

**Universidade de São Paulo
Escola Superior de Agricultura “Luiz de Queiroz”**

**Criando espaços para a restauração de ecossistemas por meio do
aumento da eficiência operacional na colheita de cana-de-açúcar**

Giulio Brossi Santoro

Dissertação apresentada para obtenção do título de Mestre
em Ciências, Programa: Recursos Florestais. Opção em:
Conservação de Ecossistemas Florestais

**Piracicaba
2022**

Giulio Brossi Santoro
Engenheiro Ambiental

Criando espaços para a restauração de ecossistemas por meio do aumento da eficiência operacional na colheita de cana-de-açúcar

versão revisada de acordo com a Resolução CoPG 6018 de 2011

Orientador:
Prof. Dr. **PAULO GUILHERME MOLIN**

Dissertação apresentada para obtenção do título de Mestre em Ciências, Programa: Recursos Florestais.
Opção em: Conservação de Ecossistemas Florestais

Piracicaba
2022

Dados Internacionais de Catalogação na Publicação
DIVISÃO DE BIBLIOTECA – DIBD/ESALQ/USP

Santoro, Giulio Brossi

Criando espaços para a restauração de ecossistemas por meio do aumento da eficiência operacional na colheita de cana-de-açúcar / Giulio Brossi Santoro. - - versão revisada de acordo com a Resolução CoPG 6018 de 2011. - - Piracicaba, 2022.

99 p.

Dissertação (Mestrado) - - USP / Escola Superior de Agricultura “Luiz de Queiroz”.

1. Compensação ambiental 2. Restauração ecológica 3. Serviços ecossistêmicos
4. Ecologia da paisagem 5. Mecanização agrícola I. Título

AGRADECIMENTOS

À minha família pelo suporte em todos os momentos, principalmente os de maior dificuldade. Em especial, aos meus pais Antonio Outeiro Pinto Santoro e Maria Cecília Curcio Brossi por conceder todas as oportunidades e incentivos para conclusão desta etapa de pós-graduação.

À Escola Superior de Agricultura “Luiz de Queiroz”/Universidade de São Paulo, pela oportunidade de avançar mais uma etapa de meu desenvolvimento profissional.

À Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), pelo auxílio financeiro através da bolsa de estudos para o desenvolvimento da pesquisa correspondente ao processo nº 2020/15792-3.

Aos professores e funcionários do Departamento de Ciências Florestais (ESALQ/USP) e aos responsáveis pelo Programa de Pós-Graduação em Recursos Florestais, pelos conselhos e por toda ajuda ao longo do curso, em especial ao Prof. Dr. Paulo Guilherme Molin, pela amizade, mentoria e profissionalismo no decorrer da orientação para o desenvolvimento deste trabalho e também ao Prof. Dr. Pedro Henrique Santin Brancalion pela colaboração contínua aportada na pesquisa a partir de sua fundamental coorientação, garantindo também a inclusão do trabalho no projeto temático FAPESP “Compreendendo florestas restauradas para o benefício das pessoas e da natureza – NewFor” (processo nº 2018/18416-2).

Ao Laboratório de Silvicultura Tropical (LASTROP) da ESALQ/USP e ao Centro de Pesquisa e Extensão em Geotecnologias da UFSCar Lagoa do Sino por garantir os equipamentos e infraestrutura necessária para o desenvolvimento da pesquisa. Aos membros e técnicos de cada laboratório, em especial à Maria Andréia Moreno por sempre disponibilizar sua ajuda em todos os momentos e também aos pós-doutorados do projeto NewFor Angélica F. de Resende, Danilo R. A. de Almeida, Catherine T. de Almeida e Pedro Krainovic, pela amizade e por toda ajuda ao longo da execução e revisão do trabalho.

À Mariana Andrade Alves da Silva por todo o suporte e por sempre me incentivar a ir cada vez mais longe.

Por fim, aos amigos e colegas da pós-graduação que de alguma forma contribuíram para a conclusão deste trabalho.

SUMÁRIO

RESUMO	5
ABSTRACT	6
LISTA DE FIGURAS	7
LISTA DE TABELAS	9
1. INTRODUÇÃO	11
1.1. Revisão bibliográfica.....	13
1.1.1. Cana-de-açúcar brasileira.....	13
1.1.2. Colheita da cana-de-açúcar	15
1.1.3. Legislação de proteção da vegetação nativa no Brasil.....	18
1.1.4. Restauração ecológica.....	21
1.1.5. Aprendizado de máquina e modelos de regressão	25
2. OBJETIVOS	31
2.1. Objetivo geral	31
2.2. Objetivos específicos.....	31
3. MATERIAIS E MÉTODOS	33
3.1. Localização e descrição da área de estudo	33
3.2. Metodologia.....	34
3.2.1. Dados geoespaciais	34
3.2.2. Segmentação da área de estudo em paisagens e amostragem.....	35
3.2.3. Delimitação e caracterização das Áreas de Linhas Curtas.....	36
3.2.4. Caracterização das paisagens	37
3.2.5. Análise estatística e modelagem de ALC para São Paulo	39
3.2.6. Cenários de redução de déficits de reserva legal restaurando ALC.....	41
4. RESULTADOS	43
4.1. Caracterização das paisagens e das ALC mapeadas	43
4.2. Modelagem.....	45
4.3. Contribuição em relação ao déficit de RL.....	54
5. DISCUSSÃO	59
5.1. Modelos e variáveis.....	59
5.2. Implicações para a restauração de ecossistemas	60
6. CONCLUSÃO	65
REFERÊNCIAS	67
APÊNDICE	77

RESUMO

Criando espaços para a restauração de ecossistemas por meio do aumento da eficiência operacional na colheita de cana-de-açúcar

A demanda pela restauração de ecossistemas vem crescendo no cenário global, visando à obtenção de diferentes tipos de benefícios ambientais e sociais, como a conservação da biodiversidade, a mitigação das mudanças climáticas e a proteção de mananciais. Contudo, a disponibilização de áreas para a restauração de ecossistemas nativos é dificultada pelo uso atual do solo pela agropecuária, sendo o aumento da eficiência produtiva de sistemas agropecuários uma oportunidade para liberação de áreas marginais para a restauração. Neste sentido, destaca-se como oportunidade o aumento da eficiência da colheita mecanizada da cana-de-açúcar no estado de São Paulo. O objetivo deste trabalho foi identificar áreas marginais da produção mecanizada de cana-de-açúcar, por meio da identificação de Áreas de Linhas Curtas (ALC), visando à expansão da restauração de ecossistemas nativos para tais regiões. As ALC são caracterizadas por linhas de plantio curtas e, neste projeto, foram considerados dois limiares mínimos: 50 e 100 metros. Assim, modelos estatísticos de regressão foram desenvolvidos a partir do uso de 6 algoritmos de aprendizado de máquina supervisionado para estimar as ALC em todo o estado. Estes modelos foram baseados em uma amostragem de 120 paisagens agrícolas de 25 km² ao longo do estado (de um total de 7.553 paisagens), nas quais as ALC foram manualmente mapeadas e foram exploradas variáveis explicativas que pudessem se correlacionar com a presença das ALC (declividade média; densidade de drenagem; percentual de cobertura de cana-de-açúcar; e métricas da paisagem aplicadas às manchas da cultura). Uma vez que as estimativas foram calculadas e espacializadas, a contribuição potencial da restauração de ecossistemas nativos nas ALC foi investigada no contexto de redução do Déficit de Reserva Legal considerando dois cenários de déficit dentro de cada paisagem. Os resultados mostraram o melhor desempenho dos modelos criados a partir do algoritmo Random Forest, para ajuste (treinamento) e validação dos dados, refletido pelo Coeficiente de Determinação (0,451 e 0,634), Erro Médio Absoluto (0,252 e 0,932) e a Raiz Quadrada do Erro Médio (0,323 e 1,195). Com esta abordagem, as estimativas de ALC para todo o estado foram de 174,19 km² para o limiar de 100 metros; e 39,78 km² para o limiar de 50 metros. O uso das ALC para redução do déficit de RL mostrou potencial para mitigar 100% do déficit em algumas paisagens (de 240 até 2.479 ao longo dos cenários propostos), mas de forma geral contribuiu para a mitigação de 0,43 a 4,83% da soma de déficit das paisagens estudadas, a depender do cenário considerado. Embora as ALC apresentem baixa contribuição direta para redução do déficit de RL, elas representam uma abordagem eficiente para identificação de regiões passíveis de restauração, que podem ainda ser abordadas no contexto de incentivos à compromissos voluntários; corroborando com os esforços, compromissos, políticas e projetos de restauração ecológica assumidos frente à década da restauração de ecossistemas.

Palavras-chave: Compensação ambiental, Restauração ecológica, Serviços ecossistêmicos, Ecologia da paisagem, Mecanização agrícola

ABSTRACT

Creating space for ecosystem restoration by increasing operational efficiency in sugarcane harvesting

The demand for ecosystem restoration has been growing globally, seeking to achieve different types of environmental and social benefits, such as biodiversity conservation, mitigation of climate change and the protection of water sources. However, the availability of areas for restoration of native ecosystems is hampered especially by agriculture. The efficiency increase of agricultural systems is an opportunity to free up marginal areas for restoration. In this way, improving the efficiency of sugarcane mechanized harvesting in the state of São Paulo stands out as such opportunity. The goal of this work was to identify marginal areas of mechanized sugarcane production, through the identification of Short Line Areas (SLA), aiming at expanding the restoration of native ecosystems to such regions. The SLA are characterized by short planting lines and in this project two minimum thresholds were considered: 50 and 100 meters. Thus, statistical regression models were developed using supervised machine learning algorithms to estimate statewide SLA. The models were based on a sampling of 120 agricultural landscapes of 25 km² throughout the state (total of 7,553), in which the SLA were manually mapped and explanatory variables that could be correlated with the presence of the SLA were explored (mean slope; drainage density; percentage of sugarcane cover, and landscape metrics applied to the crop fields). Once the estimates were calculated and spatialized, the potential contribution of the restoration of native ecosystems in SLA was investigated in the context of reducing the Legal Reserve Deficit (LRD). The results showed the best performance of the models created by the Random Forest algorithm, for data adjustment (training) and also testing. The performances were evaluated through metrics such as the Coefficient of Determination (0.451 and 0.634), Mean Absolute Error (0.252 e 0.932) and the Root Mean Squared Error (0.323 e 1.195). With this approach, estimates for the entire state were 174.19 km² of SLA considering the 100-meter threshold; and 39.78 km² for the 50-meter threshold. The use of SLA to reduce the LRD showed the potential to mitigate 100% of the deficit in some landscapes (from 240 up to 2,479 according to the scenario), but in general it contributes to mitigating from 0.43 up to 4.83% of the sum of LRD from the landscapes, depending on the scenario considered. Although the estimates of SLA were numerically low towards the direct contribution to minimize the LRD, they represent an efficient approach to identify regions susceptible to restoration, which can still be addressed in the context of incentives for voluntary commitments; corroborating the efforts, commitments, policies and projects of ecological restoration undertaken in face of ecosystem restoration's decade.

Keywords: Environmental compensation, Ecological restoration, Ecosystem services, Landscape ecology, Agricultural mechanization

LISTA DE FIGURAS

- Figura 1:** Uso da terra no estado de São Paulo com destaque para as classes de Floresta (vegetação nativa de fitofisionomia florestal), Vegetação nativa (demais fitofisionomias de vegetação nativa), Cana-de-Açúcar (área com plantio da cultura identificado) e Outros (demais classes de uso).....33
- Figura 2:** Fluxograma ilustrativo do procedimento metodológico da pesquisa abordando as entradas e saídas em quadrículas pretas; as operações em azul; e as sub operações em verde. As quadrículas destacadas pela linha vermelha pontilhada representam as operações que originaram o banco de dados utilizados para o procedimento de modelagem (pontilhado em rosa).34
- Figura 3:** Mapa da divisão do estado de São Paulo em paisagens de 25 km² categorizadas de acordo com o percentual de cobertura de cana-de-açúcar, provindo da coleção 5 do MapBiomas (2020).36
- Figura 4:** Exemplo de Áreas de Linhas Curtas (ALC) mapeadas por fotointerpretação em paisagem agrícola na bacia do rio Piracicaba. As linhas pontilhadas em preto representam exemplos de medições das linhas de plantio que se enquadram nos limiares propostos.37
- Figura 5:** Esquema ilustrativo da reamostragem dos valores de déficit RL fornecidos por Tavares et al. (2021). A sequência de A até D representa paisagens adjacentes; A linha vermelha denominada P representa o perímetro de uma propriedade rural fictícia enquanto A_P simboliza sua área; Os valores percentuais representam a fração de A_P contida em cada paisagem; DRL_P representa o déficit de reserva legal de P; $DRL_{Tavares}$ representa o valor do déficit de RL calculado para a propriedade P por Tavares et al. (2021); as equações representam o cálculo realizado para obtenção do valor proporcional de déficit RL para cada paisagem.42
- Figura 6:** Distribuição de frequência das paisagens amostradas de acordo com o total de ALC mapeados em cada uma, considerando o limiar de 50 metros.43
- Figura 7:** Distribuição de frequência das paisagens amostradas de acordo com o total de ALC mapeados em cada uma, considerando o limiar de 100 metros.44
- Figura 8:** Resultados da análise de proximidade (em metros) entre as Áreas de Linhas Curtas (ALC) mapeadas e as regiões de interesse (Áreas de Preservação Permanente, hidrografia e remanescentes de vegetação), contendo as médias das distâncias mínimas, médias e máximas para cada limiar (ALC 50m e ALC 100m).45
- Figura 9:** Comparativo dos modelos criados para o limiar de 50 metros (ALC 50m) a partir das métricas de avaliação propostas: Coeficiente de Determinação (R^2 - Rsquared), Erro Médio Absoluto (MAE) e Raiz do Erro Quadrático Médio (RMSE). Os círculos pretos representam a mediana; os retângulos azuis correspondem aos dois quartis centrais; as linhas azuis tracejadas indicam a amplitude (valores máximos e mínimos); e os círculos azuis representam os ‘outliers’46
- Figura 10:** Representação gráfica da importância de cada variável para o modelo criado pelo algoritmo Random Forest considerando o limiar de 50 metros (ALC 50m).47
- Figura 11:** Gráficos de dispersão ilustrando a correlação entre a variável resposta e as explicativas mais importantes para o modelo Random Forest considerando o limiar de 50 metros (ALC 50m). Em cada gráfico também é apresentada a equação de ajuste polinomial de grau 3 e o valor de R^2 relativo a cada ajuste.48

Figura 12: Comparativo dos modelos criados para o limiar de 100 metros (ALC 100m) a partir das métricas de avaliação propostas: Coeficiente de Determinação (R^2 - Rsquared), Erro Médio Absoluto (MAE) e Raiz do Erro Quadrático Médio (RMSE). Os círculos pretos representam a mediana; os retângulos azuis correspondem aos dois quartis centrais; as linhas azuis tracejadas indicam a amplitude (valores máximos e mínimos); e os círculos azuis representam os 'outliers'.	49
Figura 13: Representação gráfica da importância de cada variável para o modelo criado pelo algoritmo Random Forest considerando o limiar de 100 metros (ALC 100m).	50
Figura 14: Gráficos de dispersão ilustrando a correlação entre a variável resposta e as explicativas mais importantes para o modelo Random Forest considerando o limiar de 100 metros (ALC 100m). Em cada gráfico também é apresentada a equação de ajuste polinomial de grau 3 e o valor de R^2 relativo a tal ajustamento.	51
Figura 15: Estimativas de ALC para o estado de São Paulo considerando todos os modelos desenvolvidos e os limiares de 50 e 100 metros.	53
Figura 16: Distribuição espacial das estimativas de ALC de acordo com o modelo Random Forest considerando o limiar de 50 metros (ALC 50m).	53
Figura 17: Distribuição espacial das estimativas de ALC de acordo com o modelo Random Forest considerando o limiar de 100 metros (ALC 100m).	54
Figura 18: Histograma ilustrando o número de paisagens presentes em cada intervalo do percentual de mitigação do déficit de RL para o cenário 1.	55
Figura 19: Histograma ilustrando o número de paisagens presentes em cada intervalo do percentual de mitigação do déficit de RL para o cenário 2.	56
Figura 20: Histograma ilustrando o número de paisagens presentes em cada intervalo do percentual de mitigação do déficit de RL para o cenário 3.	56
Figura 21: Histograma ilustrando o número de paisagens presentes em cada intervalo do percentual de mitigação do déficit de RL para o cenário 4.	57
Figura 22: Gráficos de dispersão ilustrando a correlação entre a variável resposta e as explicativas mais importantes para o modelo Random Forest considerando o limiar de 50 metros (ALC 50m). Em cada gráfico também é apresentada a equação de ajuste polinomial de grau 3 e o valor de R^2 relativo a tal ajustamento.	78
Figura 23: Gráficos de dispersão ilustrando a correlação entre a variável resposta e as explicativas mais importantes para o modelo Random Forest considerando o limiar de 100 metros (ALC 100m). Em cada gráfico também é apresentada a equação de ajuste polinomial de grau 3 e o valor de R^2 relativo a tal ajustamento.	79
Figura 24: Distribuição espacial das estimativas de Áreas de Linhas Curtas (ALC) provenientes do modelo Random Forest considerando o limiar de 50 metros.	80
Figura 25: Distribuição espacial das estimativas de Áreas de Linhas Curtas (ALC) provenientes do modelo Random Forest considerando o limiar de 100 metros.	81
Figura 26: Distribuição das paisagens com maiores valores estimados de ALC 50 m em relação às variáveis de maior importância para o modelo.	82
Figura 27: Distribuição das paisagens com maiores valores estimados de ALC 100 m em relação às variáveis de maior importância para o modelo.	83

LISTA DE TABELAS

Tabela 1: Valores mínimos, médios e máximos de ALC mapeadas ao longo das 120 paisagens amostradas.....	43
Tabela 2: Valores da Correlação de Pearson calculados para as variáveis de maior importância para o modelo Random Forest considerando o limiar de 50 metros (ALC 50m).	47
Tabela 3: Valores de erro calculados para as previsões de cada modelo considerando o limiar de 50 metros (ALC 50m).	49
Tabela 4: Valores da Correlação de Pearson calculados para as variáveis de maior importância para o modelo Random Forest considerando o limiar de 100 metros (ALC 100m).	51
Tabela 5: Valores de erro calculados para as previsões de cada modelo considerando o limiar de 100 metros (ALC 100m).	52
Tabela 6: Panorama geral de contribuição das ALC para mitigação do déficit de RL estadual, em paisagens contendo cana-de-açúcar a partir dos limiares de 50 e 100 metros (ALC 50m e ALC 100m).	54
Tabela 7: Relação do número de paisagens com potencial de mitigação total do déficit de RL e mensuração do excedente de ALC considerando cada cenário proposto.	55
Tabela 8: Valores das métricas de avaliação para cada modelo – ALC 50 metros.	77
Tabela 9: Valores das métricas de avaliação para cada modelo – ALC 100 metros.	77
Tabela 10: Síntese da relação de maior distribuição das paisagens de acordo com cada variável mais importante para os modelos.....	84
Tabela 11: Características das paisagens amostradas de acordo com as variáveis utilizadas na pesquisa. Esta tabela também representa o banco de dados utilizado durante a etapa de modelagem.....	85
Tabela 12: Resultados da análise de proximidade (em metros) entre as Áreas de Linhas Curtas do limiar de 50 metros (ALC 50m) e as regiões de APP, hidrografia e vegetação nativa individualmente para cada paisagem amostrada.	90
Tabela 13: Resultados da análise de proximidade (em metros) entre as Áreas de Linhas Curtas do limiar de 50 metros (ALC 50m) e as regiões de APP, hidrografia e vegetação nativa individualmente para cada paisagem amostrada.	95

1. INTRODUÇÃO

A restauração ecológica emergiu nos últimos trinta anos como uma alternativa para conciliar bem-estar social e conservação da biodiversidade. Após uma grande etapa de pesquisa científica e comprovações experimentais, a restauração ecológica passou a ser considerada prioridade para alcançar o desenvolvimento sustentável mundial. Com isso, profissionais, ecologistas de restauração e políticos devem estar preparados para novas abordagens para planejar, incentivar e executar programas de restauração. A demanda pela restauração de ecossistemas vem sendo muito discutida nacional e internacionalmente. Nota-se um número crescente programas e iniciativas mundiais, nacionais e regionais em prol da restauração de ecossistemas, como por exemplo o Bonn Challenge (350 milhões de hectares no mundo até 2030) e o programa Restaura Brasil (1 bilhão de árvores no Brasil até 2030). Não obstante, a ONU declarou o início da década da restauração ecológica em 2021 com fim em 2030. No Brasil, a Lei de Proteção à Vegetação Nativa (LPVN – Lei Federal 12.651/2012) com a instituição do Cadastro Ambiental Rural (CAR) e o Programa de Regularização Ambiental (PRA), tem intensificado a demanda por restauração dos passivos nas propriedades rurais em Áreas de Preservação Permanente (APP) e Reservas Legais (RL), acenando para um mercado emergente baseado em Cotas de Reserva Ambiental (CRA) (METZGER e BRANCALION, 2013; BRANCALION et al., 2016).

As florestas possuem influência sobre processos básicos para a sobrevivência de indivíduos da fauna e flora envolvendo conceitos de ecologia de ecossistemas. Como parte da paisagem, as florestas contribuem com diversas inter-relações bióticas relacionadas ao espaço, assim, a ecologia de paisagens é definida como a ciência que estuda as os processos ecológicos relacionando-os ao ambiente (paisagem) de um ecossistema específico (TROLL, 1971). Não obstante, a combinação de aspectos socioeconômicos e ecológicos diante do caráter espacial de um objeto, compõe a ciência multidisciplinar denominada de ecologia da paisagem (CRAWSHAW et al., 2007). A ecologia de paisagem possui relação direta com processos e estruturas tanto ecológicas quanto espaciais e, por essa razão, existem métodos capazes de quantificar e descrever a estrutura de uma paisagem. Tais métodos fazem uso das métricas da paisagem, que podem ser utilizadas para descrever e medir a paisagem em parcelas ou em sua totalidade (ARROYO-RODRIGUES et al., 2020; BATISTA, 2014;). As métricas de paisagem podem ser utilizadas para quantificar e caracterizar a estrutura de uma paisagem e relacioná-la com processos ecológicos e, nesta perspectiva, a utilização das métricas pode ser considerada

como método para avaliar serviços ecossistêmicos a nível de paisagem (SYRBE & WALZ, 2012).

O conceito de serviços ecossistêmicos começou a ser discutido na literatura acadêmica como “serviços da natureza” na década de 1970. A grande mudança nos estudos ocorreu na segunda metade do século XX quando a perda de tais serviços passou a ser mais evidente com a exploração de capital natural e, em paralelo, o entendimento sobre a ecologia de ecossistemas foi aprofundado. Os serviços ecossistêmicos, por definição, são interpretados como os benefícios (perceptíveis ou não) proporcionados pelos ecossistemas aos seres humanos. As conexões que relacionam funções e processos ecossistêmicos com os benefícios proporcionados são complexas e dinâmicas, envolvendo interações entre o capital natural, social, construído e humano. Neste sentido, os serviços ecossistêmicos são divididos em quatro amplas categorias: serviços de provisão, regulação, culturais e de suporte (CONSTANZA et al., 2017; CONSTANZA et al., 1997; MEA, 2005).

As modificações no uso e ocupação do solo, em especial no setor agropecuário, têm se destacado como fator de fragmentação dos remanescentes de vegetação nativa, justificados principalmente por razões econômicas e expansões características das dinâmicas do setor agrícola e pecuário. No fim da década de 1980, os preços internacionais de açúcar aumentaram e proporcionaram uma mudança na cadeia produtiva agrícola brasileira que priorizou a produção de açúcar para exportação. No Brasil, o cultivo de cana-de-açúcar atualmente ocupa 10.063.739 hectares, representado por duas principais regiões produtoras: Centro-Sul (estados das regiões Centro-Oeste, Sudeste e Sul) e Norte-Nordeste (estados das regiões Norte e Nordeste). Neste cenário, o estado de São Paulo apresenta a maior área plantada (5.555.502 ha), seguido por Goiás (948.091 ha) e Minas Gerais (921.870 ha), tais valores equivalem respectivamente, a 55,2%, 9,4% e 9,2% da área plantada nacional (BARBOSA et al., 2020; LYRA, 2012; UNICA, 2018).

Incentivado por questões econômicas e ambientais, a colheita mecanizada de cana-de-açúcar foi implementada no Brasil de maneira gradual e com a redução da prática de queima da palha. No estado de São Paulo, a mecanização é regida pela Lei estadual nº 11.241/2002 e, em decorrência de acordos entre as usinas e o governo do estado, a queima da palha chegou ao fim em 2018. O processo de mecanização da colheita de cana-de-açúcar representa de 30% a 35% do custo total da produção, além de envolver impactos sociais de desemprego e necessidade de mão-de-obra especializada para condução de maquinários. Além disso, sistemas mecanizados podem resultar no aumento do índice de impurezas e perdas em campo. Por outro lado, a mecanização (parcial ou total) da colheita da cana-de-açúcar é, atualmente, a única opção

considerando-se questões econômicas, ergonômicas e, especialmente, legais e ambientais (LYRA, 2012; BRAUNBECK & MAGALHÃES, 1999).

Durante a colheita mecanizada, existem fatores práticos que interferem diretamente no custo do processo em relação ao consumo de combustível, tais como formato dos talhões de plantio; obstáculos (terraços para contenção de erosão); espaço ocupado por estradas; e manobras realizadas com o maquinário. Estudos específicos do processo de cultivo da cana-de-açúcar estimaram o custo energético e financeiro da colheita de linhas de plantio, e concluíram que é necessário um comprimento mínimo de 50 metros para que a produção seja capaz de custear as manobras de maquinário exigidas pela colheita (COELHO, 2009; SPEKKEN, MOLIN e ROMANELLI, 2014). Considerando tal comprimento, é possível analisar propriedades rurais e localizar as linhas de colheita onde o cultivo é caracterizado como financeiramente inviável. Portanto, o conjunto de tais linhas de cultivo constituem as regiões aqui denominadas como Áreas de Linhas Curtas (ALC), onde constata-se a oportunidade de atribuir um novo uso para a terra, economicamente e ambientalmente viável.

Apenas no estado de São Paulo, há registro de mais de 19.000 Km² de déficit de vegetação nativa, sendo 9.410 Km² referentes a APP e 9.658 Km² de RL (TAVARES et al., 2019). O estudo para destinação adequada de áreas agropecuárias improdutivas se mostra necessário em função de sua presença em grande parte do território nacional (SPAROVEK et al., 2011). A destinação de áreas improdutivas ou economicamente inviáveis para restauração ecológica, pode gerar retornos econômico-ambientais e promover adequação das propriedades às restrições legais. Diante deste cenário, justifica-se estimar as ALC em paisagens de cultivo de cana-de-açúcar em todo o estado de São Paulo, em uma perspectiva de potencial para incremento de cobertura florestal nativa; avaliar a relevância dos resultados no contexto de contribuição às políticas públicas e possível consolidação como programa de restauração ecológica; além de mensurar o potencial de mitigação do déficit de RL.

1.1. Revisão bibliográfica

1.1.1. Cana-de-açúcar brasileira

Em meados do século XV, o valor econômico do açúcar era extremamente alto no continente europeu uma vez que a produção existente não era suficiente para suprir a demanda do produto. Dessa forma, o cultivo da cana-de-açúcar passou a se mostrar de alta rentabilidade, mas incompatível com o clima europeu (LYRA, 2012). Entre os anos de 1530 e 1540, o cultivo da cana-de-açúcar foi estabelecido no Brasil por iniciativa da metrópole portuguesa com o

objetivo de quebrar o monopólio do Oriente Médio de comercialização de açúcar. O cultivo no Brasil Colônia foi inicialmente realizado na região nordeste do território com mão-de-obra indígena local, a qual foi posteriormente substituída por mão-de-obra escrava africana (BRAIBANTE et al., 2013).

Durante o século XIX, após o denominado Ciclo da Cana-de-açúcar, a produção brasileira caiu e passou a representar 8% da produção mundial. Este fenômeno foi observado pois o cultivo da cana-de-açúcar passou a ser realizado em outros países de clima propício. Nesta mesma época, a Europa passou a produzir açúcar a partir da beterraba, o que também contribuiu para a diminuição da dependência europeia do açúcar brasileiro. Dessa forma, o Brasil iniciou o investimento na produção de álcool combustível a partir da cana-de-açúcar, buscando uma nova aplicação para a cultura (CARVALHO et al., 2013). Apenas no século XX com o fim do Ciclo do Café, a produção voltou a crescer no país com investimentos em cultivo no estado de São Paulo e Rio de Janeiro (LYRA, 2012).

Durante a década de 1970, frente à crise do petróleo, o governo federal brasileiro iniciou o programa PROÁLCOOL a fim de substituir a gasolina por etanol e reduzir a dependência energética nacional de fontes externas. Para isso, a matéria prima escolhida foi a cana-de-açúcar e, por essa razão, inúmeros estudos sobre a cultura e seu método de processamento foram desenvolvidos, proporcionando cada vez mais a segurança energética brasileira (GONÇALVES et al., 2011). A primeira fase do programa, que ocorreu entre 1975 e 1979, se caracterizou pela produção de etanol anidro para compor a gasolina comercializada nos postos de abastecimento. Já na segunda fase (a partir de 1979), a prioridade passou a ser a produção de etanol hidratado para utilização direta em veículos com motores adaptados para este combustível. Com o passar dos anos, o surgimento de automóveis com motores flex incentivou o consumo interno do etanol uma vez que tal diversificação para abastecimento foi consolidada (KLEIN et al., 2019).

O PROÁLCOOL foi de extrema importância para a economia nacional, pois criou um mercado para o etanol que, juntamente da demanda externa por açúcar, permitiu o crescimento do setor sucroalcooleiro. Porém, os financiamentos proporcionados pelo programa foram praticamente extinguidos no fim da década de 1980, ao mesmo tempo em que os preços internacionais de açúcar aumentaram, proporcionando uma mudança na cadeia produtiva que priorizou a produção de açúcar para exportação. Em 2009 ocorreu uma diminuição na atividade produtiva da cana-de-açúcar como consequência da crise de 2008, porém apesar deste impacto no setor sucroalcooleiro, projeções embasadas na crescente demanda internacional por combustíveis renováveis acenam que o Brasil representará cerca de 28% da produção global de etanol entre 2020 e 2030 (ALKIMIM, SPAROVEK e CLARKE, 2015). Hoje, o Brasil é o

segundo maior produtor mundial de etanol, perdendo apenas para os Estados Unidos, cuja produção é vinculada à cultura do milho (LYRA, 2012).

Segundo Klein et al. (2019), as usinas de cana-de-açúcar podem ser classificadas em três grupos de acordo com sua produção. As destilarias autônomas são caracterizadas pela produção exclusiva de etanol; enquanto as fábricas de açúcar se restringem a produção apenas de açúcar. Por fim, as fábricas de açúcar com destilarias anexas são capazes de realizar tanto a produção de açúcar quanto de etanol. De forma geral, o processamento da cana-de-açúcar pode originar diversos produtos e subprodutos, tais como açúcar, etanol (anidro ou hidratado), fertilizantes (torta de filtro, cinzas do bagaço, vinhaça/vinhoto) e energia elétrica (queima do bagaço, palha e/ou biogás). Pesquisadores têm trabalhado no âmbito da produção e processamento de cana-de-açúcar visando otimização e diversificação de produtos e subprodutos (KLEIN et al., 2019; BORDONAL et al., 2018; SARKER et al., 2016; SINDHU et al., 2016;), contribuindo econômica e ambientalmente para a cadeia produtiva.

Em termos produtivos, o Brasil possui mais de 10 milhões de hectares de área plantada de cana-de-açúcar, distribuídas em duas regiões principais: Centro-Sul (estados das regiões Centro-Oeste, Sudeste e Sul) e Norte-Nordeste (estados das regiões Norte e Nordeste). O estado de São Paulo apresenta a maior área plantada com 5.555.502 ha, seguido por Goiás com 948.091 ha e Minas Gerais com 921.870 ha, tais valores equivalem respectivamente, a 55,2%, 9,4% e 9,2% da área plantada nacional. Comparativamente, em 1980 o Brasil contava com área plantada equivalente a pouco mais de 2,5 milhões de hectares, valor quase quatro vezes menor ao observado atualmente. Como o maior produtor mundial de cana-de-açúcar, o Brasil registrou a produção de mais de 654,5 milhões de toneladas da cultura durante a safra de 2020/2021, resultando em 41,2 milhões de toneladas de açúcar e 29,7 bilhões de litros de etanol (LYRA, 2012; UNICA, 2018; CONAB, 2021).

1.1.2. Colheita da cana-de-açúcar

O processo de colheita da cana-de-açúcar envolve desde seu corte até o transporte para as usinas. Até a década de 1950, tal processo era realizado manualmente e sem a queima dos talhões de cultivo, porém com a criação de maquinário para transporte da cana, a prática da queima passou a ser realizada para otimizar o processo de corte manual (LYRA, 2012). De acordo com Ripoli (1996), existem três sistemas utilizados para a colheita de cana-de-açúcar no Brasil, sendo eles o manual, semimecanizado e mecanizado. A colheita manual é caracterizada por não utilizar maquinário para ser realizada, e foi muito utilizada na região

nordeste do país. A colheita semimecanizada foi amplamente utilizada e consiste no corte manual (juntamente da queima dos canaviais) e transporte realizado por maquinários. Já o sistema mecanizado consiste no corte e carregamento realizado por maquinário especializado. No Brasil, a colheita mecanizada foi adotada inicialmente na região sudeste por volta de 1995 e hoje cerca de 95% da colheita na região é realizada de forma mecanizada. A adoção da mecanização nas demais regiões do país ocorreu entre 2004 e 2006, alcançando hoje patamares de mecanização da colheita entre 85% e 95%. A região nordeste é a única onde a mecanização encontra-se ainda em patamares baixos, beirando 20% da colheita (CONAB, 2019).

A capacidade de colheita manual por homem medida entre os anos de 1990 a 2000 foi equivalente a 12 toneladas de cana-de-açúcar por dia. Em contrapartida, a capacidade efetiva média observada para uma máquina colhedora é de 750 toneladas por dia, alcançando valores entre 1000 e 1200 toneladas em alguns casos. Dessa forma, nota-se o expressivo aumento de capacidade de colheita gerado pela mecanização e, além disso, a mecanização requer menos mão-de-obra e não necessita da queima dos canaviais, proporcionando reduções com despesas trabalhistas e menor passivo ambiental (SCHMIDT JUNIOR, 2011).

Um dos fatores que impulsionaram a mecanização da colheita da cana-de-açúcar no Brasil foi a escassez de mão-de-obra que ocorreu na década de 1960, o que ocasionou a busca por novos métodos para executar a atividade (SCHMIDT JUNIOR, 2011). Além disso, Lyra (2012) afirma que as empresas do setor sucroalcooleiro foram cada vez mais buscando a mecanização de seus processos de colheita, uma vez que já existiam prazos definidos por lei para a proibição das queimadas dos canaviais. No estado de São Paulo, a Lei estadual nº 11.241/2002 estipulava o fim das queimadas em áreas mecanizáveis (áreas com declividades de até 12%) para o ano de 2021 e para as não-mecanizáveis para o ano de 2031; contudo, a proibição foi antecipada para 2018 em função de liminares de justiça e também de acordos entre as usinas e o governo do estado. Neste contexto, Dias Neto et al. (2022) aponta que o índice de mecanização da colheita da cana-de-açúcar em São Paulo cresceu de 47,6% na safra de 2008/09 para 98,6% na safra 2020/2021.

A mecanização da colheita representa um aumento no custo da produção da cultura da cana-de-açúcar. Entre diversos fatores, o consumo de combustível por parte das colheitadeiras é o principal responsável por tal aumento, consumindo de 50 a 60 L/h. Como a média de consumo de combustível por uma colheitadeira é de 60 L por hectare de cana-de-açúcar, considerando a colheita de 10 hectares e o preço atual do diesel de R\$6,70, o gasto diário com óleo diesel é de aproximadamente R\$4.020,00 (LYRA, 2012). Assim, Spekken, Molin e Romanelli (2014) discutem que a eficiência do maquinário para colheita de cana-de-açúcar é

avaliada por tempo de operação. Fatores como tempo gasto com carga e descarga de materiais e da própria cultura, e também as manobras realizadas com o maquinário ao fim das linhas de colheita são diretamente responsáveis pela eficiência do processo. Contudo, Braunbeck e Magalhães (1999) indicaram que a mecanização (parcial ou total) da colheita da cana-de-açúcar é a única opção que pondera questões econômicas, ergonômicas e, especialmente, legais e ambientais, já que tal método possibilita que a colheita seja realizada sem necessidade de queima, garantindo também o aproveitamento da palha.

É evidente que a colheita mecanizada evita a emissão de grandes quantidades de Gases de Efeito Estufa (GEE) na atmosfera uma vez que não carecem da queima dos canaviais; além disso, este tipo de colheita ocasiona o depósito da palhada da cana na superfície do solo, evitando processos erosivos e contribuindo para fertilidade e acúmulo de matéria orgânica no solo (DIAS NETO et al., 2022). Corroborando com tais afirmações, Martins Filho et al. (2009) indicou que a deposição de 50% e 100% da palha da cana no solo pode reduzir os processos erosivos em 68% e 89%, respectivamente. Com a transição da colheita por queima para a mecanizada, Capaz et al. (2013) mostrou a redução de 39,3% nas emissões de GEE relacionadas ao ciclo produtivo do etanol em São Paulo entre 1990 e 2009. Não obstante, Galdos et al. (2013) apontou que, em decorrência da mecanização, a melhor gestão da colheita proporcionou uma melhoria de 90% em impactos à saúde humana; os autores também fizeram estimativas de que a contribuição potencial da atividade ao aquecimento global seria reduzida em 70% com a mecanização total do processo.

Recentemente, estudos têm se aprofundado na temática da colheita da cana-de-açúcar buscando otimizações do processo e reduções de custo, utilizando técnicas matemáticas e computacionais embasadas por algoritmos de inteligência artificial e aprendizado de máquina. Junqueira e Morabito (2017) indicaram que a colheita e o transporte da cana para as usinas são etapas que compõem um complexo sistema logístico que determina a regularidade e a qualidade da matéria prima que entrará na cadeia produtiva; sendo assim, os autores buscaram uma abordagem de modelagem matemática para apoiar as decisões referentes a sequenciamento e programação das frentes de colheita. Não obstante, Santoro, Soler e Cherri (2017) buscaram uma solução para otimizar as rotas de colheita da cultura embasados também por um modelo matemático que minimiza o tempo de manobra do maquinário, reduzindo conseqüentemente os custos com combustível e mão-de-obra. Ainda no mesmo contexto, porém com uma abordagem mais genérica, Conesa-Muñoz et al. (2016) discutem o planejamento de rotas de colheita para mecanização automatizada e utilizam algoritmos meta-heurísticos de aprendizado de máquina

para criação de um modelo de otimização. A mesma linha de pesquisa pode ser observada no trabalho de Seyyedhasani e Dvorak (2017), que fazem uso de algoritmos heurísticos e meta-heurísticos.

Todos estes trabalhos têm em comum objetivos de otimizar as linhas de plantio e colheita, reduzindo os custos relacionados à colheita mecanizada, e conseqüentemente redesenhando talhões. Contudo, mesmo com modelos sofisticados, a topografia e limitações de perímetros criam regiões onde a otimização atinge seu limite e um conjunto marginal de linhas curtas de cultivo são inevitáveis. Em paralelo, a legislação ambiental brasileira estabelece áreas de proteção e conservação da vegetação nativa através das APP e RL em propriedades rurais. A presença de remanescentes florestais nessas regiões molda o formato dos talhões de cana-de-açúcar, o que contribui também para formação de regiões onde o cultivo pode ser economicamente inviável (SPEKKEN et al., 2016).

1.1.3. Legislação de proteção da vegetação nativa no Brasil

A regulação legal da vegetação nativa e dos recursos florestais no Brasil passou por diversas modificações com o passar dos anos. O primeiro marco legal estabelecido foi o decreto federal nº 23.793 de 1934, que instituiu o primeiro código florestal com o objetivo de criar minimamente um controle sobre as expansões agrícolas (café, cana-de-açúcar e cacau) mediante a ocupação e desmatamento de áreas de vegetação nativa. Com o crescimento e avanço econômico brasileiro, em 1965 foi criada em âmbito federal a Lei nº 4.471 que estabeleceu um novo código florestal mais objetivo e também mais restritivo, com claras definições e aplicações para conservação de áreas de vegetação nativa em propriedades rurais; este novo código estabeleceu por exemplo a localização e dimensão das APP. Com o passar dos anos, ocorreram diversas modificações no código através de mecanismos legais e também surgiram outras leis ambientais que contribuíram com a implementação do código, tais como o Código das Águas (decreto nº 24.643/1934 – substituído em 1997 pela Política Nacional de Recursos Hídricos), a Política Nacional de Meio Ambiente (Lei nº 6.938/1981) e a Lei de Crimes Ambientais (Lei nº 9.605/1998). Além disso, a própria Constituição Federal de 1988 garante em seu artigo 225 o direito a um ambiente equilibrado sujeito normas de proteção e restauração estabelecidas por autoridades públicas (PARRAS et al., 2020; BRANCALION et al., 2016; BROCK, ARNELL e SIMONSON, 2021).

O código florestal de 1965 se tornou uma lei ambiental, por assim dizer, na década de 90 através de diversos decretos presidenciais. Em meados de 2001, o código florestal passou a exigir (Medida Provisória nº 2166/2001) a conservação de vegetação nativa em propriedades

rurais privadas através da RL, uma porção da propriedade de tamanho definido segundo o bioma local, que deve ser mantida com vegetação nativa ou ser objeto de restauração ecológica. Além disso, o código passou por diversas alterações nos anos 1980 e 1990, que detalharam e ampliaram a delimitação das Áreas de Preservação Permanente. Tais áreas podem ser definidas como áreas especialmente protegidas, com restrições de uso e definidas em locais sensíveis do ponto de vista geotécnico ou ambiental, com o propósito de prevenir erosão do solo, conservar a biodiversidade e os recursos hídricos. Este arcabouço legal complexo enfrentou dificuldades de implementação prática nos diversos biomas brasileiros, em especial na região amazônica, e com o aumento da taxa de desmatamento por volta do ano 2000, os esforços para implementação na região foram vistos como contrários à produção agropecuária, fato este que agregou aspectos negativos à legislação. Assim, diante do cenário político da época, o setor agropecuário propôs a criação de um novo código florestal, que veio a ser aprovado em 2012 (SOARES-FILHO et. al, 2014; BRANCALION et al., 2016).

Após um recente período de revisão, a legislação que regula o uso da vegetação nativa em propriedades privadas no Brasil foi alterada, a partir da publicação da Lei de Proteção da Vegetação Nativa – LPVN (Lei nº 12.651) no ano de 2012. Em geral, a LPVN manteve as principais características da Lei 4.771/1965 no que se refere à proteção das florestas e da vegetação nativa em imóveis rurais, e manteve os conceitos fundamentais de APP e RL (ZAKIA; PINTO, 2014), embora com alterações na forma de delimitação de algumas categorias de APPs hídricas e de topo de morro (BRASIL, 2012). Brancalion et al. (2016) explicam que a LPVN é popularmente conhecida e mencionada como “Novo Código Florestal”, mas que não se trata de um código (conjunto de instrumentos legais específicos para uma temática jurídica) e também não possui características exclusivamente florestais; na realidade, a legislação é ampla e abrange todas as formações vegetais nativas brasileiras (formações naturais não florestais).

Uma das principais inovações da LPVN em relação a sua antecessora foi o estabelecimento do Cadastro Ambiental Rural (CAR) para a totalidade dos imóveis rurais brasileiros. O CAR é um registro eletrônico obrigatório da propriedade ou posse rural, que envolve a delimitação dos limites do imóvel e dos atributos florestais, tais como fragmentos de vegetação nativa, APPs, indicação da RL, entre outros (BRASIL, 2012). A partir das informações declaradas no CAR o proprietário rural poderá requerer a regularização ambiental da propriedade, o que envolve a instituição e restauração da Reserva Legal e das APPs. Neste momento, a regularização ambiental poderá ocorrer no âmbito do Programa de Regularização

Ambiental (PRA), conjunto de disposições previstas no capítulo XIII da LPVN, e que estabelecem uma série de flexibilizações na instituição de RL e restauração de APPs, associadas ao tamanho das propriedades rurais (BRASIL, 2012; GAVIOLI et al., 2020). Tais flexibilizações, por seu turno, são associadas a comprovação de uso rural consolidado (áreas da propriedade onde a prática de atividade agrossilvipastoril já vem sendo realizada de forma contínua) em APP e/ou RL antes de 22 de julho de 2008. Em havendo uso rural consolidado na propriedade, e caso o proprietário tenha aderido ao PRA, a regularização do imóvel se beneficia das regras de adequação transitórias, que se concretizam por exemplo na dispensa da restauração de RL em propriedades menores a 4 módulos fiscais; na possibilidade de manter o uso rural consolidado em APPs, com contrapartida de restauração de parte da APP em variável conforme o tamanho da propriedade; e também na possibilidade de contabilizar áreas de APP regularizadas ou em restauração como parte da RL (ZAKIA; PINTO, 2014; BRANCALION et al., 2016).

Diante do estabelecido pela LPVN, Tavares et al. (2021) estimaram o déficit de LR do estado de São Paulo em 2 cenários. No primeiro, os autores desconsideraram os possíveis efeitos de anistia decorrentes do Art. 68 da Lei; e no segundo, consideraram a possível anistia adotando os marcos legais de 1934, 1965 e 1989. De forma geral, o Art. 68 da lei possibilita o perdão do uso econômico de áreas protegidas desde que tal exploração tenha ocorrido antes do marco legal que define tais regiões. Sendo assim, a estimativa para o primeiro cenário foi de 865.000 hectares, e para o segundo foi observada uma redução drástica, atingindo o valor de 358.000 hectares. Existem diversos fatores que contribuem para a inadequação quanto à RL da perspectiva dos produtores rurais, entre eles está o percentual exigido para conservação que é definido de acordo com o bioma local. Ou seja, este fator gera um conflito direto com a quantidade de área rural produtiva. Em outras palavras, muitos proprietários rurais afirmam que as áreas improdutivas de suas propriedades não são suficientes para contabilizar totalmente a RL e APP exigidas por lei, criando um conflito de destinação de áreas para compensação principalmente da RL (PACHECO et al., 2017). Neste contexto, Soares-filho et al. (2014) indica que a utilização de Cotas de Reserva Ambiental (CRA) – áreas com vegetação que excedam o exigido por lei – como medida compensatória pode reduzir em até 56% o déficit de RL. O processo consiste em cadastrar, no CAR, o excesso de vegetação de uma propriedade como cota compensatória de outra em déficit. Assim, as CRA podem criar um novo mercado pois passam a agregar valor monetário às parcelas de vegetação nativa, tornando também a prática da restauração ecológica mais atrativa.

1.1.4. Restauração ecológica

A degradação e o desmatamento de florestas no Brasil se iniciaram há mais de 500 anos afetando inicialmente o bioma da mata atlântica e comprometendo grande parte da biodiversidade nela contida. Com o passar do tempo, iniciativas como a restauração ecológica surgiram com o objetivo de amenizar os impactos antrópicos nos ecossistemas (RODRIGUES et al., 2009; FAO, 2005). A restauração ecológica então emergiu nos últimos trinta anos como uma alternativa para conciliar bem-estar social e conservação da biodiversidade, e o estudo de tais práticas compõem a ciência da Ecologia da Restauração (METZGER e BRANCALION, 2013). Nesta perspectiva, deve-se considerar que esta prática pode ser abordada em referência a qualquer tipo ecossistema, e para o caso das florestas tropicais é comum a utilização do termo Restauração Florestal. Outro conceito intrínseco a esta ciência é o de sucessão ecológica, caracterizado como a regeneração e recomposição natural de um ecossistema degradado. Assim, a restauração florestal pode ser definida como a intervenção antrópica proposital em ecossistemas florestais degradados visando facilitar ou ocasionar o processo de sucessão ecológica (BRANCALION, GANDOLFI e RODRIGUES, 2015). Ou de maneira mais simplificada, a restauração florestal consiste em práticas que auxiliam a recuperação de um ecossistema que foi degradado, danificado ou destruído (SER, 2004).

Em seu estudo, Rodrigues et al. (2009) abordam os avanços e evoluções observados no processo de restauração florestal ao longo dos anos utilizando uma divisão em cinco fases. A primeira e mais simplista fase contempla os primeiros projetos de restauração realizados entre 1862 e 1982, com objetivo de proteger e garantir recursos naturais para uso antrópico. Nesta fase, os processos ecológicos eram ignorados e as florestas perpetuadas exigiam longas atividades de manejo e altos custos. A segunda fase, que corresponde ao período de 1982 a 1985, foi caracterizada pelo início da incorporação de conhecimentos ecológicos nos projetos. Porém, com a motivação principal de recriar a estrutura florestal, poucas espécies secundárias e tardias eram adotadas, resultando em florestas sem capacidade de perpetuação. A terceira fase abrange o período entre 1985 e 2000, no qual os projetos executados visavam copiar um ecossistema florestal maduro utilizado como referência. Por essa razão, esta fase foi marcada por florestas que se perpetuaram devido ao aumento da diversidade de espécies utilizadas. A penúltima fase, relativamente curta (2000 a 2003), foi marcada pela mudança de objetivo dos projetos, que agora passavam a buscar o restabelecimento dos processos ecológicos básicos da floresta. Com esta mudança, os projetos consideravam ainda grande diversidade de espécies que, juntamente dos processos ecológicos, garantiam a perpetuação da floresta. Finalmente, a

quinta fase corresponde aos esforços que buscamos até hoje em garantir diversidade genética às florestas restauradas. Assim, nota-se a crescente preocupação com a origem das sementes e mudas utilizadas nos projetos.

Conforme mencionado anteriormente, a sucessão ecológica consiste na substituição gradativa de espécies vegetais com características pioneiras por aquelas que compõem os estados finais de desenvolvimento florestal (secundárias e clímax). Essa dinâmica pode ocorrer em situações onde um novo habitat florestal se perpetuou (sucessão primária), ou a partir de um distúrbio que resulta na remoção parcial ou total da vegetação florestal (sucessão secundária), levando por exemplo à formação de clareiras (CHAZDON, 2014; CHAZDON et al., 2020; RODRIGUES et al., 2009). A divisão do processo de sucessão em estágios permite a condução de estudos comparativos e a investigação de processos ecológicos que resultam nas transições de estrutura, composição e propriedades ecossistêmicas das diferentes fases (CHAZDON, 2008). Em estudos abordando florestas tropicais úmidas, Budowski (1965) discute quatro estágios de sucessão nomeados de acordo com as características vegetais predominantes e divididos com base no tempo após distúrbio na floresta: pioneiras, secundárias iniciais, secundárias tardias; e clímax.

O estágio das pioneiras ocorre nos primeiros anos após um distúrbio ou início da revegetação. Neste estágio, é possível observar o domínio de poucas espécies com crescimento rápido e intolerantes ao sombreamento. O segundo estágio, correspondente ao de secundárias iniciais, se inicia a partir do quarto ou quinto ano, e observa-se os indivíduos pioneiros já garantindo o sombreamento da área; a presença de um estrato secundário de vegetação em crescimento; e a inibição do desenvolvimento de gramíneas e arbustos que demandam luminosidade. O terceiro estágio de secundárias tardias se inicia 20 anos após o distúrbio inicial e caracteriza-se pela substituição gradual das espécies pioneiras já em senescência por espécies tardias, que apresentam desenvolvimento mais lento e tolerância ao sombreamento. É durante este estágio que a estrutura florestal ganha maior complexidade com composições em diferentes estratos verticais e também se torna mais rica em espécies. O estágio de clímax é atingido a partir de 100 anos após a perturbação inicial. Neste último estágio, a comunidade é tida como estável, mas não estática, apresentando ciclos de regeneração de espécies tolerantes e intolerantes à luminosidade decorrente da abertura de clareiras no dossel. Este estágio também é caracterizado por um crescimento lento dos indivíduos adultos e com maioria de espécies de madeira densa (BUDOWSKI, 1965; CHAZDON, 2014; CHAZDON et al., 2020).

Uma importante vertente no contexto da restauração florestal é sua motivação. O crescimento das iniciativas que visam promover a restauração florestal está diretamente

vinculado à percepção social do valor da qualidade ambiental. Em outras palavras, nota-se uma preocupação crescente da sociedade contemporânea em relação à qualidade do meio ambiente e de seus recursos, os quais impactam diretamente no bem-estar social. É possível apontar diversos motivadores que incentivam a restauração florestal, como por exemplo a remediação de um impacto já causado; prevenção de impactos iminentes; cumprimento de exigências legais; usufruto do turismo ecológico, e a própria garantia da provisão de serviços ecossistêmicos (BRANCALION, et al., 2012; BRANCALION et al., 2013). Não obstante, busca-se hoje a valorização do capital natural para que a devida atenção seja captada e focada em direção à restauração e conservação ambiental. A exploração do valor do capital natural facilita a percepção da importância da qualidade e quantidade de recursos naturais para a sociedade, em especial, para tomadores de decisão, proprietários rurais e residentes de centros urbanos (ARONSON, 2015).

Estudos contemporâneos têm buscado evidenciar os benefícios econômicos proporcionados pela restauração florestal. Brancalion et al. (2012) buscaram discutir essa perspectiva em seu trabalho e mostraram que, através de tecnificação adequada, a produtividade das pastagens contidas na região da mata atlântica poderia ser dobrada e ocasionaria ainda a liberação de 15.3 milhões de hectares para restauração florestal. Além disso, os autores enfatizam que há diversas formas de se obter capital financeiro em conjunto ou em decorrência da restauração, como por exemplo através da exploração madeireira (com plantios mistos de espécies de crescimento rápido, moderado e lento); exploração de produtos não madeireiros (alimento, ervas medicinais, materiais para construção, etc.); cultivo agrícola em conjunto com fase inicial da restauração (feijão, milho, abóbora, etc.); Pagamentos por Serviços Ambientais (PSA) e também através de ganhos indiretos por consequência de tais serviços.

Embora todo esforço de restauração seja válido, os métodos de restauração ativa geralmente apresentam custo significativo de planejamento, execução e manutenção/monitoramento. Diante da degradação florestal hoje atingida pela sociedade, é necessária a adoção da restauração florestal de paisagem, que consiste no processo de restauração dos ecossistemas florestais degradados em grandes escalas espaciais. Nesta perspectiva, é fato que o sucesso de projetos de larga escala exige esforços internacionais em diferentes níveis e escalas que busquem a redução de custos da restauração através do aproveitamento da regeneração natural da paisagem. Alcançar a regeneração natural em larga escala implica na superação de diversos desafios tais como alto nível de degradação do solo; ausência de vegetação nativa; frequência de incêndios. Além disso, devido ao longo tempo de

amadurecimento de uma floresta naturalmente regenerada, são escassos os estudos de longo prazo que definem diretrizes ou parâmetros para avaliar o sucesso de tal processo. Não obstante, do ponto de vista social e cultural, as regiões que apresentam as características iniciais da regeneração natural possuem uma reputação negativa entre proprietários rurais e também tomadores de decisão, sendo vistas como áreas abandonadas e sem valor de conservação ou econômico. Sendo assim, há muito o que ser desenvolvido e adequado desde a perspectiva social até a legal para que seja viável e desejável a condução de projetos de restauração em larga escala através da regeneração natural (BRANCALION et al., 2013; CHAZDON e GUARIGUATA, 2016; CHAZDON e URIARTE, 2016; MOLIN et al., 2018).

O processo de regeneração natural é influenciado por fatores de escala local e também de paisagem. Em geral, o potencial de regeneração é maior quando há proximidade de remanescentes florestais, solos férteis e altas taxas pluviométricas; o uso intensivo (pastagens e monocultivos), presença de gramíneas invasoras, incêndios recorrentes e solos exauridos são fatores que impedem ou dificultam a regeneração natural, ocasionando também o aumento dos custos de restauração (ARROYO-RODRIGUEZ et al., 2016; MARTINS et al., 2014). Localmente, é importante a determinação da intensidade de distúrbios presentes na região, em especial daqueles provindos das atividades anteriormente conduzidas no local, como agricultura e pecuária. Os fatores a serem analisados podem incluir tamanho da área agrícola, tipo de maquinário e frequência de uso, insumos químicos, entre outros. Contudo, a simples identificação do tipo e o tempo de uso anterior já pode caracterizar uma métrica consistente para prever a regeneração natural (ZERMENO-HERNANDEZ et al., 2015). A nível de paisagem, o fator fundamental é a presença de florestas conservadas ou florestas secundárias bem desenvolvidas, que atuam como fonte de propágulos para regiões em restauração ou regeneração, especialmente nas etapas iniciais da sucessão. Esses ambientes atuam ainda como habitat para fauna dispersora de sementes, polinizadores e também para predadores de pestes (URIARTE e CHAZDON, 2016). Neste contexto, um dos principais focos de pesquisa busca entender e/ou determinar as regiões onde a regeneração natural tende a ocorrer de maneira facilitada e ainda garantir o restabelecimento de altos níveis de biodiversidade (BORDA-NIÑO et al., 2020).

Em seu trabalho, Prieto et al. (2021) realizou uma modelagem espacial com auxílio de algoritmos de aprendizagem de máquina para identificar os locais com maior chance de atingir altas taxas de biodiversidade a partir da regeneração natural. Neste procedimento, os autores testaram e identificaram a correlação entre tal processo e diversas variáveis socioambientais, destacando a influência daquelas relacionadas à demografia, tipo de uso do solo, distúrbios

naturais e antrópicos, disponibilidade hídrica, e características pedológicas e topográficas. Não obstante, Crouzeilles et al. (2021) indicam que o restabelecimento da biodiversidade através da regeneração natural tem relação direta e positiva com a proximidade de remanescentes florestais da paisagem; enquanto fatores de oportunidade econômica, demandas sociais, e condições ecológicas e biofísicas exercem influência indireta. Sendo assim, os autores discutem que paisagens com pouca pressão socioeconômica e condições biofísicas favoráveis apresentam maiores chances de recuperação da biodiversidade a partir da regeneração natural. O trabalho de Schweizer et al. (2022) também buscou estudar a dinâmica de regeneração natural e biodiversidade considerando a influência da intensidade e configuração de uso do solo em seu entorno através de modelagem espacial baseada em fatores abióticos e configuração da paisagem. Os autores evidenciam a correlação negativa entre a intensidade de uso do solo e o acúmulo de biomassa (limitação da expansão de cobertura vegetal); além disso, mostram que a regeneração é mais limitada em áreas de cana-de-açúcar do que em pastagens devido às chances reduzidas de abandono e à maior dificuldade de germinação de regenerantes (manejo constante e cíclico da cultura).

O desenvolvimento de métodos para identificar e priorizar áreas para restauração através da regeneração natural é fundamental para contribuir com o planejamento e execução de projetos de larga escala (CHAZDON e GUARIGUATA, 2016). Por essa razão, a compreensão e avaliação do potencial de regeneração natural vem sendo estudada por diversos pesquisadores (SHOO e CATTERALL, 2013; MARTINS et al., 2014; PRIETO et al., 2021), e tem enfatizado o grande potencial da aplicação da modelagem estatística e espacial para a temática da restauração de ecossistemas como um todo, em especial aquelas que abordam metodologias fundamentadas em princípios e ferramentas de aprendizado de máquina.

1.1.5. Aprendizado de máquina e modelos de regressão

Entre diversas definições, o aprendizado de máquina (AM) pode ser considerado como uma subárea da ciência da computação caracterizada por permitir o aprendizado de computadores (algoritmos) sem uma programação explícita, sendo assim classificada como um método de inteligência artificial (SAMUEL, 1959). Os modelos de AM encontram relações entre as variáveis analisadas e, por essa razão, podem ser aplicados para diversas áreas do conhecimento e com diferentes finalidades, tais como classificações, predições (regressões) e identificação de padrões (LIAKOS, 2018; VOYANT, 2017).

Os modelos de AM podem ser classificados em diferentes categorias, de acordo com seus princípios matemáticos. Sendo assim, é possível mencionar os modelos de regressão (linear e logística), agrupamento (clustering), modelos bayesianos, aprendizado por instâncias, árvores de decisão, redes neurais artificiais, entre outros. De forma mais genérica, os modelos podem ser agrupados nas categorias de aprendizado supervisionado e não-supervisionado (LIAKOS, 2018).

O aprendizado supervisionado consiste na análise da relação entre os dados de entrada e saída (variáveis dependentes e variável resposta) a partir de um exemplo. Isto é, os algoritmos do aprendizado supervisionado necessitam da subdivisão de um banco de dados inicial em frentes de treinamento e teste para que consigam identificar os padrões e relações entre os dados e construir um modelo preditivo ou classificatório. Nesta divisão, a seção de treinamento exemplifica a relação entre os dados de entrada e saída, permitindo que o sistema seja capaz de criar uma regra geral para relacionar os dados. Por outro lado, a vertente do aprendizado não-supervisionado dispensa a segregação entre dados de treinamento e teste, uma vez que o objetivo processo de aprendizado passa a se basear na identificação direta de padrões entre os dados (KOTSIANTIS, 2007; MAHESH, 2020).

Para os casos de modelagem preditiva ou estimativa, a técnica mais utilizada é a regressão, que analisa a relação das variáveis envolvidas e utiliza as dependentes – “x” – para estimar ou prever valores para a variável independente “y”. Os modelos regressão são classificados na categoria de aprendizado supervisionado e são voltados para problemáticas envolvendo dados contínuos. Modelos baseados em princípios matemáticos que vão além da regressão linear ou logística, também podem ser utilizados para resolução de problemas que demandam previsões ou estimativas. Isto é, algoritmos baseados em árvores de decisão ou mesmo redes neurais podem ser aplicados para criar um modelo de regressão (MAULUD e ABDULAZEEZ, 2020; LIAKOS, 2018). A importância e visibilidade dos modelos de regressão tem crescido muito nos últimos anos, acompanhando os avanços tecnológicos; e a capacidade preditiva que acompanha tais modelos é o principal fator que garante sua ampla aplicabilidade. Por essa razão, estudos de aplicação comparativa entre diferentes técnicas e algoritmos de AM se tornaram comuns na literatura abordando as mais diversas temáticas (HUANG et al., 2020). A comparação de desempenho entre diferentes algoritmos pode ser medida através de várias métricas, dentre elas se destacam na literatura a avaliação do ajustamento dos modelos aos dados refletido pelo Coeficiente de Correlação (R^2); e a validação medida pelos valores de Erro Médio Absoluto – MAE, Erro Quadrático Médio – MSE e Raíz

Quadrada do Erro Médio – RMSE (UDDIN et al., 2019; GARCÍA-GUTIÉRREZ et al., 2015; BAKER et al., 2021)

Baseado no princípio de treinamento e teste de algoritmos de AM, Shendryk, Davy e Thorburn (2021) combinaram dados extraídos em séries históricas de imagens multiespectrais orbitais com variáveis de caracterização climática, pedológica e topográficas para criar um modelo preditivo e estimativo de produtividade (T/ha) de áreas destinadas ao cultivo da cana-de-açúcar. O processo de validação do modelo mostrou grande potencial preditivo e adequabilidade das variáveis nas estimativas diante do coeficiente de determinação (R^2) equivalente a 0,75 ou 75%. Os autores ainda enfatizam a aplicabilidade das previsões para aplicações de fertilizantes e planejamento da colheita. Um estudo semelhante foi conduzido também por Canata et al. (2021), que utilizaram diretamente dados de produtividade medidos em campo através do maquinário em conjunto com a imagens orbitais para gerar os modelos preditivos; os resultados também mostraram adequabilidade dos dados com R^2 equivalente a 0,70 ou 70%.

Ainda neste mesmo contexto, é válida a menção da pesquisa de Xu et al. (2020), que adotaram uma metodologia baseada em um sensor mais sofisticado para estimar a produtividade da cana-de-açúcar. Os autores levantaram diversas variáveis ambientais em pontos de amostragem diversos da área de estudo (talhões de cana-de-açúcar) onde também foram medidos os valores de peso fresco acima do solo e de altura da cultura, sendo este último medido através do sensor Light Detection and Ranging (LiDAR) abordo de uma aeronave remotamente pilotada. Os dados foram correlacionados para criar um modelo preditivo de AM buscando estimar a produtividade da cana-de-açúcar; os resultados se mostraram muito fiéis à realidade, atingindo valores de R^2 equivalentes a 0,97 ou 97%.

O trabalho de Albrecht et al. (2021) constitui um exemplo da aplicação de AM voltado para modelagem ambiental. Os autores exploraram algoritmos clássicos do AM (Support Vector Machine e Random Forest) para modelar uma região ampla do oeste australiano e encontrar áreas passíveis de exploração mineral a partir de dados geomorfológicos e planialtimétricos. Para ambos os algoritmos testados, a acurácia avaliada foi de 98% e apresentaram um tempo de processamento computacional relativamente baixo (48 minutos) considerando a ampla região analisada (1.000.000 km²). O trabalho evidencia ainda a importância do aprimoramento de metodologias de modelagem ambiental através de algoritmos clássicos de AM para solucionar problemas ou auxiliar na tomada de decisão. Esta discussão é realizada em contraponto ao uso de técnicas de Aprendizado Profundo (Deep Learning) e de

Redes Neurais Convolucionais (Convolutional Neural Networks), as quais são mais complexas e podem exigir maior poder computacional ou tempo de processamento.

A revisão sistemática de Stupariu et al. (2022) mostrou os métodos e técnicas de AM mais comumente empregados em análises de ecologia da paisagem e estudos ambientais. Ao investigar um total de 125 artigos, os autores apontam que o método mais recorrente foi de aplicação do algoritmo Random Forest (51 estudos), seguido por Redes Neurais Artificiais (34 estudos) e pelo algoritmo Support Vector Machine (19 estudos); a grande maioria dos artigos foram baseados ainda nas técnicas de aprendizado supervisionado (com etapas de treinamento e teste) explorando relações não-lineares entre variáveis. Em geral, o contexto de aplicação das técnicas de AM foram diversos, abordando mapeamentos (HUANG et al., 2018; YIN et al., 2018), tarefas de classificação (CHAPMAN et al., 2010; ROSS et al., 2018), previsões (CHEN et al., 2019; KENNEDY et al., 2015) e modelagem (SHAFIZADEH-MOGHADAM et al., 2017; PAZUR et al., 2020). Dentre os estudos envolvendo previsões, as temáticas mais recorrentes foram para determinação de ocorrência e distribuição de espécies (CURRY et al., 2018); e também para mudanças de uso do solo com ênfase em problemáticas agropecuárias (YARAMASU et al., 2020). Os trabalhos abordando modelagem correspondem a quase metade da base de artigos analisada pelos autores, dentre os quais a temática predominante foi identificação de fatores de mudança através da correlação entre diversas variáveis explicativas (WANG et al., 2016; CHRISTENSEN e ARSANJANI, 2020).

Conforme mencionado anteriormente, o Random Forest é um dos algoritmos de AM mais utilizados na área ecológica e ambiental. Este algoritmo é baseado em múltiplas árvores de decisão aleatórias, isto é, o algoritmo calcula a média das previsões ou classificações derivadas de diversas árvores individuais. As árvores de decisão individuais são construídas em partições amostrais e não na amostra original. Este processo de partição é denominado agregação e reduz o sobreajuste dos dados. O sobreajuste por sua vez é o fenômeno que ocorre quando um modelo/algoritmo apresenta um ajuste muito bom aos dados de entrada, mas é incapaz de realizar previsões de qualidade (SCHONLAU e ZOU, 2020; BREIMAN, 2001). Os algoritmos de Redes Neurais Artificiais por sua vez, foram desenvolvidos a partir da estrutura e funcionamento do cérebro humano e apresentam grande capacidade para mapear relações não-lineares, além de seu alto potencial adaptativo e de aprendizagem; sendo assim empregados em temáticas de diversas áreas científicas: tecnologia, medicina, economia, meio ambiente, entre outras (ZHAO et al., 2019; HOCENSKI et al., 2022). Outro algoritmo comumente utilizado é o Support Vector Machine (SVM), que utiliza atributos espaciais para separar e classificar os dados através da criação de diferentes planos ou regiões linearmente delimitados.

O SVM-radial é uma derivação do algoritmo que utiliza o radial de Kernel para estabelecer os limites das regiões de separação de forma não-linear quando este comportamento é observado na correlação das variáveis (ZHU et al., 2018; HARIMOORTHY e THANGAVELU, 2021).

Conforme apresentado, as técnicas e métodos de AM podem ser aplicados para diferentes finalidades e áreas da ciência, contemplando objetivos que variam desde a melhoria de processos até execução de análises refinadas para tomadas de decisão. A modelagem ambiental e agrícola são exemplos de áreas de estudo com aplicação consolidada do AM sob diferentes objetivos e que apresentam resultados eficientes e promissores (STUPARIU et al., 2022). Assim, novas propostas e abordagens envolvendo o AM para enfrentar os desafios hoje vivenciados pela humanidade, especialmente no âmbito da restauração de ecossistemas, são bem vistas e incentivadas.

2. OBJETIVOS

2.1. Objetivo geral

O objetivo geral deste trabalho foi identificar áreas potenciais para a restauração ecológica e consequente expansão de ecossistemas nativos, explorando as regiões marginais da produção mecanizada de cana-de-açúcar (Áreas de Linhas Curtas – ALC).

2.2. Objetivos específicos

Os objetivos específicos deste trabalho consistem em:

- Quantificar e compreender a ocorrência espacial das ALC nas paisagens amostradas;
- Criar e avaliar diferentes modelos estatísticos baseados no aprendizado de máquina para quantificar e espacializar as ALC;
- Estimar a contribuição potencial das ALC para a redução do déficit de RL do estado de São Paulo.

3. MATERIAIS E MÉTODOS

3.1. Localização e descrição da área de estudo

Esta pesquisa contempla a área de cultivo de cana-de-açúcar em toda a extensão territorial do estado de São Paulo (Figura 1), correspondente a cerca de 22,3% de seus 248.219 km² (IBGE, 2019; UNICA, 2018).

O estado de São Paulo é coberto por dois biomas, o Cerrado e a Mata Atlântica, que representam respectivamente 32,8% e 67,2% do território paulista (IBGE, 2019). A área de vegetação nativa atual de Cerrado equivale a 8.891,8 km² enquanto a de Mata Atlântica 50.914,3 km², o que corresponde a 19,2% e 25,2% da área total de cada bioma, respectivamente (PROJETO MAPBIOMAS, 2020). Neste cenário, considerando a legislação ambiental brasileira vigente, o estado de São Paulo apresenta um déficit de vegetação nativa (APP e RL) equivalente a 19.069 km² (TAVARES et al., 2019; IMAFLORA, 2017).

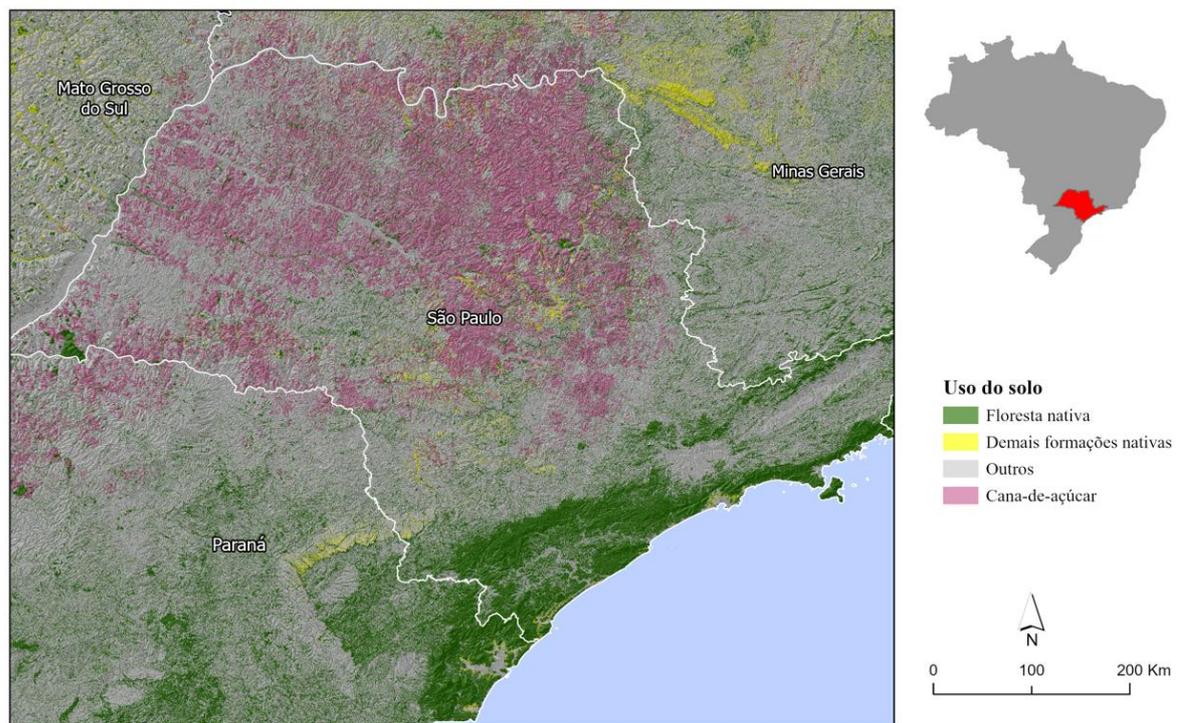


Figura 1: Uso da terra no estado de São Paulo com destaque para as classes de Floresta (vegetação nativa de fitofisionomia florestal), Vegetação nativa (demais fitofisionomias de vegetação nativa), Cana-de-Açúcar (área com plantio da cultura identificado) e Outros (demais classes de uso).

Fonte: Adaptado de Projeto Mapbiomas (2020).

3.2. Metodologia

O procedimento metodológico desta pesquisa pode ser resumido nas seguintes etapas: 1) Segmentação e amostragem das paisagens; 2) Delimitação e caracterização das ALC; 3) Caracterização das paisagens; 4) Análise estatística e modelagem; e 5) Cenários de redução do déficit de RL. A descrição individual de cada etapa está apresentada nos tópicos a seguir e o fluxograma ilustrativo do procedimento encontra-se na Figura 2.

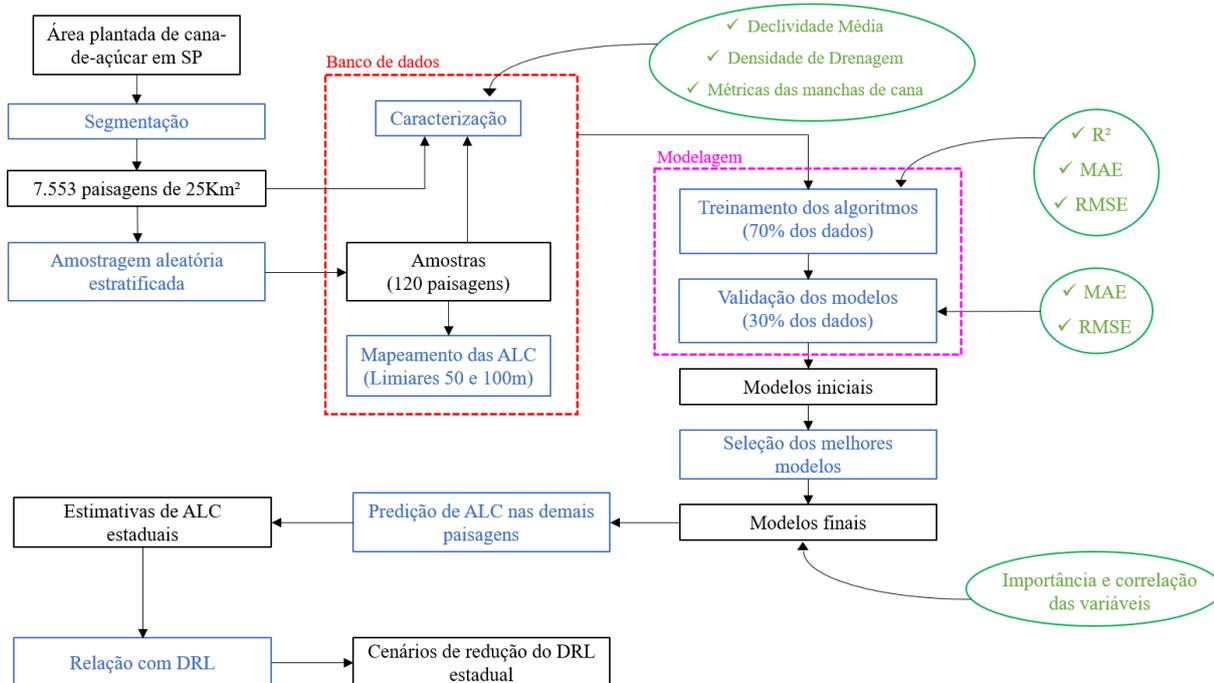


Figura 2: Fluxograma ilustrativo do procedimento metodológico da pesquisa abordando as entradas e saídas em quadrículas pretas; as operações em azul; e as sub operações em verde. As quadrículas destacadas pela linha vermelha pontilhada representam as operações que originaram o banco de dados utilizados para o procedimento de modelagem (pontilhado em rosa).

3.2.1. Dados geospaciais

Para a execução deste projeto foi utilizado o Sistema de Informação Geográfica (SIG) ArcGIS Pro, o software de estatística e modelagem R (R Core Team, 2021), o software de processamento em nuvem Google Earth Engine (GORELICK et al., 2017) e a base de dados secundários conforme descrito na lista abaixo:

- Mapas de uso da terra: arquivos matriciais com resolução espacial de 30 metros produzidos e disponibilizados pelo Projeto Mapbiomas (2020) na Coleção 5.0.

- Dados de altimetria: arquivos matriciais da Missão Topográfica de Radar Embarcado (em inglês, Shuttle Radar Topography Mission – SRTM) com resolução espacial de 30 metros previamente processados para preenchimento e correção de falhas; disponibilizados online pelo projeto TOPODATA do Instituto Nacional de Pesquisas Espaciais (INPE).
- Mapas e estatísticas agropecuárias: dados estatísticos e espaciais de déficit de RL e Malha Fundiária estadual, elaborados e disponibilizados pelo Laboratório de Planejamento de Uso do Solo e Conservação da ESALQ/USP (GEOLAB, 2019) através do Projeto Temático BIOTA FAPESP intitulado “Áreas prioritárias para compensação de Reserva Legal: pesquisa para o desenvolvimento de uma ferramenta para auxílio à tomada de decisão e transparência no processo de implementação do Programa de Regularização Ambiental (PRA) no Estado de São Paulo – BIOTA” (processo nº 2016/17680- 2).
- Estimativas de déficit de RL: valores e estatísticas de déficit de RL do estado de São Paulo estimados e especializados em nível de propriedade e atualizados para 2022 (Tavares et al., 2021).
- Rede hidrográfica estadual: arquivo vetorial representativo da hidrografia do estado de São Paulo. O arquivo foi desenvolvido em 2009 pela Fundação Brasileira para o Desenvolvimento Sustentável (FBDS) e gerado a partir da vetorização das imagens de alta resolução RapidEye, resultando em camada na escala 1:25.000.
- Imagens orbitais: imagens de satélite de alta resolução da base de dados ESRI e Google Earth Pro utilizadas para identificação e delimitação das ALC.

3.2.2. Segmentação da área de estudo em paisagens e amostragem

O estado de São Paulo foi dividido em uma malha de 5 x 5 km, formando 7.553 paisagens de 25 km² que contemplam alguma cobertura de cana-de-açúcar. Em seguida, uma amostragem aleatória estratificada e uniforme de 120 paisagens foi realizada considerando o percentual de cobertura do solo pela cultura da cana-de-açúcar. Para tal, foram utilizadas as categorias $\leq 15\%$; 15-30%; 30-45%; 45-60%; 60-75%; e $> 75\%$, sendo cada categoria representada por 20 paisagens (Figura 3). Esta categorização foi realizada buscando a obtenção futura de amostras representativas em termos de quantificação de ALC em cada paisagem, isto é, amostrar de forma balanceada paisagens com pouca e muita ALC. Para a execução desta etapa foram considerados os dados espaciais de cultivo de cana-de-açúcar da coleção 5 do

Projeto de Mapeamento Anual da Cobertura e Uso do Solo no Brasil – MapBiomias (PROJETO MAPBIOMAS, 2020).

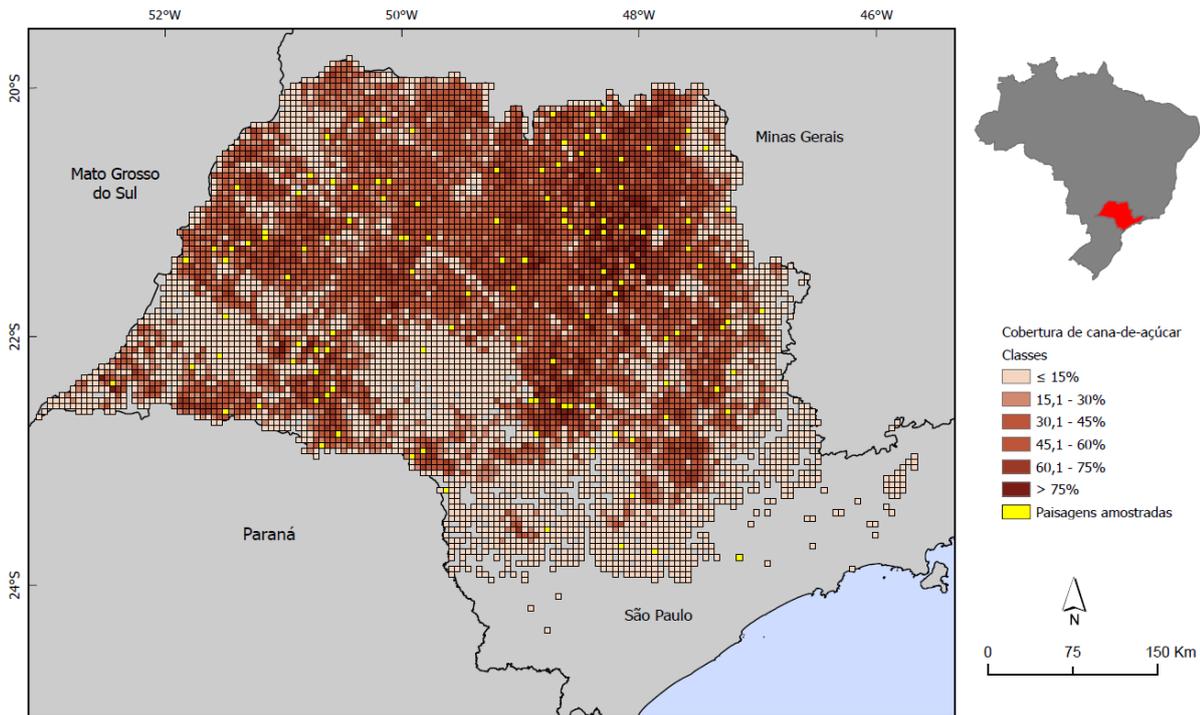


Figura 3: Mapa da divisão do estado de São Paulo em paisagens de 25 km² categorizadas de acordo com o percentual de cobertura de cana-de-açúcar, provindo da coleção 5 do MapBiomias (2020).

Fonte: Adaptado de Projeto Mapbiomas (2020).

3.2.3. Delimitação e caracterização das Áreas de Linhas Curtas

As ALC foram mapeadas pelo método de fotointerpretação em escala de 1:2.000 nas regiões dos talhões em que o comprimento das linhas de colheita foi identificada como igual ou inferior a 100 e 50 metros (Figura 4), condizente com os valores apresentados por Spekken, Molin e Romanelli (2014). Ou seja, através do ambiente SIG, as linhas de plantio de cana-de-açúcar foram manualmente medidas com ferramentas do software permitindo a aferição de seus comprimentos. Nos casos em que a metragem foi igual ou inferior a 100 metros, a região foi mapeada para compor o limiar de ALC 100m (cenário realista); analogamente, os casos onde a metragem foi igual ou inferior a 50 metros, o mapeamento da região passou a compor o limiar de ALC 50m (cenário conservador). Este procedimento foi executado em todas as 120 paisagens aleatoriamente amostradas utilizando as imagens de satélite com a mais alta resolução disponível, como basemaps ESRI e Google Earth, desde que posteriores ao ano 2019. Com tais imagens e trabalhando na escala mencionada, foi possível identificar as linhas de plantio e

também calcular o valor de área mapeada em hectares.

Após o mapeamento das ALC, foi realizada uma caracterização dessas regiões em relação às distâncias mínima, média e máxima de i) hidrografia; ii) manchas de vegetação; e iii) APP. As bases de dados utilizadas para tais análises foram o mapa hidrográfico da FBDS, classe de vegetação nativa mapeada pelo Mapbiomas, e APP de 30 m geradas a partir da hidrografia anteriormente mencionada. Para cada uma das informações, foi gerado um arquivo matricial (raster) que expressa a distância euclidiana de cada fator de análise.



Figura 4: Exemplo de Áreas de Linhas Curtas (ALC) mapeadas por fotointerpretação em paisagem agrícola na bacia do rio Piracicaba. As linhas pontilhadas em preto representam exemplos de medições das linhas de plantio que se enquadram nos limiares propostos.

3.2.4. Caracterização das paisagens

Todas as paisagens foram caracterizadas visando identificar quais variáveis podem estar relacionadas e/ou explicar a presença e quantidade (em termos de dimensão) das ALC. Neste sentido, foram investigadas declividade, densidade hidrográfica, percentual de cobertura por cana-de-açúcar, e métricas de forma dos talhões da cultura (índice de forma, área total, área nuclear, entre outros). A identificação de tais variáveis permitiu a criação de modelos de

regressão para estimar as ALC nas demais paisagens do estado de São Paulo. Uma vez extraídas as informações referentes a cada variável, um banco de dados foi construído vinculando cada informação ao identificador individual (ID) de cada paisagem do estado de São Paulo.

Declividade

A declividade das paisagens foi determinada com base nos arquivos disponibilizados pelo projeto TOPODATA. Criado pelo INPE, o projeto fornece arquivos matriciais com resolução espacial de 30 metros correspondentes aos dados SRTM processados para preenchimentos e retiradas de falhas, ou seja, fornecem dados de altimetria do terreno já corrigidos.

Dessa forma, 25 arquivos (cenos) correspondentes à cobertura total do estado de São Paulo foram baixados através da plataforma do projeto. Tais arquivos foram então manipulados em ambiente de SIG, utilizando a ferramenta 'Slope', para transformação da informação de entrada (altimetria) em valores de declividade percentual.

Por fim, ainda em ambiente SIG, foi estabelecida a relação espacial entre a camada de informação de declividade e todo o território paulista através da ferramenta 'Zonal Statistics as Table', o que permitiu a extração de valores médios de declividade percentual para cada uma das unidades da paisagem anteriormente geradas.

Densidade de drenagem

A hidrografia estadual foi obtida através do banco de dados da FBDS em escala base de 1:25.000. Os dados foram analisados a nível de paisagem buscando a obtenção da densidade de drenagem. Para tal, através da ferramenta 'Summarize Within', os comprimentos dos rios foram calculados e sua somatória dividida pela área das paisagens (25 km²), resultando na densidade de drenagem expressa em km/km².

Cobertura de cana-de-açúcar

O percentual de cobertura do solo pela cultura da cana-de-açúcar em cada unidade da paisagem foi determinado, analogamente ao procedimento realizado para a variável de declividade, através da ferramenta 'Zonal Statistics as Table' com base nos dados secundários de uso da terra da coleção 5 do Projeto de Mapeamento Anual da Cobertura e Uso do Solo no Brasil (MapBiomias). É importante mencionar que, de acordo com a fonte, a classificação que

envolve a classe da cana-de-açúcar apresentou valor de acurácia geral equivalente a 85,8%; com discordância de alocação de 7,8% e discordância de área de 6,5%.

Métricas da paisagem das manchas de cana-de-açúcar

As métricas de forma das manchas foram calculadas para todas as paisagens com base no mapeamento de uso da terra (classe de cana-de-açúcar). Os cálculos foram realizados através do programa FRAGSTATS 4.2 em opção batch. Para tal, a camada matricial correspondente à classe de cana-de-açúcar foi recortada dentro dos limites espaciais de cada unidade da paisagem e, buscando viabilizar e agilizar o procedimento, esta etapa foi realizada na interface do software R através da função ‘crop’ executada em ciclo (loop).

Em seguida, os arquivos gerados foram inseridos no programa FRAGSTATS 4.2 onde as seguintes métricas foram calculadas:

- Área nuclear e número de áreas nucleares (‘Total Core Area’ e ‘Number of Core Areas’): retornam, respectivamente, a área nuclear total dos fragmentos de uma paisagem considerando uma distância de borda informada pelo operador (neste caso, 50 metros); e o número de fragmentos que apresentam área nuclear de acordo com tal distância da borda.
- Borda total (‘Total Edge’): retorna a somatória do perímetro de cada fragmento analisado. No caso, permitirá a análise da quantidade de borda apresentada pelas manchas de cana-de-açúcar. Uma maior quantidade de borda pode indicar manchas desconexas.
- Densidade de borda (‘Edge Density’): retorna a razão entre a somatória das bordas e a área total de cada paisagem analisada. O valor pode variar entre zero e qualquer outro valor positivo sem limitação.
- Índice de forma (‘Shape Index’): relaciona aspectos de perímetro e área podendo ser interpretado quanto a complexidade do formato das manchas analisadas. O valor retornado é 1 quando o formato do fragmento é quadrado. Quanto maior o valor do índice, mais complexa é a geometria analisada.

3.2.5. Análise estatística e modelagem de ALC para São Paulo

Os dados anteriormente levantados referentes às características geomorfológicas das unidades da paisagem e também à descrição da forma das manchas de cana-de-açúcar foram

estatisticamente testados como variáveis independentes de diferentes modelos de regressão para explicar os valores de área de ALC mapeadas por paisagem. O procedimento para criação e comparação dos modelos foi realizado duas vezes de forma a criar um ajuste inicial aos dados das ALC com limiar de 50 metros, e em segundo momento para as ALC com limiar de 100 metros.

O banco de dados contendo as variáveis para 120 observações (referentes a cada paisagem amostrada) foi dividido para dar origem às amostras de treinamento (70%) e de teste (30%), com 84 e 36 observações cada, respectivamente. Em seguida, o processo seguiu para a etapa de criação dos modelos. No total, 12 modelos foram criados a partir dos dados de treinamento (6 para ALC de 100 m e outros 6 para ALC de 50 m) através do programa R com auxílio da função ‘train’ pertencente ao pacote estatístico Caret (Classification and Regression Training), que por sua vez abriga mais de 200 modelos distintos para classificação e regressão. Assim, foram selecionados os seguintes algoritmos de aprendizado de máquina supervisionado para originar os modelos: Random Forest (rf); Decision Tree (rpart); K-Nearest Neighbour (knn); Multivariate Adaptive Regression Splines (earth); Support Vector Machine (svmRadial); e Neural Network Regression (nnet). Além disso, para cada modelo foi definido um parâmetro de controle responsável pela execução do processo de validação cruzada k-fold com $k = 10$, sendo este processo ainda configurado para ser repetido 5 vezes, análogo ao realizado por Lorena et al. (2011). Para concluir essa etapa, foram utilizadas as métricas de Coeficiente de Determinação (R^2), Erro Médio Absoluto (MAE – Mean Absolute Error) e a Raiz do Erro Quadrático Médio (RMSE – Root Mean Squared Error) para avaliar o desempenho de cada algoritmo.

Em seguida, se fez uso do banco de dados de teste para avaliar o potencial preditivo de cada modelo criado. Para esta avaliação, foram utilizadas também as métricas MAE e RMSE de forma convencional e também relativa, – valores dos índices divididos pela média do vetor da variável resposta (no caso, ALC) – as quais foram calculadas comparando os valores de ALC já presentes no banco de dados de teste com os valores estimados por cada modelo. Observando abaixo as equações utilizadas para os cálculos, nota-se que o fator quadrático do RMSE evidencia erros maiores do modelo (diferença entre o observado e o estimado), característica não apresentada na métrica de MAE.

$$RMSE = \sqrt{\frac{\sum (y_i - y_p)^2}{n}} \quad MAE = \frac{\sum |y_i - y_p|}{n}$$

Com, y_i = valor real; y_p = valor estimado; n = número de observações

O processo de modelagem foi realizado também de forma a permitir a identificação das variáveis independentes que melhor explicam a presença de ALC, ou seja, quais possuem maior importância na constituição dos modelos. Este procedimento foi executado apenas para o modelo que apresentou o melhor desempenho (considerando um para cada limiar – 50m e 100m). Em paralelo, a correlação das variáveis mais importantes também foi avaliada através do cálculo do Coeficiente de Correlação de Pearson e dos gráficos de dispersão de tais variáveis em função da variável resposta.

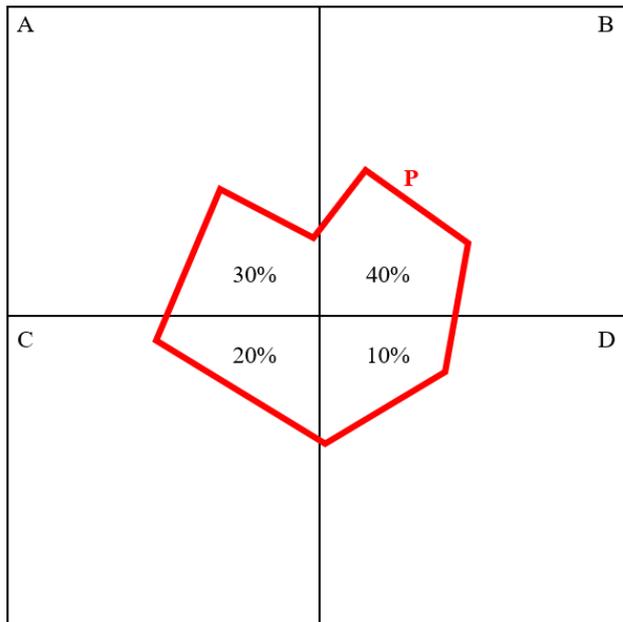
Por fim, após a avaliação, os modelos com melhor desempenho (maiores valores de R^2 e menores valores de erro) foram utilizados para estimar os valores das ALC para as demais unidades da paisagem do estado com base nas mesmas variáveis independentes descritas no tópico 3.2.3. Para gerar tais estimativas, foi utilizada a função ‘predict’ também pertencente ao pacote estatístico Caret.

3.2.6. Cenários de redução de déficits de reserva legal restaurando ALC

Os valores de déficit de RL disponibilizados por Tavares et al., 2021 são expressos a nível de propriedade rural de acordo com os registros do CAR. Além disso, os referidos dados são apresentados considerando 2 situações:

- *Déficit₁*: valores em acordo com a legislação vigente (LPVN), desconsiderando qualquer possível anistia;
- *Déficit₂*: valores considerando possível anistia prevista na legislação.

Com a finalidade de relacionar tais informações com as estimativas de ALC, os valores de déficit foram reamostrados para o mesmo nível de paisagem de 25 km², conforme ilustrado pela Figura 5. Para esta reamostragem, foi utilizado um código no software R que, inicialmente, converteu os valores de déficit de RL medidos em hectares para valores relativos de acordo com a área de cada propriedade rural (razão entre déficit e área da propriedade). Em seguida, através de análise espacial, as propriedades foram recortadas no limite de cada paisagem e seus valores de área foram recalculados e posteriormente multiplicados pelo déficit relativo calculado anteriormente, originando um valor proporcional de déficit de RL por propriedade rural dentro de sua respectiva paisagem. Por fim, foi realizada a somatória dos valores proporcionais por paisagem. Dessa forma, uma propriedade com déficit de RL, dividida em duas ou mais paisagens, manteve um déficit proporcional para cada paisagem. É importante mencionar também que para esta análise foram contabilizados os valores de déficit apenas das propriedades que apresentaram alguma porção de cana-de-açúcar em seu interior.



$$DRL_P = \frac{DRL_{Tavares}}{A_P}$$

$$DRL_A = DRL_P \cdot (0,3 \cdot A_P)$$

$$DRL_B = DRL_P \cdot (0,4 \cdot A_P)$$

$$DRL_C = DRL_P \cdot (0,2 \cdot A_P)$$

$$DRL_D = DRL_P \cdot (0,1 \cdot A_P)$$

Figura 5: Esquema ilustrativo da reamostragem dos valores de déficit RL fornecidos por Tavares et al. (2021). A sequência de A até D representa paisagens adjacentes; A linha vermelha denominada P representa o perímetro de uma propriedade rural fictícia enquanto A_P simboliza sua área; Os valores percentuais representam a fração de A_P contida em cada paisagem; DRL_P representa o déficit de reserva legal de P; $DRL_{Tavares}$ representa o valor do déficit de RL calculado para a propriedade P por Tavares et al. (2021); as equações representam o cálculo realizado para obtenção do valor proporcional de déficit RL para cada paisagem.

Prosseguindo para a etapa comparativa, foram utilizados os dados de RL e suas respectivas relações com as estimativas de ALC de 50 e 100 metros. Sendo assim, 4 cenários de análise foram criados:

- Cenário 1 (C_1): $Déficit_1$ e restauração da ALC 50 m
- Cenário 2 (C_2): $Déficit_1$ e restauração da ALC 100 m
- Cenário 3 (C_3): $Déficit_2$ e restauração da ALC 50 m
- Cenário 4 (C_4): $Déficit_2$ e restauração da ALC 100 m

Inicialmente, foi realizada uma triagem em cada cenário buscando identificar para quais paisagens os valores estimados de ALC foram superiores aos valores de déficit. Isto é, foram identificadas as paisagens nas quais o déficit pode ser completamente mitigado (considerando a restauração das ALC) e resultar ainda em um excedente, que por sua vez também foi calculado. Em seguida, para as demais paisagens foram determinados os percentuais de mitigação do déficit.

4. RESULTADOS

4.1. Caracterização das paisagens e das ALC mapeadas

A caracterização das paisagens contempladas por esse estudo é representada pelo próprio banco de dados que permitiu a construção dos modelos propostos e posterior estimativas de ALC em todo o estado, conforme consta na Tabela 11 do Apêndice.

As ALC mapeadas nas 120 paisagens amostradas apresentaram valores de área conforme exposto na Tabela 1.

Tabela 1: Valores mínimos, médios e máximos de ALC mapeadas ao longo das 120 paisagens amostradas.

Limiar	ALC total mapeada (ha)		
	Mín.	Méd.	Máx.
ALC 50 m	0	0,47	2,72
ALC 100 m	0	2,23	11,89

Além disso, a distribuição de frequência do total de ALC por paisagem pode ser observado nas Figuras 6 e 7, onde nota-se maior concentração de paisagens contendo menos ALC (forma exponencial negativa ou “J” invertido).

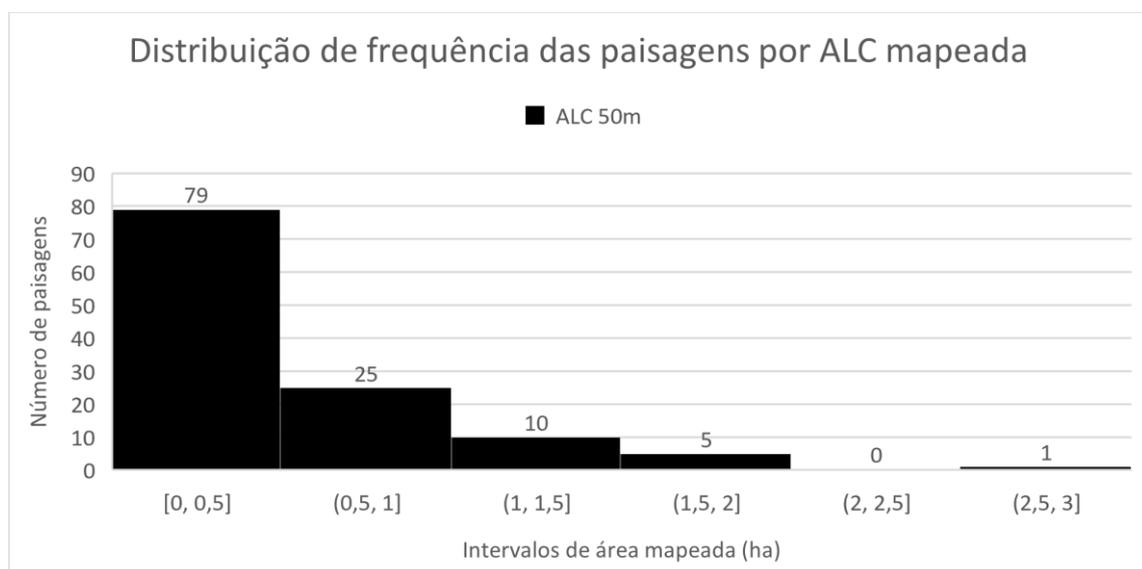


Figura 6: Distribuição de frequência das paisagens amostradas de acordo com o total de ALC mapeados em cada uma, considerando o limiar de 50 metros.

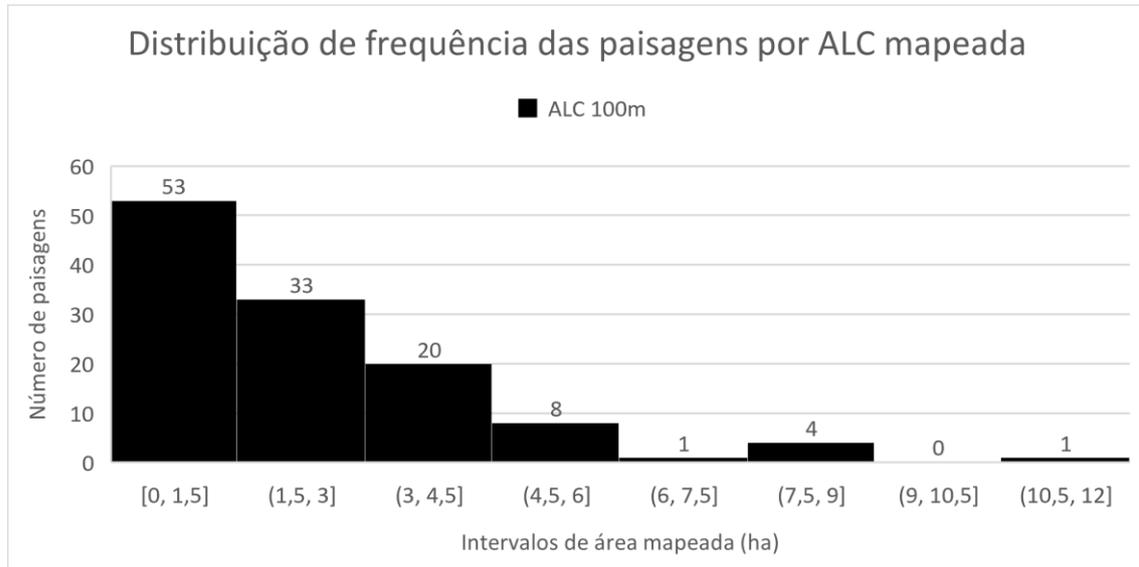


Figura 7: Distribuição de frequência das paisagens amostradas de acordo com o total de ALC mapeados em cada uma, considerando o limiar de 100 metros.

A Figura 8 abaixo mostra os resultados acerca da análise de proximidade realizada entre as ALC mapeadas e regiões de interesse caracterizadas por APP, hidrografia e fragmentos de vegetação nativa presentes nas paisagens amostradas. Os resultados individuais referentes a cada paisagem amostrada encontram-se separados de acordo com o limiar de ALC nas Tabelas 12 e 13 do Apêndice.

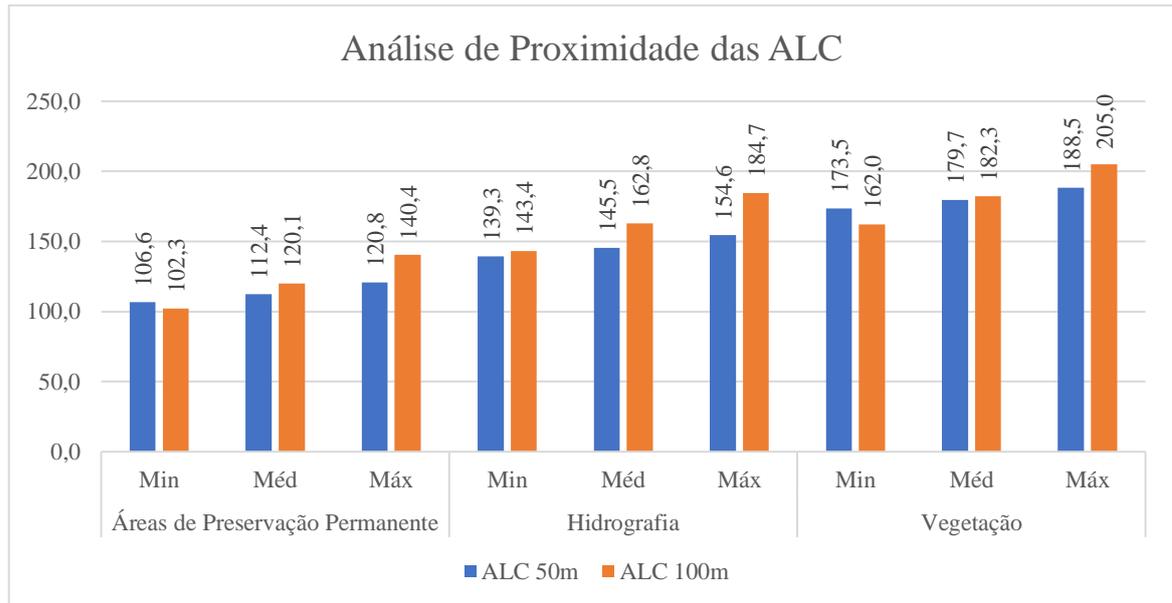


Figura 8: Resultados da análise de proximidade (em metros) entre as Áreas de Linhas Curtas (ALC) mapeadas e as regiões de interesse (Áreas de Preservação Permanente, hidrografia e remanescentes de vegetação), contendo as médias das distâncias mínimas, médias e máximas para cada limiar (ALC 50m e ALC 100m).

Esta análise de proximidade das ALC mostrou que elas se encontram relativamente próximas à APP, hidrografia e remanescentes florestais, com distâncias médias de 112,4 m, 145,5 m e 179,7 m (respectivamente) considerando o limiar de 50 metros; para o limiar de 100 metros é observado um ligeiro aumento das distâncias para 120,1 m, 162,8 m, e 182,3 m.

4.2. Modelagem

O código utilizado para criação dos modelos utilizou um procedimento de processamento em conjunto, ou seja, todos os modelos selecionados foram executados e criados simultaneamente, fato este que facilitou a comparação. Na Figura 9 estão os valores calculados das métricas R^2 , MAE e RMSE para cada algoritmo (valores numéricos na Tabela 8 do Apêndice), considerando as ALC definidas pela metragem de 50 metros.

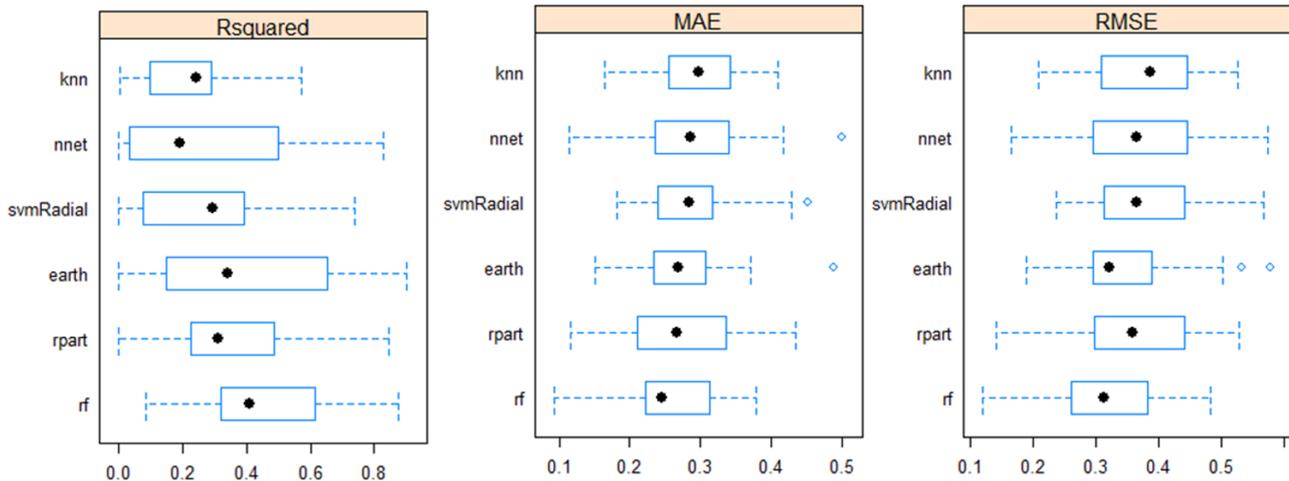


Figura 9: Comparativo dos modelos criados para o limiar de 50 metros (ALC 50m) a partir das métricas de avaliação propostas: Coeficiente de Determinação (R^2 - Rsquared), Erro Médio Absoluto (MAE) e Raiz do Erro Quadrático Médio (RMSE). Os círculos pretos representam a mediana; os retângulos azuis correspondem aos dois quartis centrais; as linhas azuis tracejadas indicam a amplitude (valores máximos e mínimos); e os círculos azuis representam os ‘outliers’.

Assim, pode-se observar que o algoritmo de melhor desempenho no ajustamento dos dados foi o Random Forest, apresentando valor médio de $R^2 = 0,451$ e os menores valores médios de erro ($MAE = 0,252$ e $RMSE = 0,323$).

Com base neste modelo, a análise de importância de cada variável foi realizada (Figura 10) e mostrou valores maiores de importância para as variáveis de número de áreas nucleares (ncore); declividade média do terreno (slope); borda total (TE); e densidade de drenagem (dd). Apesar de apresentarem valores menos expressivos, as variáveis área nuclear (core), percentual de cobertura de cana (cobertura_cana), densidade de borda (ED), e índice de forma (shape), também são importantes para o ajuste do modelo, de forma que a remoção das mesmas reflete negativamente nas métricas de avaliação (R^2 , RMSE e MAE).

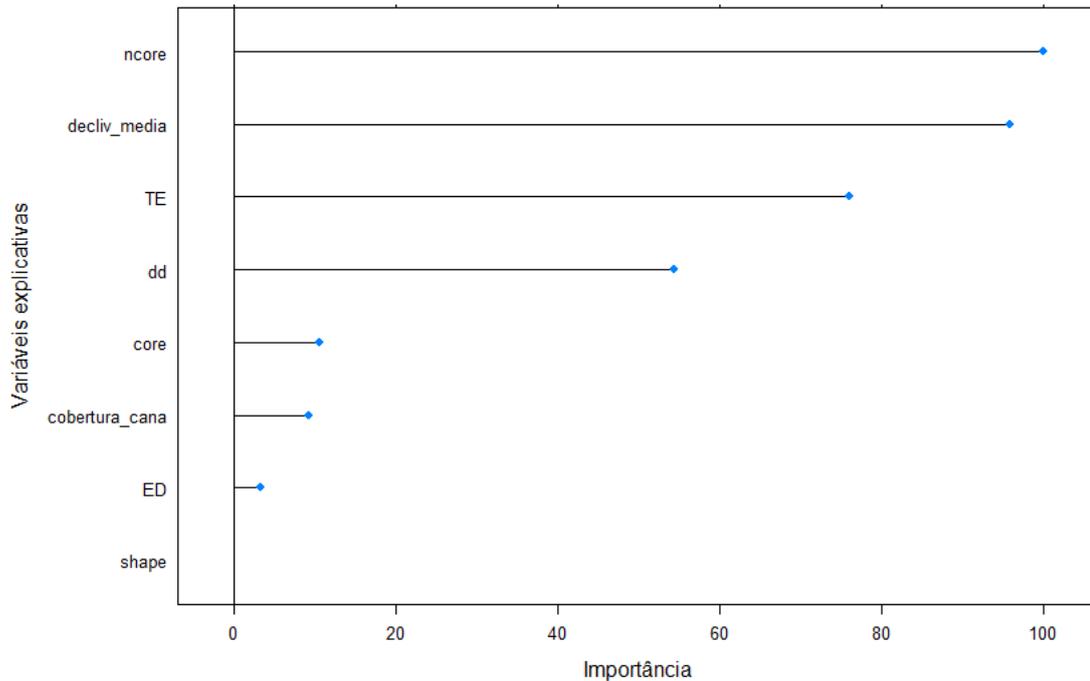


Figura 10: Representação gráfica da importância de cada variável para o modelo criado pelo algoritmo Random Forest considerando o limiar de 50 metros (ALC 50m).

Quanto à correlação entre as variáveis explicativas e a variável resposta (ALC 50m), os valores calculados para o índice de correlação de Pearson estão expressos na Tabela 2. Além disso, a Figura 11 (também na Figura 22 do Apêndice) contém os gráficos de dispersão que ilustram a correlação entre as variáveis mais importantes do modelo e a variável resposta.

Tabela 2: Valores da Correlação de Pearson calculados para as variáveis de maior importância para o modelo Random Forest considerando o limiar de 50 metros (ALC 50m).

Variáveis independentes	Coefficiente de correlação
Número de áreas nucleares (ncore)	0,547
Declividade média (slope)	0,172
Borda total (TE)	0,489
Densidade de drenagem (DD)	0,289

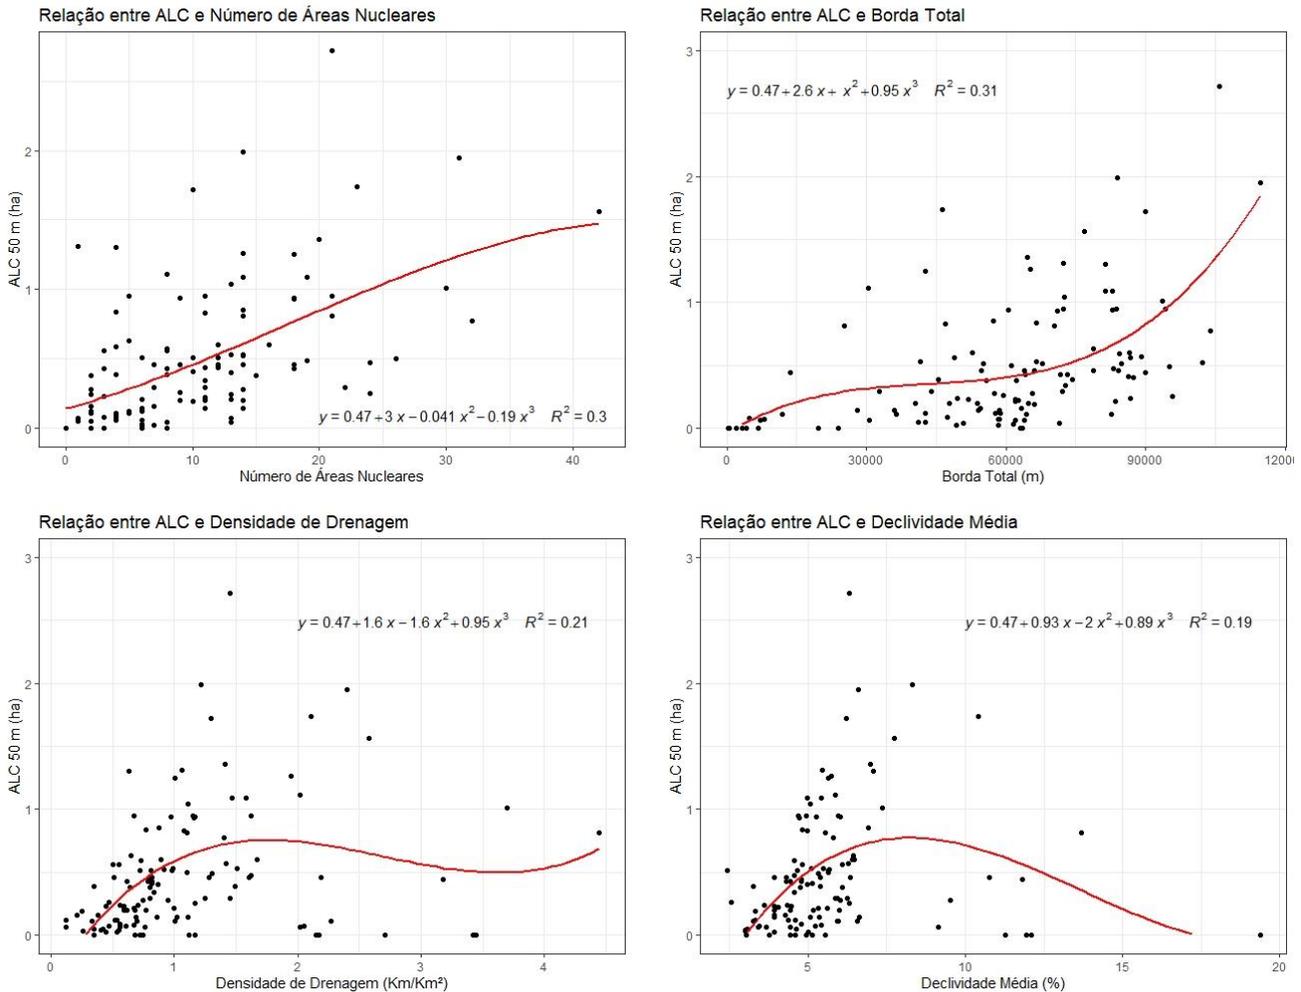


Figura 11: Gráficos de dispersão ilustrando a correlação entre a variável resposta e as explicativas mais importantes para o modelo Random Forest considerando o limiar de 50 metros (ALC 50m). Em cada gráfico também é apresentada a equação de ajuste polinomial de grau 3 e o valor de R^2 relativo a cada ajuste.

Dando continuidade, os valores calculados pelas métricas de avaliação quanto às predições dos modelos comparativamente aos dados de validação estão apresentados na Tabela 3. Dessa forma, observa-se que os menores valores de RMSE foram apresentados pelas predições baseadas no modelo Random Forest. Contudo, os valores de MAE dos modelos Random Trees, Neural Network Regression e Support Vector Machine, foram inferiores. Este fato não indica que tais modelos serão melhores para as predições em geral, já que o coeficiente de determinação para os mesmos foi inferior.

Tabela 3: Valores de erro calculados para as previsões de cada modelo considerando o limiar de 50 metros (ALC 50m).

Algoritmo	MAE	MAE relativo	RMSE	RMSE relativo	R ² médio
RF	0,36	75,65%	0,51	107,41%	0,451
RPART	0,35	73,20%	0,52	109,73%	0,356
KNN	0,36	76,58%	0,55	115,14%	0,226
NNET	0,33	69,60%	0,52	109,79%	0,260
EARTH	0,37	77,21%	0,54	113,50%	0,402
SVMRADIAL	0,33	70,21%	0,54	112,90%	0,293

Paralelamente, os mesmos procedimentos foram executados para a criação do modelo preditivo considerando as ALC com metragem de 100 metros. Dessa forma, os resultados do ajuste dos algoritmos estão expressos pelas métricas R², MAE e RMSE na Figura 12 (valores numéricos na Tabela 9 do Apêndice).

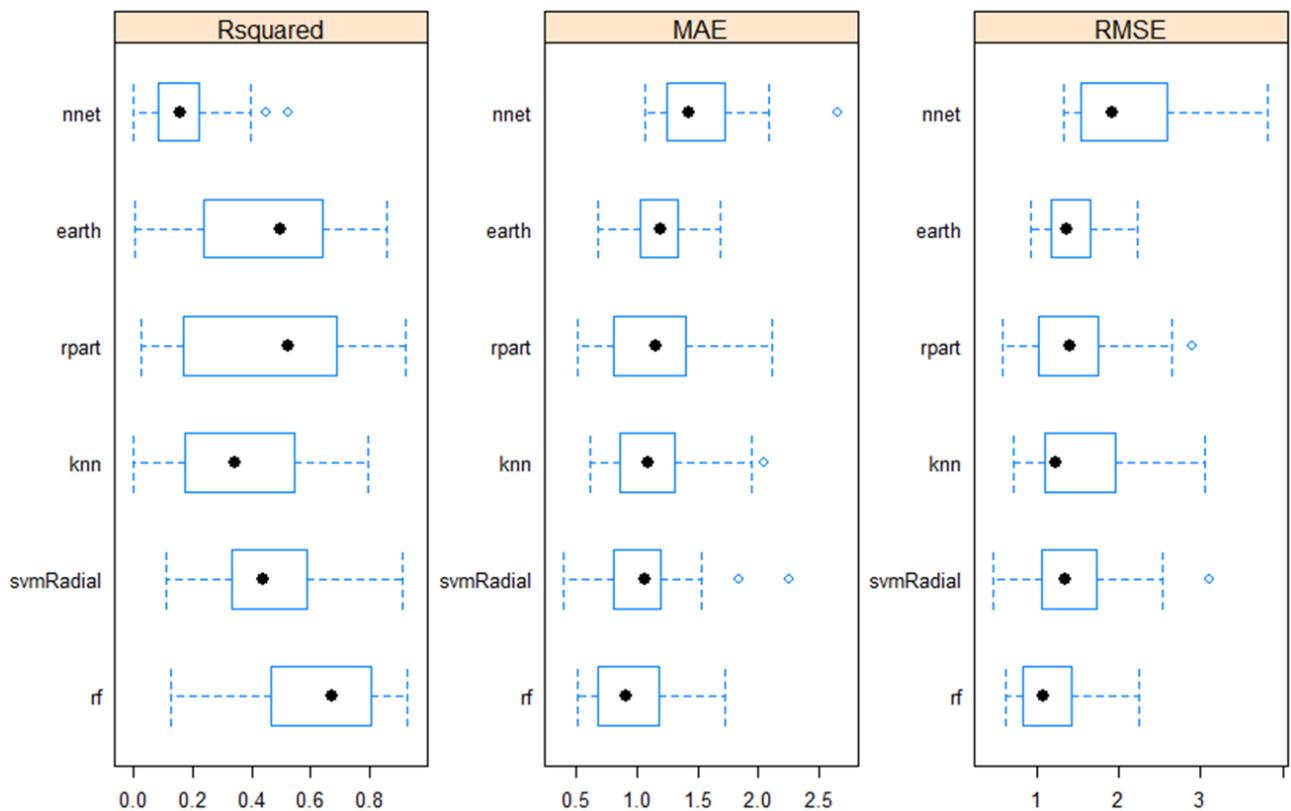


Figura 12: Comparativo dos modelos criados para o limiar de 100 metros (ALC 100m) a partir das métricas de avaliação propostas: Coeficiente de Determinação (R² - Rsquared), Erro Médio Absoluto (MAE) e Raíz do Erro Quadrático Médio (RMSE). Os círculos pretos representam a mediana; os retângulos azuis correspondem aos dois quartis centrais; as linhas azuis tracejadas indicam a amplitude (valores máximos e mínimos); e os círculos azuis representam os ‘outliers’.

Conforme observado, o modelo que teve o melhor desempenho de ajuste aos dados foi também criado pelo algoritmo Random Forest (rf), apresentando o maior coeficiente de determinação (R^2) e os menores valores de erro (RMSE e MAE). Assim, é possível afirmar que aproximadamente 63,4% dos valores da variável resposta (ALC 100 m) são explicados pelas variáveis explicativas. Comparativamente, o coeficiente de determinação para este algoritmo foi superior ao calculado na modelagem preditiva das ALC de 50 metros.

Prosseguindo para a análise de importância das variáveis (Figura 13), nota-se grande similaridade quando comparado ao modelo das ALC de 50 metros. Um fator distintivo é que, para este caso, a declividade média (decliv_media) teve uma importância inferior a borda total (TE); bem como densidade de borda (ED) foi mais importante do que as áreas nucleares (core).

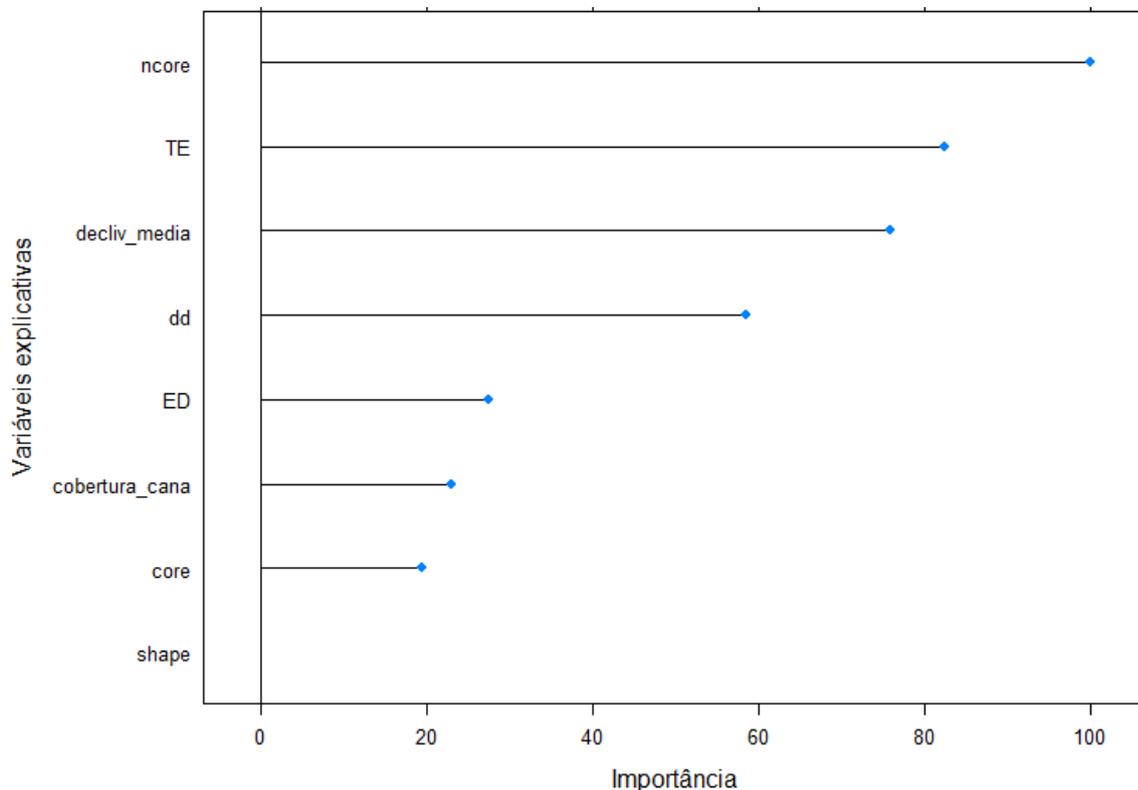


Figura 13: Representação gráfica da importância de cada variável para o modelo criado pelo algoritmo Random Forest considerando o limiar de 100 metros (ALC 100m).

Analogamente ao realizado para a modelagem das ALC de 50 metros, a correlação entre as variáveis foi analisada e os resultados expressos na Tabela 4 e na Figura 14 (também na Figura 23 do Apêndice).

Tabela 4: Valores da Correlação de Pearson calculados para as variáveis de maior importância para o modelo Random Forest considerando o limiar de 100 metros (ALC 100m).

Variáveis independentes	Coefficiente de correlação
Número de áreas nucleares (ncore)	0,632
Declividade média (slope)	0,163
Borda total (TE)	0,570
Densidade de drenagem (DD)	0,298

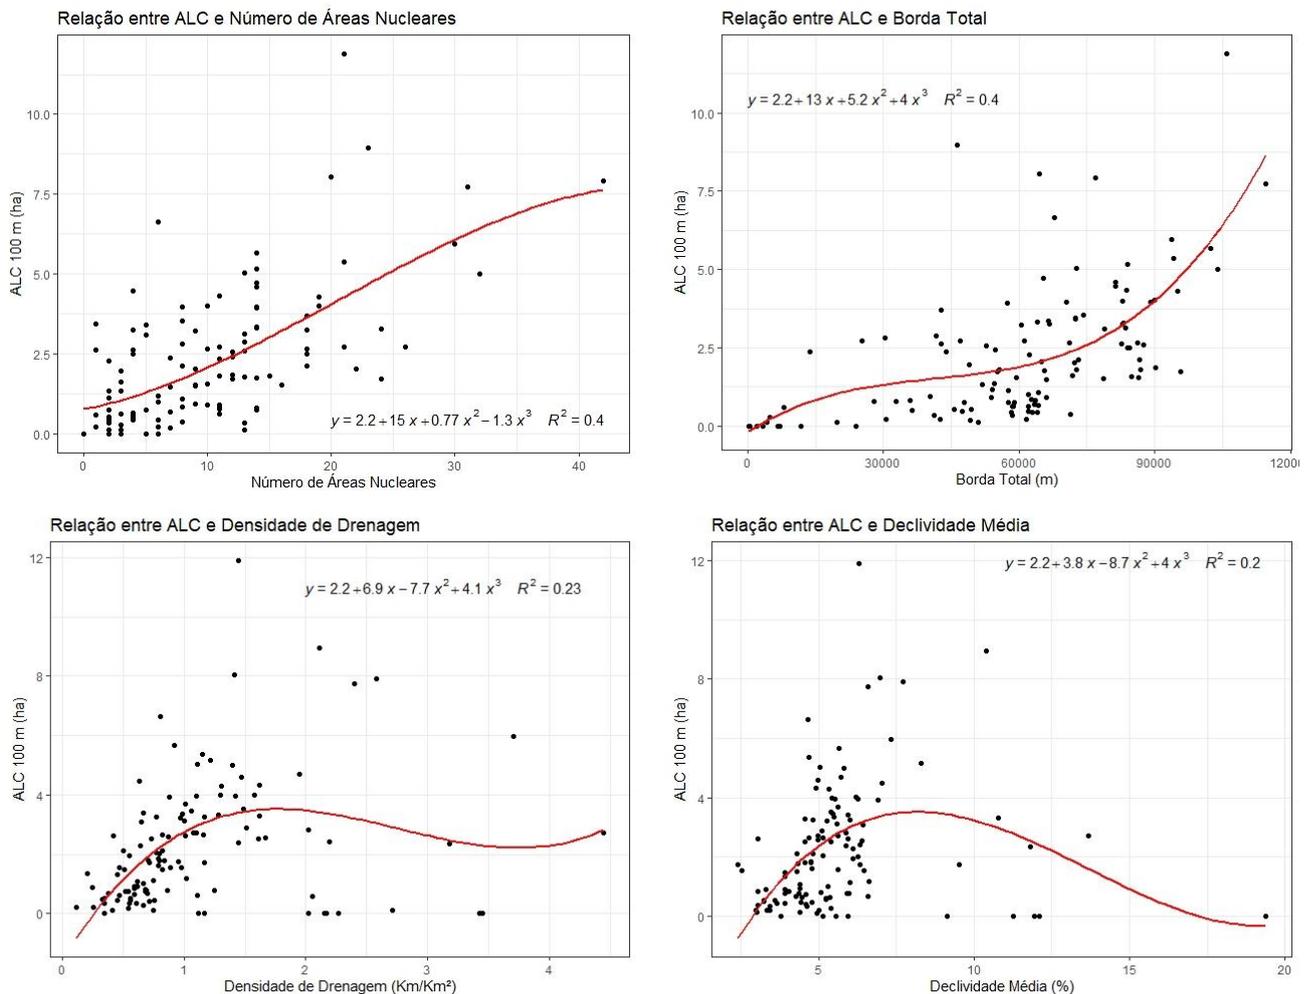


Figura 14: Gráficos de dispersão ilustrando a correlação entre a variável resposta e as explicativas mais importantes para o modelo Random Forest considerando o limiar de 100 metros (ALC 100m). Em cada gráfico também é apresentada a equação de ajuste polinomial de grau 3 e o valor de R^2 relativo a tal ajustamento.

Em seguida, após realizada a predição dos valores de ALC com as observações contidas no banco de dados de teste, a avaliação do desempenho de cada modelo resultou nas métricas

apresentadas na Tabela 5. Assim, conforme o esperado, nota-se que os menores valores de erro foram atribuídos às predições provenientes do modelo Random Forest, diferindo apenas para o MAE quando comparado ao Support Vector Machine. Neste contexto, interpretando diretamente o valor do MAE, pode-se dizer que os erros de predição do modelo Random Forest estão em torno de $\pm 1,19$ hectares.

Tabela 5: Valores de erro calculados para as predições de cada modelo considerando o limiar de 100 metros (ALC 100m).

Algoritmo	MAE	MAE relativo	RMSE	RMSE relativo	R² médio
RF	1,19	47,43%	1,80	71,78%	0,634
RPART	1,42	56,70%	1,91	76,51%	0,463
KNN	1,35	54,15%	1,96	78,33%	0,361
NNET	1,86	74,40%	2,92	116,66%	0,174
EARTH	1,49	59,72%	2,11	84,51%	0,453
SVMRADIAL	1,16	46,42%	1,82	72,83%	0,482

Por fim, os modelos foram utilizados para estimar os valores de ALC para as demais paisagens do estado de São Paulo considerando também os dois limiares de análise (50 e 100 metros), resultando na Figura 15. É importante mencionar que os resultados mais confiáveis são os provenientes do algoritmo Random Forest e, além disso, por terem sido obtidos de forma individual para cada unidade da paisagem delimitada ao longo do estado, foi possível ilustrar sua distribuição espacial (Figuras 16 e 17 – também apresentadas no Apêndice como Figuras 24 e 25).

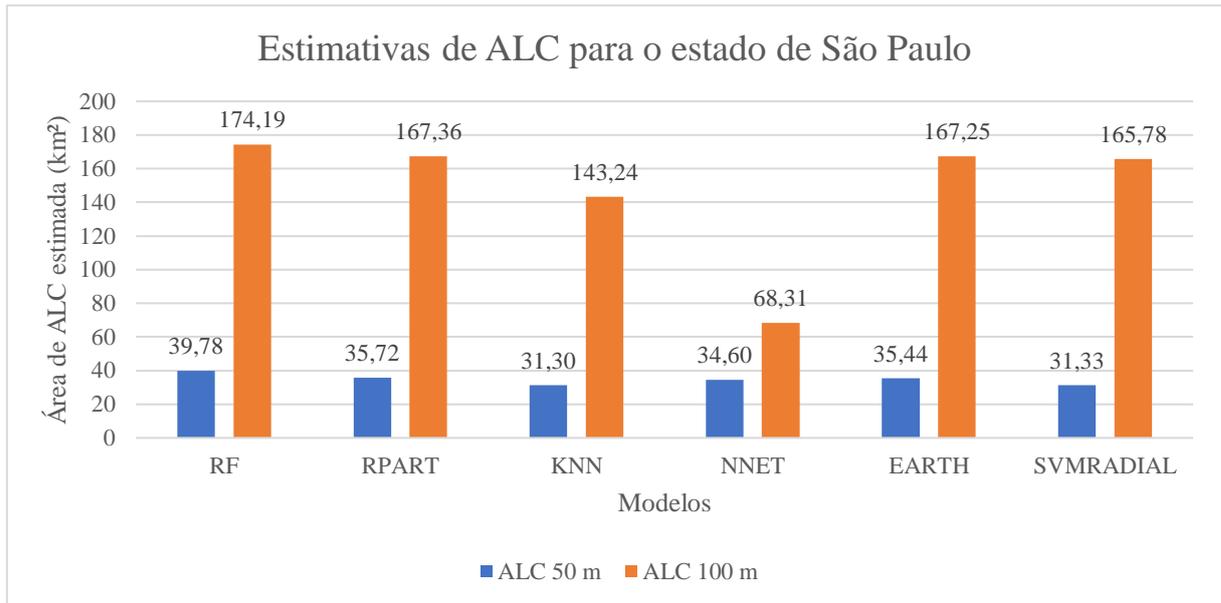


Figura 15: Estimativas de ALC para o estado de São Paulo considerando todos os modelos desenvolvidos e os limiares de 50 e 100 metros.

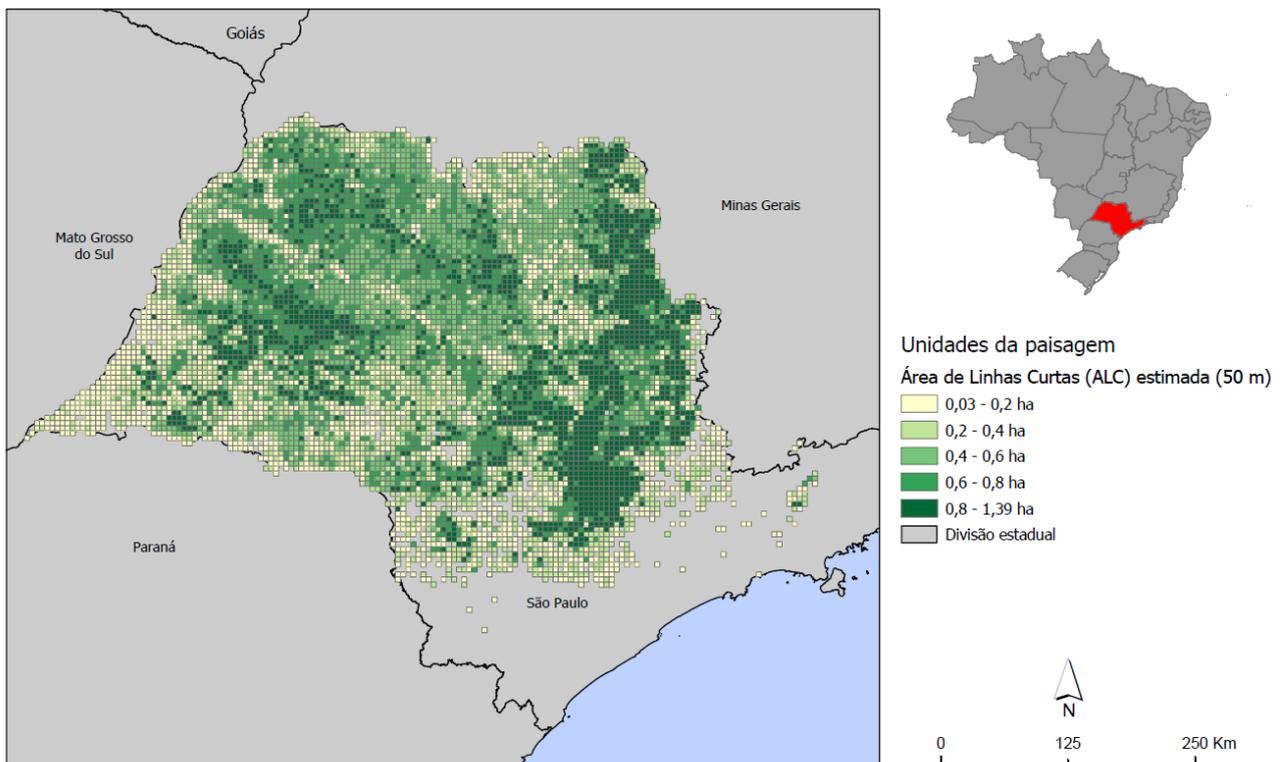


Figura 16: Distribuição espacial das estimativas de ALC de acordo com o modelo Random Forest considerando o limiar de 50 metros (ALC 50m).

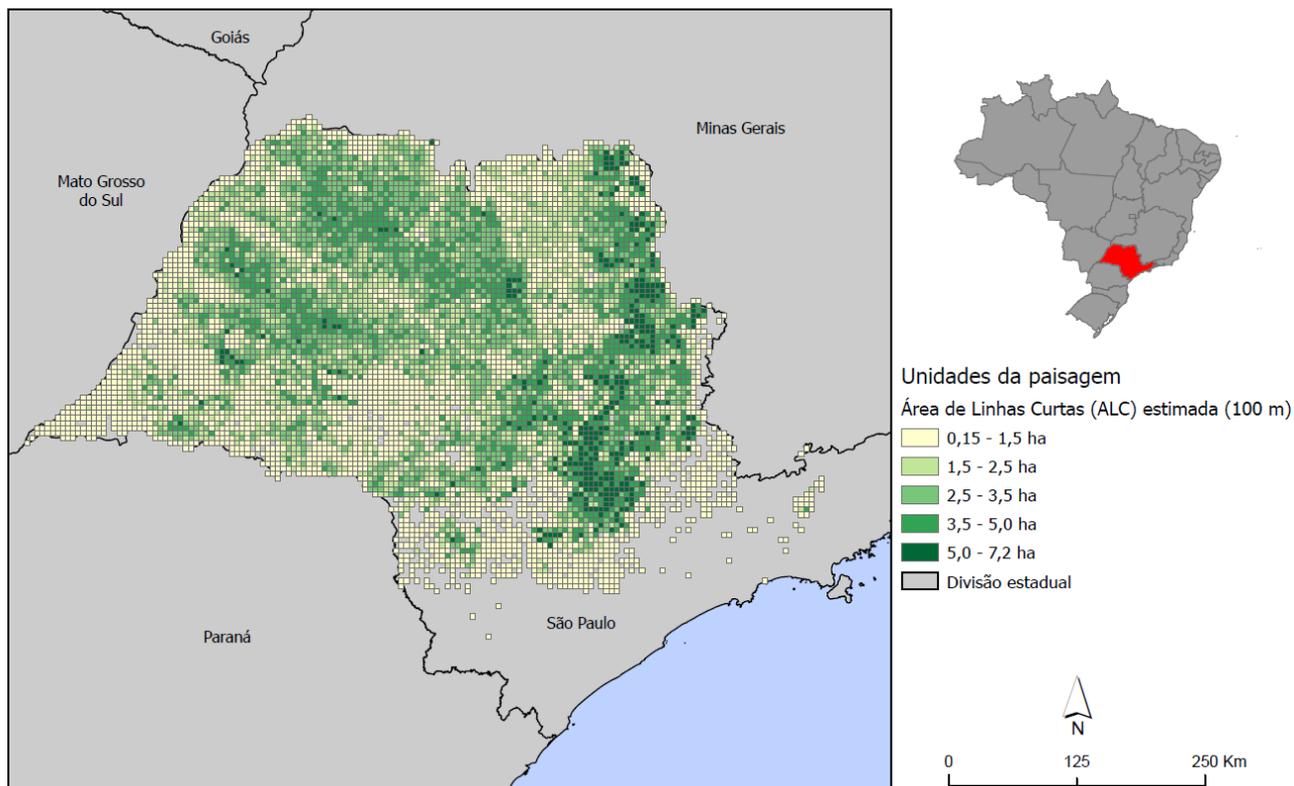


Figura 17: Distribuição espacial das estimativas de ALC de acordo com o modelo Random Forest considerando o limiar de 100 metros (ALC 100m).

4.3. Contribuição em relação ao déficit de RL

De forma geral, as ALC estimadas para as paisagens podem contribuir para mitigação do déficit de RL estadual nas proporções apresentadas na Tabela 6.

Tabela 6: Panorama geral de contribuição das ALC para mitigação do déficit de RL estadual, em paisagens contendo cana-de-açúcar a partir dos limiares de 50 e 100 metros (ALC 50m e ALC 100m).

Metragem de ALC	Área total estimada (km ²)	<i>Déficit₁</i>		<i>Déficit₂</i>	
		Valor total de déficit (km ²)	Percentual de mitigação (%)	Valor total de déficit (km ²)	Percentual de mitigação (%)
ALC 50 m	39,78	8.486,60	0,47	3.316,48	1,20
ALC 100 m	174,19		2,05		5,25

Conforme descrito na metodologia, a contribuição das ALC foi analisada em 4 cenários distintos e triados entre as paisagens onde a ALC supriu/excedeu a demanda de vegetação e onde foi insuficiente. Assim, a Tabela 7 contém o número de paisagens onde foi observado o excedente de ALC quando comparado ao déficit de RL (área de ALC superior ao valor de déficit) e a mensuração deste.

Tabela 7: Relação do número de paisagens com potencial de mitigação total do déficit de RL e mensuração do excedente de ALC considerando cada cenário proposto.

Cenário 1		Cenário 2		Cenário 3		Cenário 4	
Nº de paisagens	Excedente (ha)						
518	144,59	623	660,11	2551	1.248,30	2823	5.772,13

As demais paisagens estudadas foram compiladas de acordo com o percentual de mitigação atingido mediante a restauração das ALC e os resultados são ilustrados pelas Figuras 18 e 21 através de histogramas de distribuição de frequência.

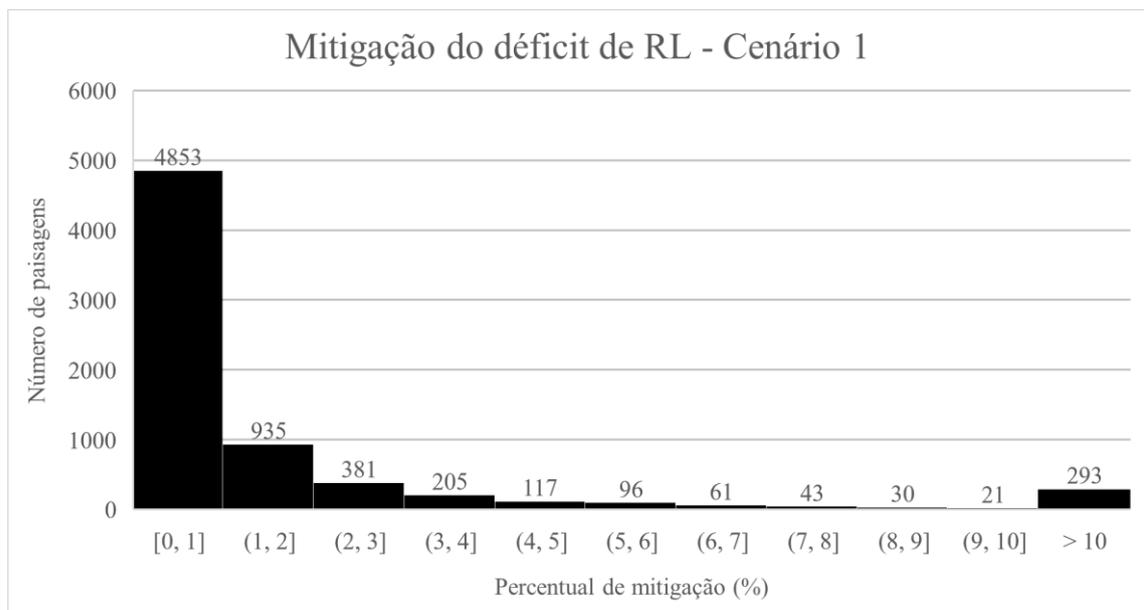


Figura 18: Histograma ilustrando o número de paisagens presentes em cada intervalo do percentual de mitigação do déficit de RL para o cenário 1.

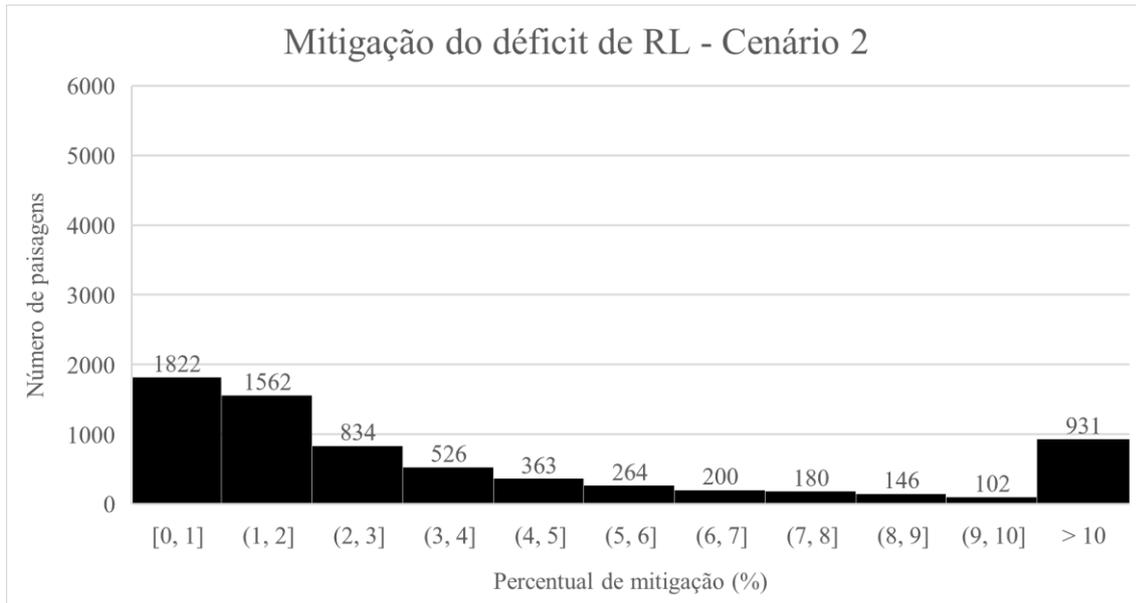


Figura 19: Histograma ilustrando o número de paisagens presentes em cada intervalo do percentual de mitigação do déficit de RL para o cenário 2.

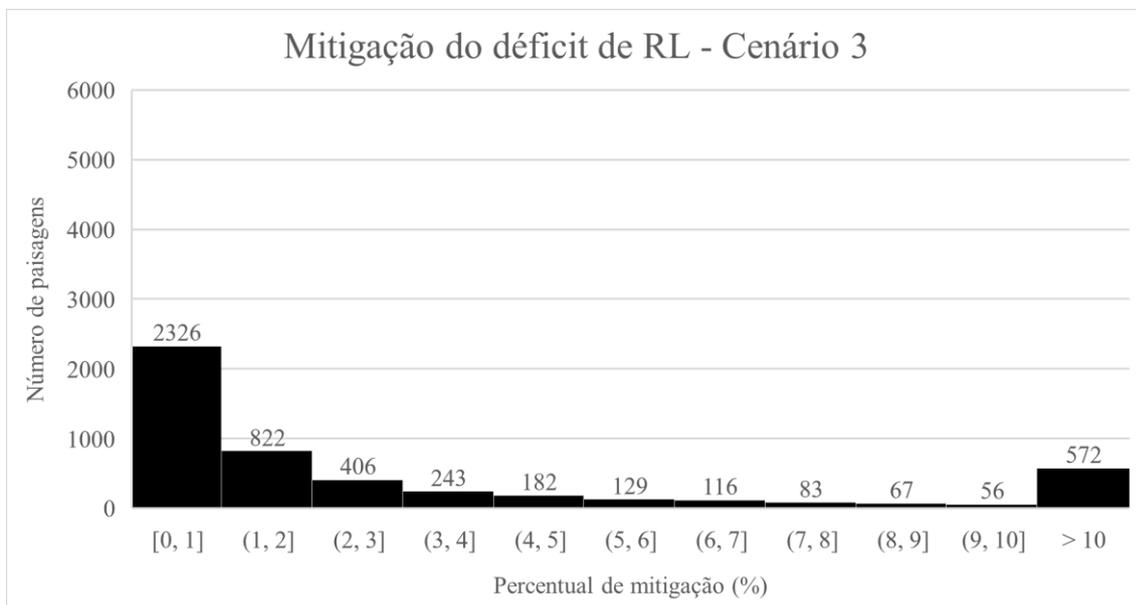


Figura 20: Histograma ilustrando o número de paisagens presentes em cada intervalo do percentual de mitigação do déficit de RL para o cenário 3.

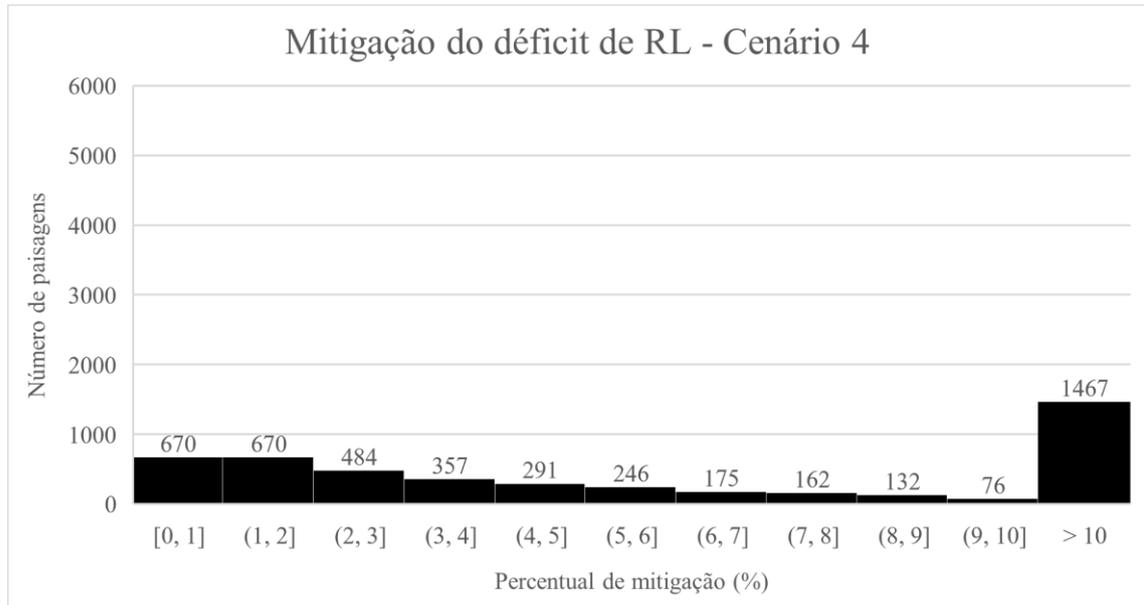


Figura 21: Histograma ilustrando o número de paisagens presentes em cada intervalo do percentual de mitigação do déficit de RL para o cenário 4.

5. DISCUSSÃO

5.1. Modelos e variáveis

Conforme apresentado no tópico anterior, os modelos que apresentaram os melhores resultados no contexto proposto foram os desenvolvidos a partir do algoritmo Random Forest, mostrando os maiores valores de R^2 e menores valores de RMSE e MAE para ambos os limiares de ALC, considerando inicialmente os resultados provenientes dos dados de treinamento. A aplicação dos modelos nos dados de teste (validação) confirmou que as melhores estimativas foram provenientes dos modelos do algoritmo Random Forest, apresentando os valores mais baixos de MAE e RMSE. Não obstante, pode-se inferir que o modelo para o limiar de 100 m teve melhor desempenho na adequação dos dados, com explicação da variância de 63,4% dos dados contra 45,1% do modelo do limiar de 50 m. Essa diferença pode ser justificada pela própria amplitude e a distribuição de valores das ALC mapeadas de acordo com cada limiar (muitas paisagens com valores baixos de ALC), evidenciando a dificuldade de relacionar a ocorrência de ALC pequenas a partir das variáveis explicativas aqui utilizadas (SHENDRYK, DAVY e THORBURN, 2021; CANATA et al., 2021; XU et al., 2020).

Em relação à importância das variáveis nos modelos, para ambos limiares, as de maior relevância foram Número de Áreas Nucleares, Declividade Média, Borda Total e Densidade de Drenagem. A quantidade de áreas nucleares está diretamente vinculada ao número de manchas individuais (desconexas) de cana-de-açúcar presentes na paisagem com tamanho significativo para garantir área após descontada a largura de borda (50 metros). A métrica de borda total apresenta relação com este conceito pois para se atingir um alto valor de borda, é necessária a presença de várias manchas desconexas. Contribuindo com esta relação, valores altos de densidade de drenagem indicam maior presença de córregos e rios, os quais transpassam e “recortam” a paisagem (especialmente quando são acompanhados por vegetação ciliar), corroborando com a fragmentação das manchas de cana-de-açúcar. Para garantir a presença de hidrografia, é necessário certo nível de declividade no terreno para ocasionar o escoamento de água, sendo o relevo também um fator influenciador dessa dinâmica.

Assim, em teoria, quanto maior o número de manchas grandes e desconexas de cana-de-açúcar acompanhadas pelo relevo característico de uma rede de drenagem densa, maiores seriam as chances de ocorrência de ALC. Contudo, por não se tratarem de relações lineares, para cada limiar modelado foram observados intervalos específicos destas variáveis explicativas que correspondem à ocorrência dos maiores valores estimados de ALC, conforme ilustrado pelos histogramas das Figuras 26 e 27 e pela Tabela 10 do Apêndice. O

comportamento não linear é uma característica já esperada e até pressuposta diante da utilização de modelos baseados no AM, e que foi evidenciada pelos baixos valores encontrados para os coeficientes de correlação de Pearson. Os maiores valores observados foram de 0,547 e 0,632, ambos referentes à variável de número de áreas nucleares e aos limiares 50 e 100 metros (respectivamente), apenas acenando para uma correlação positiva. Contudo, a interpretação dos coeficientes junto aos gráficos de dispersão (Figuras 11 e 14) torna evidente a correlação não linear entre as variáveis.

Além disso, é importante mencionar também a possibilidade de algumas das variáveis selecionadas para o estudo não apresentarem correlação suficiente para explicar a presença das ALC nos talhões de cana-de-açúcar, fato este que pode ser constatado apenas após o esforço de levantamento dos dados para todas as paisagens amostradas. Contudo, a remoção de variáveis avaliadas com menor importância pode impactar negativamente o desempenho dos modelos. Assim, uma possível alternativa seria identificar novas variáveis que apresentam maior correlação explicativa quanto à presença/quantidade de ALC nas paisagens. Dessa forma, os modelos desenvolvidos podem ser aprimorados e mostrar, por exemplo, que os resultados aqui constatados foram subestimados (GUYON e ELISSEEFF, 2003).

5.2. Implicações para a restauração de ecossistemas

A utilização dos modelos para estimar os valores de ALC, evidenciou para todas as 7.553 paisagens de 25 km² distribuídas ao longo do estado de São Paulo, valores relativamente baixos, com 39,78 km² e 174,19 km² estimados pelo Random Forest para os limiares de 50 e 100 metros, respectivamente. Este fato pode ser justificado pois, São Paulo foi uma das primeiras regiões a adotar procedimentos de mecanização no cultivo da cana-de-açúcar, permitindo que muitos procedimentos de reforma dos talhões de cultivo fossem realizados ao longo dos anos para se alcançar a geometria ideal de otimização das operações agrícolas mecanizadas; além da constante busca por melhorias proveniente de pesquisas científicas (JUNQUEIRA e MORABITO, 2017; SANTORO, SOLER e CHERRI, 2017; CONESA-MUÑOZ et al., 2016)

Sendo assim, considerando o próprio conceito aqui estabelecido para as ALC, é seguro inferir que o potencial incremento florestal ocasionado pela restauração dessas áreas se dará a partir da inserção de fragmentos florestais de tamanho reduzido na paisagem. Conforme discutido por Metzger (2000) e Gavioli, Molin e Valente (2022), diante de uma paisagem com matriz antropizada, pequenos fragmentos florestais próximos podem ser ecologicamente mais importantes do que remanescentes grandes isolados pois contribuem para a conectividade

florestal e também para a conservação da biodiversidade (embora que limitada principalmente em função do efeito de borda), atuando ainda como trampolins ecológicos. Além disso, as ALC são encontradas nas regiões marginais dos talhões de cana-de-açúcar, e com distâncias relativamente baixas de remanescentes florestais e APP ou, em alguns casos, nulas (são adjacentes – Tabelas 12 e 13). Dessa forma, a restauração dessas regiões pode ocasionar não apenas o ganho de cobertura de vegetação nativa (e potencial trampolim ecológico), mas também um incremento no tamanho médio dos fragmentos florestais da paisagem como um todo, contribuindo localmente para a redução do efeito de borda de tais fragmentos, aumento de área nuclear e conectividade da paisagem. Esta relação poderia ser verificada caso a metodologia aqui aplicada tivesse como objetivo a criação de um modelo espacialmente explícito para determinação exata das ALC em cada paisagem, assim, tal verificação se daria através do cálculo de métricas como Índice de Conectividade, Tamanho Médio e Número de Fragmentos em um cenário representativo da realidade e outro considerando a restauração virtual das ALC (ZANELLA et al., 2022; ARORA et al., 2021; SANTORO, G. B., 2019).

Corroborando com este pensamento, Rother et al. (2018) discutem em seu estudo de caso a importância dos limiares de preservação estabelecidos pela legislação ambiental brasileira, mas enfatizam que as metragens de APP muitas vezes não são extensas o suficiente para garantir um fluxo gênico ideal para espécies mais sensíveis aos efeitos de borda; indicando assim a importância de esforços de restauração que contribuam tanto para incremento florestal direto, quanto para o aumento da largura dos corredores ecológicos compostos por áreas ripárias. Simulando virtualmente o aumento no tamanho médio dos fragmentos ripários já existentes, os autores observaram o conseqüente aumento da área nuclear e índice de conectividade contrapostos à redução do número de fragmentos. Contudo, indicam ainda que o planejamento das ações de restauração é de fundamental importância, exigindo esforços complementares entre a restauração de APP e RL que excedem os limites das propriedades rurais buscando tornar a paisagem mais heterogênea como um todo, enquanto respeitando as especificidades de cada região. Nesse sentido, a abordagem de restauração das ALC se destaca por auxiliar tanto a exploração econômica agrícola (redução de gastos) e quanto o cumprimento da legislação ambiental e possível provisão de serviços ambientais vinculados à biodiversidade, sequestro de carbono, água, entre outros.

De forma geral, a restauração das ALC visando suprir o déficit de RL se mostrou válida, porém insuficiente, com contribuições mitigatórias potenciais que variaram entre 0,47% e 5,25% ao longo dos cenários propostos. É possível observar um comportamento de contribuição

crescente das ALC ao longo dos cenários analisando os percentuais de mitigação do déficit das paisagens onde não foi possível atingir a mitigação total, conforme mostram as Figuras 18 e 21. Assim, nota-se uma tendência de equalização de distribuição das paisagens em relação aos percentuais de mitigação conforme a mudança de cenários ocorre. Ainda que a contribuição geral de mitigação esteja alocada em patamares baixos, a Tabela 7 mostra que a restauração das ALC pode ocasionar a mitigação total do déficit de RL de 518 paisagens (C₁) até 2.551 (C₄); mantendo ainda excedentes de ALC que variam ao longo dos cenários de 144,59 até 5.772,13 hectares, que por sua vez podem ser vendidos como CRA ou utilizados para compensação de RL de outras paisagens/propriedades ou ainda compor potenciais áreas de restauração motivadas por incentivos voluntários, como é o caso de pagamento por serviços ambientais e parcela do mercado de créditos de carbono.

De acordo com Mello et al. (2021), a Mata Atlântica e o Cerrado são os únicos biomas brasileiros nos quais não é possível mitigar totalmente o déficit de RL apenas com estratégias de compensação ambiental externas às propriedades e em acordo com a similaridade ecológica entre as regiões relacionadas (utilização de vegetação nativa já existente de fora da propriedade), simplesmente pelo fato de não existir excedente de vegetação suficiente para suprir a demanda existente. Sendo assim, diversas regiões serão capazes de atingir a mitigação apenas através da restauração florestal no local. A restauração das ALC pode contribuir para a melhoria do cenário ambiental de ambos os biomas, que por sua vez possuem extrema importância no contexto mundial de conservação da biodiversidade e são amplamente ameaçados pela conversão de usos da terra, sendo caracterizados como hotspots de conservação (MITTERMEIER et al., 2011). Ademais, tais regiões marginais do ponto de vista agrícola, próximas a remanescentes florestais, hidrografia e APP, constituem áreas privilegiadas para a restauração ecológica passiva através da condução da regeneração natural, incrementando a cobertura florestal com uma melhor relação custo-efetividade (MOLIN et al., 2018).

Assim, apesar das ALC representarem um quantitativo baixo de mitigação do déficit de RL, os esforços de restauração são bem vistos frente a década da restauração de ecossistemas e aos compromissos ambiciosos estabelecidos pelo Brasil em âmbito internacional (METZGER e BRANCALION, 2013; BRANCALION et al., 2016). Além disso, é evidente a importância dos remanescentes florestais inseridos em regiões de forte atividade econômica (neste caso, agrícola) e alta densidade populacional. Essas características condizem com a realidade da Mata Atlântica, bioma que ocupa mais de 80% do estado de São Paulo e concentra aproximadamente 70% da população brasileira, sendo responsável também por cerca de 70% do PIB nacional. A fragmentação deste bioma hoje é observada pela pressão de áreas de cultivo agrícola

(especialmente da cana-de-açúcar) e de pastagens. Assim, a conservação e/ou restauração de fragmentos florestais, ainda que pequenos, contribuem para a provisão de serviços ecossistêmicos relacionados ao sequestro de carbono; manutenção da biodiversidade; ciclagem de água e nutrientes; e também controle de pragas (IBGE, 2019; SCHMIDT et al., 2019; MELLO et al., 2020; MITCHELL, BENNETT, e GONZALEZ, 2014; WEATHERS, CADENASSO e PICKETT, 2001).

Agregando outra perspectiva de contribuição, o estudo de Zanella, Schleyer e Speelman (2014) discutiu a adesão de proprietários rurais aos programas de PSA relacionados à provisão de água. Os autores apontaram que mesmo com a garantia de benefícios diante dos custos de oportunidade (uso do solo) apresentados por tais programas, o acesso à informação foi um dos fatores que mostrou contribuição mais relevante para explicar a adesão dos proprietários rurais. De acordo com as entrevistas de campo, os proprietários declararam que preferem ser contactados e informados diretamente por técnicos ou representantes dos órgãos responsáveis; contudo, as entrevistas aos gestores e coordenadores dos projetos de PSA revelaram uma maior preocupação destes com relação aos valores de pagamento e adequação de termos contratuais, acenando para o fato de que as estratégias de comunicação não possuem o devido destaque no contexto brasileiro. Além disso, os autores mostraram que os programas mais centralizados no governo e com estrutura de “cima para baixo” (“top-down”) costumam apresentar maior adesão dos proprietários rurais, porém não garantem um bom relacionamento entre as partes, impactando diretamente a confiança das relações e resultando em baixos níveis de satisfação por parte dos agricultores. Neste sentido, a restauração das ALC no contexto de PSA pode ser favorecida por naturalmente já contribuir com as questões de custo de oportunidade e, aliada à esta perspectiva, a abordagem pode ainda ser conduzida em programas com estrutura de governança mais descentralizados, com contato e diálogo direto entre as partes, o que contribui para a construção de uma relação de confiança (SOMMERVILLE et al., 2010). Destaca-se aqui também que a disseminação de informação e os esforços de convencimento devem ser direcionados também para as usinas de cana-de-açúcar, que possuem grandes áreas destinadas à produção da cultura que nem sempre estão ambientalmente regulares.

Diante do grande déficit de RL do estado, o cadastramento das ALC restauradas como CRA pode também ser um atrativo. Segundo Aguiar et al. (2017), a utilização das CRA é interessante para regularização de imóveis rurais dedicados à atividade agrícola, onde o custo de oportunidade da terra é muito alto para permitir a restauração ecológica. Nesse sentido, a restauração das ALC em imóveis destinados à produção da cana-de-açúcar ganha força por se

caracterizar como uma região financeiramente inviável para o cultivo. Além disso, caso esta abordagem seja adotada por imóveis que não apresentam irregularidades ambientais (déficit de APP e RL), as ALC restauradas passarão a constituir regiões florestais mais valorizadas do ponto de vista ecológico, constituindo excedentes de vegetação nativa e resultando na adicionalidade da proteção florestal (GAVIOLLI et al., 2020; AGUIAR et al., 2017).

O aumento das iniciativas de restauração ecológica na Mata Atlântica foi observado a partir do ano 2000 e motivado por três principais causas: atividades ambientais promovidas por Organizações Não-Governamentais (ONGs); Empresas privadas cumprindo compensações em acordo com a legislação e/ou buscando benefícios no mercado; e proprietários rurais também cumprindo a legislação ambiental vigente. A atuação das ONGs, na maioria das vezes, dependeu (e ainda depende) do convencimento de proprietários rurais a permitirem a implantação de projetos de restauração em suas terras, o que não é atrativo pois envolve principalmente a conversão de áreas agrícolas em ecossistemas nativos e também exige investimento de tempo e dinheiro no processo. Neste sentido, a restauração das ALC pode representar uma abordagem atrativa para o proprietário rural produtor de cana-de-açúcar e também para as usinas, uma vez que parte do princípio de que a colheita mecanizada no local é financeiramente inviável. Assim, essas regiões apresentam potencial para auxiliar políticas e projetos de restauração pontuais que abordam a problemática a partir de uma perspectiva diferente, explorando a otimização agrícola como estratégia de convencimento de proprietários rurais e podendo ainda envolver outros atrativos como os PSA e as CRA (PINTO et al., 2014).

6. CONCLUSÃO

Através do uso de geotecnologias e de uma abordagem de modelagem matemática embasada nas técnicas de aprendizado de máquina, torna-se claro o potencial de contribuição da restauração das ALC para auxiliar no planejamento de projetos de restauração ecológica no estado de São Paulo conduzidos por iniciativa privada, ONGs ou mesmo políticas públicas; contribuindo para mitigação parcial do déficit de RL. Conforme constatado, embora as ALC contribuam para a redução do déficit em patamares baixos, elas representam uma abordagem eficiente para identificação de regiões passíveis de restauração, e que também podem auxiliar no convencimento dos proprietários rurais pois envolve a utilização de regiões agrícolas (da cana-de-açúcar) onde a colheita mecanizada é financeiramente inviável.

Deste modo, e a partir do presente trabalho, estudos futuros poderão (1) aprimorar os modelos desenvolvidos a partir do teste de outras variáveis e algoritmos; (2) promover a identificação espacialmente explícita das ALC nas paisagens; (3) estimar o potencial de regeneração natural nas ALC identificadas; (4) expandir os estudos para outras regiões produtoras de cana-de-açúcar; (5) elaborar modelos semelhantes para demais culturas agrícolas de relevância no cenário brasileiro, como milho e soja.

REFERÊNCIAS

- AGUIAR, R; ENDRES, J.M; TAYLOR, C; EVANS, S. Public Conservation Policies on Private Land: A Case Study of the Brazilian Forest Code and Implications for the Agro-Industry Sector. **Pace Environmental Law Review**, v. 34, 2017. <https://digitalcommons.pace.edu/pelr/vol34/iss2/3>.
- ALBRECHT, T. et al. Using Machine Learning to Map Western Australian Landscapes for Mineral Exploration. **International Journal of Geo-Information**, [S.L.], v. 10, n. 7, p. 459, 6 jul. 2021. MDPI AG. <http://dx.doi.org/10.3390/ijgi10070459>.
- ALKIMIM, A.; SPAROVEK, G.; CLARKE, K. C. Converting Brazil's pastures to cropland: an alternative way to meet sugarcane demand and to spare forestlands. **Applied Geography**, [S.L.], v. 62, p. 75-84, ago. 2015. Elsevier BV. <http://dx.doi.org/10.1016/j.apgeog.2015.04.008>.
- ARONSON, J. Custos e benefícios da perspectiva de restauração do capital natural. In: BRANCALION, GANDOLFI e RODRIGUES (Ed.). **Restauração Florestal**. São Paulo, Oficina de textos, 2015. p. 23.
- ARORA, A.; PANDEY, M.; MISHRA, V. N.; KUMAR, R.; RAI, P. K.; COSTACHE, R.; PUNIA, M.; DI, L. Comparative evaluation of geospatial scenario-based land change simulation models using landscape metrics. **Ecological Indicators**, [S.L.], v. 128, p. 107810, set. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.ecolind.2021.107810>.
- ARROYO-RODRÍGUEZ, V. et al. Designing optimal human-modified landscapes for forest biodiversity conservation. **Ecology Letters**, [S.L.], v. 23, n. 9, p. 1404-1420, 15 jun. 2020. Wiley. <http://dx.doi.org/10.1111/ele.13535>.
- ARROYO-RODRIGUEZ, V. et al. Multiple successional pathways in human-modified tropical landscapes: New insights from forest succession, forest fragmentation and landscape ecology research. **Biol. Rev.** 2016. DOI: 10.1111/brv.12231.
- BAKER, Q. et al. Forecasting Dengue Fever Using Machine Learning Regression Techniques. 2021 12Th **International Conference On Information And Communication Systems (Icics)**, 24 maio 2021. IEEE. <http://dx.doi.org/10.1109/icics52457.2021.9464619>.
- BATISTA, M. T. F. Modelação geográfica em processos de caracterização e avaliação da paisagem numa perspectiva transfronteiriça. 264 f. Tese (Doutorado) - Curso de Ciências do Ambiente, Universidade de Évora, Évora, 2014.
- BORDA-NIÑO, M. et al. Drivers of tropical forest cover increase: A systematic review. **Land Degradation & Development**, 31, 1366–1379, 2020.
- BORDONAL, R. de O. et al. Sustainability of sugarcane production in Brazil. A review. **Agronomy For Sustainable Development**, [S.L.], v. 38, n. 2, 27 fev. 2018. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s13593-018-0490-x>.
- BRAIBANTE, M. E. F., et al. A Cana-de-Açúcar no Brasil sob um Olhar Químico e Histórico: Uma Abordagem Interdisciplinar. **Química Nova na Escola**, Santa Maria, v. 35, n. 1, p.3-10, fev. 2013.
- BRANCALION, P. H. S., et al. A critical analysis of the Native Vegetation Protection Law of Brazil (2012): updates and ongoing initiatives. **Natureza & Conservação**, V. 14, p 1-15, abr. 2016. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1679007316300020?via%3Dihub>. Acesso em: 05 out. 2020.
- BRANCALION, P. H. S., et al. Finding the money for tropical forest restoration. São Paulo: **Unasyiva** 239, Vol. 63, p. 25-34, 2012.

BRANCALION, P. H. S., GANDOLFI, S., RODRIGUES, R. R. **Restauração florestal**. São Paulo: Oficina de Textos, 2015. 428 p., 2015.

BRANCALION, P. H. S.; VIANI, R. A. G.; CALMON, M.; CARRASCOSA, H.; RODRIGUES, R. R. How to Organize a Large-Scale Ecological Restoration Program? The Framework Developed by the Atlantic Forest Restoration Pact in Brazil. **Journal of Sustainable Forestry**. v. 32, n. 7, p. 728-744, 3 out. 2013. Informa UK Limited.

BRASIL. Lei nº 12.631, de 25 de maio de 2012. Dispõe sobre a proteção da vegetação nativa; altera as Leis nº 6.938, de 31 de agosto de 1981, 9.393, de 19 de dezembro de 1996, e 11.428, de 22 de dezembro de 2006; revoga as Leis nº 4.771, de 15 de setembro de 1965, e 7.754, de 14 de abril de 1989, e a Medida Provisória nº 2.166-67, de 24 de agosto de 2001; e dá outras providências. Brasília, DF.

BRAUNBECK, O. A.; MAGALHÃES, P. S. G. Colheita de cana-de-açúcar com auxílio mecânico. Campinas, 1999. Disponível em: <http://www.agencia.cnptia.embrapa.br/Repositorio/Auxilio_Mecanico_Colheita_Cana_000fxew1k-ab02wyiv80soht9h8k862sp.pdf>. Acesso em: 01 set. 2020.

BREIMAN, L. Random forests. **Machine Learning** 45: 5–32, 2001.

BROCK, R.C., ARNELL, A., SIMONSON, W. et al. Implementing Brazil's Forest Code: a vital contribution to securing forests and conserving biodiversity. **Biodiversity and Conservation** 30, 1621–1635 (2021). <https://doi.org/10.1007/s10531-021-02159-x>

BUDOWSKI, G. **Distribution of tropical American rain forest species in the light of successional processes**. Turrialba 15: 40–42, 1965.

CANATA, T. F.; WEI, M. C. F.; MALDANER, L. F.; MOLIN, J. P. Sugarcane Yield Mapping Using High-Resolution Imagery Data and Machine Learning Technique. **Remote Sensing**, [S.L.], v. 13, n. 2, p. 232, 12 jan. 2021. MDPI AG. <http://dx.doi.org/10.3390/rs13020232>.

CAPAZ R. S., CARVALHO V. S. B., NOGUEIRA L. A. H. (2013) Impact of mechanization and previous burning reduction on GHG emissions of sugarcane harvesting operations in Brazil. **Applied Energy** 102:220–228. <https://doi.org/10.1016/j.apenergy.2012.09.049>.

CARVALHO, L. C., et al. Cana-de-açúcar e álcool combustível: histórico, sustentabilidade e segurança energética. **Enciclopédia Biosfera**, Goiânia, v. 9, n. 16, p.530-543, jul. 2013.

CHAPMAN D. S. et al. Random forest characterization of upland vegetation and management burning from aerial imagery. **Journal of Biogeography** 37(1):37–46, 2010.

CHAZDON, R. L. e GUARIGUATA, M. R. Natural regeneration as a tool for large-scale forest restoration in the tropics: prospects and challenges. **Biotropica**, [S.L.], v. 48, n. 6, p. 716-730, nov. 2016. Wiley. <http://dx.doi.org/10.1111/btp.12381>.

CHAZDON, R. L. e URIARTE, M. Natural regeneration in the context of large-scale forest and landscape restoration in the tropics. **Biotropica**. v. 48, n. 6, p. 709-715, nov. 2016. Wiley.

CHAZDON, R. L. Chance and determinism in tropical forest succession. Pages 384–408 in W. Carson and S. A. Schnitzer, eds. **Tropical forest community ecology**. John Wiley & Sons, West Sussex, UK, 2008.

CHAZDON, R. L. **Second Growth: the promise of tropical forest regeneration in an age of deforestation**. Chicago: The University of Chicago Press, 2014. 486 p.

CHAZDON, R. L., e GUARIGUATA, M. R. Natural regeneration as a tool for large-scale forest restoration in the tropics: prospects and challenges. **Biotropica**. v. 48, n. 6, p. 716-730, nov. 2016.

CHAZDON, R. L.; BRANCALION, P. H. S.; LAMB, D.; LAESTADIUS, L.; CALMON, M.; KUMAR, C. A Policy-Driven Knowledge Agenda for Global Forest and Landscape Restoration. **Conservation Letters**, [S.L.], v. 10, n. 1, p. 125-132, 4 jan. 2016. Wiley. <http://dx.doi.org/10.1111/conl.12220>.

CHAZDON, R. L.; GUTIERREZ, V.; BRANCALION, P. H. S.; LAESTADIUS, L.; GUARIGUATA, M. R. Co-Creating Conceptual and Working Frameworks for Implementing Forest and Landscape Restoration Based on Core Principles. **Forests**, 11, 706, 2020.

CHEN S. et al. An operational machine learning approach to predict mosquito abundance based on socioeconomic and landscape patterns. **Landscape Ecology** 34(6):1295–1311, 2019.

CHRISTENSEN M.; ARSANJANI J. J. Stimulating implementation of sustainable development goals and conservation action: predicting future land use/cover change in Virunga National Park, Congo. **Sustainability**. 2020. <https://doi.org/10.3390/su12041570>.

COELHO, M. F. Planejamento da qualidade no processo de colheita mecanizada da cana-de- açúcar. 2009. 75 f. Dissertação (Mestrado) - Curso de Agronomia, Universidade de São Paulo, Piracicaba, 2009.

COMPANHIA NACIONAL DE ABASTECIMENTO - CONAB. **Perfil do setor do açúcar e do etanol no Brasil: edição para a safra 2015/16**. Brasília, DF, 2019. Disponível em: <https://www.conab.gov.br/info-agro/safras/cana/perfil-do-setor-sucroalcooleiro>. Acesso em: 20 abr. 2022.

COMPANHIA NACIONAL DE ABASTECIMENTO - CONAB. **Série Histórica das Safras**. Brasília: 2021. Disponível em: <https://www.conab.gov.br/info-agro/safras/serie-historica-das-safras>. Acesso em: 01 maio 2022.

CONESA-MUÑOZ, J. et al. Route planning for agricultural tasks: a general approach for fleets of autonomous vehicles in site-specific herbicide applications. **Computers And Electronics In Agriculture**, [S.L.], v. 127, p. 204-220, set. 2016. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2016.06.012>.

CONSTANZA, R. et al. Twenty years of ecosystem services: how far have we come and how far do we still need to go? **Ecosystem Services**, v. 28, p. 1-16, dez. 2017. Elsevier. Disponível em: <http://dx.doi.org/10.1016/j.ecoser.2017.09.008>.

CONSTANZA, R., et al. The value of the world's ecosystem services and natural capital. **Nature** 387, 253–260. 1997. <https://doi.org.ez67.periodicos.capes.gov.br/10.1038/387253a0>

CRAWSHAW, D. et al. Caracterização dos Campos Sul-Rio-Grandenses: Uma Perspectiva da Ecologia da Paisagem. **Boletim Gaúcho de Geografia**, Porto Alegre, n. 33, p.233-252, dez. 2007. Disponível em: <<https://www.seer.ufrgs.br/bgg/article/view/37437/24182>>. Acesso em: 25 ago. 2019.

CROUZEILLES, R. et al. Associations between socio-environmental factors and landscape-scale biodiversity recovery in naturally regenerating tropical and subtropical forests. **Conservation Letters**, 14, 2021.

CURRY C. M. et al. Varying dataset resolution alters predictive accuracy of spatially explicit ensemble models for avian species distribution. **Ecology and Evolution** 8(24):12867–12878, 2018.

DIAS NETO, A.F., ALBIERO, D., ROSSETTO, R. et al. Modeling of Mechanized Sugarcane Harvesting to Support Decision-Making on Asset Management. **Sugar Tech** (2022). <https://doi.org/10.1007/s12355-022-01126-2>.

FAO (Food and Agriculture Organization), 2005. State of the world's forests. Departamento Florestal/FAO, Roma.

GALDOS M., CAVALETT O., SEABRA J. E. A., HORTA NOGUEIRA L. A., BONOMI A. (2013). Trends in global warming and human health impacts related to Brazilian sugarcane ethanol production considering black carbon emissions. **Applied Energy** 104:576–582. <https://doi.org/10.1016/j.apenergy.2012.11.002>.

GARCÍA-GUTIÉRREZ, J. et al. A comparison of machine learning regression techniques for LiDAR-derived estimation of forest variables. **Neurocomputing**, v. 167, p. 24-31, nov. 2015. Elsevier BV. <http://dx.doi.org/10.1016/j.neucom.2014.09.091>.

GAVIOLI, F. et al. Estrutura fundiária e conservação de florestas em propriedades rurais do circuito das frutas/sp: uma análise dos impactos da lei 12.651/2012 na conformação de reservas legais e cotas de reserva ambiental. **Caminhos de Geografia**, v. 21, n. 74, p. 241-258, 2 maio 2020. EDUFU - Editora da Universidade Federal de Uberlândia. <http://dx.doi.org/10.14393/rcg217450304>.

GAVIOLI, F. R.; MOLIN, P. G.; VALENTE, R. A. O papel das pequenas manchas florestais na qualidade ecológica de uma paisagem antropizada da Mata Atlântica. **Research, Society And Development**, [S.L.], v. 11, n. 6, p. 1-19, 1 maio 2022. Research, Society and Development. <http://dx.doi.org/10.33448/rsd-v11i6.29162>.

GEOLAB. Projeto Temático FAPESP: Código Florestal no estado de São Paulo. Passivos de Reserva Legal por propriedade no estado de São Paulo, 2019. Disponível em: <https://codigoflorestal.wixsite.com/tematico>.

GONÇALVES, R. C. et al. Desafios e perspectivas da produção de etanol no Brasil – uma revisão. **Revista Liberato**, Novo Hamburgo, v. 12, n. 18, p.123-132, jul. 2011.

GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE, R. Google Earth Engine: planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**. V. 202, p. 18-27, dez. 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2017.06.031>.

GUYON, I., & ELISSEEFF, A. (2003). An introduction to variable and feature selection. *Journal of Machine Learning Research*, 3, 11571182.

HARIMOORTHY, K. e THANGAVELU, M. Multi-disease prediction model using improved SVM-radial bias technique in healthcare monitoring system. **Journal of Ambient Intelligence and Humanized Computing**, 12, 3715–3723 (2021). <https://doi.org/10.1007/s12652-019-01652-0>

HOCENSKI, V. et al. Environmental impact estimation of ceramic tile industry using modeling with neural networks. **International Journal Of Electrical And Computer Engineering Systems**, v. 13, n. 13, p. 29-35, 3 fev. 2022. Faculty of Electrical Engineering, Computer Science and Information Technology Osijek. <http://dx.doi.org/10.32985/ijeces.13.1.4>.

HUANG B. et al. Urban land-use mapping using a deep convolutional neural network with high spatial resolution multispectral remote sensing imagery. **Remote Sensing of Environment** 214:73–86, 2018.

HUANG, JC. et al. Application and comparison of several machine learning algorithms and their integration models in regression problems. **Neural Comput & Applic** 32, 5461–5469 (2020). <https://doi.org/10.1007/s00521-019-04644-5>

IBGE. Mapa de biomas do Brasil, 2019. Brasil. Disponível em: <https://www.ibge.gov.br/geociencias/informacoes-ambientais>.

IMAFLOA. Atlas da Agropecuária Brasileira, 2017. Brasil. Disponível em: <http://atlasagropecuario.imaflora.org/>.

INSTITUTO FLORESTAL – IF. Inventário florestal do estado de São Paulo: Mapeamento da Cobertura Vegetal Nativa. Brasil, 2020. Disponível em: <https://www.infraestruturameioambiente.sp.gov.br>

JUNQUEIRA, R. de A. R.; MORABITO, R. Abordagens de otimização para a programação e sequenciamento das frentes de colheita de cana-de-açúcar. **Gestão & Produção**, [S.L.], v. 24, n. 2, p. 407-422, 1 jun. 2017. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/0104-530x1882-16>.

- JUNQUEIRA, R. de A. R.; MORABITO, R. Modeling and solving a sugarcane harvest front scheduling problem. **International Journal Of Production Economics**, [S.L.], v. 213, p. 150-160, jul. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.ijpe.2019.03.009>.
- KENNEDY R. E. et al. Attribution of disturbance change agent from Landsat time-series in support of habitat monitoring in the Puget Sound region, USA. **Remote Sensing of Environment** 166:271–285, 2015.
- KLEIN, B. C.; SAMPAIO, I. L. de M.; MANTELATTO, P. E.; MACIEL FILHO, R.; BONOMI, A. Beyond ethanol, sugar, and electricity: a critical review of product diversification in Brazilian sugarcane mills. **Biofuels, Bioproducts And Biorefining**, [S.L.], v. 13, n. 3, p. 809-821, 21 jan. 2019. Wiley. <http://dx.doi.org/10.1002/bbb.1969>.
- KOTSARIANTIS, S.B. Supervised Machine Learning: A review of classification techniques. In: **Emerging Artificial Intelligence Applications in Computer Engineering**. V. 160, 22 p. 2007. IOS Press, Netherlands.
- LIAKOS, K. et al. Machine Learning in Agriculture: a review. **Sensors**, [S.L.], v. 18, n. 8, p. 2674, 14 ago. 2018. MDPI AG. Disponível em: <http://dx.doi.org/10.3390/s18082674>.
- LORENA, A. et al. Comparing machine learning classifiers in potential distribution modelling. **Expert Systems with Applications**, v. 38, n. 5, p. 5268-5275, maio 2011. Elsevier BV. <http://dx.doi.org/10.1016/j.eswa.2010.10.031>.
- LYRA, G. A. Consumo de combustível de duas colhedoras de canade- açúcar em função da velocidade e rotação de motor. 2012. 66 f. Dissertação (Mestrado) - Curso de Agronomia, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Botucatu, 2012.
- MAHESH, B. Machine learning algorithms – A Review. **International Journal of Science and Research**. V. 09, 381-386 p. 01 jan. 2020.
- MARTINS FILHO M. V., LICCIOTI T. T., PEREIRA G. T., MARQUES JÚNIOR J., SANCHEZ R. B. (2009). Perdas de solo e nutrientes por erosão num Argissolo com resíduos vegetais de cana-de-açúcar. **Engenharia Agrícola** 29:8–18. <https://doi.org/10.1590/S0100-69162009000100002>.
- MARTINS, S. V. et al. Potencial de Regeneração Natural de Florestas Nativas nas Diferentes Regiões do Estado do Espírito Santo. CEDAGRO, Vitória, ES, Brazil, 2014.
- MAULUD, D. & ABDULAZEEZ, A. M. A Review on Linear Regression Comprehensive in Machine Learning. **Journal of Applied Science and Technology Trends**, [S.L.], v. 1, n. 4, p. 140-147, 31 dez. 2020. Interdisciplinary Publishing Academia. <http://dx.doi.org/10.38094/jastt1457>.
- MELLO, K. de; FENDRICH, A. N.; SPAROVEK, G.; SIMMONDS, J. S.; MARON, M.; TAVARES, P. A.; BRITES, A. D.; RODRIGUES, R. R.; JOLY, C. A.; METZGER, J. P. Achieving private conservation targets in Brazil through restoration and compensation schemes without impairing productive lands. **Environmental Science & Policy**, [S.L.], v. 120, p. 1-10, jun. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.envsci.2021.02.014>.
- MELLO, K., TANIWAKI, R. H., PAULO, F. R., VALENTE, R. A., RANDHIR, T. O., MACEDO, D. R., LEAL C. G., RODRIGUES, C. B., & HUGHES, R. M. (2020) Multiscale land use impacts on water quality: Assessment, planning, and future perspectives in Brazil. **Journal of Environmental Management**, 270, 1-16. <https://doi.org/10.1016/j.jenvman.2020.110879>
- METZGER, J. P. Tree Functional Group Richness and Landscape Structure in a Brazilian Tropical Fragmented Landscape. **Ecological Applications**, v. 10, n. 4, p. 1147-1161, ago. 2000. Wiley. [http://dx.doi.org/10.1890/1051-0761\(2000\)010\[1147:tfgral\]2.0.co;2](http://dx.doi.org/10.1890/1051-0761(2000)010[1147:tfgral]2.0.co;2).

METZGER, J. P. W.; BRANCALION, P. H. S. Challenges and opportunities in applying a landscape ecology perspective in ecological restoration: a powerful approach to shape neolandscapes. **Natureza & Conservação**, Curitiba, n. 2, p. 103-107, 2013. Disponível em: <<http://doi.editoracubo.com.br/10.4322/natcon.2013.018>> DOI: 10.4322/natcon.2013.018.

METZGER, J. P. W.; BRANCALION, P. H. S. Challenges and opportunities in applying a landscape ecology perspective in ecological restoration: a powerful approach to shape neolandscapes. **Natureza & Conservação**, Curitiba, n. 2, p. 103-107, 2013.

Millennium Ecosystem Assessment (MEA). 2005. **Ecosystems and Human Well-Being: Synthesis**. Island Press

MITCHELL, M. G. E., BENNETT, E. M., & GONZALEZ, A. (2014). Forest fragments modulate the provision of multiple ecosystem services. **Journal of Applied Ecology**, 51, 909–918. <https://doi.org/10.1111/1365-2664.12241>

MITTERMEIER, R. A.; TURNER, W. R.; LARSEN, F. W.; BROOKS, T. M.; GASCON, C. Global Biodiversity Conservation: the critical role of hotspots. **Biodiversity Hotspots**, [S.L.], p. 3-22, 2011. Springer Berlin Heidelberg. http://dx.doi.org/10.1007/978-3-642-20992-5_1.

MOLIN, P. G. Dynamic modeling of native vegetation in the Piracicaba river basin and its effects on ecosystem services. 2014. 148 f. Thesis (Doctor degree) – Forest resources program, Universidade de São Paulo, Piracicaba, 2014.

MOLIN, P. G. Dynamic modeling of native vegetation in the Piracicaba river basin and its effects on ecosystem services. 2014. 148 f. Thesis (Doctor degree) – Forest resources program, Universidade de São Paulo, Piracicaba, 2014.

MOLIN, P. G. Ineficiência operacional agrícola gerando oportunidades de restauração. **In: X Simpósio Brasileiro Sobre Tecnologia De Sementes Florestais**, Belo Horizonte, 2018.

MOLIN, P. G.; CHAZDON, R.; FERRAZ, S. F. B.; BRANCALION, P. H. S. A landscape approach for cost-effective large-scale forest restoration. **Journal of Applied Ecology**, v. 1, p. 1, 2018.

MOLIN, P. G.; GERGEL, S. E.; SOARES-FILHO, B. S.; FERRAZ, S. F. B. Spatial determinants of Atlantic Forest loss and recovery in Brazil. **Landscape Ecology**, v. 1, p. 1, 2017.

MORAES, E. E. Avaliação das perdas invisíveis de cana-de-açúcar (*Saccharum* spp.) e impurezas vegetais na colheita mecanizada. 1992. 124p. Dissertação (Mestrado em Máquinas Agrícolas) - Faculdade de Engenharia Agrícola. Universidade Estadual de Campinas.

NEVES, J. L. M.; MAGALHAES, P. S. G. e OTA, W. M. Sistema de monitoramento de perdas visíveis de cana-de-açúcar em colhedora de cana picada. **Engenharia Agrícola**. 2004, vol.24, n.3, pp.764-770. ISSN 1809-4430. Disponível em: <https://doi.org/10.1590/S0100-69162004000300030>. Acesso em 05 nov. 2020.

PACHECO, R. et al. Regularização do passivo de reserva legal: percepção dos produtores rurais no Pará e Mato Grosso. **Ambiente e Sociedade**, São Paulo, v. 20, n. 2, p.185-206, jun. 2017. Disponível em: <http://www.scielo.br/scielo.php?pid=S1414-753X2017000200181&script=sci_arttext&tlng=pt>.

PARRAS, R. et al. The Configuration of Forest Cover in Ribeirão Preto: a diagnosis of Brazil's forest code implementation. **Sustainability**, [S.L.], v. 12, n. 14, p. 5686, 15 jul. 2020. MDPI AG. <http://dx.doi.org/10.3390/su12145686>.

PAZUR R, et al. Abandonment and recultivation of agricultural lands in Slovakia-patterns and determinants from the past to the future. **Land** 9(9):316, 2020.

PINTO, S.R.; MELO, F.; TABARELLI, M.; PADOVESI, A.; MESQUITA, C.A.; DE MATTOS SCARAMUZZA, C.A.; CASTRO, P.; CARRASCOSA, H.; CALMON, M.; RODRIGUES, R.; CÉSAR, R.G.; BRANCALION, P.H.S. Governing and Delivering a Biome-Wide Restoration Initiative: The Case of Atlantic Forest Restoration Pact in Brazil. **Forests** 2014, 5, 2212-2229. <https://doi.org/10.3390/f5092212>

PRIETO, P. V. et al. Predicting landscape-scale biodiversity recovery by natural tropical forest regrowth. **Conservation Biology**, v. 36, n. 3, 27 out. 2021. Wiley. <http://dx.doi.org/10.1111/cobi.13842>.

PROJETO MAPBIOMAS – Coleção 5 da Série Anual de Mapas de Cobertura e Uso de Solo do Brasil, acessado em 23 de outubro de 2020. Disponível em: <https://mapbiomas.org/>

R CORE TEAM (2021). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.

RIPOLI, T. C. C. Ensaio & certificação de máquinas para colheita de cana-de-açúcar. In: **Máquinas agrícolas: ensaio e certificação**. Piracicaba: FEALQ, 1996. cap.13, p. 635-673.

RODRIGUES, R. R. et al. 2009. On the restoration of high diversity forests: 30 years of experience in the Brazilian Atlantic Forest. **Biological Conservation**, São Paulo, v. 142, n. 6, p. 1242-1251, 10 jan. 2009.

ROSS S. et al. Listening to ecosystems: data-rich acoustic monitoring through landscape-scale sensor networks. **Ecological Research** 33(1):135–147, 2018.

ROTHER, D. C et al. How Legal-Oriented Restoration Programs Enhance Landscape Connectivity? Insights From the Brazilian Atlantic Forest. **Tropical Conservation Science**, v. 11, p. 194008291878507, jan. 2018. SAGE Publications. <http://dx.doi.org/10.1177/1940082918785076>.

SAMUEL, A.L. Some Studies in Machine Learning Using the Game of Checkers. **IBM J. Res. Dev.** 1959, 44, 206–226.

SANTORO, E.; SOLER, E.M.; CHERRI, A.C. Route optimization in mechanized sugarcane harvesting. **Computers and Electronics in Agriculture**, [S.L.], v. 141, p. 140-146, set. 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2017.07.013>.

SANTORO, G. B. Ineficiência operacional agrícola na cultura de cana-de-açúcar gerando oportunidades de restauração florestal. 2019. 67 f. TCC (Graduação) - Curso de Engenharia Ambiental, Centro de Ciências da Natureza, Universidade Federal de São Carlos, Buri, 2019.

SARKER, T. C. et al. Recent Advances in Sugarcane Industry Solid By-Products Valorization. **Waste And Biomass Valorization**, [S.L.], v. 8, n. 2, p. 241-266, 24 ago. 2016. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s12649-016-9665-3>.

SCHMIDT JUNIOR, J. C. Avaliação de desempenho efetivo de colhedora de cana-de-açúcar (*Saccharum spp*). 2011. 110 f. Dissertação (Mestrado) - Curso de Máquinas Agrícolas, Universidade de São Paulo, Piracicaba, 2011. Disponível em: https://www.teses.usp.br/teses/disponiveis/11/111148/tde-23112011-094646/publico/JOAO_CONRADO_SCHMIDT_JUNIOR.pdf. Acesso em: 23 ago. 2019.

SCHMIDT, K., MARTÍN-LÓPEZ, B., PHILLIPS, P. M., JULIUS, E., MAKAN, N., & WALZ, A. (2019) Key landscape features in the provision of ecosystem services: insights for management. **Land Use Policy**, 82, 353-366. <https://doi.org/10.1016/j.landusepol.2018.12.02>.

SCHONLAU, M. e ZOU, R. Y. The random forest algorithm for statistical learning. **The Stata Journal: Promoting communications on statistics and Stata**, [S.L.], v. 20, n. 1, p. 3-29, mar. 2020. SAGE Publications. <http://dx.doi.org/10.1177/1536867x20909688>.

SCHWEIZER, D. et al. Natural forest regrowth under different land use intensities and landscape configurations in the Brazilian Atlantic Forest. **Forest Ecology and Management**, v. 508, mar. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.foreco.2022.120012>.

SER (Society for Ecological Restoration). 2004. **The SER International primer on ecological restoration**.

SEYYEDHASANI, H.; DVORAK, J. S. Using the Vehicle Routing Problem to reduce field completion times with multiple machines. **Computers and Electronics in Agriculture**, [S.L.], v. 134, p. 142-150, mar. 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2016.11.010>.

SHAFIZADEH-MOGHADAM H, et al. Integration of genetic algorithm and multiple kernel support vector regression for modeling urban growth. **Computers Environment Urban Systems** 65:28–40, 2017.

SHENDRYK, Y.; DAVY, R.; THORBURN, P. Integrating satellite imagery and environmental data to predict field-level cane and sugar yields in Australia using machine learning. **Field Crops Research**, [S.L.], v. 260, p. 107984, jan. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.fcr.2020.107984>.

SINDHU, R. et al. Bioconversion of sugarcane crop residue for value added products – An overview. **Renewable Energy**, [S.L.], v. 98, p. 203-215, dez. 2016. Elsevier BV. <http://dx.doi.org/10.1016/j.renene.2016.02.057>.

SOARES-FILHO, B. et al. Cracking Brazil's Forest Code. **Science**, v. 344, p.344-363, abr. 2014. Disponível em: <http://lerf.eco.br/img/publicacoes/Soares_Filho_et_al_2014_artigo_Science.pdf>. Acesso em: 25 ago. 2019.

SOMMERVILLE, M.; JONES, J.P.G.; RAHAJAHARISON, M.; MILNER-GULLAND, E.J. The role of fairness and benefit distribution in community-based payment for environmental services interventions: a case study from Menabe, Madagascar. **Ecol. Econ.**, 69 (2010), pp. 1262-1271.

SPAROVEK G. et al. A revisão do código florestal brasileiro. **Novos Estudos-CEBRAP**, 89 (2011), pp. 111-135.

SPEKKEN, M. et al. Planning machine paths and row crop patterns on steep surfaces to minimize soil erosion. **Computers and Electronics in Agriculture**, [S.L.], v. 124, p. 194-210, jun. 2016. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2016.03.013>.

SPEKKEN, M; MOLIN, J. P; ROMANELLI, T. L. Cost of boundary manoeuvres in sugarcane production. **Biosystem Engineering**, São Paulo, p.112-126, mar. 2014.

STUPARIU, M. S. et al. Machine learning in landscape ecological analysis: a review of recent approaches. **Landscape Ecology** 37, 1227–1250 (2022). <https://doi.org/10.1007/s10980-021-01366-9>.

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. 2012. Disponível em: <https://doi.org/10.1016/j.ecolind.2012.02.013>.

TAVARES, P. A. et al. Testing temporal benchmarks effects on the implementation of the new Brazilian Forest Act. **Environmental Science & Policy**, [S.L.], v. 126, p. 213-222, dez. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.envsci.2021.09.024>.

TAVARES, P. A. et al. Unfolding additional massive cutback effects of the Native Vegetation Protection Law on Legal Reserves, Brazil. **Biota Neotropica**, Campinas, v. 19, n. 4, p. 1-9, 29 jul. 2019.

TROLL, C. Landscape ecology (geoecology) and biogeocenology – A terminological study. **Geoforum**, Oxford, v. 2, n. 4, p. 43-46, jan. 1971. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/0016718571900297>. Acesso em 04 nov. 2020.

UDDIN, S. et al. Comparing different supervised machine learning algorithms for disease prediction. **BMC Med Inform Decis Mak** 19, 281 (2019). <https://doi.org/10.1186/s12911-019-1004-8>

UNIÃO DA INDÚSTRIA DE CANA-DE-AÇÚCAR (UNICA). **Dados de produção**. 2018.

URIARTE, M. e CHAZDON, R. L. Incorporating natural regeneration in forest landscape restoration in tropical regions: synthesis and key research gaps. **Biotropica**, [S.L.], v. 48, n. 6, p. 915-924, nov. 2016. Wiley. <http://dx.doi.org/10.1111/btp.12411>.

VOYANT, C. et al. Machine learning methods for solar radiation forecasting: a review. *Renewable Energy*, [S.L.], v. 105, p. 569-582, maio 2017. Elsevier BV. Disponível em: <http://dx.doi.org/10.1016/j.renene.2016.12.095>.

WANG, Q. et al. Identification and apportionment of the drivers of land use change on a regional scale: unbiased recursive partitioning-based stochastic model application. **Agriculture Ecosystems Environment** 217:99–110, 2016.

WEATHERS, K. C., CADENASSO, M. L., & PICKETT, S. T. A. (2001). Forest edges as nutrient and pollutant concentrators: Potential synergisms between fragmentation, forest canopies, and the atmosphere. **Conservation Biology**, 15, 1506–1514. <https://doi.org/10.1046/j.1523-1739.2001.01090.x>

XU, J. X. et al. Estimation of Sugarcane Yield Using a Machine Learning Approach Based on UAV-LiDAR Data. **Remote Sensing**, [S.L.], v. 12, n. 17, p. 2823, 31 ago. 2020. MDPI AG. <http://dx.doi.org/10.3390/rs12172823>.

YARAMASU, R. et al. Pre-season crop type mapping using deep neural networks. **Computers and Electronics in Agriculture** 176:105664, 2020.

YIN, H. et al. Land use and land cover change in Inner Mongolia—understanding the effects of China’s re-vegetation programs. **Remote Sensing of Environment** 204:918–930, 2018.

ZAKIA, M. J; PINTO, L. F. G. **Guia para aplicação da nova lei florestal em imóveis rurais**. 2a edição revisada e ampliada. Piracicaba, SP: Imaflora, 2014. 36p.

ZANELLA, L.; BORÉM, R. A. T.; SOUZA, C. G.; ALVES, H. M. R.; BORÉM, F. M. Atlantic Forest Fragmentation Analysis and Landscape Restoration Management Scenarios. **Natureza & Conservação**, Brasília, Brasil, v. 1, n. 10, p. 57-63, jul. 2012. Disponível em: <http://dx.doi.org/10.4322/natcon.2012.010>. Acesso em: 12 maio 2022.

ZANELLA, M. A.; SCHLEYER, C.; SPEELMAN, S. Why do farmers join Payments for Ecosystem Services (PES) schemes? An Assessment of PES water scheme participation in Brazil. **Ecological Economics**, v. 105, p. 166-176, set. 2014. Elsevier BV. <http://dx.doi.org/10.1016/j.ecolecon.2014.06.004>.

ZERMENO-HERNANDEZ, I. et al. Ecological disturbance caused by agricultural land uses and its effects on tropical forest regeneration. **Appl. Veg. Sci.** 18: 443–455, 2015.

ZHAO, K. et al. Application Research of Artificial Neural Network in Environmental Quality Monitoring. **International Journal of Pattern Recognition and Artificial Intelligence**, v. 33, n. 12, p. 1959039, nov. 2019. World Scientific Pub Co Pte Lt. <http://dx.doi.org/10.1142/s0218001419590390>.

ZHU, X. et al. Fault Diagnosis of Rotation Machinery Based on Support Vector Machine Optimized by Quantum Genetic Algorithm. *IEEE Access*, v. 6, p. 33583-33588, 2018. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/access.2018.2789933>.

APÊNDICE

Tabela 8: Valores das métricas de avaliação para cada modelo – ALC 50 metros.

Algoritmo	R ²			MAE			RMSE		
	Mín,	Média	Máx,	Mín.	Média	Máx.	Mín.	Média	Máx.
RF	0,083	0,451	0,876	0,094	0,252	0,379	0,120	0,323	0,482
RPART	0,074	0,356	0,846	0,116	0,275	0,434	0,142	0,360	0,528
KNN	0,003	0,226	0,570	0,165	0,299	0,409	0,208	0,384	0,527
NNET	0,000	0,260	0,827	0,114	0,290	0,500	0,165	0,373	0,575
EARTH	0,001	0,402	0,900	0,151	0,274	0,489	0,188	0,346	0,578
SVMRADIAL	0,000	0,293	0,741	0,183	0,286	0,453	0,237	0,377	0,568

Tabela 9: Valores das métricas de avaliação para cada modelo – ALC 100 metros.

Algoritmo	R ²			MAE			RMSE		
	Mín,	Média	Máx,	Mín.	Média	Máx.	Mín.	Média	Máx.
RF	0,128	0,634	0,926	0,507	0,932	1,722	0,619	1,195	2,254
RPART	0,028	0,463	0,921	0,507	1,121	2,116	0,579	1,437	2,89
KNN	0,0004	0,361	0,792	0,612	1,164	2,053	0,72	1,559	3,055
NNET	0,003	0,174	0,523	1,058	1,503	2,659	1,334	2,100	3,819
EARTH	0,005	0,453	0,856	0,679	1,186	1,685	0,93	1,433	2,226
SVMRADIAL	0,113	0,482	0,911	0,388	1,075	2,253	0,471	1,442	3,109

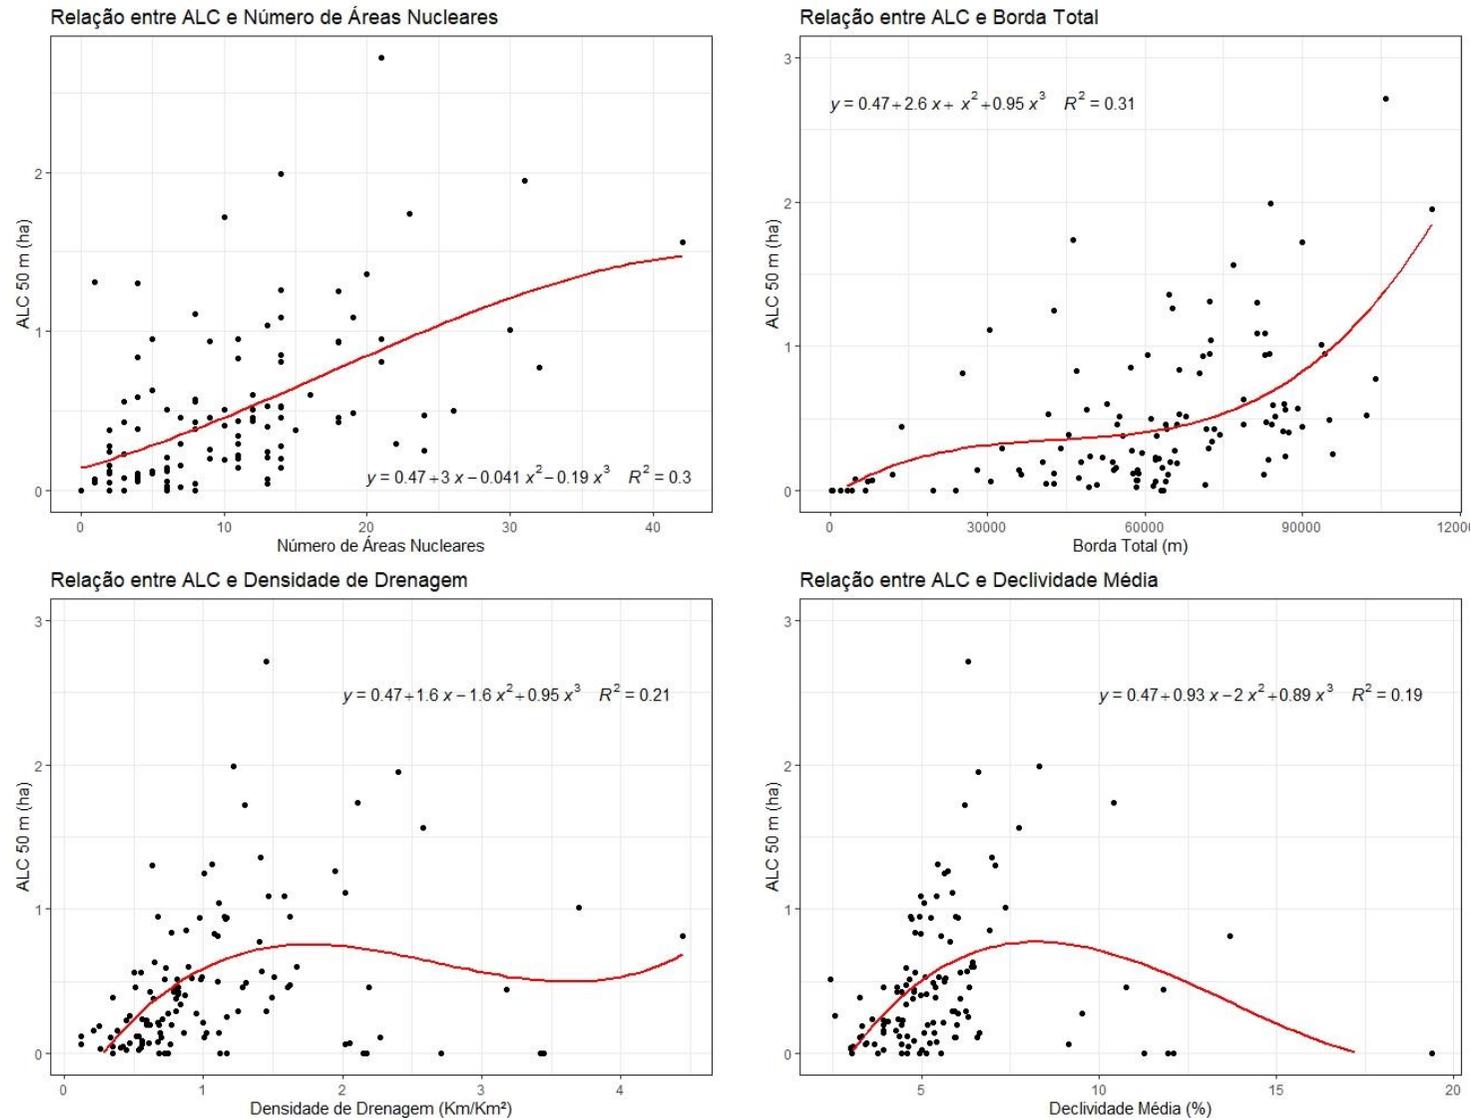


Figura 22: Gráficos de dispersão ilustrando a correlação entre a variável resposta e as explicativas mais importantes para o modelo Random Forest considerando o limiar de 50 metros (ALC 50m). Em cada gráfico também é apresentada a equação de ajuste polinomial de grau 3 e o valor de R^2 relativo a tal ajustamento.

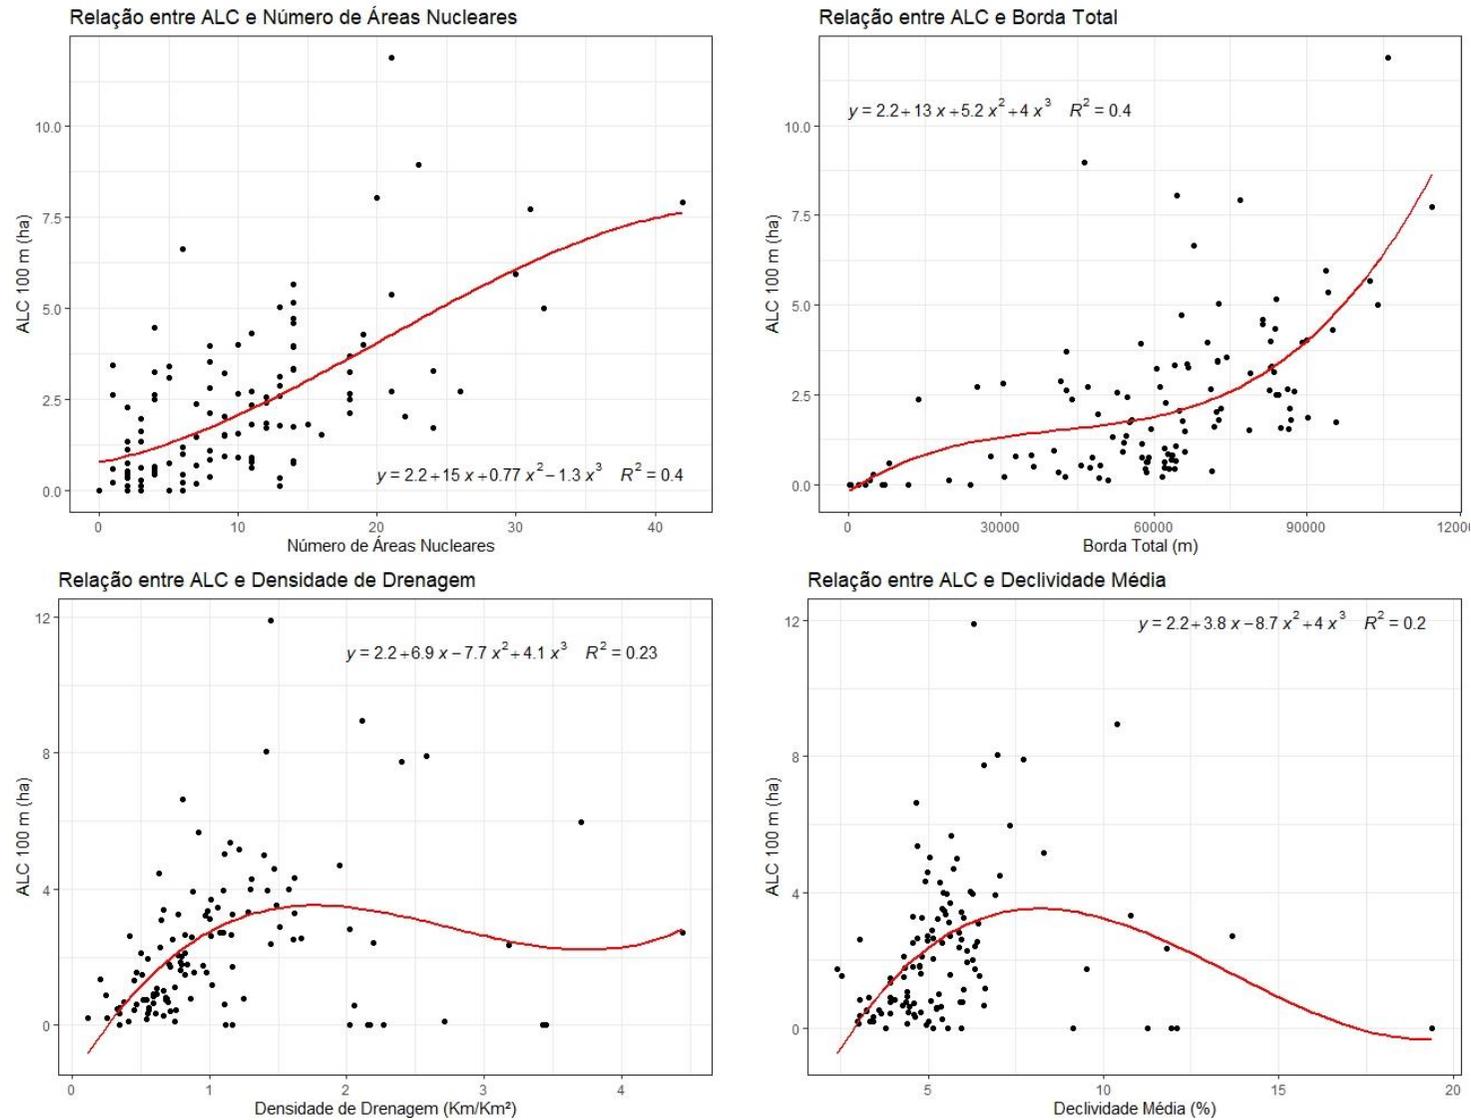


Figura 23: Gráficos de dispersão ilustrando a correlação entre a variável resposta e as explicativas mais importantes para o modelo Random Forest considerando o limiar de 100 metros (ALC 100m). Em cada gráfico também é apresentada a equação de ajuste polinomial de grau 3 e o valor de R² relativo a tal ajustamento.

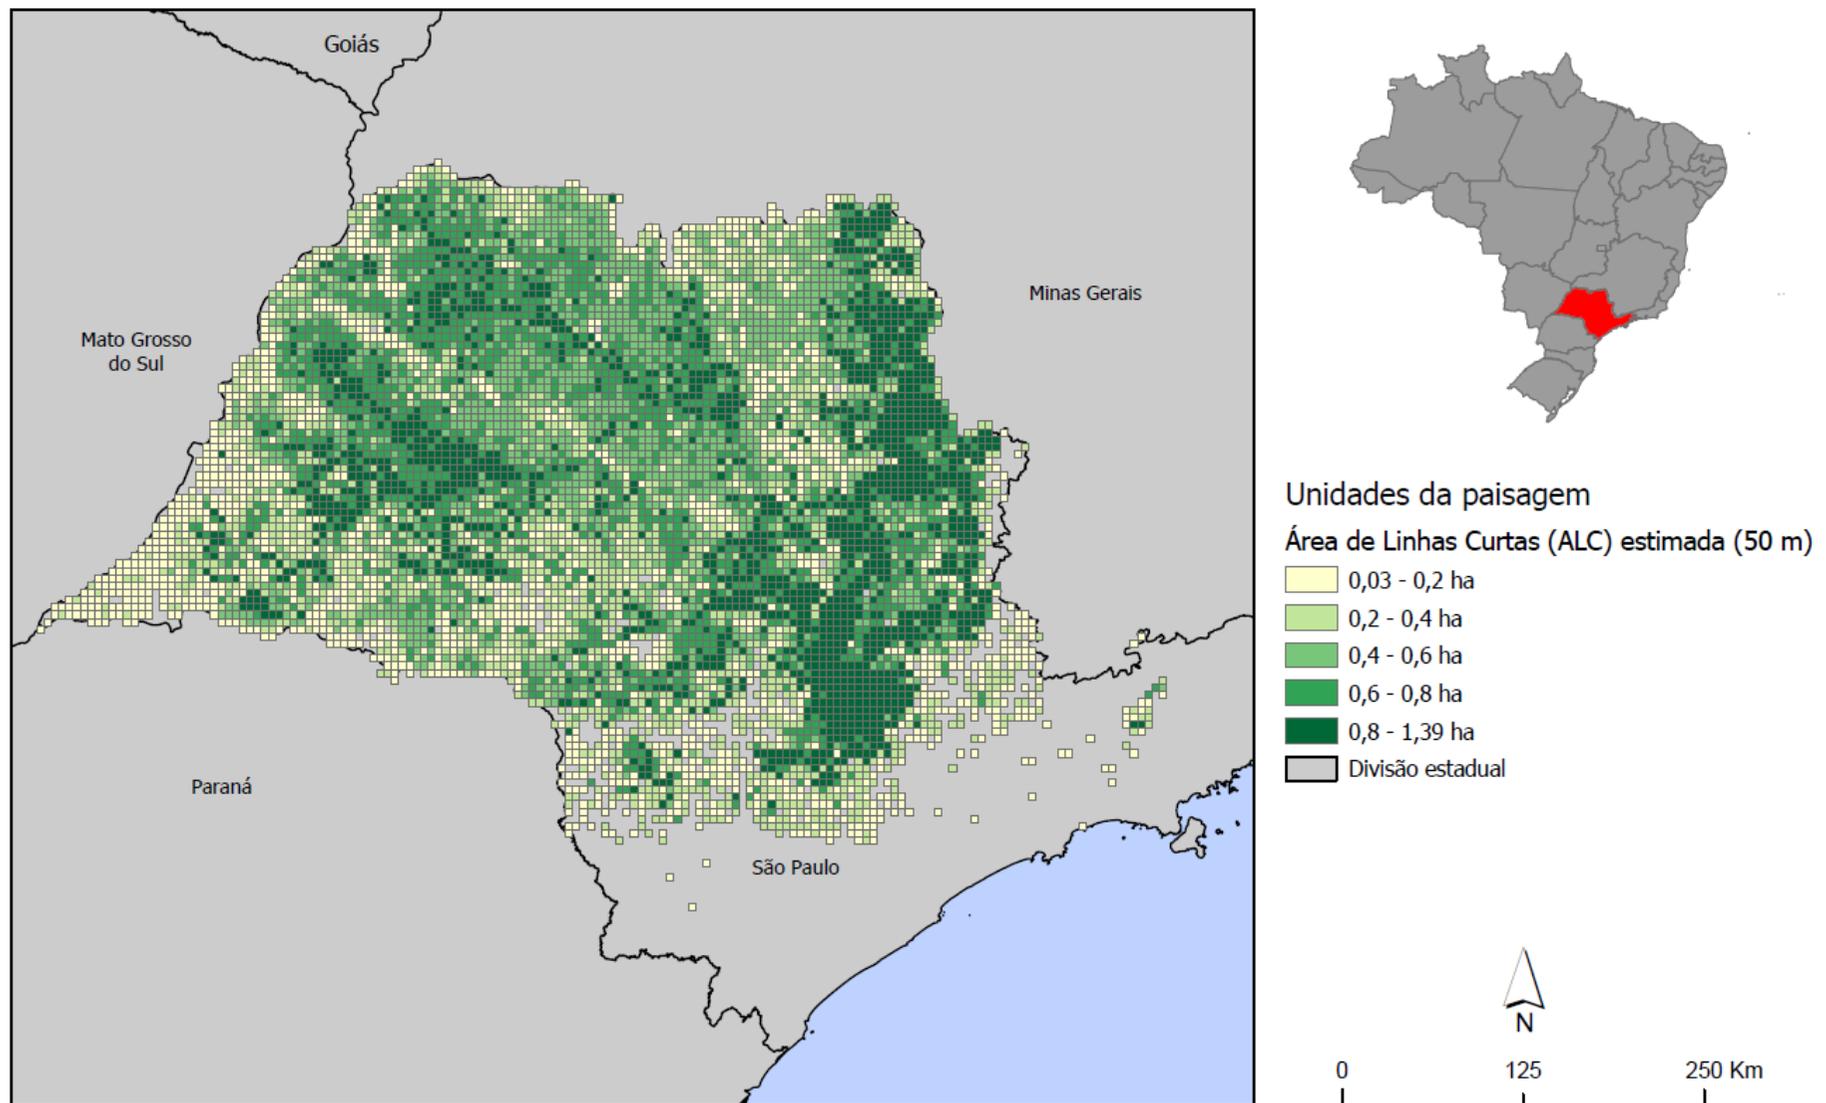


Figura 24: Distribuição espacial das estimativas de Áreas de Linhas Curtas (ALC) provenientes do modelo Random Forest considerando o limiar de 50 metros.

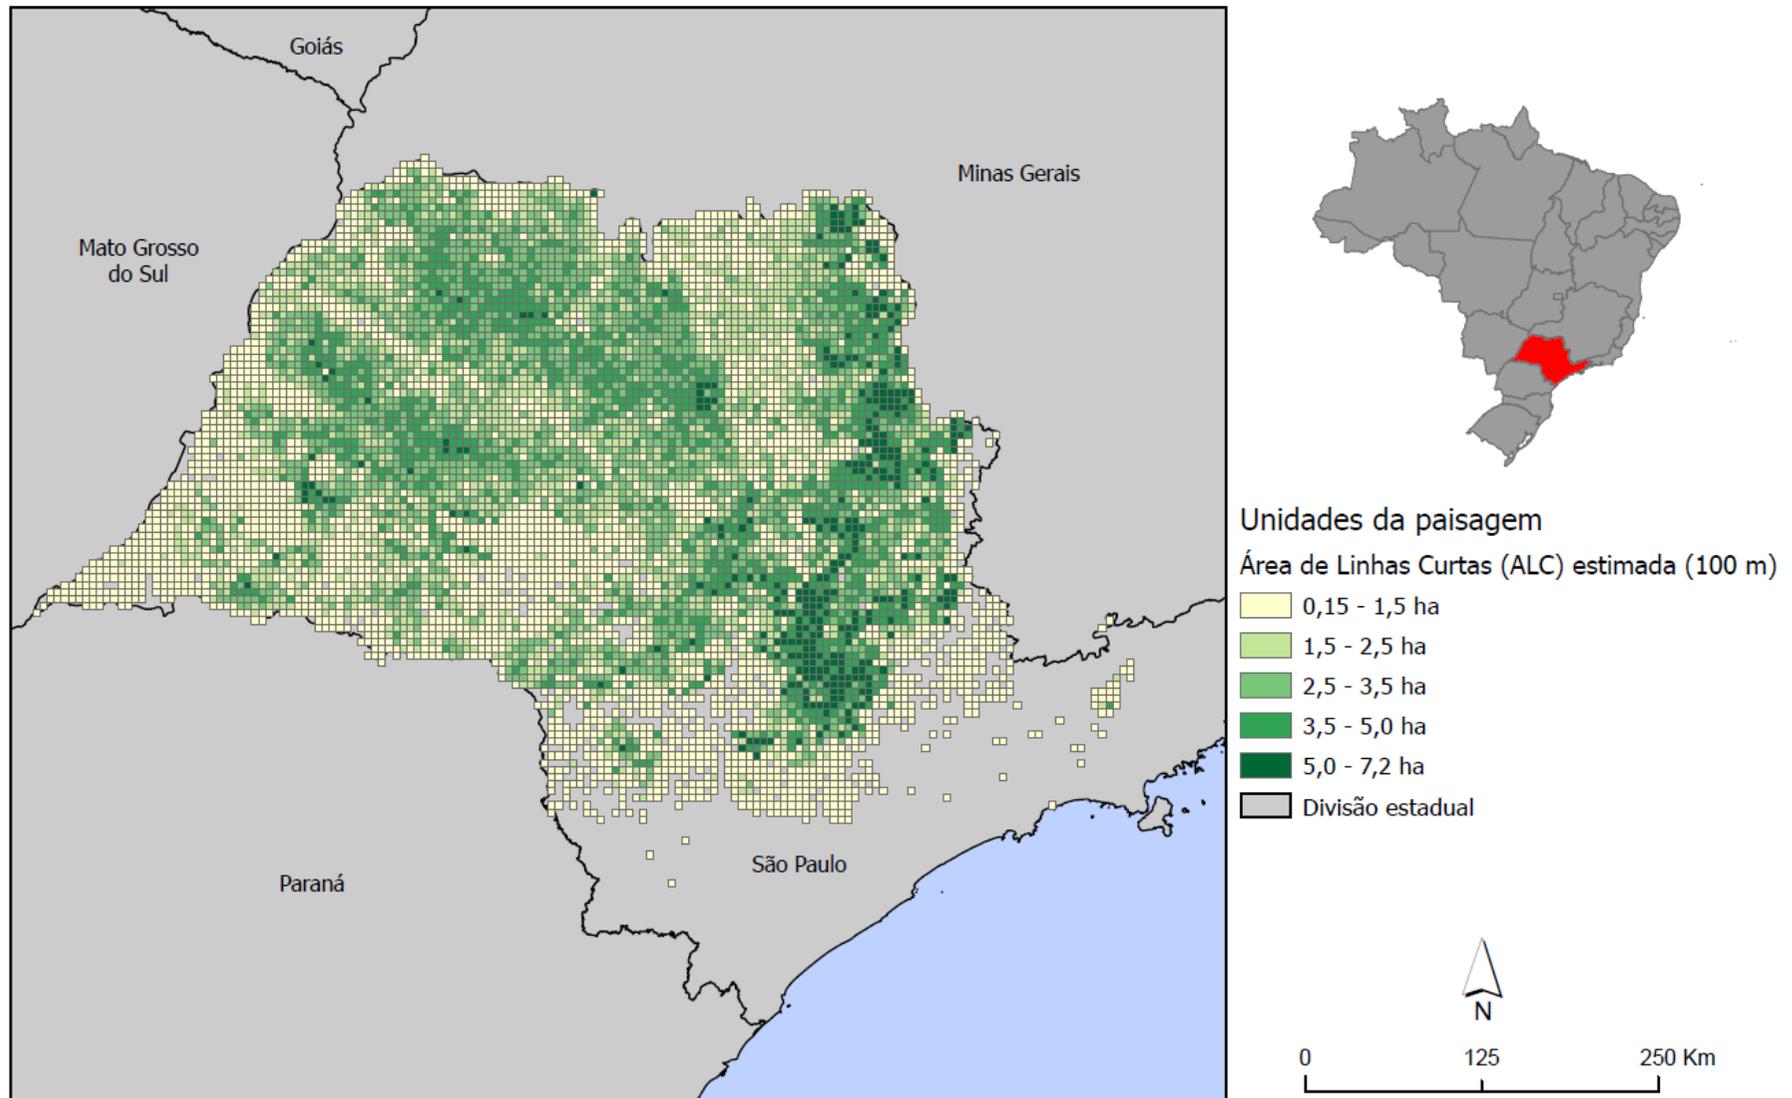


Figura 25: Distribuição espacial das estimativas de Áreas de Linhas Curtas (ALC) provenientes do modelo Random Forest considerando o limiar de 100 metros.

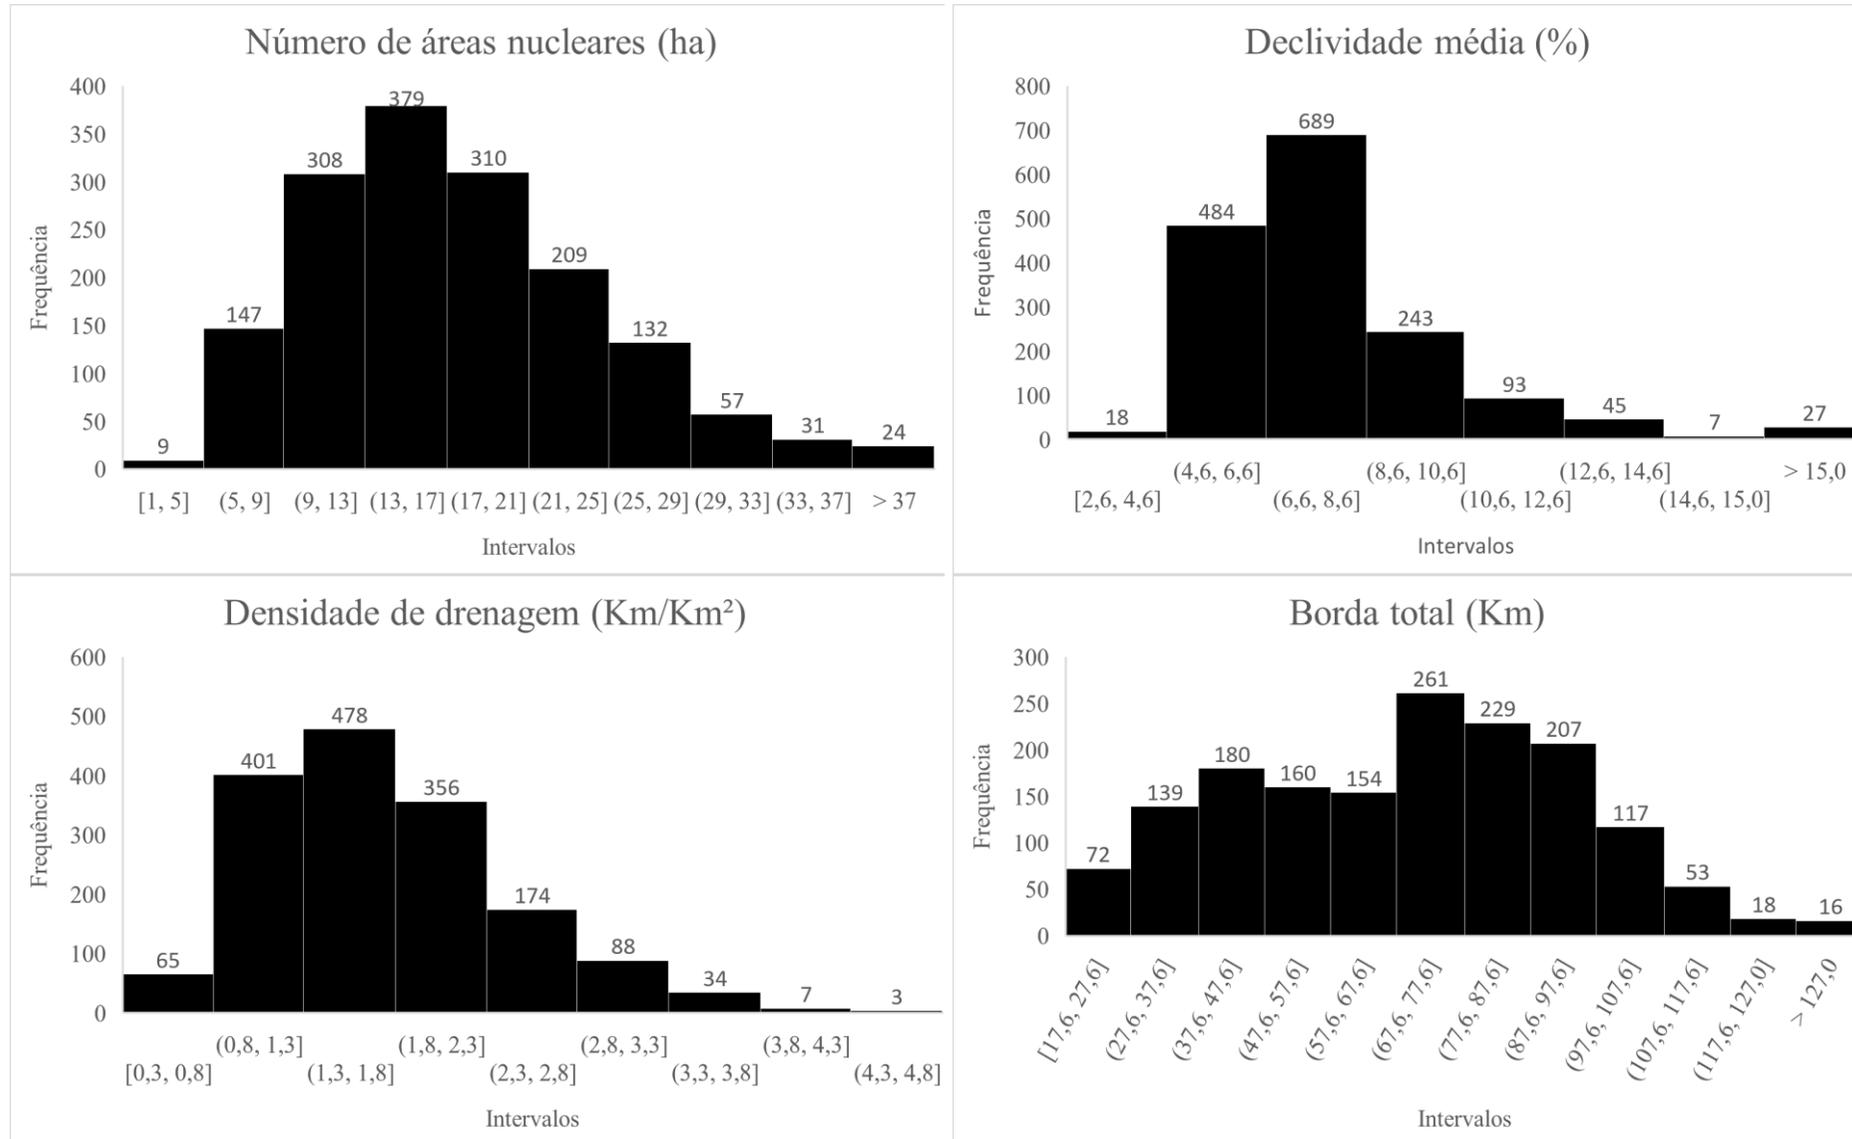


Figura 26: Distribuição das paisagens com maiores valores estimados de ALC 50 m em relação às variáveis de maior importância para o modelo.

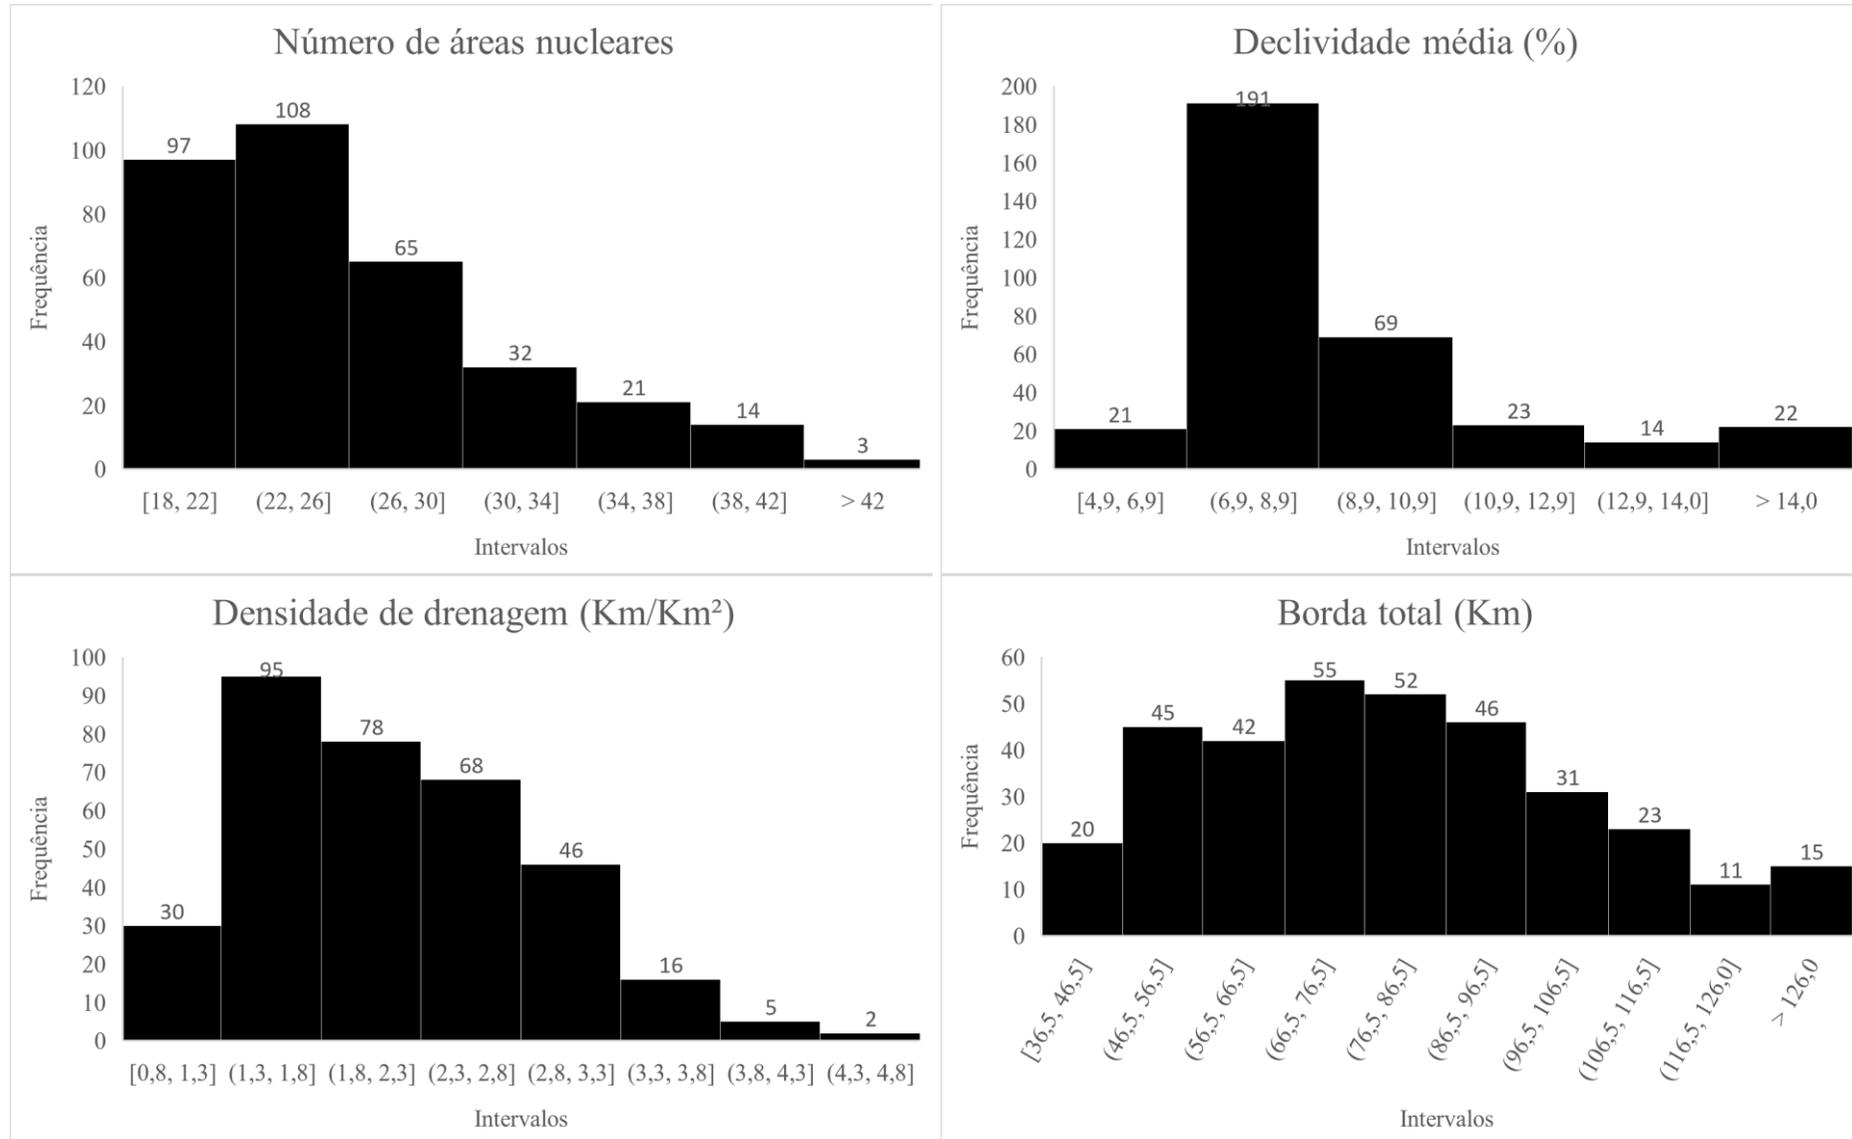


Figura 27: Distribuição das paisagens com maiores valores estimados de ALC 100 m em relação às variáveis de maior importância para o modelo.

Tabela 10: Síntese da relação de maior distribuição das paisagens de acordo com cada variável mais importante para os modelos.

Limiar	Intervalo de ALC (ha)	Nº total de paisagens	Concentração de paisagens de acordo com cada variável mais importante para o modelo							
			Nº de Áreas Nucleares		Declividade Média (%)		Densidade de drenagem (Km/Km ²)		Borda total (Km)	
			Intervalo	Nº de paisagens	Intervalo	Nº de paisagens	Intervalo	Nº de paisagens	Intervalo	Nº de paisagens
ALC 50 m	0,8 - 1,39	1606	9 - 21	997	4,6 - 10,6	1416	0,8 - 2,3	1235	67,6 - 97,6	697
ALC 100 m	5 - 7,2	340	18 - 30	270	6,9 - 12,9	283	1,3 - 2,8	241	66,5 - 96,5	153

Tabela 11: Características das paisagens amostradas de acordo com as variáveis utilizadas na pesquisa. Esta tabela também representa o banco de dados utilizado durante a etapa de modelagem.

Paisagem amostrada	Cobertura de cana (%)	Declividade Média (%)	Densidade de drenagem	Área Nuclear (ha)	Nº de Áreas Nucleares	Índice de Forma	Borda Total (m)	Densidade de Borda (m/ha)	ALC 50m	ALC 100m
1	0.03	12.09	3.42	0	0	1.5	556.36	727.95	0	0
2	0.02	11.27	3.45	0	0	1.4	432.72	905.89	0	0
3	4.14	5.23	2.05	92.77	1	1.82	7974.49	68.08	0.07	0.58
4	0.63	5.13	1.12	4.11	6	1.28	6676.32	362.09	0	0
5	11.42	5.93	1.25	230.91	11	1.32	32825.22	101.47	0.29	0.79
6	0.02	19.37	2.15	0	0	1	370.91	554.63	0	0
7	0.82	5.41	0.67	10.89	3	1.53	4883.60	206.12	0.08	0.28
8	68.58	4.81	0.5	1682	8	1.84	86730.29	44.50	0.56	2.12
9	0.17	11.95	2.17	0.57	3	1.39	1978.17	376.47	0	0
10	29	4.79	0.56	687	4	1.62	47414.21	57.38	0.09	0.48
11	17.77	7.73	2.58	287.18	42	1.53	76839.45	152.21	1.56	7.91
12	75.27	4.29	0.38	1948.93	7	1.69	63301.36	29.52	0.16	0.68
13	50.77	5.4	1.49	1217.8	8	2.19	74304.92	51.46	0.39	3.53
14	17.33	5.88	2.02	402.59	8	1.36	30476.15	61.82	1.11	2.82
15	43.6	6.6	2.4	911.22	31	1.62	114610.09	92.08	1.95	7.74
16	55.72	5.16	0.77	1389.28	9	1.9	64846.81	40.87	0.2	2.04
17	9.7	5.64	1.01	158.02	18	1.36	42716.06	155.36	1.25	3.7
18	61.63	3.92	0.45	1601.28	3	2.14	51865.08	29.44	0.23	1.33
19	79.65	6.1	0.64	2075.32	2	1.56	62250.46	27.45	0.38	2.29
20	80.36	6.03	0.75	2111.63	2	1.98	57552.31	25.14	0.28	1.13
21	51.25	6.63	1.02	1291.74	6	1.57	54090.52	37.11	0.14	1.18
22	53.92	4.99	0.87	1280.37	13	1.72	87472.10	56.89	0.4	2.6
23	40.1	5	0.54	995.77	7	1.71	49268.74	43.06	0.02	0.19

Paisagem amostrada	Cobertura de cana (%)	Declividade Média (%)	Densidade de drenagem	Área Nuclear (ha)	Nº de Áreas Nucleares	Índice de Forma	Borda Total (m)	Densidade de Borda (m/ha)	ALC 50m	ALC 100m
24	79.47	4.45	0.76	2076.28	4	1.43	62003.19	27.37	0.06	0.46
25	79.97	6.1	0.55	2127.77	3	1.83	48897.83	21.45	0.56	1.96
26	46.49	4.67	0.81	1127.23	6	1.8	67752.24	50.97	0.51	6.65
27	8.74	3.93	0.86	170.15	14	1.39	27941.62	112.10	0.14	0.78
28	55.94	3.91	0.82	1395.01	7	1.84	66021.34	41.37	0.46	1.48
29	77.17	3.43	0.12	2104.46	1	1.63	30537.96	13.87	0.06	0.21
30	2.5	11.81	3.18	34.39	11	1.24	13723.54	193.34	0.44	2.36
31	31.44	5.87	1.45	770.31	7	1.51	43890.59	48.67	0.29	2.38
32	23.29	6.97	1.41	480.55	20	1.47	64537.72	96.92	1.36	8.05
33	25	3.01	0.41	564.33	13	1.37	50876.00	71.34	0.04	0.13
34	11.66	3.78	0.35	259.95	6	1.37	24047.10	72.87	0	0
35	66.56	6.58	0.7	1701.21	4	2.63	64290.45	33.86	0.11	0.67
36	0.32	4.95	2.71	0.57	3	1.16	4265.42	442.05	0	0.11
37	45.92	5.54	1.1	1100.19	14	1.45	70472.22	53.85	0.81	3.97
38	65.71	4.42	0.62	1683.53	8	1.45	64228.63	34.23	0.43	1.08
39	0.79	9.13	2.02	5.06	6	1.27	7170.86	322.14	0.06	0
40	28.5	4.42	0.59	694.93	9	1.55	40428.80	49.59	0.2	0.93
41	22.77	5.98	0.68	515.13	14	1.37	47785.11	73.36	0.2	0.76
42	27.43	10.78	1.28	597.86	14	1.5	64043.18	81.52	0.46	3.33
43	36.87	5.37	1.11	879.31	11	1.56	58541.40	55.48	0.14	0.63
44	25.4	6.9	0.88	554.97	14	1.67	57366.86	78.87	0.85	3.93
45	75.39	5.32	0.67	1970.81	6	1.76	62126.83	28.78	0.21	1.01
46	59.16	5.49	0.99	1494.75	14	1.45	66577.70	39.30	0.53	3.35
47	29.91	6.26	0.8	649.07	22	1.45	72141.30	84.13	0.29	2.03
48	3.06	5.95	2.27	52.74	5	1.67	11869.01	135.04	0.11	0
49	75.04	6.43	0.65	1902.69	5	1.94	78817.62	36.71	0.63	3.1

Paisagem amostrada	Cobertura de cana (%)	Declividade Média (%)	Densidade de drenagem	Área Nuclear (ha)	Nº de Áreas Nucleares	Índice de Forma	Borda Total (m)	Densidade de Borda (m/ha)	ALC 50m	ALC 100m
50	3.89	13.68	4.44	45.57	21	1.33	25221.64	226.22	0.81	2.72
51	40.8	6.32	1.17	888.48	24	1.51	95755.68	81.69	0.25	1.73
52	78.35	4.47	0.59	2058.8	3	1.96	62003.19	27.59	0.23	0.64
53	57.4	5.14	0.82	1383.36	10	1.61	86297.56	52.47	0.41	2.65
54	34.01	3.25	0.33	864.03	2	2.05	36348.83	37.24	0.11	0.49
55	41.24	5.4	1.61	932.05	18	1.42	84072.12	71.27	0.46	2.51
56	63.29	4.77	0.79	1541.66	12	1.88	90068.45	49.66	0.44	1.85
57	78.98	4.6	0.72	2074.27	2	1.61	62992.28	27.78	0	0.42
58	76.62	7.06	0.63	1940.52	4	4.33	81290.33	36.94	1.3	4.48
59	44.27	8.3	1.22	1022.9	14	1.47	83948.49	66.03	1.99	5.17
60	77.56	5.46	1.06	2002.81	1	2.41	72388.57	32.49	1.31	3.45
61	41.45	3.31	0.25	990.52	10	1.68	66144.98	55.53	0.19	0.9
62	29.75	4.56	1.62	607.23	24	1.59	83083.04	97.40	0.47	3.29
63	52.26	4.68	1.15	1220.28	21	1.51	94272.05	62.85	0.95	5.37
64	75.33	4.81	0.77	1960.87	4	1.61	66639.52	30.81	0.84	3.25
65	36.92	4.32	0.82	846.45	18	1.45	73130.38	68.92	0.43	2.13
66	66.79	3.25	0.35	1782.6	4	1.73	45559.67	23.71	0.39	0.53
67	38.42	7.35	3.7	830.88	30	1.59	93715.69	84.94	1.01	5.96
68	60.57	6.48	0.89	1488.73	16	1.55	86483.02	49.68	0.6	1.54
69	70.36	3.6	0.56	1862.47	2	1.8	49516.01	24.58	0.24	0.53
70	60.71	4.93	1.62	1488.83	11	1.54	83701.22	48.04	0.95	4.33
71	25.62	3.45	0.61	565.48	13	1.49	58417.76	79.43	0.07	0.35
72	24.4	4.99	1.08	568.06	11	1.42	46919.66	66.73	0.83	2.72
73	38.48	5.27	0.97	922.21	9	1.62	60519.57	54.77	0.94	3.23
74	71.35	4.33	0.71	1795.31	13	1.6	86853.92	42.27	0.24	1.79

Paisagem amostrada	Cobertura de cana (%)	Declividade Média (%)	Densidade de drenagem	Área Nuclear (ha)	Nº de Áreas Nucleares	Índice de Forma	Borda Total (m)	Densidade de Borda (m/ha)	ALC 50m	ALC 100m
75	32.46	5.73	1.95	746.42	14	1.56	65279.53	69.51	1.26	4.71
76	75.21	5.94	1.01	1909.38	4	2.45	82588.50	38.19	0.11	2.62
77	77.89	5.24	0.47	2059.56	4	1.58	58665.03	26.18	0.07	0.62
78	77.55	4.59	0.54	2054.21	2	2.1	57675.95	25.84	0.12	0.75
79	64.3	5.67	0.92	1538.13	14	2.06	102308.36	55.28	0.52	5.66
80	83.79	3.06	0.42	2275.85	1	2.17	42716.06	17.72	0.05	2.63
81	30.3	4.05	0.59	689	11	1.61	62745.00	71.96	0.22	0.85
82	58.8	3.67	0.56	1491.89	4	2.28	64043.18	37.98	0.06	0.45
83	49.95	6.3	1.45	1117	21	1.88	105955.60	73.86	2.72	11.89
84	60.53	6.21	1.3	1469.63	10	1.67	90006.63	51.72	1.72	4.01
85	77.63	4.38	0.52	2051.54	5	2.3	58850.49	26.34	0.12	0.76
86	48.33	9.52	0.95	1197.06	14	1.41	65588.62	47.11	0.28	1.76
87	67.36	5.64	0.98	1681.81	10	1.78	84813.94	43.74	0.51	1.57
88	13.82	10.4	2.11	268.74	23	1.33	46239.67	116.18	1.74	8.96
89	43.16	5.61	1	989.37	13	1.68	83515.76	67.35	0.21	3.13
90	73.15	4.79	0.79	1884.92	3	2.03	71708.58	34.05	0.43	1.62
91	32.61	5.43	1.58	695.31	19	1.52	82835.77	88.30	1.09	4
92	59.75	6.27	1.42	1449.28	8	2.46	89079.36	51.76	0.57	3.97
93	18	4.42	0.75	458.09	2	1.41	19719.86	38.17	0	0.13
94	50.31	4.71	1.16	1239.67	18	1.35	71028.58	48.96	0.93	2.66
95	23.78	6.41	1.67	529.65	12	1.51	52792.35	77.11	0.6	2.56
96	70.44	3.05	0.55	1811.74	8	1.66	71399.49	35.21	0.04	0.36
97	22.12	6.35	2.19	474.34	12	1.62	54646.88	85.85	0.46	2.42
98	30.79	5.06	1.11	670.95	13	1.87	72574.03	81.70	1.04	5.04
99	47.64	5.34	1.31	1091.21	19	1.53	95075.68	69.14	0.49	4.3
100	43.21	4.98	1.47	995.2	14	1.98	81413.96	65.58	1.09	4.59

Paisagem amostrada	Cobertura de cana (%)	Declividade Média (%)	Densidade de drenagem	Área Nuclear (ha)	Nº de Áreas Nucleares	Índice de Forma	Borda Total (m)	Densidade de Borda (m/ha)	ALC 50m	ALC 100m
101	65.2	4.57	0.84	1663.66	11	1.57	72759.48	38.69	0.34	1.8
102	37.11	6.03	1.17	826.19	18	1.65	82897.59	77.45	0.94	3.25
103	47.91	3.05	0.68	1189.99	8	1.77	63610.45	46.06	0	0.83
104	76.15	3.91	0.45	2020.01	6	1.67	58294.13	26.51	0.02	0.44
105	72.54	3.93	0.21	1931.45	2	1.85	54461.43	25.99	0.16	1.34
106	83.67	4.62	0.35	2289.13	2	1.73	41170.61	17.04	0.05	0.35
107	63.86	4.55	0.73	1579.97	4	2.82	84443.03	45.87	0.59	2.51
108	66.48	5.95	0.67	1697.77	5	1.53	72450.39	37.76	0.95	3.41
109	0.23	5.55	1.17	0.38	2	1.33	3338.16	492.13	0	0
110	27.99	3.92	0.62	650.12	11	1.48	53905.07	66.66	0.2	0.91
111	14.42	5.11	1.51	296.54	13	1.36	41603.34	99.79	0.53	2.89
112	49.93	2.55	0.47	1265.28	9	1.65	59406.85	41.12	0.26	1.54
113	32.83	2.42	0.72	783.68	12	1.45	55203.24	58.31	0.51	1.73
114	22.9	5.64	1.1	485.8	26	1.37	61261.38	92.44	0.5	2.73
115	8.2	5.07	0.69	148.75	14	1.46	35916.11	151.35	0.14	0.8
116	45.75	5.81	1.4	1019.18	32	1.63	103915.62	78.57	0.77	5
117	21.66	4.76	0.8	461.53	15	1.39	55697.78	89.38	0.38	1.8
118	63.45	4.31	0.51	1598.12	9	1.95	78693.98	42.86	0.46	1.5
119	53.7	3	0.26	1366.93	6	1.85	61632.29	39.66	0.03	0.22
120	21.12	3.33	0.12	484.08	6	1.58	42654.24	69.89	0.12	0.22

Tabela 12: Resultados da análise de proximidade (em metros) entre as Áreas de Linhas Curtas do limiar de 50 metros (ALC 50m) e as regiões de APP, hidrografia e vegetação nativa individualmente para cada paisagem amostrada.

Paisagem	APP			Hidrografia			Vegetação		
	Mín.	Méd.	Máx.	Mín.	Méd.	Máx.	Mín.	Méd.	Máx.
1	0	0	0	0	0	0	0	0	0
2	0	0	0	0	0	0	0	0	0
3	53.0	57.4	61.1	22.3	28.3	30.8	33.5	43.7	48.7
4	0	0	0	0	0	0	0	0	0
5	116.2	127.1	143.3	151.5	160.1	175.6	70.8	81.1	93.0
6	0	0	0	0	0	0	0	0	0
7	154.5	157.3	165.3	155.0	157.8	165.7	34.8	38.6	48.9
8	191.8	189.9	208.3	231.7	232.0	247.8	350.1	336.8	372.0
9	0	0	0	0	0	0	0	0	0
10	68.0	74.7	89.1	390.2	399.6	417.5	201.0	211.1	220.1
11	20.6	29.5	39.5	41.8	52.4	63.5	179.3	190.8	203.9
12	522.3	533.5	543.6	627.0	637.7	647.2	138.8	146.2	153.6
13	37.1	41.6	47.0	61.0	65.8	69.4	33.0	37.2	42.2
14	42.5	49.7	58.1	107.1	116.7	127.9	41.8	52.6	64.1
15	26.5	35.9	46.7	51.8	61.1	72.7	172.2	185.0	195.8
16	58.9	59.4	67.3	92.5	91.9	101.4	195.8	179.6	208.8
17	84.9	95.0	103.5	114.3	126.7	140.9	132.2	146.2	160.6
18	23.8	33.6	46.6	88.6	94.9	106.5	100.5	106.6	116.0
19	58.5	65.2	72.6	59.3	66.6	73.9	205.4	211.6	218.8
20	45.9	52.1	59.7	55.5	63.2	70.1	296.9	301.8	307.8
21	195.4	198.0	203.4	269.8	275.9	277.1	235.6	235.3	237.2
22	131.1	146.8	144.9	148.1	159.7	161.0	102.0	130.2	118.8
23	22.2	20.0	22.2	66.3	61.7	66.3	19.1	21.7	19.1
24	30.1	36.3	40.0	46.7	53.0	67.1	18.1	23.1	31.7
25	93.2	100.6	109.6	112.5	120.1	128.1	102.8	110.8	121.4

Paisagem	APP			Hidrografia			Vegetação		
	Mín.	Méd.	Máx.	Mín.	Méd.	Máx.	Mín.	Méd.	Máx.
26	237.6	250.7	260.2	247.3	260.9	270.1	172.9	184.2	194.4
27	176.5	183.5	192.7	260.3	267.9	274.8	327.4	339.0	349.9
28	169.8	178.5	187.9	215.2	225.1	234.5	141.9	151.6	161.3
29	131.2	135.9	139.7	98.4	103.4	107.5	87.9	91.6	97.2
30	27.0	37.7	45.5	69.0	80.6	90.2	71.1	84.4	95.3
31	33.3	42.7	48.5	63.0	70.2	79.0	619.9	624.3	630.1
32	21.1	29.8	38.5	60.0	69.5	80.4	13.9	22.3	32.9
33	123.3	122.6	124.2	138.8	139.1	140.9	211.1	211.5	214.7
34	0	0	0	0	0	0	0	0	0
35	66.5	67.9	69.9	134.9	138.1	140.3	228.8	235.7	242.5
36	0	0	0	0	0	0	0	0	0
37	61.9	70.5	76.6	110.6	116.6	123.4	92.1	97.9	104.1
38	97.3	105.2	113.2	109.0	116.4	124.9	253.1	260.5	267.5
39	0	0	0	0	0	0	0	0	0
40	28.5	32.8	38.5	66.7	70.1	75.4	234.9	242.2	249.7
41	576.8	583.7	596.8	581.6	590.9	604.3	48.3	54.8	63.3
42	219.7	198.9	240.7	257.4	236.6	278.1	185.4	169.8	203.9
43	3.9	13.0	20.6	44.0	49.9	58.6	173.6	182.1	190.4
44	296.5	305.9	317.1	326.3	336.4	348.0	49.5	60.0	70.5
45	46.4	75.6	52.9	69.0	88.4	74.0	150.1	205.0	160.9
46	144.1	131.5	162.8	172.1	161.9	192.8	94.7	88.0	106.9
47	10.2	19.6	30.7	38.1	51.3	64.1	15.2	25.5	35.4
48	62.0	66.6	71.9	96.6	100.8	106.4	1408.3	1413.5	1418.5
49	74.6	79.8	84.3	98.3	105.0	109.7	21.3	28.0	35.1
50	132.6	143.3	153.2	175.2	186.9	198.8	63.0	72.2	85.9
51	23.3	31.2	37.0	54.9	62.3	71.4	141.3	148.7	154.8
52	20.8	40.6	56.2	27.6	62.2	60.3	292.5	207.3	315.7

Paisagem	APP			Hidrografia			Vegetação		
	Mín.	Méd.	Máx.	Mín.	Méd.	Máx.	Mín.	Méd.	Máx.
53	92.1	99.4	110.7	112.2	118.6	130.6	199.2	207.1	217.3
54	922.4	937.4	954.0	1014.6	1029.7	1046.6	563.1	572.4	583.3
55	60.3	67.1	75.1	96.5	105.5	116.3	111.5	120.4	125.1
56	83.4	89.9	99.1	109.7	116.9	127.2	81.7	88.3	96.2
57	0	0	0	0	0	0	0	0	0
58	292.3	301.5	310.2	323.5	333.8	343.6	73.9	84.7	95.2
59	39.9	58.2	71.4	55.7	70.7	88.3	59.4	76.5	87.8
60	21.4	28.1	35.9	45.0	50.8	59.7	34.0	40.8	50.1
61	800.1	804.8	811.1	791.5	796.4	802.3	526.9	531.9	536.1
62	138.3	145.1	152.3	174.7	184.2	194.6	745.7	754.4	765.8
63	73.5	79.5	88.7	107.2	114.0	124.1	87.3	95.9	103.1
64	77.6	92.6	97.1	103.6	122.3	121.3	81.0	80.9	96.1
65	242.4	252.4	260.5	279.7	288.5	297.9	174.6	184.6	194.3
66	272.0	240.4	286.8	299.2	274.3	314.5	3581.9	3660.8	3599.2
67	28.3	36.8	45.9	67.9	77.5	87.3	339.4	346.4	355.6
68	112.8	133.9	131.5	116.4	142.6	137.7	62.6	67.2	80.2
69	59.6	67.8	75.1	69.4	83.8	96.0	486.0	499.7	520.4
70	45.3	50.6	56.0	75.2	81.2	86.9	134.0	140.6	146.1
71	351.1	363.1	370.8	412.8	429.7	439.8	0.8	7.9	11.8
72	30.4	47.5	63.1	209.5	224.4	239.3	144.0	152.9	165.6
73	56.5	64.6	80.5	179.1	186.7	203.8	267.6	266.2	289.0
74	164.3	169.7	175.8	196.5	201.8	208.5	139.5	146.4	152.8
75	48.3	58.7	69.8	74.6	86.2	98.5	341.0	354.2	364.8
76	32.8	39.4	44.7	62.2	67.1	72.1	179.4	189.2	195.8
77	3.9	5.4	13.2	29.2	33.0	44.8	132.5	139.9	138.4
78	31.2	38.6	44.4	30.9	39.0	47.8	88.4	96.7	105.2
79	94.8	106.5	116.0	112.1	122.1	133.2	68.1	81.7	93.8
80	61.9	69.2	76.9	24.0	30.9	38.0	69.5	79.1	80.6

Paisagem	APP			Hidrografia			Vegetação		
	Mín.	Méd.	Máx.	Mín.	Méd.	Máx.	Mín.	Méd.	Máx.
81	340.6	348.7	362.0	422.5	432.9	445.7	163.9	173.1	186.1
82	138.6	143.9	147.6	145.2	149.3	151.6	534.6	537.8	545.5
83	79.1	88.1	99.7	108.0	118.2	130.3	104.5	113.9	123.6
84	42.8	59.5	70.6	67.8	80.9	99.1	43.7	54.3	65.2
85	112.7	116.3	123.1	134.7	137.7	144.8	123.9	124.0	131.4
86	193.0	168.8	209.2	181.2	161.1	198.7	164.5	152.8	184.5
87	39.8	49.2	56.3	101.5	108.8	116.2	42.6	51.9	59.7
88	30.5	40.7	51.6	48.3	60.0	69.9	21.7	36.1	49.2
89	169.7	176.6	179.8	185.6	191.9	196.6	135.6	144.2	146.1
90	12.0	22.4	32.9	64.3	74.9	86.7	32.2	43.5	52.8
91	55.6	64.4	77.4	114.7	123.8	139.6	136.5	139.5	166.3
92	98.5	94.8	114.3	118.5	113.3	135.3	81.4	116.9	99.0
93	0	0	0	0	0	0	0	0	0
94	15.0	26.6	37.6	62.1	76.3	91.2	35.6	46.9	62.9
95	112.1	124.5	136.9	132.4	142.2	154.1	142.6	151.4	162.8
96	214.0	168.6	214.0	187.7	149.9	187.7	143.8	86.9	143.8
97	16.8	23.3	33.4	59.7	66.9	78.2	221.1	230.9	242.2
98	68.4	79.9	88.7	100.9	111.0	120.7	105.2	115.2	126.2
99	88.0	95.1	102.6	123.7	130.5	137.9	56.7	62.4	71.1
100	29.8	38.5	46.4	57.7	67.2	77.3	259.2	269.5	281.6
101	78.6	85.9	90.2	116.8	120.9	130.6	32.0	34.2	40.3
102	82.8	98.6	102.1	101.4	112.2	121.0	71.8	80.1	90.6
103	0	0	0	0	0	0	0	0	0
104	40.0	42.8	40.0	99.5	102.8	99.5	22.3	13.3	22.3
105	63.0	70.6	76.4	109.6	116.5	125.5	50.5	62.0	76.2
106	123.5	124.9	123.5	97.5	98.5	97.5	144.8	148.9	144.8
107	34.0	40.0	45.0	68.1	74.7	79.8	27.3	33.3	40.0

Paisagem	APP			Hidrografia			Vegetação		
	Mín.	Méd.	Máx.	Mín.	Méd.	Máx.	Mín.	Méd.	Máx.
108	52.6	59.9	68.9	76.1	83.5	93.4	43.4	57.4	69.1
109	0	0	0	0	0	0	0	0	0
110	277.1	283.0	289.2	304.7	313.3	318.5	208.8	215.9	224.2
111	115.8	124.0	131.8	154.5	164.5	174.8	342.6	350.3	359.1
112	219.5	224.4	230.4	235.3	240.1	246.2	54.8	58.2	63.2
113	61.4	67.5	75.0	71.7	79.5	87.7	59.4	68.1	77.8
114	174.7	184.8	193.8	212.6	220.7	229.8	217.8	230.3	241.2
115	221.1	222.1	229.4	187.7	188.5	197.1	76.4	88.3	92.8
116	95.3	97.7	110.9	124.2	129.6	141.5	142.6	142.9	161.9
117	79.7	85.1	89.9	89.1	94.6	99.8	61.9	68.0	72.3
118	131.0	141.0	151.1	149.1	159.4	171.0	36.9	43.6	53.8
119	45.2	55.0	69.8	86.4	95.9	110.2	112.3	118.3	128.3
120	36.7	45.6	50.7	431.3	438.4	447.1	32.2	40.2	47.9

Tabela 13: Resultados da análise de proximidade (em metros) entre as Áreas de Linhas Curtas do limiar de 50 metros (ALC 50m) e as regiões de APP, hidrografia e vegetação nativa individualmente para cada paisagem amostrada.

Paisagem	APP			Hidrografia			Vegetação		
	Mín.	Méd.	Máx.	Mín.	Méd.	Máx.	Mín.	Méd.	Máx.
1	0	0	0	0	0	0	0	0	0
2	0	0	0	0	0	0	0	0	0
3	37.0	48.7	62.9	55.8	69.5	81.8	26.5	48.9	70.1
4	0	0	0	0	0	0	0	0	0
5	113.4	133.7	160.4	150.2	168.1	195.9	67.0	87.0	108.0
6	0	0	0	0	0	0	0	0	0
7	154.5	161.6	180.0	151.9	160.3	180.2	25.4	43.1	62.9
8	175.0	196.6	212.9	218.8	243.1	264.6	335.2	358.3	380.0
9	0	0	0	0	0	0	0	0	0
10	48.8	67.9	92.7	259.4	280.4	302.8	120.4	140.4	153.8
11	20.6	39.8	63.1	42.1	66.4	91.5	94.1	119.1	148.5
12	515.0	543.1	568.2	618.0	645.5	670.8	121.1	145.6	174.0
13	21.1	34.2	48.7	47.7	64.2	82.0	17.3	35.0	56.0
14	27.5	44.7	68.2	69.0	97.8	131.5	37.5	64.1	90.3
15	16.2	35.6	56.7	49.6	71.2	95.6	156.2	180.8	208.4
16	55.2	74.3	95.0	84.5	102.4	121.1	137.6	163.0	186.0
17	70.3	90.3	114.9	100.5	123.6	154.2	139.4	164.0	186.6
18	16.5	34.6	62.7	80.4	100.1	124.2	75.7	98.6	124.6
19	40.7	52.3	65.9	48.5	61.3	76.3	220.6	238.7	260.8
20	47.5	58.2	71.4	62.0	73.2	85.7	467.0	482.3	498.7
21	144.1	162.7	182.1	207.3	224.5	244.0	155.5	171.2	184.3
22	138.4	160.6	186.3	163.4	182.7	205.7	94.3	114.6	139.5
23	1.2	16.3	30.0	46.2	63.3	76.7	0.1	15.6	40.8
24	23.3	36.3	53.3	39.5	61.5	85.2	22.0	40.0	61.1

Paisagem	APP			Hidrografia			Vegetação		
	Mín.	Méd.	Máx.	Mín.	Méd.	Máx.	Mín.	Méd.	Máx.
25	46.0	62.1	79.1	72.9	92.5	114.8	79.7	97.5	119.4
26	186.2	211.9	236.7	195.0	222.0	245.2	130.8	168.1	206.5
27	196.3	217.9	238.8	335.9	353.4	369.3	242.1	277.8	307.7
28	168.4	192.6	221.6	216.0	241.8	270.4	144.6	161.2	181.7
29	130.7	143.9	165.4	98.4	111.5	134.6	73.7	95.3	124.9
30	26.2	40.2	59.8	65.2	85.4	109.9	65.6	90.5	115.2
31	23.8	44.8	68.3	64.3	85.8	110.7	547.2	577.4	610.9
32	15.8	34.6	57.6	48.9	74.3	103.1	13.7	34.5	63.8
33	123.3	131.5	133.6	138.8	148.6	153.6	210.5	218.2	223.7
34	0	0	0	0	0	0	0	0	0
35	50.6	59.7	70.7	105.6	121.7	143.9	167.2	190.4	215.9
36	306.8	315.2	330.0	268.9	277.7	293.3	203.3	214.8	236.2
37	55.3	77.7	103.1	98.4	121.3	146.7	81.8	99.7	120.8
38	183.3	200.6	220.2	209.2	225.7	241.3	352.9	368.8	388.3
39	0	0	0	0	0	0	0	0	0
40	20.6	34.8	50.0	60.1	74.9	90.1	229.7	252.2	281.2
41	577.2	597.3	621.8	581.6	603.5	628.1	47.7	62.0	86.0
42	138.5	167.6	198.1	177.9	208.8	240.8	107.7	129.5	153.6
43	1.3	18.1	38.9	39.0	55.8	79.4	158.2	183.4	211.1
44	327.4	352.2	380.2	351.9	377.7	407.8	67.7	87.4	111.2
45	57.4	69.5	83.2	77.1	88.9	101.8	243.1	262.6	280.9
46	79.5	100.2	123.3	113.6	137.2	162.9	51.2	74.3	97.3
47	3.2	21.0	40.8	30.0	58.6	92.6	9.4	33.0	57.5
48	0	0	0	0	0	0	0	0	0
49	38.5	53.7	72.7	72.8	91.2	118.1	41.8	55.8	75.2
50	139.8	160.5	178.6	176.2	200.4	227.8	62.5	81.3	102.8

Paisagem	APP			Hidrografia			Vegetação		
	Mín.	Méd.	Máx.	Mín.	Méd.	Máx.	Mín.	Méd.	Máx.
51	41.8	61.7	88.0	55.8	79.0	107.8	132.9	160.6	190.0
52	35.9	52.2	71.8	62.8	74.6	86.6	305.9	324.5	346.1
53	71.3	93.4	120.7	72.0	92.4	118.6	230.3	252.4	276.2
54	900.3	936.9	967.4	991.8	1029.1	1059.9	563.1	584.1	608.6
55	55.1	74.9	99.5	87.6	108.4	132.1	124.0	150.5	176.7
56	83.7	101.6	123.6	106.9	128.4	154.6	81.7	98.6	122.2
57	44.8	56.1	72.6	68.9	76.6	86.1	150.7	171.9	198.3
58	376.8	396.3	415.1	393.4	413.6	433.6	64.6	83.0	101.8
59	25.2	45.8	72.3	49.0	73.3	101.9	32.7	54.0	79.3
60	18.4	32.1	45.1	39.9	53.5	69.4	29.1	43.0	59.8
61	903.0	923.3	945.1	908.3	928.1	951.0	647.2	663.6	679.7
62	98.7	116.4	137.7	126.9	148.9	172.8	723.4	750.0	775.4
63	64.8	83.0	106.3	93.3	113.3	137.0	73.1	91.1	110.7
64	51.7	68.6	87.3	80.3	97.3	116.0	109.3	129.0	147.7
65	245.7	267.7	297.3	288.9	311.7	343.8	169.3	192.4	220.5
66	4.8	11.6	17.9	58.2	64.5	72.3	3678.7	3702.7	3722.6
67	22.8	41.1	63.0	57.9	82.1	104.7	392.0	416.6	443.2
68	87.3	104.9	125.2	96.3	113.5	133.8	54.2	69.1	87.3
69	57.6	69.2	83.3	68.5	89.3	121.7	466.1	498.9	526.2
70	37.7	54.3	72.0	69.6	87.6	110.0	129.2	149.1	173.9
71	296.5	352.1	384.5	332.8	399.6	439.8	0.8	11.6	51.9
72	29.9	57.1	89.6	214.7	250.6	291.9	160.5	188.0	218.8
73	49.0	69.9	94.1	165.4	193.0	226.5	241.6	265.0	293.4
74	121.3	137.0	154.4	155.8	174.1	196.4	112.4	127.5	146.4
75	43.2	66.4	92.0	72.0	96.7	127.4	312.0	342.1	371.2
76	40.0	54.2	72.5	52.1	69.4	89.1	171.7	192.6	217.7

Paisagem	APP			Hidrografia			Vegetação		
	Mín.	Méd.	Máx.	Mín.	Méd.	Máx.	Mín.	Méd.	Máx.
77	17.9	33.9	53.6	41.2	53.7	68.5	119.7	145.1	171.0
78	35.0	45.0	56.2	29.1	39.7	54.4	107.8	126.5	147.3
79	85.3	125.8	166.2	105.6	146.2	189.9	53.6	86.2	127.9
80	76.1	97.1	121.5	53.2	80.7	113.5	53.9	85.4	118.6
81	381.2	402.6	427.9	452.3	471.9	499.5	193.6	218.0	250.5
82	118.4	149.0	183.0	125.2	156.8	189.6	515.6	539.8	564.2
83	57.5	77.0	101.2	81.5	107.1	136.5	82.5	107.3	136.3
84	50.3	72.8	100.3	66.4	90.7	116.4	42.0	56.8	78.0
85	79.1	94.1	111.0	104.1	119.6	134.8	91.1	105.2	119.9
86	217.4	241.7	272.6	234.7	260.5	292.5	90.5	112.1	134.7
87	29.3	43.8	58.7	80.5	97.4	114.4	96.7	112.3	131.9
88	50.2	74.2	99.0	72.8	97.4	125.2	21.8	43.5	71.3
89	97.2	116.4	139.3	123.7	145.2	169.2	86.4	112.5	140.5
90	25.4	44.0	62.9	60.4	84.3	107.1	18.7	37.2	60.4
91	37.1	63.4	95.2	107.4	134.5	163.2	81.2	109.4	143.2
92	76.5	101.1	127.2	92.2	118.3	145.7	90.2	109.8	134.8
93	109.2	119.2	125.7	740.7	751.1	757.7	0.0	13.2	30.8
94	14.4	36.9	67.2	64.5	84.7	107.1	32.5	59.8	86.6
95	91.4	110.8	135.2	114.5	134.0	159.4	194.7	220.4	249.8
96	161.6	178.2	202.2	150.5	161.1	182.1	47.8	81.7	104.2
97	8.7	24.9	47.8	52.6	73.6	96.1	170.3	195.5	226.3
98	66.4	91.5	117.5	82.0	109.1	138.4	98.5	122.3	150.4
99	51.5	71.2	98.7	93.0	116.1	143.5	31.9	51.2	77.4
100	28.4	43.7	61.5	56.6	75.1	99.0	222.0	253.3	287.6
101	47.8	64.5	87.1	72.1	91.7	116.5	22.4	36.9	53.7
102	102.4	125.6	149.7	115.2	137.8	162.3	51.9	66.6	85.2

Paisagem	APP			Hidrografia			Vegetação		
	Mín.	Méd.	Máx.	Mín.	Méd.	Máx.	Mín.	Méd.	Máx.
103	30.0	56.9	84.5	77.1	109.0	141.5	616.2	648.0	675.8
104	20.4	30.4	47.0	72.8	89.0	112.2	2.5	18.1	51.6
105	43.9	85.0	111.2	105.4	135.6	167.4	37.9	69.4	104.9
106	120.8	130.6	150.7	97.1	105.0	124.5	132.7	156.1	179.1
107	39.4	55.2	73.1	73.8	89.0	104.2	20.4	38.3	57.8
108	87.4	107.9	130.4	110.7	133.6	160.0	43.2	70.0	96.9
109	0	0	0	0	0	0	0	0	0
110	272.0	287.6	309.4	299.2	319.5	347.1	199.4	221.5	243.2
111	106.0	124.9	148.0	139.0	158.4	179.5	294.3	318.9	344.8
112	218.8	237.3	260.2	234.7	253.4	276.6	48.3	66.0	84.4
113	72.4	86.9	101.4	89.9	104.3	120.4	72.5	94.1	116.1
114	152.6	175.2	203.1	194.9	215.3	242.2	172.5	209.4	246.1
115	230.3	250.6	273.0	199.8	220.9	245.3	48.4	77.9	105.9
116	82.2	107.2	131.3	108.0	135.0	161.0	127.3	148.4	174.7
117	84.7	102.0	122.4	97.0	113.3	132.0	66.5	83.2	98.6
118	132.8	162.0	188.5	159.1	185.3	210.3	19.4	37.9	62.3
119	42.1	64.6	96.1	86.2	106.8	137.2	112.3	131.9	153.6
120	56.6	76.9	104.3	825.3	853.7	878.8	12.4	44.0	74.8