos polinizadores. Em ambientes tropicais, a proteção da biodiversidade terrestre animal e vegetal pode demandar faixas ripárias de cerca de 100 m ou mais (LUKE et al., 2019).

O uso da terra a montante também deve ser considerado para avaliar a efetividade das faixas ripárias em proteger as funções aquáticas e a biodiversidade terrestre (LUKE et al., 2019). O modelo utilizado foca apenas na erosão em sulcos e entressulcos, não simulando processos erosivos em ravinas, erosão fluvial e movimentos de massa. Portanto, as cargas brutas e relativas dos cenários avaliados não consideram esses eventos. Bacias com baixa cobertura florestal nas vertentes, ainda que disponham de largas faixas ripárias, irão experimentar impactos decorrentes desses processos erosivos não modelados. A erosão em ravinas, por exemplo, costuma ocorrer principalmente em áreas com declividade íngreme e solos arenosos, sendo desencadeada ou intensificada por cultivos agrícolas inapropriados e eventos extremos de chuva (VALENTIN; POESEN; LI, 2005). A colheita e o preparo da terra reduzem a biomassa vegetal e a resistência do solo superficial à erosão, o que favorece o surgimento de

ravinas (POESEN et al., 2003). Outro impacto desses processos erosivos é o aumento da conectividade sedimentológica na bacia, o que beneficia a entrega do solo desprendido pela erosão em sulcos e entressulcos (POESEN et al., 2003). Nesse sentido, os cenários devem ser apreciados tendo em conta essas incertezas em relação às fontes de sedimentos simuladas, as necessidades para a geração de serviços hidrológicos dependentes de outros atributos da água, e os requisitos de provisão de outros serviços ambientais.

As paisagens de modelos neutros apresentaram maior frequência de valores altos e baixos e menor frequência de valores intermediários de produção de sedimentos. Esse padrão é um reflexo da concentração das menores e maiores cargas nos percentuais extremos e da distribuição bimodal das cargas nas classes intermediárias de floresta. Houve grande dispersão das cargas em relação à média dos cenários, sendo que a variância foi a menor nos extremos de percentual e teve pico em 40% no grupo MN e em 50% no grupo MNRipária. Esses resultados apoiam os de Gergel (2005), em que a variância para paisagens simuladas teve pico em 35% e foi menor em valores extremos de coberturas que retém poluentes. Consequentemente, a configuração parece ser mais relevante em bacias com porcentagens intermediárias de coberturas (GERGEL, 2005; CLÉMENT et al., 2017). No modelo heurístico usado por Gergel (2005), a média e a variância decaíram drasticamente e permaneceram próximas de zero a partir de 70% de coberturas-sumidouro, enquanto neste trabalho as medidas se apresentaram como uma função linear e quadrática, respectivamente, da proporção de florestas. Outra diferença nesta pesquisa foram as variâncias de grande magnitude em relação às médias das paisagens. Esse resultado é reflexo da posição das manchas na paisagem, o que indica que simulações sob uma topografia realística trazem resultados mais adequados para a modelagem de serviços hidrológicos (THOMAS et al., 2020). Não obstante, os resultados demonstram que a simulação da estrutura da paisagem acoplada a modelos hidrológicos de base física fornece evidências sobre padrões de médias e variâncias de cargas de poluentes semelhantes às obtidas para paisagens totalmente aleatórias, com fluxo unidirecional e relevo uniforme.

Tanto a porcentagem de floresta quanto a autocorrelação espacial apresentaram tamanho de efeito negativo, ou seja, maior porcentagem e desagregação de florestas se associaram com menor carga anual de sedimentos, havendo também uma sinergia entre esses dois fatores (THOMAS et al., 2020). Limiares para a relação entre produção de sedimentos e proporção de florestas não foram detectados, visto que tanto as cargas observadas quanto as cargas médias decaem como uma função linear à medida que a porcentagem de floresta aumenta. Nesse sentido, os dados simulados não sugerem a existência de um ponto em que há uma mudança abrupta no aporte de sedimentos. Os resultados obtidos indicam que nem sempre a perda bruta

de cobertura e a fragmentação resultarão em prejuízos imediatos aos serviços ambientais de regulação que dependem do movimento da matéria na paisagem (MITCHELL; BENNETT; GONZALEZ, 2015). Ainda que tenha se correlacionado fortemente com vários índices da paisagem (e.g. ED, PARA_MN, PD), a autocorrelação espacial não representa totalmente as diferentes configurações de floresta. Variações nos valores das métricas foram observados em grupos homogêneos de porcentagem de floresta e rugosidade, e paisagens com o mesmo valor para uma métrica resultaram em diferentes cargas anuais. Como já explorado, essa variação pode ser explicada pela posição que os fragmentos florestais assumem em relação aos caminhos de fluxo na bacia (THOMAS et al., 2020).

A proporção de florestas explicou a maior parte da variação nas cargas anuais médias (49% a 55%), e essa fração foi maior no grupo com a proteção da faixa ripária. A autocorrelação espacial explicou uma proporção pequena (2% a 7%), e essa fração foi maior no grupo sem a proteção da faixa ripária. Esses resultados corroboram que ambas composição e configuração afetam a qualidade da água (QIU, 2019). Dessa forma, a gestão da paisagem voltada para o atributo de qualidade da água deve considerar não só a quantidade de coberturas, mas também sua configuração espacial (MITCHELL; BENNETT; GONZALEZ, 2015; THOMAS et al., 2020). Além disso, os resultados apontam que a proporção tem maior relevância em determinar a qualidade da água nas paisagens com a zona ripária protegida, enquanto a autocorrelação espacial tem maior importância para as paisagens desprotegidas. Esses resultados sugerem que, em bacias sem a proteção ripária, a floresta deve ser disposta de forma que seja uma barreira ao aporte dos sedimentos na água. Por outro lado, quando a zona ripária já está protegida, o grau de fragmentação da floresta na bacia é pouco relevante e aumentar a sua proporção tem como principal objetivo reduzir a erosão do solo que pode ser carregada até a água. De fato, Valera et al. (2019) concluem que a implantação de faixas ripárias largas é insuficiente para garantir a qualidade da água de forma global, sendo necessário manter maiores quantidades de floresta na bacia.

Nas paisagens sem a faixa florestal, o tamanho de efeito da autocorrelação espacial na média de sedimentos foi maior nas baixas porcentagens de floresta do que nos percentuais intermediários. Ou seja, quando há pouca floresta na bacia, o valor adotado para a autocorrelação espacial tem maior relevância na diferença entre as médias. Nos percentuais intermediários, a rugosidade tem um menor peso em diferenciar as médias, o que sugere a importância de outros aspectos da configuração da paisagem que não são capturados somente pelo valor de autocorrelação espacial. Esses resultados demonstram que é possível modificar a configuração das florestas sem alterar drasticamente sua quantidade de forma a melhorar a

qualidade da água (DING et al., 2016). A porcentagem de floresta, por sua vez, teve maior tamanho de efeito quando a desagregação é máxima (*roughness* = 0,9). Consequentemente, quando a fragmentação é alta, a proporção tem maior relevância na diferenciação das médias. Nesse sentido, mesmo que a desagregação da floresta seja aumentada por meio da implantação de pequenos fragmentos, esse fator isoladamente pode ser insuficiente para melhorar a qualidade da água, sendo necessário aumentar a cobertura florestal de forma expressiva (QIU; TURNER, 2015).

A análise exploratória das métricas de paisagem demonstrou que há uma grande correlação entre os índices, e destes com os argumentos geradores dos modelos neutros – porcentagem e rugosidade. Consequentemente, métricas de configuração correlacionadas fortemente com a produção de sedimentos exibiram forte correlação com a proporção, o que indica uma interdependência das cargas anuais com a composição e não com a configuração. As métricas de paisagem geralmente são colineares (KEARNS et al., 2005) e seus valores e variação são intensamente afetados pela composição e configuração que moldam os processos na paisagem (REMMEL; CSILLAG, 2003). Dessa forma, o efeito da configuração se confunde com o da composição (LAMY et al., 2016). Essa abordagem exploratória do conjunto total de paisagens simuladas se mostrou pouco produtiva para o estudo do papel da configuração na qualidade da água, podendo resultar em conclusões equivocadas. De fato, algumas correlações apresentaram diferentes magnitudes e sinais invertidos quando analisadas por grupos de percentuais em comparação ao conjunto geral. Isso reforça que algumas métricas podem exibir relações ambíguas a depender da quantidade ou fragmentação da classe estudada (TISCHENDORF, 2001). Portanto, comparações são úteis quando as paisagens têm valores similares de proporção de classe (GARDNER; URBAN, 2007). Nesse sentido, a composição e configuração associadas a cada paisagem devem ser consideradas explicitamente de forma a evitar conclusões equivocadas resultantes da análise isolada de métricas (REMMEL; CSILLAG, 2003).

A análise exploratória segmentada por classes de percentuais foi mais bem-sucedida, pois foi possível isolar o efeito da proporção de florestas e avaliar a relação das métricas de configuração com a qualidade da água. Houve um predomínio de correlações fortes no grupo sem proteção ripária e de correlações fracas no grupo com proteção. Esses resultados reforçam os obtidos pela análise de variância aplicada às médias, em que a autocorrelação espacial teve maior relevância para a geração de sedimentos nas paisagens sem faixa ripária florestal. Por conseguinte, as métricas de configuração mostraram interdependência mais clara com a qualidade da água em paisagens com quantidades fixas de floresta e sem zona ripária protegida.

Em geral, as correlações revelam que bacias com uma floresta menos agregada, inclusive na zona ripária, com maior extensão perimetral e de formato irregular e menos contíguo exibem menor carga de sedimentos. Ao se proteger completamente a zona ripária com florestas, apenas considerar a sua agregação na bacia parece ser suficiente. Entretanto, esses efeitos devem ser cogitados considerando quantidades fixas de floresta na paisagem, que devem ser preferencialmente altas.

A partir dos resultados das análises de correlação, sugere-se que estudos de paisagem, principalmente aqueles que utilizam simulação, explorem previamente o comportamento das métricas tomadas como variáveis explicativas (TISCHENDORF, 2001). Espera-se que as métricas representem adequadamente a configuração e não sejam governadas pela composição na paisagem. Ao se apreciar apenas um aspecto da configuração, uma relação com o serviço ambiental pode ser detectada quando na verdade são outros aspectos que estão de fato influenciando a provisão (RIEB; BENNETT, 2020). Por essa razão, deve-se calcular um determinado volume de métricas e fazer uma análise exploratória para avaliar as correlações entre elas, com a porcentagem de floresta e com outros fatores de confusão. Técnicas estatísticas que consideram variáveis colineares nas análises ou que geram um conjunto reduzido de métricas podem ser empregadas. Exemplos incluem os coeficientes de correlação, o fator de inflação da variância (VIF), análises de componentes principais, a regressão por componentes principais, e a regressão LASSO (*Least absolute shrinkage and selection operator*) (DORMANN et al., 2013). No entanto, análises exploratórias de múltiplas métricas não devem ser tomadas como inferências causais. É preciso definir uma hipótese a ser testada considerando mecanismos que se cogita estarem por trás da relação padrão-processo (GUSTAFSON et al., 2019).

As análises voltadas para a identificação de métricas de paisagem como variáveis explicativas reforçaram que a proporção de florestas, principalmente na zona ripária, mas também na bacia hidrográfica, é a variável mais importante para a predição da carga de sedimentos. Logo, a quantidade de cobertura florestal se mostrou fator mais importante para a manutenção da qualidade da água (MELLO et al., 2018), devendo ser considerada tanto em escala de bacia quanto de zona ripária durante o planejamento e gestão hídrica (DING et al., 2016; LIU et al., 2017; MELLO et al., 2018). Por outro lado, o destaque da porcentagem e da densidade de manchas florestais na zona ripária como preditores mais importantes sugere que a estrutura nessa escala pode ter um desempenho ligeiramente superior em explicar a variação na qualidade da água, assim como constatado por outros autores (CHANG; PSARIS, 2013; YE et al., 2015; JIANG et al., 2017).

As árvores de regressão demonstraram que contabilizar a proporção de florestas na zona ripária pode ser suficiente para prever a qualidade da água em bacias com porcentagens de floresta inferiores a 19% e superiores a 70%. Desse modo, em paisagens com quantidades muito altas ou muito baixas de cobertura, a porcentagem parece ser suficiente para explicar a variação na qualidade da água (CLÉMENT et al., 2017). Os índices de paisagem selecionados, que representam a agregação e subdivisão das florestas, mas que também podem refletir outros aspectos da configuração, demonstraram maior relevância em porcentagens intermediárias de cobertura florestal (i.e., 19% a 69%). Esses resultados corroboram os obtidos pela análise das médias e variâncias por classes de percentual e pelos trabalhos de Gergel (2005) e Clément et al. (2017), que constataram uma maior relevância da configuração em classes intermediárias de cobertura florestal. Villard e Metzger (2014) já haviam sugerido uma maior probabilidade de a configuração espacial influenciar movimentos animais na paisagem em valores intermediários de coberturas. Nesta pesquisa, evidências dessa função são apontadas para indicadores de qualidade da água que dependem do movimento da matéria na bacia hidrográfica.

Nos percentuais intermediários, a árvore de regressão indicou que uma maior subdivisão e desagregação das florestas propiciaria uma melhor qualidade da água. Estudos como os de Li, Liu e Ji (2015), Qiu e Turner (2015), Clément et al. (2017), Rieb e Bennett (2020) e Thomas et al. (2020) também identificaram um efeito positivo da fragmentação das florestas na qualidade da água. Esse fenômeno pode ser explicado pelo aumento da heterogeneidade na paisagem devido a uma maior intercalação de fragmentos de diferentes coberturas (MORENO-MATEOS et al., 2008). Consequentemente, a provisão de serviços ambientais beneficiados por uma maior conectividade entre as coberturas é favorecida (MITCHELL; BENNETT; GONZALEZ, 2015). No entanto, esses resultados se opõem aos encontrados por Lee et al. (2009), Ding et al. (2016) e Mello et al. (2022), em que uma maior fragmentação das florestas foi associada a pior qualidade da água. Ainda, esses resultados destoam dos documentados por Laurance et al. (2011) em pesquisa em longo prazo, em que a fragmentação mostrou ter efeitos negativos, por meio da redução do tamanho e conectividade dos fragmentos ou pelo aumento da área sob efeito de borda, na biodiversidade, nos regimes hidrológicos e nos ciclos biogeoquímicos. A partir de experimentos de fragmentação em longo prazo, Haddad et al. (2015) também detectaram que a fragmentação em geral (i.e., menores fragmentos, maior isolamento e maior borda) causam impactos negativos tanto na biodiversidade quando nas funções ecossistêmicas, como a retenção de nutrientes. Conforme já discutido, o efeito positivo da fragmentação das florestas na qualidade da água nas paisagens simuladas se deve a uma maior dispersão das manchas florestais na bacia. Consequentemente, essas manchas podem ou atenuar a perda de solo ou

atuar como barreiras ao transporte de sedimentos erodidos. Muitas dessas áreas críticas para a entrega de sedimentos estão situadas no entorno da drenagem gerada pelo modelo, o que justifica a relevância da densidade de manchas florestais na zona ripária para a predição da qualidade da água.

5 CONCLUSÃO

O acoplamento de um modelo de produção de sedimentos calibrado para uma bacia hidrográfica com paisagens replicadas permitiu avaliar como a quantidade e a configuração das florestas influenciam a qualidade da água. Essa estratégia se mostrou satisfatória para fins exploratórios, visto que propiciou uma comparação de uma variedade de diferentes cenários de estrutura da paisagem que são difíceis ou impossíveis de se obter em experimentos de campo. Ao se comparar diferentes cenários de estrutura da paisagem, a proteção das zonas ripárias se mostrou a estratégia mais eficaz, principalmente porque o modelo identifica como áreas críticas para a entrega de sedimentos aquelas mais próximas da drenagem mapeada. Não obstante, é possível combinar diferentes estratégias de desenho da paisagem considerando metas pré-definidas e outros requisitos, como a proporção de floresta a ser conservada, a largura mínima ou máxima desejada para a faixa ripária, a necessidade de proteger áreas de alta declividade, entre outros. Essas estratégias podem ser transpostas ao contexto local e agregadas com informações sobre outros serviços ambientais de interesse, bem como compatibilizadas com as necessidades das partes interessadas, podendo assim resultar em metas satisfatórias para a produção de sedimentos.

A porcentagem de floresta em ambas as escalas de bacia hidrográfica e zona ripária se destacou como fator crucial para a produção de sedimentos, e seu aumento está associado a uma queda proporcional da carga anual. A porcentagem na bacia hidrográfica se mostrou suficiente para prever a qualidade da água em bacias que dispõem de uma faixa ripária florestal fixa. Por outro lado, a autocorrelação espacial das florestas também explicou uma porção da qualidade da água, ainda que pequena, tendo se mostrado especialmente relevante em bacias que não possuem uma faixa ripária florestal de largura fixa. Além disso, foi demonstrado que o papel de alguns aspectos da configuração deve ser interpretado após se isolar o efeito da composição, visto que esta modula fortemente a qualidade da água. As correlações de algumas métricas de paisagem com a produção de sedimentos apresentaram tanto sinais inversos quanto magnitudes diferentes quando avaliadas no conjunto total e por classes de percentuais de floresta. Quando a quantidade de floresta na paisagem é considerada, a sua desagregação e subdivisão se associaram a menores cargas anuais, um reflexo do papel que os fragmentos florestais exercem principalmente como barreiras ao transporte dos sedimentos. No entanto, esse aspecto é secundário para a determinação da qualidade da água, visto que a quantidade de floresta na bacia hidrográfica e sua posição em relação à zona ripária são fundamentais.

Em bacias hidrográficas sem faixa ripária fixa e com percentuais intermediários de cobertura florestal, as métricas de configuração exibiram uma relação mais clara com a produção de sedimentos, podendo atuar como variáveis explicativas da qualidade da água. Índices simples que se mostraram úteis para predição foram a densidade de manchas na zona ripária, o índice de aglomeração (CLUMPY) e a densidade de bordas. Além das métricas de paisagem tradicionais, um índice crucial para compreender como a estrutura se relaciona com a qualidade da água é aquele que considere a localização da floresta na bacia hidrográfica. Os resultados indicaram que acrescentar manchas na bacia pode não ser suficiente para a melhoria da qualidade da água, pois elas devem ser dispostas preferencialmente ao longo, próximas e paralelamente às zonas ripárias.

Os resultados deste capítulo devem ser apreciados tendo em vista o contexto em que foram gerados, ou seja, o uso de um modelo hidrológico de base física e paisagens binárias geradas artificialmente. Os processos que influenciam a erosão e o transporte do solo não estão totalmente representados pelo modelo, e o padrão da paisagem em bacias reais certamente não são condicionados a um gerador de números aleatórios. Resultados semelhantes podem ser esperados ao se utilizar modelagem, porém, em condições reais a configuração da paisagem pode exibir influências diversas e mais complexas do que as encontradas neste trabalho. Todavia, os resultados do experimento fornecem hipóteses que podem ser testadas com mensurações em campo. Ainda, os resultados refletem a qualidade da água segundo um único indicador e sem considerar outros atributos hidrológicos ou outros serviços proporcionados pelas florestas, sejam eles hidrológicos ou não.

CONSIDERAÇÕES FINAIS

As duas abordagens utilizadas neste trabalho – revisão sistemática e experimento de simulação – se mostraram adequadas para explorar a relação entre padrão da paisagem nas escalas de bacia hidrográfica e zona ripária e a qualidade da água. A revisão da literatura indicou que ainda não há clareza sobre a influência do padrão da paisagem na qualidade da água, principalmente no que se refere ao papel da configuração. O experimento de simulação, por sua vez, reafirmou algumas das evidências da literatura e forneceu hipóteses que podem ser testadas analisando a relação padrão-processo em paisagens reais. Retomando o fator motivador desta pesquisa, i.e., subsidiar o planejamento e gestão de paisagens voltados para a conservação dos serviços ambientais hidrológicos, alguns caminhos podem ser derivados de uma convergência das evidências obtidas por ambas as abordagens. Essas orientações, elencadas abaixo, enfatizam as principais conclusões sobre a relação padrão-processo estudada nesta pesquisa e focam no manejo de florestas.

- 1) Sobre as escalas espaciais para gestão dos serviços hidrológicos:
 - a. Ambas as escalas de bacia hidrográfica e zona ripária devem ser consideradas no planejamento e gestão das paisagens.

- 2) Sobre o papel da composição e da configuração na regulação da qualidade da água:
 - a. Deve-se considerar tanto a composição quanto a configuração da paisagem, pois ambas influenciam a qualidade da água nas escalas de bacia e zona ripária.

- 3) Sobre os usos e coberturas do solo e sua relação com a qualidade da água:
 - a. A quantidade de florestas na bacia hidrográfica e na zona ripária é o principal fator associado com uma melhor qualidade da água, sendo o seu aumento uma estratégia prioritária.
 - b. A área urbana é um fator degradante da qualidade da água e deve ser mantida em proporção mínima na paisagem.
 - i. Esse uso contribui não só com fontes difusas de poluição, mas também pontuais e afeta negativamente diversos indicadores.

- c. Maiores porcentagens de agricultura na paisagem têm efeito degradante na qualidade da água, principalmente pela introdução de nitrogênio e fósforo advindos de fertilizantes.
 - i. Além de buscar reduzir a sua proporção, é fundamental adotar medidas de controle da carga de fertilizantes aplicada nas culturas agrícolas.
 - d. A proporção de pastagem na paisagem não teve relação clara com a qualidade da água, sendo recomendado manejos menos intensivos de forma a não causar impactos negativos.
- 4) Sobre estratégias de alocação da cobertura florestal na paisagem:
- a. É possível mesclar diferentes estratégias com relação à quantidade e configuração das florestas na bacia hidrográfica de forma a atingir metas de produção de sedimentos.
 - i. A disposição aleatória da floresta na área de drenagem, a implantação de faixas ripárias florestais de diferentes larguras, e a proteção de áreas de maior declividade são estratégias que podem ser combinadas considerando metas a serem atingidas, os recursos disponíveis, e as necessidades e valores contexto-específicos.
- 5) Sobre a influência da configuração das florestas na qualidade da água:
- a. O fator mais importante da configuração é a localização dos fragmentos florestais na bacia. Manchas situadas próximas das zonas ripárias e paralelas a elas são efetivas no controle do aporte de sedimentos.
 - b. A agregação das florestas parece ser mais relevante para o controle da produção de sedimentos em paisagens que não possuem faixa ripária florestal fixa, o que torna esse fator essencial a ser considerado em bacias com essa estrutura.
 - c. É possível modificar a agregação quando há quantidades baixas de floresta (< 20%) de forma a aliviar a carga de sedimentos. Porém, em muitos casos, essa estratégia será insuficiente e deverá ser acompanhada por um aumento substancial da proporção na paisagem.
 - d. Em paisagens com proporções intermediárias de floresta, inserir manchas florestais, i.e., aumentar a desagregação, leva a uma maior heterogeneidade

na paisagem, podendo resultar em menor perda e aporte de sedimentos na água, visto que essas manchas podem atuar como barreiras físicas ao transporte dos sedimentos.

- e. Em paisagens com proporções intermediárias de floresta, métricas simples e de fácil interpretação e manejo, como a densidade de manchas ou a densidade de bordas, podem ser úteis para predizer as cargas anuais e auxiliar o manejo e monitoramento da configuração na escala de bacia hidrográfica e zona ripária.

Em resumo, uma estratégia básica que parece ser efetiva para o controle da poluição difusa, considerando o aporte de sedimentos e a cobertura florestal, consiste em primeiro verificar a existência de uma faixa florestal ao longo da zona ripária. Caso ela esteja presente, recomenda-se aumentar a quantidade de florestas no restante da bacia, especialmente nas áreas próximas à rede hidrográfica. Caso não haja uma faixa ripária florestal consistente em torno da drenagem, a estratégia prioritária seria preenchê-la, principalmente em bacias com pouca cobertura florestal. Em seguida, poderia ser feito o incremento da proporção das florestas na área de drenagem da mesma forma descrita acima. Outras estratégias a serem combinadas incluem o alargamento das faixas ripárias, ainda que descontínuas, uma disposição mais aleatória da floresta na bacia, ou a cobertura de áreas de alta declividade.

Cabe ressaltar que as orientações voltadas para a configuração das florestas são derivadas de um experimento que utilizou modelagem da erosão em sulcos e entressulcos, ignorando outros processos erosivos, e simulações em paisagens binárias artificiais. Portanto, seus resultados podem não ser transpostos diretamente para tomada de decisão. Além disso, as conclusões acima se referem a apenas um componente da qualidade da água, e não abrangem outros atributos ou serviços ambientais que são desejáveis em paisagens multifuncionais. Ainda, esta abordagem assume que as florestas são plenamente funcionais e que a agricultura aplica boas práticas de manejo do solo. Todos esses fatores devem ser observados ao se utilizar as conclusões deste trabalho para cogitar o desenho de paisagens. Entretanto, os resultados fornecem hipóteses que podem ser testadas em futuras pesquisas ou apreciadas durante o planejamento e gestão da paisagem, buscando validá-las no contexto local. Consequentemente, considera-se que o propósito geral desta pesquisa de contribuir com evidências obtidas a partir da ecologia da paisagem para o desenho de paisagens voltadas à provisão de serviços ambientais hidrológicos foi atingido. A síntese e os resultados do experimento de simulação podem ser incorporados à base de evidências sobre a influência do padrão da paisagem na qualidade da

água. Futuramente, essas contribuições podem ser agregadas em processos de planejamento, gestão ou monitoramento de instrumentos de conservação dos serviços hidrológicos de forma a aprimorar sua efetividade.

RECOMENDAÇÕES

São recomendações para trabalhos futuros:

- Investigar o papel da configuração, especialmente de coberturas fáceis de manejar como a florestal e agrícola, utilizando dados observados de indicadores de qualidade da água;
- Analisar a relação de métricas de configuração com a qualidade da água tendo isolado o efeito da composição;
- Aplicar a estratégia de experimento de simulação a outras estruturas da paisagem, incluindo outros tipos de cobertura do solo;
- Aplicar a estratégia de experimento de simulação para outros serviços ambientais mensurados por modelagem;
- Avaliar o desempenho de índices espaciais que considerem a posição e orientação das manchas florestais na bacia como preditores da qualidade da água;
- Explorar o efeito da configuração das florestas em outros serviços hidrológicos e serviços ambientais prestados pela biodiversidade.

REFERÊNCIAS

- ADAMS, V. M.; GAME, E. T.; BODE, M. Synthesis and review: delivering on conservation promises: the challenges of managing and measuring conservation outcomes. **Environmental Research Letters**, v. 9, n. 8, p. 085002, 2014.
- ALBERTI, M. et al. The impact of urban patterns on aquatic ecosystems: An empirical analysis in Puget lowland sub-basins. **Landscape and Urban Planning**, v. 80, n. 4, p. 345–361, 2007.
- ALEWELL, C. et al. Using the USLE: Chances, Challenges and Limitations of Soil Erosion Modelling. **International Soil and Water Conservation Research**, v. 7, n. 3, p. 203–225, set. 2019.
- ALNAHIT, A. O.; MISHRA, A. K.; KHAN, A. A. Stream Water Quality Prediction Using Boosted Regression Tree and Random Forest Models. **Stochastic Environmental Research and Risk Assessment**, 20 jan. 2022.
- ALOE, A. M.; BECKER, B. J. An Effect Size for Regression Predictors in Meta-Analysis. **Journal of Educational and Behavioral Statistics**, v, 37, n. 2, p. 278-297, 2012.
- ALVARES, C. A. et al. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2013.
- AMESTOY, P. R. et al. **igraph**: Network Analysis and Visualization. 2020. R package version 1.2.6. Disponível em: <<https://CRAN.R-project.org/package=igraph>>.
- ANA (AGÊNCIA NACIONAL DE ÁGUAS). **Portal Hidroweb v3.1.1**. Disponível em: <<https://www.snirh.gov.br/hidroweb/mapa>>. Acesso em: 02 abr. 2021.
- ANDERSEN, T. et al. Ecological Thresholds and Regime Shifts: Approaches to Identification. **Trends in Ecology & Evolution**, v. 24, n. 1, p. 49–57, 1 jan. 2009.
- ANESEYEE, A. B. et al. Land Use/Land Cover Change Effect on Soil Erosion and Sediment Delivery in the Winike Watershed, Omo Gibe Basin, Ethiopia. **Science of The Total Environment**, v. 728, p. 138776, ago. 2020.
- ARNOLD, J. G. et al. 1998. Large area hydrologic modeling and assessment. Part I: model development. **Journal of the American Water Resources Association**, v. 34, n.1, p. 73–89, 1998.
- ARNOLD, J. G. et al. **Soil & Water Assessment Tool: Input/Output Documentation**. Texas Water Resources Institute, 2012.
- ASABE (AMERICAN SOCIETY OF AGRICULTURAL AND BIOLOGICAL ENGINEERS). **Guidelines for calibrating, validating, and evaluating hydrologic and water quality (H/WQ) models**. ASABE, 621, jun. 2017.
- ASHBOLT, N. J.; GRABOW, W. O. K.; SNOZZI, M. Indicators of microbial water quality. *In*: WHO (WORLD HEALTH ORGANIZATION). **Water Quality: Guidelines, Standards and Health**. London: IWA Publishing, 2001.

BAIRD, R. B.; EATON A. D.; RICE, E. W. (Eds.). **Standard Methods for the Examination of Water and Wastewater**. 23rd ed. Washington, DC: American Public Health Association, American Water Works Association, Water Environment Federation, 2017.

BARTUSZEVIGE, A. M. et al. Landscape Design: Integrating Ecological, Social, and Economic Considerations into Conservation Planning. **Wildlife Society Bulletin**, v. 40, n. 3, p. 411–422, 1 set. 2016.

BATENI, F.; FAKHERAN, S.; SOFFIANIAN, A. Assessment of land cover changes and water quality changes in the Zayandehroud River Basin between 1997-2008. **Environmental Monitoring and Assessment**, v. 185, n. 12, p. 10511–10519, 2013.

BENAVIDEZ, R. et al. A Review of the (Revised) Universal Soil Loss Equation ((R)USLE): With a View to Increasing Its Global Applicability and Improving Soil Loss Estimates. **Hydrology and Earth System Sciences**, v. 22, n. 11, p. 6059–6086, 27 nov. 2018.

BENDER, R. et al. Attention should be given to multiplicity issues in systematic reviews. **Journal of Clinical Epidemiology**, v. 61, p. 857-865, 2008.

BERTONI, J.; LOMBARDI NETO, F. **Conservação do solo**. São Paulo: Ícone, 1990.

BILOTTA, G. S.; MILNER, A. M.; BOYD, I. On the use of systematic reviews to inform environmental policies. **Environmental Science & Policy**, v. 42, n. Supplement C, p. 67–77, 2014.

BIVAND et al. **rgdal**: Bindings for the 'Geospatial' Data Abstraction Library. 2021. R package version 1.5-23. Disponível em: <<https://CRAN.R-project.org/package=rgdal>>. Acesso em: 15 jan. 2021.

BORENSTEIN, M. et al. **Introduction to Meta-Analysis**. Chichester, UK: John Wiley & Sons, 2009.

BORSELLI, L.; CASSI, P.; TORRI, D. Prolegomena to Sediment and Flow Connectivity in the Landscape: A GIS and Field Numerical Assessment. **CATENA**, v. 75, n. 3, p. 268–277, 15 nov. 2008.

BRADSHAW, C. J. A. et al. Global Evidence That Deforestation Amplifies Flood Risk and Severity in the Developing World. **Global Change Biology**, v. 13, n. 11, p. 2379–2395, 1 nov. 2007.

BRAUMAN, K. A. et al. The Nature and Value of Ecosystem Services: An Overview Highlighting Hydrologic Services. **Annual Review of Environment and Resources**, v. 32, n. 1, p. 67–98, 2007.

BREIMAN, L. et al. **Classification and Regression Trees**. Taylor & Francis, 1984. 368 p.

BREIMAN, L. **Random Forests**. Machine Learning, v. 45, n. 1, p. 5–32, 1 out. 2001.

BREZONIK, P. L.; ARNOLD, W. A. **Water Chemistry**: an introduction to the chemistry of natural and engineered aquatic systems. New York: Oxford University Press, 2011.

BRUIJNZEEL, L. A. Hydrological functions of tropical forests: not seeing the soil for the trees? **Agriculture, Ecosystems & Environment**, v. 104, n. 1, p. 185–228, set. 2004.

BU, H. et al. Effects of land-use patterns on in-stream nitrogen in a highly-polluted river basin in Northeast China. **Science of the Total Environment**, v. 553, p. 232–242, 2016.

BU, H. et al. Relationships between land use patterns and water quality in the Taizi River basin, China. **Ecological Indicators**, v. 41, p. 187–197, 2014.

BUCK, O.; NIYOGI, D. K.; TOWNSEND, C. R. Scale-Dependence of Land Use Effects on Water Quality of Streams in Agricultural Catchments. **Environmental Pollution (Barking, Essex: 1987)**, v. 130, n. 2, p. 287–299, jul. 2004.

CANNING, A. D.; DEATH, R. G. Ecosystem Health Indicators — Freshwater Environments. In: FATH, B. (Ed.). **Encyclopedia of Ecology**. 2nd ed. Elsevier, 2019. v. 1. p. 46-60.

CARPENTER, S. R. et al. Science for Managing Ecosystem Services: Beyond the Millennium Ecosystem Assessment. **Proceedings of the National Academy of Sciences**, v. 106, n. 5, p. 1305–1312, 3 fev. 2009.

CEE (COLLABORATION FOR ENVIRONMENTAL EVIDENCE). **Guidelines and Standards for Evidence Synthesis in Environmental Management**. Version 5.0. Environmental Evidence, 2018. Disponível em: <www.environmentalevidence.org/information-for-authors>. Acesso em: 03 fev. 2019.

CETESB (COMPANHIA AMBIENTAL DO ESTADO DE SÃO PAULO). **Sistema Infoáguas**. Disponível em: <<https://sistemainfoaguas.cetesb.sp.gov.br/Home>>. Acesso em: 02 abr. 2021.

CHANDLER, J. et al. Chapter I: Introduction. In: HIGGINS, J. P. T. et al. (ed.) **Cochrane Handbook for Systematic Reviews of Interventions version 6.0 (updated July 2019)**. Cochrane, 2019. Disponível em: <www.training.cochrane.org/handbook>. Acesso em: 26 fev. 2020.

CHANG, H.; PSARIS, M. Local landscape predictors of maximum stream temperature and thermal sensitivity in the Columbia River Basin, USA. **Science of the Total Environment**, v. 461–462, p. 587–600, 2013.

CHAPLIN-KRAMER, R. et al. Landscape configuration is the primary driver of impacts on water quality associated with agricultural expansion. **Environmental Research Letters**, v. 11, n. 7, 2016.

CHEN, L. D. et al. Development of a new index for integrating landscape patterns with ecological processes at watershed scale. **Chinese Geographical Science**, v. 19, p. 37-45, 2009.

CHEN, W.; CHI, G.; LI, J. The Spatial Aspect of Ecosystem Services Balance and Its Determinants. **Land Use Policy**, v. 90, p. 104263, 1 jan. 2020.

CIAGRO (CENTRO INTEGRADO DE INFORMAÇÕES AGROMETEOROLÓGICAS). **Temperatura média mensal no período de 01/01/2005 a 31/12/2019**. Local: Analândia. Disponível em: <<http://www.ciiagro.sp.gov.br/ciiagroonline/>>. Acesso em: 21 jun. 2021.

- CLÉMENT, F. et al. Landscape diversity and forest edge density regulate stream water quality in agricultural catchments. **Ecological Indicators**, v. 72, p. 627–639, 2017.
- CLEVELAND, W. S.; DEVLIN, S. J. Locally Weighted Regression: An Approach to Regression Analysis by Local Fitting. **Journal of the American Statistical Association**, v. 83, n. 403, p. 596-610, 1988.
- CLIMATESERV. Disponível em: <<https://climateserv.servirglobal.net/>>. Acesso em: 25 mar. 2021.
- COHEN, J. A Power Primer. **Psychological Bulletin**, v. 112, n.1, p. 155-159, 1992.
- COLE, L. J. et al. Riparian Buffer Strips: Their Role in the Conservation of Insect Pollinators in Intensive Grassland Systems. **Agriculture, Ecosystems & Environment**, v. 211, p. 207–220, dez. 2015.
- COLE, L. J.; STOCKAN, J.; HELLIWELL, R. Managing Riparian Buffer Strips to Optimise Ecosystem Services: A Review. **Agriculture, Ecosystems & Environment**, v. 296, p. 106891, 1 jul. 2020.
- COOK, D. J.; MULROW, C. D.; HAYNES, R. B. Systematic reviews: synthesis of best evidence for clinical decisions. **Annals of Internal Medicine**, v. 126, n. 5, p. 376–380, 1 mar. 1997.
- COSTA, J. C. et al. Validação dos dados de precipitação estimados pelo CHIRPS para o Brasil. **Revista Brasileira de Climatologia**, v. 24, 11 jun. 2019.
- COSTANZA, R. et al. The value of the world's ecosystem services and natural capital. **Nature**, v. 387, n. 6630, p. 253-260, 1997.
- CULLEN, P. Water in the Landscape: The Coupling of Aquatic Ecosystems and their Catchments. In: LINDENMAYER, D. B.; HOBBS, R. J. (ed.). **Managing and Designing Landscapes for Conservation**. Oxford: Blackwell Publishing Ltd, 2007. cap. 39, p. 458–472. (Conservation Science and Practice).
- CURZON, H. F.; KONTOLEON, A. From ignorance to evidence? The use of programme evaluation in conservation: Evidence from a Delphi survey of conservation experts. **Journal of Environmental Management**, v. 180, n. Supplement C, p. 466–475, 15 set. 2016.
- CUSHMAN, S. A.; MCGARIGAL, K.; NEEL, M. C. Parsimony in landscape metrics: Strength, universality, and consistency. **Ecological Indicators**, v. 8, n. 5, p. 691–703, 1 set. 2008.
- CUTLER, A.; CUTLER, R.; STEVENS, J. R. Random Forests. In: ZHANG, C.; MA, Y. (eds.). **Ensemble Machine Learning: Methods and Applications**. Springer, 2012. p. 157-175.
- CUTLER, D. R. et al. Random Forests for Classification in Ecology. **Ecology**, v. 88, n. 11, p. 2783–2792, nov. 2007.

DAEE (DEPARTAMENTO DE ÁGUAS E ENERGIA ELÉTRICA). **Banco de Dados Hidrológicos**. Disponível em: <<http://www.hidrologia.dae.gov.br/>>. Acesso em: 02 abr. 2021.

DAILY, G. C. et al. Ecosystem services in decision making: time to deliver. **Frontiers in Ecology and the Environment**, v. 7, n. 1, p. 21–28, 2009.

DAILY, G. C. **Nature's services**: societal dependence on natural ecosystems. Washington, DC: Island, 1997. 392 p.

DAVIES-COLLEY, R. J.; SMITH, D. G. Turbidity, suspended sediment, and water clarity: a review. **Journal of the American Water Resources Association**, v. 37, n. 5, 2001.

DE GROOT, R. S. et al. Challenges in integrating the concept of ecosystem services and values in landscape planning, management and decision making. **Ecological Complexity, Ecosystem Services – Bridging Ecology, Economy and Social Sciences.**, v. 7, n. 3, p. 260–272, 2010.

DE GROOT, R. S.; WILSON, M. A.; BOUMANS, R. M. J. A typology for the classification, description and valuation of ecosystem functions, goods and services. **Ecological Economics**, v. 41, n. 3, p. 393–408, jun. 2002.

DE OLIVEIRA, L. M.; MAILLARD, P.; DE ANDRADE PINTO, E. J. Application of a Land Cover Pollution Index to Model Non-Point Pollution Sources in a Brazilian Watershed. **Catena**, v. 150, p. 124–132, 2017.

DE VENTE, J. et al. Predicting Soil Erosion and Sediment Yield at Regional Scales: Where Do We Stand? **Earth-Science Reviews**, v. 127, p. 16–29, dez. 2013.

DE'ATH, G.; FABRICIUS, K. E. Classification and Regression Trees: A Powerful yet Simple Technique for Ecological Data Analysis. **Ecology**, v. 81, n. 11, p. 3178–3192, 2000.

DEEKS, J.J.; HIGGINS, J. P. T.; ALTMAN, D. G. (Eds.). Chapter 10: Analysing data and undertaking meta-analyses. *In*: HIGGINS, J. P. T. et al. (ed.) **Cochrane Handbook for Systematic Reviews of Interventions version 6.0 (updated July 2019)**. Cochrane, 2019. Disponível em: <www.training.cochrane.org/handbook>. Acesso em: 26 fev. 2020.

DEGIFE, A.; WORKU, H.; GIZAW, S. Environmental Implications of Soil Erosion and Sediment Yield in Lake Hawassa Watershed, South-Central Ethiopia. **Environmental Systems Research**, v. 10, n. 1, p. 28, dez. 2021.

DELKASH, M.; AL-FARAJ, F. A. M.; SCHOLZ, M. Impacts of Anthropogenic Land Use Changes on Nutrient Concentrations in Surface Waterbodies: A Review. **Clean - Soil, Air, Water**, v. 46, 1800051, 2018.

DESMET, P. J. J.; GOVERS, G. A GIS Procedure for Automatically Calculating the USLE LS Factor on Topographically Complex Landscape Units. **Journal of Soil and Water Conservation**, v. 51, n. 5, p. 427–433, 1 set. 1996.

DI RAIMO, L. A. di L. et al. Variabilidade espacial da erodibilidade no estado de Mato Grosso, Brasil. **Revista de Ciências Agrárias**, v. 42, n. 1, p. 55-67, 2019.

- DIEBEL, M. W. et al. Landscape Planning for Agricultural Nonpoint Source Pollution Reduction III: Assessing Phosphorus and Sediment Reduction Potential. **Environmental Management**, v. 43, n. 1, p. 69–83, 1 jan. 2009.
- DING, J. et al. Influences of the land use pattern on water quality in low-order streams of the Dongjiang River basin, China: A multi-scale analysis. **Science of the Total Environment**, v. 551–552, p. 205–216, 2016.
- DORMANN, C. F. et al. Collinearity: a review of methods to deal with it and a simulation study evaluating their performance. **Ecography**, v. 36, p. 27–46, 2013.
- DOSSKEY, M. G. et al. The Role of Riparian Vegetation in Protecting and Improving Chemical Water Quality in Streams1. **JAWRA Journal of the American Water Resources Association**, v. 46, n. 2, p. 261–277, 1 abr. 2010.
- DRAMSTAD, W. E. Spatial metrics – useful indicators for society or mainly fun tools for landscape ecologists? **Norsk Geografisk Tidsskrift - Norwegian Journal of Geography**, v. 63, n. 4, p. 246–254, 1 dez. 2009.
- DURLAK; J. A. How to Select, Calculate, and Interpret Effect Sizes. **Journal of Pediatric Psychology**, v. 24, n. 9, p. 917–928, 2009.
- EIGENBROD, F. Redefining Landscape Structure for Ecosystem Services. **Current Landscape Ecology Reports**, v. 1, n. 2, p. 80–86, 1 jun. 2016.
- EMBRAPA (EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA). **Sistema Brasileiro de Classificação de Solos**. 5. ed. rev. Brasília, DF: 2018. 356 p.
- FERRARO, P. J. et al. Estimating the impacts of conservation on ecosystem services and poverty by integrating modeling and evaluation. **Proceedings of the National Academy of Sciences**, v. 112, n. 24, p. 7420–7425, 2015.
- FERRARO, P. J. et al. Forest Figures: Ecosystem Services Valuation and Policy Evaluation in Developing Countries. **Review of Environmental Economics and Policy**, v. 6, n. 1, p. 20–44, 2012.
- FERRO, V.; MINACAPILLI, M. Sediment delivery processes at basin scale. **Hydrological Sciences**, v. 40, p. 703–717, 1995.
- FIELD, A.; MILES, J.; FIELD, Z. **Discovering Statistics Using R**. SAGE Publications, 2012. 957 p.
- FLUX32. 2019. **Software for Load Estimation**. Version 4.0 (30/12/2019). Disponível em: <<https://www.pca.state.mn.us/wplmn/flux32>>. Acesso em: 03 abr. 2021.
- FOLEY, J. A. et al. Global Consequences of Land Use. **Science**, v. 309, n. 5734, p. 570–574, 2005.
- FORMAN, R. T. T. Some General Principles of Landscape and Regional Ecology. **Landscape Ecology**, v. 10, n. 3, p. 133–142, 1 jun. 1995.
- FORMAN, R. T. T.; GODRON, M. **Landscape Ecology**. Wiley, 1986. 619 p.

- FORTIN, M.-J. et al. On the Role of Spatial Stochastic Models in Understanding Landscape Indices in Ecology. **Oikos**, v. 102, n. 1, p. 203–212, 2003.
- FOURNIER, A.; FUSSELL, D.; CARPENTER, L. Computer rendering of stochastic models. **Communications of the ACM**, v. 25, n. 6, p. 371–384, 1 jun. 1982.
- FOX, E. W. et al. Assessing the Accuracy and Stability of Variable Selection Methods for Random Forest Modeling in Ecology. **Environmental Monitoring and Assessment**, v. 189, n. 7, p. 316, jul. 2017.
- FRANKLIN, D. H. et al. Spatial considerations in wet and dry periods for phosphorus in streams of the fort cobb watershed, United States. **Journal of the American Water Resources Association**, v. 49, n. 4, p. 908–922, 2013.
- FRATERRIGO, J. M.; DOWNING, J. A. The Influence of Land Use on Lake Nutrients Varies with Watershed Transport Capacity. **Ecosystems**, v. 11, n. 7, p. 1021–1034, 1 nov. 2008.
- FRAZIER, A. E.; KEDRON, P. Landscape Metrics: Past Progress and Future Directions. **Current Landscape Ecology Reports**, v. 2, p. 63-72, 2017.
- GAILLARDET, J.; VIERS, J.; DUPRÉ, B. 5.09 - Trace Elements in River Waters. *In*: HOLLAND, H. D.; TUREKIAN, K. K. (Eds.). **Treatise on Geochemistry**. Elsevier, 2003. v. 5. p. 225-272, 2003.
- GAO, Y. et al. A Review on Missing Hydrological Data Processing. **Environmental Earth Sciences**, v. 77, n. 2, p. 47, 19 jan. 2018.
- GARDNER, R. H. RULE: Map Generation and a Spatial Analysis Program. *In*: KLOPATEK, J. M. et al. (ed.). **Landscape Ecological Analysis**. New York: Springer-Verlag, 1999. cap. 13, p. 280-303.
- GARDNER, R. H.; URBAN, D. L. Neutral models for testing landscape hypotheses. **Landscape Ecology**, v. 22, p. 15-29, 2007.
- GARG, A. X.; HACKAM, D.; TONELLI, M. Systematic Review and Meta-analysis: When One Study Is Just not Enough. **Clinical Journal of the American Society of Nephrology**, v. 3, p. 253-260, 2008.
- GERGEL, S. E. et al. Landscape Indicators of Human Impacts to Riverine Systems. **Aquatic Sciences**, v. 64, n. 2, p. 118–128, 2002.
- GERGEL, S. E. Spatial and non-spatial factors: When do they affect landscape indicators of watershed loading? **Landscape Ecology**, v. 20, n. 2, p. 177–189, 2005.
- GIPPEL, C. J. Potential of Turbidity Monitoring for Measuring the Transport of Suspended Solids in Streams. **Hydrological Processes**, v. 9, n. 1, p. 83–97, 1995.
- GIRI, S. Water Quality Prospective in Twenty First Century: Status of Water Quality in Major River Basins, Contemporary Strategies and Impediments: A Review. **Environmental Pollution**, v. 271, p. 116332, 15 fev. 2021.

GOWER, J.; LUBBE, S.; ROUX, N. **Understanding biplots**. Chichester, UK: John Wiley & Sons, 2011.

GRAFFELMAN, J. Enriched biplots for canonical correlation analysis. **Journal of Applied Statistics**, v. 32, n. 2, p. 173-188, 2005.

GRIFFITH, J. A. Geographic techniques and recent applications of remote sensing to landscape-water quality studies. **Water, Air, and Soil Pollution**, v. 138, n. 1-4, p. 181-197, 2002.

GUMIERE, S. J. et al. Vegetated Filter Effects on Sedimentological Connectivity of Agricultural Catchments in Erosion Modelling: A Review. **Earth Surface Processes and Landforms**, v. 36, n. 1, p. 3-19, jan. 2011.

GUNDERSEN, P.; SCHMIDT, I. K.; RAULUND-RASMUSSEN, K. Leaching of Nitrate from Temperate Forests - Effects of Air Pollution and Forest Management. **Environmental Reviews**, v. 14, n. 1, p. 1-57, 2006.

GUPTA, H. V.; SOROOSHIAN, S.; YAPO, P. O. Status of Automatic Calibration for Hydrologic Models: Comparison with Multilevel Expert Calibration. **Journal of Hydrologic Engineering**, v. 4, n. 2, p. 135-143, 1 abr. 1999.

GUSTAFSON, E. J. How Has the State-of-the-Art for Quantification of Landscape Pattern Advanced in the Twenty-First Century? **Landscape Ecology**, v. 34, n. 9, p. 2065-2072, 1 set. 2019.

HA, M.; WU, M. Simulating and Evaluating Best Management Practices for Integrated Landscape Management Scenarios in Biofuel Feedstock Production. **Biofuels, Bioproducts and Biorefining**, v. 9, n. 6, p. 709-721, 1 nov. 2015.

HADDAD, N. M. et al. Habitat fragmentation and its lasting impact on Earth's ecosystems. **Science Advances**, v. 1, n. 2, p. e1500052, 2015.

HAIDARY, A. et al. Assessing the Impacts of Four Land Use Types on the Water Quality of Wetlands in Japan. **Water Resources Management**, v. 27, n. 7, p. 2217-2229, 2013.

HAIR, J. F. et al. **Multivariate Data Analysis**. 8th ed. Andover, UK: Cengage Learning, EMEA, 2019.

HALLEY, J. M. et al. Uses and Abuses of Fractal Methodology in Ecology. **Ecology Letters**, v. 7, n. 3, p. 254-271, 2004.

HAMEL, P. et al. A New Approach to Modeling the Sediment Retention Service (InVEST 3.0): Case Study of the Cape Fear Catchment, North Carolina, USA. **Science of The Total Environment**, v. 524-525, p. 166-177, 15 ago. 2015.

HAMEL, P. et al. Sediment Delivery Modeling in Practice: Comparing the Effects of Watershed Characteristics and Data Resolution across Hydroclimatic Regions. **The Science of the Total Environment**, v. 580, p. 1381-1388, 15 fev. 2017.

HAMEL, P. et al. The Value of Hydrologic Information for Watershed Management Programs: The Case of Camboriú, Brazil. **Science of The Total Environment**, v. 705, p. 135871, 25 fev. 2020.

HAN, H. et al. Effects of Land-Use and Climate Change on Sediment and Nutrient Retention in Guizhou, China. **Ecosystem Health and Sustainability**, v. 6, n. 1, p. 1810592, 16 dez. 2020.

HAO, F. et al. Assessing the Relationship Between Landscape Patterns and Nonpoint-Source Pollution in the Danjiangkou Reservoir Basin in China. **Journal of the American Water Resources Association**, v. 48, n. 6, p. 1162–1177, 2012.

HÄRDLE, W. K.; SIMAR, L. **Applied Multivariate Statistical Analysis**. 4th ed. Springer, 2015.

HARMEL, R. D. et al. Estimating Storm Discharge and Water Quality Data Uncertainty: A Software Tool for Monitoring and Modeling Applications. **Environmental Modelling & Software**, v. 24, n. 7, p. 832–842, 1 jul. 2009.

HARMEL, R. D. et al. Evaluating, Interpreting, and Communicating Performance of Hydrologic/Water Quality Models Considering Intended Use: A Review and Recommendations. **Environmental Modelling & Software**, v. 57, p. 40–51, 1 jul. 2014.

HARPER, K. A. et al. Edge Influence on Forest Structure and Composition in Fragmented Landscapes. **Conservation Biology**, v. 19, n. 3, p. 768-782, 2005.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The Elements of Statistical Learning: Data Mining, Inference, and Prediction**. 2nd ed. Springer, 2021. (Springer Series in Statistics)

HEIN, L. et al. Spatial Scales, Stakeholders and the Valuation of Ecosystem Services. **Ecological Economics**, v. 57, n. 2, p. 209–228, 2006.

HESSELBARTH, M. H. K. **landscapemetrics**: Landscape Metrics for Categorical Map Patterns. 2021. R package version 1.5.4. Disponível em: <<https://cran.r-project.org/web/packages/landscapemetrics/>>. Acesso em: 15 jan. 2021.

HIGGINS, J. P. T. et al. (Eds.) **Cochrane Handbook for Systematic Reviews of Interventions version 6.0 (updated July 2019)**. Cochrane, 2019. Disponível em: <www.training.cochrane.org/handbook>. Acesso em: 26 fev. 2020.

HIJMANS et al. **raster**: Geographic Data Analysis and Modeling. 2021. R package version 3.4-5. Disponível em: <<https://CRAN.R-project.org/package=raster>>. Acesso em: 15 jan. 2021.

HIVELY, W. D. et al. Relating nutrient and herbicide fate with landscape features and characteristics of 15 subwatersheds in the Choptank River watershed. **Science of the Total Environment**, v. 409, n. 19, p. 3866–3878, 2011.

HOCHBERG, Y. A sharper Bonferroni procedure for multiple tests of significance. **Biometrika**, v. 75, p. 800–803, 1988.

HOF, J.; FLATHER, C. Optimization of landscape pattern. *In*: WU, J.; HOBBS, R. (ed.). **Key Topics in Landscape Ecology**. Cambridge: Cambridge University Press, 2007. cap. 8, p. 143-160. (Cambridge Studies in Landscape Ecology)

HOFMANN, M. A. Searching for effects in big data: Why p-values are not advised and what to use instead. *In*: 2015 Winter Simulation Conference (WSC), 2015, [...]. 2015. p. 725–736.

HOU, Y. et al. Ecosystem Service Potential, Flow, Demand and Their Spatial Associations: A Comparison of the Nutrient Retention Service between a Human- and a Nature-Dominated Watershed. **Science of The Total Environment**, v. 748, p. 141341, 15 dez. 2020.

HUANG, J. et al. Evaluation of the Impacts of Land Use on Water Quality: A Case Study in The Chaohu Lake Basin. **Scientific World Journal**, p. 329187, 2013.

HUANG, Z. et al. Effects of land use patterns on stream water quality: a case study of a small-scale watershed in the Three Gorges Reservoir Area, China. **Environmental Science and Pollution Research**, v. 23, n. 4, p. 3943–3955, 2016.

IBGE (INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA). **Censo Agropecuário 2017**. Disponível em: <<https://sidra.ibge.gov.br/>>. Acesso em: 24 mar. 2021.

IMBERNON, J.; BRANTHOMME, A. Characterization of landscape patterns of deforestation in tropical rainforests. **International Journal of Remote Sensing**, v. 22, n. 9, p. 1753-1765, 2001.

INSTITUTO FLORESTAL. **Inventário Florestal do estado de São Paulo**: mapeamento da cobertura vegetal nativa. São Paulo: Instituto Florestal, 2020. Disponível em: <<https://datageo.ambiente.sp.gov.br/>>. Acesso em: 26 mar. 2021.

InVEST. **Tutorial**: batch processing on Windows. Disponível em: <<https://invest.readthedocs.io/en/latest/scripting.html>>. Acesso em: 15 fev. 2021.

JAGER, H. I. et al. Landscape influences on headwater streams on Fort Stewart, Georgia, USA. **Environmental Management**, v. 48, n. 4, p. 795–807, 2011.

JAMES, G. et al. **An Introduction to Statistical Learning: with Applications in R**. 2nd ed. Springer, 2021.

JIANG, Y. et al. Effects of Land Use Types on Dissolved Trace Metal Concentrations in the Le'an River Basin, China. **Environmental Monitoring and Assessment**, v. 189, n. 12, p. 633, dez. 2017.

JOHNSON, G. D.; MYERS, W. L.; PATIL, G. P. Predictability of surface water pollution loading in Pennsylvania using watershed-based landscape measurements. **Journal of the American Water Resources Association**, v. 37, n. 4, p. 821–835, 2001.

JOHNSON, L. B. et al. Landscape influences on water chemistry in Midwestern stream ecosystems. **Freshwater Biology**, v. 37, n. 1, p. 193–208, 1997.

JONES, A. S. et al. Surrogate Measures for Providing High Frequency Estimates of Total Suspended Solids and Total Phosphorus Concentrations. **JAWRA Journal of the American Water Resources Association**, v. 47, n. 2, p. 239–253, 2011.

- JONES, K. B. et al. Informing Landscape Planning and Design for Sustaining Ecosystem Services from Existing Spatial Patterns and Knowledge. **Landscape Ecology**, v. 28, n. 6, p. 1175–1192, 11 set. 2012.
- JUNG, M. LecoS — A Python Plugin for Automated Landscape Ecology Analysis. **Ecological Informatics**, v. 31, p. 18–21, 1 jan. 2016.
- KAY, D. et al. Sustainable reduction in the flux of microbial compliance parameters from urban and arable land use to coastal bathing waters by a wetland ecosystem produced by a marine flood defence structure. **Water Research**, v. 39, n. 14, p. 3320–3332, 2005.
- KEARNS, F. R. et al. A method for the use of landscape metrics in freshwater research and management. **Landscape Ecology**, v. 20, n. 1, p. 113–125, 2005.
- KEELER, B. L. et al. Linking water quality and well-being for improved assessment and valuation of ecosystem services. **Proceedings of the National Academy of Sciences**, v. 109, n. 45, p. 18619–18624, 6 nov. 2012.
- KING, R. S. et al. Spatial Considerations for Linking Watershed Land Cover to Ecological Indicators in Streams. **Ecological Applications**, v. 15, n. 1, p. 137–153, fev. 2005.
- KINNELL, P. I. A. Event Soil Loss, Runoff and the Universal Soil Loss Equation Family of Models: A Review. **Journal of Hydrology**, v. 385, n. 1, p. 384–397, 7 maio 2010.
- KLAUDA, R. et al. Maryland biological stream survey: A state agency program to assess the impact of anthropogenic stresses on stream habitat quality and biota. **Environmental Monitoring and Assessment**, v. 51, n. 1–2, p. 299–316, 1998.
- KLEIJN, D.; SUTHERLAND, W. J. How Effective Are European Agri-Environment Schemes in Conserving and Promoting Biodiversity? **Journal of Applied Ecology**, v. 40, n. 6, p. 947–969, 1 dez. 2003.
- KŘOVÁKOVÁ, K. et al. Landscape Functions and Their Change – a Review on Methodological Approaches. **Ecological Engineering**, v. 75, p. 378–383, 1 fev. 2015.
- KUPFER, J. A. Landscape Ecology and Biogeography: Rethinking Landscape Metrics in a Post-FRAGSTATS Landscape. **Progress in Physical Geography: Earth and Environment**, v. 36, n. 3, p. 400–420, 1 jun. 2012.
- LAGRO JR., J. Assessing patch shape in landscape mosaics. **Photogrammetric Engineering & Remote Sensing**, v. 57, n. 3, p. 285–293, 1991.
- LAJEUNESSE, M. J. Recovering Missing or Partial Data from Studies: A Survey of Conversions and Imputations for Meta-analysis. *In*: KORICHEVA, J.; GUREVITCH, J.; MENGERSEN, K. (ed.). **Handbook of Meta-analysis in Ecology and Evolution**. Princeton and Oxford: Princeton University Press, 2013. cap. 13, p. 195–206.
- LAKE, P. S. Flowing Waters in the Landscape. *In*: LINDENMAYER, D. B.; HOBBS, R. J. (ed.). **Managing and Designing Landscapes for Conservation**. Oxford: Blackwell Publishing Ltd, 2007. cap. 38, p. 445–457, 2007. (Conservation Science and Practice).

LAMY, T. et al. Landscape Structure Affects the Provision of Multiple Ecosystem Services. **Environmental Research Letters**, v. 11, n. 12, p. 124017, dez. 2016.

LASSERSON, T. J.; THOMAS, J.; HIGGINS, J. P. T. Chapter 1: Starting a review. *In*: HIGGINS, J. P. T. et al. (ed.) **Cochrane Handbook for Systematic Reviews of Interventions version 6.0 (updated July 2019)**. Cochrane, 2019. Disponível em: <www.training.cochrane.org/handbook>. Acesso em: 26 fev. 2020.

LAU, L.; ROTHSTEIN, H. R.; STEWART, G. B. History and Progress of Meta-analysis. *In*: KORICHEVA, J.; GUREVITCH, J.; MENGERSEN, K. (ed.). **Handbook of Meta-analysis in Ecology and Evolution**. Princeton and Oxford: Princeton University Press, 2013. cap. 25, p. 407-419.

LAURANCE, W. F. et al. The Fate of Amazonian Forest Fragments: A 32-Year Investigation. **Biological Conservation**, v. 144, n. 1, p. 56–67, 1 jan. 2011.

LAUSCH, A. et al. Understanding and Quantifying Landscape Structure – A Review on Relevant Process Characteristics, Data Models and Landscape Metrics. **Ecological Modelling**, v. 295, p. 31–41, 10 jan. 2015.

LEE, S-W. et al. Landscape ecological approach to the relationships of land use patterns in watersheds to water quality characteristics. **Landscape and Urban Planning**, v. 92, n. 2, p. 80–89, 2009.

LEFEBVRE, C. et al. Chapter 4: Searching for and selecting studies. *In*: HIGGINS, J. P. T. et al. (ed.) **Cochrane Handbook for Systematic Reviews of Interventions version 6.0 (updated July 2019)**. Cochrane, 2019. Disponível em: <www.training.cochrane.org/handbook>. Acesso em: 26 fev. 2020.

LEGENDRE, P.; LEGENDRE, L. **Numerical Ecology**. 3th ed. Oxford: Elsevier, 2012 (Developments in Environmental Modelling, 24)

LI, C. et al. Impact of Climate Variability and Landscape Patterns on Water Budget and Nutrient Loads in a Peri-urban Watershed: A Coupled Analysis Using Process-based Hydrological Model and Landscape Indices. **Environmental Management**, v. 61, n. 6, p. 954–967, 2018.

LI, H.; LIU, L.; JI, X. Modeling the relationship between landscape characteristics and water quality in a typical highly intensive agricultural small watershed, Dongting lake basin, south central China. **Environmental Monitoring and Assessment**, v. 187, n. 3, p. 1–12, 2015.

LI, H.; WU, J. Use and Misuse of Landscape Indices. **Landscape Ecology**, v. 19, n. 4, p. 389–399, 1 maio 2004.

LI, S.; ZHANG, Y.; ZHANG, Q. Interaction of landscape setting and stream flow seasonality on nitrogen concentrations in a subtropical river, China. **Acta Oecologica**, v. 44, p. 38–45, 2012.

LI, X. et al. Evaluating the Effectiveness of Neutral Landscape Models to Represent a Real Landscape. **Landscape and Urban Planning**, v. 69, n. 1, p. 137–148, 15 jul. 2004.

LIAW, A. **randomForest**: Breiman and Cutler's Random Forests for Classification and Regression. 2022. R package version 4.7-1. Disponível em: <<https://CRAN.R-project.org/package=randomForest>>.

LIAW, A.; WIENER, M. Classification and Regression by randomForest. **R News**, v. 2/3, p. 18-22, 2002.

LIND, L.; HASSELQUIST, E. M.; LAUDON, H. Towards Ecologically Functional Riparian Zones: A Meta-Analysis to Develop Guidelines for Protecting Ecosystem Functions and Biodiversity in Agricultural Landscapes. **Journal of Environmental Management**, v. 249, p. 109391, nov. 2019.

LIPSEY, M. W.; WILSON, D. B. **Practical Meta-Analysis**. Thousand Oaks, CA: SAGE Publications, 2000. (Applied Social Research Methods Series, 49)

LIU, J. et al. Source identification and impact of landscape pattern on riverine nitrogen pollution in a typical urbanized watershed, Beijing, China. **Science of the Total Environment**, v. 628–629, p. 1296–1303, 2018.

LIU, J. et al. Spatial Scale and Seasonal Dependence of Land Use Impacts on Riverine Water Quality in the Huai River Basin, China. **Environmental Science and Pollution Research**, v. 24, n. 26, p. 20995–21010, 1 set. 2017.

LIU, J.; SHEN, Z.; CHEN, L. Assessing How Spatial Variations of Land Use Pattern Affect Water Quality across a Typical Urbanized Watershed in Beijing, China. **Landscape and Urban Planning**, v. 176, p. 51–63, ago. 2018.

LIU, Z.; YANG, H. The impacts of spatiotemporal landscape changes on water quality in Shenzhen, China. **International Journal of Environmental Research and Public Health**, v. 15, n. 5, 2018.

LOMBARDI NETO, F.; MOLDENHAUER, W. C. Erosividade da chuva: sua distribuição e relação com as perdas de solo em Campinas (SP). **Bragantia**, v. 51, n.2, p. 189-196, 1992.

LOPEZ, R. D. et al. Watershed vulnerability predictions for the Ozarks using landscape models. **Journal of Environmental Quality**, v. 37, n. 5, p. 1769–1780, 2008.

LÓPEZ-LÓPEZ, J. A. et al. Dealing with effect size multiplicity in systematic reviews and meta-analyses. **Research Synthesis Methods**, v. 9, p. 336-351, 2018.

LOVELL, S. T.; SULLIVAN, W. C. Environmental benefits of conservation buffers in the United States: Evidence, promise, and open questions. **Agriculture, Ecosystems & Environment**, v. 112, n. 4, p. 249–260, 2006.

ŁOWICKI, D. Prediction of flowing water pollution on the basis of landscape metrics as a tool supporting delimitation of nitrate vulnerable zones. **Ecological Indicators**, v. 23, p. 27–33, 2012.

LUCAS, M. F.; MEDLEY, K. E. Landscape structure and nutrient budgets in an agricultural watershed, Southwest Ohio. **Ohio Journal of Science**, v. 102, n. 2, p. 15–23, 2002.

LUKE, S. H. et al. Riparian Buffers in Tropical Agriculture: Scientific Support, Effectiveness and Directions for Policy. **Journal of Applied Ecology**, v. 56, n. 1, p. 85–92, jan. 2019.

MAIR, P.; WILCOX, R. Robust Statistical Methods in R Using the WRS2 Package. **Behavior Research Methods**, v. 52, n. 2, p. 464–488, 1 abr. 2020.

MAIR, P.; WILCOX, R.; PATIL, I. **WRS2**: A Collection of Robust Statistical Methods. 2021. R package version 1.1-3. Disponível em: <<https://CRAN.R-project.org/package=WRS2>>. Acesso em: 27 jul. 2021.

MANAHAN, S. E. **Environmental Chemistry**. 7th ed. Boca Raton: CRC Press LLC, 2000.

MANNIGEL, A. R. et al. Fator erodibilidade e tolerância de perda dos solos do Estado de São Paulo. **Acta Scientiarum**, v. 24, n. 5, p. 1335-1340, 2002.

MAPBIOMAS. **Projeto MapBiomas** – Coleção 5 da Série Anual de Mapas de Cobertura e Uso de Solo do Brasil, acessado em 23/05/2021 através do link: <https://mapbiomas.org/>. 2021.

MARGRITER, S. C. et al. Using indicators of land-use development intensity to assess the condition of coastal wetlands in Hawai'i. **Landscape Ecology**, v. 29, n. 3, p. 517–528, 2014.

MARTÍNEZ, M. L. et al. Effects of land use change on biodiversity and ecosystem services in tropical montane cloud forests of Mexico. **Forest Ecology and Management**, v. 258, n. 9, p. 1856–1863, 10 out. 2009.

MATEO-SAGASTA, J.; ZADEH, S. M.; TURRAL, H. **Water pollution from agriculture: a global review**. Executive summary. FAO and IWMI, 2017.

MAYER, A. L. et al. How Landscape Ecology Informs Global Land-Change Science and Policy. **BioScience**, p. biw035, 27 abr. 2016.

MCCUEN, R. H.; KNIGHT, Z.; CUTTER, A. G. Evaluation of the Nash–Sutcliffe Efficiency Index. **Journal of Hydrologic Engineering**, v. 11, n. 6, p. 597–602, 1 nov. 2006.

MCGARIGAL, K. Fragstats Help v4. 2015. Disponível em: <<https://www.umass.edu/landeco/research/fragstats/fragstats.html>>. Acesso em: 17 out. 2020.

MCGARIGAL, K. Landscape Pattern Metrics. **Wiley StatsRef: Statistics Reference Online**, 2014.

MCGARIGAL, K.; CUSHMAN, S. A.; ENE, E. **FRAGSTATS v4**: Spatial Pattern Analysis Program for Categorical and Continuous Maps. Computer software program produced by the authors at the University of Massachusetts, Amherst. 2012. Disponível em: <<http://www.umass.edu/landeco/research/fragstats/fragstats.html>>.

MCINTOSH, E. J. et al. The Impact of Systematic Conservation Planning. **Annual Review of Environment and Resources**, v. 42, n. 1, p. 677–697, 17 out. 2017.

MEA (MILLENNIUM ECOSYSTEM ASSESSMENT). **Ecosystems and Human Well-being: Synthesis**. Washington, DC: Island Press, 2005.

- MEAYS, C. L. et al. Source tracking fecal bacteria in water: a critical review of current methods. **Journal of Environmental Management**, v. 73, p. 71–79, 2004.
- MELLO, K. d. et al. Effects of Land Use and Land Cover on Water Quality of Low-Order Streams in Southeastern Brazil: Watershed versus Riparian Zone. **Catena**, v. 167, p. 130–138, 2018.
- MELLO, K. de et al. Effects of Forest Cover Pattern on Water Quality of Low-Order Streams in an Agricultural Landscape in the Pirapora River Basin, Brazil. **Environmental Monitoring and Assessment**, v. 194, n. 3, p. 189, 14 fev. 2022.
- MELLO, K. de et al. Multiscale Land Use Impacts on Water Quality: Assessment, Planning, and Future Perspectives in Brazil. **Journal of Environmental Management**, v. 270, p. 110879, 15 set. 2020.
- MENGERSEN, K.; JENNIONS, M. D.; SCHMID, C. H. Statistical Models for the Meta-analysis of Nonindependent Data. In: KORICHEVA, J.; GUREVITCH, J.; MENGERSEN, K. (ed.). **Handbook of Meta-analysis in Ecology and Evolution**. Princeton and Oxford: Princeton University Press, 2013. cap. 16, p. 255-283.
- METZGER, J. P. O que é ecologia de paisagens? **Biota Neotropica**, v. 1, n. 1/2, BN00701122001, 2001.
- MILBORROW, S. **rpart**: Recursive Partitioning and Regression Trees. 2021. R package version 3.1.0. Disponível em: <<https://cran.r-project.org/web/packages/rpart.plot/>>.
- MILOVANOVIĆ, A.; RODIĆ, D. M.; MARUNA, M. Eighty-year review of the evolution of landscape ecology: from a spatial planning perspective. **Landscape Ecology**, v. 35, p. 2141-2161, 2020.
- MITCHELL, M. G. E. et al. Reframing landscape fragmentation's effects on ecosystem services. **Trends in Ecology & Evolution**, v. 30, n. 4, p. 190–198, 2015.
- MITCHELL, M. G. E.; BENNETT, E. M.; GONZALEZ, A. Linking Landscape Connectivity and Ecosystem Service Provision: Current Knowledge and Research Gaps. **Ecosystems**, v. 16, p. 894-908, 2013.
- MITCHELL, M. G. E.; BENNETT, E. M.; GONZALEZ, A. Strong and nonlinear effects of fragmentation on ecosystem service provision at multiple scales. **Environmental Research Letters**, v. 10, n. 9, p. 094014, 2015.
- MITEVA, D. A.; PATTANAYAK, S. K.; FERRARO, P. J. Evaluation of biodiversity policy instruments: what works and what doesn't? **Oxford Review of Economic Policy**, v. 28, n. 1, p. 69–92, 2012.
- MOHER, D. et al. Preferred reporting items for systematic reviews and meta-analyses: the PRISMA statement. **BMJ**, v. 339, b2535, 2009.
- MONCAYO-ESTRADA, R. et al. Nitrogen nutrients in a subtropical river: Temporal variation and analysis at different spatial scales. **Marine and Freshwater Research**, v. 68, n. 10, p. 1935–1949, 2017.

MONGEON, P.; PAUL-HUS, A. The journal coverage of Web of Science and Scopus: a comparative analysis. **Scientometrics**, v. 106, n. 1, p. 213–228, 2016.

MOREIRA et al. Programa computacional para estimativa da erosividade da chuva no estado de São Paulo utilizando redes neurais artificiais. **Engenharia na Agricultura**, v. 14, n. 2, p. 88-92, 2006.

MORENO-MATEOS, D. et al. Relationships between Landscape Pattern, Wetland Characteristics, and Water Quality in Agricultural Catchments. **Journal of Environmental Quality**, v. 37, n. 6, p. 2170-2180, 2008.

MORGAN, F. P. C. **Soil erosion and conservation**. London: Longman Scientific and Technical, 1995.

MORI, G. B. et al. Influence of landscape properties on stream water quality in agricultural catchments in Southeastern Brazil. **Annales de Limnologie**, v. 51, n. 1, p. 11–21, 2015.

MORIASI, D. N. et al. Hydrologic and Water Quality Models: Performance Measures and Evaluation Criteria. **Transactions of the ASABE**, v. 58, n. 6, p. 1763-1785, 2015.

MORIASI, D. N. et al. Model Evaluation Guidelines for Systematic Quantification of Accuracy in Watershed Simulations. **Transactions of the ASABE**, v. 50, n. 3, p. 885-900, 2007.

MURADIAN, R. et al. Reconciling theory and practice: An alternative conceptual framework for understanding payments for environmental services. **Ecological Economics**, Special Section - Payments for Environmental Services: Reconciling Theory and Practice., v. 69, n. 6, p. 1202–1208, 2010.

NAGAKAWA, S.; CUTHILL, I. C. Effect size, confidence interval and statistical significance: a practical guide for biologists. **Biological Reviews**, v. 82, p. 591-605, 2007.

NASH, J. E.; SUTCLIFFE, J. V. River flow forecasting through conceptual models: Part I - A discussion of principles. **Journal of Hydrology**, v. 10, n.3, p. 282-290, 1970.

NASH, M. S. et al. Multi-scale landscape factors influencing stream water quality in the state of Oregon. **Environmental Monitoring and Assessment**, v. 156, n. 1–4, p. 343–360, 2009.

NASSAUER, J. I.; OPDAM, P. Design in Science: Extending the Landscape Ecology Paradigm. **Landscape Ecology**, v. 23, n. 6, p. 633–644, 14 maio 2008.

NATURAL CAPITAL PROJECT. 2021a. **InVEST Software Platform**. Disponível em: <<https://naturalcapitalproject.stanford.edu/software/invest>>. Acesso em: 25 jan. 2021.

NATURAL CAPITAL PROJECT. 2021b. **natcap/invest**. GitHub repository. Disponível em: <<https://github.com/natcap/invest>>. Acesso em: 30 mai. 2021.

NEARY, D. G.; ICE, G. G.; JACKSON, C. R. Linkages between forest soils and water quality and quantity. **Forest Ecology and Management**, v. 258, n. 10, p. 2269–2281, 30 out. 2009.

NEEL, M. C.; MCGARIGAL, K.; CUSHMAN, S. A. Behavior of Class-Level Landscape Metrics across Gradients of Class Aggregation and Area. **Landscape Ecology**, v. 19, n. 4, p. 435–455, 1 maio 2004.

NIEDERLÄNDER, H. A. G. et al. **State of the Art on Monitoring and Assessment of Rivers**. UN/ECE Task Force on Monitoring & Assessment. Lelystad, 1996. v. 5.

NIELSEN, A. et al. Watershed Land Use Effects on Lake Water Quality in Denmark. **Ecological Applications**, v. 22, n. 4, p. 1187–1200, jun. 2012.

NOBRE, R. L. G. et al. Precipitation, Landscape Properties and Land Use Interactively Affect Water Quality of Tropical Freshwaters. **Science of The Total Environment**, v. 716, p. 137044, 10 maio 2020.

NOVOTNY, V. et al. Unlocking the Relationship of Biotic Integrity of Impaired Waters to Anthropogenic Stresses. **Water Research**, v. 39, n. 1, p. 184–198, 1 jan. 2005.

OLIVEIRA, A. H. et al. Development of Topographic Factor Modeling for Application in Soil Erosion Models. *In*: SORIANO, M. C. H. (ed.). **Soil Processes and Current Trends in Quality Assessment**. IntechOpen, 2013.

OLIVEIRA, P. T. S.; WENDLAND, E.; NEARING, M. A. Rainfall Erosivity in Brazil: A Review. **CATENA**, v. 100, p. 139–147, jan. 2013.

OU, Y.; WANG, X. GIS and ordination techniques for studying influence of watershed characteristics on river water quality. **Water Science and Technology**, v. 64, n. 4, p. 861–870, 2011.

OUYANG, W. et al. Non-Point Source Pollution Dynamics under Long-Term Agricultural Development and Relationship with Landscape Dynamics. **Ecological Indicators**, v. 45, p. 579–589, out. 2014.

PANDEY, A. et al. Physically Based Soil Erosion and Sediment Yield Models Revisited. **CATENA**, v. 147, p. 595–620, 1 dez. 2016.

PARDINI, R. et al. Beyond the Fragmentation Threshold Hypothesis: Regime Shifts in Biodiversity Across Fragmented Landscapes. **PLoS ONE**, v. 5, n. 10, p. e13666, 27 out. 2010.

PARKER, D. B.; RHOADES, M. B. Oxygen Measurement: Biological–Chemical Oxygen Demand. *In*: TRIMBLE, S. W. **Encyclopedia of Water Science**. 2nd ed. Boca Raton: CRC PRes, 2008. v. I-II p. 800-802.

PAUDEL, J.; CRAGO, C. L. Environmental Externalities from Agriculture: Evidence from Water Quality in the United States. **American Journal of Agricultural Economics**, v. 103, n. 1, p. 185–210, 2021.

PAULA, F. R. D. et al. Multi-scale assessment of forest cover in an agricultural landscape of Southeastern Brazil: Implications for management and conservation of stream habitat and water quality. **Ecological Indicators**, v. 85, p. 1181–1191, 2018.

- PEEL, M. C.; FINLAYSON, B. L.; MCMAHON, T. A. Updated world map of the Köppen-Geiger climate classification. **Hydrology and Earth System Sciences**, v. 11, p. 1633-1644, 2007.
- PERINOTTO, A. R. C. Geoturismo: a caracterização do município de Analândia/SP. **Revista Acadêmica Observatório de Inovação do Turismo**, v. 3, n. 1, 2008.
- PISSARRA, T. C. T. et al. Regression Model of Stream Water Quality Based on Interactions between Landscape Composition and Riparian Buffer Width in Small Catchments. **Water**, v. 11, n. 9, p. 1757, 23 ago. 2019.
- POESEN, J. et al. Gully Erosion and Environmental Change: Importance and Research Needs. **CATENA**, v. 50, n. 2–4, p. 91–133, jan. 2003.
- POTTER, K. M.; CUBBAGE, F. W.; SCHABERG, R. H. Multiple-scale landscape predictors of benthic macroinvertebrate community structure in North Carolina. **Landscape and Urban Planning**, v. 71, n. 2–4, p. 77–90, 2005.
- PRADO, H.; OLIVEIRA, J.B.; ALMEIDA, C.L.F. **Levantamento pedológico semidetalhado do Estado de São Paulo**: Quadrícula de São Carlos. Campinas: EMBRAPA/CPA/IA, 1981. (Mapa, escala 1:100.000).
- PRASAD, A. M.; IVERSON, L. R.; LIAW, A. Newer Classification and Regression Tree Techniques: Bagging and Random Forests for Ecological Prediction. **Ecosystems**, v. 9, n. 2, p. 181–199, mar. 2006.
- PROBST, P.; WRIGHT, M. N.; BOULESTEIX, A. Hyperparameters and Tuning Strategies for Random Forest. **WIREs Data Mining and Knowledge Discovery**, v. 9, n. 3, maio 2019.
- PULLIN, A. S.; KNIGHT, T. M.; WATKINSON, A. R. Linking reductionist science and holistic policy using systematic reviews: unpacking environmental policy questions to construct an evidence-based framework. **Journal of Applied Ecology**, v. 46, p. 970-975, 2009.
- QGIS.org, 2021. **QGIS Geographic Information System**. QGIS Association. Disponível em: <<http://www.qgis.org>>.
- QIU, J. Effects of Landscape Pattern on Pollination, Pest Control, Water Quality, Flood Regulation, and Cultural Ecosystem Services: A Literature Review and Future Research Prospects. **Current Landscape Ecology Reports**, v. 4, n. 4, p. 113–124, 1 dez. 2019.
- QIU, J.; TURNER, M. G. Importance of landscape heterogeneity in sustaining hydrologic ecosystem services in an agricultural watershed. **Ecosphere**, v. 6, n. 11, 2015.
- R CORE TEAM. **foreign**: Read Data Stored by 'Minitab', 'S', 'SAS', 'SPSS', 'Stata', 'Systat', 'Weka', 'dBase', ... 2020. R package version 0.8-81. Disponível em: <<https://CRAN.R-project.org/package=foreign>>. Acesso em: 15 jan. 2021.
- R CORE TEAM. **R**: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. 2021. Disponível em: <<https://www.R-project.org/>>.

- REDHEAD, J. W. et al. National Scale Evaluation of the InVEST Nutrient Retention Model in the United Kingdom. **Science of The Total Environment**, v. 610–611, p. 666–677, jan. 2018.
- REMMEL, T. K.; CSILLAG, F. When Are Two Landscape Pattern Indices Significantly Different? **Journal of Geographical Systems**, v. 5, n. 4, p. 331–351, 1 dez. 2003.
- RENARD, K. et al. **Predicting Soil Erosion by Water: A Guide to Conservation Planning with the revised soil loss equation**. United States Department of Agriculture (USDA), 1997
- RENARD, K. G. et al. RUSLE: Revised Universal Soil Loss Equation. **Journal of Soil and Water Conservation**, v. 46, n. 1, p. 30-33, 1991.
- RENARD, K. G.; FREIMUND, J. R. Using Monthly Precipitation Data to Estimate the R-Factor in the Revised USLE. **Journal of Hydrology**, v. 157, n. 1–4, p. 287–306, maio 1994.
- REVELLE, W. **psych**: Procedures for Psychological, Psychometric, and Personality Research. 2021. R package version 2.1.9. Disponível em: <<https://CRAN.R-project.org/package=psych>>.
- RIEB, J. T.; BENNETT, E. M. Landscape Structure as a Mediator of Ecosystem Service Interactions. **Landscape Ecology**, v. 35, n. 12, p. 2863–2880, 1 dez. 2020.
- RITTER, A.; MUÑOZ-CARPENA, R. Performance Evaluation of Hydrological Models: Statistical Significance for Reducing Subjectivity in Goodness-of-Fit Assessments. **Journal of Hydrology**, v. 480, p. 33–45, 14 fev. 2013.
- ROBERTS, A. D.; PRINCE, S. D. Effects of urban and non-urban land cover on nitrogen and phosphorus runoff to Chesapeake Bay. **Ecological Indicators**, v. 10, n. 2, p. 459–474, 2010.
- ROCKSTRÖM, J. et al. A Safe Operating Space for Humanity. **Nature**, v. 461, n. 7263, p. 472–475, 24 set. 2009.
- ROSÁRIO, V. A. C.; GUIMARÃES, J. C.; VIANI, R. A. G. How Changes in Legally Demanded Forest Restoration Impact Ecosystem Services: A Case Study in the Atlantic Forest, Brazil. **Tropical Conservation Science**, v. 12, p. 194008291988288, jan. 2019.
- ROSE, K. C. et al. Annual precipitation regulates spatial and temporal drivers of lake water clarity: **Ecological Applications**, v. 27, n. 2, p. 632–643, 2017.
- ROSENTHAL, R.; RUBIN, D. B. *Requivalent*: A simple effect size indicator. **Psychological Methods**, v. 8, n. 4, p. 492–496, 2003.
- ROSSI, M. **Mapa pedológico do Estado de São Paulo: revisado e ampliado**. São Paulo: Instituto Florestal, 2017. v.1. 118p. (inclui Mapas). Disponível em: <<http://www.iflorestal.sp.gov.br/>>. Acesso em: 10 mar. 2021.
- ROTHSTEIN, H. R. et al. Quality Standards for Research Syntheses. *In*: KORICHEVA, J.; GUREVITCH, J.; Mengersen, K. (ed.). **Handbook of Meta-analysis in Ecology and Evolution**. Princeton and Oxford: Princeton University Press, 2013. cap. 20, p. 323-338.

- SAAD, S. I. et al. Analyzing Ecological Restoration Strategies for Water and Soil Conservation. **PLOS ONE**, v. 13, n. 2, p. e0192325, 9 fev. 2018.
- SÁNCHEZ-CANALES, M. et al. Sensitivity Analysis of a Sediment Dynamics Model Applied in a Mediterranean River Basin: Global Change and Management Implications. **Science of The Total Environment**, v. 502, p. 602–610, jan. 2015.
- SÃO PAULO (Estado). **Hidrografia do estado de São Paulo - UGRHI 5**. Coordenadoria de Planejamento Ambiental, Secretaria do Meio Ambiente do Estado de São Paulo, 2018. Disponível em: <<https://datageo.ambiente.sp.gov.br/>>. Acesso em: 8 fev. 2021.
- SÃO PAULO (Estado). **Modelo Digital De Elevação (MDE) do Estado de São Paulo**. Coordenadoria de Planejamento Ambiental, Secretaria do Meio Ambiente do Estado de São Paulo, 2013. Disponível em: <<https://datageo.ambiente.sp.gov.br/>>. Acesso em: 08 fev. 2021.
- SAUPE, D. Algorithms for random fractals. *In*: PEITGEN, H-O.; SAUPE, D. (ed.). **The Science of Fractal Images**. New York: Springer-Verlag, 1988. cap. 2., p. 71-136.
- SAURA, S.; MARTÍNEZ-MILLÁN, J. Landscape Patterns Simulation with a Modified Random Clusters Method. **Landscape Ecology**, v. 15, n. 7, p. 661–678, 1 out. 2000.
- SCANLON, B. R. et al. Global Impacts of Conversions from Natural to Agricultural Ecosystems on Water Resources: Quantity versus Quality. **Water Resources Research**, v. 43, n. 3, 2007.
- SCHLOERKE, B. et al. **GGally**: Extension to 'ggplot2'. 2021. R package version 2.1.2. Disponível em: <<https://CRAN.R-project.org/package=GGally>>.
- SCHÜNEMANN, H. J. et al. Chapter 14: Completing ‘Summary of findings’ tables and grading the certainty of the evidence. *In*: HIGGINS, J. P. T. et al. (ed.) **Cochrane Handbook for Systematic Reviews of Interventions version 6.0 (updated July 2019)**. Cochrane, 2019. Disponível em: <www.training.cochrane.org/handbook>. Acesso em: 26 fev. 2020.
- SCIAINI, M. et al. **landscapetools**: Landscape Utility Toolbox. 2020a. R package version 0.6.2. Disponível em: <<https://CRAN.R-project.org/package=landscapetools>>. Acesso em: 15 jan. 2021.
- SCIAINI, M. et al. NLMR and landscapetools: An integrated environment for simulating and modifying neutral landscape models in R. **Methods in Ecology and Evolution**, v. 9, p. 2240-2248, 2018.
- SCIAINI, M. et al. **NLMR**: Simulating Neutral Landscape Models. 2020b. R package version 1.0. Disponível em: <<https://CRAN.R-project.org/package=NLMR>>.
- SCOTT, J. M.; TEAR, T. H. What Are We Conserving? Establishing Multiscale Conservation Goals and Objectives in the Face of Global Threats. *In*: LINDENMAYER, D. B.; HOBBS, R. J. (ed.). **Managing and Designing Landscapes for Conservation**. Oxford: Blackwell Publishing Ltd, 2007. cap. 42, p. 494–510. (Conservation Science and Practice).
- SHANDAS, V.; ALBERTI, M. Exploring the Role of Vegetation Fragmentation on Aquatic Conditions: Linking Upland with Riparian Areas in Puget Sound Lowland Streams. **Landscape and Urban Planning**, v. 90, n. 1–2, p. 66–75, 2009.

SHARP, R. et al. **InVEST 3.9.0.post24+ug.g66b919f User's Guide**. The Natural Capital Project, Stanford University, University of Minnesota, The Nature Conservancy, and World Wildlife Fund. 2020. Disponível em: <<https://naturalcapitalproject.stanford.edu/software/invest>>. Acesso em: 25 jan. 2021.

SHELLEY, B.G. What should we call instruments commonly known as payments for environmental services? A review of the literature and a proposal. **Annals of the New York Academy of Sciences**, v. 1219, n. 1, p.209–225, 2011.

SHEN, Z. et al. Relating landscape characteristics to non-point source pollution in a typical urbanized watershed in the municipality of Beijing. **Landscape and Urban Planning**, v. 123, p. 96–107, 2014.

SHEN, Z. Y. et al. A Comprehensive Study of the Effect of GIS Data on Hydrology and Non-Point Source Pollution Modeling. **Agricultural Water Management**, v. 118, p. 93–102, fev. 2013.

SHI, P.; ZHANG, Y.; LI, Z.; LI, P.; XU, G. Influence of land use and land cover patterns on seasonal water quality at multi-spatial scales. **Catena**, v. 151, p. 182–190, 2017.

SILVA, F. das G. B. da et al. Previsão da perda de solo na Fazenda Canchim – SP (EMBRAPA) utilizando geoprocessamento e o USLE 2D. **Engenharia Sanitária e Ambiental**, v. 15, n. 2, p. 141–148, jun. 2010.

SINGH, J.; KNAPP, V.; DEMISSIE, M. **Hydrologic modeling of the Iroquois River watershed using HSPF and SWAT**. Champaign, Ill.: Illinois State Water Survey. 2004. Disponível em: <<https://swat.tamu.edu/media/90101/singh.pdf>>. Acesso em: 18 jun. 2021.

SPAKE, R. et al. Unpacking Ecosystem Service Bundles: Towards Predictive Mapping of Synergies and Trade-Offs between Ecosystem Services. **Global Environmental Change**, v. 47, p. 37–50, 1 nov. 2017.

STEINGRÖVER, E. G.; GEERTSEMA, W.; VAN WINDERGEN, W. K. R. E. Designing agricultural landscapes for natural pest control: a transdisciplinary approach in the Hoeksche Waard (The Netherlands). **Landscape Ecology**, v. 25, n. 6, p. 825–838, 2010.

STEWART, G. Meta-analysis in applied ecology. **Biology Letters**, v. 6, p. 78-81, 2010.

STROBL, C.; MALLEY, J.; TUTZ, G. An Introduction to Recursive Partitioning: Rationale, Application and Characteristics of Classification and Regression Trees, Bagging and Random Forests. **Psychological methods**, v. 14, n. 4, p. 323–348, dez. 2009.

SU, W.-C.; AHERN, J. F.; CHANG, C.-Y. Why Should We Pay Attention to “Inconsistent” Land Uses? A Viewpoint on Water Quality. **Landscape and Ecological Engineering**, v. 12, n. 2, p. 247–254, jul. 2016.

SUN, R. et al. Effect of land-use patterns on total nitrogen concentration in the upstream regions of the haihe river basin, China. **Environmental Management**, v. 51, n. 1, p. 45–58, 2013.

SUN, Y. et al. Scale effects on spatially varying relationships between urban landscape patterns and water quality. **Environmental Management**, v. 54, n. 2, p. 272–287, 2014.

- SUTTON, T.; DASSAU, O.; SUTTON, M. **A Gentle Introduction to QGIS**. 2009. Disponível: <https://docs.qgis.org/3.16/en/docs/gentle_gis_introduction/index.html>. Acesso em: 31 mai. 2021.
- SWEENEY, B. W. et al. Riparian Deforestation, Stream Narrowing, and Loss of Stream Ecosystem Services. **Proceedings of the National Academy of Sciences of the United States of America**, v. 101, n. 39, p. 14132–14137, 28 set. 2004.
- SWEENEY, B. W.; NEWBOLD, J. D. Streamside forest buffer width needed to protect stream water quality, habitat, and organisms: A literature review. **Journal of the American Water Resources Association**, v. 50, n. 3, p. 560-584, 2014.
- SYNES, N. W. et al. Emerging Opportunities for Landscape Ecological Modelling. **Current Landscape Ecology Reports**, v. 1, n. 4, p. 146–167, 1 dez. 2016.
- SYRBE, R.-U.; WALZ, U. Spatial Indicators for the Assessment of Ecosystem Services: Providing, Benefiting and Connecting Areas and Landscape Metrics. **Ecological Indicators**, v. 21, p. 80–88, 1 out. 2012.
- TANG, J. Dynamic linkages between vegetation phenology and seasonal changes in water quality in the Choptank watershed, USA. **International Journal of Remote Sensing**, v. 36, n. 12, p. 3041–3057, 2015.
- TANIWAKI, R. H. et al. Impacts of Converting Low-Intensity Pastureland to High-Intensity Bioenergy Cropland on the Water Quality of Tropical Streams in Brazil. **The Science of the Total Environment**, v. 584–585, p. 339–347, 15 abr. 2017.
- TEIXEIRA, D. B. de S. **Erosividade da chuva no estado de São Paulo com base em séries sintéticas de dados pluviográficos**. 2019. Dissertação (Mestrado em Meteorologia Aplicada) - Universidade Federal de Viçosa, Viçosa, MG, 2019.
- TEIXEIRA, Z.; MARQUES, J. C. Relating landscape to stream nitrate-N levels in a coastal eastern-Atlantic watershed (Portugal). **Ecological Indicators**, v. 61, p. 693–706, 2015.
- TERMORSHUIZEN, J. W.; OPDAM, P. Landscape Services as a Bridge between Landscape Ecology and Sustainable Development. **Landscape Ecology**, v. 24, n. 8, p. 1037–1052, 1 out. 2009.
- THAPA, R. B.; ESTOQUE, R. C. Geographically Weighted Regression in Geospatial Analysis. In: MURAYAMA, Y. (ed.). **Progress in Geospatial Analysis**. Tokyo: Springer, 2012. cap 6, p. 85-96.
- THERNEAU, T. M.; ATKINSON, E. J. **An Introduction to Recursive Partitioning Using the RPART Routines**. 2022. Disponível em: <<https://cran.r-project.org/web/packages/rpart/>>. Acesso em: 15 fev. 2022.
- THERNEAU, T.; ATKINSON, B.; RIPLEY, B. **rpart**: Recursive Partitioning and Regression Trees. 2022. R package version 4.1.16. Disponível em: <<https://cran.r-project.org/web/packages/rpart/>>.
- THOMAS, A. et al. Fragmentation and Thresholds in Hydrological Flow-based Ecosystem Services. **Ecological Applications**, v. 30, n. 2, mar. 2020.

THOMAS, J. et al. Chapter 2: Determining the scope of the review and the questions it will address. *In*: HIGGINS, J. P. T. et al. (ed.) **Cochrane Handbook for Systematic Reviews of Interventions version 6.0 (updated July 2019)**. Cochrane, 2019. Disponível em: <www.training.cochrane.org/handbook>. Acesso em: 26 fev. 2020.

TISCHENDORF, L. Can landscape indices predict ecological processes consistently? **Landscape Ecology**, v. 16, p. 235-254, 2001.

TÖRNBLM, J. et al. Catchment Land Cover as a Proxy for Macroinvertebrate Assemblage Structure in Carpathian Mountain Streams. **Hydrobiologia**, v. 673, n. 1, p. 153–168, set. 2011.

TURNER, M. G.; DONATO, D. C.; ROMME, W. H. Consequences of spatial heterogeneity for ecosystem services in changing forest landscapes: priorities for future research. **Landscape Ecology**, v. 28, n. 6, p. 1081–1097, 2013.

TURNER, M.; GARDNER, R. H. **Landscape Ecology in theory and practice**. 2nd ed. New York: Springer, 2015.

URIARTE, M. et al. Influence of land use on water quality in a tropical landscape: a multi-scale analysis. **Landscape Ecology**, v. 26, n. 8, p. 1151, 2011.

UUEMAA, E.; MANDER, Ü.; MARJA, R. Trends in the Use of Landscape Spatial Metrics as Landscape Indicators: A Review. **Ecological Indicators**, 10 years Ecological Indicators. v. 28, p. 100–106, 1 maio 2013.

VALENTIN, C.; POESEN, J.; LI, Y. Gully Erosion: Impacts, Factors and Control. **CATENA**, v. 63, n. 2–3, p. 132–153, out. 2005.

VALERA, C. A. et al. The Buffer Capacity of Riparian Vegetation to Control Water Quality in Anthropogenic Catchments from a Legally Protected Area: A Critical View over the Brazilian New Forest Code. **Water**, v. 11, n. 3, 549, mar. 2019.

VERHAGEN, W. et al. Effects of landscape configuration on mapping ecosystem service capacity: a review of evidence and a case study in Scotland. **Landscape Ecology**, v. 31, n. 7, p. 1457–1479, 2016.

VIGIAK, O. et al. Comparison of Conceptual Landscape Metrics to Define Hillslope-Scale Sediment Delivery Ratio. **Geomorphology**, v. 138, n. 1, p. 74–88, 1 fev. 2012.

VILLARD, M.-A.; METZGER, J. P. Beyond the Fragmentation Debate: A Conceptual Model to Predict When Habitat Configuration Really Matters. **Journal of Applied Ecology**, v. 51, n. 2, p. 309–318, 2014.

VÖRÖSMARTY, C. J. et al. Global Threats to Human Water Security and River Biodiversity. **Nature**, v. 467, n. 7315, p. 555–561, 30 set. 2010.

VOS, C. C. et al. Transferring ecological knowledge to landscape planning: a design method for robust corridors. *In*: WU, J.; HOBBS, R. (ed.). **Key Topics in Landscape Ecology**. Cambridge: Cambridge University Press, 2007. cap. 13, p. 227-245. (Cambridge Studies in Landscape Ecology)

WALKER, W. W. **Simplified procedures for eutrophication assessment and prediction:** user manual. US Army Corps of Engineers, 1999. 235 p. (Instruction report W-96-2).

WALTERS, H. M.; BRODY, S.; HIGHFIELD, W. Examining the relationship between development patterns and total phosphorus in the Galveston Bay Estuary. **Environmental Science and Policy**, v. 88, p. 10–16, 2018.

WANG, G. et al. The Influence of Land Use Patterns on Water Quality at Multiple Spatial Scales in a River System. **Hydrological Processes**, v. 28, n. 20, p. 5259–5272, 2014.

WANG, H.; WU, Z.; HU, C. A Comprehensive Study of the Effect of Input Data on Hydrology and Non-Point Source Pollution Modeling. **Water Resources Management**, v. 29, n. 5, p. 1505–1521, mar. 2015.

WANG, Q.; MALANSON, G. P. Neutral Landscapes: Bases for Exploration in Landscape Ecology. **Geography Compass**, v. 2, n. 2, p. 319–339, 2008.

WANG, Q.; MALANSON, G. P. Patterns of Correlation Among Landscape Metrics. **Physical Geography**, v. 28, n. 2, p. 170–182, 1 mar. 2007.

WHITE, H. Theory–Based Impact Evaluation: Principles and Practice. **The Journal of Development Effectiveness**, v. 1, p. 271–284, 2009.

WHITE, J. W. et al. Ecologists should not use statistical significance tests to interpret simulation model results. **Oikos**, v. 123, p. 385–388, 2014.

WHO (WORLD HEALTH ORGANIZATION). **Guidelines for drinking-water quality:** incorporating first addendum. Vol. 1, Recommendations. 3rd ed. Geneva: World Health Organization, 2006.

WICKHAM et al. **ggplot2:** Create Elegant Data Visualisations Using the Grammar of Graphics. 2021. R package version 3.3.5. Disponível em: <<https://CRAN.R-project.org/package=ggplot2>>. Acesso em: 10 mar. 2022.

WIENS, J. A. Central Concepts and Issues of Landscape Ecology. *In:* GUTZWILLER, K. J. (ed.). **Applying Landscape Ecology in Biological Conservation**. New York: Springer, 2002. cap 1, p. 3–21.

WILCOX, R. **Fundamentals of Modern Statistical Methods:** Substantially Improving Power and Accuracy. 2nd ed. Springer, 2010. 249 p.

WILCOX, R. **Introduction to Robust Estimation and Hypothesis Testing**. Elsevier, 2012. 690 p.

WILCOX, R. R.; TIAN, T. S. Measuring effect size: a robust heteroscedastic approach for two or more groups. **Journal of Applied Statistics**, v. 38, n. 7, p. 1359–1368, 1 jul. 2011.

WISCHMEIER, W. H.; JOHNSON, C. B.; CROSS, B. V. A Soil Erodibility Nomograph for Farmland and Construction Sites. **Journal of Soil and Water Conservation**, v. 26, p. 189–193, 1971.

WISCHMEIER, W. H.; SMITH, D. D. **Predicting rainfall-erosion losses from cropland east of the Rocky Mountains**: guide for selection of practices for soil and water conservation. Washington, DC: USDA, 1965.

WITH, K. A.; KING, A. W. The Use and Misuse of Neutral Landscape Models in Ecology. *Oikos*, v. 79, n. 2, p. 219–229, 1997.

WMO (WORLD METEOROLOGICAL ORGANIZATION). **Guide to Hydrological Practices**. Volume I. Hydrology – From Measurement to Hydrological Information. 6th ed. Geneva: WMO, 2008.

WOODCOCK, P.; PULLIN, A. S.; KAISER, M. J. Evaluating and improving the reliability of evidence syntheses in conservation and environmental science: A methodology. *Biological Conservation*, v. 176, n. Supplement C, p. 54–62, 2014.

WORLD MAPS OF KÖPPEN-GEIGER CLIMATE CLASSIFICATION. 2020. Disponível em: <<http://koeppen-geiger.vu-wien.ac.at/>>. Acesso em: 19 nov. 2020.

WU, J. Key Concepts and Research Topics in Landscape Ecology Revisited: 30 Years after the Allerton Park Workshop. *Landscape Ecology*, v. 28, n. 1, p. 1–11, 2013a.

WU, J. Landscape sustainability science (II): core questions and key approaches. *Landscape Ecology*, 2021.

WU, J. Landscape sustainability science: ecosystem services and human well-being in changing landscapes. *Landscape Ecology*, v. 28, p. 999–1023, 2013b.

WU, J.; HOBBS, R. Landscape ecology: the state-of-the-science. *In*: WU, J.; HOBBS, R. (ed.). **Key Topics in Landscape Ecology**. Cambridge: Cambridge University Press, 2007. cap. 15, p. 271 - 287. (Cambridge Studies in Landscape Ecology)

WU, J.; QI, Y. Dealing with Scale in Landscape Analysis: An Overview. *Geographic Information Sciences*, v. 6, n. 1, p. 1–5, 1 jun. 2000.

XIAO, H.; JI, W. Relating landscape characteristics to non-point source pollution in mine waste-located watersheds using geospatial techniques. *Journal of Environmental Management*, v. 82, n. 1, p. 111–119, 2007.

YE, Y. et al. Seasonal water quality upstream of Dahuofang Reservoir, China - the effects of land use type at various spatial scales. *Clean - Soil, Air, Water*, v. 42, n. 10, p. 1423–1432, 2014.

YUNUS, A. J. M.; NAKAGOSHI, N.; IBRAHIM, A. L. Application of GIS and remote sensing for measuring and evaluating land-use change and its impact on water quality in the Pinang River watershed. *Ecology and Civil Engineering*, v. 6, n. 1, p. 97–110, 2003.

ZAR, J. H. **Biostatistical Analysis**. 5th ed. New Jersey: Pearson Prentice Hall, 2010.

ZHANG, M. et al. A global review on hydrological responses to forest change across multiple spatial scales: Importance of scale, climate, forest type and hydrological regime. *Journal of Hydrology*, v. 546, p. 44–59, mar. 2017.

ZHANG, T.; YANG, X. Predicting Nitrogen Loading With Land-Cover Composition: How Can Watershed Size Affect Model Performance? **Environmental Management**, v. 51, n. 1, p. 96–107, 1 jan. 2013.

ZHANG, Z. Nonpoint Source and Water Quality Modeling. *In*: ESLAMIAN, S. (Ed.). **Handbook of Engineering Hydrology**: Environmental Hydrology and Water Management. London: CRC Press, 2014. cap 13, p. 261-298.

ZHOU, T.; WU, J.; PENG, S. Assessing the effects of landscape pattern on river water quality at multiple scales: A case study of the Dongjiang River watershed, China. **Ecological Indicators**, v. 23, p. 166–175, 2012.

ZUUR, A. F.; IENO, E. N.; ELPHICK, C. S. A protocol for data exploration to avoid common statistical problems. **Methods in Ecology and Evolution**, v. 1, p. 3-14, 2010.

ZUUR, A. F.; IENO, E. N.; SMITH, G. M. **Analysing Ecological Data**. New York: Springer, 2007. (Statistics for Biology and Health)

APÊNDICE A – Parâmetros de qualidade da água

Neste apêndice são apresentadas as descrições dos parâmetros de qualidade da água utilizados pelos estudos incluídos na revisão sistemática, divididos em físico-químicos e biológicos.

1 PARÂMETROS FÍSICO-QUÍMICOS

1.1 Compostos de nitrogênio

As formas de nitrogênio de maior interesse na avaliação das águas superficiais em ordem decrescente de estado oxidativo são: nitrato, nitrito, amônia e nitrogênio orgânico, sendo todos parte do ciclo do nitrogênio (BAIRD; EATON; RICE, 2017). São definidos como (BAIRD; EATON; RICE, 2017):

- a) Nitrato (NO_3^-) – íon de ocorrência natural. Medida: mg/L, μM ;
- b) Nitrito (NO_2^-) – íon de ocorrência natural. Estado oxidativo intermediário do nitrogênio (amônia para nitrato e redução do nitrato). Medida: mg/L;
- c) Amônia (NH_3 e NH_4^+) – inclui as formas ionizada e não ionizada. Produzida pela desaminação de compostos orgânicos de nitrogênio e pela hidrólise da ureia. Medida: mg/L, kg/km² dia;
- d) Nitrogênio orgânico – nitrogênio ligado organicamente no estado de oxidação -3. Inclui o nitrogênio orgânico total e a porção dissolvida. Medida: mg/L;
Além destes, outras formas avaliadas incluem (BAIRD; EATON; RICE, 2017):
- e) Nitrogênio Kjeldahl – nitrogênio orgânico + amônia. Medida: mg/L;
- f) Nitrogênio oxidado total – nitrato + nitrito. Medida: mg/L;
- g) Nitrogênio total – nitrogênio orgânico + amônia + nitrito + nitrato. Inclui as medidas de nitrogênio total, nitrogênio Kjeldahl, nitrogênio dissolvido total, razão *input/output* de nitrogênio, $\delta^{15}\text{N}$. Medida: mg/L, kg/ha ano.

A razão das cargas de entrada pelas cargas de saída em kg/ha (*input/output ratio*) foi utilizada por Lucas e Medley (2002). As cargas de entrada de N correspondem àquelas advindas da deposição atmosférica úmida, do esterco e de fertilizantes. As saídas correspondem às áreas de milho e soja colhidas e à carga que atinge os corpos d'água. Valores maiores indicam maior estoque e, conseqüentemente, melhor qualidade da água.

Isótopos de ocorrência natural também foram utilizados como parâmetros ($\delta^{15}\text{N-NO}_3$, $\delta^{18}\text{O-NO}_3$, $\delta^{15}\text{N}$), pois a sua abundância varia de acordo com a fonte (e.g., isótopo $\delta^{15}\text{N}$ é mais frequente em esterco e esgoto) (LIU et al., 2018).

1.2 Compostos de fósforo

Nas águas superficiais o fósforo ocorre majoritariamente na forma de fosfato (ortofosfato, fosfato condensado) e fosfatos organicamente ligados (BAIRD; EATON; RICE, 2017). Portanto:

- a) Fósforo total – Fósforo total, fosfato, ortofosfato, razão *input/output* de fósforo. Medidas: mg/L, $\mu\text{g/L}$, kg/ha ano, kg/km² dia.

Outras formas, modeladas pelo software SWAT são (ARNOLD et al., 2012):

- b) Fósforo solúvel – formas minerais solúveis de fósforo (kg/ha ano);
- c) Fósforo no sedimento – formas minerais de fósforo adsorvidas ao sedimento (kg/ha ano);
- d) Fósforo orgânico – formas orgânicas de fósforo transportadas com o sedimento (kg/ha ano).

A razão das cargas de entrada pelas cargas de saída em kg/ha (*input/output ratio*) foi utilizada por Lucas e Medley (2002). As cargas de entrada de P correspondem àquelas advindas da deposição atmosférica úmida, do esterco e de fertilizantes, enquanto as saídas correspondem às áreas de milho e soja colhidas e à carga que atinge os corpos d'água. Valores maiores indicam maior estoque e, conseqüentemente, melhor qualidade da água.

1.3 Elementos traço

Aqui são incluídos elementos que são encontrados em concentrações muito baixas na água (MANAHAN, 2000). Abrangem principalmente metais, mas também o Arsênio (As), um metaloide, e o selênio (Se), um não metal (MANAHAN, 2000). Estes elementos podem ter efeitos benéficos, prejudiciais ou tóxicos, dependendo da sua concentração no ambiente (BAIRD; EATON; RICE, 2017) e associação com outros elementos (MANAHAN, 2000).

Alguns desses elementos traço são metais potencialmente tóxicos, como o mercúrio, e outros são considerados nutrientes para animais e plantas, como o ferro (MANAHAN 2000). Porém, acima de certos limiares, todos eles podem se tornar tóxicos, causar efeitos cumulativos nos organismos, ou alterar os atributos de qualidade e prejudicar os diversos usos da água.

Alguns são usados no tratamento da água (e.g., alumínio), em pesticidas e outros agroquímicos (e.g., arsênio, chumbo, zinco), em ligas metálicas (e.g., cobre, ferro, vanádio, zinco, berílio, cádmio, titânio) ou são encontrados em efluentes industriais (e.g., arsênio, chumbo, mercúrio) (BAIRD; EATON; RICE, 2017). A abundância natural desses elementos depende da sua presença na crosta terrestre e da sua mobilidade durante processos de intemperismo e transporte (GAILLARDET; VIERS; DUPRÉ, 2003).

Foram incluídos: Alumínio (Al), Berílio (Be), Cádmio (Cd), Ferro (Fe), Chumbo (Pb), Titânio (Ti), Ítrio (Y), Zinco (Zn), Urânio (U), Tálcio (Tl), Selênio (Se), Arsênio (As), Mercúrio (Hg), Bário (Ba), Gálio (Ga), Escândio (Sc), Vanádio (V), Cobre (Cu), Rubídio (Rb). Medidas: $\mu\text{g/L}$, ppb.

1.4 Cálcio

Componente essencial para plantas e animais e amplamente utilizado em fertilizantes (BAIRD; EATON; RICE, 2017). Medidas: mg/L.

1.5 Potássio

Componente essencial para plantas e animais e amplamente utilizado em fertilizantes, explosivos, pigmentos e na galvanoplastia (BAIRD; EATON; RICE, 2017). Medidas: mg/L.

1.6 Sódio

Componente essencial para plantas e animais, tem função metabólica. Presente na soda cáustica, sal de cozinha, fertilizantes e usado no tratamento de água (BAIRD; EATON; RICE, 2017). Medidas: mg/L.

1.7 Cloro

Abrange o cloro total e o íon cloreto. Cl^- é o principal ânion inorgânico encontrado nas águas (BAIRD; EATON; RICE, 2017). Medidas: mg/L.

1.8 Sulfato

Íon SO_4^{2-} encontrado de forma ampla na natureza (BAIRD; EATON; RICE, 2017).

Medidas: mg/L.

1.9 Dióxido de carbono

Indica a concentração do gás carbônico dissolvido na água. Medidas: mg/L.

1.10 Sólidos

Os sólidos se referem à matéria suspensa ou dissolvida na água, sendo particionados em (BAIRD; EATON; RICE, 2017):

- a) Sólidos totais – material que permanece após evaporação e secagem da amostra de água em uma temperatura específica. Incluem os sólidos suspensos e dissolvidos. Medidas: mg/L;
- b) Sólidos dissolvidos totais – porção dos sólidos totais que atravessa um filtro com capacidade de retenção de partículas maiores que 2 μm em determinadas condições. Medidas: mg/L;
- c) Sólidos suspensos totais – porção dos sólidos totais que é retida por um filtro com capacidade de retenção de partículas maiores que 2 μm em determinadas condições. Medidas: mg/L;
- d) Sólidos suspensos orgânicos – fração dos sólidos suspensos totais que é composta por matéria orgânica. Medidas: mg/L.

1.11 Carbono

As medidas de carbono encontradas foram carbono total, carbono orgânico e carbono inorgânico, definidas como (BAIRD; EATON; RICE, 2017):

- a) Carbono orgânico total – abrange todos os átomos de carbono ligados covalentemente com moléculas orgânicas. Engloba a matéria orgânica em vários estados de oxidação. É uma forma mais direta de expressar o conteúdo de carbono orgânico do que medidas de DBO e DQO. Medidas: mg/L;
- b) Carbono inorgânico total – fração inorgânica do carbono total, formada basicamente por carbonato, bicarbonato e gás carbônico dissolvido. Medidas: mg/L;
- c) Carbono total – soma das frações orgânicas e inorgânicas. Medidas: mg/L.

1.12 Demanda Bioquímica de Oxigênio (DBO)

Este indicador mensura a quantidade necessária para degradar bioquimicamente a matéria orgânica, oxidar material inorgânico e/ou oxidar formas reduzidas de nitrogênio (BAIRD; EATON; RICE, 2017). É um parâmetro muito usado para medir as cargas de efluentes e a eficiência de estações de tratamento de água (BAIRD; EATON; RICE, 2017). Medidas: mg/L.

1.13 Demanda Química de Oxigênio (DQO)

Mensura a quantidade, geralmente expressa em termos equivalentes de oxigênio, de um oxidante específico que reage com a amostra sob condições controladas (BAIRD; EATON; RICE, 2017). O oxidante utilizado geralmente é o dicromato de potássio, mas também é possível usar o permanganato de potássio. Uma diferença entre a DBO e a DQO é que esta última oxida toda a matéria orgânica, incluindo aquela não biodegradável (PARKER; RHOADES, 2008). Medidas: mg/L.

1.14 Oxigênio dissolvido

Indica a concentração de oxigênio dissolvido na água. Medidas: mg/L, kg/km² dia.

1.15 Condutividade

Mensura a habilidade de uma solução aquosa em transmitir uma corrente elétrica. A presença de íons pode afetar a condutividade, sendo que soluções com compostos inorgânicos costumam ser boas condutoras, enquanto as com compostos orgânicos costumam ser más condutoras (BAIRD; EATON; RICE, 2017). Medidas: $\mu\text{S}/\text{cm}$, mS/cm .

1.16 Alcalinidade

Exprime a capacidade da água em neutralizar um ácido. A alcalinidade das águas superficiais indica geralmente a presença de carbonato, bicarbonato e hidróxidos, mas também

pode apontar a contribuição de boratos, fosfatos, silicatos e outras bases (BAIRD; EATON; RICE, 2017). Medidas: Alcalinidade (mg/L, meq/L), bicarbonato (HCO_3) (mg/L).

1.17 Salinidade

Indica a massa de sais dissolvidos em uma massa de solução. Métodos indiretos como medidas de condutividade, densidade, velocidade do som e índice refrativo são utilizados para mensurar a salinidade (BAIRD; EATON; RICE, 2017). Medidas: ng/L, ppt.

1.18 pH

Especifica a intensidade do caráter ácido ou básico de uma solução em uma determinada temperatura de acordo com a atividade dos íons hidrogênio (BAIRD; EATON; RICE, 2017). Medida: 0 a 14.

1.19 Temperatura

Indica a energia térmica da água. Medidas: °C.

1.20 Cor

Este parâmetro indica principalmente a presença de matéria orgânica natural na água de forma dissolvida, sem considerar a influência de partículas suspensas (BAIRD; EATON; RICE, 2017). Quando a matéria suspensa não é eliminada da amostra, é mensurada a “cor aparente” da água (BAIRD; EATON; RICE, 2017). Medidas: Absorbância a 254nm e 420nm, escala platina-cobalto (Pt-Co).

1.21 Turbidez e claridade

Turbidez e claridade são medidas distintas dos efeitos óticos de sedimentos suspensos, mas que são inversamente correlacionadas (DAVIES-COLLEY; SMITH, 2001).

A turbidez mede a capacidade da luz em ser espalhada e absorvida em vez de transmitida sem alterações através de uma amostra de água (BAIRD; EATON; RICE, 2017). A presença de matéria suspensa e coloidal, como partículas de argila, silte, matéria orgânica e inorgânica,

plâncton, entre outros, altera a turbidez da água (BAIRD; EATON; RICE, 2017). Medidas: mg/L, FTU (unidade de turbidez formazina), NTU (unidade nefelométrica de turbidez).

A claridade mede a capacidade de transmissão da luz na água (BREZONIK; ARNOLD, 2011). Medidas: profundidade de Secchi (m).

1.22 Acidez

Indica a capacidade da água em reagir com uma base forte em um determinado pH (BAIRD; EATON; RICE, 2017). A acidez pode aumentar devido à presença de ácidos minerais fortes, ácidos fracos (e.g., carbônico e acético) e sais hidrolisáveis (e.g., sulfato de ferro e alumínio) (BAIRD; EATON; RICE, 2017). Medidas: mg/L.

1.23 Óleos e graxas

Inclui substâncias com características físicas similares identificadas a partir da sua solubilidade em um solvente de extração orgânico (BAIRD; EATON; RICE, 2017). Medidas: mg/L.

1.24 Fenol volátil

Compostos com uma ou mais hidroxilas (OH) ligadas a um anel aromático (BAIRD; EATON; RICE, 2017). Medidas: mg/L.

1.25 Herbicidas

Abrangem os compostos metolaclo e atrazina, que são aplicados nas lavouras e possuem relativa mobilidade em atingir a água superficial e subterrânea (WHO, 2006). Medidas: µg/L.

2 PARÂMETROS BIOLÓGICOS

2.1 Densidade de macroinvertebrados

Os macroinvertebrados bentônicos são organismos que habitam o sedimento ou substrato do fundo do ambiente aquático, incluindo principalmente platelmintos, anelídeos, moluscos, crustáceos e insetos (BAIRD; EATON; RICE, 2017). São usados como indicadores biológicos de qualidade da água superficial porque permitem identificar alterações causadas por resíduos domésticos, industriais e agrícolas (BAIRD; EATON; RICE, 2017). Diversos índices, como a densidade, podem ser avaliados e comparados com condições de referência (BAIRD; EATON; RICE, 2017). Foram obtidos dados de Coleoptera, Amphipoda, Diptera, Ephemeroptera, Gastropoda, Oligochaeta, Plecoptera e Trichoptera. Medidas: indivíduos/m².

2.2 Índices bióticos

Os Índices de Integridade Biótica (IBI) combinam diversos indicadores de condições ecológicas relativos a organismos de interesse de forma a obter uma pontuação que é comparada a uma condição de referência, i.e., uma área não impactada (CANNING; DEATH, 2019). Esses índices são comumente baseados em macroinvertebrados bentônicos, porém, peixes, fitoplâncton e macrófitas também podem ser incluídos. Os índices utilizados pelos estudos da revisão sistemática incluem:

Potter, Cabbage e Schaberg (2005): Índice Biótico Ephemeroptera, Plecoptera e Trichoptera (*EPT Biotic Index*) e Índice Biótico da Carolina do Norte (*NC Biotic Index*), que apontam a presença de invertebrados menos e mais tolerantes à degradação da qualidade da água. Variam de 0 (i.e., melhor qualidade da água) a 10 (i.e., pior qualidade da água).

Clément et al. (2017): O Índice de Diatomáceas do leste do Canadá (*Indice Diatomées de l'Est du Canada - IDEC*) integra os efeitos de múltiplos estressores nos riachos, especialmente aqueles relacionados à eutrofização, e reflete o estado trófico do rio. Varia de 0 (i.e., pior qualidade da água) a 100 (i.e., melhor qualidade da água).

Alberti et al. (2007) e Shandas e Alberti (2009): O Índice de Integridade Biótica bentônica (B-IBI) combina riqueza, diversidade, atributos populacionais, tolerância a perturbações, alimentação e outros hábitos dos macroinvertebrados. Varia de 10 (i.e., pior qualidade da água) a 50 (i.e., melhor qualidade da água).

Klauda et al. (1998): O Índice de Integridade Biótica de assembleias de peixes (*fish IBI*) compara a condição de assembleias de peixes nos locais amostrados com condições de referência. Inclui como métricas o número de espécies nativas, espécies bentônicas, espécies tolerantes, generalistas, onívoros, abundância, entre outras. Varia de 1 (i.e., pior qualidade da água) a 5 (i.e., melhor qualidade da água).

2.3 Coliformes totais

Esse grupo inclui bactérias gram-negativas, não formadoras de esporos, anaeróbias facultativas, com forma de bastonete, fermentadoras de lactose e que desenvolvem colônias em meios específicos (BAIRD; EATON; RICE, 2017). Embora possam identificar contaminação fecal ou presença de bactérias patogênicas, não são considerados indicadores específicos de poluição fecal (ASHBOLT; GRABOW; SNOZZI, 2001). Medidas: ufc/100 mL.

2.4 Coliformes fecais

Atuam como indicadores de poluição fecal, pois geralmente são encontrados nas fezes humanas e de animais de sangue quente, embora haja espécies no ambiente que não se relacionam diretamente com poluição fecal (BAIRD; EATON; RICE, 2017). Destacam-se a bactéria *Escherichia coli*, bem como os estreptococos fecais, que englobam os gêneros *Enterococcus* e *Streptococcus* (ASHBOLT; GRABOW; SNOZZI, 2001). Medidas: células/100 mL, ufc/100 mL, número mais provável.

Uriarte et al. (2011) utilizaram a razão coliformes fecais/estreptococos fecais (FC/FS) como indicador de uma maior contribuição de material fecal humano, que tipicamente é expressa por um maior valor dessa razão (MEAYS et al., 2004).

2.5 Clorofila a

A concentração deste pigmento fotossintético é utilizada para mensurar a biomassa do fitoplâncton (BAIRD; EATON; RICE, 2017). A biomassa pode indicar mudanças na estrutura da comunidade (CANNING; DEATH, 2019) em razão da concentração dos nutrientes na água, ajudando a prever florações de cianobactérias (SUN et al., 2014). Medidas: µg/L, mg/L.

3 OUTROS PARÂMETROS

3.1 Índice de Potencial Poluidor

Se refere ao potencial de poluição por fontes não pontuais, tendo sido utilizado por Johnson, Myers e Patil (2001). É uma combinação ponderada de outros índices: índice de

escoamento, índice de uso químico, índice de produção de sedimentos, e índice de carga animal. Valores maiores indicam maior carga poluidora.

3.2 Índice de Qualidade da Água

Índice que combina medidas de oxigênio dissolvido, pH, DBO, DQO, sólidos suspensos totais e nitrogênio amoniacal. Aplicado por Yunus, Nakagoshi e Ibrahim (2003), foi desenvolvido pelo *Malaysian Department of Environment*. Varia de 0 (i.e., pior qualidade da água) a 100 (i.e., melhor qualidade da água).

APÊNDICE B – Métricas de paisagem

A descrição e cálculo das métricas utilizadas pelos artigos da revisão sistemática e no experimento de simulação foram extraídas de McGarigal (2015), exceto quando indicado. As classes de uso e cobertura do solo são identificadas pelos termos “classe” e “tipo de mancha”. Quando conveniente, são descritas as interpretações da métrica em nível de classe e paisagem, mas não em nível de mancha, pois esse último não foi objeto de estudo deste trabalho. Algumas métricas calculadas pelo software *Fragstats* (MCGARIGAL; CUSHMAN; ENE, 2012) são fornecidas em nível de classe e paisagem por meio de parâmetros estatísticos: média, média ponderada pela área, mediana, amplitude, desvio padrão e coeficiente de variação. Esses parâmetros são descritos nos Quadros B.1 e B.2.

As métricas são apresentadas em dois blocos: i) composição e ii) configuração. Composição inclui medidas de abundância proporcional, riqueza, equabilidade e diversidade. Configuração abrange índices de área e borda, forma, área central, contraste e agregação, bem como outros aspectos da configuração, como a posição das manchas. Dentro da categoria “agregação” estão incluídas métricas que abordam conceitos de dispersão, intercalação, subdivisão e isolamento. Mais informações sobre o cálculo de cada métrica são encontradas em McGarigal (2015).

Quadro B.1 – Parâmetros estatísticos usados para caracterizar as métricas em nível de classe

Parâmetro estatístico	Cálculo	
Média	$MN = \frac{\sum_{j=1}^n x_{ij}}{n_i}$	x_{ij} = valor da métrica por mancha n_i = número de manchas da mesma classe
Média ponderada pela área	$AM = \sum_{j=1}^n \left[x_{ij} \left(\frac{a_{ij}}{\sum_{j=1}^n a_{ij}} \right) \right]$	x_{ij} = valor da métrica por mancha a_{ij} = área de cada mancha
Mediana	$MD = X_{50\%}$	$X_{50\%}$ = valor central do conjunto ranqueado de valores da métrica
Amplitude	$RA = X_{max} - X_{min}$	X_{max} = maior valor da métrica X_{min} = menor valor da métrica
Desvio padrão	$SD = \sqrt{\frac{\sum_{j=1}^n \left[x_{ij} - \left(\frac{\sum_{j=1}^n x_{ij}}{n_i} \right) \right]^2}{n_i}}$	x_{ij} = valor da métrica por mancha n_i = número de manchas da mesma classe
Coeficiente de variação	$CV = \frac{SD}{MN} \times 100$	SD = desvio padrão MN = média

Fonte: Adaptado de McGarigal (2015).

Quadro B.2 – Parâmetros estatísticos usados para caracterizar as métricas em nível de paisagem

Parâmetro estatístico	Cálculo	
Média	$MN = \frac{\sum_{i=1}^m \sum_{j=1}^n x_{ij}}{N}$	x_{ij} = valor da métrica por mancha N = número total de manchas
Média ponderada pela área	$AM = \sum_{i=1}^m \sum_{j=1}^n \left[x_{ij} \left(\frac{a_{ij}}{\sum_{i=1}^m \sum_{j=1}^n a_{ij}} \right) \right]$	x_{ij} = valor da métrica por mancha a_{ij} = área de cada mancha
Mediana	$MD = X_{50\%}$	$X_{50\%}$ = valor central do conjunto ranqueado de valores da métrica
Amplitude	$RA = X_{max} - X_{min}$	X_{max} = maior valor da métrica X_{min} = menor valor da métrica
Desvio padrão	$SD = \sqrt{\frac{\sum_{i=1}^m \sum_{j=1}^n \left[x_{ij} - \left(\frac{\sum_{i=1}^m \sum_{j=1}^n x_{ij}}{N} \right) \right]^2}{N}}$	x_{ij} = valor da métrica por mancha N = número total de manchas
Coefficiente de variação	$CV = \frac{SD}{MN} \times 100$	SD = desvio padrão MN = média

Fonte: Adaptado de McGarigal (2015).

1 MÉTRICAS DE COMPOSIÇÃO

1.1 Abundância proporcional

Porcentagem da paisagem (*Percentage of Landscape – PLAND*)

$$PLAND = P_i = \frac{\sum_{j=1}^n a_{ij}}{A} \times 100$$

P_i = proporção da paisagem ocupada pela classe i ;

a_{ij} = área (m²) da mancha ij ;

A = área da paisagem (m²).

Porcentagem da paisagem ocupada por uma determinada classe de uso e cobertura do solo.

Medida: %, $0 < PLAND \leq 100$

Índice de poluição da cobertura do solo (*Land Cover Pollution Index - LCPI*)

Índice calculado por De Oliveira, Maillard e Andrade Pinto (2017), é mensurado pela razão entre a área de classes de uso e cobertura do solo identificadas como fontes (*source*) e classes consideradas sumidouros (*sink*) em uma determinada paisagem.

1.2 Riqueza

Densidade de riqueza de manchas (*Patch Richness Density – PRD*)

$$PRD = \frac{m}{A} \times 10000 \times 100$$

m = número de classes presentes na paisagem, excluindo a borda da paisagem, se presente;
A = área da paisagem (m²).

Representa o número de diferentes tipos de manchas presentes em toda a paisagem por unidade de área.

Medida: número por 100 hectares, PRD > 0, sem limite

1.3 Equabilidade

Índice de equabilidade de Shannon (*Shannon's Evenness Index – SHEI*)

$$SHEI = \frac{-\sum_{i=1}^m (P_i \times \ln P_i)}{\ln m}$$

P_i = proporção da paisagem ocupada pela classe i;
m = número de classes presentes na paisagem, excluindo a borda da paisagem se presente.

É um indicador de equabilidade, uma medida de abundância relativa das classes. Valores próximos de zero ocorrem quando a distribuição da área entre os diferentes tipos de mancha se torna desigual (i.e., dominado por uma classe). O índice atinge valor máximo quando a área da paisagem está distribuída igualmente entre os tipos de mancha.

Medida: $0 \leq SHEI \leq 1$

Índice da maior mancha (*Largest Patch Index – LPI*)

$$\text{Classe} \quad LPI = \frac{\max(a_{ij})_{j=1}^n}{A} \times 100$$

$$\text{Paisagem} \quad LPI = \frac{\max(a_{ij})}{A} \times 100$$

a_{ij} = área (m²) da mancha ij;
A = área da paisagem (m²).

Exprime a porcentagem da paisagem ocupada pela maior mancha. Pode ser medida em nível de classe ou paisagem. Valores próximos de zero indicam que a maior mancha é muito pequena com relação à paisagem, enquanto $LPI = 100$ indica que a maior mancha ocupa 100% da área. É uma medida de dominância, o complemento da equabilidade.

Medida: %, $0 < LPI \leq 100$

1.4 Diversidade

Índice de diversidade de Shannon (*Shannon's Diversity Index – SHDI*)

$$SHDI = - \sum_{i=1}^m (P_i \times \ln P_i)$$

P_i = proporção da paisagem ocupada pela classe i .

Mensura a diversidade da paisagem, cujo valor aumenta à medida que a riqueza de tipos de manchas aumenta e/ou a distribuição proporcional da área entre esses tipos se torna mais equitativa.

Medida: $SHDI \geq 0$, sem limite

2 MÉTRICAS DE CONFIGURAÇÃO

2.1 Área e borda

Área da mancha (*Patch Area – AREA*)

$$AREA = a_{ij} \times \frac{1}{10000}$$

a_{ij} = área (m²) da mancha ij .

Área das manchas, podendo ser calculada em nível de classe e paisagem. Geralmente é calculada considerando a média, média ponderada pela área, mediana, amplitude, desvio padrão e coeficiente de variação.

Medida: hectares, $AREA > 0$, sem limite

Comprimento de borda total (*Total Edge – TE*) e médio (*Mean Patch Edge – PE_MN*)

Classe

$$TE = \sum_{k=1}^m e_{ik}$$

Paisagem	$TE = E$
e_{ik} = comprimento total (m) do perímetro envolvendo a classe i, inclui a borda da paisagem e segmentos de fundo envolvendo a classe i;	
E = comprimento total (m) dos segmentos de perímetro na paisagem.	

TE indica a soma do comprimento dos segmentos de borda que envolvem as manchas. Pode ser calculada em nível de classe e paisagem. Além da borda total, pode-se calcular o comprimento de borda médio.

Medida: metros, TE ou PE_MN ≥ 0 , sem limite.

Densidade de borda (*Edge Density – ED*)

Classe	$ED = \frac{\sum_{k=1}^m e_{ik}}{A} \times 10000$
Paisagem	$ED = \frac{E}{A} \times 10000$
e_{ik} = comprimento total (m) do perímetro envolvendo a classe i, inclui a borda da paisagem e segmentos de fundo envolvendo a classe i;	
E = comprimento total (m) dos segmentos de perímetro na paisagem;	
A = área total da paisagem (m ²).	

Soma do comprimento dos segmentos de borda que envolvem as manchas dividido pela área total da paisagem. Pode ser calculada em nível de classe e paisagem. A diferença para o comprimento de borda total é que esta medida é padronizada por área, permitindo a comparação entre paisagens de tamanhos diferentes.

Medida: metros por hectare, ED ≥ 0 , sem limite

Raio de rotação (*Radius of Gyration – GYRATE*)

	$GYRATE = \sum_{r=1}^z \frac{h_{ijr}}{z}$
h_{ijr} = distância (m) entre o pixel ijr , localizado dentro da mancha ij , e o centroide da mancha ij , baseado na distância entre os centros do pixel;	
z = número de pixels na mancha ij .	

Essa medida indica a extensão da mancha, ou seja, seu alcance na paisagem. Quando a mancha é formada por um único pixel, seu valor é zero, e à medida que a mancha aumenta sua extensão, maior é o valor desta métrica. Pode ser calculada em nível de classe e paisagem por meio de medidas como média, média ponderada pela área, mediana, amplitude, desvio padrão e coeficiente de variação.

Medida: metros, GYRATE ≥ 0 , sem limite

2.2 Forma

Razão perímetro-área (*Perimeter-Area Ratio – PARA*)

$$PARA = \frac{p_{ij}}{a_{ij}}$$

p_{ij} = perímetro (m) da mancha ij;
 a_{ij} = área (m²) da mancha ij.

Mensura a razão entre o perímetro e área das manchas. Mede a complexidade da forma, ou seja, valores maiores indicam formas mais complexas. No entanto, essa medida não é padronizada e varia de acordo com o tamanho da mancha. Pode ser calculada em nível de classe e paisagem por meio de medidas como média, média ponderada pela área, mediana, amplitude, desvio padrão e coeficiente de variação.

Medida: PARA > 0, sem limite

Índice de forma (*Shape Index – SHAPE*)

$$SHAPE = \frac{0,25 \times p_{ij}}{\sqrt{a_{ij}}}$$

p_{ij} = perímetro (m) da mancha ij;
 a_{ij} = área (m²) da mancha ij.

É calculado pela razão entre o perímetro e a raiz quadrada da área da mancha, ajustada por meio de uma constante. Mede a complexidade da forma ajustando os valores com base em uma forma quadrada. Valores iguais a um (1) indicam que a mancha tem forma quadrada, enquanto valores maiores que um (1) apontam que a forma da mancha se torna mais irregular. Pode ser calculada em nível de classe e paisagem por meio de medidas como média, média ponderada pela área, mediana, amplitude, desvio padrão e coeficiente de variação.

Medida: SHAPE ≥ 1, sem limite

Índice de dimensão fractal (*Fractal Dimension Index – FRAC*)

$$FRAC = \frac{2 \ln(0,25 \times p_{ij})}{\ln a_{ij}}$$

p_{ij} = perímetro (m) da mancha ij;
 a_{ij} = área (m²) da mancha ij.

É indicado por duas vezes o logaritmo do perímetro da mancha dividido pelo logaritmo da área da mancha, sendo o perímetro ajustado por uma constante. Valores próximos de um (1) apontam formas simples semelhantes a um quadrado, enquanto valores próximos de dois (2) indicam formas complexas com perímetros altamente convolutos, i.e., que desviam da geometria euclidiana. Pode ser calculada em nível de classe e paisagem por meio de medidas como média, média ponderada pela área, mediana, amplitude, desvio padrão e coeficiente de variação.

Medida: $1 \leq \text{FRAC} \leq 2$

Círculo circunscrito relacionado (*Related Circumscribing Circle* – CIRCLE)

$$\text{CIRCLE} = 1 - \left(\frac{a_{ij}}{a_{ij}^s} \right)$$

a_{ij} = área (m²) da mancha ij;

a_{ij}^s = área (m²) do menor círculo circunscrito no entorno da mancha ij.

Seu cálculo é feito ao se dividir a área da mancha pela área do seu menor círculo circunscrito e subtrair esse valor de 1. Manchas de forma mais circular têm valores próximos de zero, enquanto manchas com valores próximos de um (1) têm forma mais alongada. Pode ser calculada em nível de classe e paisagem por meio de medidas como média, média ponderada pela área, mediana, amplitude, desvio padrão e coeficiente de variação.

Medida: $0 \leq \text{CIRCLE} < 1$

Índice de contiguidade (*Contiguity Index* – CONTIG)

$$\text{CONTIG} = \frac{\left(\frac{\sum_{r=1}^z c_{ijr}}{a_{ij}^*} \right) - 1}{v - 1}$$

c_{ijr} = valor de contiguidade para o pixel r na mancha ij;

v = soma dos valores em um *template* 3x3;

a_{ij}^* = área da mancha ij em termos de número de pixels.

Avalia a conectividade espacial dos pixels dentro de uma mancha, mensurando a configuração da sua borda, ou seja, sua forma (LAGRO JR., 1991). Valor zero indica uma mancha com apenas um pixel, enquanto valores próximos de um (1) indicam uma maior contiguidade da mancha. Pode ser calculada em nível de classe e paisagem por meio de medidas como média, média ponderada pela área, mediana, amplitude, desvio padrão e coeficiente de variação.

Medida: $0 \leq \text{CONTIG} \leq 1$

Dimensão fractal perímetro-área (*Perimeter-Area Fractal Dimension – PAFRAC*)

Classe	2
	$PAFRAC = \frac{[n_i \sum_{j=1}^n (\ln p_{ij} \times \ln a_{ij})] - [(\sum_{j=1}^n \ln p_{ij}) \times (\sum_{j=1}^n \ln a_{ij})]}{(n_i \sum_{j=1}^n \ln p_{ij}^2) - (\sum_{j=1}^n \ln p_{ij})^2}$
<p>p_{ij} = perímetro (m) da mancha ij; a_{ij} = área (m²) da mancha ij; n_i = número de manchas da classe i na paisagem.</p>	

Esta medida reflete a complexidade da forma das manchas, sendo que paisagens com fragmentos com formas simples (e.g., quadradas) possuem valores próximos de 1, enquanto paisagens com fragmentos mais complexos e perímetros convolutos apresentam valores próximos de 2. É calculada utilizando uma regressão do logaritmo da área pelo logaritmo do perímetro da mancha. O cálculo pelo *Fragstats* exige um mínimo de 10 manchas e que haja variação em seus tamanhos.

Medida: $1 \leq \text{PAFRAC} \leq 2$

2.3 Área central

Área central total (*Total Core Area – TCA*) e área sob efeito de borda (*Area under Edge Effect – AEE*)

$TCA = \sum_{j=1}^n a_{ij}^c \times \frac{1}{10000}$
$AEE = \sum_{j=1}^n a_{ij} \times \left(\frac{1}{10000}\right) - TCA$
<p>a_{ij}^c = área central (m²) da mancha ij baseada no comprimento do efeito de borda definido (m); a_{ij} = área (m²) da mancha ij.</p>

Índica a área dentro da mancha que está além de uma determinada distância da borda daquela mancha. A região que está dentro da distância especificada pode ser denominada área sob efeito de borda. Essa métrica tem importância ecológica, pois o efeito de borda engloba os processos bióticos e abióticos que ocorrem nas bordas dos fragmentos e que resultam em alterações na composição, estrutura e função dessas manchas (HARPER et al., 2005). Além do valor total, pode ser calculada em nível de classe e paisagem por meio de medidas como média, média ponderada pela área, mediana, amplitude, desvio padrão e coeficiente de variação.

Medida: hectares, CORE ou AEE ≥ 0 , sem limite

2.4 Contraste

Índice de contraste de borda (*Edge Contrast Index – ECON*)

$$ECON = \frac{\sum_{k=1}^m (p_{ijk} \times d_{ik})}{p_{ij}} \times 100$$

p_{ijk} = comprimento (m) do perímetro da mancha ij adjacente à classe k;

d_{ik} = dissimilaridade (pesos de contraste) entre as classes i e k;

p_{ij} = comprimento (m) do perímetro da mancha ij.

Mede a magnitude da diferença entre coberturas adjacentes por meio da atribuição de pesos de contraste para combinações pareadas de tipos de manchas. Valor zero indica que a paisagem consiste em apenas uma mancha, enquanto o valor máximo indica que todo o perímetro das manchas tem máximo contraste de borda. Valores menores que 100 ocorrem quando uma porção do perímetro da mancha não tem máximo contraste. Pode ser calculada em nível de classe e paisagem por meio de medidas como média, média ponderada pela área, mediana, amplitude, desvio padrão e coeficiente de variação.

Medida: %, $0 \leq ECON \leq 100$

2.5 Agregação

Índice de intercalação e justaposição (*Interspersion & Juxtaposition Index – IJI*)

Classe

$$IJI = \frac{-\sum_{k=1}^m \left[\left(\frac{e_{ik}}{\sum_{k=1}^m e_{ik}} \right) \ln \left(\frac{e_{ik}}{\sum_{k=1}^m e_{ik}} \right) \right]}{\ln(m-1)} \times 100$$

Paisagem

$$IJI = \frac{-\sum_{i=1}^m \sum_{k=i+1}^m \left[\left(\frac{e_{ik}}{E} \right) \ln \left(\frac{e_{ik}}{E} \right) \right]}{\ln(0,5[m(m-1)])} \times 100$$

e_{ik} = comprimento total (m) do perímetro na paisagem entre as classes i e k;

m = número de classes presentes na paisagem, incluindo a borda da paisagem, se presente;

E = comprimento total (m) dos perímetros na paisagem, excluindo o *background*.

Índice medido a partir de adjacências entre as manchas, podendo ser calculado em nível de classe e paisagem. Em nível de classe, valores próximos de zero ocorrem quando a classe analisada está adjacente a uma única classe diferente e quando o número de tipos de cobertura aumenta. O valor máximo ocorre quando uma determinada classe está igualmente adjacente a todas as outras, ou seja, intercalada e justaposta ao máximo. Em nível de paisagem, valores

próximos de zero indicam que a distribuição das adjacências entre as classes é desigual, e o valor máximo ocorre quando todas as classes se encontram igualmente adjacentes entre si. Essa métrica exige um mínimo de três classes para ser calculada.

Medida: %, $0 < IJI \leq 100$

Porcentagem de adjacências semelhantes (*Percentage of Like Adjacencies – PLADJ*)

Classe	$PLADJ = \left(\frac{g_{ii}}{\sum_{k=1}^m g_{ik}} \right) \times 100$
Paisagem	$PLADJ = \left(\frac{\sum_{i=1}^m g_{ii}}{\sum_{i=1}^m \sum_{k=1}^m g_{ik}} \right) \times 100$
<p>g_{ii} = número de adjacências semelhantes (junções) entre pixels da classe i baseado no método de contagem dupla (<i>double-count</i>);</p> <p>g_{ik} = número de adjacências entre pixels das classes i e k baseado no método de contagem dupla (<i>double-count</i>).</p>	

Mede o grau de dispersão, independentemente da proporção das classes na paisagem. Em nível de classe, essa métrica indica a porcentagem das adjacências entre pixels que são adjacências semelhantes, ou seja, de um mesmo tipo de uso e cobertura. Em nível de paisagem, mensura a agregação dos diferentes tipos de mancha. Quando $PLADJ = 0$, a classe ou todas as classes estão desagregadas ao máximo (i.e., cada pixel é uma mancha), não havendo adjacências semelhantes. Seu valor aumenta à medida que a proporção de adjacências semelhantes aumenta, o que indica uma maior agregação dos pixels de uma classe ou de todas as classes.

Medida: %, $0 \leq PLADJ \leq 100$

Índice de agregação (*Aggregation Index – AI*)

Classe	$AI = \left(\frac{g_{ii}}{\max g_{ii}} \right) \times 100$
Paisagem	$AI = \left[\sum_{i=1}^m \left(\frac{g_{ii}}{\max g_{ii}} \right) P_i \right] \times 100$
<p>g_{ii} = número de adjacências semelhantes (junções) entre pixels da classe i baseado no método de contagem única (<i>single-count</i>);</p> <p>$\max g_{ii}$ = número máximo de adjacências semelhantes (junções) entre pixels da classe i baseado no método de contagem única (<i>single-count</i>);</p> <p>P_i = proporção da paisagem ocupada pela classe i.</p>	

Índice similar ao PLADJ, porém, é calculado usando um método em que a adjacência semelhante é computada apenas uma vez (*single-count method*). Pode ser computado em nível de classe e paisagem. Atinge valor zero quando a classe (em nível de classe) ou as classes (em

nível de paisagem) se encontram desagregadas ao máximo, i.e., sem adjacências semelhantes. Seu valor aumenta à medida que a classe ou as classes se agregam, atingindo valor máximo quando a classe ou a paisagem está concentrada em uma única mancha compacta.

Medida: %, $0 \leq AI \leq 100$

Índice de aglomeração (*Clumpiness Index* – CLUMPY)

Dado que: $G_i = \frac{g_{ii}}{\sum_{k=1}^m g_{ik}}$

$$\frac{G_i - P_i}{1 - P_i} \text{ para } G_i \geq P_i$$

$$CLUMPY = \frac{G_i - P_i}{1 - P_i} \text{ para } G_i < P_i ; P_i \geq 0,5$$

$$\frac{P_i - G_i}{-P_i} \text{ para } G_i < P_i ; P_i < 0,5$$

g_{ii} = número de adjacências semelhantes (junções) entre pixels da classe i baseado no método de contagem dupla (*double-count*);

g_{ik} = número de adjacências entre pixels das classes i e k baseado no método de contagem dupla (*double-count*);

P_i = proporção da paisagem ocupada pela classe i .

Essa métrica indica a agregação de uma determinada classe e fornece uma medida da fragmentação sem a influência da área ocupada na paisagem. Os valores positivos sugerem um maior contágio e, conseqüentemente, uma classe mais agregada. Valor zero indica uma distribuição aleatória da classe independentemente da sua proporção na paisagem. Os valores negativos indicam uma classe mais desagregada do que o esperado considerando um padrão aleatório de dispersão.

Medida: porcentagem, $-1 \leq CLUMPY \leq 1$

Índice de forma da paisagem (*Landscape Shape Index* – LSI)

Classe $LSI = \frac{0,25 \sum_{k=1}^m e_{ik}^*}{\sqrt{A}}$

Paisagem $LSI = \frac{0,25 E^*}{\sqrt{A}}$

e_{ik}^* = comprimento total (m) do perímetro na paisagem entre as classes i e k , inclui a borda da paisagem e segmentos de perímetro do *background* envolvendo a classe i ;

E^* = comprimento total (m) do perímetro na paisagem, inclui a borda da paisagem e segmentos de perímetro do *background*;

A = área total da paisagem (m²).

Essa métrica provê uma medida padronizada para quantidade de borda ou densidade de borda ajustando para o tamanho da paisagem analisada. Pode ser calculada em nível de classe ou paisagem. O valor mínimo ocorre quando a classe ou a paisagem consiste em uma simples mancha quadrada, aumentando à medida que a forma se torna mais irregular e/ou o comprimento da borda de uma classe ou de toda a paisagem aumenta.

Medida: $LSI \geq 1$, sem limite

Índice de forma da paisagem padronizado (*Normalized Landscape Shape Index – NLSI*)

$$NLSI = \frac{e_i - \min e_i}{\max e_i - \min e_i}$$

e_i = comprimento total do perímetro da classe i em termos de número de superfícies de pixels, inclui a borda da paisagem e segmentos de perímetro do *background* envolvendo a classe i ;
 $\min e_i$ = número mínimo do comprimento do perímetro da classe i em termos de número de superfícies de pixels;
 $\max e_i$ = número máximo do comprimento do perímetro da classe i em termos de número de superfícies de pixels.

Este índice é uma versão padronizada da métrica LSI e indica o efeito isolado da agregação, ou seja, sem a influência da composição. O valor zero ocorre quando a classe consiste em uma única mancha perfeitamente ou quase quadrada e altamente compactada. À medida que a classe se torna desagregada, este índice aumenta até atingir o valor 1. Essa métrica não é recomendada para avaliar paisagens diferentes de formas quadradas, e quando a porcentagem da classe é alta.

Medida: $0 \leq NLSI \leq 1$

Índice de coesão de manchas (*Patch Cohesion Index – COHESION*)

Classe

$$COHESION = \left(1 - \frac{\sum_{j=1}^n p_{ij}^*}{\sum_{j=1}^n p_{ij}^* \sqrt{a_{ij}^*}} \right) \times \left(1 - \frac{1}{\sqrt{Z}} \right)^{-1} \times 100$$

Paisagem

$$COHESION = \left(1 - \frac{\sum_{i=1}^m \sum_{j=1}^n p_{ij}^*}{\sum_{i=1}^m \sum_{j=1}^n p_{ij}^* \sqrt{a_{ij}^*}} \right) \times \left(1 - \frac{1}{\sqrt{Z}} \right)^{-1} \times 100$$

p_{ij}^* = perímetro da mancha ij em termos de número de superfícies de pixels;

a_{ij}^* = área da mancha ij em termos de número de pixels;

Z = número total de pixels na paisagem.

Essa métrica mensura a conectividade física de um determinado tipo de cobertura. Em nível de classe, valores próximos de zero indicam que a classe ocorre em menor proporção na paisagem e, conseqüentemente, está mais subdividida e menos conectada. Valores maiores indicam que a classe ocorre em proporção maior e está mais agrupada. Em valores próximos do limiar de percolação, essa métrica atinge uma assíntota. Apesar de poder ser calculada em nível de paisagem, McGarigal (2015) afirma que seu comportamento nesta escala ainda necessita de avaliação.

Medida (classe): $0 < \text{COHESION} < 100$

Medida (paisagem): amplitude ainda não avaliada.

Número de manchas (*Number of Patches – NP*)

Classe	$NP = n_i$
Paisagem	$NP = N$
n_i = número de manchas na paisagem da classe i ;	
N = número total de manchas na paisagem.	

Indica o número de manchas, em nível de classe ou paisagem.

Medida: $NP \geq 1$, sem limite

Densidade de manchas (*Patch Density – PD*)

Classe	$PD = \frac{n_i}{A} \times 10000 \times 100$
Paisagem	$PD = \frac{N}{A} \times 10000 \times 100$
n_i = número de manchas na paisagem da classe i ;	
N = número total de manchas na paisagem;	
A = área da paisagem (m^2).	

Indica o número de manchas, em nível de classe ou paisagem, por unidade de área.

Medida: número por 100 hectares, $PD > 0$, restringido pelo tamanho do pixel

Índice de divisão da paisagem (*Landscape Division Index – DIVISION*)

Classe	$DIVISION = \left[1 - \sum_{j=1}^n \left(\frac{a_{ij}}{A} \right)^2 \right]$
Paisagem	$DIVISION = \left[1 - \sum_{i=1}^m \sum_{j=1}^n \left(\frac{a_{ij}}{A} \right)^2 \right]$
a_{ij} = área (m^2) da mancha ij ;	

A = área da paisagem (m²).

Essa métrica é interpretada como a probabilidade de dois pixels aleatórios na paisagem não pertencerem à mesma mancha. Em nível de classe, atinge valor zero quando a paisagem consiste em uma única mancha. O valor máximo ocorre quando a classe analisada compreende uma única mancha com área do tamanho de um pixel. Quando a proporção da paisagem ocupada pela classe diminui e as manchas diminuem de tamanho, o índice se aproxima de um (1). Em nível de paisagem, o maior valor é observado quando a paisagem está subdividida ao máximo, i.e., quando cada pixel é uma mancha separada. Este índice é perfeitamente e inversamente correlacionado com a métrica MESH.

Medida: proporção, $0 \leq \text{DIVISION} < 1$

Índice de cisão (*Splitting Index – SPLIT*)

Classe	$SPLIT = \frac{A^2}{\sum_{j=1}^n a_{ij}^2}$
Paisagem	$SPLIT = \frac{A^2}{\sum_{i=1}^m \sum_{j=1}^n a_{ij}^2}$
<p>a_{ij} = área (m²) da mancha ij; A = área da paisagem (m²).</p>	

É interpretada como o número de manchas de mesmo tamanho obtido ao se dividir a classe ou a paisagem em S manchas. O mesmo grau de divisão observado para a paisagem de acordo com sua distribuição de área cumulativa é considerado no cálculo dessa métrica. O valor mínimo ocorre quando a paisagem contém apenas uma mancha. Este índice apresenta valores maiores à medida que a classe de interesse é reduzida em área e se encontra fragmentada em manchas menores. Em nível de paisagem, valores maiores indicam que a paisagem está mais fragmentada em manchas menores, atingindo valor máximo quando cada pixel é caracterizado como uma mancha única.

Medida: $1 \leq \text{SPLIT} \leq$ número de pixels na paisagem ao quadrado

Tamanho efetivo da malha (*Effective Mesh Size – MESH*)

Classe	$MESH = \frac{\sum_{j=1}^n a_{ij}^2}{A} \times \left(\frac{1}{10000} \right)$
Paisagem	$MESH = \frac{\sum_{i=1}^m \sum_{j=1}^n a_{ij}^2}{A}$
<p>a_{ij} = área (m²) da mancha ij; A = área da paisagem (m²).</p>	

Indica o tamanho das manchas quando a classe ou a paisagem é dividida em S manchas de mesmo tamanho. O mesmo grau de divisão observado para a paisagem de acordo com sua distribuição de área cumulativa é considerado no cálculo dessa métrica. Seu valor inferior indica que a classe consiste em uma única mancha do tamanho de um pixel, enquanto o valor máximo ocorre quando toda paisagem é formada por apenas uma única mancha. Em nível de paisagem, o valor mínimo aponta que a paisagem está subdividida ao máximo e cada pixel é caracterizado como uma mancha única, e o valor máximo ocorre quando a paisagem é composta por uma única mancha. É perfeitamente e inversamente correlacionada com DIVISION.

Medida (classe): hectares, razão entre tamanho do pixel e área da paisagem \leq MESH \leq área da paisagem

Medida (paisagem): hectares, tamanho do pixel \leq MESH \leq área da paisagem

Distância euclidiana do vizinho mais próximo (*Euclidean Nearest Neighbor Distance – ENN*)

$$ENN = h_{ij}$$

h_{ij} = distância (m) da mancha ij até a mancha vizinha da mesma classe mais próxima, baseada na distância entre bordas, calculada como a distância entre o centro dos pixels.

Indica a menor distância em linha reta de borda a borda entre manchas de uma mesma classe. É a métrica mais simples utilizada para mensurar o isolamento das manchas. Pode ser calculada em nível de classe e paisagem por meio de medidas como média, média ponderada pela área, mediana, amplitude, desvio padrão e coeficiente de variação.

Medida: metros, $ENN > 0$, sem limite

Índice de contágio (*Contagion Index – CONTAG*)

$$CONTAG = \left[1 + \frac{\sum_{i=1}^m \sum_{k=1}^m \left[P_i \frac{g_{ik}}{\sum_{k=1}^m g_{ik}} \right] \times \left[\ln \left(P_i \frac{g_{ik}}{\sum_{k=1}^m g_{ik}} \right) \right]}{2 \ln(m)} \right] \times 100$$

P_i = proporção da paisagem ocupada pela classe i;

g_{ik} = número de adjacências (junções) entre pixels das classes i e k baseado no método de contagem dupla (*double-count*);

m = número de classes presentes na paisagem, incluindo a borda da paisagem, se presente.

Essa métrica é calculada apenas em nível de paisagem, sendo inversamente relacionada com a densidade de borda. Computa tanto a dispersão quanto a intercalação das diferentes

classes. Níveis baixos de dispersão (i.e., alta proporção de adjacências semelhantes) e de intercalação (i.e., distribuição desigual de adjacências) resultam em alto valor dessa métrica, e vice-versa. Valores próximos de zero indicam que as classes estão desagregadas e intercaladas ao máximo, e valores próximos de 100 indicam uma tendência de as classes estarem maximamente agregadas.

Medida: %, $0 < \text{CONTAG} \leq 100$

Fragmentação da floresta - Índice de Matheron (*Forest Fragmentation - Matheron Index - FF*)

Calculado por Paula et al. (2018), é mensurado pelo Índice de Matheron, que tem como base a razão perímetro-área, podendo também indicar forma (IMBERNON; BRANTHOMME, 2001). Seu cômputo é feito ao se dividir o perímetro total da floresta pela raiz quadrada da área da floresta multiplicada pela raiz quadrada da área da paisagem. Valores maiores indicam uma maior fragmentação ou formas mais irregulares.

Medida: $\text{FF} > 0$

2.6 Outras métricas de configuração

Distância da maior mancha (*Largest Patch Distance - LD*)

Paula et al. (2018) mensuraram a distância do maior fragmento de floresta até o trecho de rio que foi amostrado para as variáveis de qualidade da água. Essa métrica indica o comprimento do segmento da rede de drenagem que conecta essa maior mancha até o ponto amostral.

Medida: metros, $\text{LD} \geq 0$

Posição da floresta (*Forest Position - near, intermediate, distant - FP*)

Paula et al. (2018) elaboraram um índice para indicar a porcentagem da área de floresta que se encontrava em uma distância intermediária, próxima ou longe da água. As distâncias hidrológicas foram obtidas a partir de um MDE e divididas pela maior distância em cada bacia, de forma a padronizar o uso da métrica em bacias de diferentes áreas. Em seguida, os pixels foram classificados em três categorias de distância – perto, intermediária e distante – e calculou-se a porcentagem de floresta em cada uma delas.

Medida: %, $0 \leq \text{FP} \leq 100$

Proximidade da mancha até o riacho (*Average Proximity of Patch to Streams – APPS*)

Walters, Brody e Highfield (2018) calcularam a distância média do centroide de manchas de área urbana até o riacho mais próximo.

Medida: quilômetros, APPS ≥ 0

Distância média da floresta até o riacho (*Mean Distance of Forest to Stream – DFS*)

Mori et al. (2015) calcularam a distância média da cobertura florestal até a rede hidrográfica das bacias.

Medida: metros, DFS ≥ 0

3 OUTRAS MÉTRICAS**Índice de paisagem ponderado por localização (*Location-weighted Landscape Index – LWLI*)**

Desenvolvido por Chen et al. (2009) e aplicado por Li et al. (2018), essa métrica integra o padrão da paisagem com medidas das classes de uso e cobertura do solo considerando sua distância até o exutório da bacia, o gradiente de declividade e a elevação. Por exemplo, uma classe “fonte”, quando próxima do exutório e em área declivosa e de baixa altitude, pode contribuir com maior carga de nutrientes (CHEN et al., 2009). Quanto maior o valor de LWLI, maior a perda de nutrientes ou de solo (CHEN et al., 2009). O cálculo dessa métrica pode ser conferido em Chen et al. (2009).

APÊNDICE C – Resultados da revisão sistemática

Os resultados da revisão sistemática da literatura são apresentados a seguir na forma de tabelas. Cada linha representa uma relação entre um parâmetro de qualidade da água e uma métrica da paisagem, obedecendo a classificação dos usos e coberturas do solo de acordo com o Quadro 4. O número de resultados com sinal negativo e positivo, bem como as referências que apontam essas relações, estão presentes. As referências são citadas de acordo com o ID disponível no Quadro 6. A coluna valor-*p* indica o resultado do teste do sinal aplicado, sendo que os valores $p < 0,05$ estão destacados em negrito. Em alguns casos, a quantidade de referências não é idêntica ao número de resultados da coluna “Direção do tamanho de efeito”, pois em algumas ocasiões é fornecido mais de um tamanho de efeito obtido de uma amostra por artigo. Esses casos são destacados por um asterisco (*) na coluna valor-*p*. Sugere-se cautela na interpretação dos valores-*p* do teste do sinal para essas relações, pois o princípio da independência está violado. Em outros casos há dois ou mais tamanhos de efeito por artigo, mas que foram obtidos de subgrupos de amostras que não se sobrepõem.

1 COMPOSTOS DE NITROGÊNIO

Escala	Parâmetro	Métrica	Direção do tamanho de efeito		Valor- <i>p</i>		Referências (Quadro 6)	
			Negativo	Positivo	Teste unicaudal	Teste bicaudal	Sinal negativo	Sinal positivo
Bacia	Amônia	PLAND floresta	10	0	0,0010	0,0020	9, 22, 26, 27, 40, 42, 44, 46, 47, 94	
Bacia	Amônia	LPI floresta	1	0	0,5	1	73	
Bacia	Amônia	ED floresta	1	0	0,5	1	40	
Bacia	Amônia	FP % floresta intermediária	0	1	0,5	1		64
Bacia	Amônia	PLAND agricultura	1	10	0,0054	0,0107	46	9, 15, 22, 26, 27, 40, 42, 43, 44, 94
Bacia	Amônia	LPI agricultura	0	1	0,5	1		40
Bacia	Amônia	PD agricultura	0	1	0,5	1		40

Bacia	Amônia	PLAND pastagem	2	4	0,23438	0,46875	15, 26	9, 22, 44
Bacia	Amônia	LPI pastagem	0	1	0,5	1		73
Bacia	Amônia	PLAND urbano	0	13	0,0001	0,0002		9, 15, 22, 26, 27, 40, 42, 43, 44, 46, 47, 94, 97
Bacia	Amônia	LPI urbano	1	2	0,375	0,75	73	16, 40
Bacia	Amônia	ED urbano	1	0	0,5	1	73	
Bacia	Amônia	PD urbano	0	1	0,5	1		43
Bacia	Amônia	PLAND estradas	0	2	0,25	0,5		44
Bacia	Amônia	PRD	1	0	0,5	1	9	
Bacia	Amônia	LPI	1	0	0,5	1	27	
Bacia	Amônia	SHDI	2	2	0,375	0,75	26, 46	9, 27
Bacia	Amônia	ED	0	2	0,25	0,5		27, 46
Bacia	Amônia	PARA_MN	0	1	0,5	1		9
Bacia	Amônia	SHAPE_MN	0	2	0,25	0,5		9, 27
Bacia	Amônia	FRAC	0	1	0,5	1		9
Bacia	Amônia	CIRCLE	0	1	0,5	1		9
Bacia	Amônia	IJI	1	0	0,5	1	46	
Bacia	Amônia	LSI	1	0	0,5	1	46	
Bacia	Amônia	COHESION	0	1	0,5	1		46
Bacia	Amônia	NP	1	0	0,5	1	46	
Bacia	Amônia	PD	0	2	0,25	0,5		27, 46
Bacia	Amônia	DIVISION	0	1	0,5	1		9
Bacia	Amônia	CONTAG	2	2	0,375	0,75	9, 27	43, 59
Bacia	Amônia	LCPI	0	1	0,5	1		15
Bacia	Nitrito	PLAND floresta	2	0	0,25	0,5	9, 22	
Bacia	Nitrito	PLAND agricultura	0	2	0,25	0,5		9, 22
Bacia	Nitrito	PLAND pastagem	2	2	0,375	0,75	15, 22	9, 59
Bacia	Nitrito	PLAND urbano	0	3	0,125	0,25		9, 15, 22
Bacia	Nitrito	PRD	1	0	0,5	1	9	
Bacia	Nitrito	SHDI	0	1	0,5	1		9
Bacia	Nitrito	PARA_MN	0	1	0,5	1		9
Bacia	Nitrito	SHAPE_MN	0	1	0,5	1		9
Bacia	Nitrito	FRAC	0	1	0,5	1		9
Bacia	Nitrito	CIRCLE	1	0	0,5	1	9	
Bacia	Nitrito	PD	0	1	0,5	1		59
Bacia	Nitrito	DIVISION	0	1	0,5	1		9
Bacia	Nitrito	CONTAG	1	1	0,5	1	9	59

Bacia	Nitrato	LCPI	0	1	0,5	1		15
Bacia	Nitrato	PLAND floresta	10	3	0,0349	0,0698	24, 27, 35, 40, 42, 43, 48, 63, 80, 94	9, 44, 55
Bacia	Nitrato	LPI floresta	1	1	0,5	1	43	55
Bacia	Nitrato	SHAPE_MN floresta	1	0	0,5	1	81	
Bacia	Nitrato	IJI floresta	1	0	0,5	1	43	
Bacia	Nitrato	LSI floresta	1	0	0,5	1	40	
Bacia	Nitrato	COHESION floresta	0	1	0,5	1		81
Bacia	Nitrato	PD floresta	0	1	0,5	1		16
Bacia	Nitrato	PLAND agricultura	0	13	0,0001	0,0002		9, 24, 27, 31, 35, 40, 42, 44, 48, 55, 63, 80, 94
Bacia	Nitrato	LPI agricultura	0	1	0,5	1		40
Bacia	Nitrato	ED agricultura	0	1	0,5	1		40
Bacia	Nitrato	PD agricultura	1	0	0,5	1	43	
Bacia	Nitrato	PLAND pastagem	5	2	0,1641	0,3281	4, 9, 48, 55	43, 59
Bacia	Nitrato	ED pastagem	1	1	0,5	1	9	43
Bacia	Nitrato	IJI pastagem	1	0	0,5	1	43	
Bacia	Nitrato	PD pastagem	0	1	0,5	1		43
Bacia	Nitrato	PLAND urbano	0	11	0,0005	0,0010		9, 27, 35, 40, 42, 44, 48, 81, 94, 97, 44
Bacia	Nitrato	LPI urbano	1	1	0,5	1	43	40
Bacia	Nitrato	IJI urbano	0	1	0,5	1		43
Bacia	Nitrato	AI urbano	1	0	0,5	1	81	
Bacia	Nitrato	PD estradas	0	1	0,5	1		43
Bacia	Nitrato	PRD	1	0	0,5	1	9	
Bacia	Nitrato	LPI	1	2	0,375	0,75	27	48
Bacia	Nitrato	SHDI	1	2	0,375	0,75	48	9, 27
Bacia	Nitrato	ED	0	1	0,5	1		27
Bacia	Nitrato	PARA_MN	0	1	0,5	1		9
Bacia	Nitrato	SHAPE_MN	1	1	0,5	1	27	9
Bacia	Nitrato	FRAC	0	1	0,5	1		9
Bacia	Nitrato	CIRCLE	1	0	0,5	1	9	
Bacia	Nitrato	IJI	0	1	0,5	1		43
Bacia	Nitrato	DIVISION	2	1	0,375	0,75	43, 48	9
Bacia	Nitrato	PD	0	1	0,5	1		27
Bacia	Nitrato	CONTAG	1	1	0,5	1	27	9

Bacia	N total	PLAND floresta	17	1	0,00007	0,0001	9, 14, 16, 22, 26, 27, 28, 38, 39, 40, 48, 49, 58, 63, 78, 94, 99	55
Bacia	N total	LPI floresta	3	0	0,125	0,25	38, 40, 73	
Bacia	N total	ED floresta	1	1	0,5	1	40	38
Bacia	N total	SHAPE_MN floresta	1	0	0,5	1	38	
Bacia	N total	AI floresta	0	1	0,5	1		38
Bacia	N total	COHESION floresta	0	1	0,5	1		38
Bacia	N total	PD floresta	0	1	0,5	1		38
Bacia	N total	ENN_MN floresta	1	0	0,5	1	38	
Bacia	N total	PLAND agricultura	3	13	0,0085	0,0171	26, 38, 55	9, 14, 22, 27, 30, 31, 39, 40, 48, 58, 63, 78, 94
Bacia	N total	LPI agricultura	1	1	0,5	1	38	40
Bacia	N total	ED agricultura	0	1	0,5	1		38
Bacia	N total	SHAPE_MN agricultura	0	1	0,5	1		38
Bacia	N total	AI agricultura	0	1	0,5	1		38
Bacia	N total	COHESION agricultura	0	1	0,5	1		38
Bacia	N total	PD agricultura	0	2	0,25	0,5		38, 40
Bacia	N total	ENN_MN agricultura	1	0	0,5	1	38	
Bacia	N total	PLAND pastagem	7	4	0,1611	0,3223	14, 22, 26, 28, 31, 48, 78	9, 39, 55, 57
Bacia	N total	PLAND urbano	0	10	0,0010	0,0020		9, 14, 22, 26, 27, 38, 39, 40, 48, 78
Bacia	N total	LPI urbano	0	2	0,25	0,5		38, 40
Bacia	N total	ED urbano	1	1	0,5	1	73	38
Bacia	N total	AI urbano	0	1	0,5	1		38
Bacia	N total	COHESION urbano	0	1	0,5	1		38
Bacia	N total	PD urbano	0	1	0,5	1		38
Bacia	N total	ENN_MN urbano	1	0	0,5	1	38	
Bacia	N total	PLAND estradas	0	1	0,5	1		44
Bacia	N total	PD estradas	0	2	0,25	0,5		78, 99
Bacia	N total	PRD	1	0	0,5	1	9	
Bacia	N total	SHEI	1	1	0,5	1	79	78
Bacia	N total	LPI	4	1	0,1563	0,3125	27, 38, 39, 79	48
Bacia	N total	SHDI	3	5	0,2188	0,4375	26, 48, 79	9, 27, 38, 39, 78
Bacia	N total	PA média	1	0	0,5	1	78	
Bacia	N total	PA mediana	1	0	0,5	1	78	
Bacia	N total	PA desvio padrão	1	0	0,5	1	78	

Bacia	N total	PA coeficiente de variação	0	1	0,5	1		78
Bacia	N total	TE	0	1	0,5	1		78
Bacia	N total	PE_MN	1	0	0,5	1	78	
Bacia	N total	ED	0	3	0,125	0,25		27, 38, 78
Bacia	N total	PARA_MN	1	1	0,5	1	78	9
Bacia	N total	SHAPE_MN	3	1	0,25	0,5	27, 38, 78	9
Bacia	N total	SHAPE_AM	1	0	0,5	1	78	
Bacia	N total	FRAC_MN	1	2	0,375	0,75	30	9, 78
Bacia	N total	FRAC_AM	1	0	0,5	1	78	
Bacia	N total	CIRCLE	0	1	0,5	1		9
Bacia	N total	AI	1	0	0,5	1	38	
Bacia	N total	LSI	0	1	0,5	1		30
Bacia	N total	COHESION	1	0	0,5	1	38	
Bacia	N total	NP	0	1	0,5	1		78
Bacia	N total	PD	2	3	0,3125	0,625	31, 79	27, 38, 39
Bacia	N total	DIVISION	1	1	0,5	1	48	9
Bacia	N total	ENN_MN	1	0	0,5	1	38	
Bacia	N total	CONTAG	4	0	0,0625	0,125	9, 27, 38, 39	
Bacia	N total	LWLI	0	1	0,5	1		39
Bacia	N orgânico	PLAND floresta	3	0	0,125	0,25	22, 28, 63	
Bacia	N orgânico	PLAND agricultura	0	2	0,25	0,5		22, 63
Bacia	N orgânico	PLAND pastagem	1	1	0,5	1	28	22
Bacia	N orgânico	PLAND urbano	0	1	0,5	1		22
Buffer	Amônia	PLAND floresta	5	0	0,0313	0,0625	15, 40, 42, 47, 94	
Buffer	Amônia	PLAND agricultura	0	5	0,0313	0,0625		15, 40, 42, 57, 94
Buffer	Amônia	PLAND urbano	1	5	0,0938	0,1875	42	15, 40, 47, 94, 97
Buffer	Amônia	LPI urbano	0	1	0,5	1		16
Buffer	Amônia	CONTAG	0	1	0,5	1		59
Buffer	Amônia	LCPI	0	1	0,5	1		15
Buffer	Nitrato	PLAND floresta	1	1	0,5	1	15	59
Buffer	Nitrato	PLAND agricultura	0	1	0,5	1		15
Buffer	Nitrato	PLAND urbano	0	2	0,25	0,5		15, 59
Buffer	Nitrato	CONTAG	1	0	0,5	1	59	
Buffer	Nitrato	LCPI	0	1	0,5	1		15
Buffer	Nitrato	PLAND floresta	4	2	0,2344	0,4688	40, 42, 57, 94	55, 99
Buffer	Nitrato	LPI floresta	0	1	0,5	1		55

Buffer	Nitrato	AI floresta	1	0	0,5	1	16	
Buffer	Nitrato	DFS floresta	1	0	0,5	1	55	
Buffer	Nitrato	PLAND agricultura	1	3	0,25	0,5	42	40, 55, 94
Buffer	Nitrato	PLAND pastagem	1	0	0,5	1	55	
Buffer	Nitrato	PLAND urbano	1	3	0,25	0,5	42	40, 94, 97
Buffer	N total	PLAND floresta	8	1	0,0176	0,0352	14, 40, 49, 55, 57, 85, 94, 99	70
Buffer	N total	ECON_AM floresta	0	1	0,5	1		70
Buffer	N total	AI floresta	1	0	0,5	1	16	
Buffer	N total	PLAND agricultura	1	4	0,1563	0,3125	55	14, 40, 70, 94
Buffer	N total	PLAND pastagem	1	2	0,375	0,75	14	55, 85
Buffer	N total	PLAND urbano	0	5	0,0313	0,0625		14, 40, 57, 85, 94
Buffer	N total	LPI urbano	0	1	0,5	1		16
Buffer	N total	PA_AM urbano	0	1	0,5	1		70
Buffer	N total	PD estradas	0	1	0,5	1		99
Outras classes de uso e cobertura do solo								
Bacia	Amônia	PLAND água	3	5	0,2188	0,4375	43, 44, 73	9, 26, 27, 42, 44
Bacia	Amônia	PLAND solo exposto	2	4	0,2344	0,4688	9, 57	27, 42, 44, 73
Bacia	Amônia	PLAND áreas úmidas	0	1	0,5	1		31
Bacia	Amônia	PLAND mineração	0	1	0,5	1		9
Bacia	Amônia	IJI água	0	1	0,5	1		73
Bacia	Amônia	IJI solo exposto	1	0	0,5	1	73	
Bacia	Amônia	PD solo exposto	1	0	0,5	1	73	
Bacia	Nitrato	PLAND água	0	1	0,5	1		9
Bacia	Nitrato	PLAND solo exposto	1	0	0,5	1	9	
Bacia	Nitrato	PLAND mineração	0	1	0,5	1		9
Bacia	Nitrato	PLAND água	1	3	0,25	0,5	9	27, 42, 44
Bacia	Nitrato	PLAND solo exposto	2	4	0,2344	0,4688	9, 57	4, 27, 42, 43
Bacia	Nitrato	PLAND áreas úmidas	3	0	0,125	0,25	35, 48, 63	
Bacia	Nitrato	PLAND mineração	1	0	0,5	1	9	
Bacia	Nitrato	NP água	0	1	0,5	1		4
Bacia	Nitrato	LPI solo exposto	0	2	0,25	0,5		4, 43
Bacia	Nitrato	TE solo exposto	0	1	0,5	1		4
Bacia	Nitrato	ED solo exposto	0	1	0,5	1		4
Bacia	N total	PLAND água	2	2	0,375	0,75	26, 73	9, 27
Bacia	N total	PLAND solo exposto	2	3	0,3125	0,625	9, 57	27, 39, 44
Bacia	N total	PLAND áreas úmidas	2	0	0,25	0,5	28, 63	
Bacia	N total	PLAND mineração	1	0	0,5	1	9	

Bacia	N total	ED solo exposto	0	1	0,5	1	73
Bacia	N total	PD solo exposto	1	0	0,5	1	73
Bacia	N orgânico	PLAND áreas úmidas	2	0	0,25	0,5	28, 63
Buffer	Amônia	PLAND solo exposto	0	1	0,5	1	42
Buffer	Nitrato	PLAND solo exposto	0	1	0,5	1	42
Buffer	N total	PLAND solo exposto	1	0	0,5	1	57

2 COMPOSTOS DE FÓSFORO

Escala	Parâmetro	Métrica	Direção do tamanho de efeito		Valor-p		Referências (Quadro 6)	
			Negativo	Positivo	Teste unicaudal	Teste bicaudal	Sinal negativo	Sinal positivo
Bacia	P total	PLAND floresta	17	2	0,0003	0,0007	14, 26, 27, 38, 39, 44, 46, 47, 48, 49, 55, 57, 58, 63, 66, 94, 99	85, 88
Bacia	P total	LPI floresta	1	1	0,5	1	38	55
Bacia	P total	ED floresta	0	1	0,5	1		38
Bacia	P total	SHAPE_MN floresta	1	0	0,5	1	38	
Bacia	P total	AEE floresta	1	0	0,5	1	47	
Bacia	P total	PLADJ floresta	0	1	0,5	1		66
Bacia	P total	AI floresta	1	0	0,5	1	38	
Bacia	P total	PD floresta	1	1	0,5	1	66	38
Bacia	P total	ENN_MN floresta	0	2	0,25	0,5		38, 47
Bacia	P total	PLAND agricultura	3	11	0,0222	0,0444	26, 46, 55	14, 27, 38, 39, 48, 58, 63, 66, 73, 85, 94
Bacia	P total	LPI agricultura	1	0	0,5	1	38	
Bacia	P total	ED agricultura	0	2	0,25	0,5		38, 66
Bacia	P total	SHAPE_MN agricultura	1	0	0,5	1	38	
Bacia	P total	AI agricultura	0	1	0,5	1		38
Bacia	P total	COHESION agricultura	0	2	0,25	0,5		38, 66
Bacia	P total	PD agricultura	0	1	0,5	1		38
Bacia	P total	ENN_MN agricultura	1	0	0,5	1	38	
Bacia	P total	PLAND pastagem	3	8	0,0806	0,1611	4, 26, 66	14, 39, 44, 48, 49, 55, 85
Bacia	P total	PD pastagem	0	1	0,5	1		66
Bacia	P total	PLAND urbano	3	11	0,0222	0,0444	46, 48, 88	14, 26, 27, 38, 39, 44, 47, 49, 59, 85, 94
Bacia	P total	LPI urbano	1	2	0,375	0,75	88	16, 38

Bacia	P total	PA_MN urbano	1	0	0,5	1	88	
Bacia	P total	ED urbano	0	1	0,5	1		38
Bacia	P total	SHAPE_MN urbano	1	0	0,5	1	38	
Bacia	P total	CONTIG urbano	1	0	0,5	1	88	
Bacia	P total	PLADJ urbano	1	0	0,5	1	88	
Bacia	P total	AI urbano	1	0	0,5	1	38	
Bacia	P total	COHESION urbano	0	1	0,5	1		38
Bacia	P total	NP urbano	0	1	0,5	1		88
Bacia	P total	PD urbano	0	2	0,25	0,5		38, 88
Bacia	P total	ENN_MN urbano	0	1	0,5	1		38
Bacia	P total	APPS urbano	0	1	0,5	1		88
Bacia	P total	PLAND estradas	0	1	0,5	1		44
Bacia	P total	PD estradas	2	1	0,375	0,75	73, 99	47
Bacia	P total	LPI	4	1	0,1563	0,3125	27, 38, 39, 79	48
Bacia	P total	SHEI	1	0	0,5	1	79	
Bacia	P total	SHDI	4	3	0,2734	0,5469	26, 46, 48, 79	27, 38, 39
Bacia	P total	ED	0	3	0,125	0,25		27, 38, 46
Bacia	P total	SHAPE_MN	2	0	0,25	0,5	27, 38	
Bacia	P total	IJI	0	1	0,5	1		46
Bacia	P total	AI	1	0	0,5	1	38	
Bacia	P total	LSI	1	1	0,5	1	46	79
Bacia	P total	COHESION	1	1	0,5	1	38	46
Bacia	P total	NP	0	1	0,5	1		46
Bacia	P total	PD	4	3	0,2734	0,5469	31, 46, 59, 79	27, 38, 39
Bacia	P total	DIVISION	1	0	0,5	1	48	
Bacia	P total	ENN_MN	1	0	0,5	1	38	
Bacia	P total	CONTAG	4	1	0,1563	0,3125	27, 38, 39, 49	66
Bacia	P total	LWLI	0	1	0,5	1		39
Bacia	P orgânico	PLAND floresta	1	0	0,5	1	63	
Bacia	P orgânico	PLAND agricultura	0	1	0,5	1		63
Bacia	P no sedimento	PLAND floresta	1	0	0,5	1	63	
Bacia	P no sedimento	PLAND agricultura	0	1	0,5	1		63
Bacia	P solúvel	PLAND floresta	1	0	0,5	1	63	
Bacia	P solúvel	PLAND agricultura	0	1	0,5	1		63
Buffer	P total	PLAND floresta	7	0	0,0078	0,0156	14, 47, 49, 55, 59, 77, 94	
Buffer	P total	PLAND agricultura	1	5	0,0938	0,1875	55	14, 57, 58, 77, 94
Buffer	P total	PLAND pastagem	1	2	0,375	0,75	59	14, 55

Buffer	P total	PLAND urbano	1	4	0,1563	0,3125	77	14, 47, 59, 94
Buffer	P total	LPI urbano	0	1	0,5	1		16
Buffer	P total	PA_AM urbano	0	1	0,5	1		70
Buffer	P total	PD estradas	0	1	0,5	1		99

3 ELEMENTOS TRAÇO

Escala	Parâmetro	Métrica	Direção do tamanho de efeito		Valor-p		Referências (Quadro 6)	
			Negativo	Positivo	Teste unicaudal	Teste bicaudal	Sinal negativo	Sinal positivo
Bacia	Elementos traço	PLAND floresta	8	2	0,0439*	0,0879*	29, 93	29
Bacia	Elementos traço	ED floresta	5	0	0,0313*	0,0625*	93	
Bacia	Elementos traço	PLAND agricultura	0	4	0,0625*	0,125*		29, 93
Bacia	Elementos traço	PLAND pastagem	0	2	0,25	0,5		29, 93
Bacia	Elementos traço	PLAND urbano	0	5	0,0313*	0,0625*		29, 93
Bacia	Elementos traço	SHEI	3	1	0,25*	0,5*	79	79
Bacia	Elementos traço	LPI	1	2	0,375*	0,75*	79	79
Bacia	Elementos traço	SHDI	1	3	0,25*	0,5*	79	79
Bacia	Elementos traço	IJI	0	1	0,5	1		93
Bacia	Elementos traço	LSI	3	0	0,125*	0,25*	79	
Bacia	Elementos traço	PD	1	3	0,25*	0,5*	79	79
Bacia	Elementos traço	CONTAG	2	0	0,25*	0,5*	93	
Buffer	Elementos traço	PLAND floresta	11	0	0,0005*	0,0010*	29	
Buffer	Elementos traço	PLAND agricultura	0	14	0,0001*	0,0001*		29
Buffer	Elementos traço	PLAND pastagem	4	0	0,0625*	0,125*	29	
Buffer	Elementos traço	PLAND urbano	0	7	0,0078*	0,0156*		29
Buffer	Elementos traço	SHEI	4	1	0,1563*	0,3125*	79	79
Buffer	Elementos traço	SHDI	0	5	0,0313*	0,0625*		79
Outras classes de uso e cobertura do solo								
Bacia	Elementos traço	PLAND mineração	0	5	0,0313*	0,0625*		93
Bacia	Elementos traço	ED mineração	0	5	0,0313*	0,0625*		93

4 CÁLCIO, POTÁSSIO, SÓDIO, CLORO, DIÓXIDO DE CARBONO E SULFATO

			Direção do tamanho de efeito	Valor-p	Referências (Quadro 6)			
--	--	--	------------------------------	---------	------------------------	--	--	--

Escala	Parâmetro	Métrica	Negativo	Positivo	Teste unicaudal	Teste bicaudal	Sinal negativo	Sinal positivo
Bacia	Cálcio	TE pastagem	0	1	0,5	1		4
Bacia	Cálcio	ED pastagem	1	0	0,5	1	4	
Bacia	Cálcio	LSI pastagem	0	1	0,5	1		4
Bacia	Potássio	FF floresta	0	1	0,5	1		64
Bacia	Potássio	TE pastagem	0	1	0,5	1		4
Bacia	Potássio	ED pastagem	1	0	0,5	1	4	
Bacia	Potássio	LSI pastagem	0	1	0,5	1		4
Bacia	Sódio	TE pastagem	0	1	0,5	1		4
Bacia	Sódio	ED pastagem	1	0	0,5	1	4	
Bacia	Sódio	LSI pastagem	0	1	0,5	1		4
Bacia	Cloro	PLAND floresta	1	0	0,5	1	27	
Bacia	Cloro	PLAND agricultura	0	1	0,5	1		27
Bacia	Cloro	TE pastagem	0	1	0,5	1		4
Bacia	Cloro	ED pastagem	1	0	0,5	1	4	
Bacia	Cloro	LSI pastagem	0	1	0,5	1		4
Bacia	Cloro	PLAND urbano	0	2	0,25	0,5		27, 97
Bacia	Cloro	LPI	1	0	0,5	1	27	
Bacia	Cloro	SHDI	0	1	0,5	1		27
Bacia	Cloro	ED	0	1	0,5	1		27
Bacia	Cloro	SHAPE_MN	1	0	0,5	1	27	
Bacia	Cloro	PD	0	1	0,5	1		27
Bacia	Cloro	CONTAG	0	1	0,5	1		27
Bacia	Sulfato	TE pastagem	0	1	0,5	1		4
Bacia	Sulfato	ED pastagem	1	0	0,5	1	4	
Bacia	Sulfato	LSI pastagem	0	1	0,5	1		4
Bacia	Dióxido de carbono	LD floresta	0	1	0,5	1		64
Buffer	Potássio	FP % floresta distante	0	1	0,5	1		64
Buffer	Dióxido de carbono	PD floresta	0	1	0,5	1		64
Buffer	Dióxido de carbono	FP % floresta distante	0	1	0,5	1		64
Buffer	Dióxido de carbono	LD floresta	0	1	0,5	1		64
Buffer	Cloro	PLAND urbano	0	1	0,5	1		97
Outras classes de uso e cobertura do solo								
Bacia	Cálcio	NP água	0	1	0,5	1		4
Bacia	Cálcio	PLAND solo exposto	0	1	0,5	1		4
Bacia	Cálcio	TE solo exposto	0	1	0,5	1		4

Bacia	Cálcio	ED solo exposto	0	1	0,5	1	4
Bacia	Cálcio	LSI solo exposto	0	1	0,5	1	4
Bacia	Cálcio	NP solo exposto	0	1	0,5	1	4
Bacia	Potássio	NP água	0	1	0,5	1	4
Bacia	Potássio	PLAND solo exposto	0	1	0,5	1	4
Bacia	Potássio	TE solo exposto	0	1	0,5	1	4
Bacia	Potássio	ED solo exposto	0	1	0,5	1	4
Bacia	Potássio	LSI solo exposto	0	1	0,5	1	4
Bacia	Potássio	NP solo exposto	0	1	0,5	1	4
Bacia	Sódio	NP água	0	1	0,5	1	4
Bacia	Sódio	PLAND solo exposto	0	1	0,5	1	4
Bacia	Sódio	TE solo exposto	0	1	0,5	1	4
Bacia	Sódio	ED solo exposto	0	1	0,5	1	4
Bacia	Sódio	LSI solo exposto	0	1	0,5	1	4
Bacia	Sódio	NP solo exposto	0	1	0,5	1	4
Bacia	Cloro	PLAND água	0	1	0,5	1	27
Bacia	Cloro	NP água	0	1	0,5	1	4
Bacia	Cloro	PLAND solo exposto	1	1	0,5	1	27
Bacia	Cloro	TE solo exposto	0	1	0,5	1	4
Bacia	Cloro	ED solo exposto	0	1	0,5	1	4
Bacia	Cloro	LSI solo exposto	0	1	0,5	1	4
Bacia	Cloro	NP solo exposto	0	1	0,5	1	4
Bacia	Sulfato	NP água	0	1	0,5	1	4
Bacia	Sulfato	PLAND solo exposto	0	1	0,5	1	4
Bacia	Sulfato	TE solo exposto	0	1	0,5	1	4
Bacia	Sulfato	ED solo exposto	0	1	0,5	1	4
Bacia	Sulfato	LSI solo exposto	0	1	0,5	1	4
Bacia	Sulfato	NP solo exposto	0	1	0,5	1	4

5 SÓLIDOS

Escala	Parâmetro	Métrica	Direção do tamanho de efeito		Valor-p		Referências (Quadro 6)	
			Negativo	Positivo	Teste unicaudal	Teste bicaudal	Sinal negativo	Sinal positivo
Bacia	Sólidos suspensos orgânicos	PLAND floresta	1	0	0,5	1	14	
Bacia	Sólidos suspensos orgânicos	PLAND agricultura	0	1	0,5	1		14
Bacia	Sólidos suspensos orgânicos	PLAND pastagem	0	1	0,5	1		14

Bacia	Sólidos suspensos orgânicos	PLAND urbano	0	1	0,5	1	14
Bacia	Sólidos suspensos totais	PLAND floresta	2	3	0,3125	0,625	14, 55
Bacia	Sólidos suspensos totais	LPI floresta	0	1	0,5	1	73
Bacia	Sólidos suspensos totais	FP % floresta próxima	0	1	0,5	1	64
Bacia	Sólidos suspensos totais	DFS floresta	0	1	0,5	1	55
Bacia	Sólidos suspensos totais	PLAND agricultura	1	2	0,375	0,75	55
Bacia	Sólidos suspensos totais	PLAND pastagem	1	1	0,5	1	14
Bacia	Sólidos suspensos totais	LPI pastagem	0	1	0,5	1	73
Bacia	Sólidos suspensos totais	PLAND urbano	0	2	0,25	0,5	14, 31
Bacia	Sólidos suspensos totais	CONTAG	1	0	0,5	1	73
Bacia	Sólidos dissolvidos totais	PLAND floresta	2	0	0,25	0,5	22, 31
Bacia	Sólidos dissolvidos totais	PLAND agricultura	1	1	0,5	1	31
Bacia	Sólidos dissolvidos totais	PLAND pastagem	1	1	0,5	1	4
Bacia	Sólidos dissolvidos totais	PLAND urbano	0	2	0,25	0,5	22, 31
Buffer	Sólidos suspensos orgânicos	PLAND floresta	1	0	0,5	1	14
Buffer	Sólidos suspensos orgânicos	PLAND agricultura	0	1	0,5	1	14
Buffer	Sólidos suspensos orgânicos	PLAND pastagem	0	1	0,5	1	14
Buffer	Sólidos suspensos orgânicos	PLAND urbano	0	1	0,5	1	14
Buffer	Sólidos suspensos totais	PLAND floresta	2	1	0,375	0,75	14, 55
Buffer	Sólidos suspensos totais	LPI floresta	0	1	0,5	1	55
Buffer	Sólidos suspensos totais	FP % floresta próxima	0	1	0,5	1	64
Buffer	Sólidos suspensos totais	FP % floresta intermediária	0	1	0,5	1	64
Buffer	Sólidos suspensos totais	DFS floresta	0	1	0,5	1	55
Buffer	Sólidos suspensos totais	PLAND agricultura	1	1	0,5	1	55
Buffer	Sólidos suspensos totais	PLAND pastagem	1	1	0,5	1	14
Buffer	Sólidos suspensos totais	PLAND urbano	0	1	0,5	1	14
Outras classes de uso e cobertura do solo							
Bacia	Sólidos suspensos totais	IJI água	0	1	0,5	1	73
Bacia	Sólidos suspensos totais	IJI solo exposto	1	0	0,5	1	73
Bacia	Sólidos suspensos totais	PLAND áreas úmidas	1	0	0,5	1	28
Bacia	Sólidos dissolvidos totais	NP água	0	1	0,5	1	4
Bacia	Sólidos dissolvidos totais	LPI solo exposto	0	1	0,5	1	4

6 CARBONO

	Direção do tamanho de efeito	Valor-p	Referências (Quadro 6)
--	------------------------------	---------	------------------------

Escala	Parâmetro	Métrica	Negativo	Positivo	Teste unicaudal	Teste bicaudal	Sinal negativo	Sinal positivo
Bacia	Carbono inorgânico total	PLAND floresta	1	0	0,5	1	83	
Bacia	Carbono inorgânico total	PLAND agricultura	0	1	0,5	1		83
Bacia	Carbono inorgânico total	PLAND pastagem	0	1	0,5	1		83
Bacia	Carbono total	PLAND floresta	1	0	0,5	1	83	
Bacia	Carbono total	PLAND agricultura	0	1	0,5	1		83
Bacia	Carbono total	PLAND pastagem	0	1	0,5	1		83
Bacia	Carbono orgânico total	PLAND floresta	1	0	0,5	1	83	
Bacia	Carbono orgânico total	PLAND agricultura	0	1	0,5	1		83
Bacia	Carbono orgânico total	PLAND pastagem	1	0	0,5	1	83	
Bacia	Carbono orgânico total	SHEI	0	1	0,5	1		79
Bacia	Carbono orgânico total	LPI	1	0	0,5	1	79	
Bacia	Carbono orgânico total	SHDI	1	0	0,5	1	79	
Bacia	Carbono orgânico total	LSI	0	1	0,5	1		79
Bacia	Carbono orgânico total	PD	1	0	0,5	1	79	
Buffer	Carbono orgânico total	SHDI	0	1	0,5	1		79
Buffer	Carbono orgânico total	LSI	0	1	0,5	1		79

7 DEMANDA BIOQUÍMICA DE OXIGÊNIO (DBO)

Escala	Parâmetro	Métrica	Direção do tamanho de efeito		Valor-p		Referências (Quadro 6)	
			Negativo	Positivo	Teste unicaudal	Teste bicaudal	Sinal negativo	Sinal positivo
Bacia	DBO	PLAND floresta	2	0	0,25	0,5	38, 46	
Bacia	DBO	LPI floresta	1	0	0,5	1	38	
Bacia	DBO	ED floresta	0	1	0,5	1		38
Bacia	DBO	SHAPE_MN floresta	1	0	0,5	1	38	
Bacia	DBO	AI floresta	1	0	0,5	1	38	
Bacia	DBO	COHESION floresta	1	0	0,5	1	38	
Bacia	DBO	PD floresta	0	1	0,5	1		38
Bacia	DBO	ENN_MN floresta	0	1	0,5	1		38
Bacia	DBO	PLAND agricultura	1	1	0,5	1	46	38
Bacia	DBO	ED agricultura	0	1	0,5	1		38
Bacia	DBO	SHAPE_MN agricultura	0	1	0,5	1		38
Bacia	DBO	AI agricultura	0	1	0,5	1		38
Bacia	DBO	COHESION agricultura	0	1	0,5	1		38
Bacia	DBO	PD agricultura	0	1	0,5	1		38
Bacia	DBO	ENN_MN agricultura	1	0	0,5	1		38

Bacia	DBO	TE pastagem	0	1	0,5	1		4
Bacia	DBO	ED pastagem	1	0	0,5	1	4	
Bacia	DBO	LSI pastagem	0	1	0,5	1		4
Bacia	DBO	NP pastagem	0	1	0,5	1		4
Bacia	DBO	PLAND urbano	0	2	0,25	0,5		38, 46
Bacia	DBO	LPI urbano	0	1	0,5	1		38
Bacia	DBO	ED urbano	0	1	0,5	1		38
Bacia	DBO	AI urbano	0	1	0,5	1		38
Bacia	DBO	COHESION urbano	0	1	0,5	1		38
Bacia	DBO	PD urbano	0	1	0,5	1		38
Bacia	DBO	ENN_MN urbano	1	0	0,5	1	38	
Bacia	DBO	LPI	1	0	0,5	1	38	
Bacia	DBO	SHDI	1	1	0,5	1	46	38
Bacia	DBO	ED	1	1	0,5	1	46	38
Bacia	DBO	SHAPE_MN	1	0	0,5	1	38	
Bacia	DBO	IJI	1	0	0,5	1	46	
Bacia	DBO	AI	1	0	0,5	1	38	
Bacia	DBO	LSI	0	1	0,5	1		46
Bacia	DBO	COHESION	1	1	0,5	1	38	46
Bacia	DBO	NP	1	0	0,5	1	46	
Bacia	DBO	PD	0	2	0,25	0,5		38, 46
Bacia	DBO	ENN_MN	1	0	0,5	1	38	
Bacia	DBO	CONTAG	1	0	0,5	1	38	
Outras classes de uso e cobertura do solo								
Bacia	DBO	NP água	0	1	0,5	1		4
Bacia	DBO	PLAND solo exposto	0	1	0,5	1		4
Bacia	DBO	TE solo exposto	0	1	0,5	1		4
Bacia	DBO	ED solo exposto	0	1	0,5	1		4
Bacia	DBO	LSI solo exposto	0	1	0,5	1		4
Bacia	DBO	NP solo exposto	0	1	0,5	1		4

8 DEMANDA QUÍMICA DE OXIGÊNIO (DQO)

Escala	Parâmetro	Métrica	Direção do tamanho de efeito		Valor- <i>p</i>		Referências (Quadro 6)	
			Negativo	Positivo	Teste unicaudal	Teste bicaudal	Sinal negativo	Sinal positivo
Bacia	DQO	PLAND floresta	4	0	0,0625	0,125	16, 26, 38, 46	
Bacia	DQO	LPI floresta	1	0	0,5	1	38	

Bacia	DQO	ED floresta	0	1	0,5	1		38
Bacia	DQO	SHAPE_MN floresta	1	0	0,5	1	38	
Bacia	DQO	AI floresta	1	0	0,5	1	38	
Bacia	DQO	COHESION floresta	1	0	0,5	1	38	
Bacia	DQO	PD floresta	0	1	0,5	1		38
Bacia	DQO	ENN_MN floresta	0	1	0,5	1		38
Bacia	DQO	PLAND agricultura	2	2	0,375	0,75	26, 46	38, 44
Bacia	DQO	LPI agricultura	0	1	0,5	1		38
Bacia	DQO	ED agricultura	0	1	0,5	1		38
Bacia	DQO	SHAPE_MN agricultura	0	1	0,5	1		38
Bacia	DQO	AI agricultura	0	1	0,5	1		38
Bacia	DQO	COHESION agricultura	1	0	0,5	1	38	
Bacia	DQO	PD agricultura	0	1	0,5	1		38
Bacia	DQO	ENN_MN agricultura	1	0	0,5	1	38	
Bacia	DQO	PLAND pastagem	1	1	0,5	1	26	44
Bacia	DQO	LPI pastagem	0	1	0,5	1		73
Bacia	DQO	TE pastagem	0	1	0,5	1		4
Bacia	DQO	ED pastagem	1	1	0,5	1	4	73
Bacia	DQO	LSI pastagem	0	1	0,5	1		4
Bacia	DQO	PD pastagem	0	1	0,5	1		16
Bacia	DQO	PLAND urbano	0	6	0,0156	0,0313		26, 38, 44, 46
Bacia	DQO	LPI urbano	0	1	0,5	1		38
Bacia	DQO	ED urbano	0	1	0,5	1		38
Bacia	DQO	SHAPE_MN urbano	1	0	0,5	1	38	
Bacia	DQO	AI urbano	0	1	0,5	1		38
Bacia	DQO	COHESION urbano	0	1	0,5	1		38
Bacia	DQO	PD urbano	1	1	0,5	1	73	38
Bacia	DQO	ENN_MN urbano	0	1	0,5	1		38
Bacia	DQO	LPI	1	0	0,5	1	38	
Bacia	DQO	SHDI	2	1	0,375	0,75	26, 46	38
Bacia	DQO	ED	1	1	0,5	1	46	38
Bacia	DQO	SHAPE_MN	1	0	0,5	1	38	
Bacia	DQO	IJI	1	0	0,5	1	46	
Bacia	DQO	AI	1	0	0,5	1	38	
Bacia	DQO	LSI	0	1	0,5	1		46
Bacia	DQO	COHESION	2	0	0,25	0,5	38, 46	
Bacia	DQO	NP	1	0	0,5	1	46	

Bacia	DQO	PD	1	2	0,375	0,75	73	38, 46
Bacia	DQO	ENN_MN	1	0	0,5	1	38	
Bacia	DQO	CONTAG	1	0	0,5	1	38	
Buffer	DQO	LSI pastagem	0	1	0,5	1		16
Buffer	DQO	LPI urbano	0	1	0,5	1		16
Outras classes de uso e cobertura do solo								
Bacia	DQO	PLAND água	0	2	0,25	0,5		26, 44
Bacia	DQO	IJI água	0	1	0,5	1		73
Bacia	DQO	NP água	0	1	0,5	1		4
Bacia	DQO	PLAND solo exposto	0	2	0,25	0,5		4, 44
Bacia	DQO	TE solo exposto	0	1	0,5	1		4
Bacia	DQO	ED solo exposto	0	1	0,5	1		4
Bacia	DQO	IJI solo exposto	1	0	0,5	1	73	
Bacia	DQO	LSI solo exposto	0	1	0,5	1		4
Bacia	DQO	NP solo exposto	0	1	0,5	1		4

9 OXIGÊNIO DISSOLVIDO

Escala	Parâmetro	Métrica	Direção do tamanho de efeito		Valor-p		Referências (Quadro 6)	
			Negativo	Positivo	Teste unicaudal	Teste bicaudal	Sinal negativo	Sinal positivo
Bacia	Oxigênio dissolvido	PLAND floresta	0	6	0,0156	0,0313		14, 15, 22, 26, 27, 85
Bacia	Oxigênio dissolvido	LPI floresta	0	1	0,5	1		16
Bacia	Oxigênio dissolvido	LD floresta	1	0	0,5	1	64	
Bacia	Oxigênio dissolvido	PLAND agricultura	2	3	0,3125	0,625	22, 27	14, 26, 85
Bacia	Oxigênio dissolvido	PD agricultura	1	0	0,5	1	97	
Bacia	Oxigênio dissolvido	PLAND pastagem	3	1	0,25	0,5	14, 22, 28	26
Bacia	Oxigênio dissolvido	TE pastagem	1	0	0,5	1	4	
Bacia	Oxigênio dissolvido	ED pastagem	0	1	0,5	1		4
Bacia	Oxigênio dissolvido	PLAND urbano	6	0	0,0156	0,0313	14, 15, 22, 26, 27, 85	
Bacia	Oxigênio dissolvido	PD urbano	1	0	0,5	1	97	
Bacia	Oxigênio dissolvido	SHEI	0	1	0,5	1		79
Bacia	Oxigênio dissolvido	LPI	0	1	0,5	1		27
Bacia	Oxigênio dissolvido	SHDI	2	1	0,375	0,75	27, 79	26
Bacia	Oxigênio dissolvido	ED	1	0	0,5	1	27	
Bacia	Oxigênio dissolvido	SHAPE_MN	0	1	0,5	1		27
Bacia	Oxigênio dissolvido	PD	1	0	0,5	1	27	

Bacia	Oxigênio dissolvido	CONTAG	0	1	0,5	1		27
Bacia	Oxigênio dissolvido	LCPI	1	0	0,5	1	15	
Buffer	Oxigênio dissolvido	PLAND floresta	0	2	0,25	0,5		14, 15
Buffer	Oxigênio dissolvido	FP % floresta distante	1	0	0,5	1	64	
Buffer	Oxigênio dissolvido	LD floresta	1	0	0,5	1	64	
Buffer	Oxigênio dissolvido	PLAND agricultura	2	0	0,25	0,5	14, 15	
Buffer	Oxigênio dissolvido	PD agricultura	1	0	0,5	1	97	
Buffer	Oxigênio dissolvido	PLAND pastagem	1	0	0,5	1	14	
Buffer	Oxigênio dissolvido	PLAND urbano	3	0	0,125	0,25	14, 15, 97	
Buffer	Oxigênio dissolvido	LPI urbano	1	0	0,5	1	16	
Buffer	Oxigênio dissolvido	PD urbano	1	0	0,5	1	97	
Buffer	Oxigênio dissolvido	SHEI	0	1	0,5	1		79
Buffer	Oxigênio dissolvido	SHDI	1	0	0,5	1	79	
Buffer	Oxigênio dissolvido	LCPI	1	0	0,5	1	15	
Outras classes de uso e cobertura do solo								
Bacia	Oxigênio dissolvido	PLAND água	1	1	0,5	1	27	26
Bacia	Oxigênio dissolvido	PLAND solo exposto	2	0	0,25	0,5	4, 27	
Bacia	Oxigênio dissolvido	LPI solo exposto	1	0	0,5	1	4	
Bacia	Oxigênio dissolvido	TE solo exposto	1	0	0,5	1	4	
Bacia	Oxigênio dissolvido	ED solo exposto	1	0	0,5	1	4	
Bacia	Oxigênio dissolvido	LSI solo exposto	1	0	0,5	1	4	

10 CONDUTIVIDADE

Escala	Parâmetro	Métrica	Direção do tamanho de efeito		Valor-p		Referências (Quadro 6)	
			Negativo	Positivo	Teste unicaudal	Teste bicaudal	Sinal negativo	Sinal positivo
Bacia	Condutividade	PLAND floresta	4	0	0,0625	0,125	22, 27, 83, 93	
Bacia	Condutividade	LPI floresta	1	0	0,5	1	16	
Bacia	Condutividade	ED floresta	1	0	0,5	1	93	
Bacia	Condutividade	NP floresta	1	0	0,5	1	4	
Bacia	Condutividade	LD floresta	0	1	0,5	1	64	
Bacia	Condutividade	PLAND agricultura	1	3	0,25	0,5	93	22, 27, 83
Bacia	Condutividade	PLAND pastagem	0	3	0,125	0,25	22, 59, 83	
Bacia	Condutividade	TE pastagem	0	1	0,5	1	4	
Bacia	Condutividade	ED pastagem	1	0	0,5	1	4	

Bacia	Condutividade	LSI pastagem	0	1	0,5	1	4
Bacia	Condutividade	NP pastagem	0	1	0,5	1	4
Bacia	Condutividade	PLAND urbano	0	5	0,0313	0,0625	22, 27, 59, 93, 97
Bacia	Condutividade	LPI	1	0	0,5	1	27
Bacia	Condutividade	SHDI	0	1	0,5	1	27
Bacia	Condutividade	ED	0	1	0,5	1	27
Bacia	Condutividade	SHAPE_MN	1	0	0,5	1	27
Bacia	Condutividade	IJI	0	1	0,5	1	93
Bacia	Condutividade	PD	0	2	0,25	0,5	27, 93
Bacia	Condutividade	CONTAG	2	1	0,375	0,75	27, 93
Buffer	Condutividade	LSI agricultura	0	1	0,5	1	16
Buffer	Condutividade	PLAND pastagem	0	1	0,5	1	59
Buffer	Condutividade	PLAND urbano	0	1	0,5	1	97
Buffer	Condutividade	LPI urbano	0	1	0,5	1	16
Buffer	Condutividade	CONTAG	0	1	0,5	1	59
Outras classes de uso e cobertura do solo							
Bacia	Condutividade	PLAND água	0	1	0,5	1	27
Bacia	Condutividade	NP água	0	1	0,5	1	4
Bacia	Condutividade	PLAND solo exposto	0	2	0,25	0,5	4, 27
Bacia	Condutividade	LPI solo exposto	0	1	0,5	1	4
Bacia	Condutividade	TE solo exposto	0	1	0,5	1	4
Bacia	Condutividade	LSI solo exposto	0	1	0,5	1	4
Bacia	Condutividade	NP solo exposto	0	1	0,5	1	4
Bacia	Condutividade	PLAND mineração	0	1	0,5	1	93
Bacia	Condutividade	ED mineração	0	1	0,5	1	93

11 ALCALINIDADE

Escala	Parâmetro	Métrica	Direção do tamanho de efeito		Valor-p		Referências (Quadro 6)	
			Negativo	Positivo	Teste unicaudal	Teste bicaudal	Sinal negativo	Sinal positivo
Bacia	Alcalinidade	PLAND floresta	2	0	0,25	0,5	31, 83	
Bacia	Alcalinidade	FP % floresta intermediária	0	1	0,5	1		64
Bacia	Alcalinidade	LD floresta	0	1	0,5	1		64
Bacia	Alcalinidade	PLAND agricultura	0	2	0,25	0,5		31, 83
Bacia	Alcalinidade	PLAND pastagem	0	1	0,5	1		83
Bacia	Alcalinidade	TE pastagem	0	1	0,5	1		4
Bacia	Alcalinidade	ED pastagem	1	0	0,5	1	4	

Bacia	Alcalinidade	LSI pastagem	0	1	0,5	1	4
Buffer	Alcalinidade	LD floresta	0	1	0,5	1	64
Outras classes de uso e cobertura do solo							
Bacia	Alcalinidade	PLAND solo exposto	0	1	0,5	1	4
Bacia	Alcalinidade	LPI solo exposto	0	1	0,5	1	4
Bacia	Alcalinidade	TE solo exposto	0	1	0,5	1	4
Bacia	Alcalinidade	ED solo exposto	0	1	0,5	1	4
Bacia	Alcalinidade	LSI solo exposto	0	1	0,5	1	4
Bacia	Alcalinidade	NP solo exposto	0	1	0,5	1	4
Bacia	Alcalinidade	PLAND áreas úmidas	0	1	0,5	1	31

12 SALINIDADE

Escala	Parâmetro	Métrica	Direção do tamanho de efeito		Valor- <i>p</i>		Referências (Quadro 6)	
			Negativo	Positivo	Teste unicaudal	Teste bicaudal	Sinal negativo	Sinal positivo
Bacia	Salinidade	PLAND floresta	1	0	0,5	1	27	
Bacia	Salinidade	PLAND agricultura	0	1	0,5	1		27
Bacia	Salinidade	PLAND urbano	0	1	0,5	1		27
Bacia	Salinidade	SHEI	1	0	0,5	1	79	
Bacia	Salinidade	LPI	1	1	0,5	1	27	79
Bacia	Salinidade	SHDI	0	2	0,25	0,5		27, 79
Bacia	Salinidade	ED	0	1	0,5	1		27
Bacia	Salinidade	SHAPE_MN	1	0	0,5	1	27	
Bacia	Salinidade	LSI	1	0	0,5	1	79	
Bacia	Salinidade	PD	0	2	0,25	0,5		27, 79
Bacia	Salinidade	CONTAG	1	0	0,5	1	27	
Buffer	Salinidade	SHEI	1	0	0,5	1	79	
Buffer	Salinidade	SHDI	1	0	0,5	1	79	
Outras classes de uso e cobertura do solo								
Bacia	Salinidade	PLAND água	0	1	0,5	1		27
Bacia	Salinidade	PLAND solo exposto	1	0	0,5	1	27	

13 pH

Escala	Parâmetro	Métrica	Direção do tamanho de efeito		Valor- <i>p</i>		Referências (Quadro 6)	
			Negativo	Positivo	Teste unicaudal	Teste bicaudal	Sinal negativo	Sinal positivo

Bacia	pH	PLAND floresta	2	0	0,25	0,5	27, 83	
Bacia	pH	PLAND agricultura	1	1	0,5	1	83	27
Bacia	pH	PLAND pastagem	0	1	0,5	1		83
Bacia	pH	PLAND urbano	0	1	0,5	1		27
Bacia	pH	SHEI	0	1	0,5	1		79
Bacia	pH	LPI	2	0	0,25	0,5	27, 79	
Bacia	pH	SHDI	1	1	0,5	1	79	27
Bacia	pH	ED	0	1	0,5	1		27
Bacia	pH	SHAPE_MN	1	0	0,5	1	27	
Bacia	pH	LSI	0	1	0,5	1		79
Bacia	pH	PD	1	1	0,5	1	79	27
Bacia	pH	CONTAG	1	0	0,5	1	27	
Buffer	pH	PD floresta	1	0	0,5	1	64	
Buffer	pH	SHEI	0	1	0,5	1		79
Buffer	pH	SHDI	1	0	0,5	1	79	
Outras classes de uso e cobertura do solo								
Bacia	pH	PLAND água	0	1	0,5	1		27
Bacia	pH	PLAND solo exposto	0	1	0,5	1		27
Bacia	pH	NP solo exposto	0	1	0,5	1		4

14 TEMPERATURA

Escala	Parâmetro	Métrica	Direção do tamanho de efeito		Valor-p		Referências (Quadro 6)	
			Negativo	Positivo	Teste unicaudal	Teste bicaudal	Sinal negativo	Sinal positivo
Bacia	Temperatura	FF floresta	0	1	0,5	1		64
Bacia	Temperatura	PD floresta	0	1	0,5	1		16
Bacia	Temperatura	LD floresta	0	1	0,5	1		64
Bacia	Temperatura	PLAND pastagem	0	1	0,5	1		11
Bacia	Temperatura	PD pastagem	1	0	0,5	1	16	
Bacia	Temperatura	LPI	1	0	0,5	1	79	
Bacia	Temperatura	SHEI	0	1	0,5	1		79
Bacia	Temperatura	SHDI	1	0	0,5	1	79	
Bacia	Temperatura	LSI	0	1	0,5	1		79
Buffer	Temperatura	PLAND floresta	2	0	0,25	0,5	11, 16	
Buffer	Temperatura	FF Floresta	1	0	0,5	1	64	
Buffer	Temperatura	FP % floresta distante	0	1	0,5	1		64

15 COR

Escala	Parâmetro	Métrica	Direção do tamanho de efeito		Valor-p		Referências (Quadro 6)	
			Negativo	Positivo	Teste unicaudal	Teste bicaudal	Sinal negativo	Sinal positivo
Bacia	Cor	PLAND floresta	1	1	0,5*	1*	83	83
Bacia	Cor	PD floresta	0	1	0,5	1		64
Bacia	Cor	FP % floresta intermediária	0	1	0,5	1		64
Bacia	Cor	PLAND agricultura	1	1	0,5*	1*	83	83
Bacia	Cor	PLAND pastagem	2	0	0,25*	0,5*	83	
Buffer	Cor	PD floresta	0	1	0,5	1		64
Buffer	Cor	FF floresta	0	1	0,5	1		64

16 TURBIDEZ E CLARIDADE

Escala	Parâmetro	Métrica	Direção do tamanho de efeito		Valor-p		Referências (Quadro 6)	
			Negativo	Positivo	Teste unicaudal	Teste bicaudal	Sinal negativo	Sinal positivo
Bacia	Turbidez e claridade	PLAND floresta		1	0	0,5	1	55
Bacia	Turbidez e claridade	FP % floresta intermediária		0	1	0,5	1	64
Bacia	Turbidez e claridade	PLAND agricultura		0	2	0,25	0,5	55, 71
Bacia	Turbidez e claridade	PLAND pastagem		0	2	0,25	0,5	55, 85
Bacia	Turbidez e claridade	PLAND urbano		0	1	0,5	1	85
Buffer	Turbidez e claridade	PLAND floresta		2	0	0,25	0,5	55, 71
Buffer	Turbidez e claridade	LPI floresta		1	0	0,5	1	55
Buffer	Turbidez e claridade	PLAND agricultura		0	3	0,125	0,25	55, 71, 77
Buffer	Turbidez e claridade	PLAND pastagem		0	1	0,5	1	55
Buffer	Turbidez e claridade	PLAND urbano		1	0	0,5	1	77

17 OUTROS PARÂMETROS

Escala	Parâmetro	Métrica	Direção do tamanho de efeito		Valor-p		Referências (Quadro 6)	
			Negativo	Positivo	Teste unicaudal	Teste bicaudal	Sinal negativo	Sinal positivo
Bacia	Herbicidas	PLAND floresta		0	2	0,25*	0,5*	24
Bacia	Herbicidas	PLAND agricultura		4	0	0,0625*	0,125*	24
Bacia	Óleos e graxas	PLAND floresta		0	1	0,5	1	46
Bacia	Óleos e graxas	PLAND agricultura		1	0	0,5	1	46
Bacia	Óleos e graxas	PLAND urbano		0	1	0,5	1	46

Bacia	Óleos e graxas	SHDI	1	0	0,5	1	46
Bacia	Óleos e graxas	ED	1	0	0,5	1	46
Bacia	Óleos e graxas	IJI	0	1	0,5	1	46
Bacia	Óleos e graxas	LSI	0	1	0,5	1	46
Bacia	Óleos e graxas	COHESION	0	1	0,5	1	46
Bacia	Óleos e graxas	NP	1	0	0,5	1	46
Bacia	Óleos e graxas	PD	0	1	0,5	1	46
Bacia	Fenol volátil	PLAND floresta	1	0	0,5	1	46
Bacia	Fenol volátil	PLAND agricultura	1	0	0,5	1	46
Bacia	Fenol volátil	PLAND urbano	0	1	0,5	1	46
Bacia	Fenol volátil	SHDI	0	1	0,5	1	46
Bacia	Fenol volátil	ED	1	0	0,5	1	46
Bacia	Fenol volátil	IJI	1	0	0,5	1	46
Bacia	Fenol volátil	LSI	1	0	0,5	1	46
Bacia	Fenol volátil	COHESION	0	1	0,5	1	46
Bacia	Fenol volátil	NP	1	0	0,5	1	46
Bacia	Fenol volátil	PD	0	1	0,5	1	46
Bacia	Índice de Potencial Poluidor	PLAND agricultura	0	1	0,5	1	30
Bacia	Índice de Potencial Poluidor	FRAC	1	0	0,5	1	30
Bacia	Índice de Potencial Poluidor	CONTAG	1	0	0,5	1	30
Bacia	Índice de Qualidade da Água	PLAND floresta	0	1	0,5	1	96
Bacia	Índice de Qualidade da Água	PLAND agricultura	1	0	0,5	1	96
Bacia	Índice de Qualidade da Água	PLAND urbano	0	1	0,5	1	96
Buffer	Acidez	PD floresta	0	1	0,5	1	64

18 DENSIDADE DE MACROINVERTEBRADOS

Escala	Parâmetro	Métrica	Direção do tamanho de efeito		Valor- <i>p</i>		Referências (Quadro 6)	
			Negativo	Positivo	Teste unicaudal	Teste bicaudal	Sinal negativo	Sinal positivo
Bacia	Densidade de macroinvertebrados	PLAND floresta	3	5	0,2188*	0,4375*	83	83
Bacia	Densidade de macroinvertebrados	PLAND agricultura	3	5	0,2188*	0,4375*	83	83
Bacia	Densidade de macroinvertebrados	PLAND pastagem	6	2	0,1094*	0,21875*	83	83

19 ÍNDICES BIÓTICOS

Escala	Parâmetro	Métrica	Direção do tamanho de efeito		Valor-p		Referências (Quadro 6)	
			Negativo	Positivo	Teste unicaudal	Teste bicaudal	Sinal negativo	Sinal positivo
Bacia	Índices bióticos	PLAND floresta	0	3	0,125	0,25		13, 65, 102
Bacia	Índices bióticos	PA_MN floresta	0	1	0,5	1		101
Bacia	Índices bióticos	ED floresta	0	1	0,5	1		13
Bacia	Índices bióticos	PLADJ floresta	0	1	0,5	1		101
Bacia	Índices bióticos	AI floresta	0	2	0,25	0,5		101, 102
Bacia	Índices bióticos	PLAND agricultura	1	0	0,5	1	65	
Bacia	Índices bióticos	PD agricultura	1	0	0,5	1	13	
Bacia	Índices bióticos	PLAND urbano	4	1	0,1563	0,3125	13, 36, 65, 101	65
Bacia	Índices bióticos	PA_MN urbano	1	0	0,5	1	101	
Bacia	Índices bióticos	PLADJ urbano	1	0	0,5	1	101	
Bacia	Índices bióticos	AI urbano	1	0	0,5	1	101	
Bacia	Índices bióticos	PD urbano	1	0	0,5	1	13	
Bacia	Índices bióticos	PD estradas	1	0	0,5	1	101	
Bacia	Índices bióticos	SHDI	1	1	0,5	1	13	101
Bacia	Índices bióticos	CONTAG	1	1	0,5	1	101	13
Buffer	Índices bióticos	PLAND floresta	0	2	0,25*	0,5*		65
Buffer	Índices bióticos	PLAND agricultura	1	0	0,5	1	65	
Buffer	Índices bióticos	PLAND urbano	1	0	0,5	1	65	

20 COLIFORMES TOTAIS E FECAIS

Escala	Parâmetro	Métrica	Direção do tamanho de efeito		Valor-p		Referências (Quadro 6)	
			Negativo	Positivo	Teste unicaudal	Teste bicaudal	Sinal negativo	Sinal positivo
Bacia	Coliformes totais	PLAND agricultura		1	0	0,5	1	33
Bacia	Coliformes totais	PLAND urbano		0	1	0,5	1	33
Bacia	Coliformes fecais	PLAND floresta		2	2	0,375	0,75	14, 57 47, 85
Bacia	Coliformes fecais	LPI floresta		1	0	0,5	1	47
Bacia	Coliformes fecais	PLAND agricultura		2	3	0,3125*	0,625*	33 14, 57, 85
Bacia	Coliformes fecais	PLAND pastagem		1	2	0,375	0,75	14 57, 85
Bacia	Coliformes fecais	PLAND urbano		0	6	0,0156*	0,0313*	14, 33, 47, 57, 85
Bacia	Coliformes fecais	PD estradas		0	1	0,5	1	47
Buffer	Coliformes fecais	PLAND floresta		2	1	0,375	0,75	14, 57 47
Buffer	Coliformes fecais	PLAND agricultura		0	2	0,25	0,5	14, 57
Buffer	Coliformes fecais	PLAND pastagem		1	1	0,5	1	14 57

Buffer	Coliformes fecais	PLAND urbano	0	3	0,125	0,25	14, 47, 57
Outras classes de uso e cobertura do solo							
Bacia	Coliformes fecais	PLAND solo exposto	2	0	0,25*	0,5*	57
Bacia	Coliformes fecais	PLAND áreas úmidas	1	0	0,5	1	57
Buffer	Coliformes fecais	PLAND solo exposto	2	1	0,375*	0,75*	57 47
Buffer	Coliformes fecais	PLAND áreas úmidas	0	1	0,5	1	57

21 CLOROFILA A

Escala	Parâmetro	Métrica	Direção do tamanho de efeito		Valor-p		Referências (Quadro 6)	
			Negativo	Positivo	Teste unicaudal	Teste bicaudal	Sinal negativo	Sinal positivo
Bacia	Clorofila a	PLAND floresta	1	1	0,5	1	58	27
Bacia	Clorofila a	PLAND agricultura	1	1	0,5	1	27	58
Bacia	Clorofila a	PD pastagem	0	1	0,5	1		16
Bacia	Clorofila a	PLAND urbano	1	0	0,5	1	27	
Bacia	Clorofila a	LSI urbano	0	1	0,5	1		16
Bacia	Clorofila a	SHEI	0	1	0,5	1	79	
Bacia	Clorofila a	LPI	1	1	0,5	1	79	27
Bacia	Clorofila a	SHDI	2	0	0,25	0,5	27, 79	
Bacia	Clorofila a	ED	1	0	0,5	1	27	
Bacia	Clorofila a	SHAPE_MN	1	0	0,5	1	27	
Bacia	Clorofila a	LSI	0	1	0,5	1		79
Bacia	Clorofila a	PD	2	0	0,25	0,5	27, 79	
Bacia	Clorofila a	CONTAG	0	1	0,5	1		27
Buffer	Clorofila a	PLAND floresta	1	0	0,5	1	77	
Buffer	Clorofila a	LSI floresta	1	0	0,5	1	16	
Buffer	Clorofila a	PLAND agricultura	2	1	0,375	0,75	16, 77	58
Buffer	Clorofila a	AI agricultura	0	1	0,5	1		16
Buffer	Clorofila a	PD pastagem	0	1	0,5	1		16
Buffer	Clorofila a	PLAND urbano	0	1	0,5	1		77
Buffer	Clorofila a	LSI urbano	0	1	0,5	1		16
Buffer	Clorofila a	SHEI	0	1	0,5	1		79
Buffer	Clorofila a	SHDI	1	0	0,5	1	79	
Outras classes de uso e cobertura do solo								
Bacia	Clorofila a	PLAND água	1	0	0,5	1	27	
Bacia	Clorofila a	PLAND solo exposto	1	0	0,5	1	27	

APÊNDICE D – *Scripts* utilizados no experimento de simulação

Abaixo são apresentados os *scripts* em linguagem R e Python utilizados para os processamentos em lote descritos na seção de Material e Métodos do Capítulo 2.

1 SCRIPTS EM LINGUAGEM R

a) *Script* utilizado para geração das paisagens de modelos neutros

```
#Instalar os pacotes necessários (caso não instalados)
install.packages("NLMR")
install.packages("landscapetools")
install.packages("igraph")
install.packages("raster")
install.packages("rgdal")

#Carregar os pacotes necessários (se já instalados)
library(NLMR)
library(landscapetools)
library(igraph)
library(raster)
library(rgdal)

#####
# PAISAGENS DE MODELOS NEUTROS - MN #
#####

#Carregar a camada máscara no formato da bacia hidrográfica
bacia<-raster("C:/tese_corumbatai/corumbatai_modelo_neutro.tif")

#Definir os valores das porcentagens, roughness e número de paisagens desejadas
percent <- c(0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9)
roughness <- c(0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9)
numberpsg <- 1:100

#Usar um loop do tipo "for" para gerar as paisagens, manipular e gravar no disco
for (p in percent){
  for (r in roughness){
    for (n in numberpsg){
      paisagem<-nlm_mpd(ncol=402, nrow=402, resolution=30, roughness=r,
rand_dev=1, rescale=TRUE)

      crs(paisagem)<-"+proj=utm +zone=23 +south +ellps=GRS80
+towgs84=0,0,0,0,0,0,0 +units=m +no_defs"
      ext<-extent(214816.2110000000102445, 226846.2110000000102445,
7543065.6155000003054738, 7555095.6155000003054738)
      extent(paisagem)<-ext

      paisagem<-mask(paisagem, bacia)

      paisagem<-util_classify(paisagem, weighting= c(p, 1-p))

      fname<-paste('paisagem_p', p, '_r', r, '_', n, '.tif', sep="")
      writeRaster(paisagem, filename=fname, format="GTiff", NAflag=-9999)
    }
  }
}
```

b) *Script* utilizado para geração das paisagens planejadas

```

#Instalar os pacotes necessários (caso não instalados)
install.packages("raster")
install.packages("rgdal")

#Carregar os pacotes necessários (se já instalados)
library(raster)
library(rgdal)

#####
# FAIXAS RIPÁRIAS - PRIPÁRIA #
#####

#Carregar arquivo raster da drenagem
#Carregar arquivo raster da área da bacia (máscara)
riacho<-raster("C:/tese_corumbatai/so_drenagem.tif")
bacia<-raster("C:/tese_corumbatai/bacia_raster2.tif")

#Transformar valores de 1 para 2 (vetor_bacia)
vetor_bacia[vetor_bacia==1]=2

#Definir a largura inicial do buffer
largura <- 30

#Usar um loop do tipo "while" para gerar as paisagens, manipular e gravar no
disco
while (largura < 1030){
  riparia <- buffer(riacho, width = largura)
  riparia<-merge(riparia, bacia)
  riparia<-mask(riparia, bacia)

  fname<-paste('buffer_', largura, '.tif', sep="")
  writeRaster(riparia, filename = fname, format="GTiff", NAflag=-9999)

  largura <- largura + 30
}

#####
# DECLIVIDADE - PDECLIVIDADE #
#####

#Carregar arquivo raster da declividade em porcentagem
#Carregar arquivo raster da área da bacia (máscara)
declividade<-raster("C:/tese_corumbatai/declividade_porcentagem.tif")

#Definir declividade inicial
dec_inicial <- 63

#Usar um loop do tipo "while" para gerar as paisagens, manipular e gravar no
disco
while (dec_inicial > 0){
  m <- c(dec_inicial, 64, 1, 0, dec_inicial, 2)
  mrec <- matrix(m, ncol= 3, byrow=TRUE)

  pordeclividade <- reclassify(declividade, mrec)

  fname<-paste('declividade_', dec_inicial, '_a_64', '.tif', sep="")
  writeRaster(pordeclividade, filename = fname, format="GTiff", NAflag=-9999)

  dec_inicial <- dec_inicial - 1
}

```

```
#####
# PAISAGENS DE MODELOS NEUTROS COM FAIXA RIPÁRIA DE 30M - MNRIPÁRIA #
#####

#Carregar riacho (raster só com a drenagem)
#Carregar bacia (raster com área total da bacia)
#Criar o buffer de largura 30m ao longo da drenagem

riacho<-raster("C:/tese_corumbatai/so_drenagem.tif")
bacia<-raster("C:/tese_corumbatai/corumbatai_modelo_neutro.tif")
riparia<-buffer(riacho, width = 30)

#Definir os valores das porcentagens, roughness e número de paisagens desejadas

percent <- c(0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9)
roughness <- c(0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9)
numberpsg <- 1:100

#Usar um loop do tipo "for" para gerar as paisagens, manipular e gravar no disco
for (p in percent){
  for (r in roughness){
    for (n in numberpsg){
      paisagem<-nlm_mpd(ncol=402, nrow=402, resolution=30, roughness=r,
rand_dev=1, rescale=TRUE)

      crs(paisagem)<-"+proj=utm +zone=23 +south +ellps=GRS80
+towgs84=0,0,0,0,0,0,0 +units=m +no_defs"
      ext<-extent(214816.2110000000102445, 226846.2110000000102445,
7543065.6155000003054738, 7555095.6155000003054738)
      extent(paisagem)<-ext

      paisagem <- mask(paisagem, bacia)

      paisagem <- util_classify(paisagem, weighting= c(p, 1-p))

      paisagem <-merge(riparia, paisagem)

      fname <- paste('paisagem2_p', p, '_r', r, '_', n, '.tif', sep='')
      writeRaster(paisagem, filename=fname, format="GTiff", NAflag=-9999)
    }
  }
}
}
```

- c) *Script* utilizado para criação do lote para cálculo das métricas de paisagem pelo *Fragstats*.

```
#Definir os valores das porcentagens, roughness e número de paisagens desejadas

percent <- c(0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9)
roughness <- c(0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9)
numberpsg <- 1:100

#Criar uma lista para abrigar os caminhos

lista_fragstats<-vector()

#Usar um loop do tipo "for" para gerar os caminhos e adicionar à lista

for (p in percent){
  for (r in roughness){
    for (n in numberpsg){
      paisagem_cam<-print(paste('C:/tese_corumbatai/paisagens/paisagem_p', p,
'_r', r, '_', n, '.tif', x, 999, x, x, 1, x, IDF_GeoTIFF', sep=""))
      lista_fragstats <- c(lista_fragstats, paisagem_cam)
    }
  }
}
}
```

```
#Gravar o lote no disco utilizando o formato “.fbt”
```

```
write.table(lista_fragstats, file="batch_corumbatai.fbt", quote=FALSE,
row.names=FALSE, col.names=FALSE)
```

- d) *Script* utilizado para extração do valor da produção de sedimentos a partir da tabela de atributos dos vetores.

```
#Instalar e carregar o pacote foreign, que permite a leitura da dbf
```

```
install.packages("foreign")
library(foreign)
```

```
#####
# PAISAGENS DE MODELOS NEUTROS #
#####
```

```
#Código utilizado para as paisagens de modelos neutros e para as paisagens
planejadas de modelos neutros com faixa ripária fixa de 30m
```

```
#Criar o dataframe para inserir os valores
```

```
lista_sed_export <-data.frame()
```

```
#Definir os valores das porcentagens, roughness e número de paisagens desejadas
```

```
percent <- c(0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9)
roughness <- c(0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9)
numberpsg <- 1:100
```

```
#Usar um loop do tipo “for” para extrair o dbf do vetor e adicionar o valor ao
dataframe
```

```
for (p in percent){
  for (r in roughness){
    for (n in numberpsg){
      arq<-
paste('C:/tese_corumbatai/saida_invest/watershed_results_sdr_paisagem_p',p, '_r',
r, '-', n, '.dbf', sep='')
      dbf_shape <- read.dbf(arq)
      col_psg <- paste('C:/tese_corumbatai/paisagens/paisagem_p', p, '_r', r,
'_', n, '.tif', sep='')
      porcentagem <-paste(p)
      roughness_valor <- paste(r)
      linha <- cbind(dbf_shape, col_psg, porcentagem, roughness_valor)
      lista_sed_export <- rbind(linha, lista_sed_export)
    }
  }
}
```

```
#Gravar a tabela no disco no formato “.csv”
```

```
write.csv(lista_sed_export, file="sed_export_paisagens.csv", quote=FALSE,
row.names=FALSE, col.names=TRUE, na="NA", dec=".")
```

```
#####
# FAIXAS RIPÁRIAS - PRIPÁRIA #
#####
```

```
#Criar o dataframe para inserir os valores
```

```
lista_sed_export <-data.frame()
```

```
#Definir a largura dos buffers
```

```
larguras <- seq(30, 1020, by=30)
```

```
#Usar um loop do tipo “for” para extrair o dbf do vetor e adicionar o valor ao
dataframe
```

```

for (l in larguras){
  arq<-
  paste('C:/tese_corumbatai/saida_invest_rip/watershed_results_sdr_buffer_',l,
        '.dbf', sep='')
  dbf_shape <- read.dbf(arq)
  col_psg <- paste('buffer_', l, sep='')
  largura <-paste(l)
  linha <- cbind(dbf_shape, col_psg, largura)
  lista_sed_export <- rbind(linha, lista_sed_export)
}

#Gravar a tabela no disco no formato “.csv”

write.csv(lista_sed_export, file="sed_export_riparia.csv", quote=FALSE,
row.names=FALSE, col.names=TRUE, na="NA", dec=".")

#####
# DECLIVIDADE - PDECLIVIDADE #
#####

#Criar o dataframe para inserir os valores
lista_sed_export <-data.frame()

#Definir as declividades

declividades <- 1:63

#Usar um loop do tipo “for” para extrair o dbf do vetor e adicionar o valor ao
dataframe

for (d in declividades){
  arq<-
  paste('C:/tese_corumbatai/saida_invest_dec/watershed_results_sdr_declividade_',
d, '_a_64', '.dbf', sep='')
  dbf_shape <- read.dbf(arq)
  col_psg <- paste(d, '_a_64', sep='')
  dec_i <-paste(d)
  linha <- cbind(dbf_shape, col_psg, dec_i)
  lista_sed_export <- rbind(linha, lista_sed_export)
}

#Gravar a tabela no disco no formato “.csv”

write.csv(lista_sed_export, file="sed_export_declividade.csv", quote=FALSE,
row.names=FALSE, col.names=TRUE, na="NA", dec=".")

```

- e) *Script* utilizado para extração da cobertura do solo na faixa ripária de 30 m das paisagens MN para posterior cálculo de métricas de paisagem nesta escala.

```

#Instalar os pacotes necessários (caso não instalados)

install.packages("raster")
install.packages("rgdal")

#Carregar os pacotes necessários (se já instalados)

library(raster)
library(rgdal)

#Carregar o buffer de 30m em torno do riacho já preparado no QGIS

bufferr <- raster("C:/tese_corumbatai/zriparia2.tif")

#Definir os valores das porcentagens, roughness e número de paisagens desejadas

percent <- c(0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9)
roughness <- c(0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9)
numberpsg <- 1:100

#Usar um loop do tipo “for” para carregar as paisagens MN já geradas, extrair a
cobertura do solo tendo o buffer como máscara e gravar no disco

```

```

for (p in percent){
  for (r in roughness){
    for (n in numberpsg){

      setwd("C:/tese_corumbatai/paisagens_mn")
      fname <- paste('paisagem_p', p, '_r', r, '_', n, '.tif', sep="")

      paisagem <- raster(fname)

      paisagem <- mask(paisagem, bufferr)

      rname <- paste('ripariamn_p', p, '_r', r, '_', n, '.tif', sep="")

      setwd("C:/tese_corumbatai/zriparia_mn")
      writeRaster(paisagem, filename=rname, format="GTiff", NAflag=-9999)
    }
  }
}

```

2 SCRIPTS EM LINGUAGEM PYTHON

a) *Script* utilizado na calibração do modelo SDR

```

# coding=UTF-8
# -----
# Generated by INVEST 3.9.0 on Tue Jan  5 20:00:28 2021
# Model: Sediment Delivery Ratio Model (SDR)

import logging
import sys

import natcap.invest.sdr.sdr
import natcap.invest.utils

LOGGER = logging.getLogger(__name__)
root_logger = logging.getLogger()

handler = logging.StreamHandler(sys.stdout)
formatter = logging.Formatter(
    fmt=natcap.invest.utils.LOG_FMT,
    datefmt='%m/%d/%Y %H:%M:%S ')
handler.setFormatter(formatter)
logging.basicConfig(level=logging.INFO, handlers=[handler])

args = {
    'biophysical_table_path':
    'C:/tese_corumbatai/entrada_teste/tabelabiofisica_corumbatai.csv',
    'dem_path': 'C:/tese_corumbatai/entrada_teste/dem_corumbatai_filled.tif',
    'drainage_path': '',
    'erodibility_path':
    'C:/tese_corumbatai/entrada_teste/erodibilidade_corum.tif',
    'erosivity_path':
    'C:/tese_corumbatai/entrada_teste/erosividade_corum_2009.tif',
    'ic_0_param': '0.5',
    'k_param': '0.9',
    'lulc_path': 'C:/tese_corumbatai/entrada_teste/lulc_corumbatai_2009.tif',
    'results_suffix': 'resultado',
    'sdr_max': '0.8',
    'threshold_flow_accumulation': '150',
    'watersheds_path': 'C:/tese_corumbatai/entrada_teste/bacia_vetor.shp',
    'workspace_dir': 'C:/tese_corumbatai/entrada_teste/calibracao_15'
}

#Definir os valores para os fatores K e IC0 e os anos para calibração

anos = [2005, 2006, 2007, 2008, 2009, 2010, 2011, 2012, 2013, 2014, 2015, 2016,
2017, 2018, 2019]
fatork = [2, 1.5, 1.4, 1.3, 1.2, 1.1, 1, 0.9, 0.8, 0.7, 0.6, 0.5]
fatorIC = [0.25, 0.5, 0.75, 1, 1.25, 1.5, 1.75, 2]

```

```

#Usar um loop do tipo "for" para alterar o argumento desejado (neste caso, K, IC
e anos)
#Variar K e IC juntos

for k in fatork :
    args['k_param'] = k
    for ic in fatorIC :
        args['ic_0_param'] = ic
        for ano in anos :
            uso_solo = 'C:/tese_corumbatai/entrada_teste/lulc_corumbatai_' +
str(ano) + '.tif'
            erosividade = 'C:/tese_corumbatai/entrada_teste/erosividade_corum_' +
str(ano) + '.tif'
            args['lulc_path'] = uso_solo
            args['erosivity_path'] = erosividade
            args['results_suffix'] = 'ano' + str(ano) + '_' + str(k) + '_' +
str(ic)
            if __name__ == '__main__':
                natcap.invest.sdr.sdr.execute(args)

#Variar somente o IC (ou K)

for ic in fatorIC :
    args['ic_0_param'] = ic
    for ano in anos :
        uso_solo = 'C:/tese_corumbatai/entrada_teste/lulc_corumbatai_' + str(ano)
+ '.tif'
        erosividade = 'C:/tese_corumbatai/entrada_teste/erosividade_corum_' +
str(ano) + '.tif'
        args['lulc_path'] = uso_solo
        args['erosivity_path'] = erosividade
        args['results_suffix'] = 'ano' + str(ano) + '_' + str(ic)
        if __name__ == '__main__':
            natcap.invest.sdr.sdr.execute(args)

```

- b) *Script* utilizado no cálculo da produção de sedimentos para cada uma das paisagens geradas pelo experimento de simulação.

```

# coding=UTF-8
# -----
# Generated by InVEST 3.9.0 on Tue Jan  5 20:00:28 2021
# Model: Sediment Delivery Ratio Model (SDR)

import logging
import sys

import natcap.invest.sdr.sdr
import natcap.invest.utils

LOGGER = logging.getLogger(__name__)
root_logger = logging.getLogger()

handler = logging.StreamHandler(sys.stdout)
formatter = logging.Formatter(
    fmt=natcap.invest.utils.LOG_FMT,
    datefmt='%m/%d/%Y %H:%M:%S ')
handler.setFormatter(formatter)
logging.basicConfig(level=logging.INFO, handlers=[handler])

args = {
    'biophysical_table_path':
'C:/tese_corumbatai/entrada_corumbatai/tabelabiofisica_corumbatai.csv',
    'dem_path':
'C:/tese_corumbatai/entrada_corumbatai/dem_corumbatai_filled.tif',
    'drainage_path': '',
    'erodibility_path':
'C:/tese_corumbatai/entrada_corumbatai/erodibilidade_corum.tif',
    'erosivity_path':
'C:/tese_corumbatai/entrada_corumbatai/erosividade_corum_medial5a.tif',
    'ic_0_param': '0.25',
    'k_param': '0.8',
    'lulc_path': 'C:/tese_corumbatai/paisagens',

```

```

'results_suffix': 'sufixo',
'sdr_max': '0.8',
'threshold_flow_accumulation': '150',
'watersheds_path': 'C:/tese_corumbatai/entrada_corumbatai/bacia_vetor.shp',
'workspace_dir': 'C:/tese_corumbatai/saida_invest'
}

#####
# MODELOS NEUTROS #
#####

#Código utilizado para as paisagens de modelos neutros e para as paisagens
planejadas de modelos neutros com faixa ripária fixa de 30m

#Definir os valores das porcentagens, roughness e número de paisagens desejadas

percent = [0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9]
roughness = [0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9]
numberpsg = list(range(1,101))

#Criar a lista de caminhos das paisagens (uso e cobertura do solo)

uso_solo = list()

#Criar o caminho de cada paisagem e adicionar à lista

for p in percent :
    for r in roughness :
        for n in numberpsg :
            paisagem = 'C:/tese_corumbatai/paisagens/paisagem_p' + str(p) + '_r'
+ str(r) + '_' + str(n) + '.tif'
            uso_solo.append(paisagem)

#Atualizar o argumento 'lulc_path', o sufixo e rodar o INVEST

for psg in uso_solo :
    args['lulc_path'] = psg
    a = psg.split('/')
    b = a[3]
    c = b.split('.tif')
    sufixo = c[0]
    args['results_suffix'] = sufixo
    if __name__ == '__main__':
        natcap.invest.sdr.sdr.execute(args)

#####
# FAIXAS RIPÁRIAS - PRIPÁRIA #
#####

#Definir as larguras do buffer

larguras = list(range(30, 1050, 30))

#Criar a lista de caminhos das paisagens (uso e cobertura do solo)

uso_solo = list()

#Criar o caminho de cada paisagem e adicionar à lista

for l in larguras :
    paisagem = 'C:/tese_corumbatai/planejadas_rip/buffer_' + str(l) + '.tif'
    uso_solo.append(paisagem)

#Atualizar o argumento 'lulc_path', o sufixo e rodar o INVEST

for psg in uso_solo :
    args['lulc_path'] = psg
    a = psg.split('/')
    b = a[3]
    c = b.split('.tif')
    sufi = c[0]
    args['results_suffix'] = sufi
    if __name__ == '__main__':
        natcap.invest.sdr.sdr.execute(args)

```

```
#####
# DECLIVIDADE - PDECLIVIDADE #
#####

#Definir as declividades
declividades = list(range(1, 64))

#Criar a lista de caminhos das paisagens (uso e cobertura do solo)
uso_solo = list()

#Criar o caminho de cada paisagem e adicionar à lista
for d in declividades :
    paisagem = 'C:/tese_corumbatai/planejadas_dec/declividade_' + str(d) +
'_a_64' + '.tif'
    uso_solo.append(paisagem)

#Atualizar o argumento 'lulc_path', o sufixo e rodar o INVEST
for psg in uso_solo :
    args['lulc_path'] = psg
    a = psg.split('/')
    b = a[3]
    c = b.split('.tif')
    sufi = c[0]
    args['results_suffix'] = sufi
    if __name__ == '__main__':
        natcap.invest.sdr.sdr.execute(args)
```


APÊNDICE E – Resultados das análises estatísticas

A seguir são apresentados os resultados das análises estatísticas e das florestas aleatórias e árvores de regressão.

1 Comparação de médias entre múltiplos grupos independentes

Método da ANOVA robusta utilizando média aparada em 20%, alfa = 0,05 e *nboot* = 599

1.1 Diferença na produção de sedimentos entre classes de porcentagem de floresta

Sedimento ~ Porcentagem – grupo geral de paisagens

1.1.1 Grupo MN

a) ANOVA robusta

Call:

```
tlway(formula = sed_export ~ porcentagem, data = mn, tr = 0.2,
      alpha = 0.05, nboot = 599)
```

Test statistic: F = 4253.026
 Degrees of freedom 1: 8
 Degrees of freedom 2: 1938.71
 p-value: 0

Explanatory measure of effect size: 0.7

Bootstrap CI: [0.7; 0.71]

b) Teste post hoc

Call:

```
lincon(formula = sed_export ~ porcentagem, data = mn, tr = 0.2,
      alpha = 0.05, nboot = 599)
```

	psihat	ci.lower	ci.upper	p.value
0.1 vs. 0.2	1801.1887	1391.6723	2210.705	0
0.1 vs. 0.3	3624.7100	3137.8011	4111.619	0
0.1 vs. 0.4	5239.3890	4705.4018	5773.376	0
0.1 vs. 0.5	7322.7007	6792.4070	7852.994	0
0.1 vs. 0.6	8805.6104	8330.5076	9280.713	0
0.1 vs. 0.7	10189.1660	9798.6796	10579.652	0
0.1 vs. 0.8	11466.1631	11156.7742	11775.552	0
0.1 vs. 0.9	12463.6944	12229.3419	12698.047	0
0.2 vs. 0.3	1823.5213	1267.1489	2379.894	0
0.2 vs. 0.4	3438.2003	2840.6808	4035.720	0
0.2 vs. 0.5	5521.5120	4927.7349	6115.289	0
0.2 vs. 0.6	7004.4216	6457.4613	7551.382	0
0.2 vs. 0.7	8387.9773	7913.1105	8862.844	0
0.2 vs. 0.8	9664.9743	9253.8823	10076.066	0
0.2 vs. 0.9	10662.5057	10304.6058	11020.406	0
0.3 vs. 0.4	1614.6790	960.2233	2269.135	0
0.3 vs. 0.5	3697.9907	3046.9135	4349.068	0
0.3 vs. 0.6	5180.9003	4573.2291	5788.572	0
0.3 vs. 0.7	6564.4560	6021.6520	7107.260	0
0.3 vs. 0.8	7841.4530	7352.8485	8330.058	0
0.3 vs. 0.9	8838.9844	8393.9127	9284.056	0
0.4 vs. 0.5	2083.3117	1397.0991	2769.524	0
0.4 vs. 0.6	3566.2213	2920.3533	4212.089	0
0.4 vs. 0.7	4949.7770	4364.2704	5535.284	0
0.4 vs. 0.8	6226.7740	5691.2875	6762.261	0

0.4 vs. 0.9	7224.3054	6729.2847	7719.326	0
0.5 vs. 0.6	1482.9097	840.2578	2125.562	0
0.5 vs. 0.7	2866.4653	2284.5266	3448.404	0
0.5 vs. 0.8	4143.4624	3612.4277	4674.497	0
0.5 vs. 0.9	5140.9937	4650.1015	5631.886	0
0.6 vs. 0.7	1383.5557	850.7226	1916.389	0
0.6 vs. 0.8	2660.5527	2183.7229	3137.382	0
0.6 vs. 0.9	3658.0841	3225.1110	4091.057	0
0.7 vs. 0.8	1276.9971	884.7852	1669.209	0
0.7 vs. 0.9	2274.5284	1938.1029	2610.954	0
0.8 vs. 0.9	997.5313	760.3081	1234.755	0

1.1.2 Grupo MNRipária

a) ANOVA robusta					
Call:					
tlway(formula = sed_export ~ porcentagem, data = mnrip, tr = 0.2, alpha = 0.05, nboot = 599)					
Test statistic: F = 8487.11					
Degrees of freedom 1: 8					
Degrees of freedom 2: 1977.93					
p-value: 0					
Explanatory measure of effect size: 0.74					
Bootstrap CI: [0.74; 0.75]					
b) Teste post hoc					
Call:					
lincon(formula = sed_export ~ porcentagem, data = mnrip, tr = 0.2, alpha = 0.05, nboot = 599)					
	psihat	ci.lower	ci.upper	p.value	
0.1 vs. 0.2	154.0562	127.44522	180.6673	0	
0.1 vs. 0.3	311.9391	277.49062	346.3877	0	
0.1 vs. 0.4	503.8424	462.22527	545.4596	0	
0.1 vs. 0.5	677.9017	631.39596	724.4075	0	
0.1 vs. 0.6	836.3915	794.96253	877.8205	0	
0.1 vs. 0.7	1004.4265	972.26081	1036.5921	0	
0.1 vs. 0.8	1152.7430	1127.01056	1178.4754	0	
0.1 vs. 0.9	1285.4749	1269.39185	1301.5579	0	
0.2 vs. 0.3	157.8829	118.40754	197.3583	0	
0.2 vs. 0.4	349.7862	303.66893	395.9035	0	
0.2 vs. 0.5	523.8455	473.46140	574.2295	0	
0.2 vs. 0.6	682.3352	636.38390	728.2866	0	
0.2 vs. 0.7	850.3702	812.80360	887.9369	0	
0.2 vs. 0.8	998.6867	966.37616	1030.9973	0	
0.2 vs. 0.9	1131.4186	1106.06403	1156.7732	0	
0.3 vs. 0.4	191.9033	140.97654	242.8300	0	
0.3 vs. 0.5	365.9626	311.08970	420.8354	0	
0.3 vs. 0.6	524.4523	473.66063	575.2441	0	
0.3 vs. 0.7	692.4873	649.02682	735.9478	0	
0.3 vs. 0.8	840.8038	801.88178	879.7259	0	
0.3 vs. 0.9	973.5357	940.13378	1006.9376	0	
0.4 vs. 0.5	174.0593	114.26618	233.8524	0	
0.4 vs. 0.6	332.5491	276.58311	388.5150	0	
0.4 vs. 0.7	500.5840	451.23932	549.9288	0	
0.4 vs. 0.8	648.9006	603.30326	694.4978	0	
0.4 vs. 0.9	781.6324	740.72839	822.5364	0	
0.5 vs. 0.6	158.4898	98.82548	218.1541	0	
0.5 vs. 0.7	326.5248	273.00066	380.0489	0	
0.5 vs. 0.8	474.8413	424.91817	524.7644	0	
0.5 vs. 0.9	607.5731	561.79931	653.3470	0	
0.6 vs. 0.7	168.0350	118.84899	217.2210	0	
0.6 vs. 0.8	316.3515	270.92150	361.7815	0	
0.6 vs. 0.9	449.0834	408.36754	489.7992	0	
0.7 vs. 0.8	148.3165	111.39164	185.2414	0	
0.7 vs. 0.9	281.0484	250.02752	312.0692	0	
0.8 vs. 0.9	132.7319	108.33871	157.1250	0	

1.2 Diferença na produção de sedimentos entre classes de autocorrelação espacial

Sedimento ~ *Roughness* – grupo geral de paisagens

1.2.1 Grupo MN

a) ANOVA robusta

Call:

```
tlway(formula = sed_export ~ roughness_valor, data = mn, tr = 0.2,
      alpha = 0.05, nboot = 599)
```

Test statistic: F = 89.1933
 Degrees of freedom 1: 8
 Degrees of freedom 2: 2017.08
 p-value: 0

Explanatory measure of effect size: 0.26
 Bootstrap CI: [0.25; 0.28]

b) Teste post hoc

Call:

```
lincon(formula = sed_export ~ roughness_valor, data = mn, tr = 0.2,
      alpha = 0.05, nboot = 599)
```

		psihat	ci.lower	ci.upper	p.value
0.1 vs. 0.2	71.84734	-890.65589	1034.351	0.82454	
0.1 vs. 0.3	192.83028	-766.86124	1152.522	0.82454	
0.1 vs. 0.4	305.33074	-629.18255	1239.844	0.82454	
0.1 vs. 0.5	644.36435	-305.65876	1594.387	0.48570	
0.1 vs. 0.6	1074.53639	125.18827	2023.885	0.01279	
0.1 vs. 0.7	1990.22537	1063.81012	2916.641	0.00000	
0.1 vs. 0.8	3375.00314	2507.82535	4242.181	0.00000	
0.1 vs. 0.9	4630.81244	3822.54798	5439.077	0.00000	
0.2 vs. 0.3	120.98294	-834.08380	1076.050	0.82454	
0.2 vs. 0.4	233.48340	-696.28292	1163.250	0.82454	
0.2 vs. 0.5	572.51701	-372.83516	1517.869	0.72273	
0.2 vs. 0.6	1002.68905	58.01513	1947.363	0.02489	
0.2 vs. 0.7	1918.37803	996.73035	2840.026	0.00000	
0.2 vs. 0.8	3303.15580	2441.13801	4165.174	0.00000	
0.2 vs. 0.9	4558.96510	3757.05928	5360.871	0.00000	
0.3 vs. 0.4	112.50046	-814.35727	1039.358	0.82454	
0.3 vs. 0.5	451.53407	-490.95647	1394.025	0.82454	
0.3 vs. 0.6	881.70611	-60.10417	1823.516	0.07163	
0.3 vs. 0.7	1797.39509	879.12961	2715.661	0.00000	
0.3 vs. 0.8	3182.17286	2324.00872	4040.337	0.00000	
0.3 vs. 0.9	4437.98216	3638.91920	5237.045	0.00000	
0.4 vs. 0.5	339.03361	-577.81804	1255.885	0.82454	
0.4 vs. 0.6	769.20565	-146.94717	1685.358	0.15323	
0.4 vs. 0.7	1684.89463	792.94696	2576.842	0.00000	
0.4 vs. 0.8	3069.67240	2238.19530	3901.150	0.00000	
0.4 vs. 0.9	4325.48170	3557.49755	5093.466	0.00000	
0.5 vs. 0.6	430.17204	-501.78886	1362.133	0.82454	
0.5 vs. 0.7	1345.86102	437.69401	2254.028	0.00020	
0.5 vs. 0.8	2730.63880	1881.98535	3579.292	0.00000	
0.5 vs. 0.9	3986.44809	3199.85982	4773.036	0.00000	
0.6 vs. 0.7	915.68898	8.22733	1823.151	0.03895	
0.6 vs. 0.8	2300.46675	1452.55882	3148.375	0.00000	
0.6 vs. 0.9	3556.27605	2770.49079	4342.061	0.00000	
0.7 vs. 0.8	1384.77777	562.78243	2206.773	0.00001	
0.7 vs. 0.9	2640.58707	1883.53090	3397.643	0.00000	
0.8 vs. 0.9	1255.80929	570.90966	1940.709	0.00000	

1.2.2 Grupo MNRipária

a) ANOVA robusta

Call:

```
tlway(formula = sed_export ~ roughness_valor, data = mnrip, tr = 0.2,
      alpha = 0.05, nboot = 599)
```

Test statistic: F = 16.3223
 Degrees of freedom 1: 8

Degrees of freedom 2: 2020.71
p-value: 0

Explanatory measure of effect size: 0.13
Bootstrap CI: [0.12; 0.16]

b) Teste post hoc

Call:
lincon(formula = sed_export ~ roughness_valor, data = mnrip,
tr = 0.2, alpha = 0.05, nboot = 599)

	psihat	ci.lower	ci.upper	p.value
0.1 vs. 0.2	17.00771	-76.90317	110.91859	0.81323
0.1 vs. 0.3	25.42309	-68.73642	119.58260	0.81323
0.1 vs. 0.4	43.42189	-49.70084	136.54463	0.81323
0.1 vs. 0.5	50.74297	-40.80317	142.28911	0.81323
0.1 vs. 0.6	102.47826	10.97195	193.98457	0.01996
0.1 vs. 0.7	123.47831	32.97543	213.98119	0.00131
0.1 vs. 0.8	181.80327	92.50375	271.10279	0.00000
0.1 vs. 0.9	240.37694	154.77764	325.97624	0.00000
0.2 vs. 0.3	8.41538	-86.99309	103.82385	0.81323
0.2 vs. 0.4	26.41418	-67.97090	120.79927	0.81323
0.2 vs. 0.5	33.73526	-59.03964	126.51016	0.81323
0.2 vs. 0.6	85.47055	-7.26514	178.20625	0.12626
0.2 vs. 0.7	106.47060	14.61751	198.32370	0.01372
0.2 vs. 0.8	164.79556	74.11502	255.47611	0.00000
0.2 vs. 0.9	223.36923	136.41408	310.32438	0.00000
0.3 vs. 0.4	17.99880	-76.63370	112.63131	0.81323
0.3 vs. 0.5	25.31988	-67.76098	118.40074	0.81323
0.3 vs. 0.6	77.05517	-15.98650	170.09685	0.23862
0.3 vs. 0.7	98.05522	5.94808	190.16237	0.03376
0.3 vs. 0.8	156.38018	65.44247	247.31789	0.00001
0.3 vs. 0.9	214.95385	127.73353	302.17417	0.00000
0.4 vs. 0.5	7.32108	-84.71116	99.35331	0.81323
0.4 vs. 0.6	59.05637	-32.93624	151.04898	0.73794
0.4 vs. 0.7	80.05642	-10.99115	171.10399	0.16421
0.4 vs. 0.8	138.38138	48.54159	228.22117	0.00014
0.4 vs. 0.9	196.95504	110.84165	283.06844	0.00000
0.5 vs. 0.6	51.73529	-38.66149	142.13208	0.81323
0.5 vs. 0.7	72.73534	-16.69995	162.17064	0.25366
0.5 vs. 0.8	131.06030	42.94909	219.17152	0.00029
0.5 vs. 0.9	189.63397	105.21002	274.05791	0.00000
0.6 vs. 0.7	21.00005	-68.39450	110.39460	0.81323
0.6 vs. 0.8	79.32501	-8.74486	167.39488	0.14446
0.6 vs. 0.9	137.89867	53.51751	222.27984	0.00004
0.7 vs. 0.8	58.32496	-28.81065	145.46057	0.65807
0.7 vs. 0.9	116.89862	33.54453	200.25272	0.00083
0.8 vs. 0.9	58.57366	-23.38988	140.53721	0.50861

1.3 Diferença na produção de sedimentos entre classes de autocorrelação espacial dentro de cada classe de porcentagem de floresta

Sedimento ~ *Roughness* – por classes de porcentagem de floresta

1.3.1 Grupo MN

Porcentagem de floresta = 0,1

a) ANOVA robusta

Call:
t1way(formula = sed_export ~ roughness_valor, data = dados, tr = 0.2,
alpha = 0.05, nboot = 599)

Test statistic: F = 26.7034
Degrees of freedom 1: 8
Degrees of freedom 2: 220.57
p-value: 0

Explanatory measure of effect size: 0.56

Bootstrap CI: [0.49; 0.63]

Porcentagem de floresta = 0,2

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ roughness_valor, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 39.9648
 Degrees of freedom 1: 8
 Degrees of freedom 2: 220.89
 p-value: 0

Explanatory measure of effect size: 0.5
 Bootstrap CI: [0.46; 0.56]

Porcentagem de floresta = 0,3

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ roughness_valor, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 45.0106
 Degrees of freedom 1: 8
 Degrees of freedom 2: 220.64
 p-value: 0

Explanatory measure of effect size: 0.49
 Bootstrap CI: [0.44; 0.54]

Porcentagem de floresta = 0,4

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ roughness_valor, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 62.8008
 Degrees of freedom 1: 8
 Degrees of freedom 2: 218.28
 p-value: 0

Explanatory measure of effect size: 0.46
 Bootstrap CI: [0.43; 0.51]

Porcentagem de floresta = 0,5

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ roughness_valor, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 37.7306
 Degrees of freedom 1: 8
 Degrees of freedom 2: 216.77
 p-value: 0

Explanatory measure of effect size: 0.39
 Bootstrap CI: [0.36; 0.45]

Porcentagem de floresta = 0,6

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ roughness_valor, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 50.5732
 Degrees of freedom 1: 8
 Degrees of freedom 2: 212.69
 p-value: 0

Explanatory measure of effect size: 0.43
 Bootstrap CI: [0.41; 0.49]

Porcentagem de floresta = 0,7

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ roughness_valor, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 31.7389
 Degrees of freedom 1: 8
 Degrees of freedom 2: 214.45
 p-value: 0

Explanatory measure of effect size: 0.41
 Bootstrap CI: [0.37; 0.46]

Porcentagem de floresta = 0,8

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ roughness_valor, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 34.6697
 Degrees of freedom 1: 8
 Degrees of freedom 2: 206
 p-value: 0

Explanatory measure of effect size: 0.4
 Bootstrap CI: [0.36; 0.48]

Porcentagem de floresta = 0,9

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ roughness_valor, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 29.2612
 Degrees of freedom 1: 8
 Degrees of freedom 2: 209.85
 p-value: 0

Explanatory measure of effect size: 0.49
 Bootstrap CI: [0.42; 0.6]

1.3.2 Grupo MNRipária

Porcentagem de floresta = 0,1

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ roughness_valor, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 9.1342
 Degrees of freedom 1: 8
 Degrees of freedom 2: 220.48
 p-value: 0

Explanatory measure of effect size: 0.28
 Bootstrap CI: [0.24; 0.36]

Porcentagem de floresta = 0,2

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ roughness_valor, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 14.9439
 Degrees of freedom 1: 8
 Degrees of freedom 2: 220.92
 p-value: 0

Explanatory measure of effect size: 0.35
 Bootstrap CI: [0.29; 0.41]

Porcentagem de floresta = 0,3

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ roughness_valor, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 17.0655
 Degrees of freedom 1: 8
 Degrees of freedom 2: 220.56
 p-value: 0

Explanatory measure of effect size: 0.31
 Bootstrap CI: [0.26; 0.37]

Porcentagem de floresta = 0,4

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ roughness_valor, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 10.3682
 Degrees of freedom 1: 8
 Degrees of freedom 2: 220.32
 p-value: 0

Explanatory measure of effect size: 0.28
 Bootstrap CI: [0.24; 0.36]

Porcentagem de floresta = 0,5

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ roughness_valor, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 9.7548
 Degrees of freedom 1: 8
 Degrees of freedom 2: 218.9
 p-value: 0

Explanatory measure of effect size: 0.24
 Bootstrap CI: [0.2; 0.32]

Porcentagem de floresta = 0,6

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ roughness_valor, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 8.003
 Degrees of freedom 1: 8
 Degrees of freedom 2: 218.78
 p-value: 0

Explanatory measure of effect size: 0.24
 Bootstrap CI: [0.21; 0.32]

Porcentagem de floresta = 0,7

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ roughness_valor, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 8.3423
 Degrees of freedom 1: 8
 Degrees of freedom 2: 218.48
 p-value: 0

Explanatory measure of effect size: 0.23

<hr/> Bootstrap CI: [0.21; 0.32] <hr/> Porcentagem de floresta = 0,8 <hr/> a) ANOVA robusta <hr/> Call: <pre>tlway(formula = sed_export ~ roughness_valor, data = dados, tr = 0.2, alpha = 0.05, nboot = 599)</pre> Test statistic: F = 8.0343 Degrees of freedom 1: 8 Degrees of freedom 2: 217.8 p-value: 0 Explanatory measure of effect size: 0.3 Bootstrap CI: [0.24; 0.4] <hr/> Porcentagem de floresta = 0,9 <hr/> a) ANOVA robusta <hr/> Call: <pre>tlway(formula = sed_export ~ roughness_valor, data = dados, tr = 0.2, alpha = 0.05, nboot = 599)</pre> Test statistic: F = 7.4003 Degrees of freedom 1: 8 Degrees of freedom 2: 217.94 p-value: 0 Explanatory measure of effect size: 0.29 Bootstrap CI: [0.22; 0.43] <hr/>

1.4 Diferença na produção de sedimentos entre classes de porcentagem de floresta dentro de cada nível de autocorrelação espacial

Sedimento ~ Porcentagem – por classes de *roughness*

1.4.1 Grupo MN

Roughness = 0,1 <hr/> a) ANOVA robusta <hr/> Call: <pre>tlway(formula = sed_export ~ porcentagem, data = dados, tr = 0.2, alpha = 0.05, nboot = 599)</pre> Test statistic: F = 427.1809 Degrees of freedom 1: 8 Degrees of freedom 2: 216.79 p-value: 0 Explanatory measure of effect size: 0.69 Bootstrap CI: [0.68; 0.71] <hr/> Roughness = 0,2 <hr/> a) ANOVA robusta <hr/> Call: <pre>tlway(formula = sed_export ~ porcentagem, data = dados, tr = 0.2, alpha = 0.05, nboot = 599)</pre> Test statistic: F = 358.3789 Degrees of freedom 1: 8 Degrees of freedom 2: 218.51 p-value: 0 Explanatory measure of effect size: 0.69 <hr/>

Bootstrap CI: [0.68; 0.71]

Roughness = 0,3

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ porcentagem, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 505.5333
 Degrees of freedom 1: 8
 Degrees of freedom 2: 216
 p-value: 0

Explanatory measure of effect size: 0.71
 Bootstrap CI: [0.69; 0.72]

Roughness = 0,4

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ porcentagem, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 619.2844
 Degrees of freedom 1: 8
 Degrees of freedom 2: 216
 p-value: 0

Explanatory measure of effect size: 0.73
 Bootstrap CI: [0.7; 0.74]

Roughness = 0,5

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ porcentagem, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 1104.866
 Degrees of freedom 1: 8
 Degrees of freedom 2: 214.86
 p-value: 0

Explanatory measure of effect size: 0.74
 Bootstrap CI: [0.72; 0.75]

Roughness = 0,6

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ porcentagem, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 1140.429
 Degrees of freedom 1: 8
 Degrees of freedom 2: 213.8
 p-value: 0

Explanatory measure of effect size: 0.73
 Bootstrap CI: [0.71; 0.74]

Roughness = 0,7

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ porcentagem, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 814.3697
 Degrees of freedom 1: 8
 Degrees of freedom 2: 211.11
 p-value: 0

Explanatory measure of effect size: 0.75
 Bootstrap CI: [0.73; 0.76]

Roughness = 0,8

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ porcentagem, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 559.8564
 Degrees of freedom 1: 8
 Degrees of freedom 2: 206
 p-value: 0

Explanatory measure of effect size: 0.81
 Bootstrap CI: [0.78; 0.84]

Roughness = 0,9

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ porcentagem, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 504.4514
 Degrees of freedom 1: 8
 Degrees of freedom 2: 207.68
 p-value: 0

Explanatory measure of effect size: 0.88
 Bootstrap CI: [0.85; 0.92]

1.4.2 Grupo MNRipária

Roughness = 0,1

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ porcentagem, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 474.8932
 Degrees of freedom 1: 8
 Degrees of freedom 2: 213.12
 p-value: 0

Explanatory measure of effect size: 0.71
 Bootstrap CI: [0.69; 0.73]

Roughness = 0,2

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ porcentagem, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 736.9969
 Degrees of freedom 1: 8
 Degrees of freedom 2: 217.03
 p-value: 0

Explanatory measure of effect size: 0.71
 Bootstrap CI: [0.69; 0.73]

Roughness = 0,3

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ porcentagem, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 1405.326
 Degrees of freedom 1: 8
 Degrees of freedom 2: 214.57
 p-value: 0

Explanatory measure of effect size: 0.72
 Bootstrap CI: [0.71; 0.74]

Roughness = 0,4

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ porcentagem, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 1062.566
 Degrees of freedom 1: 8
 Degrees of freedom 2: 216.01
 p-value: 0

Explanatory measure of effect size: 0.74
 Bootstrap CI: [0.72; 0.75]

Roughness = 0,5

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ porcentagem, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 930.6355
 Degrees of freedom 1: 8
 Degrees of freedom 2: 216.45
 p-value: 0

Explanatory measure of effect size: 0.75
 Bootstrap CI: [0.73; 0.77]

Roughness = 0,6

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ porcentagem, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 744.7919
 Degrees of freedom 1: 8
 Degrees of freedom 2: 218.36
 p-value: 0

Explanatory measure of effect size: 0.74
 Bootstrap CI: [0.73; 0.75]

Roughness = 0,7

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ porcentagem, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 1177.587
 Degrees of freedom 1: 8
 Degrees of freedom 2: 215.8
 p-value: 0

Explanatory measure of effect size: 0.76
 Bootstrap CI: [0.75; 0.79]

Roughness = 0,8

a) ANOVA robusta

Call:
 tlway(formula = sed_export ~ porcentagem, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 1304.968
 Degrees of freedom 1: 8
 Degrees of freedom 2: 212.8
 p-value: 0

Explanatory measure of effect size: 0.77
 Bootstrap CI: [0.76; 0.79]

Roughness = 0,9

a) ANOVA robusta

Call:
 t1way(formula = sed_export ~ porcentagem, data = dados, tr = 0.2,
 alpha = 0.05, nboot = 599)

Test statistic: F = 1564.494
 Degrees of freedom 1: 8
 Degrees of freedom 2: 212.68
 p-value: 0

Explanatory measure of effect size: 0.82
 Bootstrap CI: [0.8; 0.84]

2 Correlações de Spearman entre produção de sedimentos e métricas de paisagem

Todas as correlações foram estatisticamente significativas ($p < 0,05$) exceto quando indicado nas notas.

Métrica	Nível de classe - floresta		Nível de paisagem	
	MN	MNRipária	MN	MNRipária
AI	-0,031	-0,527	0,271	-0,281
AREA_AM	-0,723	-0,831	-	-
AREA_CV	-0,228	-0,054	-	-
AREA_MD	0,105	-0,019 ^a	-	-
AREA_MN	-0,075	-0,150	-	-
AREA_SD	-0,233	-0,190	-	-
CIRCLE_AM	0,004 ^a	0,829	-	-
CIRCLE_CV	-0,211	-0,087	-	-
CIRCLE_MD	0,211	0,206	-	-
CIRCLE_MN	0,223	0,226	-	-
CIRCLE_SD	-0,095	0,078	-	-
CLUMPY	0,399	-0,064	-	-
COHESION	-0,623	-0,759	0,207	-0,181
CONTAG	-	-	0,148	-0,302
CONTIG_AM	-0,132	-0,555	-	-
CONTIG_CV	-0,217	-0,116	-	-
CONTIG_MD	0,152	-0,002 ^a	-	-
CONTIG_MN	0,218	0,037	-	-
CONTIG_SD	0,070	0,025	-	-
DIVISION	0,765	0,832	-0,071	0,602
ED	-0,267	0,283	-	-
ENN_AM	0,493	0,388	-	-
ENN_CV	0,265	0,190	-	-
ENN_MD	0,361	0,272	-	-

ENN_MN	0,465	0,323	-	-
ENN_SD	0,327	0,217	-	-
FRAC_AM	-0,258	0,456	-	-
FRAC_CV	-0,103	0,266	-	-
FRAC_MD	0,183	0,209	-	-
FRAC_MN	0,197	0,294	-	-
FRAC_SD	-0,097	0,269	-	-
GYRATE_AM	-0,675	-0,315	-	-
GYRATE_CV	-0,320	-0,131	-	-
GYRATE_MD	0,102	0,040	-	-
GYRATE_MN	0,056	0,015 ^a	-	-
GYRATE_SD	-0,073	0,012 ^a	-	-
LPI	-0,755	-0,832	-	-
LSI	-0,181	0,395	-0,267	0,283
MESH	-0,765	-0,832	0,074	-0,602
NLSI	-0,379	-0,018 ^a	-	-
PAFRAC	-0,122	0,320	-	-
PARA_AM	0,125	0,539	-	-
PARA_CV	0,177	0,053	-	-
PARA_MD	-0,144	0,006 ^a	-	-
PARA_MN	-0,215	-0,036	-	-
PARA_SD	0,061	0,024	-	-
PD	-0,157	-0,044	-	-
PD_zrip	-0,244	-	-	-
PLADJ	-0,125	-0,539	0,267	-0,283
PLAND	-0,821	-0,834	-	-
PLAND_zrip	-0,854	-	-	-
SHAPE_AM	-0,316	0,410	-	-
SHAPE_CV	-0,227	0,254	-	-
SHAPE_MD	0,136	0,200	-	-
SHAPE_MN	0,177	0,328	-	-
SHAPE_SD	-0,211	0,304	-	-
SPLIT	0,765	0,832	-0,072	0,602

Notas:

^a $p \geq 0,05$

3 Correlações de Spearman entre produção de sedimentos e métricas de paisagem por porcentagem da paisagem ocupada por floresta

Todas as correlações foram estatisticamente significativas ($p < 0,05$) exceto quando indicado nas notas.

3.1 Métricas em nível de classe para o grupo MN

Porcentagem de floresta (%)									
Métrica	10	20	30	40	50	60	70	80	90
AI	0,367	0,427	0,465	0,498	0,473	0,526	0,468	0,490	0,412
AREA_AM	0,376	0,431	0,469	0,489	0,397	0,390	0,293	0,314	0,248
AREA_CV	-0,383	-0,409	-0,448	-0,428	-0,420	-0,487	-0,414	-0,435	-0,370
AREA_MD	0,371	0,354	0,395	0,358	0,372	0,396	0,337	0,349	0,307
AREA_MN	0,427	0,452	0,483	0,467	0,447	0,497	0,419	0,439	0,368
AREA_SD	0,248	0,171	0,121	0,157	0,141	0,133	0,214	0,157	0,132
CIRCLE_AM	0,168	0,142	0,068	-0,020 ^a	0,054 ^a	-0,036 ^a	0,004 ^a	-0,160	-0,272
CIRCLE_CV	-0,375	-0,325	-0,348	-0,312	-0,332	-0,343	-0,303	-0,333	-0,287
CIRCLE_MD	0,493	0,382	0,358	0,332	0,347	0,383	0,368	0,347	0,330
CIRCLE_MN	0,451	0,321	0,316	0,252	0,294	0,316	0,306	0,310	0,308
CIRCLE_SD	-0,273	-0,312	-0,347	-0,358	-0,298	-0,352	-0,250	-0,307	-0,208
CLUMPY	0,367	0,427	0,465	0,498	0,473	0,526	0,468	0,490	0,412
COHESION	0,395	0,455	0,493	0,494	0,430	0,424	0,322	0,296	0,214
CONTIG_AM	0,366	0,429	0,467	0,501	0,474	0,527	0,470	0,493	0,414
CONTIG_CV	-0,350	-0,288	-0,324	-0,280	-0,290	-0,326	-0,265	-0,306	-0,287
CONTIG_MD	0,352	0,333	0,380	0,343	0,362	0,406	0,343	0,360	0,294
CONTIG_MN	0,397	0,398	0,429	0,408	0,404	0,449	0,379	0,423	0,350
CONTIG_SD	0,022 ^a	0,015 ^a	-0,039 ^a	0,043 ^a	0,033 ^a	-0,011 ^a	0,083	0,069	0,056 ^a
DIVISION	-0,378	-0,434	-0,470	-0,490	-0,396	-0,390	-0,294	-0,315	-0,248
ED	-0,417	-0,428	-0,461	-0,475	-0,460	-0,517	-0,476	-0,512	-0,496
ENN_AM	0,242	0,119	0,131	0,127	0,150	0,198	0,292	0,293	0,295
ENN_CV	-0,041 ^a	-0,008 ^a	-0,016 ^a	0,115	0,083	0,120	0,092	0,104	0,089
ENN_MD	0,244	0,174	0,218	0,248	0,278	0,391	0,442	0,414	0,384
ENN_MN	0,343	0,274	0,307	0,357	0,336	0,456	0,487	0,456	0,461
ENN_SD	0,107	0,100	0,118	0,208	0,151	0,265	0,228	0,225	0,208
FRAC_AM	-0,307	-0,348	-0,395	-0,444	-0,437	-0,503	-0,455	-0,488	-0,419
FRAC_CV	-0,357	-0,392	-0,429	-0,437	-0,397	-0,455	-0,367	-0,405	-0,316
FRAC_MD	0,475	0,367	0,364	0,310	0,326	0,357	0,346	0,355	0,346
FRAC_MN	0,397	0,262	0,257	0,151	0,200	0,250	0,268	0,269	0,308
FRAC_SD	-0,348	-0,389	-0,425	-0,435	-0,391	-0,451	-0,361	-0,401	-0,310
GYRATE_AM	0,443	0,469	0,467	0,430	0,297	0,121	0,037 ^a	-0,093	-0,130
GYRATE_CV	-0,212	-0,225	-0,284	-0,246	-0,305	-0,370	-0,354	-0,404	-0,378
GYRATE_MD	0,364	0,348	0,386	0,334	0,337	0,373	0,313	0,322	0,301
GYRATE_MN	0,451	0,458	0,480	0,449	0,432	0,483	0,409	0,421	0,374
GYRATE_SD	0,234	0,184	0,134	0,162	0,157	0,137	0,215	0,156	0,129
LPI	0,361	0,414	0,454	0,477	0,387	0,386	0,291	0,314	0,248
LSI	-0,367	-0,427	-0,465	-0,498	-0,473	-0,526	-0,468	-0,490	-0,412
MESH	0,376	0,431	0,469	0,489	0,397	0,390	0,293	0,314	0,248
NLSI	-0,367	-0,428	-0,464	-0,498	-0,473	-0,526	-0,468	-0,490	-0,412
PAFRAC	-0,569	-0,525	-0,485	-0,588	-0,466	-0,575	-0,512	-0,552	-0,512
PARA_AM	-0,367	-0,427	-0,465	-0,498	-0,473	-0,526	-0,468	-0,490	-0,412

PARA_CV	0,205	0,139	0,082	0,130	0,121	0,097	0,194	0,151	0,145
PARA_MD	-0,332	-0,322	-0,375	-0,332	-0,351	-0,395	-0,326	-0,357	-0,284
PARA_MN	-0,397	-0,396	-0,425	-0,408	-0,403	-0,444	-0,376	-0,419	-0,347
PARA_SD	0,006 ^a	-0,004 ^a	-0,051 ^a	0,021 ^a	0,020 ^a	-0,028 ^a	0,060 ^a	0,050 ^a	0,024 ^a
PD	-0,427	-0,452	-0,483	-0,467	-0,447	-0,497	-0,419	-0,439	-0,368
PD_zrip	-0,482	-0,491	-0,525	-0,510	-0,467	-0,479	-0,424	-0,441	-0,371
PLADJ	0,367	0,427	0,465	0,498	0,473	0,526	0,468	0,490	0,412
PLAND_zrip	-0,559	-0,515	-0,561	-0,546	-0,575	-0,476	-0,469	-0,361	-0,459
SHAPE_AM	-0,300	-0,342	-0,385	-0,436	-0,432	-0,500	-0,452	-0,487	-0,419
SHAPE_CV	-0,346	-0,387	-0,436	-0,452	-0,425	-0,489	-0,409	-0,445	-0,390
SHAPE_MD	0,422	0,337	0,358	0,276	0,302	0,338	0,296	0,315	0,307
SHAPE_MN	0,459	0,355	0,336	0,221	0,274	0,300	0,295	0,284	0,267
SHAPE_SD	-0,298	-0,374	-0,417	-0,457	-0,416	-0,481	-0,398	-0,437	-0,376
SPLIT	-0,376	-0,431	-0,469	-0,489	-0,397	-0,390	-0,293	-0,314	-0,248

Notas:

^a $p \geq 0,05$

3.2 Métricas em nível de classe para o grupo MNRipária

Métrica	Porcentagem de floresta (%)								
	10	20	30	40	50	60	70	80	90
AI	0,141	0,224	0,207	0,178	0,153	0,144	0,165	0,171	0,078
AREA_AM	0,253	0,419	0,476	0,472	0,478	0,466	0,424	0,431	0,454
AREA_CV	-0,265	-0,317	-0,286	-0,252	-0,212	-0,212	-0,174	-0,219	-0,135
AREA_MD	0,248	0,285	0,273	0,266	0,206	0,246	0,162	0,253	0,178
AREA_MN	0,284	0,350	0,339	0,305	0,271	0,274	0,222	0,266	0,208
AREA_SD	0,132	0,064 ^a	0,006 ^a	-0,009 ^a	0,021 ^a	-0,004 ^a	0,117	0,038 ^a	0,135
CIRCLE_AM	0,349	0,337	0,101	0,012 ^a	-0,029 ^a	-0,058 ^a	-0,197	-0,165	-0,247
CIRCLE_CV	-0,228	-0,211	-0,201	-0,170	-0,115	-0,168	-0,085	-0,210	-0,087
CIRCLE_MD	0,250	0,260	0,212	0,185	0,121	0,144	0,093	0,190	0,103
CIRCLE_MN	0,265	0,246	0,207	0,155	0,088	0,129	0,063 ^a	0,179	0,076
CIRCLE_SD	-0,083	-0,106	-0,127	-0,161	-0,136	-0,125	-0,117	-0,154	-0,074
CLUMPY	0,138	0,219	0,197	0,166	0,140	0,128	0,150	0,157	0,055 ^a
COHESION	0,262	0,386	0,397	0,373	0,349	0,327	0,257	0,288	0,205
CONTIG_AM	0,139	0,224	0,205	0,174	0,150	0,141	0,165	0,172	0,079
CONTIG_CV	-0,236	-0,228	-0,198	-0,170	-0,108	-0,146	-0,086	-0,194	-0,083
CONTIG_MD	0,203	0,220	0,188	0,199	0,139	0,173	0,110	0,193	0,058 ^a
CONTIG_MN	0,246	0,262	0,236	0,198	0,162	0,174	0,142	0,194	0,067
CONTIG_SD	0,006 ^a	-0,011 ^a	-0,022 ^a	-0,054 ^a	-0,010 ^a	-0,026 ^a	0,064 ^a	-0,012 ^a	0,085
DIVISION	-0,277	-0,438	-0,511	-0,524	-0,525	-0,514	-0,463	-0,455	-0,473
ED	-0,187	-0,206	-0,150	-0,114	-0,073	-0,072	-0,083	-0,127	-0,072
ENN_AM	0,140	0,021 ^a	0,017 ^a	-0,060 ^a	-0,074 ^a	-0,056 ^a	0,084	0,094	0,206
ENN_CV	-0,059 ^a	-0,113	0,004 ^a	-0,077	0,026 ^a	0,029 ^a	-0,045 ^a	0,012 ^a	-0,010 ^a
ENN_MD	0,185	0,141	0,137	0,086	0,093	0,118	0,195	0,161	0,281

ENN_MN	0,229	0,158	0,172	0,065 ^a	0,108	0,122	0,198	0,182	0,258
ENN_SD	0,027 ^a	-0,040 ^a	0,078	-0,027 ^a	0,036 ^a	0,063 ^a	0,012 ^a	0,072 ^a	0,015 ^a
FRAC_AM	-0,154	-0,187	-0,173	-0,141	-0,132	-0,129	-0,156	-0,161	-0,068
FRAC_CV	0,118	0,028 ^a	-0,045 ^a	-0,060 ^a	-0,046 ^a	-0,071	-0,077	-0,157	-0,109
FRAC_MD	0,264	0,283	0,247	0,224	0,165	0,196	0,122	0,235	0,183
FRAC_MN	0,298	0,293	0,246	0,208	0,129	0,180	0,100	0,208	0,150
FRAC_SD	0,122	0,031 ^a	-0,046 ^a	-0,058 ^a	-0,031 ^a	-0,056 ^a	-0,069	-0,148	-0,103
GYRATE_AM	0,413	0,199	0,023 ^a	0,005 ^a	-0,035 ^a	-0,066	-0,168	-0,111	-0,090
GYRATE_CV	-0,205	-0,252	-0,211	-0,184	-0,148	-0,178	-0,149	-0,206	-0,132
GYRATE_MD	0,243	0,268	0,221	0,207	0,138	0,158	0,086	0,179	0,091
GYRATE_MN	0,303	0,334	0,288	0,244	0,203	0,186	0,145	0,199	0,133
GYRATE_SD	0,178	0,067	-0,002 ^a	-0,011 ^a	0,017 ^a	-0,009 ^a	0,104	0,026 ^a	0,127
LPI	0,275	0,438	0,510	0,524	0,524	0,513	0,463	0,455	0,472
LSI	-0,136	-0,218	-0,199	-0,171	-0,148	-0,139	-0,162	-0,170	-0,077
MESH	0,278	0,438	0,511	0,524	0,524	0,514	0,463	0,455	0,472
NLSI	-0,141	-0,224	-0,207	-0,178	-0,130	-0,120	-0,145	-0,154	-0,054 ^a
PAFRAC	-0,203	-0,252	-0,295	-0,117	-0,229	-0,222	-0,214	-0,173	-0,191
PARA_AM	-0,141	-0,225	-0,209	-0,180	-0,155	-0,146	-0,166	-0,171	-0,079
PARA_CV	0,081	0,038 ^a	-0,003 ^a	-0,035 ^a	-0,011 ^a	-0,022 ^a	0,089	0,012 ^a	0,119
PARA_MD	-0,190	-0,220	-0,185	-0,201	-0,140	-0,172	-0,113	-0,188	-0,060 ^a
PARA_MN	-0,245	-0,260	-0,237	-0,198	-0,165	-0,174	-0,142	-0,192	-0,067
PARA_SD	-0,004 ^a	-0,020 ^a	-0,024 ^a	-0,067	-0,009 ^a	-0,033 ^a	0,042 ^a	-0,023 ^a	0,071
PD	-0,258	-0,320	-0,290	-0,256	-0,217	-0,214	-0,175	-0,220	-0,134
PLADJ	0,141	0,225	0,209	0,180	0,155	0,146	0,166	0,171	0,079
SHAPE_AM	-0,140	-0,191	-0,173	-0,140	-0,131	-0,128	-0,155	-0,160	-0,068
SHAPE_CV	0,002 ^a	-0,040 ^a	-0,068	-0,117	-0,093	-0,138	-0,116	-0,178	-0,118
SHAPE_MD	0,247	0,279	0,238	0,227	0,153	0,189	0,115	0,201	0,141
SHAPE_MN	0,306	0,341	0,295	0,254	0,192	0,201	0,133	0,205	0,135
SHAPE_SD	0,144	0,066	-0,013 ^a	-0,028 ^a	-0,011 ^a	-0,041 ^a	-0,005 ^a	-0,101	-0,086
SPLIT	-0,278	-0,438	-0,511	-0,524	-0,524	-0,514	-0,463	-0,455	-0,473

Notas:

^a $p \geq 0,05$

3.3 Métricas em nível de paisagem para o grupo MN

Métrica	Porcentagem de floresta (%)								
	10	20	30	40	50	60	70	80	90
AI	0,417	0,428	0,461	0,475	0,460	0,517	0,476	0,512	0,497
COHESION	0,342	0,379	0,431	0,456	0,426	0,472	0,427	0,443	0,483
CONTAG	0,417	0,428	0,461	0,475	0,460	0,517	0,476	0,512	0,497
DIVISION	-0,356	-0,334	-0,363	-0,413	-0,403	-0,429	-0,356	-0,363	-0,372
LSI	-0,417	-0,428	-0,461	-0,475	-0,460	-0,517	-0,476	-0,512	-0,496
MESH	0,357	0,331	0,362	0,411	0,403	0,427	0,356	0,362	0,371
PLADJ	0,417	0,428	0,461	0,475	0,460	0,517	0,476	0,512	0,496

SPLIT	-0,356	-0,331	-0,361	-0,413	-0,403	-0,428	-0,357	-0,363	-0,371
-------	--------	--------	--------	--------	--------	--------	--------	--------	--------

3.4 Métricas em nível de paisagem para o grupo MNRipária

Métrica	Porcentagem de floresta (%)								
	10	20	30	40	50	60	70	80	90
AI	0,187	0,206	0,150	0,114	0,073	0,072	0,082	0,127	0,071
COHESION	-0,036 ^a	0,116	0,137	0,129	0,106	0,153	0,130	0,228	0,199
CONTAG	0,162	0,188	0,127	0,105	0,088	0,131	0,163	0,246	0,296
DIVISION	0,278	0,158	0,049 ^a	0,003 ^a	-0,044 ^a	-0,170	-0,204	-0,341	-0,474
LSI	-0,187	-0,206	-0,150	-0,114	-0,073	-0,072	-0,083	-0,127	-0,072
MESH	-0,278	-0,158	-0,049 ^a	-0,003 ^a	0,044 ^a	0,170	0,205	0,341	0,474
PLADJ	0,187	0,206	0,150	0,114	0,073	0,072	0,083	0,127	0,072
SPLIT	0,278	0,158	0,049 ^a	0,003 ^a	-0,044 ^a	-0,170	-0,205	-0,341	-0,474

Notas:

^a $p \geq 0,05$

4 Métricas de paisagem como variáveis preditoras da produção de sedimentos

4.1 Florestas aleatórias

4.1.1 Resultados dos algoritmos de floresta aleatória

Grupo MN
Call: randomForest(formula = sed_export ~ ., data = mn1, mtry = 28, ntree = 500, importance = T, do.trace = 100) Type of random forest: regression Number of trees: 500 No. of variables tried at each split: 28 Mean of squared residuals: 2810844 % Var explained: 86.99
Grupo MNRipária
Call: randomForest(formula = sed_export ~ ., data = mnripl, mtry = 24, ntree = 500, importance = T, do.trace = 100) Type of random forest: regression Number of trees: 500 No. of variables tried at each split: 24 Mean of squared residuals: 29754.98 % Var explained: 85.9

4.1.2 Valores absolutos da importância das variáveis

Grupo MN			Grupo MNRipária		
	%IncMSE	IncNodePurity		%IncMSE	IncNodePurity
PLAND	3026721.22	23563570552	PLAND	255420.3775	1078481615
PD	212109.01	857141441	PD	1416.4557	3961722
ED	960837.37	4423647126	ED	28365.0740	63180926

LSI	341331.44	1065141307	LSI	4351.6309	13189809
AREA_MN	134037.78	434753982	AREA_MN	5931.4551	15984220
AREA_MD	49663.66	152883147	AREA_MD	3867.3193	9893933
AREA_SD	282323.63	1335502717	AREA_SD	2794.9235	13278036
AREA_CV	128230.29	689869466	AREA_CV	3371.8135	8625628
GYRATE_MN	272795.36	1121074779	GYRATE_MN	3710.4859	12390897
GYRATE_MD	184458.90	681132878	GYRATE_AM	16262.4939	72881630
GYRATE_SD	132248.70	811023218	GYRATE_MD	2203.4312	7890140
GYRATE_CV	285489.81	3335140662	GYRATE_SD	1465.4138	7791771
SHAPE_MN	118825.58	803957929	GYRATE_CV	2405.3025	15927311
SHAPE_AM	231676.59	1172858267	SHAPE_MN	8400.2211	39529873
SHAPE_MD	69972.81	350316504	SHAPE_AM	12728.3395	46500403
SHAPE_SD	147097.18	691078589	SHAPE_MD	1740.3960	4448910
SHAPE_CV	177154.21	706914563	SHAPE_SD	3335.4143	13044665
FRAC_MN	92065.03	698145435	SHAPE_CV	2257.4315	9789005
FRAC_AM	189002.71	850767746	FRAC_MN	2881.5636	11177715
FRAC_MD	48776.75	308785035	FRAC_AM	29907.3207	116403870
FRAC_SD	81857.27	450781674	FRAC_MD	3756.4038	9166655
FRAC_CV	82754.49	478158796	FRAC_SD	888.1036	5885165
PARA_MN	112908.39	543959467	FRAC_CV	991.3086	6262874
PARA_AM	363795.78	1144558302	PARA_MN	1965.2445	7401869
PARA_MD	68777.61	298519282	PARA_MD	1068.7260	3060001
PARA_SD	58390.47	428410759	PARA_SD	682.3414	4880724
PARA_CV	81115.74	585278025	PARA_CV	1008.8924	6110514
CIRCLE_MN	121912.28	745034870	CIRCLE_MN	5022.4957	16485907
CIRCLE_AM	802607.12	3499247999	CIRCLE_MD	5085.8350	14702820
CIRCLE_MD	96085.72	490379686	CIRCLE_SD	1032.7127	8847519
CIRCLE_SD	89884.64	703683955	CIRCLE_CV	1123.8986	6182632
CIRCLE_CV	83655.04	521222595	CONTIG_MN	1716.5467	6801869
CONTIG_MN	126953.33	594844150	CONTIG_MD	981.6540	3243065
CONTIG_AM	776350.69	2264357850	CONTIG_SD	653.4204	4857055
CONTIG_MD	74496.34	291160819	CONTIG_CV	947.0407	5981880
CONTIG_SD	59952.12	452019035	CLUMPY	8421.6007	22140010
CONTIG_CV	64017.46	460002529			
CLUMPY	1296064.54	5126769367			
PLADJ	316379.94	975648382			
AI	188336.78	595751719			
PLAND_zrip	32340396.02	100609159850			
PD_zrip	1893566.28	8582012390			

4.2 Resultados das árvores de regressão

4.2.1 Resultados da divisão binária recursiva

Grupo MN (cp = 0,01)					
n= 8100					
node), split, n, deviance, yval					
* denotes terminal node					
1) root 8100 5329.90500 1.1350250					
2) PLAND_zrip>=44.2217 4499 1257.76600 0.5968111					
4) PLAND_zrip>=69.76075 2305 266.61020 0.3184510 *					
5) PLAND_zrip< 69.76075 2194 624.91740 0.8892541					
10) CLUMPY< 0.8928 641 62.90922 0.5143713 *					
11) CLUMPY>=0.8928 1553 434.74170 1.0439870 *					
3) PLAND_zrip< 44.2217 3601 1140.65300 1.8074560					
6) PLAND_zrip>=19.08695 2217 671.55910 1.5808420					
12) PD_zrip>=38.37225 498 89.70807 1.0684840 *					
13) PD_zrip< 38.37225 1719 413.24770 1.7292740 *					
7) PLAND_zrip< 19.08695 1384 172.86530 2.1704650 *					
Grupo MNRipária (cp = 0,01)					
n= 8100					
node), split, n, deviance, yval					
* denotes terminal node					
1) root 8100 52.044990 0.12729120					
2) PLAND>=51.03695 4500 14.333710 0.07429916					
4) PLAND>=77.92855 1800 1.766464 0.03487979 *					

5)	PLAND<	77.92855	2700	7.905589	0.10057870
10)	PLAND>=	68.92995	900	1.849927	0.07483250 *
11)	PLAND<	68.92995	1800	5.160788	0.11345190 *
3)	PLAND<	51.03695	3600	9.278718	0.19353120
6)	PLAND>=	33.2813	1800	4.528489	0.16544120 *
7)	PLAND<	33.2813	1800	1.909659	0.22162120 *

4.2.2 Tabelas e gráficos do parâmetro de complexidade (cp) obtidos por validação cruzada

Grupo MN (cp = 0,01)

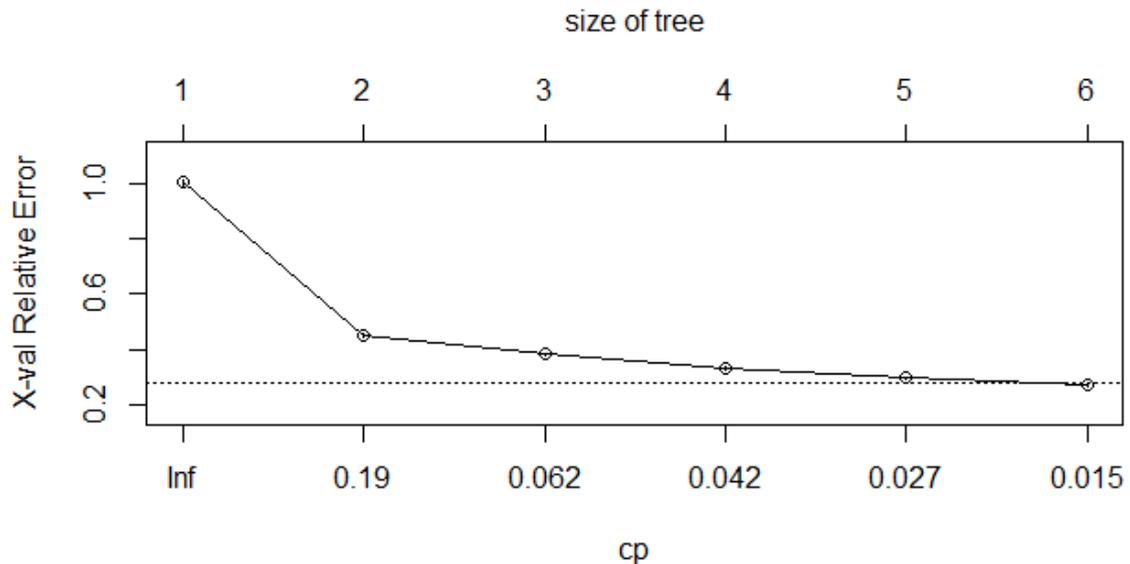
Regression tree:
 rpart(formula = sed_export ~ ., data = mn1, xval = 10, cp = 0.01)

Variables actually used in tree construction:
 [1] CLUMPY PD_zrip PLAND_zrip

Root node error: 5329.9/8100 = 0.65801

n= 8100

	CP	nsplit	rel error	xerror	xstd
1	0.550007	0	1.00000	1.00016	0.0088193
2	0.068714	1	0.44999	0.45238	0.0066395
3	0.055579	2	0.38128	0.38217	0.0056383
4	0.031633	3	0.32570	0.33249	0.0050345
5	0.023878	4	0.29407	0.29655	0.0045915
6	0.010000	5	0.27019	0.27307	0.0042067



Grupo MNRipária (cp = 0,01)

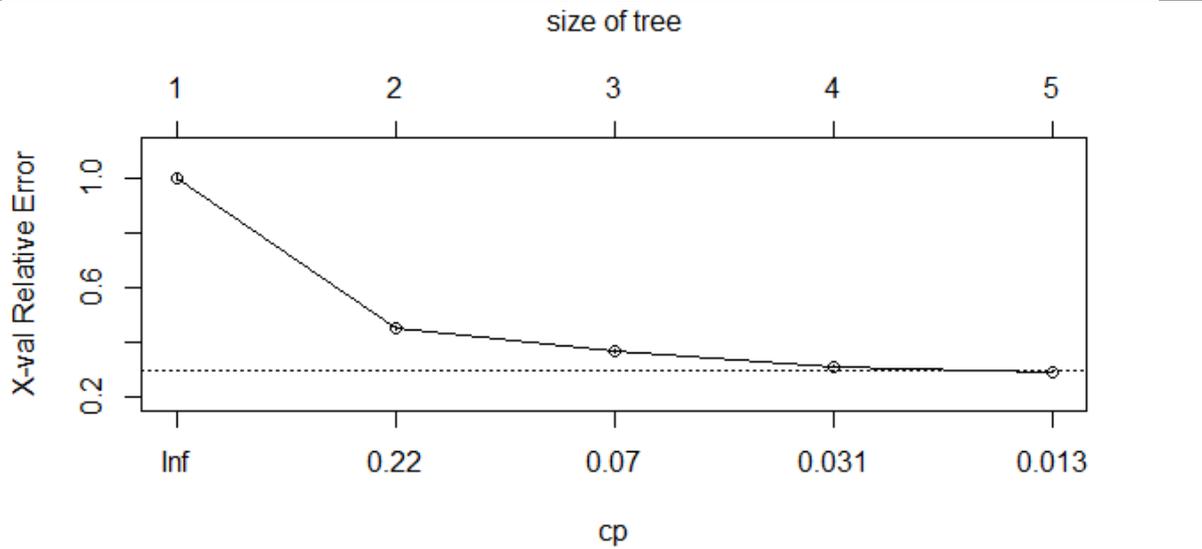
Regression tree:
 rpart(formula = sed_export ~ ., data = mnrip1, xval = 10, cp = 0.01)

Variables actually used in tree construction:
 [1] PLAND

Root node error: 52.045/8100 = 0.0064253

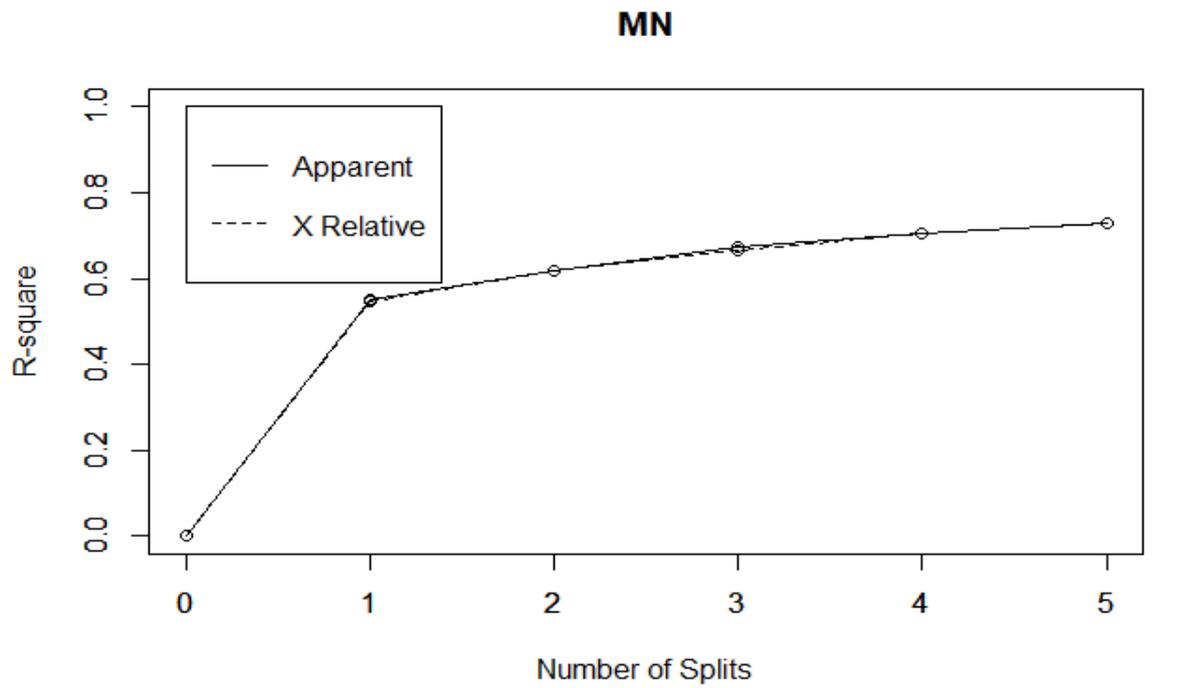
n= 8100

	CP	nsplit	rel error	xerror	xstd
1	0.546307	0	1.00000	1.00030	0.0086437
2	0.089570	1	0.45369	0.45393	0.0063807
3	0.054579	2	0.36412	0.36721	0.0052102
4	0.017194	3	0.30954	0.31268	0.0044226
5	0.010000	4	0.29235	0.29330	0.0040990



4.2.3 Gráfico do valor aproximado de R^2 para cada divisão

Grupo MN (cp = 0,01)



Grupo MNRipária (cp = 0,01)

