LÔIDE ANGELINI SOBRINHA

Classificação semiautomática de imagens de satélites e suas implicações na
modelação do escoamento superficial direto em bacias urbanas

VERSÃO CORRIGIDA

São Carlos

2016

LÔIDE ANGELINI SOBRINHA

Classificação semiautomática de imagens de satélites e suas implicações na modelação do escoamento superficial direto em bacias urbanas

Tese apresentada à Escola de Engenharia de São Carlos, da Universidade de São Paulo, como parte dos requisitos para obtenção do título de Doutor em Ciências: Engenharia Hidráulica e Saneamento

Orientador: Prof. Dr. João Luiz Boccia Brandão

São Carlos
2016

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

A582 Angelini Sobrinha, Lôide
Classificação semiautomática de imagens de
satélites e suas implicações na modelação do
escoamento superficial direto em bacias urbanas /
Lôide Angelini Sobrinha; orientador João Luiz Boccia
Brandão. São Carlos, 2016.

Tese (Doutorado) - Programa de Pós-Graduação em
Engenharia Hidráulica e Saneamento e Área de
Concentração em Hidráulica e Saneamento -- Escola de
Engenharia de São Carlos da Universidade de São
Paulo, 2016.

1. Sensoriamento remoto. 2. Modelagem hidrológica.
3. Algoritmo de classificação de imagens.
4. Análise multicritério. I. Título.

FOLHA DE JULGAMENTO

Candidata: Engenheira **LOIDE ANGELINI SOBRINHA**.

Título da tese: "Proposição de metodologia para avaliar a classificação semiautomática de imagens de satélite e suas implicações na quantificação do escoamento superficial direto em bacias urbanas".

Data da defesa: 15/07/2016

Comissão Julgadora:

Resultado:

Prof. Titular **Edson Cezar Wendland (Orientador)**
(Escola de Engenharia de São Carlos/EESC)

Aprovada

Profa. Titular **Luisa Fernanda Ribeiro Reis**
(Escola de Engenharia de São Carlos/EESC)

Aprovada

Prof. Dr. **Ademir Pacelli Barbassa**
(Universidade Federal de São Carlos/UFSCar)

APROVADA

Prof. Dr. **José Paulo Soares de Azevedo**
(Universidade Federal do Rio de Janeiro/UFRJ)

APROVADA

Dra. **Silvana Susko Marcellini**
(INNOVARE Engenharia Ltda.)

Aprovada

Coordenadora do Programa de Pós-Graduação em Engenharia Hidráulica e Saneamento:

Profa. Associada **Maria Bernadete A. Varesche Silva**

Presidente da Comissão de Pós-Graduação:
Prof. Associado **Luis Fernando Costa Alberto**

Dedico ao Professor
João Luiz Boccia Brandão

AGRADECIMENTOS

Diante da oportunidade de poder expressar minha gratidão, busco fazê-lo de forma mais pura e sincera, pois esse é um dos sentimentos humanos mais nobres.

Ao professor João Luiz Boccia Brandão, excelente profissional e verdadeiro exemplo de vida, por toda dedicação na qual conduziu a pesquisa e pela amizade que me ofereceu.

Ao professor Ademir Paceli Barbassa pela amizade.

À minha família, que sempre apoiou a minha carreira profissional e me ensinou a olhar sempre para frente. Deu-me forças para superar distâncias e dificuldades. Destaco agradecimento especial à minha irmã Nágela Angelini Recher.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPQ) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão da bolsa de pesquisa.

À Financiadora de Pesquisa e Projetos (FINEP) e ao Projeto Manejo de Águas Pluviais em Meio Urbano (Maplu 2), que forneceram recursos para a compra dos equipamentos utilizados na pesquisa, da imagem de satélite de alta resolução (WorldView-II) e do *software* eCognition.

À Universidade de São Paulo e ao Departamento de Engenharia Hidráulica e Saneamento que me ofereceram apoio e forneceram boas condições de trabalho.

À toda equipe do Laboratório de Simulação Numérica (LabSim) que constituíram uma verdadeira equipe, demonstrando competência e dedicação ao trabalho, superando os desafios do trabalho árduo que é o monitoramento hidrológico e acima de tudo, à amizade. Minha gratidão à: Renata Genova Martins, Leandro Guimarães Bais Martins, Fernando Girardi de Abreu, Dayse Lira, Ana Elisa Ferrari Carvalho, Heider Gusmão Lemos, Marcus Vinícius Galbetti, Rafael Rezende Novais, Rodrigo Martins de Almeida, Anne Caroline Negrão, Daniele Feitoza e Maria Mercedes Gamboa.

Aos amigos que fiz na cidade de São Carlos (para citar alguns: Thalita Fernandes, Gustavo Arthur Monzeli, Priscila Aragão Zaninetti, Ana Carolina Toniolo, Stephanie Andreossi, Ivo Mateus Pinatti, Phillipe Fernandes de Almeida, Priscila Marcones, Thiago Galvão Tiradentes Decina, Thays dos Santos Ferreira, Lara Rosa, Suelen Almeida, Rafael de Andrade, Leonardo Dal Picolo Cadurin, Roger Alfredo, Júlia Inforzato Guermandi, Natália Araboni C. Oliveira).

À minha segunda família Girardi de Abreu: Odete, Rubem, Robson, Tania, Victório,
Luiza e Fernando.

“O que mais me surpreende na humanidade são os homens, porque perdem a saúde para juntar dinheiro, depois perdem dinheiro para recuperar a saúde. E por pensarem ansiosamente no futuro, esquecem-se do presente de tal forma que acabam por não viver nem o presente nem o futuro. E vivem como se nunca fossem morrer... e morrem como se nunca tivessem vivido.”

Dalai Lama

RESUMO

ANGELINI SOBRINHA, L. **Classificação semiautomática de imagens de satélites e suas implicações na modelação do escoamento superficial direto em bacias urbanas.** 2016. 193 f. Tese (Doutorado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Paulo, 2016.

A modelagem hidrológica quando associada aos recursos do sensoriamento remoto e do geoprocessamento torna-se uma ferramenta importante, pois é capaz de estabelecer diferentes cenários da cobertura e do uso da terra e suas implicações na drenagem urbana, auxiliando no planejamento urbano. Entretanto, a relação entre o modelo chuva x vazão e tais técnicas, com finalidade de avaliar classificadores de imagens a partir de hidrogramas de cheia não foi encontrada na literatura, tornando esse o objetivo principal desta tese. Para isso, foram utilizadas três imagens de satélite de diferentes resoluções espaciais (0,5m, 5m e 15m) e três algoritmos classificadores (Máxima Verossimilhança, Máquinas Vetores Suporte e Análise Orientada a Objeto) e formados conjuntos denominado “classificador-imagem” para classificação da cobertura e do uso da terra. As áreas das classes dos usos da terra de cada conjunto “classificador-imagem” e os valores de *Curve Number* foram os principais dados de entrada do modelo chuva-vazão NRCS, que permitiu gerar os hidrogramas de cheia para cada caso. Os hidrogramas simulados foram comparados aos hidrogramas observados na bacia e avaliados, quanto a sua representatividade, pelo coeficiente de Nash Sutcliffe. As classificações do uso da terra foram avaliadas pelo Índice Kappa, com valores de 0,58 a 0,99 e pela Exatidão Global, com valores de 0,64 a 0,99. Para as vazões, o coeficiente de Nash Sutcliffe foi considerado satisfatório ($NS < 0,50$) em duas simulações e, nas demais simulações, considerado muito bom ($NS > 0,75$). Para fornecer subsídio a tomada de decisão, foi realizada uma análise multicritério dos conjuntos classificador-imagem, que permitiu classificar os conjuntos com maior desempenho: 1º) o classificador SVM e a imagem Landsat-8; 2º) o classificador MaxVer e a imagem WordView-II; 3º) o classificador NN e a imagem RapidEye.

Palavras-chave: Modelo chuva-vazão. Algoritmo de classificação de imagens. Sensoriamento remoto. Análise multicritério.

ABSTRACT

ANGELINI SOBRINHA, L. **Semi-automatic classification of satellite images and their implications in modeling direct runoff in urban watersheds.** 2016. 193 f. Thesis (Ph.D.) - São Carlos School Engineering, University of São Paulo, São Paulo, 2016.

Hydrological modeling when associated with remote sensing and geoprocessing resources becomes an important tool, because it is able to establish different land use scenarios and its implications for urban drainage, assisting in urban planning. However, the relationship between the routing model and such techniques, for purpose to evaluate images classifiers from the runoff hydrograph was not found in the literature, making this the main objective of this thesis. Thereunto, three satellite images were used in different spatial resolutions (0.5m, 5m and 15m) and three algorithms classifiers (Maximum Likelihood, Support Vector Machine and Oriented Object Analysis) and composed sets called "classifier-image" for the land use classification. The areas of the land use classes of each set "classifier-image" and the Curve Number values were the main input of the routing model NRCS, which allowed generating the runoff hydrograph for each case. The simulated hydrographs were compared to the observed hydrograph in the basin and evaluated their representativeness through the Nash Sutcliffe coefficient. Kappa Index was calculated to evaluate land use classifications, with values between 0.58 to 0.99 and Global accuracy between 0.64 to 0.99. Towards the flows rates, the Nash Sutcliffe coefficient was considered satisfactory for two simulations ($NS < 0.50$) and, to other simulations, considered very good ($NS > 0.75$). To provide subsidy to decision-making, it carried out a multi-criteria analysis of the classifier-image sets, that allowed to classify the set with higher performance: 1) SVM classifier and Landsat-8 image; 2) MaxVer classifier and WorldView-II image; 3) NN classifier and RapidEye image.

Keywords: Routing model. Image classification algorithm. Remote sensing. Multicriteria-analyse.

LISTA DE ILUSTRAÇÕES

Figura 1 - Efeito da urbanização na onda de cheia (hidrograma).....	22
Figura 2 - Estrutura da discretização dos modelos	29
Figura 3 - Método de Thiessen (esquerda) e método das isoietas (direita)	32
Figura 4 - Princípio da proporcionalidade (direita) e princípio da sobreposição (esquerda) ...	36
Figura 5 - HU sintético triangular do NRCS	46
Figura 6 - Representação do IFOV na definição do tamanho do pixel da imagem.....	51
Figura 7 - Espectro eletromagnético.....	52
Figura 8 - Assinaturas espectrais de uma folha	53
Figura 9 - Esquema do cubo de cores RGB.....	59
Figura 10 - Geração da imagem RGB no plano de cor (corte transversal)	59
Figura 11 - Histograma da imagem	60
Figura 12 - Composição de bandas 4,3,2 em imagem MS com resolução espacial de 30m (a) e imagem fusionada (MS+PAN) com resolução espacial de 15m (b).	65
Figura 13 - Distribuição normal	70
Figura 14 - Sistema SVM de classificação de imagens com máxima separação do hiperplano (a) e feições linearmente separáveis (b)	72
Figura 15 - Categorias de cobertura da terra derivadas dos dados de referência (a) e imagem classificada (b).	77
Figura 16 - Exemplo da aplicação dos avaliadores de acuracidade da classificação	78
Figura 17 - Classificação dos usos da terra em bacias hidrográficas do município de São Carlos – SP	87
Figura 18 - Localização da área de estudo	90
Figura 19 - Bacia do Córrego do Mineirinho localizada em São Carlos – SP	91
Figura 20 - Modelo Digital de Elevação da bacia do Córrego do Mineirinho	92
Figura 21 - Pluviógrafo eletrônico com <i>datallogger</i>	93
Figura 22 - Medidor de vazão IQ Plus ADCP fixo (A) e sistema de proteção de impactos (B)	93
Figura 23 - Rede de monitoramento hidrológico na bacia do Córrego do Mineirinho	94
Figura 24 - Imagens de satélites pré-processadas no Orfeo Monteverdi.....	98
Figura 25 - Coleta de amostras das classes da cobertura e do uso da terra	100
Figura 26 - Fluxograma do processo de classificação das imagens	101

Figura 27 - Processo de classificação de imagens e obtenção da matriz de confusão no ArcGIS	104
Figura 28 - Processo de classificação de imagens no Orfeo ToolBox do QGIS	106
Figura 29 - Interface do programa GroupStas presente no QGIS	107
Figura 30 - Fluxograma da regra Fuzzy para a classificação da imagem WorldView-II	108
Figura 31 - Fluxograma da regra Fuzzy para a classificação das imagens RapidEye e Landsat-8.....	109
Figura 32 - Eventos chuva-vazão utilizados na pesquisa.....	112
Figura 33 - Critérios utilizados na análise TOPSIS para avaliar os classificadores de imagens	114
Figura 34 - Critérios utilizados na análise TOPSIS para avaliar as imagens de satélite.....	114
Figura 35 - Desempenho dos classificadores de imagens.....	118
Figura 36 - Hidrogramas de ESD para classes de uso da terra definidas a partir de classificação manual	119
Figura 37 - (A) Mapa da cobertura e do uso da terra gerado pelo classificador MaxVer do ArcGis e (B) imagem WorldView-II com resolução espacial de 0,5 metros	121
Figura 38 - Hidrogramas de ESD das classes de uso da terra no exutório da bacia para o evento 3	124
Figura 39 - (A) Mapa da cobertura e do uso da terra gerado pelo classificador MaxVer do ArcGis e (B) imagem RapidEye com resolução espacial de 5 metros.....	126
Figura 40 - Efeito dos hidrogramas de ESD das classes de uso da terra no exutório da bacia para o evento 3	128
Figura 41 - (A) Mapa da cobertura e do uso da terra gerado pelo classificador MaxVer do ArcGis e (B) imagem Landsat-8 com resolução espacial de 15 metros	129
Figura 42 - Efeito dos hidrogramas de ESD das classes de uso da terra no exutório da bacia para o evento 3	131
Figura 43 - Índices de avaliação da classificação MaxVer e das vazões simuladas	132
Figura 44 - (A) Mapa da cobertura e do uso da terra gerado pelo classificador NN do Ecognition e (B) imagem WorldView-II com resolução espacial de 0,5m	133
Figura 45 - Efeito dos hidrogramas de ESD das classes de uso da terra no exutório da bacia para o evento 3	135
Figura 46 - (A) Mapa da cobertura e do uso da terra gerado pelo classificador NN do Ecognition e (B) imagem RapidEye com resolução espacial de 5m	137

Figura 47 - Efeito dos hidrogramas de ESD das classes de uso da terra no exutório da bacia para o evento 3.....	139
Figura 48 - (A) Mapa da cobertura e do uso da terra gerado pelo classificador NN do Ecognition (B) imagem Landsat-8 com resolução espacial de 15m	141
Figura 49 - Efeito dos hidrogramas de ESD das classes de uso da terra no exutório da bacia para o evento 3.....	143
Figura 50 - Índices de avaliação da classificação NN e das vazões simuladas	144
Figura 51 - (A) Mapa da cobertura e do uso da terra gerado pelo classificador SVM do QGIS e (B) imagem WorldView-II com resolução espacial de 0,5m	146
Figura 52 - Efeito dos hidrogramas de ESD das classes de uso da terra no exutório da bacia para o evento 3.....	147
Figura 53 - (A) Mapa da cobertura e do uso da terra gerado pelo classificador SVM do QGIS e (B) imagem RapidEye com resolução espacial de 5m	150
Figura 54 - Efeito dos hidrogramas de ESD das classes de uso da terra no exutório da bacia para o evento 3.....	151
Figura 55 - (A) Mapa da cobertura e do uso da terra gerado pelo classificador SVM do QGIS (B) imagem Landsat-8 com resolução espacial de 15m.....	153
Figura 56 - Efeito dos hidrogramas de ESD das classes de uso da terra no exutório da bacia para o evento 3.....	155
Figura 57 - Índices de avaliação da classificação SVM e das vazões simuladas	155
Figura 58 - Variação nas áreas das classes de uso da terra que mais geraram escoamento superficial	156
Figura 59 - Área de cada classe de uso da terra para a classificação SVM e diferentes imagens de satélite	157
Figura 60 - Área de cada classe de uso da terra para a classificação NN e diferentes imagens de satélite	158
Figura 61 - Área de cada classe de uso da terra para a classificação MaxVer e diferentes imagens de satélite.....	160
Figura 62 - Hidrogramas de ESD gerados a partir do classificador SVM para o evento 1	162
Figura 63 - Hidrogramas de ESD gerados a partir do classificador MaxVer para o evento 1	163
Figura 64 - Hidrogramas de ESD gerados a partir do classificador NN para o evento 1	164
Figura 65 - Hidrogramas de ESD gerados a partir do classificador SVM para o evento 2	165
Figura 66 - Hidrogramas de ESD gerados a partir do classificador MaxVer para o evento 2	166
Figura 67 - Hidrogramas de ESD gerados a partir do classificador NN para o evento 2.....	167

Figura 68 - Hidrogramas de ESD gerados a partir do classificador SVM para o evento 3 ...	168
Figura 69 - Hidrogramas de ESD gerados a partir do classificador MaxVer para o evento 3	169
Figura 70 - Hidrogramas de ESD gerados a partir do classificador NN para o evento 3	170
Figura 71 - Vazões de pico simuladas e observadas	174

LISTA DE TABELAS

Tabela 1 - Fórmulas empíricas de tempo de concentração.....	30
Tabela 2 - Classificação hidrológica dos solos brasileiros	40
Tabela 3 - Condições antecedentes de umidade do solo	42
Tabela 4 - Valores de CN para áreas urbanas.....	42
Tabela 5 - CN para áreas agrícolas	43
Tabela 6 - CN estimados para cana de açúcar em grupos hidrológicos de cobertura do solo complexos no Hawai	44
Tabela 7 - Características dos instrumentos imageadores OLI e TIRS	57
Tabela 8 - Especificações técnicas básicas de satélites	58
Tabela 9 - Exemplo de matriz de confusão	76
Tabela 10 - Representatividade da classificação relacionada à estatística do índice Kappa	79
Tabela 11 - Bandas do satélite WorldView-II	95
Tabela 12 - Índice Kappa para classificação da imagem WorldView-II com diferentes processos de coleta de amostras de treinamento	99
Tabela 13 - Comparação entre as classes de uso da terra utilizadas na classificação e aquelas utilizadas nos cálculos hidrológicos	102
Tabela 14 - Dados dos eventos de precipitação utilizados	111
Tabela 15 - Dados dos eventos de vazão utilizados	111
Tabela 16 - <i>Curve Number</i> aplicados	112
Tabela 17 - Tabela de importância utilizada para atribuição dos pesos aos critérios e as alternativas.....	113
Tabela 18 - Índices de exatidão obtidos nas matrizes de confusão para os classificadores de imagens.....	117
Tabela 19 - Contribuição das vazões por classes de uso da terra na classificação manual da imagem WorldView-II	118
Tabela 20 - Matriz de confusão relacionada à imagem WorldView-II e a imagem classificada	122
Tabela 21 - Contribuição das vazões por classes de uso da terra na classificação MaxVer e imagem WorldView-II	123
Tabela 22 - Matriz de confusão relacionada à imagem RapidEye e a imagem classificada ..	127
Tabela 23 - Contribuição das vazões das classes de uso da terra na classificação MaxVer e imagem RapidEye	127

Tabela 24 - Matriz de confusão relacionada à imagem Landsat-8 e a imagem classificada .	130
Tabela 25 - Contribuição das vazões das classes de uso da terra na classificação MaxVer e imagem Landsat-8.....	130
Tabela 26 - Matriz de confusão relacionada à imagem WorldView-II e a imagem classificada	134
Tabela 27 - Contribuição das vazões das classes de uso da terra na classificação NN e imagem WorldView-II.....	135
Tabela 28 - Matriz de confusão relacionada à imagem RapidEye e a imagem classificada..	136
Tabela 29 - Contribuição das vazões das classes de uso da terra na classificação NN e imagem RapidEye	138
Tabela 30 - Matriz de confusão relacionada à imagem Landsat-8 e à imagem classificada .	142
Tabela 31 - Contribuição das vazões das classes de uso da terra na classificação NN e imagem Landsat-8.....	142
Tabela 32- Matriz de confusão relacionada à imagem WorldView-II e a imagem classificada	144
Tabela 33 - Contribuição das vazões das classes de uso da terra na classificação SVM e imagem WorldView-II.....	147
Tabela 34 - Matriz de confusão relacionada à imagem RapidEye e a imagem classificada..	148
Tabela 35 - Contribuição das vazões das classes de uso da terra na classificação SVM e imagem RapidEye	151
Tabela 36 - Matriz de confusão relacionada à imagem Landsat-8 e a imagem classificada .	152
Tabela 37 - Contribuição das vazões das classes de uso da terra na classificação SVM e imagem Landsat-8.....	154
Tabela 38- Porcentagens das áreas de cada classe nas diferentes classificações.....	156
Tabela 39 - Valores das áreas obtidos pela classificação SVM.....	157
Tabela 40 - Valores das áreas obtidos pela classificação NN.....	159
Tabela 41 - Valores das áreas obtidos pela classificação MaxVer	160
Tabela 42 -Vantagens e desvantagens dos classificadores semiautomáticos de imagens	172
Tabela 43 - Erros relativos entre as vazões de pico observadas e simuladas.....	173
Tabela 44 - Peso dos critérios utilizados na análise dos classificadores de imagens.....	175
Tabela 45 - Peso dos critérios utilizados na análise das imagens de satélites	176
Tabela 46 - Resultado da análise multicritério dos classificadores e das imagens de satélite	176
Tabela 47 - Metodologia proposta e resumo dos resultados obtidos na pesquisa.....	184

LISTA DE SIGLAS

ADCP	Acoustic Doppler Current Profiler
ANN	Artificial Neural Network
AOO	Análise Orientada a Objeto
AP	Acurácia do Produtor
AU	Acurácia do Usuário
CAR	Cadastro Ambiental Rural
CDCC	Centro de Divulgação Científica e Cultural
CN	Curve Number
CNES	Centro Nacional de Estudos Espaciais
CSV	Comma-Separated Values
DBF	Data Base File
DN	Digital Number
EBSC	Escola Municipal Bento da Silva César
EESC/USP II	Campus II da Escola de Engenharia de São Carlos, da Universidade de

São Paulo

ESD	Escoamento Superficial Direto
EULA	End-User License Agreement
GS	Gram Schmidt
GSG	ArcGIS Signature File
HPF	High-Pass Filter
HU	Hidrograma Unitário
HUI	Hidrograma Unitário Instantâneo
IFOV	Instantaneous Field of View
IHS	Hue, Saturation, Intensity
INPE	Instituto Nacional de Pesquisas Espaciais
IR	Infrared
ITK	Insight Toolkit
MaxVer	Máxima Verossimilhança
MDE	Modelo Digital de Elevação
ML	Maximum Likelihood
MMA	Ministério do Meio Ambiente
MS	Banda multiespectral

MVG	Máxima Verossimilhança Gaussiana
NN	Nearest Neighbor
NRCS	Natural Resources Conservation Service
NS	Coeficiente de Nash Sutcliffe
NVDI	Índice de Vegetação da Diferença Normalizada
OLI	Operacional Terra Imager
PAN	Banda Pancromática
PC	Principais Componentes
PDI	Processamento Digital de Imagens
PIXEL	Picture Element
PSSF	Posto de Saúde da Família do Jardim Santa Felícia
RCS	Relative Contribution Spectral
SAVI	Índice de Vegetação Ajustado ao Solo
SCS	Soil Conservation Service
SIGs	Sistemas de Informação Geográficas
SVM	Support Vector Machine
Tc	Tempo de concentração
TIRS	Thermal Infrared Sensor
UTM	Universal Transverse Mercator

SUMÁRIO

1.0 INTRODUÇÃO	21
1.1 Hipóteses	24
1.2 Objetivos	25
1.3 Organização dos capítulos.....	25
2.0 MODELOS CHUVA-VAZÃO	28
2.1. Parâmetros e monitoramento hidrológico	31
2.2. Hidrograma Unitário	34
2.3. Modelo Natural Resources Conservation Service (NRCS)	38
2.3.1. Hidrograma unitário sintético triangular do NRCS	45
2.4. Análise multicritério TOPSIS	47
3.0 PROCESSAMENTO DIGITAL DE IMAGENS	49
3.1. Estrutura das imagens de sensoriamento remoto	50
3.1.1 Sensores remotos e resolução de imagens	52
3.2. Características dos satélites e de suas imagens	55
3.3. A cor no sensoriamento remoto	58
3.4. Histograma das imagens de sensoriamento remoto	60
3.5. Técnicas de processamento digital de imagens.....	61
3.5.1. Correção geométrica e radiométrica	62
3.5.2. Técnica de fusão de imagens.....	63
3.5.3. Técnicas de segmentação de imagens	65
3.5.4. Técnicas de classificação de imagens	67
3.6. Método de classificação de imagens	68
3.6.1. Máxima Verosimilhança - MaxVer	69
3.6.2. Método Support Vector Machine (Máquinas Vetores Suporte) – SVM.....	72
3.6.3. Método da Análise Orientada a Objeto (AOO)	74
3.7. Avaliação da classificação de imagem.....	76
3.8. Classificadores automáticos de imagem de sensoriamento remoto	80
3.8.1. eCognition Developer	80
3.9. Sistemas de Informações Geográficas: uma ferramenta para classificação de imagens.....	82

3.9.1. QGIS	83
3.9.2. ArcGis.....	84
3.10. Estudos relacionados à classificação de imagens de sensoriamento remoto	84
4.0 METODOLOGIA DA PESQUISA	88
4.1. Área de estudo	89
4.2. Monitoramento hidrológico	92
4.3. Características das imagens de satélites utilizadas	95
4.4. Pré-processamento das imagens no <i>software</i> Orfeo Monteverdi	96
4.5. Definição do processo de coleta de amostras	98
4.6. Classificação das imagens	100
4.6.1 Classificação pelo método MaxVer e obtenção da matriz de confusão no ArcGis	102
4.6.2. Classificação pelo método SVM e obtenção da matriz de confusão no QGIS...	105
4.6.3. Classificação por Análise Orientada a Objeto e obtenção da matriz de confusão no eCognition.....	107
4.6.4. Classificação manual	109
4.7. Cálculo de índices avaliadores da classificação de imagens	110
4.8. Processamento dos dados hidrológicos	110
4.9. Hidrogramas simulados	112
4.10. Análise multicritério	113
5.0 RESULTADOS E DISCUSSÃO	116
5.1. Classificadores de imagens.....	117
5.1.1. Classificação manual com imagem WorldView-II	118
5.1.2. Classificador MaxVer com imagem WorldView-II	120
5.1.3 Classificação MaxVer com imagem RapidEye	124
5.1.4. Classificador MaxVer com imagem Landsat-8	128
5.1.5. Classificador NN com imagem WorldView-II.....	132
5.1.6. Classificador NN com imagem RapidEye	136
5.1.7. Classificador NN com imagem Landsat-8.....	139
5.1.8. Classificador SVM com imagem WorldView-II.....	144
5.1.9. Classificador SVM com imagem RapidEye	148
5.1.10. Classificador SVM com imagem Landsat-8.....	152
5.2. Análise das áreas da cobertura e do uso da terra nas diferentes imagens classificadas	155

5.2.1. Classificador SVM.....	156
5.2.2. Classificador NN.....	158
5.2.3. Classificador MaxVer	159
5.3. Análise dos classificadores de imagens na geração de escoamento superficial.....	160
5.3.1. Evento 1	161
5.3.2. Evento 2	164
5.3.3. Evento 3	167
5.4. Importância da resolução espacial da imagem de satélite no processo de classificação para estudos hidrológicos	170
5.5. Facilidades de aplicação das técnicas de classificação	171
5.6. Representação dos classificadores em relação às vazões observadas	172
5.7. Análise multicritério.....	174
6.0 CONCLUSÃO	179
6.1. Desempenho dos classificadores de imagem de satélite	179
6.2. Impacto da resolução espacial das imagens nos hidrogramas de ESD	180
6.3. Técnicas de processamento digital de imagens e geoprocessamento: facilidade e dificuldades.....	181
6.4. Análise multicritério.....	182
6.5. Resumo da metodologia proposta	183
6.6. Recomendações para continuidade dos estudos.....	184
7.0 REFERÊNCIAS BIBLIOGRÁFICAS	186

1.0 INTRODUÇÃO

Dentre os vários problemas associados à água no ambiente urbano, a gestão da drenagem urbana é um dos problemas mais sérios, pois pode gerar uma série de riscos à população e prejuízos aos bens e à economia do município.

Tais problemas tiveram origem a partir da década de 60 com o efeito da impermeabilização das superfícies. Nessa época, o Brasil enfrentou um intenso fenômeno de êxodo rural provocado pelas ofertas de melhoria da qualidade de vida e pelas facilidades que o meio urbano oferecia, resultando no crescimento das áreas urbanas de forma rápida e desordenada.

A ocupação das áreas urbanas, que envolveu a apropriação de áreas de várzeas e a transformação dos ambientes naturais em ocupações urbanas, gerou consequências negativas sobre os recursos hídricos. Tais consequências são relacionadas ao uso dos recursos hídricos para: abastecimento de água, transporte e tratamento de esgotos sanitários e drenagem pluvial. Os problemas causados por enchentes são relacionadas à ocupação das áreas de várzea ribeirinha e à impermeabilização das superfícies que causa o aumento do Escoamento Superficial Direto (ESD).

Para um melhor entendimento dos impactos causados pelo processo de impermeabilização, deve-se analisar o processo hidrológico nas superfícies naturais. Neste processo, parte da água precipitada é interceptada pela vegetação, parte dela infiltra-se no solo, parte é evaporada e a parcela restante gera o ESD. Já nas superfícies impermeabilizadas, há redução da interceptação, da evaporação e da infiltração, favorecendo o aumento do escoamento superficial e, consequentemente, o aumento do pico de vazão e a redução do tempo de concentração da água na bacia.

O efeito da urbanização no hidrograma cheia é ilustrado na Figura 1. Nesta figura são apresentadas as cheias produzidas em uma bacia no estado natural e no estado de urbanização, referentes à mesma chuva. Na área urbana, a vazão cresce mais rapidamente e o pico é maior.

Consequentemente para a bacia urbanizada, os tempos de base¹ e de pico do hidrograma são menores e as vazões e volumes escoados maiores. Do ponto de vista hidráulico, a cheia pré-urbanização é amortecida pela bacia em estado natural; já a cheia urbana é mais rápida e pouco abatida, em função das características hidráulicas do “novo” escoamento superficial gerado pela impermeabilização.

A infiltração e o escoamento superficial possuem uma relação direta, pois quanto maior a infiltração, menor será o ESD; assim, em superfícies impermeabilizadas, o escoamento superficial é sempre maior, devido à baixa infiltração da água no solo.

Figura 1 - Efeito da urbanização na onda de cheia (hidrograma)

A Política de Desenvolvimento Urbano foi instituída na Constituição Federal em 1988 e tem por objetivo ordenar o pleno desenvolvimento das funções sociais da cidade para garantir o bem-estar de seus habitantes. O artigo 182 §1º estabelece como instrumento básico dessa política o Plano Diretor, que é obrigatório para cidades com mais de vinte mil habitantes e deve ser aprovado pela Câmara Municipal.

A política urbana foi regulamentada pela Lei Federal nº 10.257 de 10 de julho de 2001, conhecida como Estatuto da Cidade. Esta estabelece diretrizes gerais, tais como a ordenação e o controle do uso da terra em prol do bem coletivo, da segurança, do bem-estar dos cidadãos e do equilíbrio ambiental.

¹ Tempo base do hidrograma corresponde ao intervalo de tempo entre o início da chuva e o tempo em que terminam os escoamentos superficial e subsuperficial, enfim é o tempo que delimita a passagem da onda de cheia numa seção do rio.

O planejamento do município é o instrumento da política urbana que prevê o plano diretor e o zoneamento ambiental. O zoneamento, por sua vez, é um instrumento amplamente utilizado nos planos diretores, através do qual a cidade é dividida em áreas sobre as quais incidem diretrizes diferenciadas para a cobertura e o uso da terra, especialmente os índices urbanísticos. O levantamento da cobertura e do uso da terra indica a distribuição geográfica da tipologia de uso, identificada por meio de padrões homogêneos da cobertura terrestre.

A forma típica de apresentação de uma classificação da cobertura e do uso da terra para fins de planejamento urbano (zoneamento) é um mapa contendo as zonas (tipos de cobertura e usos da terra). Este mapa pode ser obtido por meio de classificação de imagens de satélites. As formas de classificação das imagens são basicamente três: manual, automática e semiautomática.

A classificação manual, se realizada com auxílio de imagem de alta resolução espacial, pode representar as características dos usos da terra acuradamente; entretanto é necessário dispor de tempo para executar esse trabalho. Já as classificações automáticas e semiautomáticas são realizadas a partir de *softwares* classificadores e do conhecimento do usuário na aplicação dessas ferramentas.

Os classificadores de imagens são muitos e a licença de aquisição difere quanto a sua disponibilidade: de forma gratuita ou custosa. Quanto à sua tipologia, podem ser *softwares* específicos e com função única de classificar imagens ou incorporados aos Sistemas de Informações Geográficas (SIG's).

Atualmente, com a facilidade de acesso às tecnologias de sensoriamento remoto e às técnicas de geoprocessamento, tornou-se viável a execução da classificação da cobertura e do uso da terra de forma gratuita. Entretanto, a combinação entre os dados de entrada (imagens de satélite) e os classificadores disponíveis podem gerar demasiados resultados, dificultando a tomada de decisão.

Estudos que apresentam ferramentas de suporte à decisão no âmbito do planejamento urbano são relevantes neste contexto. Assim sendo, esse é um dos focos desta tese, pois propõe uma metodologia para avaliar a classificação semiautomática de imagens a partir de hidrogramas de cheia e busca ainda apresentar, por meio de uma análise multicritério, os conjuntos classificadores-imagens com melhor desempenho.

O conteúdo desta tese pretende auxiliar o leitor, principalmente aqueles que trabalham nas prefeituras dos pequenos municípios, a decidir sobre quais ferramentas do

CAPÍTULO 1 - ELEMENTOS INTRODUTÓRIOS

sensoriamento remoto, do processamento digital de imagens e do geoprocessamento podem ser utilizadas com confiabilidade na obtenção de hidrogramas de cheia em pequenas e médias bacias urbanas e semiurbanas (área de drenagem entre 2,5 km² e 100 km²).

1.1 Hipóteses

Tendo em vista que a classificação da cobertura e do uso da terra é uma informação fundamental para o desenvolvimento de estudos de hidrologia urbana, em especial na modelagem chuva-vazão, e que a imagem de satélite é o principal dado de entrada da classificação, há a necessidade de se conhecer o comportamento dos processos envolvidos. Portanto, esta tese é baseada nas seguintes hipóteses:

i) As imagens de satélites com maior resolução espacial são as que geram os mapas da cobertura e do uso da terra mais representativos da verdade de campo.

ii) As imagens de baixa resolução espacial (30 m) não são representativas para pequenas bacias urbanas e semiurbanas (área inferior a 2,5 km²).

iii) As funcionalidades de um Sistema de Informação Geográfica permitem e facilitam as análises necessárias às atividades de gerenciamento de recursos hídricos no âmbito de uma bacia hidrográfica. São diversas as aplicações desses recursos na hidrologia urbana, entretanto a hipótese de avaliar a classificação semiautomática de imagens de satélite a partir de hidrogramas de cheia precisos não foi testada.

iv) Há influência das confusões entre as classes da cobertura e do uso da terra no hidrograma de escoamento superficial direto simulado.

v) Parte-se do princípio que o hidrólogo sem especialização na área de geociências e o técnico que utiliza as ferramentas do sensoriamento remoto e do geoprocessamento não possuem a base teórica para aplicação de tais recursos de forma otimizada. Diz-se “forma otimizada” aquela em que o especialista possui base suficiente para optar pelas ferramentas

CAPÍTULO 1 - ELEMENTOS INTRODUTÓRIOS

que produzirão o resultado esperado e, portanto, otimiza seu tempo de trabalho. Dessa forma, hipotetiza-se que a avaliação multicritério, que apresenta o melhor desempenho dentre os conjuntos “classificadores-imagens”, possa auxiliar na tomada de decisão em relação à busca da solução ideal.

1.2 Objetivos

O objetivo deste trabalho consiste em avaliar diferentes técnicas de classificação semiautomática de imagens e ferramentas de geoprocessamento para propor uma metodologia de avaliação da classificação semiautomática de imagens de satélite e suas implicações na quantificação do escoamento superficial direto. Para isso, os seguintes objetivos específicos foram estabelecidos:

- i. Apontar os classificadores e as imagens de satélite de melhor desempenho;
- ii. Quantificar o impacto da resolução espacial das imagens de satélite na geração de hidrogramas de cheia;
- iii. Apontar as facilidades e dificuldades da aplicação de técnicas de processamento digital de imagens e de geoprocessamento;
- iv. Apresentar análise multicritério do desempenho dos classificadores e das imagens de satélite.

1.3 Organização dos capítulos

O trabalho é iniciado com elementos introdutórios, tais como: uma breve introdução ao assunto, expondo a importância das ferramentas do geoprocessamento e do sensoriamento remoto aplicadas aos recursos hídricos, e como podem afetar a tomada de decisão; os objetivos pretendidos; e as hipóteses que intitulam este trabalho como tese de doutoramento. O principal produto é fornecer subsídios aos tomadores de decisão quanto ao planejamento de bacias urbanas e semiurbanas.

CAPÍTULO 1 - ELEMENTOS INTRODUTÓRIOS

No capítulo 2 são abordados a modelagem e o monitoramento hidrológico. Na modelagem são detalhados os modelos do tipo chuva-vazão: Hidrograma Unitário (HU) e *Natural Resources Conservation Service* (NRCS), que são objetos deste estudo. No monitoramento são abordados os métodos estatísticos aplicados aos dados de precipitação e vazão, que são os parâmetros de entrada dos modelos chuva-vazão. Em seguida, é apresentada a metodologia da análise multicritério TOPSIS que foi aplicada no trabalho.

No capítulo 3 são apresentados os conceitos de Processamento Digital de Imagens (PDI), de geoprocessamento e de Sistemas de Informações Geográficas. Sobre o PDI, é realizada uma breve revisão com noções de geociências, entretanto o foco é dado as técnicas de classificação de imagens semiautomáticas e, nesse sentido, são apresentados os algoritmos classificadores de imagens utilizados: Máxima Verossimilhança (MaxVer), *Support Vector Machine* (SVM) e *Nearest Neighbor*. Sobre esses algoritmos abordaram-se principalmente suas funções estatísticas.

Dentre os temas apresentados no capítulo 3, destacam-se os métodos utilizados para avaliar a classificação de imagens. Foram utilizadas as principais referências nesse assunto e traduziu-se a metodologia da construção da matriz de confusão, com exemplos ilustrativos e adaptados à realidade brasileira. Também são apresentadas as equações de obtenção dos coeficientes de avaliação da classificação de imagens.

Em seguida são destacados os *softwares* mais utilizados na classificação de imagens e os SIG's que dispõem de ferramentas para o mesmo fim, tais como o QGIS e o ArcGIS®. Ao final foi elaborado um breve resumo sobre a aplicação da classificação de imagens em bacias hidrográficas do município de São Carlos - SP.

No capítulo 4 é apresentado o passo a passo da metodologia aplicada no trabalho. A construção deste capítulo consiste na proposta desta tese, e tem o objetivo de permitir que o leitor possa utilizá-la como referência/manual para produzir trabalhos relacionados à classificação de imagens. A dificuldade em encontrar material de apoio para executar certas rotinas, principalmente na classificação de imagens, foi um dos motivos para descrever detalhadamente a metodologia abordada.

No capítulo 5 são apresentados e discutidos os resultados encontrados. A leitura pode se caracterizar repetitiva e um pouco cansativa, uma vez que foram gerados nove mapas da cobertura e do uso da terra e 27 hidrogramas de cheia; entretanto, é importante que o leitor se atente aos mapas gerados a partir dos conjuntos classificadores-imagens, pois neles são apresentados os resultados que o usuário poderá esperar ao utilizar cada conjunto. Os

CAPÍTULO 1 - ELEMENTOS INTRODUTÓRIOS

resultados são relacionados à análise das possíveis confusões entre classes da cobertura e do uso da terra.

Ainda no capítulo 5, os mapas da cobertura e do uso da terra são utilizados para gerar os hidrogramas de cheia para um evento chuva-vazão monitorado. Nessa análise, buscou-se apresentar o hidrograma de cada classe da cobertura e do uso da terra para permitir a avaliação do impacto das confusões entre classes no hidrograma resultante.

Após apresentar os resultados das classificações das diferentes imagens é realizada uma análise das diferenças entre as áreas de cada classe da cobertura e do uso da terra em decorrência dos diferentes conjuntos classificador-imagem. Busca-se analisar a influência da qualidade da imagem de satélite no processo de classificação.

No texto seguinte, é apresentado um dos principais resultados do trabalho, que são os hidrogramas resultantes de cada conjunto classificador-imagem comparados aos hidrogramas observados próximo ao exutório da bacia. Esse processo é repetido para os três eventos chuva-vazão observados. Com a apresentação dos nove gráficos contendo todas as simulações (27 simulações) é esperado que o tomador de decisão possa avaliar a qualidade da imagem de satélite e o comportamento do classificador na geração de ESD pelo modelo NRCS. Essa reflexão é apresentada no texto seguinte, que aborda a importância da resolução espacial da imagem no processo de classificação orientado a estudos hidrológicos.

O próximo tema é de grande valia para usuários do geoprocessamento e para aqueles que executam a classificação de imagens, pois resume as facilidades e dificuldades encontradas na aplicação dos algoritmos classificadores e apresenta um quadro contendo as vantagens e desvantagens de cada classificador utilizado.

A avaliação estatística entre as vazões simuladas e observadas e os índices de avaliação da classificação embasaram os critérios da análise TOPSIS. Essas análises buscaram descrever a relação dos custos e dos benefícios de se utilizar classificadores semiautomáticos e imagens de alta, média e baixa resolução espacial. Como resultados foram apontados em ordem classificatória o desempenho dos classificadores e imagens de satélite de acordo com os critérios preestabelecidos.

No capítulo 6 são apresentadas as principais conclusões e o atendimento aos objetivos do trabalho, principalmente a validação das hipóteses levantadas.

CAPÍTULO 1 - ELEMENTOS INTRODUTÓRIOS

2.0 MODELOS CHUVA-VAZÃO

Os modelos hidrológicos que buscam descrever o processo de transformação da precipitação efetiva² em vazão têm como parâmetros a taxa de áreas impermeáveis e a eficiência do escoamento superficial. Sua estrutura básica envolve algoritmos de perda por depressão e impermeabilização, perda por infiltração, escoamento superficial da bacia e escoamento nos canais (TUCCI; PORTO; BARROS, 1995, p. 32-33).

Os modelos do tipo chuva-vazão têm como simplificações: as características nas sub-bacias são uniformes; não consideram a distribuição espacial das características de impermeabilização nas sub-bacias; não consideram o escoamento em condutos, mas a propagação geral das sub-bacias; e a separação do escoamento é realizada por índices, de acordo com o uso e ocupação do solo (TUCCI; PORTO; BARROS, 1995, p. 32-33).

A estrutura desses modelos é baseada: na **discretização da bacia hidrográfica**; nas **variáveis temporais de entrada**; na **estrutura básica da integração dos processos**; na **aquisição de dados físicos da bacia**; e na **determinação dos parâmetros** (TUCCI, 2005, p. 234 - 238).

Os modelos de **discretização da bacia**, em geral, são divididos em três estruturas: concentrado; distribuído por sub-bacia; e distribuído por módulos, a saber:

- **Concentrado**: toda a bacia é representada por uma precipitação média e os processos hidrológicos por variáveis concentradas no espaço. Esse modelo é usado em bacias pequenas, em que a distribuição espacial dos parâmetros e das variáveis não compromete os resultados, para o estudo desejado;

- **Distribuído por sub-bacia**: a bacia é dividida em sub-bacias de acordo com a drenagem principal, e baseia-se nos seguintes fatores: disponibilidade de dados, locais de interesse e variabilidade dos parâmetros físicos da bacia. Geralmente os parâmetros e a precipitação são considerados uniformes em cada sub-bacia.

- **Distribuído por módulos**: esta discretização é realizada por meio de formas geométricas como quadrados e retângulos, sem relação direta com a forma da bacia, mas caracterizando internamente os componentes dos processos. Os parâmetros são definidos por combinações (blocos) das características do relevo, tipo, uso e profundidade do solo. Esses

² Precipitação efetiva é a parcela da precipitação que gera o escoamento superficial direto, pois não se perdeu por processos de infiltração, interceptação, evaporação ou retenção superficial.

blocos compõem os módulos do modelo e o balanço hídrico é realizado por cada bloco e dentro de cada módulo. A representação da discretização dos modelos é apresentada na Figura 2.

Figura 2 - Estrutura da discretização dos modelos
 Fonte: Tucci (2005, p. 235)

As **variáveis temporais de entrada** utilizadas pelos modelos são: precipitação, evaporação potencial e vazão. Entretanto, numa bacia urbana onde há predominância de solo impermeabilizado e o escoamento ocorre em canais, os principais processos envolvidos são: a distribuição espacial da impermeabilização; o escoamento; e, em menor escala, a infiltração. Para simulações de cheias, por exemplo, o escoamento subterrâneo e a evapotranspiração são geralmente desprezíveis (TUCCI, 2005, p. 324).

A **estrutura básica da integração dos processos** é usualmente separada em dois módulos: a bacia em que se simula o balanço vertical dos fluxos e o escoamento na sub-bacia ou módulo; e, o canal em que se simula o escoamento em rios, propagando a vazão de montante para receber a contribuição do módulo da bacia (TUCCI, 2005, p. 235).

A grande variabilidade das características naturais da bacia e do uso do solo resulta numa grande quantidade de informações a serem transferidas para os modelos, principalmente nos modelos distribuídos, em que são estabelecidas relações entre as características físicas das bacias e os parâmetros dos modelos. Nesse sentido, os sistemas de informações geográficas e o sensoriamento remoto destacam-se por fazer parte da estrutura de entrada de alguns modelos (TUCCI, 2005, p. 237).

O tipo de modelo influencia na **determinação dos parâmetros** de entrada, uma vez que existem modelos estimados com base nas características físicas da bacia e outros ajustados com base em dados observados das variáveis de entrada e saída (TUCCI, 2005, p.238).

O tempo de pico e o tempo de concentração da bacia hidrográfica podem ser estimados por equações empíricas, estabelecidas com base em dados de algumas regiões. O tempo de concentração (t_c) é caracterizado pelo tempo em que toda a área da bacia está contribuindo simultaneamente para a seção em estudo, ou seja, é o tempo que a gota de água, que cai no ponto mais distante da bacia, leva para chegar ao exutório da mesma (COLLISCHONN; TASSI, 2008, p. 14).

Um cálculo de t_c preciso é geralmente complicado, pois a velocidade do escoamento depende, dentre outros fatores, da vazão escoada. Assim, a rigor, para cada vazão ou intensidade de chuva haveria um t_c ; contudo, como o modelo chuva-vazão é simplificado, é possível simplificar também o t_c (CAMPOS, 2009, p. 53).

Há vários métodos e equações para o cálculo do t_c da bacia. Em geral, essas equações são em função do comprimento e da declividade do talvegue, da rugosidade da superfície, da declividade e da área da bacia. As equações devem ser aplicadas com cautela, pois é necessário observar as condições em que foram obtidas (PAIVA; PAIVA, 2003, p. 67). As equações propostas por seus respectivos autores e as recomendações de uso de cada formulação são apresentadas na Tabela 1.

Tabela 1 - Fórmulas empíricas de tempo de concentração

Equação	Recomendação de uso	Autor
$t_c = 0,0196 \left(\frac{L^3}{h} \right)^{0,385}$ <p>L = comprimento do talvegue em m; h = diferença de cota em m; t_c = tempo de concentração em minutos.</p>	<p>Desenvolvida com dados do NRCS para sete bacias rurais em Tenesse com canal bem definido de declividade variando de 3 a 10% e áreas de até 0,5 km².</p> <p>Segundo Paiva e Paiva (2003), nesta equação, por ter sido desenvolvida para bacias tão pequenas, o escoamento em superfície representa uma parte considerável do tempo de concentração.</p>	<p>Kirpich (1940)</p> <p>Fonte: Adaptado de Chow, Maidment e Mays (1988); ABC6 (2000)</p>
$t_c = \frac{100L^{0,8} \left[\left(\frac{1000}{CN} \right) - 9 \right]^{0,7}}{1900S^{0,5}}$ <p>L= maior comprimento do canal de drenagem (<i>longest flow path</i>) em ft S= declividade média da bacia em % (área de drenagem) CN = Curve Number t_c = tempo de concentração</p>	<p>Desenvolvida pelo NRCS com dados de bacias rurais, é bem adaptada a pequenas bacias urbanas, menores que 8 km². Representativa para áreas completamente pavimentadas. Para áreas mistas tende a superestimar os resultados.</p> <p>Fatores de ajuste são aplicados para corrigir áreas impermeáveis e melhoramento do canal. A equação assume que o $T_c=1,67$ do tempo de retardo.</p>	<p>NRCS (1973) Lag Equation</p> <p>Fonte: Kibler (1982)</p>

Continuação		
Equação	Recomendação de uso	Autor
$t_c = 1,8(1,1 - C)L^{0,5}/S^{0,33}$ L = comprimento do canal principal em ft; S = declividade média da bacia em %; C= coeficiente de escoamento superficial (<i>runoff</i>) do método racional. t _c = tempo de concentração	Desenvolvido para drenagem de aeroportos pelo corpo dos engenheiros do EUA; É válida para escoamento superficial em pequenas bacias urbanas.	Administração Federal de Aviação (1970) Fonte: Adaptado de Chow, Maidment e Mays (1988)
$t_c = 447(nL)S^{0,3}I^{-0,4}$ L = comprimento do canal principal em km; S = declividade média da bacia em %; n= rugosidade de Manning; I= intensidade da precipitação em mm/h. t _c = tempo de concentração	A equação foi deduzida a partir das equações de onda cinemática aplicada à superfícies, baseando-se na hipótese de precipitação constante igual ao tempo de concentração e na equação de Manning. É adequada a pequenas bacias onde o método racional pode ser aplicado (áreas menores que 3 km²).	Onda cinemática Fonte: Chow, Maidment e Mays (1988) e Tucci (1993, p. 818) Kibler (1982)

2.1. Parâmetros e monitoramento hidrológico

As variáveis mais utilizadas nos modelos hidrológicos são a precipitação (entrada) e a vazão e o monitoramento destas variáveis auxilia na boa representatividade dos modelos aplicados.

Apesar da maior disponibilidade de dados ser da precipitação, a densidade de postos de monitoramento, a falta de dados em intervalos menores que um dia e o tamanho das séries monitoradas são as maiores limitações deste parâmetro. Sendo assim, as incertezas existentes nos dados de precipitação são uma das maiores fontes de erros dos modelos (TUCCI, 2005).

A estimativa adequada da precipitação requer uma densa rede de pluviômetros e pluviógrafos, pois quando a densidade da rede é pequena, a precipitação tende a ser sub ou super avaliada. Para a análise desses dados são utilizados os seguintes métodos de cálculo: da precipitação média espacial, geoestatístico (*Kriging*), de **Thiessen** e das **Isoietas**.

O método de Thiessen baseia-se na geometria do plano de localização dos postos de monitoramento para ponderar a influência dos seus dados no cálculo da precipitação média de determinada área. Sua metodologia consiste em: i) ligar os pontos de localização dos postos em planta; ii) traçar linhas perpendiculares na metade do intervalo das linhas que ligam os postos; iii) a área de influência de cada posto é delimitada pelas linhas traçadas

CAPÍTULO 2 - MODELAGEM HIDROLÓGICA

perpendicularmente e as interseções entre as mesmas; iv) a precipitação média é obtida pela Equação 1:

$$\bar{P} = \frac{\sum_{i=1}^n P_i A_i}{A_t} \text{ (Equação 1)}$$

Em que, A_i é a área de influência do posto i com precipitação P_i ; A_t é a área total da bacia.

O método das isoietas baseia-se no traçado das isoietas de um evento ou de um período pré-estabelecido. Sua metodologia consiste no seguinte: i) determinar as isoietas com base nos dados dos postos da bacia; ii) traçar linhas intermediárias e calcular a área de influência para cada posto pluviométrico; iii) a precipitação média é calculada pela Equação 1 (TUCCI, 2014). Os esquemas de aplicação do método de Thiessen e do método das isoietas são apresentados na Figura 3:

Figura 3 - Método de Thiessen (esquerda) e método das isoietas (direita)

O intervalo de tempo (discretização dos dados) é escolhido em função da variabilidade da precipitação e do tempo de resposta da bacia que é representado pelo tempo de pico e tempo de concentração da bacia. Recomenda-se um intervalo de tempo de pelo menos 1/3 do tempo de pico para representar ao menos quatro pontos na subida do hidrograma (TUCCI, 2005, p. 338).

Os métodos tradicionais de determinação dos parâmetros utilizadas para aplicação nos modelos hidrológicos são:

- ✓ Medidas diretas: no caso dos modelos chuva-vazão essa medida envolve a obtenção dos valores como a área de drenagem da bacia, o comprimento, e características das seções do rio, medidas que podem ser obtidas em campo ou por mapas, entre outros;

CAPÍTULO 2 - MODELAGEM HIDROLÓGICA

- ✓ Amostragem: quando a medida é uma amostra representativa do comportamento do parâmetro, por exemplo: a rugosidade de um rio, a capacidade de infiltração e a condutividade hidráulica do solo. Estas são condições locais que podem ser medidas em campo e representar o sistema;
- ✓ Ajuste por tentativa e erro: os parâmetros são obtidos com base nos dados observados das variáveis de entrada e saída do modelo. No ajuste, o usuário busca obter o hidrograma de saída (simulado) o mais próximo possível do observado para os períodos de ajuste e de verificação; portanto, muitas vezes as funções hidrológicas, tais como a curva de permanência e a curva de probabilidade de vazões máximas, entre outras, são usadas para verificar a qualidade do ajuste e verificação;
- ✓ Ajuste por otimização: utilizam funções objetivos implícitas que são alteradas de acordo com os critérios nelas inseridos. As estatísticas ou funções objetivos mais tradicionais são:

$$\text{Erro padrão: } EP = \sqrt{\frac{\sum_{t=1}^n \{(Q_{obs}(t) - Q_{sim}(t))\}^2}{n}} \quad (\text{Equação 2})$$

$$\text{Coeficiente R2: } R^2 = 1 - \frac{\sum_{t=1}^n \{(Q_{obs}(t) - Q_{sim}(t))\}^2}{\sum_t \{(Q_{obs}(t) - Q_m)\}^2} \quad (\text{Equação 3})$$

$$\text{Diferença por volumes: } \Delta V = \frac{\sum_{t=1}^n Q_{obs}(t) - \sum_{t=1}^n Q_{sim}(t)}{\sum_t Q_{obs}(t)} 100 \quad (\text{Equação 4})$$

$$\text{Fator da curva de permanência: } EI = 1 - \frac{\sum_{p=p_o}^{p_n} \{Q_{D_c}(p) - Q_{D_o}(p)\} \Delta p}{\sum_t Q_{D_o}(p) \Delta p} \quad (\text{Equação 5})$$

$$\text{Coeficiente de Nash Sutcliffe: } NS = 1 - \frac{\sum (Q_{obs} - Q_{sim})^2}{\sum (Q_{obs} - Q_{obs_{media}})^2} \quad (\text{Equação 6})$$

Em que: $Q_{obs}(t)$ e $Q_{sim}(t)$ são vazões observadas e simuladas pelo modelo em função do tempo t ; Q_m é a vazão média para o período em análise; $Q_{D_o}(p)$ e $Q_{D_c}(p)$ são vazões observadas e simuladas para a probabilidade p da curva de permanência; Δp é o intervalo utilizado da curva de permanência; n é o tamanho da amostra; e $Q_{obs_{media}}$ é a vazão observada média.

O coeficiente de Nash Sutcliffe, utilizado neste trabalho, é aplicado para verificar o ajuste dos picos de vazão, pois a função dá um peso maior às vazões maiores.

CAPÍTULO 2 - MODELAGEM HIDROLÓGICA

A tendência atual do desenvolvimento de técnicas de ajuste em modelos chuva-vazão são as técnicas baseadas na **incerteza dos parâmetros**, aquelas que utilizam as características dos erros dos modelos para identificar os parâmetros, e as **técnicas de multiobjetivos**, caracterizadas por buscar o ajuste do modelo com base em mais de uma variável de saída, denominado de *ajuste com múltipla resposta ou multiobjetivo*. Porém, nada impede de que a duas técnicas sejam usadas em conjunto. A primeira busca mais informações do sistema para estabelecer consistência interna do ajuste dos parâmetros, e a segunda busca o aprimoramento técnico do ajuste (TUCCI, 2005, p. 360).

2.2. Hidrograma Unitário

Um dos primeiros modelos apresentados para representar o escoamento superficial na bacia foi o Hidrograma Unitário (HU), que consiste em um processo de transformação da precipitação efetiva em escoamento superficial, por um método linear. Os modelos de escoamento superficial são classificados em lineares e não lineares e, sobre essa classificação, em conceituais e empíricos (TUCCI, 2005, p.107).

Ressalta-se a importância de se compreender as diferenças entre os modelos lineares e não lineares. O modelo é matematicamente linear quando os princípios da sobreposição e homogeneidade são satisfeitos. Para exemplificar, considere que y_1 é um parâmetro de entrada no modelo que produz uma saída x_1 . No mesmo modelo, uma entrada y_2 produz uma saída x_2 . Assim, quando y_1+y_2 produz a saída x_1+x_2 , o princípio da sobreposição foi aplicado. O modelo linear também tem a característica de ser homogêneo, pois as n entradas irão produzir n saídas (Ex: $ny_1 \rightarrow nx_1$). O modelo se torna não-linear quando um coeficiente varia em função do outro, como apresentado na Equação 7 (TUCCI, 2005, p. 24).

Para aplicar este conceito e melhor entender suas diferenças destaca-se o caso da equação da continuidade representando o escoamento em um reservatório:

$$\frac{dS}{dt} = I - Q \quad (\text{Equação 7})$$

$$S = K \cdot Q \quad (\text{Equação 8})$$

Na equação 7, S é o armazenamento; I a vazão de entrada; Q a vazão de saída.

CAPÍTULO 2 - MODELAGEM HIDROLÓGICA

A equação 8 apresenta a linearidade do sistema, pois estabelece uma relação entre o armazenamento e a vazão de saída, em que S é a variável de estado do sistema e k é um coeficiente relativo ao tempo de esvaziamento do sistema.

A combinação das equações 7 e 8 resulta em uma equação diferencial referente ao modelo de escoamento em um reservatório linear, em que Q é a variável de saída; I é a variável de entrada; t é a variável independente.

$$K \frac{dQ}{dt} + Q = I \quad (\text{Equação 9})$$

Portanto, se k for constante ou se depender somente do tempo t , o modelo é linear. Mas, ao considerar o tempo de esvaziamento constante, admite-se que este parâmetro independe da vazão de saída. Fato que não é verdade, pois se sabe que o tempo de esvaziamento de um reservatório deve variar com a vazão de saída e, dessa forma, K depende de Q , tornando a equação diferencial não-linear.

O uso dos modelos lineares se deve, principalmente, à sua facilidade, ao fato de que algumas bacias apresentam pequena não-linearidade, e pelo modelo apresentar melhores resultados para faixas de vazões de ajuste, desprezando-se os erros em outras faixas de valores.

O HU é, por definição, um hidrograma resultante de uma chuva efetiva unitária gerada uniformemente sobre a bacia, com intensidade uniforme e período de tempo específico. Quatro aspectos devem ser levados em consideração sobre o HU: 1) a medida da chuva efetiva; 2) a distribuição espacial uniforme sobre a bacia; 3) a intensidade de chuva efetiva constante no tempo; e 4) a duração da precipitação específica (McCUEN, 1986, p. 375).

Há diversos tipos de HU: aquele denominado T-horas ou T-minutos é resultante de uma chuva efetiva unitária de intensidade constante e de duração T (horas ou minutos). Já o Hidrograma Unitário Instantâneo (HUI) é um caso especial de HU de T-horas ou T-minutos com a duração da chuva efetiva infinitamente pequena (McCUEN, 1986, p. 375).

Em resumo, Tucci (2005, p. 363) conceitua o método do hidrograma unitário como uma estrutura linear cujas precipitações efetivas de diferentes magnitudes produzem, proporcionalmente, hidrogramas de mesmo tempo de base.

O HU resulta da precipitação efetiva unitária, que equivale ao ESD gerado sobre a área da bacia. Dessa forma, a precipitação efetiva pode ser usada como constante de proporcionalidade para converter um HU em volume de ESD (McCUEN, 1986, p. 376).

CAPÍTULO 2 - MODELAGEM HIDROLÓGICA

A constante de proporcionalidade é conhecida como “princípio da proporcionalidade” que consiste no conceito de que para uma precipitação efetiva de dada duração, o volume escoado superficialmente é proporcional à intensidade dessa precipitação (COLLISCHONN; DORNELLES, 2013, p 148).

Para gerar as vazões do hidrograma de ESD produzidas por precipitações efetivas sucessivas é aplicado o princípio da sobreposição, que consiste no conceito de que as vazões do ESD podem ser somadas às chuvas efetivas unitárias (COLLISCHONN; DORNELLES, 2013, p. 148). Os princípios da proporcionalidade e da sobreposição são ilustrados na Figura 4.

Figura 4 - Princípio da proporcionalidade (direita) e princípio da sobreposição (esquerda)

Fonte – Collischonn e Tassi (2008, p. 113)

Com a aplicação dos princípios da proporcionalidade e da sobreposição, é possível calcular hidrogramas resultantes de eventos complexos a partir de um hidrograma unitário, denominado processo de convolução (COLLISCHONN; TASSI, 2008, p.114). A equação de convolução é uma função de transferência da precipitação efetiva para ESD (McCUEN, 1989, p. 384).

Os processos usados na convolução são os meios de derivação do hidrograma de ESD por meio da chuva efetiva e do HU (McCUEN, 1989, p. 386). Esses podem ser usados tanto nas funções de distribuição discreta ou contínua. Na função contínua, as operações de multiplicação, translação e adição são feitas usando a integral de convolução, conforme Equação 10.

$$y(t) = \int_0^t x(\tau)U(t - \tau)d\tau \quad (\text{Equação 10})$$

CAPÍTULO 2 - MODELAGEM HIDROLÓGICA

Em que, $U(t)$ é o tempo de distribuição do HU; $y(t)$ é o tempo de distribuição do ESD; $x(\tau)$ é o tempo computado da distribuição de chuva efetiva; e τ é o tempo de retardo entre o começo do tempo da chuva e o início do HU (McCUEN, 1989, p. 386).

A equação mais utilizada em hidrologia para aplicação em computadores digitais é a integral de convolução na sua forma discreta, que relaciona o tempo de distribuição da chuva efetiva $x(\tau)$, o ESD $y(t)$, e o HU $U(t - \tau)$, conforme Equação 11:

$$y(t) = \sum_{\tau=0}^t x(\tau)U(t - \tau) \quad (\text{Equação 11})$$

A equação pode ser usada da seguinte maneira:

$$y(t) = \begin{cases} \sum_{j=1}^t x(j)U(t - j + 1) & \text{se } j \leq n_p \\ \sum_{j=1}^{n_p} x(j)U(t - j + 1) & \text{se } n_p < j \leq n_u \end{cases} \quad (\text{Equação 12})$$

Em que, n_p é o número de ordenadas na representação discreta da distribuição da chuva efetiva $x(j)$; n_u é o número de ordenadas na representação discreta do HU $U(t - j + 1)$; e as seguintes restrições são aplicadas:

$$U(i) = 0 \text{ para } i < 1 \text{ e } i > n_u \quad (\text{Equação 13})$$

A escolha do intervalo de tempo do HU depende do tempo de resposta da bacia e da variabilidade da precipitação, este deve ser relativamente pequeno para que as distribuições dos volumes máximos instantâneos não sejam distorcidas. O tempo de pico, que é representado pela distância entre o centro de gravidade da precipitação e pico do hidrograma, é utilizado como indicador para obtenção do intervalo de tempo (TUCCI, 2005, p.112).

As hipóteses sobre as quais está baseada a metodologia do hidrograma unitário são simplificações da realidade. Um exemplo disso, é que o escoamento não é gerado de forma uniforme em toda a bacia, pois as zonas preferenciais de geração de escoamento são as zonas impermeabilizadas por ação do homem e as áreas com solos saturados ou próximos da saturação, localizadas em regiões próximas a rede de drenagem (COLLISCHONN e DORNELLES, 2013, p. 162).

Da mesma forma, o escoamento ocorre mais rapidamente para um evento intenso do que para outro de menor intensidade, contrariando a teoria de linearidade dos hidrogramas e dos tempos de base que são iguais. Entretanto, essa metodologia é muito útil para representar o comportamento de uma bacia no que se refere à forma como o escoamento gerado numa bacia chega ao exutório (COLLISCHONN; DORNELLES, 2013, p. 162).

CAPÍTULO 2 - MODELAGEM HIDROLÓGICA

Entretanto, os hidrogramas unitários sintéticos formam a base de muitos modelos hidrológicos amplamente utilizados no cálculo de vazões máximas de projeto e têm funcionado relativamente bem (COLLISCHONN; DORNELLES, 2013, p. 162).

2.3. Modelo Natural Resources Conservation Service (NRCS)

O modelo *Natural Resources Conservation Service* (1975), antigo *Soil Conservation Service* (SCS), apresentado pelo Departamento de Agricultura dos Estados Unidos (USDA, 1986) é amplamente utilizado nas simulações de hidrograma de cheia de projeto para obras hidráulicas e para estabelecer risco de enchentes. O modelo foi desenvolvido por meio da análise de três mil tipos de solos com cobertura vegetal e plantações, estabelecendo uma relação empírica que associa a capacidade de armazenamento da bacia a um *Curve Number* (CANHOLI, 2005, p. 111).

Sua ampla utilização é devida ao número reduzido de parâmetros e a simplicidade do método. Caracterizado como concentrado, o modelo possui como dados de entrada a precipitação de projeto e como resultado estima o volume de ESD.

A primeira hipótese do método é que o volume do ESD é calculado por uma equação que relaciona a razão entre o volume superficial acumulado (Q em mm) e a precipitação total acumulada (P , em mm), e a razão entre a infiltração (F) e a infiltração acumulada potencial da bacia (S), isto é:

$$\frac{Q}{P - I_a} = \frac{F}{S} \quad (\text{Equação 14})$$

Em que: Q é a chuva efetiva ou escoamento superficial ao longo do evento (mm); P é a precipitação total ocorrida ao longo do evento (mm); F é a infiltração acumulada ao longo do evento de chuva (mm); S é a infiltração acumulada potencial (mm); e I_a são as perdas iniciais (mm).

A segunda hipótese do método é que as perdas iniciais (I_a) representam 20% da capacidade de armazenamento da água no solo (S), ou seja:

$$I_a = 0,2S \quad (\text{Equação 15})$$

As perdas iniciais são caracterizadas como todas as perdas que ocorrem antes do início do escoamento, incluindo: água retida nas depressões, interceptadas pela vegetação,

evaporadas, e infiltradas. O I_a é altamente variável, mas geralmente é correlacionado com parâmetros de cobertura da solo (USDA, 1986, p. 2-1).

A primeira e a segunda hipótese do método NRCS-CN são bastante criticadas por terem uma base física frágil (COLLISCHONN; DORNELLES, 2013, p.139), mas a combinação dessas duas equações com a equação da continuidade permite chegar a uma estimativa do ESD a partir de dados de vazão e das características da bacia, conforme Equação 16.

$$Q = \frac{(P-I_a)^2}{(P+S-I_a)} \text{ quando } P > I_a \text{ e } Q=0 \text{ quando } P \leq I_a \quad (\text{Equação 16})$$

Em que: I_a são as perdas iniciais (mm), S o potencial de armazenamento no solo ou infiltração acumulada potencial (mm), e Q é o ESD ou precipitação efetiva ao longo do evento (mm), P é a precipitação total ocorrida ao longo do evento (mm).

Considerando a equação 16, a equação 17 pode ser reescrita da seguinte maneira:

$$Q = \frac{(P-0,2S)^2}{(P+0,8S)} \text{ quando } P > I_a \text{ e } Q=0 \text{ quando } P \leq I_a \quad (\text{Equação 17})$$

O valor de S foi analisado experimentalmente em diversas bacias dos Estados Unidos na década de 1950 e foi relacionado ao parâmetro CN, conforme Equação 18.

$$S = \frac{25400}{CN} - 254 \quad (\text{Equação 18})$$

O CN foi estabelecido em uma escala de 0 a 100 e retrata as condições da cobertura do solo quanto à sua permeabilidade, ou seja, aos solos com alta permeabilidade são utilizados menores valores de CN e aos solos impermeáveis os maiores valores.

Os fatores determinantes do CN são: **os grupos hidrológicos de solo, o tipo de cobertura, o tratamento do solo; as condições hidrológicas, e as condições antecedentes de umidade do solo.**

Os grupos hidrológicos de solo são classificados em quatro tipos (A, B, C, D) de acordo com sua taxa de infiltração mínima. Esses grupos foram obtidos para solos expostos depois de prolongado período de chuva (solos encharcados). De acordo com USDA (1986, apêndice A) os quatro grupos hidrológicos de solo apresentados pelos cientistas do NRCS são:

CAPÍTULO 2 - MODELAGEM HIDROLÓGICA

Grupo A: solos com baixo potencial para escoamento e taxa de infiltração alta (maior que 7,62 mm/h). Consiste principalmente de areias ou cascalho profundos;

Grupo B: solos com taxa de infiltração moderada (3,81 a 7,62 mm/h), constituído de areia fina a média;

Grupo C: solos com baixa taxa de infiltração (1,27 a 3,81 mm/h). Constituídos de solos com uma camada mais impermeável abaixo da superfície e de textura fina (maior teor de argila);

Grupo D: solos com alto potencial para a geração de escoamento, por possuir taxa de infiltração muito baixa (0 a 1,27 mm/h). Constituídos de solos argilosos com alto potencial de expansão, solos com camada de argila próxima a superfície, solos rasos sobre rochas impermeáveis, e solos com lençol freático próximo da superfície.

Sartori, Lombardi Neto e Genovez (2005) apresentou uma proposta para extensão da classificação dos solos sugerindo nova nomenclatura ao Sistema Brasileiro de Classificação de Solos da Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA), publicada em 1999. A nova classificação proposta por Sartori, Lombardi Neto e Genovez (2005) é apresentada na Tabela 2.

Tabela 2 - Classificação hidrológica dos solos brasileiros

Grupo hidrológico do Solo	Características	Classificação
Grupo A	Solos muito profundos (prof. > 200 cm) ou profundos (100 a 200 cm). Solos com alta taxa de infiltração e com alto grau de resistência e tolerância à erosão; Solos porosos com baixo gradiente textural (< 1,20). Solos de textura média. Solos de textura argilosa ou muito argilosa desde que a estrutura proporcione alta macroporosidade em todo o perfil. Solos bem drenados ou excessivamente drenados. Solos com argila de atividade baixa (Tb), minerais de argila 1:1. A textura dos horizontes superficial e subsuperficial pode ser: média/média, argilosa/argilosa e muito argilosa/muito argilosa.	Latossolo Amarelo, Latossolo Vermelho Amarelo, Latossolo Vermelho, ambos de textura argilosa ou muito argilosa e com alta macroporosidade; Latossolo Amarelo e Latossolo Vermelho Amarelo, ambos de textura média, mas com horizonte superficial não arenoso.
Grupo B	Solos profundos (100 a 200 cm). Solos com moderada taxa de infiltração, mas com moderada resistência e tolerância a erosão. Solos porosos com gradiente textural variando entre 1,20 e 1,50. Solos de textura arenosa ao longo do perfil ou de textura média com horizonte superficial arenoso. Solos de textura argilosa ou muito argilosa desde que a estrutura proporcione boa macroporosidade em todo o perfil. Solos com argila de atividade baixa (Tb), minerais de argila 1:1. A textura dos horizontes superficial e subsuperficial pode ser: arenosa/arenosa, arenosa/média, média/argilosa, argilosa/argilosa e argilosa/muito argilosa	Latossolo Amarelo e Latossolo Vermelho Amarelo, ambos de textura média, mas com horizonte superficial de textura arenosa; Latossolo Bruno; Nitossolo Vermelho; Neossolo Quartzarênico; Argissolo Vermelho ou Vermelho Amarelo de textura arenosa/média, média/argilosa, argilosa/argilosa ou argilosa/muito argilosa que não apresentam mudança textural abrupta.

		Continuação
Grupo C	Solos profundos (100 a 200 cm) ou pouco profundos (50 a 100 cm). Solos com baixa taxa de infiltração e baixa resistência e tolerância à erosão. São solos com gradiente textural maior que 1,50 e comumente apresentam mudança textural abrupta. Solos associados a argila de atividade baixa (Tb). A textura nos horizontes superficial e subsuperficial pode ser: arenosa/média e média/argilosa apresentando mudança textural abrupta; arenosa/argilosa e arenosa/muito argilosa.	Argissolo pouco profundo, mas não apresentando mudança textural abrupta ou Argissolo Vermelho, Argissolo Vermelho Amarelo e Argissolo Amarelo, ambos profundos e apresentando mudança textural abrupta; Cambissolo de textura média e Cambissolo Háplico ou Húmico, mas com características físicas semelhantes aos Latossolos (Latossólico); Espodossolo Ferrocárbico; Neossolo Flúvico.
Grupo D	Solos com taxa de infiltração muito baixa oferecendo pouquíssima resistência e tolerância a erosão. Solos rasos (prof. < 50 cm). Solos pouco profundos associados à mudança textural abrupta ou solos profundos apresentando mudança textural abrupta aliada à argila de alta atividade (Ta), minerais de argila 2:1. Solos argilosos associados à argila de atividade alta (Ta). Solos orgânicos.	Neossolo Litólico; Organossolo; Gleissolo; Chernossolo; Planossolo; Vertissolo; Alissolo; Luvisolo; Plintossolo; Solos de Mangue; Afloramentos de Rocha; Demais Cambissolos que não se enquadram no Grupo C; Argissolo Vermelho Amarelo e Argissolo Amarelo, ambos pouco profundos e associados à mudança textural abrupta.
Fonte: Adaptado de Sartori, Lombardi Neto e Genovez (2005)		

O tipo de cobertura é caracterizado por solos com cobertura vegetal, solos expostos e superfícies impermeáveis. Os métodos de caracterização do tipo de cobertura mais comuns são reconhecimento de campo, fotografias aéreas, e mapas de uso do solo (USDA, 1986, p. 2-3).

O tratamento do solo, por sua vez, descreve o gerenciamento dos solos agricultáveis, que inclui práticas mecânicas (contorno e terraceamento) e práticas de gerenciamento (rotação de culturas e plantio direto) [USDA, 1986, p. 2-3].

As condições hidrológicas indicam o efeito do tratamento e do tipo de cobertura do solo na infiltração e no escoamento superficial. Essas condições são geralmente estimadas a partir da densidade da vegetação e de coberturas de resíduos em áreas amostrais. Boas condições, por exemplo, indica que o solo possui baixo potencial de gerar ESD para aquele grupo hidrológico, tipo de cobertura e tratamento (USDA, 1986, p. 2-3).

As condições antecedentes de umidade do solo influenciam diretamente no volume e na taxa de escoamento superficial. O modelo NRCS desenvolveu três condições antecedentes

CAPÍTULO 2 - MODELAGEM HIDROLÓGICA

de umidade dos solos, apresentadas conceitualmente por McCUEN (1989, p. 295) e quantificadas por Mishra e Singh (2003), conforme Tabela 3.

Tabela 3 - Condições antecedentes de umidade do solo

Condição Antecedente	Conceito	Precipitação acumulada nos últimos 5 dias que antecederam o evento
Condição I	Solos secos, mas não há ponto de murcha das plantas	$P_{ant} < 13 \text{ mm}$
Condição II	Condições médias	$13 \text{ mm} > P_{ant} > 28 \text{ mm}$
Condição III	Solo saturado em decorrência de chuvas intensas	$P_{ant} > 28 \text{ mm}$

Fonte: Adaptado de McCUEN (1989); Mishra e Singh (2003)

Os CNs urbanos da Tabela 2-2a foram estimados para solo típicos norte americanos e assumem uma porcentagem de área impermeável. Esses valores foram desenvolvidos sobre as seguintes suposições: (a) área permeável urbana (*open space*) é equivalente à pastagem em condição hidrológica boa; (b) área impermeável tem CN de 98 e é diretamente conectada ao sistema de drenagem (USDA, 1986, p. 2-9).

Os valores de CN foram apresentados no documento técnico (*Technical Release*) TR-55 do Departamento de Agricultura dos Estados Unidos (USDA) para diversos tipos de cobertura do solo, distribuídos nos quatro grupos hidrológicos e na condição de umidade antecedente II. As tabelas de interesse neste estudo são: aquelas classificadas para áreas urbanas (2-2a), para solos agrícolas (2-2c) e para cultura de cana de açúcar (9-4). Essa última encontra-se nos anexos do Manual Nacional de Engenharia (Part 630) de 2004 e é apresentada como uma classificação de grupos hidrológicos de solos complexos no Hawaii. As tabelas originais são apresentadas:

Tabela 4 - Valores de CN para áreas urbanas

Table 2-2a Runoff curve numbers for urban areas¹

Cover description		Curve numbers for hydrologic soil group			
Cover type and hydrologic condition	Average percent impervious area ²	A	B	C	D
Fully developed urban areas (vegetation established)					
Open space (lawns, parks golf courses, cemeteries, etc.) ³					
Poor condition (grass cover < 50%)		68	79	86	89
Fair condition (grass cover 50% to 75%)		49	69	79	84
Good condition (grass cover > 75%)		39	61	74	80
Impervious areas:					
Paved parking lots, roofs, driveways, etc. (excluding right-of-way)		98	98	98	98

Continuing				
Streets and roads:				
Paved; curbs and storm sewers (excluding right-of-way)	98	98	98	98
Paved; open ditches (including right-of-way)	83	89	92	93
Gravel (including right-of-way)	76	85	89	91
Dirt (including right-of-way)	72	82	87	89
Western desert urban areas:				
Natural desert landscaping (pervious areas only) ⁴	63	77	85	88
Artificial desert landscaping (impervious weed barrier, desert shrub with 1 to 2 inch sand or gravel mulch, and basin borders)	96	96	96	96
Urban districts				
Commercial and business	85	89	92	94
Industrial	75	81	88	91
Residential districts by average lot size:				
1/8 acre or less (town houses)	65	77	85	90
1/4 acre	38	61	75	83
1/3 acre	30	57	72	81
1/2 acre	25	54	70	80
1 acre	20	51	68	79
2 acres	12	46	65	77
Developing urban areas				
Newly graded areas (pervious areas, no vegetation) ⁵	77	86	91	94

Fonte: USDA (1986, p. 2-5)

¹ Average runoff condition, and $I_a = 0.2S$.

² The average percent impervious area shown was used to develop the composite CN's. Other assumptions are as follows: impervious areas are directly connected to the drainage system, impervious areas have a CN of 98, and pervious areas are considered equivalent to open space in good hydrologic condition. CN's for other combinations of conditions may be computed using figure 2-3 or 2-4.

³ CN's shown are equivalent to those of pasture. Composite CN's may be computed for other combinations of open space cover type.

⁴ Composite CN's for natural desert landscaping should be computed using figures 2-3 or 2-4 based on the impervious area percentage (CN = 98) and the pervious area CN. The pervious area CN's are assumed equivalent to desert shrub in poor hydrologic condition.

⁵ Composite CN's to use for the design of temporary measures during grading and construction should be computed using figure 2-3 or 2-4 based on the degree of development (impervious area percentage) and the CN's for the newly graded pervious areas.

Tabela 5 - CN para áreas agrícolas

Table - 2.2c Runoff curve numbers for other agricultural lands ¹					
Cover description	Hydrologic	Curve numbers for hydrologic soil group			
Cover type	Condition	A	B	C	D
Pasture, grassland, or range – continuous Forage for grazing ²	Poor	68	79	86	89
	Fair	49	69	79	84
	Good	39	61	74	80
Meadow – continuous grass, protected from grazing and generally mowed for hay	-	30	58	71	78
Brush-brush-weed-grass mixture with brush the major element ³	Poor	48	67	77	83
	Fair	35	56	70	77
	Good	30 ⁴	48	65	73
Woods-grass combination (orchard or tree farm) ⁵	Poor	57	73	82	86
	Fair	43	65	76	82
	Good	32	58	72	79
Woods ⁶	Poor	45	66	77	83
	Fair	36	60	73	79
	Good	30	55	70	77
Farmsteads-buildings, lanes, driveways, and surrounding lots	-	59	74	82	86

Fonte: USDA (1986, p. 2-7)

¹ Average runoff condition, and Ia = 0.2S.

² *Poor*: <50% ground cover or heavily grazed with no mulch.

Fair: 50 to 75% ground cover and not heavily grazed.

Good: > 75% ground cover and lightly or only occasionally grazed.

³ *Poor*: <50% ground cover.

Fair: 50 to 75% ground cover.

Good: >75% ground cover.

⁴ Actual curve number is less than 30; use CN = 30 for runoff computations.

⁵ CN's shown were computed for areas with 50% woods and 50% grass (pasture) cover. Other combinations of conditions may be computed from the CN's for woods and pasture.

⁶ *Poor*: Forest litter, small trees, and brush are destroyed by heavy grazing or regular burning.

Fair: Woods are grazed but not burned, and some forest litter covers the soil.

Good: Woods are protected from grazing, and litter and brush adequately cover the soil.

Tabela 6 - CN estimados para cana de açúcar em grupos hidrológicos de cobertura do solo complexos no Hawaii

Table - 9-4 Runoff curve numbers; tentative estimates for sugarcane hydrologic soil-cover complexes in Hawaii ¹				
Cover and treatment ²	Curve numbers for hydrologic soil group			
	A	B	C	D
Sugarcane:				
Limited cover, straight row	67	78	85	89
Partial cover, straight row	49	69	79	84
Complete cover, straight row	39	61	74	80
Limited cover, contoured	65	75	82	86
Partial cover, contoured	25	59	75	83
Complete cover, contoured	6	35	70	79

Fonte: USDA (2004)

¹ Average runoff condition and Ia = 0.2S.

² Degrees of cover:

Limited cover—Cane newly planted, or ratooned cane with a limited root system; canopy over less than half the field area.

Partial cover—Cane in the transition period between limited and complete cover; canopy over half to nearly the entire field area.

Complete cover—Cane from the stage of growth when full canopy is provided to the stage at harvest.

Straight-row planting is up and down hill or cross-slope on slopes greater than 2 percent.

Contoured planting is the usual contouring or cross-slope planting on slopes less than 2 percent.

Há condições em que os valores de CN tabelados não são aplicados, são essas: (a) toda a área impermeável é diretamente conectada ao sistema de drenagem, (b) todo ou parte da área impermeável não é diretamente conectada ao sistema de drenagem. Nesses casos, a versão técnica (TR-55) do USDA recomenda o uso de figuras que apresentam relações entre os valores compostos de CN e as porcentagens de áreas impermeáveis conectadas.

As limitações do modelo NRCS-CN são apresentadas pelo USDA (1986, p. 2-11):

(1) como o CN foi desenvolvido para condições médias de umidade antecedente do solo, ao usar um evento de chuva histórico, a acuracidade do modelo diminui;

(2) a equação do NRCS-CN não relaciona o tempo, portanto não leva em conta a duração da chuva ou sua intensidade;

(4) a hipótese de que a abstração inicial é de 20% da infiltração acumulada potencial (S) pode ser importante na aplicação do modelo em áreas urbanas devida à combinação de áreas impermeáveis e permeáveis, que implica em perdas iniciais importantes e que não são

levadas em conta. Por outro lado, um volume maior de perdas pode ocorrer em áreas impermeáveis com depressões em sua superfície;

(5) o modelo não é válido para determinar escoamento de neve derretida ou chuva no solo congelado;

(6) a acuracidade do modelo diminui quando a lamina do escoamento é menor que 12,7 mm;

(7) o modelo é aplicado somente para determinar ESD; portanto, não negligencia o escoamento subsuperficial ou lençóis freáticos altos que contribuem para o escoamento superficial. Tais condições são relacionadas ao tipo hidrológico do solo A e as áreas florestadas com CN relativamente baixo;

(8) o modelo não representa bem o escoamento superficial para CN's menores que 40.

2.3.1. Hidrograma unitário sintético triangular do NRCS

A partir dos estudos sobre o modelo NRCS, com um grande número de bacias e de hidrogramas unitários nos EUA, pesquisadores verificaram que os hidrogramas unitários podem ser aproximados por relações de tempo e vazão, estimadas com base no tempo de concentração e na área da bacia.

Portanto, na aplicação do modelo NRCS-CN, tem-se que o volume gerado pelo modelo na separação do escoamento é propagado até o rio através do uso do HU sintético triangular, obtido com base no valor da vazão de pico (q_p), do tempo de pico (t_p) e do tempo de recessão ($1,67t_b$), que é estimado com base no tempo de pico. O HU sintético do NRCS e as equações utilizadas para determinar o t_p , e q_p são apresentadas:

$$t_p = 0,6t_c \quad (\text{Equação 19})$$

$$T_p = t_p + \frac{D}{2} \quad (\text{Equação 20})$$

$$T_b = 2,67T_p \quad (\text{Equação 21})$$

$$q_p = \frac{0,75A_bP_u}{3,6T_p} \quad (\text{Equação 22})$$

Em que:

t_p é o tempo de pico;

t_c é o tempo de concentração da bacia;

T_b é o tempo de base;

q_p é a vazão de pico;

T_p é o tempo de ascensão do hidrograma

Figura 5 - HU sintético triangular do NRCS
Fonte: Collischonn e Tassi (2008, p. 120-121)

Pode-se observar nas equações e na figura que o tempo de pico (t_p) do hidrograma pode ser estimado como 60% do tempo de concentração e o tempo de subida do hidrograma como o tempo de pico mais a metade da duração da chuva D (Equação 20).

A equação do tempo de base (Equação 21) implica dizer que o tempo de recessão do hidrograma triangular, a partir do pico até retornar a zero, é 67% maior do que o tempo de ascensão (T_p).

O volume total escoado (V) para uma chuva efetiva unitária (P) é dado pelo produto da área da bacia (A) pela lâmina de chuva efetiva ($V=AP$). Esse mesmo volume pode ser calculado pela área sob a curva de um hidrograma triangular de duração total T_b e de vazão de pico q_p por: $V=AP$. Combinando essas duas expressões e introduzindo a equação $T_b = T_p + 1,67T_p$, a vazão de pico do hidrograma, para uma chuva efetiva unitária, pode ser calculada por:

$$q_p = \frac{0,208A}{T_p} \quad (\text{Equação 23})$$

Em que: T_p é o tempo de ascensão em horas. A é a área da bacia em km^2 , e o resultado é a vazão de pico q_p em m^3/s por mm de chuva efetiva.

2.4. Análise multicritério TOPSIS

O método TOPSIS de análise multicriterial foi proposto por Hwang e Yoon (1981), e baseia-se na ideia de que a alternativa escolhida deve apresentar a menor distância da solução positiva ideal, bem como a maior distância da solução negativa ideal. Não há relação de preferência (AFSHAR et al., 2011; LEE et al., 2013; 2014; TORKAMANI et al., 2012).

É apresentado o passo a passo que compõe o método TOPSIS, conforme apresentado por Lee et al. (2014).

1. Normaliza-se a matriz de decisão $X = (x_{i,j})_{m \times n}$, sendo $x_{i,j}$ a medida de performance da alternativa i em relação ao critério j ; m o total de alternativas; e n o total de critérios. Para tanto, utiliza-se a seguinte fórmula:

$$v_{i,j} = \frac{x_{i,j}}{\sqrt{\sum_i x_{i,j}^2}} \text{ (Equação 24)}$$

Para: $i = 1, 2, \dots, m$; $j = 1, 2, \dots, n$; $v_{i,j}$ = função de normalização.

2. A partir da matriz de decisão normalizada, calcula-se a matriz de decisão ponderada, cujos elementos $r_{i,j}$ são calculados por:

$$r_{i,j} = w_j \cdot v_{i,j} \text{ (Equação 25)}$$

Sendo w_j o peso do j -ésimo critério ($\sum_{j=1}^n w_j = 1$);

3. Determinam-se as soluções ideais positiva e negativa:

$$A^+ = \{r_1^+, \dots, r_n^+\} = \{\langle \max(r_{i,j} | i = 1, \dots, m) | j \in J^+ \rangle, \langle \min(r_{i,j} | i = 1, \dots, m) | j \in J^- \rangle\}$$

$$A^- = \{r_1^-, \dots, r_n^-\} = \{\langle \max(r_{i,j} | i = 1, \dots, m) | j \in J^- \rangle, \langle \min(r_{i,j} | i = 1, \dots, m) | j \in J^+ \rangle\}$$

Sendo:

- J^+ = conjunto dos critérios positivos (quanto maior $r_{i,j}$, melhor);
- J^- = conjunto dos critérios negativos (quanto menor $r_{i,j}$, melhor);

4. Calculam-se as distâncias que separam cada alternativa da positiva ideal (d_i^+) e da negativa ideal (d_i^-):

$$d_i^+ = [\sum_j (r_j^+ - r_{i,j})^2]^{1/2} \text{ (Equação 26)}$$

$$d_i^- = [\sum_j (r_j^- - r_{i,j})^2]^{1/2} \text{ (Equação 27)}$$

Para $i = 1, 2, \dots, m$;

5. Calculam-se as proximidades relativas R_i de cada alternativa à solução ideal:

$$R_i = \frac{d_i^-}{d_i^+ + d_i^-} \text{ (Equação 28)}$$

Quanto maior o valor de R_i , mais próxima está a alternativa i da ideal e, portanto, melhor ela é.

3.0 PROCESSAMENTO DIGITAL DE IMAGENS

As primeiras aplicações de imagens digitais surgiram nas indústrias de jornais em Londres e Nova York, no início da década de 1920. Nesta época, a transmissão da imagem era feita por meio do sistema Bartlane, via cabo submarino, de maneira que um equipamento de impressão especializado codificava as imagens para transmissão a cabo, as quais eram então reconstruídas no terminal receptor. A introdução do sistema Bartlane reduziu o tempo requerido de mais de uma semana para três horas no transporte de imagens, através do oceano Atlântico.

Em 1921, os sistemas Bartlane eram capazes de identificar imagens com cinco níveis de cinza distintos; já em 1929 a capacidade do sistema era de identificação de 15 níveis de cinza (GONZALES; WOODS, 2010).

A história do Processamento Digital de Imagens (PDI) possui estreita relação com o surgimento do computador digital, o qual só ocorreu em 1940. Tal relação é atribuída à necessidade da capacidade de armazenamento, visualização e transmissão dos dados, que só é possível com o auxílio de um computador digital. Como conceito, o PDI consiste em utilizar-se de algoritmos, de técnicas computacionais, matemáticas e estatísticas para interpretação e extração de informações da imagem digital.

Segundo Novo (1992) o PDI pode ser classificado em três conjuntos: i) **técnicas de processamento e preparação de imagens**, as quais se referem aos programas computacionais, que permitem transformar dados digitais brutos em dados corrigidos radiometricamente e geometricamente; ii) **técnicas de realce**, que buscam melhorar a qualidade visual da imagem; iii) **técnicas de classificação**, que consistem no reconhecimento automático de objetos da imagem, a partir de análise quantitativa dos níveis de cinza.

De acordo com Gonzalez e Woods (2010), o PDI é dividido em três diferentes processos: de nível baixo, médio e alto. Os processos de nível baixo envolvem as operações de pré-processamento, que são: i) **redução de ruído**, ii) **realce de contraste**, e iii) **aguçamento de imagens**. No pré-processamento, tanto a entrada quanto a saída são imagens.

No processo de nível médio, a entrada geralmente é uma imagem e a saída são os atributos extraídos dela, os quais envolvem as seguintes tarefas: i) **segmentação**, que consiste

na separação da imagem em regiões ou objetos; ii) **descrição dos objetos**, que se caracteriza pela definição das classes espectrais e iii) **classificação**, que é o reconhecimento dos objetos individuais. Já na terceira etapa, que consiste no processamento de nível alto, é necessário “dar sentido” ao conjunto de objetos reconhecidos na análise de imagens, a fim de realizar funções cognitivas normalmente associadas à visão.

3.1. Estrutura das imagens de sensoriamento remoto

O sensoriamento remoto implica na obtenção de dados ou imagens de um objeto terrestre que se encontra distante do sensor. Isto inclui, além de imagens de satélite e radar, as fotografias aéreas, digitais ou não (PARANHOS FILHO; LASTORIA; TORRES, 2008, p.16).

As imagens de sensoriamento remoto são constituídas de arranjos de elementos na forma de uma malha ou grid. Cada célula do grid, denominada *pixel* (do inglês, *Picture Element*), possui uma localização definida em um sistema de coordenadas do tipo “linha” e “coluna”, representados por “x” e “y”, respectivamente, e ainda um atributo numérico, representado por “z”, que indica o nível de cinza da célula. Este, varia de preto a branco e é conhecido como DN, do inglês *Digital Number* (CRÓSTA, 1992). O DN representa a média da intensidade de energia eletromagnética (refletida ou emitida) dos objetos terrestres e medida pelo sensor.

O sistema de obtenção de informações por sensoriamento remoto consiste na aquisição e análise dos dados. A aquisição envolve a detecção da radiação proveniente da superfície, a transformação e a transmissão de arquivos de dados. O segundo compreende as etapas de pré-processamento da imagem (NOVO, 1992).

A imagem produzida é dependente do modo com que o sistema determina o valor do DN, que leva em conta a resolução espacial e o campo de visão instantâneo (*Instantaneous Field Of View* - IFOV) do sensor, o qual determina o tamanho do pixel. O sensor realiza a leitura espectral de uma área, de acordo com tamanho do pixel, e a amplitude deste valor depende da resolução radiométrica. O sistema de produção da imagem é apresentado na Figura 6.

CAPÍTULO 3 - PROCESSAMENTO DIGITAL DE IMAGENS, SENSORIAMENTO REMOTO E GEOPROCESSAMENTO

Figura 6 - Representação do IFOV na definição do tamanho do pixel da imagem
Fonte: Google (2015)

Como vantagens, as imagens de satélites se destacam por: i) terem menor custo quando comparado às técnicas de levantamento aerofotogramétrico e das fotografias aéreas; ii) sua disponibilidade devido à rapidez de coleta de dados; iii) sua cobertura que é praticamente global; iv) sua aplicabilidade em diversas áreas do conhecimento; e v) seu formato digital que permite a aplicação das técnicas de geoprocessamento entre outras (PARANHOS FILHO; LASTORIA; TORRES, 2008).

CAPÍTULO 3 - PROCESSAMENTO DIGITAL DE IMAGENS, SENSORIAMENTO REMOTO E GEOPROCESSAMENTO

3.1.1 Sensores remotos e resolução de imagens

Os sensores são capazes de coletar energia, proveniente de objetos da superfície terrestre e convertê-la em sinal passível de registro para extração de informações (NOVO, 1992).

Toda matéria a uma temperatura absoluta acima de zero Kelvin emite energia e é considerada uma fonte de radiação eletromagnética. A energia ou fluxo radiante que provém do sol varia com as temperaturas que ocorrem em sua superfície e com a opacidade de certas regiões da atmosfera terrestre. Essa energia pode ser ordenada de maneira contínua em função de seu comprimento de onda ou de sua frequência, sendo esta disposição denominada de espectro eletromagnético (NOVO, 1988; MORAES, 2002).

Os objetos da superfície terrestre, devido as diferentes propriedades físico-químicas e biológicas, interagem de diferentes maneiras com a energia eletromagnética incidente, sendo que essas interações possibilitam a distinção e o reconhecimento dos objetos pelo sensor.

A formação da imagem por meio de interações eletromagnéticas varia de acordo com o sensor utilizado, sendo que apenas uma parte do espectro desta radiação fará parte da imagem. No sensoriamento remoto as faixas utilizadas são: visível e infravermelho (Figura 7).

Figura 7 - Espectro eletromagnético

Fonte: Griffiths (1999)

A radiação de cada objeto terrestre é captada dentro de um espectro específico, ou seja, em uma faixa de comprimento de onda específica. Assim, o comportamento espectral de um objeto pode ser definido como o conjunto dos valores sucessivos da reflectância do objeto

CAPÍTULO 3 - PROCESSAMENTO DIGITAL DE IMAGENS, SENSORIAMENTO REMOTO E GEOPROCESSAMENTO

ao longo do espectro eletromagnético, denominado assinatura espectral do objeto. Um exemplo de assinaturas espectrais de uma folha é apresentado na Figura 8.

Figura 8 - Assinaturas espectrais de uma folha
Fonte: INPE (2016)

Analisando a assinatura espectral da folha verde na Figura 8 é possível entender as variações da refletância de cada banda do visível (azul, verde e vermelho) e do infravermelho. Na banda do visível, a menor refletância (maior absorvância) é produzida por pigmentos da folha (clorofila, xantofila e carotenos) enquanto que na banda infravermelha (IR), a maior refletância resulta da interação da radiação com a estrutura celular superficial da folha.

A maior refletância na banda verde (*Green*) resulta na cor da folha. Já a elevada refletância na banda infravermelha (IR) está relacionada com os aspectos fisiológicos da folha e varia com o conteúdo de água na sua estrutura celular superficial; por isso é um forte indicador da sua natureza, estágio de desenvolvimento, sanidade, etc (STEFFEN, 2016).

Os sensores remotos utilizados para coleta da energia eletromagnética proveniente dos objetos terrestres são compostos por: i) **coletor** capaz de concentrar o fluxo de energia proveniente da amostra no detector; ii) **filtro** responsável pela seleção da faixa espectral da energia a ser medida; iii) **detector** que possui propriedades elétricas capazes de absorver o fluxo da energia e produzir um sinal elétrico; iv) **processador** responsável pela amplificação do sinal gerado pelo detector e pela digitalização do sinal elétrico gerado; e v) **unidade de saída** capaz de registrar sinais elétricos captados pelo detector para extrair informações (MORAES, 2002).

CAPÍTULO 3 - PROCESSAMENTO DIGITAL DE IMAGENS, SENSORIAMENTO REMOTO E GEOPROCESSAMENTO

Os sensores são classificados em função da fonte de energia e do tipo de produto que ele produz. Com relação à primeira classificação, são **passivos** quando não possuem fonte própria de radiação e **ativos** quando possuem sua própria fonte de radiação eletromagnética, trabalhando em faixas restritas do espectro. Os sensores eletro óticos, por exemplo, são passivos, pois se utilizam da energia eletromagnética emitida pelo sol. Já os sensores ativos são aqueles que emitem um sinal, em geral de radar, e quantificam algumas características do sinal de retorno emitido pela superfície terrestre.

A classificação em função do tipo de produto que ele produz está dividida em: **Não-imageadores e Imageadores**. Os primeiros não geram imagem da superfície observada, como por exemplo, os espectrorradiômetros (assinatura espectral) e os radiômetros (saída em dígitos ou gráficos). Já os segundos são aqueles que capturam uma imagem e fornecem informações sobre a variação espacial da resposta espectral da superfície observada.

As características dos sensores estão relacionadas com suas resoluções: espacial, espectral, radiométrica e temporal. O termo resolução da imagem, por sua vez, é utilizado para descrever o número de pixels de uma imagem. Estes podem ser exibidos em uma tela e representam a área da superfície terrestre. As definições das resoluções são:

- ✓ Resolução espectral: largura espectral em que opera o sensor. Esta define o intervalo espectral no qual são realizadas as medidas, e conseqüentemente a composição espectral do fluxo de energia que atinge o detector, portanto, quanto mais estreitas forem as faixas espectrais, e/ou quanto maior for o número de bandas espectrais captadas pelo sensor, maior é a resolução espectral da imagem (MORAES, 2002);
- ✓ Resolução espacial: capacidade do sensor em distinguir objetos. Esta depende principalmente do detector, da altura e do posicionamento do sensor em relação ao objeto (CRÓSTA, 1992; MORAES, 2002);
- ✓ Resolução radiométrica: define a eficiência do sistema em detectar pequenos sinais, ou seja, refere-se à maior ou menor capacidade do sistema sensor em detectar e registrar diferenças na energia refletida e/ou emitida pelos elementos que compõe a imagem. Esta eficiência é apresentada em valor numérico e representa a intensidade da radiância proveniente da área do terreno correspondente ao pixel, chamado de nível de cinza. A quantidade de níveis de cinza é igual a $2^{(\text{Número de Bits})}$.
- ✓ Resolução temporal: tempo necessário para que o satélite obtenha uma nova imagem do mesmo ponto da superfície terrestre, também conhecido como tempo de revisita.

CAPÍTULO 3 - PROCESSAMENTO DIGITAL DE IMAGENS, SENSORIAMENTO REMOTO E GEOPROCESSAMENTO

A qualidade de um sensor é geralmente especificada pela sua capacidade de obter medidas detalhadas da energia eletromagnética; portanto, deve-se levar em conta a discretização do sinal elétrico.

3.2. Características dos satélites e de suas imagens

Os principais tipos de satélites são: os **geoestacionários** e os **de órbita polar e heliossíncronos**. Os primeiros estão sobre a linha do Equador, aproximadamente 37.000 km de altitude (escala continental). Já os de órbita polar e heliossíncronos, estão localizados em torno dos 700 km de altitude, no sentido nordeste/sudoeste, de modo que se encontram em órbita descendente sobre o lado iluminado do globo e ascendente sobre o lado escuro. Os últimos são os que produzem as imagens de alta resolução espacial.

Dentre os satélites globais de maior resolução espacial, utilizados no monitoramento e levantamento dos recursos naturais terrestres, podem-se citar: o WorldView-II, o Quickbird, e o Ikonos. Na resolução média, encontra-se o RapidEye e, com menor resolução, o Landsat-8.

O Quickbird e o Ikonos foram lançados na Base da Força Aérea de Vandenberg, na Califórnia (EUA); o primeiro em outubro de 2001 e o segundo em setembro de 1999 (DIGITAL GLOBE, 2013). Ambos não foram utilizados como ferramentas para este trabalho e, portanto, não são discutidos no texto.

O satélite RapidEye foi lançado em 2008 na base aérea de Baikonur, Cazaquistão, a uma altitude de 630 km. O satélite possui as bandas: azul (440-510 nm), verde (520-590 nm), vermelha (630-685 nm), vermelho borda – *rededge* (690-730 nm) e infravermelho próximo - NIR (760-850 nm) (GLOBALGEO, 2015).

O Ministério do Meio Ambiente (MMA), com o objetivo de analisar o processo de regularização de propriedades rurais e realizar o Cadastro Ambiental Rural (CAR), criou o Programa de Regularização Ambiental. Para fim de desenvolvimento deste programa, o MMA disponibiliza as imagens do satélite RapidEye para instituições públicas, universidades e institutos tecnológicos, bastando o interessado realizar um cadastro no *site* e assinar um

CAPÍTULO 3 - PROCESSAMENTO DIGITAL DE IMAGENS, SENSORIAMENTO REMOTO E GEOPROCESSAMENTO

termo de comprometimento pelo uso corporativo das imagens. Este termo consiste no Contrato de Licença do Usuário Final (*End-User License Agreement* - EULA).

As imagens RapidEye do Estado de São Paulo são disponibilizadas por meio do Programa de Monitoramento da Agricultura. São de “Nível 3A”, isto é, são cenas com área de 25 km² (5000 linhas e 5000 colunas) e seu pré-processamento consiste na ortorretificação e nas correções radiométrica e geométrica.

O sistema de coordenadas de referência é o *Universal Transverse Mercator* (UTM) WGS84 e a reamostragem é feita por convolação cubica (padrão) e pelo método do vizinho próximo. As imagens são entregues em formato geotiff com 12 bits de resolução radiométrica e resolução espacial de 5 metros (GLOBALGEO, 2015).

O WorldView-II foi lançado no dia 8 de outubro de 2009 em Vandenberg, Califórnia (EUA) e opera a uma altitude de 770 km. A resolução espacial da imagem é de 0,5 m (0,1 m a mais que seu antecessor, o QuickBird) e captura imagens com até 0,3 m de resolução no modo pancromático (PAN) e 1,84 m no modo multiespectral (MS). Porém, em função das condições estabelecidas pelo governo dos EUA, as imagens de satélite são fornecidas comercialmente com 0,5 m de resolução espacial no modo PAN e 2,0 m no modo MS. Além das quatro bandas tradicionais (vermelho - 630 -690 nm; verde - 510 – 580 nm; azul - 450 – 510 nm; e infravermelho próximo (NIR-1) - 770 – 895 nm), possui quatro novas bandas: azul costal; amarela; vermelho limítrofe; e infravermelho próximo 2 [NIR-2]). As principais características das novas bandas são:

- ✓ Azul Costal (400 – 450 nm): favorece a identificação, análise de margens, linha de costa e estudos batimétricos, com base na penetração da luz nas camadas de água. Esta banda é sensível a mudanças atmosféricas e é utilizada para pesquisas e técnicas de ajuste do produto final.
- ✓ Amarela (585 – 625 nm): utilizada para identificar diferenças sutis na vegetação e no solo exposto para alvos específicos, sendo relevante também na identificação de bancos de areia. Esta banda auxilia no processamento da cor natural e na correção de nuances para melhor representar imagens à visão humana.
- ✓ Vermelho limítrofe (705 – 745 nm): auxilia na análise de condições vegetativas das plantas. Oferece informações diretamente relacionadas à saúde vegetal, demonstradas pela produção de clorofila e padrões de crescimento de determinadas algas e plantas.

CAPÍTULO 3 - PROCESSAMENTO DIGITAL DE IMAGENS, SENSORIAMENTO REMOTO E GEOPROCESSAMENTO

✓ **Infravermelho Próximo 2 (860 - 1040nm):** auxilia na análise e composição de índices de vegetação e estudo de biomassa verde.

O Instituto Nacional de Pesquisas Espaciais (INPE) disponibiliza imagens gratuitas dos seguintes satélites: Landsat1; Landsat2; Landsat3; Landsat5; Landsat7; Landsat8, CBERS 1; CBERS 2; CBERS 2B; CBERS 4, Resources Sat1; Aqua e Terra. Porém, somente os satélites Resources Sat1, Aqua, Terra e Landsat8 continuam em atividade. Os satélites Terra e Aqua, lançados em 1999 e 2002, respectivamente, apesar de estarem disponíveis, não serão discutidos neste trabalho, devido sua baixa resolução espacial.

A plataforma Landsat-8, lançada pela NASA em fevereiro de 2013, opera com dois instrumentos imageadores: *Operacional Terra Imager (OLI)* e *Thermal Infrared Sensor (TIRS)*. Os produtos OLI disponibilizam nove bandas multiespectrais com resolução espacial de 30 m (bandas de 1 a 7 e 9) e uma pancromática com resolução espacial de 15 m (banda 8). A nova banda 1 (ultra-azul) é útil para estudos costeiros e aerossol, e a banda 9 (cirrus) é útil para a detecção de nuvens. As bandas 10 e 11 pertencem ao instrumento imageador TIRS que são úteis no fornecimento de temperaturas das superfícies e possuem resolução espacial de 100 m. As características das bandas do satélite Landsat-8 são apresentadas na Tabela 7.

Tabela 7 - Características dos instrumentos imageadores OLI e TIRS

Bandas	Comprimento da onda (µm)	Resolução espacial (m)
Band 1 – Ultra azul	0.43 – 0.45	30
Band 2 – Azul	0.45 – 0.51	30
Band 3 – Verde	0.53 – 0.59	30
Band 4 – Vermelha	0.64 – 0.67	30
Band 5 – Infravermelho Próximo (NIR)	0.85 – 0.88	30
Band 6 – SWIR* 1	1.57 – 1.65	30
Band 7 – SWIR* 2	2.11 – 2.29	30
Band 8 – Pancromática	0.50 – 0.68	15
Band 9 – Cirrus	1.36 – 1.38	30
Band 10 – Infravermelho termal(TIRS) 1	10.60 – 11.19	100
Band 11 – Infravermelho termal(TIRS) 2	11.50 – 12.51	100

*Short-wave Infrared – Onda Infravermelho curta

Fonte: Adaptado de USGS (2015).

As imagens Landsat-8 são entregues em formato geotiff com resolução radiométrica de 16 bits, mas é possível fazer uma conversão para 8 bits (Conversão Radiométrica - *rescale*), sua projeção é UTM, Datum WGS 1984, porém estas imagens são projetadas ao norte, sendo necessário reprojeta-las. A licença para aquisição das imagens é pública, portanto é adquirida gratuitamente por meio de cadastramento em *sites* tais como o *Earth Explorer* e do INPE.

CAPÍTULO 3 - PROCESSAMENTO DIGITAL DE IMAGENS, SENSORIAMENTO REMOTO E GEOPROCESSAMENTO

As especificações técnicas básicas dos satélites comerciais com imagens de alta resolução e os satélites de resoluções mais baixas são apresentadas na Tabela 8.

Tabela 8 - Especificações técnicas básicas de satélites

Satélite	Resolução Espacial	Resolução Temporal	Resolução Radiométrica por pixel	Sensibilidade espectral (Nº bandas MS)*
Worldview-2	0,5 m (PAN) 2 m (MS)	1,1 dias	11 bits	450 a 800 nm (PAN) 400 a 1040 nm (8 MS)
Quickbird	0,6 m (PAN) 2,4 m (MS)	2,4 dias	11 bits	405 a 1053 nm (PAN) 430 a 918 nm (4 MS)
Ikonos	1,0 m (PAN) 4,0 m (MS)	3 dias	11 bits	450 a 900 nm (PAN) 450 a 900 nm (4 MS)
RapidEye	6,0 m (imageado) 5m (reamostrado)	5,5 dias	12 bits	440 a 880 nm (5 MS)
Landsat8	15 m (PAN) 30 m (MS)	16 dias	16 bits	500 a 680 nm (PAN-B8) 450 a 1380 nm (8 MS)

Legenda: PAN – Banda Pancromática; MS – Bandas multiespectrais; B 8 – Banda 8 do satélite Landsat8; Nº bandas MS – Número de bandas multiespectrais.

Fonte: EngeSat (2016).

3.3. A cor no sensoriamento remoto

Uma das composições mais comuns no pré-processamento das imagens de sensoriamento remoto é aquela que utiliza as bandas: vermelha (*Red*), verde (*Green*) e azul (*Blue*), denominada composição RGB. Estas cores primárias foram reveladas pelo trabalho de Thomas Young (1773-1829) que ao projetar a luz através de filtros circulares (vermelhos, verdes e azuis) e realizar combinação de cores, sobrepondo-as umas às outras, descobriu que diversos efeitos eram obtidos. Também observou que essas três cores não podiam ser produzidas com mistura de duas delas, por isso as chamou de cores primárias aditivas (CRÓSTA, 1992).

Uma forma de produzir fotografias coloridas a partir do processo aditivo é por meio de três conjuntos de fotografias branco e preto da mesma área e por filtros azul, verde e vermelho, respectivamente, pois ao projetar esses filtros, as cores originais dos objetos são reproduzidas (NOVO, 1992, p. 73).

O modelo RGB se baseia em um sistema de coordenadas cartesianas e pode ser representado por um cubo, no qual: os valores RGB primários estão em três vértices; as cores secundárias (ciano, magenta e amarelo) estão em outros três vértices; o preto está na origem; e

CAPÍTULO 3 - PROCESSAMENTO DIGITAL DE IMAGENS, SENSORIAMENTO REMOTO E GEOPROCESSAMENTO

o branco está no vértice mais distante da origem. A escala de cinza (pontos de valores RGB iguais) estende-se do preto ao branco, do segmento da reta que une esses dois pontos (GONZALES; WOODS, 2010).

As diferentes cores nesse modelo são definidas por vetores que se estendem a partir da origem do cubo e por conveniência assume-se que todos os valores de cor foram normalizados, de forma que o cubo seja unitário, ou seja, assume-se que os valores de R, G e B estejam no intervalo $[0,1]$. O cubo utilizado como exemplo é apresentado na Figura 9.

Figura 9 - Esquema do cubo de cores RGB
Fonte: Gonzalez e Woods (2010)

As imagens representadas por esse modelo consistem de três componentes de imagens para cada cor primária e, quando alimentadas em um monitor RGB, essas três imagens se combinam na tela para produzir uma imagem de cores compostas, conforme Figura 10.

Figura 10 - Geração da imagem RGB no plano de cor (corte transversal)
Fonte: Gonzales e Woods (2010)

No sensoriamento remoto, o processo aditivo de formação de cores é utilizado em fotografias multiespectrais. A interação RGB é denominada composição colorida “cor verdadeira”, assim como as outras interações são as composições “falsa-cor”. Tais composições dependem do objeto de estudo, portanto, se o objetivo é quantificar a vegetação de tal área, utiliza-se a banda infravermelha, que faz com que a vegetação seja facilmente identificada.

As imagens produzidas por sensores multiespectrais possuem intervalos de comprimento de onda contíguos havendo repetição da informação espectral de uma banda para a outra. Como exemplo, se destaca a sombra produzida por projeções dos raios solares oblíquos ao terreno imageado, que sempre será exibido na imagem em cor escura, independente da banda considerada; portanto, os pixels da área que contém sombra terão valores de DN baixos em todas as bandas. Quando isso acontece, as bandas são consideradas correlacionadas do ponto de vista espectral.

3.4. Histograma das imagens de sensoriamento remoto

O histograma é uma das formas mais comuns de se representar a distribuição dos níveis de cinza de uma imagem, pois fornece informações sobre seus valores e da proporção da imagem que corresponde a cada valor de DN. Um exemplo de histograma é apresentado na Figura 11.

Figura 11 - Histograma da imagem
Fonte: INPE (2016)

A probabilidade de se encontrar um DN de um dado valor dentro da imagem é denominada “distribuição de intensidades e função de densidade da probabilidade” e esta é representada por colunas com números inteiros (CRÓSTA, 1992).

O entendimento do histograma da imagem é a base necessária para se aplicar técnicas de realce e contraste, pois sua forma fornece as informações de intensidade média e dispersão dos valores de DN, este último, por exemplo, influencia diretamente no contraste da imagem, pois quanto maior a dispersão ao longo do eixo dos DN's, maior é o contraste da imagem. Os histogramas podem ser:

- ✓ Uni-dimensionais: apenas uma banda;
- ✓ Bi-modais: quando se tem mais de uma banda;
- ✓ Cumulativos: plota-se a frequência cumulativa dos pixels com determinado DN, contra os valores de DN. Neste caso, a inclinação da curva do gráfico é a medida do contraste;
- ✓ Multi-dimensionais ou scattergrama: utilizados em imagens multiespectrais, apresentam o grau de correlação entre as bandas. Este tipo de histograma é útil nas técnicas de realce e contraste quando se quer produzir imagens coloridas e realçadas.

3.5. Técnicas de processamento digital de imagens

O objetivo principal do processamento de imagens é o de remover as barreiras inerentes ao sistema visual humano, facilitando a extração de informações. Portanto, o processamento digital deve ser encarado como um estágio preparatório da atividade de interpretação das imagens de sensoriamento remoto.

O estágio preparatório envolve: i) a **retificação e restauração (correção radiométrica e geométrica)**, que são operações realizadas para minimizar as distorções e degradações dos dados de uma imagem, ii) o **realçamento** para melhorar a visualização e interpretação da imagem, e iii) a **classificação** que visa identificar as composições de diferentes materiais da superfície da terra.

CAPÍTULO 3 - PROCESSAMENTO DIGITAL DE IMAGENS, SENSORIAMENTO REMOTO E GEOPROCESSAMENTO

As técnicas de correção radiométrica e geométrica nem sempre são aplicadas pelo usuário final, pois na maioria das vezes ao adquirir a imagem os processos já foram aplicados e, portanto, serão brevemente citados neste trabalho.

As técnicas de realce são aquelas que modificam, através de funções matemáticas, os níveis de cinza (DN), sendo as mais comuns a ampliação de contraste e a composição colorida. Neste trabalho, foi utilizada a composição colorida RGB, denominada cor verdadeira.

3.5.1. Correção geométrica e radiométrica

A correção geométrica é aplicada para reparar problemas decorrentes do sensor ou de inconsistências no sistema de varredura e interferência atmosférica; pois elimina as distorções geométricas sistemáticas introduzidas na etapa de aquisição das imagens (PARANHOS FILHO; LASTORIA; TORRES, 2008; BARBASSA; BIELENKI JUNIOR, 2012).

O processo de correção gera o deslocamento dos pixels que necessitam ser reposicionados e, para isso, são utilizadas técnicas de reamostragem. Novo (1992) conceitua e apresenta as vantagens e desvantagens de alguns dos algoritmos aplicados na reamostragem:

- ✓ Alocação de vizinho mais próximo (*Nearest Neighbor*): o valor de um determinado pixel é atribuído ao pixel vizinho. Esta técnica tem um processamento rápido, é facilmente implementado e não altera o valor original do pixel, porém, provoca descontinuidades geométricas na imagem corrigida (lacunas da ordem de $\frac{1}{2}$ pixel) que pode se tornar inadequada para manipulação numérica.
- ✓ Interpolação bilinear: o valor do pixel é determinado a partir de quatro valores provenientes dos pixels vizinhos. Esta técnica tem maior precisão geométrica e elimina as descontinuidades, porém requer maior quantidade de cálculos e altera o valor original do pixel.
- ✓ Convolução cúbica: o valor de um determinado pixel é determinado a partir de uma matriz de 16 valores provenientes dos pixels vizinhos. Esta técnica melhora a visualização da imagem, porém requer maior tempo de processamento e degrada a qualidade radiométrica dos dados.

CAPÍTULO 3 - PROCESSAMENTO DIGITAL DE IMAGENS, SENSORIAMENTO REMOTO E GEOPROCESSAMENTO

A correção radiométrica consiste em minimizar as diferenças entre os níveis de cinza registrados por detectores, que ocorre devido a problemas na calibração dos sensores ou em função da não linearidade da resposta dos detectores à radiância da imagem.

A técnica consiste em reorganizar os pixels da imagem em relação a um sistema de projeção cartográfico. Isto pode ser feito por meio da reformatação da imagem, quando se tem os valores dos pontos de controle no terreno (latitude e longitude). A reformatação é realizada por uma função que relaciona a posição do ponto (x, y) com sua respectiva posição geográfica, pelo método dos mínimos quadrados (NOVO, 1992).

3.5.2. Técnica de fusão de imagens

A técnica de fusão de imagens foi proposta para melhor aproveitamento das informações produzidas por diferentes sensores. A fusão consiste em sobrepor os sensores pancromático (com maior resolução espacial) e os sensores multiespectrais (com menor resolução espacial) para gerar um produto final com melhor qualidade visual e, por exemplo, aplicar as técnicas de classificação de imagens.

Tais técnicas podem ser divididas basicamente em três grupos: i) as que utilizam um modelo de domínio espacial, ii) as de domínio espectral e, iii) as que trabalham com operações algébricas (UFRGS, 2016).

Os modelos de **domínio espacial** são aqueles que isolam a informação espacial de alta frequência, provenientes da imagem de alta resolução, e as combinam com a imagem multiespectrais. Dois exemplos são: transformadas *Wavelets* e a técnica HPF (*High-Pass Filter*).

Os modelos de **domínio espectral** são formados pelos processos que realizam uma transformação na imagem multiespectral, resultando num novo conjunto de bandas, em que uma delas é correlacionada com a imagem pancromática. Alguns exemplos são: Principais Componentes (PC), IHS (*Hue, Saturation, Intensity*) e Gram-Schmidt (UFRGS, 2016).

A última técnica é formada por **modelos algébricos** que operam funções aritméticas pixel-a-pixel. Como exemplos, podem ser citadas as técnicas Brovey, a técnica Multiplicativa e a fusão simples por contribuição relativa espectral (RCS).

De acordo com Amro et al (2011) no método RCS é aplicada uma combinação linear de bandas espectrais, utilizando-se somente das informações das bandas multiespectrais; assim a fusão sintética das bandas é aplicada em cada pixel.

A fusão simples por contribuição relativa (*Simple RCS Pan sharpening*) aumenta os detalhes espaciais da imagem pancromática por meio de cálculos aritméticos. A operação é realizada por dois processos: i) a imagem multiespectral é ampliada e registrada para a imagem pancromática e ii) o operador de fusão RCS pixel-a-pixel é aplicado aos pixels co-registrados da imagem para obter os pixels fundidos (OTB, 2015).

A fusão *Simple PanSharpeing* é realizada de acordo com a equação 29:

$$PXS(i,j) = \frac{PAN(i,j)}{PAN_{suavização}(i,j)} XS(i,j) \text{ (Equação 29)}$$

Em que: i e j são indicadores de pixels; PAN é a imagem pancromática; XS é a imagem multiespectral; e $PAN_{suavização}$ é a imagem pancromática suavizada com uma função *Kernel* para ajustar-se à escala da imagem multiespectral.

O algoritmo de fusão simples por contribuição relativa, aplicado neste trabalho, é apresentado na Figura 12. Nesta figura, são apresentadas as bandas multiespectrais de resolução espacial de 30m (a) e o resultado da fusão com a banda PAN de 15m (b) de parte de uma imagem Landsat8 do ano de 2014, sendo sua resolução final de 15m.

Figura 12 - Composição de bandas 4,3,2 em imagem MS com resolução espacial de 30m (a) e imagem fusionada (MS+PAN) com resolução espacial de 15m (b).

3.5.3. Técnicas de segmentação de imagens

A segmentação consiste na identificação de regiões ou segmentos (não sobrepostos) na imagem. Nesse processo, a imagem é subdividida nos objetos que a compõe e o nível de detalhe dessa divisão depende do objetivo do problema a ser resolvido (GONZALEZ; WOODS, 2010).

Esta técnica segue o princípio de que a partir de uma imagem digital, seja possível, através de algoritmos estatísticos, reduzir as informações da mesma em regiões (objetos) homogêneas, as quais consistem de funções diretas do problema considerado, ajudando em uma análise mais adequada da imagem.

Para possibilitar a identificação de segmentos na imagem é desejável que a região representada pelos pixels seja: homogênea, que os segmentos sejam delimitados por bordas ou por outros segmentos e, que as diferenças entre as regiões adjacentes da imagem sejam significativas. Na prática, esses pré-requisitos são utópicos e a separação da região geralmente é destacada buscando-se as discontinuidades e as similaridades nos diferentes tons da imagem (MANTELLI, 2016).

CAPÍTULO 3 - PROCESSAMENTO DIGITAL DE IMAGENS, SENSORIAMENTO REMOTO E GEOPROCESSAMENTO

As discontinuidades são representadas por mudanças bruscas nos níveis de cinza, como linhas e bordas. Já as similaridades baseiam-se: nos limiares dos níveis de cinza, na subdivisão da imagem em regiões homogêneas e no crescimento de regiões. Neste último, o limiar está baseado na distância Euclidiana entre os valores médios dos níveis de cinza de cada região. Assim, duas regiões são consideradas distintas se a distância entre suas médias for superior ao limite de similaridade escolhido (FERNANDES, 2005).

As técnicas de segmentação de imagens são divididas em: i) **segmentação no espaço de medidas**, ii) **segmentação no domínio espacial** e iii) **segmentação no domínio da frequência**.

A técnica de segmentação do espaço de medida é dividida em: i) agrupamento por pixel; ii) agrupamento por histograma; e iii) agrupamento por limiar (limiarização):

i) A técnica consiste em dividir a imagem em partes diferentes e identificar cada parte, em seguida os pixels são analisados estatisticamente (comparados com seus vizinhos), e distribuídos nas partes definidas, portanto, os pixels com propriedades em comum formam os segmentos da imagem. Geralmente, este método é empregado onde existem objetos distintos e grande diferença de intensidade nos níveis de cinza do fundo da imagem.

ii) Na segunda técnica, os pixels da imagem são representados por um histograma construído pelos valores de DN (eixo x) e as frequências (eixo y) e a determinação dos segmentos é dada pelos intervalos entre os picos do histograma.

iii) O agrupamento por *limiarização* é utilizado quando o intervalo entre os picos de um histograma bimodal não está claramente definido.

As técnicas de segmentação por crescimento de regiões parte do princípio que pixels com valores semelhantes devem pertencer ao mesmo objeto e por isso são agrupados em uma única região. Este processo inicia considerando cada pixel como sendo uma região e é repetido iterativamente, unindo-se a regiões na imagem até que se atinja um ponto de parada, que geralmente é baseado em critérios de semelhança entre as regiões. Para realizar tais funções a técnica utiliza dois limiares: similaridade e área (PIZARRO; CONUMELLO; MANTELLI, 2016).

A técnica de segmentação no domínio da frequência considera a imagem como um sinal e utiliza as suas variações no espaço da imagem como frequências, ou seja, observam-se as texturas de uma imagem como aspectos principais (MANTELLI, 2016).

CAPÍTULO 3 - PROCESSAMENTO DIGITAL DE IMAGENS, SENSORIAMENTO REMOTO E GEOPROCESSAMENTO

3.5.4. Técnicas de classificação de imagens

A classificação de uma imagem pode ser realizada de forma manual, por fotointerpretação, ou de forma automática. A classificação automática consiste no agrupamento de pixels com características espectrais semelhantes para determinar uma “classe”.

As técnicas de classificação de imagens automáticas são mais utilizadas na elaboração de cartas temáticas (CRÓSTA, 1992). São divididas em **classificação multiespectral**, na qual os alvos a serem identificados são baseados na resposta espectral, e **Classificação Orientada a Objeto**, que considera o arranjo espacial dos pixels (PARANHOS FILHO; LASTORIA; TORRES, 2008).

Ainda segundo os autores, a classificação automática pode ser realizada de forma **supervisionada e não supervisionada**. A técnica supervisionada tem a função de redividir estatisticamente a imagem em classes, baseadas nas áreas de treinamento (*training samples*), fornecidas ao sistema pelo usuário. Esta classificação leva em conta a capacidade interpretativa do usuário, portanto, a imagem é classificada com base em determinados parâmetros definidos pelo mesmo. A seleção da amostra, geralmente um polígono, é a que define a base da padronização da área a ser classificada, portanto, esta área deve conter uma quantidade suficiente de pixels (CRÓSTA, 1992).

O processo consiste em duas etapas: o reconhecimento das categorias dos objetos do mundo real e a rotulação dos objetos encontrados. Nas imagens digitais, esse rótulo ou legenda é um valor numérico (MATHER, 2004). Os algoritmos estatísticos são usados para extrair informações das amostras de treinamento do classificador, tais como: valores máximos, mínimos e médios das feições, ou a média e a matriz de variância-covariância de cada classe.

O método de classificação não supervisionado é normalmente realizado com o uso de agrupamentos ou nuvens (*clusters*). O classificador identifica e classifica o agrupamento a partir de comparações espectrais entre pixels, estabelecendo padrões específicos dos pixels da

imagem (PARANHOS FILHO; LASTORIA; TORRES, 2008). Uma das vantagens desse método é que não requer conhecimento prévio do analista (NOVO, 1992).

A classificação híbrida é aquela em que o analista utiliza a classificação não supervisionada como base para seleção de amostras de treinamento, para realizar uma classificação supervisionada (NOVO, 1992).

O método supervisionado de classificação e os algoritmos aplicados nesta pesquisa são apresentados com mais detalhes nos textos que se seguem.

3.6. Método de classificação de imagens

Existe uma variedade de métodos utilizados na classificação supervisionada em que o produto final é um mapa temático. Alguns desses métodos são brevemente conceituados:

- ✓ Método do paralelepípedo: trabalha com uma área quadrada representativa, definida pelo maior e pelo menor valor de pixels contidos no agrupamento selecionado. Como desvantagem do método, tem-se a inclusão de pixels não pertencentes à classe, devido à amostra ser um polígono.
- ✓ Método da distância mínima: calcula o valor médio dos pixels na amostra de treinamento e, mede as distâncias entre esse valor e o valor dos pixels restantes da imagem. Sendo assim, atribui-se a cada pixel um valor conforme a classe mais próxima dele.
- ✓ Método da máxima verossimilhança ou MaxVer: utiliza a média e a covariância dos pixels presentes na amostra de treinamento e calcula a probabilidade de um pixel externo pertencer a essa amostra. Recomenda-se utilizar amostras com mais de 100 pixels.
- ✓ Método de aprendizado em máquinas ou SVM: calcula a média e o desvio padrão do conjunto de bandas da imagem de entrada, com base na variância de cada banda, e utiliza esses valores para centrar e reduzir a intensidade das amostras de treinamento, com valor médio de 0 e desvio padrão de 1.
- ✓ Método da análise orientada a objetos ou AOO: delimita os objetos com características espectrais (ou radiométricas) homogêneas, considerando o DN de cada pixel e de seus vizinhos para agrupá-los em conjuntos. Assim, a classificação passa a considerar

CAPÍTULO 3 - PROCESSAMENTO DIGITAL DE IMAGENS, SENSORIAMENTO REMOTO E GEOPROCESSAMENTO

informações extraídas desses objetos, como resposta espectral média, variância, dimensões, forma e textura.

As estatísticas utilizadas nos métodos: Máxima Verossimilhança, Suporte Vector Machine e na Análise Orientada a Objeto são descritas nos textos que se seguem, pois foram os métodos aplicados nesta pesquisa. Essa abordagem busca auxiliar o leitor na compreensão dos resultados de cada classificação das imagens.

3.6.1. Máxima Verossimilhança - MaxVer

O método de classificação de imagens por “Máxima Verossimilhança – MaxVer” (*maximum likelihood*) considera a ponderação das distâncias entre as médias dos DN's das classes, utilizando parâmetros estatísticos que dizem qual a probabilidade de um pixel pertencer ou não à uma determinada classe. Considera também a localização do pixel, segundo a distribuição espectral da classe. Em outras palavras, o classificador estima o vetor médio da matriz de variância e covariância de cada classe, assumindo que a frequência de distribuição dos pixels possua probabilidade de distribuição normal (MATHER, 2004).

As amostras de treinamento definem o diagrama de dispersão das classes e suas distribuições de probabilidade normal. Como exemplo, tem-se duas classes (1 e 2) com distribuição de probabilidades distintas. Estas distribuições representam a probabilidade de um pixel pertencer a uma ou outra classe, e dependem da posição do pixel. Quando duas curvas de probabilidade se sobrepõem, o método indica que um determinado pixel tem igual probabilidade de pertencer às duas classes. Nesta situação, estabelece-se um critério de decisão a partir da definição de limiares.

A probabilidade de $P(x)$ de determinado pixel, de um conjunto de elementos, pertencer a determinada classe é dada por uma distribuição multivariada normal, apresentada na Equação 30, e a distribuição normal dos pixels de duas classes com igual probabilidade de pertencer às classes 1 ou 2 e seu limite de decisão, são apresentados na Figura 13.

(Equação 30)

$$P(x) = 2\pi^{-0,5p} |S_i|^{-0,5} \exp[-0,5(y'S_i^{-1}y)]$$

S_i é a matriz de variancia-covariancia da amostra da classe i ;
 $y = (x - \bar{x}_i)$ e $\bar{x}_i$ é a média multivariada da classe i ;
 $y'S_i^{-1}y$ é a distância Mahalanobis.

Fonte - Mather (2004)

Figura 13 - Distribuição normal

A distância de Mahalanobis, citada na equação 30, é baseada na correlação entre as variáveis. O método é utilizado em análises de agrupamentos, técnicas de classificação e para detectar *outliers* em conjuntos de dados multivariados, especialmente no desenvolvimento de modelos de regressão linear.

O método MaxVer parte do princípio que o usuário conhece bastante da imagem a ser classificada para definir classes representativas. Nos casos em que isso não acontece é possível partir de algumas premissas, razoáveis o suficiente, para permitir bons resultados (CRÓSTA, 1992).

Batista e Santos (2013) apresentaram um trabalho referente à classificação de imagens Landsat5 para detectar mudanças na cobertura e no uso da terra do município de Teofilândia, Bahia (BA), nos períodos de 1993 a 2008. Foram aplicadas técnicas de pré-processamento (correção atmosférica, registro, composição RGB - 543), processamento (classificação MaxVer com limiar de aceitação de 95%.) e pós-processamento. Os *softwares* utilizados neste trabalho foram: o *Idrisi Andes*, o *Envi 4.4*, o *Arc Gis 9.3* e o *Spring 4.3.3*.

As imagens foram divididas em períodos secos (1993 e 2007) e chuvosos (1994 e 2008) e classificados os seguintes usos: água, área urbana, caatinga, pastagem e solo exposto. Para a classe urbana foi criada uma máscara fazendo com que sua área fosse constante em todas as análises, pois consideraram o crescimento urbano pouco significativo.

Um dos pontos interessantes no trabalho de Batista e Santos (2013) é que as amostras de treinamento foram analisadas permitindo um grau de confusão entre elas de, no máximo 5%, e um desempenho médio das amostras acima de 95%. Se a confusão entre classes fosse superior a 5%, as amostras seriam excluídas e novas amostras seriam coletadas e analisadas, em um processo iterativo, até que os valores apresentados fossem adequados aos critérios estabelecidos (classificação de 100% da imagem).

CAPÍTULO 3 - PROCESSAMENTO DIGITAL DE IMAGENS, SENSORIAMENTO REMOTO E GEOPROCESSAMENTO

Contudo, foram analisadas as classificações para os períodos secos e chuvosos, e comparadas com a imagem classificada do ano de 2008. O resultado obtido demonstrou que as influências da sazonalidade nas mudanças das classes da cobertura e do uso da terra são mais expressivas do que os extremos do recorte temporal entre os anos analisados. Em sua dissertação de mestrado, Batista (2011) apresentou o valor do índice Kappa calculado para a classificação MaxVer da imagem do ano de 2008, sendo este de 0,86.

O método de classificação MaxVer foi aplicado no *software* IDRISI, versão 15.0, por Demarchi, Piroli e Zimback (2011) que utilizaram imagens Landsat-5 com resolução espacial de 30 m do município de Santa Cruz do Rio Pardo – SP, para os anos de 2007 e 2009. O trabalho teve como objetivo analisar a evolução temporal da cobertura e do uso da terra, por meio da classificação supervisionada; verificar a exatidão do mapeamento através do índice Kappa; e comparar os índices de vegetação NDVI (Índice de Vegetação da Diferença Normalizada) e SAVI (Índice de Vegetação Ajustado ao Solo) em diferentes fatores de ajuste.

Com relação à exatidão da classificação, aplicaram os métodos de coleta de pontos de amostragem denominados *Aleatórios* e *Sistemáticos*, presentes no IDRISI, sendo o primeiro uma coleta aleatoriamente distribuída e, no método sistemático os pontos de coleta formaram uma grade regular. Os valores dos índices Kappa obtidos variaram de 0,47 a 0,74 nas três imagens analisadas.

Góes, Melo Filho e Carvalho (2006) compararam o desempenho dos classificadores Isoseg, Bhattacharyya, Maxver e Maxver-ICM a partir da análise das áreas das classes em imagens classificadas e dos valores de índice Kappa, utilizando como verdade terrestre um mapa temático previamente editado. Foram utilizadas técnicas de pré-processamento (correções atmosférica, geométrica e radiométrica), realce (fusão IHS e análise por componentes principais) e classificação das imagens CCD/CBERS-1 e ETM+/Landsat-7.

Como resultado, o MaxVer apresentou valores de índice Kappa de 0,15 para a vegetação 1; 0,32 para a vegetação 2; 0,22 para área urbana; 0,13 para manguezal; e 0,76 para as dunas, e obteve uma média de 0,35, considerada ruim de acordo com Landis e Koch (1977, p. 165).

CAPÍTULO 3 - PROCESSAMENTO DIGITAL DE IMAGENS, SENSORIAMENTO REMOTO E GEOPROCESSAMENTO

3.6.2. Método Support Vector Machine (Máquinas Vetores Suporte) – SVM

O classificador SVM fornece uma classificação inteligente de pixels, baseada no aprendizado de várias imagens. Em seu treinamento, o SVM utiliza como característica a intensidade de cada pixel. Para que o classificador possa comparar as amostras de treinamento e a imagem de satélite, é estimada a estatística da imagem de entrada, utilizada para centrar e reduzir a intensidade das amostras de treinamento com valor médio de 0 e desvio padrão de 1. A ferramenta que computa as estatísticas calcula a média e o desvio padrão do conjunto de bandas da imagem de entrada, com base na variância de cada banda.

De forma simplificada, o método consiste na busca da superfície de separação entre duas classes com a determinação do subconjunto de amostras de treinamento, que melhor descreva a fronteira entre duas classes. Estas amostras são chamadas de *vetores de suporte* e definem o sistema de classificação. A separação máxima entre duas classes (vetores de suporte) é apresentada na Figura 14.

Figura 14 - Sistema SVM de classificação de imagens com máxima separação do hiperplano (a) e feições linearmente separáveis (b)

Fonte: Raghavendra e Deka (2014)

No caso das duas classes serem não-linearmente separáveis, o método usa um núcleo de expansão (*Kernel*) para fazer projeções das características do espaço para espaços com dimensões mais elevadas, onde a separação das classes tornam-se lineares (OTB, 2015).

Os princípios básicos do treinamento e da classificação SVM são dados pelos exemplos em que se tem N amostras representadas por y_i e x_i , sendo que $i = 1 \dots N$; $y_i \in \{-1, +1\}$

é a legenda da classe, e $x_i \in R_n$ é a dimensão das características do vetor. A função de classificação é dada pela Equação 31:

$$f(x, \alpha) = x \rightarrow y \text{ (Equação 31)}$$

Na equação, α é o parâmetro de classificação. Assim, o SVM encontra uma separação ótima do hiperplano para satisfazer as seguintes restrições: as amostras de treinamento +1 e -1 ficam em lados diferentes do hiperplano, e a distância dos vetores mais próximos do hiperplano é maximizada. Estes, são os vetores de suporte (SV) e essa distância é chamada de *margem*. A equação de separação do hiperplano é apresentada:

$$w x + b = 0 \text{ (Equação 32)}$$

Nesta, w é o vetor normal e x qualquer ponto do hiperplano. A distância ortogonal da origem é dada por $\frac{|b|}{\|w\|}$. Para os vetores localizados fora do hiperplano tem-se $w x + b > 0$, ou $w x + b < 0$. Para tanto, a função de classificação pode ser escrita como:

$$f(x, w, b) = \text{sgn}(w x + b) \text{ (Equação 33)}$$

Os vetores suportes são localizados em dois hiperplanos paralelos à separação ótima das classes. Para encontrar o hiperplano ótimo define-se w e b :

$$w x + b = \pm 1 \text{ (Equação 34)}$$

Desde que não exista vetor dentro da margem, a seguinte restrição pode ser usada: $w x_i + b \geq +1$ se $y_i = +1$; e $w x_i + b \leq -1$ se $y_i = -1$. Que pode ser reescrito como:

$$y_i (w x_i + b) - 1 \geq 0 \quad \forall_i \text{ (Equação 35)}$$

A distância ortogonal dos dois hiperplanos paralelos para a origem são $\frac{|1-b|}{\|w\|}$ e $\frac{|-1-b|}{\|w\|}$.

Portanto, o módulo da margem é igual a $\frac{2}{\|w\|}$ e deve ser maximizada. Para resolver este problema é necessário encontrar w e b que minimizem $\left\{\frac{1}{2} \|w\|^2\right\}$, sob a restrição de:

$$y_i (w x_i + b) \geq +1 \quad i = 1 \dots N \text{ (Equação 36)}$$

Este problema pode ser resolvido utilizando os multiplicadores de Lagrange, com um multiplicador por amostra. Portanto, apenas os vetores suporte terão um multiplicador de Lagrange positivo, neste caso, as duas classes não são linearmente separáveis e pode-se modificar a equação acima da seguinte maneira:

$$\begin{aligned} w x_i + b &\geq +1 - \xi_i \text{ se } y_i = +1 \\ w x_i + b &\leq -1 + \xi_i \text{ se } y_i = -1 \text{ (Equação 37)} \\ \xi_i &\geq 0 \quad \forall_i \end{aligned}$$

A letra grega ξ_i , pronunciada *Csi* ou *xi*, é utilizada para variáveis aleatórias. Se $\xi_i > 1$ considera-se que a amostra está errada. A função a ser minimizada é $\frac{1}{2} \|w\|^2 + C(\sum_i \xi_i)$, em que C é o parâmetro de tolerância. A otimização do problema é a mesma do caso linear, mas um multiplicador deve ser adicionado para cada nova restrição ($\xi_i > 0$). Se a superfície de decisão é necessariamente não linear, esta solução não poderá ser adotada e a abordagem kernel deve ser adotada.

Para alcançar uma melhor convergência do algoritmo é altamente recomendável normalizar componentes do vetor suporte no intervalo de $[-1; 1]$. Para problemas com mais de duas classes ($n > 2$) pode-se optar por treinar o classificador, jogando a classe analisada contra todas as outras, ou cada classe contra cada uma das outras ($N \times (N - 1)$). Esta última é a abordagem utilizada no classificador SVM Orfeo Toolbox, onde a decisão final é tomada para escolher a classe mais frequentemente selecionada por todo o conjunto SVM (OTB, 2015).

3.6.3. Método da Análise Orientada a Objeto (AOO)

A Análise Orientada a Objetos (AOO) apresenta-se como um método alternativo aos tradicionais de classificação, pois, além da informação espectral de cada pixel, utiliza também a informação da relação espacial entre os pixels e sua vizinhança. Este último é conhecido como método de alocação do vizinho mais próximo, do inglês *Nearest Neighbor*.

Estes classificadores procuram simular o comportamento de um foto-intérprete ao reconhecer áreas homogêneas de imagens, baseados em suas propriedades espectrais e espaciais (ANTUNES; CORTESE, 2007).

Paranhos Filho, Lastoria e Torres (2008) afirmam que a principal diferença entre este tipo de classificação e a tradicional, é que a AOO não analisa os pixels individualmente, mas em relação ao seu conjunto, ou seja, o sistema não considera apenas o DN do pixel, mas também os pixels ao seu redor, procurando por similaridades estatísticas e agrupando-os em conjuntos por segmentação.

Um dos classificadores que utilizam a AOO está disponível no *software* eCognition. Este utiliza um algoritmo de segmentação denominado multiresolução (*multiresolution*

CAPÍTULO 3 - PROCESSAMENTO DIGITAL DE IMAGENS, SENSORIAMENTO REMOTO E GEOPROCESSAMENTO

segmentation) para extrair objetos de imagens homogêneas, com base no valor do pixel e em sua forma.

Em suma, o algoritmo executa um procedimento de otimização que tem por finalidade maximizar a homogeneidade. Os critérios utilizados para este parâmetro são a **escala** e a **cor**. O parâmetro escala determina a heterogeneidade máxima permitida para os objetos da imagem resultante. Quando se modifica o valor da escala, varia-se o tamanho do objeto da imagem, portanto os valores de escala maiores resultam em objetos maiores e vice-versa (DEFINIENS, 2015).

Para definir a homogeneidade de um objeto, dois critérios devem ser considerados: a forma (*shape*) e a compacidade (*compactness*). Ambos possuem um oponente cuja soma entre eles resultam no valor 1. O oponente do critério *forma* é a cor e da *compacidade* é a suavidade, sendo que os critérios compacidade e suavidade, juntos, representam o critério forma.

Após a segmentação, o classificador segue a lógica de regras *fuzzy* de pertinência para associar os objetos segmentados às classes. Nesta lógica, um objeto pode estar associado a várias classes com diferentes graus de pertinência, sendo que o grau de pertinência varia de 0 (não pertence) a 1 (pertence) e a classe considerada é aquela cujo grau de pertinência é maior.

A AOO é utilizada principalmente para imagens de alta resolução que, por captarem muitos detalhes diferentes (calçadas, gramados, casas, asfalto, terrenos baldios etc.), apresentam um padrão espectral complexo. Desta forma, este tipo de classificador permite um maior aproveitamento das imagens, distinguindo de forma mais precisa os objetos que compõem a imagem, aumentando a acurácia e a precisão da classificação (PARANHOS FILHO; LASTORIA; TORRES, 2008).

3.7. Avaliação da classificação de imagem

A análise da acurácia de uma classificação supervisionada depende de dois fatores: da representatividade das informações presentes na imagem, e do grau de desvio suposto no qual a técnica de classificação é baseada (MATHER, 2004).

O método de classificação pode ser avaliado em relação a um dado de referência, por meio de critérios estatísticos. Segundo Congalton e Green (2009) uma matriz de confusão (ou matriz de erro) pode ser usada como o ponto de partida para a aplicação de uma série de técnicas estatísticas descritivas e analíticas.

O método mais comum para representar o grau de acuracidade da classificação, é a construção de uma matriz de confusão. Como exemplo dessa matriz é apresentada a Tabela 9, na qual o total de elementos da linha 1 apresenta o número de pixels que o operador identificou pertencente à classe 1. O elemento da linha 1 com a coluna 1 (x_1, y_1), contém o número de pixels identificados pelo classificador como corretamente pertencentes a classe 1; o mesmo ocorre para todos os elementos da diagonal principal, ou seja, ela contém os pixels classificados corretamente.

Os outros elementos da linha 1 apresentam o número e a distribuição de pixels incorretamente classificados. A acurácia da classificação para a classe 1 é, portanto, o número de pixels (x_1, y_1) dividido pelo número total de pixels identificados pelo operador como valor de referência relacionado a classe 1 - somatório da linha (MATHER, 2004).

Tabela 9 - Exemplo de matriz de confusão

Imagem de Satélite (Referência)	Imagem Classificada					Referência ($\sum_{\text{linha}}$)
	$x_1; y_1$	Erros de classificação da linha 1 (omissão)				$\sum x_1$
	Erros de classificação da coluna 1 (comissão)	$x_2; y_2$				$\sum x_2$
			$x_3; y_3$			$\sum x_3$
				$x_4; y_4$		$\sum x_4$
					$x_5; y_5$	$\sum x_5$
$\sum_{\text{coluna}}$						

Os processos da matriz de confusão dependem da quantidade de pixels nas amostras de cada classe da cobertura e do uso da terra. Deve-se separar amostras de treinamento do total de amostras de cada classe para o cálculo da acuracidade da classificação, tornando-as

CAPÍTULO 3 - PROCESSAMENTO DIGITAL DE IMAGENS, SENSORIAMENTO REMOTO E GEOPROCESSAMENTO

como valores de referência (amostras de validação). As amostras de treinamento são usadas pelo classificador para extração do DN de cada classe, enquanto que as amostras de validação são utilizadas para verificar a acurácia da classificação (MATHER, 2004 p. 245).

A interpretação literal da medida da acuracidade derivada da matriz de confusão pode conduzir a erros. Na Figura 15, é apresentada a representatividade de amostras de treinamento em uma classificação de imagem hipotética. Se a seleção da amostra de treinamento for a área correspondente à linha sólida, a acurácia da classificação será de 100%; enquanto que, se a seleção for a área da amostra da linha tachada, a acurácia deverá ser 75%.

A	A	A	A	F	A	A
A	A	A	F	F	F	U
A	A	A	F	A	A	A
A	A	A	A	A	A	A
U	A	F	A	U	U	U
A	A	A	A	U	U	A
A	A	A	A	A	A	A

(a)

A	A	A	A	A	A	A
A	A	A	A	A	A	A
A	A	A	A	A	A	A
A	A	A	A	A	A	A
A	A	A	A	A	A	A
A	A	A	A	A	A	A
A	A	A	A	A	A	A

(b)

Figura 15 - Categorias de cobertura da terra derivadas dos dados de referência (a) e imagem classificada (b).
Fonte: Mather (2004)

Os erros de classificação da linha na matriz de confusão (Tabela 9) são conhecidos como erros de omissão, que são aqueles originados por escolhas de amostras de treinamento não representativas dos dados de referência, como por exemplo, a área da amostra na linha tachada (Figura 15). Já os erros de classificação da coluna são chamados de erros de comissão, que são aqueles em que o classificador julgou ser pertencente à determinada classe, mas não concordam com o dado de referência (MATHER, 2004 p. 245).

Os erros de omissão são calculados por:

$$E_o = \frac{X_{i+} - X_{ii}}{X_{i+}} \text{ (Equação 38)}$$

Em que: E_o estima o valor do erro de omissão; X_{i+} é o somatório dos erros de omissão (linha); e X_{ii} é o valor da diagonal principal.

Já os erros de comissão são calculados por:

$$E_{co} = \frac{X_{+i} - X_{ii}}{X_{+i}} \text{ (Equação 39)}$$

Em que: E_{co} estima o valor do erro de comissão; X_{+i} é o somatório de erros de comissão (coluna); e X_{ii} é o valor da diagonal principal.

CAPÍTULO 3 - PROCESSAMENTO DIGITAL DE IMAGENS, SENSORIAMENTO REMOTO E GEOPROCESSAMENTO

Segundo Congalton e Green (2009) um erro de comissão ocorre quando uma área é incluída em uma categoria incorreta, e o erro de omissão ocorre quando a área é excluída da categoria a qual pertence, portanto todo erro no mapa é uma omissão da categoria correta e uma comissão para uma categoria incorreta.

Uma forma de obter a acuracidade de cada classe da imagem classificada é calcular a acuracidade do produtor e do usuário. Apesar da matriz de confusão ser um mecanismo de verificação da exatidão da classificação, é comum apresentar a acuracidade global e a acuracidade do produtor e/ou do usuário. Entretanto, somente o maior valor desses índices não representa a real acuracidade do mapa. Um exemplo é apresentado por Congalton e Green (2009) para demonstrar a necessidade de apresentar as três medidas de acuracidade.

Na matriz de confusão, apresentada na Figura 16, contém quatro áreas da cobertura e do uso da terra classificadas como Agricultura, enquanto que os dados de referência mostram que estas pertencem de fato à classe Pinus. Portanto, quatro áreas foram omitidas da classe Pinus e cometidas à classe Agricultura incorretamente. Para esclarecer esses erros de omissão e comissão, a matriz de confusão pode ser usada para calcular as medidas de acuracidade global, do produtor e do usuário.

		Dados de Referência				
Dados Classificados	Classes de Uso da Terra	A	P	VR	FS	Total da linha
	A	65	4	22	24	115
	P	6	81	5	8	100
	VR	0	11	85	19	115
	FS	4	7	3	90	104
	Total da Coluna	75	103	115	141	434

Acuracidade de Produtor

$$A = 65/75 = 87\%$$

$$P = 81/103 = 79\%$$

$$VR = 85/115 = 74\%$$

$$FS = 90/141 = 64\%$$

Legenda das Classes de Uso da Terra

A = Agricultura

P = Plantação de Pinus

VR = Vegetação rasteira

FS = Floresta com serapilheira

$$\text{Acuracidade Global} = (65+81+85+90) / 321/434 = 74\%$$

Acuracidade de Usuário

$$A = 65/115 = 57\%$$

$$P = 81/100 = 81\%$$

$$VR = 85/115 = 74\%$$

$$FS = 90/104 = 87\%$$

Figura 16 - Exemplo da aplicação dos avaliadores de acuracidade da classificação

Fonte: Adaptado de Congalton e Green (2009)

Estudando a matriz, é revelada uma acuracidade global (acuracidade do mapa) de 74%, enquanto que, se o interesse for saber a acuracidade da classe Agricultura, é obtida uma acuracidade do produtor de 87%, que é considerada boa. Se a análise se resumisse a esses dois

CAPÍTULO 3 - PROCESSAMENTO DIGITAL DE IMAGENS, SENSORIAMENTO REMOTO E GEOPROCESSAMENTO

valores, concluir-se-ia que esta classificação é semelhante à média global, que é mais que suficiente para a classe Agricultura.

Chegar a essa conclusão pode ser um erro muito grave. Um cálculo rápido da acurácia do usuário revela um valor de 57%. Em outras palavras, apesar de 87% das áreas com Agricultura serem corretamente identificadas como Agricultura, apenas 57% dessas áreas no mapa são realmente Agricultura na imagem de referência.

As medidas de exatidão global, exatidão do produtor e exatidão do usuário são apresentadas:

Exatidão Global

$$F_m = \frac{\sum X_i}{N} \times 100 \text{ (Equação 40)}$$

Exatidão do usuário

$$F_u = \frac{X_{ii}}{X_{i+}} \times 100 \text{ (Equação 41)}$$

Exatidão do produtor

$$F_p = \frac{X_{ii}}{X_{+i}} \times 100 \text{ (Equação 42)}$$

Em que: F_m é o valor da exatidão global; X_i o número de elementos na diagonal; e N o total de elementos amostrados.

A estimativa Kappa expressa a medida da diferença entre a concordância dos dados de referência e a classificação automática, e a probabilidade de concordância entre os dados de referência e a classificação aleatória. Conceitualmente, o índice Kappa pode ser definido como:

$$K = \frac{N \sum X_{ii} - \sum X_{i+} X_{+i}}{N^2 - \sum X_{i+} X_{+i}} \text{ (Equação 43)}$$

Em que: X_{ii} é a concordância observada; X_{i+} e X_{+i} são produtos das marginais; e N o total de elementos observados.

Landis e Koch (1977) apresentam uma tabela com valores representativos da classificação em relação ao índice Kappa.

Tabela 10 - Representatividade da classificação relacionada à estatística do índice Kappa

Índice Kappa	Concordância
0,00	Péssima
0,01 a 0,20	Ruim
0,21 a 0,40	Razoável
0,41 a 0,60	Boa
0,61 a 0,80	Muito Boa
0,81 a 1,00	Excelente

Fonte - Landis e Koch (1977)

CAPÍTULO 3 - PROCESSAMENTO DIGITAL DE IMAGENS, SENSORIAMENTO REMOTO E GEOPROCESSAMENTO

3.8. Classificadores automáticos de imagem de sensoriamento remoto

Na maioria dos classificadores automáticos de imagens, cada classe de uso da terra é caracterizada por uma função de decisão, que pode ser probabilística (método paramétrico) ou determinística (não paramétrico).

No método paramétrico, supõe-se que a forma geral da função densidade de probabilidade seja conhecida, a qual descreve o comportamento dos dados. Já no método não paramétrico, a função de densidade de probabilidade, associada aos dados, não é conhecida.

Nos classificadores paramétricos, os métodos mais utilizados em sensoriamento remoto são: Máxima Verossimilhança Gaussiana (MVG), que é um caso particular do classificador de Bayes; e os não-paramétricos são, por exemplo: as redes neurais, os sistemas Fuzzy, e os sistemas SVM (*Support Vector Machine*) (ANDREOLA, 2009).

Há uma variedade de *softwares* de processamento digital de imagens que podem ser utilizados para classificar imagens de sensores remotos. Estes podem ser adquiridos de forma comercial e gratuita. Os mais encontrados nos trabalhos acadêmicos são: ENVI, ERDAS IMAGINE e ER-Mapper, IDRISI, PCI Geomática, MultiSpec e eCognition Developer. Este último, por ter sido aplicado nesta pesquisa é apresentado com mais detalhes no texto que segue.

3.8.1. eCognition Developer

O *software* eCognition foi desenvolvido pela Companhia *Definiens*, fundada em 1994 pelo professor Gerd Binnig na Alemanha, que desenvolveu junto a sua equipe de pesquisadores a "Tecnologia de Cognição em Redes", do inglês *Definiens Cognition Network Technology*®. A tecnologia simula como a mente humana entende imagens, portanto é capaz de segmentar e classificar objetos complexos, percebendo as relações entre eles, bem como os seus contextos (DEFINIENS, 2015).

Para classificação de imagens de sensoriamento remoto, o *software* possibilita sua aplicação em dois módulos: um módulo de classificação simples, baseado em lógica *Fuzzy* e

no método do Vizinho Mais Próximo (*Nearest Neighbor*), denominado *Quick Map Mode*; e um módulo de classificação avançada, denominado *Rule Set Mode*, que disponibiliza diversos algoritmos de segmentação e classificação de imagens.

A principal estratégia do eCognition baseia-se na construção de uma rede hierárquica de objetos da imagem que permitam representar o conteúdo das informações em diferentes escalas simultaneamente. Neste contexto, são utilizados os critérios de homogeneidade para tomada de decisão sobre a união de regiões de interesse, tendo em vista as competências do analista da imagem.

Para criar regiões homogêneas pode ser utilizado o algoritmo de segmentação denominado multiresolução. Este algoritmo constrói um conjunto hierárquico de objetos primitivos, presentes na imagem em diferentes resoluções, e resulta em segmentos (conjunto de pixels) que, baseados em parâmetros espectrais (forma, escala, homogeneidade e cor), podem ser reagrupados em objetos maiores ou “super objetos” homogêneos quanto aos parâmetros estipulados (FORGHANI; CECHET; NADIMPALLI, 2016; KUX; RIBEIRO, 2009).

Diversos trabalhos foram desenvolvidos com o uso do *software* eCognition. Forghani, Cechet e Nadimpalli (2016) desenvolveram metodologia para derivar rugosidade da superfície do terreno a fim de gerar informações para simulações de risco de ventanias utilizando as imagens dos satélites MODIS, Landsat e IKONOS. Foi aplicada a classificação semiautomática em parte de uma imagem de Nova Gales do Sul, na Austrália, utilizando-se de segmentação multiresolução e do algoritmo Vizinho Mais Próximo. Como resultados obtiveram onze categorias de uso da terra com exatidão global de 79% para áreas urbanas e 93% para áreas rurais.

Mitri e Gitas (2016) aplicaram a classificação orientada a objeto para mapear áreas queimadas na ilha mediterrânea de Thasos usando imagem Landsat TM. Schwarz, Steinmeier e Waser (2016) realizaram estudo sobre a detecção de perdas por escoamento superficial em áreas de florestas alpinas pelos métodos da AOO e classificação baseada em pixel, utilizando dados dos satélites IKONOS e SPOT. Manakos, Schneider e Ammer (2016) realizaram comparação entre os métodos de classificação presentes no eCognition e o ISODATA com dados de campo.

CAPÍTULO 3 - PROCESSAMENTO DIGITAL DE IMAGENS, SENSORIAMENTO REMOTO E GEOPROCESSAMENTO

Os artigos científicos das diversas aplicações com o *software* eCognition podem ser encontradas na página eletrônica da empresa comercializadora do *software*, denominada TRIMBLE. (TIMBLE, 2016).

3.9. Sistemas de Informações Geográficas: uma ferramenta para classificação de imagens

Um sistema de informação geográfica (SIG), do inglês *Geographic Information System* (GIS), consiste em um conjunto formado por: computador (*hardware*), programas (*software*) e dados geográficos. O SIG é desenhado para capturar, armazenar, atualizar, manipular, analisar e exibir todas as formas de informações referenciadas geograficamente (ESRI, 2016).

Os SIG's são ferramentas de geoprocessamento multidisciplinares, e segundo Barbassa e Bielenki Júnior (2012) o geoprocessamento, quando aplicado a uma determinada temática, como recursos hídricos, está calcado em três pilares básicos: o conhecimento do tema, a cartografia e a informática. De fato, as funcionalidades dos SIG's são amplamente aplicadas nas áreas de recursos hídricos, pois não só permitem como facilitam as análises necessárias às atividades de gerenciamento dos recursos hídricos no âmbito da bacia hidrográfica.

A classificação supervisionada pode ser realizada com auxílio dos SIG's que incorporam os classificadores automáticos e semiautomáticos de imagens, sendo que os *softwares* disponíveis para o processamento digital das imagens, principalmente aqueles que realizam a classificação automática, são comerciais ou de livre acesso.

Alguns exemplos desses SIG's são: SAGA GIS, TerraView, SPRING, InterImage, ESRI (ArcView) e QGIS. Os dois últimos são apresentados com mais detalhes nos textos que seguem, uma vez que foram utilizados nesta pesquisa.

3.9.1. QGIS

O QGIS possui interface gráfica simples, está escrito em linguagem de programação C++³ e Python⁴, e é baseado em bibliotecas Qt4⁵. Possui código aberto (GNU - *General Public License*) e suporta formatos vetoriais, matriciais e de base de dados; permite procurar, editar e criar arquivos vetoriais e dados espaciais em Postgre SQL/PostGIS⁶. A última versão do *software* (2.14) foi lançada em fevereiro de 2015.

Alguns algoritmos de outros SIG's podem ser incorporados ao QGIS por meio da extensão *sextante*, disponível desde a versão 2.0. O módulo ou extensão *sextante* consiste em um conjunto de algoritmos que fornecem ferramentas robustas para análise espacial e tratamento da informação geográfica. Um exemplo da incorporação desses algoritmos é a integração do Orfeo Toolbox (OTB) ao QGIS.

O conjunto de algoritmos OTB consiste em um programa de sensoriamento remoto e processamento digital de imagens desenvolvido e mantido pelo CNES (Centro Nacional de Estudos Espaciais) da França, em consórcio com a COSMO-SkyMed, da Itália. O programa foi implementado em C++ e distribuído como uma biblioteca de código aberto (CeCILL), baseada em processamento de imagens médicas *Insight Toolkit* (ITK) e oferece funcionalidades específicas (ORFEO TOOLBOX, 2015).

No QGIS o programa funciona como um *plugin* que oferece 82 algoritmos para processamento digital de imagens, divididos em: 1 - calibração; 2 - extração de feições; 3 - geometria; 4 - filtros para imagens; 5 - manipulação de imagens; 6 - treinamento de imagens; 7 - fusão; 8 - segmentação; 9 - estéreo; e 10 - manipulação de dados vetoriais.

³ C++ é uma linguagem de programação popular, de nível médio multiparadigma e de uso geral.

⁴ Python é uma linguagem de programação de alto nível, interpretada, imperativa, orientada a objetos, e dinâmica.

⁵ Qt é um *framework* (arcabouço) multiplataforma. Com ele é possível desenvolver aplicativos e bibliotecas uma única vez e compilá-los para diversas plataformas sem que seja necessário alterar o código fonte.

⁶ *PostGIS* é uma extensão espacial gratuita e de código fonte livre. Sua construção é feita sobre um Sistema Gerenciador de Banco de Dados Objeto Relacional (SGBDOR) denominado PostgreSQL.

3.9.2. ArcGis

O ArcGIS possui um pacote de *softwares* destinados à elaboração e manipulação de informações vetoriais e matriciais, para uso e gerenciamento de bases temáticas. Os *softwares* desenvolvidos pela ESRI (*Environmental Systems Research Institute*) disponibilizam em um ambiente SIG diversas ferramentas de forma integrada. O Desktop ArcGIS divide-se nos seguintes aplicativos: ArcMap, ArcCatalog e ArcToolbox.

- ✓ O ArcMap é o módulo central que permite visualização e edição de dados gráficos e tabulares, consultas e análises espaciais e, geração de layouts de impressão;
- ✓ O ArcCatalog organiza e gerencia todos os dados do SIG. Possui ferramentas de busca, registro, pré-visualização, visualização de dados, inclusive via internet; geração e visualização de metadados; definição ou modificação de tabelas; e gerenciamento de dados;
- ✓ O ArcToolbox contém ferramentas de conversão de dados, exportação e importação de diversos formatos, e de conversão de projeções cartográficas. Uma extensão opcional é o módulo *Spatial Analyst*, que disponibiliza ferramentas de modelagem e análises de feições em arquivos matriciais, incluindo os algoritmos de classificação de imagens supervisionada e não supervisionada.

A ESRI também disponibiliza licenças opcionais tais como: o ArcView, o ArcEditor, o ArcInfo e o WorkStation e recentemente lançou a versão online do *software*.

3.10. Estudos relacionados à classificação de imagens de sensoriamento remoto

Albuquerque (2012) realizou a classificação supervisionada em uma imagem GeoEye, de setembro de 2010, de 16 bit de resolução radiométrica e 0,5 m de resolução espacial, com o algoritmo SVM presente no *software* ENVI, versão 4.8. O objetivo do trabalho foi de realizar a classificação automática da cobertura e do uso da terra no entorno da Usina do Lajeado (TO) e comparar a acuracidade do classificador com o tradicional método MaxVer. Como resultado, obteve índice Kappa e exatidão global de 84% e 86% para os dois classificadores.

CAPÍTULO 3 - PROCESSAMENTO DIGITAL DE IMAGENS, SENSORIAMENTO REMOTO E GEOPROCESSAMENTO

Rokni et al. (2014) testaram técnicas de fusão associadas à classificação de imagens Landsat para detectar mudanças nas águas superficiais do lago Urmia (nordeste do Irã). As técnicas de fusão aplicadas nas imagens Landsat-7 ETM+ do ano de 2000, com 15 m de resolução espacial, e Landsat-5 TM do ano 2010 com 30 m de resolução espacial foram: transformação IHS; Filtro Passa-Alta (*High Pass Filter* – HPF); Gram Schmidt (GS); e Wavelet-PC (Principal Components).

As imagens receberam pré-processamento no *software* ENVI 4.8, tais como: calibração radiométrica, correção atmosférica, mosaicagem, re-registro e reamostragem (alocação por vizinho mais próximo). Foram aplicadas as técnicas de fusão para analisar seu desempenho na união das imagens Landsat ETM + pancromática (2000) e Landsat TM multiespectral (2010), a fim de avaliar a capacidade de detecção das técnicas de fusão de bordas na imagem.

A técnica de fusão Gram Schmidt apresentou melhor desempenho avaliado por interpretação visual e nível de detecção de bordas. Esta foi utilizada no preparo da imagem para aplicação dos algoritmos de classificação, que foram: redes neurais artificiais (*Artificial Neural Network* - ANN), máquinas de vetores suporte (*Support Vector Machine* – SVM), e máxima verossimilhança (*Maximum Likelihood* - ML).

Na avaliação dos resultados foram destacados os classificadores ANN e SVM com os maiores índices Kappa e exatidão global, sendo estes de 91% (Kappa) e 99,9% (exatidão global), em ambos os classificadores. Já o classificador ML atingiu precisão de 89% para o índice Kappa e 99,1% de exatidão global. Portanto, os autores destacaram a aplicabilidade desta metodologia em estudos sobre as mudanças em águas superficiais e para monitoramento de inundações.

O *software* InterImage foi utilizado por Ribeiro, Fonseca e Kux (2011) com o objetivo de avaliar o desempenho das imagens do sensor WorldView-II no mapeamento da cobertura e do uso da terra em áreas urbanas e investigar suas potencialidade na discriminação de alvos urbanos. Os processamentos das imagens foram realizados utilizando os seguintes *softwares*: MatLab 7.9, para simulação das bandas espectrais do QuickBird-II através das bandas espectrais do WorldView-II; ENVI 4.7, para fusão e recorte das áreas-testes; PCI Geomática V10.3.1 para ortorretificação; e finalmente o InterIMAGE 0.95, para classificação da cobertura e do uso da terra.

CAPÍTULO 3 - PROCESSAMENTO DIGITAL DE IMAGENS, SENSORIAMENTO REMOTO E GEOPROCESSAMENTO

A classificação foi avaliada por meio da matriz de confusão e dos índices Kappa e Kappa-condicional. A partir da matriz de confusão foram calculadas as medidas de exatidão global, do usuário e do produtor. Como resultado, obtiveram-se valores de exatidão global e índice Kappa nas classificações com as imagens WorldView-II superiores aos valores obtidos com as imagens QuickBird simuladas, tornando viável a hipótese de que a melhor resolução da imagem (WorldView-II), pode facilitar a identificação de alvos urbanos e, conseqüentemente, aprimorar a classificação da cobertura e do uso da terra.

A imagem WorldView-II, com resolução espacial de 0,5 m, adquirida pela Universidade de São Paulo, gerou diversos trabalhos sobre a classificação da cobertura e do uso da terra das bacias hidrográficas do município de São Carlos – SP: Aprígio (2012), Decina (2012), Message (2013) e Martins e Brandão (2015). As classes de cobertura e de uso da terra definidas nos respectivos trabalhos são apresentadas na Figura 17.

Figura 17 - Classificação dos usos da terra em bacias hidrográficas do município de São Carlos – SP

4.0 METODOLOGIA DA PESQUISA

A metodologia desenvolvida nesta pesquisa baseia-se na classificação de imagens de satélites de diferentes resoluções espaciais e na construção de hidrogramas de cheia. A partir das áreas de cada classe de uso da terra nas imagens classificadas e dos valores de CN do modelo hidrológico NRCS, foram simulados hidrogramas para três eventos pluviométricos selecionados. Esses hidrogramas foram comparados aos respectivos hidrogramas observados. Desta forma, foi possível avaliar o efeito das diferentes resoluções espaciais das imagens e dos classificadores semiautomáticos nos hidrogramas de cheia simulados pelo modelo NRCS.

Os algoritmos classificadores utilizados foram: o *Support Vector Machine* (SVM), proveniente do conjunto de ferramentas Orfeo Toolbox e disponíveis no QGIS (versão 2.8), cuja licença é livre; o método “Máxima Verossimilhança” (MaxVer), proveniente do conjunto de ferramentas *Arc Toolbox* disponíveis no ArcGIS® (versão 10.1), cuja licença é comercial; e o algoritmo “Vizinho mais Próximo”, do inglês *Nearest Neighbor* (NN), proveniente do *software* eCognition Developer, cuja licença é comercial.

O objetivo da utilização de tais classificadores é avaliar seu desempenho em relação a acuracidade, facilidade de uso e o custo da licença dos *softwares*. Para isso, foram realizadas diversas análises com o intuito de avaliar as facilidades e dificuldades na aplicação dos respectivos algoritmos e dos recursos para avaliação da classificação, obtida por meio dos próprios *softwares*, denominada “matriz de confusão”. A partir desta avaliação foi possível realizar uma análise multicritério, a fim de apontar o desempenho dos classificadores e das imagens utilizadas nesta pesquisa.

A escolha das diferentes imagens de satélite (WorldView-II, RapidEye e Landsat-8) permitiu avaliar o impacto da resolução espacial nos hidrogramas de cheia. As três imagens processadas nos três classificadores geraram nove mapas da cobertura e do uso da terra, dos quais foram extraídas as áreas de cada classe de uso da terra. Essas informações foram utilizadas como dados de entrada no modelo hidrológico chuva-vazão NRCS para simular os hidrogramas de ESD.

O modelo foi construído por meio de planilhas no Microsoft Excel em etapas: i) atribuiu-se um valor de CN para cada classe de uso da terra, de acordo com USDA (1986); ii) calcularam-se os valores de precipitação efetiva para cada evento; iii) a partir do cálculo do tempo de concentração e do valor da área da bacia, construíram-se os hidrogramas unitários;

CAPÍTULO 4 - MÉTODO DE PESQUISA

iv) aplicou-se a técnica de convolução para as precipitações efetivas e obtiveram-se os hidrogramas simulados resultantes.

Para a construção dos hidrogramas foram utilizados três eventos chuva-vazão monitorados na bacia em estudo, com valores de precipitação total de 40 mm, 45, mm e 53 mm, considerados os maiores eventos nos anos de 2014 e 2015. Com os hidrogramas simulados, foi possível quantificar os volumes de ESD e as vazões de pico obtidas com base nas imagens classificadas e compará-los com as vazões observadas próximas ao exutório da bacia.

Os processos envolvidos e os detalhes de cada aplicação são apresentados nos tópicos deste capítulo, a saber:

- ✓ A apresentação da área de estudo;
- ✓ O monitoramento hidrológico;
- ✓ As características das imagens de satélite utilizadas;
- ✓ O pré-processamento das imagens no *software* Orfeo Monteverdi;
- ✓ A definição do processo de coleta de amostras;
- ✓ A classificação pelo método MaxVer e obtenção da matriz de confusão e das áreas no ArcGIS;
- ✓ A classificação pelo método SVM e obtenção da matriz de confusão no QGIS;
- ✓ A classificação por Análise Orientada a Objeto e obtenção da matriz de confusão no eCognition;
- ✓ O cálculo dos índices avaliadores da classificação;
- ✓ O processamento dos dados hidrológicos;
- ✓ Os hidrogramas simulados;
- ✓ A construção da análise multicritério TOPSIS.

4.1. Área de estudo

A área de estudo corresponde à bacia do Córrego do Mineirinho, que se localiza no município de São Carlos – SP, situado na região central do Estado de São Paulo, cerca de 240 km da capital do Estado. O município abrange uma área de 1.132 km², sendo que 67 km² (6%

da área total) é área predominantemente urbana e, dessa área, 33 km² são ocupados por 238.950 habitantes. O clima é o temperado de altitude, com verões chuvosos e invernos secos, sendo a temperatura média do mês mais quente superior a 22°C. A precipitação média anual é de 1.512 mm (PMSC, 2015).

A área total da bacia do Córrego do Mineirinho é de 5,85 km², com perímetro de 10,9 km e diferença entre as cotas da bacia de 95 m, sendo a maior cota situada ao nível de 874 m e a menor cota ao nível de 779 m. A rede de canais da bacia do Córrego do Mineirinho possui comprimento total de 5 km, sendo que o canal principal possui aproximadamente 4 km. A localização da bacia é apresentada na Figura 18.

Figura 18 - Localização da área de estudo
Fonte: Angelini Sobrinha et al (2014)

A bacia possui quatro nascentes localizadas no bairro residencial Santa Angelina: a nascente 1 encontra-se ao norte, em área urbanizada, e forma o canal principal; a nascente 2 possui regime intermitente e está localizada na área rural, a oeste; a nascente 3 está localizada dentro do campus 2 da USP também a oeste; e a nascente 4 está localizada em área urbana a leste da bacia. Os mapas, contendo a localização das nascentes e o Modelo Digital de Elevação (MDE) da bacia, são apresentados na Figura 19 e 20, respectivamente.

CAPÍTULO 4 - MÉTODO DE PESQUISA

Figura 19 - Bacia do Córrego do Mineirinho localizada em São Carlos – SP

Figura 20 - Modelo Digital de Elevação da bacia do Córrego do Mineirinho

4.2. Monitoramento hidrológico

Realizou-se o monitoramento da precipitação e da vazão na bacia do Córrego do Mineirinho. A precipitação foi registrada por meio de pluviômetros da marca *Hydrological Service* Modelo TB4, que apresentam resolução de 0,2 mm, com registro automático em *datalogger*. O aparelho é mantido em modo *stand by* até que a primeira basculada atinja esta

CAPÍTULO 4 - MÉTODO DE PESQUISA

resolução e passe a computar os registros. O equipamento utilizado é apresentado na Figura 21.

Figura 21 - Pluviôgrafo eletrônico com *datalogger*

As vazões foram medidas com auxílio de uma sonda ADCP - *Acoustic Doppler Current Profiler* - da marca *Sontek*, instalada no centro de uma galeria de concreto de seção regular situada próxima ao exutório da bacia (Figura 22 a). Para protegê-la de impactos, foi instalada uma grade a uma distância de um 1 m à montante do equipamento. Essa distância foi calculada de forma a não intervir no processo de medição (interferências no pulso acústico emitido) e nas condições de fluxo, evitando o acúmulo de sedimentos sobre a sonda (Figura 22 b).

A

B

Figura 22 - Medidor de vazão IQ Plus ADCP fixo (A) e sistema de proteção de impactos (B)

CAPÍTULO 4 - MÉTODO DE PESQUISA

Foram utilizados quatro pluviógrafos: três deles instalados dentro da bacia do Córrego do Mineirinho e o último próximo ao seu exutório. O mapa contendo a localização dos pluviógrafos e do medidor de vazão é apresentado na Figura 23.

Figura 23 - Rede de monitoramento hidrológico na bacia do Córrego do Mineirinho

Os pontos apresentados no mapa da Figura 23 referem-se aos seguintes pluviógrafos:

✓

EBSC: instalado nas dependências da Escola Municipal Bento da Silva César

CAPÍTULO 4 - MÉTODO DE PESQUISA

(-21,9910 S; -47,9280 W);

- ✓ Electrolux: instalado nas dependências da fábrica da Electrolux (-22,0240 S; -47,9070 W);
- ✓ PSSF: instalado nas dependências do Posto de Saúde da Família do Jardim Santa Felícia (-21,9990 S; -47,9195 W);
- ✓ EESC/USP II: instalado nas dependências do campus II da Escola de Engenharia de São Carlos, da Universidade de São Paulo (-21,9974 S; -47,9271 W).

4.3. Características das imagens de satélites utilizadas

Para avaliar o efeito das diferentes resoluções de imagens e classificadores nos hidrogramas de cheia simulado foram utilizadas as seguintes imagens:

- ✓ Uma imagem WorldView-II do ano de 2011, com resolução espacial de 0,5 m, comprada pela Universidade de São Paulo;
- ✓ Uma imagem RapidEye do ano de 2011, com resolução espacial de 5 m, disponibilizada pelo Ministério do Meio Ambiente (MMA);
- ✓ Uma imagem Landsat-8 do ano de 2013, com resolução espacial de 15 m, de livre acesso na internet.

A imagem WordView-II, datada de 02 de junho de 2011, contém dois arquivos: um com a banda pancromática (resolução espacial de 0,5 m) e outro com as bandas multiespectrais (oito bandas com resolução espacial de 2 m), e resolução radiométrica de 11 bits. As bandas multiespectrais da imagem WorldView-II são apresentadas na Tabela 11.

Tabela 11 - Bandas do satélite WorldView-II

Banda 1: Azul Costal (<i>Coastal Blue</i>);	Banda 5: Vermelha (<i>Red</i>)
Banda 2: Azul (<i>Blue</i>);	Banda 6: Vermelho limítrofe (<i>Red Edge</i>)
Banda 3: Verde (<i>Green</i>);	Banda 7: Infravermelho Próximo I (NIR I)
Banda 4: Amarela (<i>Yellow</i>);	Banda 8: Infravermelho Próximo II (NIR II)

A imagem RapidEye foi disponibilizada gratuitamente pelo MMA já pré-processada. A imagem é composta de uma cena que contém as cinco bandas espectrais (B1 - azul; B2 -

verde; B3 - vermelha; B4 - infravermelho; B5 - infravermelho próximo), obtida em formato geotiff com 12 bits de resolução radiométrica e 5 m de resolução espacial.

Com relação à data de aquisição da imagem, havia apenas duas opções para a região de interesse: uma datada de 14/11/2013 e outra de 15/09/2011; portanto, selecionou-se a imagem do ano de 2011 por sua maior semelhança quanto ao uso da terra das imagens Landsat-8 e WorldView-II.

A imagem Landsat-8, datada de 11/11/2013, foi obtida em formato geotiff com resolução radiométrica de 16 bits e resolução espacial de 30 m (MS) e de 15 m (PAN), sua projeção é UTM, Datum WGS 1984. Devido a sua projeção ao norte, a imagem foi reprojetaada às coordenadas do projeto. A licença para aquisição das imagens é pública e foi adquirida gratuitamente por meio de um cadastramento no *site* do *Earth Explorer*.

4.4. Pré-processamento das imagens no *software* Orfeo Monteverdi

O pré-processamento limitou-se à fusão das bandas pancromática e multiespectrais, com a finalidade de aumentar a resolução espacial das imagens e facilitar a identificação das classes na fase de treinamento dos classificadores. Esse processo não foi aplicado à imagem RapidEye, pois a mesma já continha pré-processamento.

Para reduzir o tempo de processamento nesse *software*, as imagens foram limitadas à área de estudo, por meio do corte da imagem com uma camada vetorial que contém a delimitação da bacia, processo simples realizado no QGIS. A camada vetorial do divisor de águas da bacia em estudo foi disponibilizada pelo Centro de Divulgação Científica e Cultural (CDCC) da USP de São Carlos-SP.

No Orfeo Monteverdi foram realizados os seguintes passos:

- ✓ Imagem WorldView-II: as imagens com as bandas MS e PAN foram importadas e processadas com o algoritmos: “sobreposição de sensores”, para deixá-las com as mesmas dimensões; e o algoritmo “fusão” (*Simple RCS Pan sharpening operation*), com objetivo de aumentar a resolução espacial. O resultado é uma imagem com pixels de 0,5 m de área.
- ✓ Imagem Landsat-8: as bandas 4, 3, 2 (MS) e 8 (PAN) foram importadas, fez-se a composição RGB e concatenarem-se as imagens. Foram processados os algoritmos “sobreposição de sensores” (PAN e MS) e “fusão” (*Simple RCS Pan sharpening operation*).

CAPÍTULO 4 - MÉTODO DE PESQUISA

O resultado é uma imagem com pixels de 15 m de área. As imagens pré-processadas são apresentadas na Figura 24.

WorldView-II

Resolução de 0,5m – Campus 2 da USP
(02/06/2011)

RapidEye

Resolução de 5m – Campus 2 da USP
(15/19/2011)

Figura 24 - Imagens de satélites pré-processadas no Orfeo Monteverdi

4.5. Definição do processo de coleta de amostras

Foram realizados testes a fim de analisar a interferência do processo de coleta de amostras de treinamento no resultado final da classificação da imagem, que é a matriz de confusão. Para esta análise, foram selecionados a imagem WorldView-II e os classificadores MaxVer e SVM. Foi coletado um conjunto de amostras para treinamento do classificador e outro conjunto para validação da classificação. Essas amostras foram combinadas de formas diferentes na realização dos testes.

As amostras foram criadas no ArcGis e, posteriormente, utilizadas no QGIS. Os testes realizados consistiram nos seguintes arranjos:

- ✓ 1º teste: as amostras do conjunto de treinamento foram aplicadas para a classificação e as amostras do conjunto de validação foram aplicadas para gerar a matriz de confusão;
- ✓ 2º teste: as amostras do conjunto de validação foram aplicadas para a classificação e as amostras do conjunto de treinamento foram aplicadas para gerar a matriz de confusão;
- ✓ 3º teste: as amostras dos conjuntos de treinamento e validação foram concatenadas e elaborou-se um arquivo único (*merge*). Por meio deste, foram criados dois novos arquivos com amostras selecionadas aleatoriamente para compor cada conjunto (treinamento e validação), com cautela para não selecionar as mesmas amostras nas fases dos diferentes processos.

CAPÍTULO 4 - MÉTODO DE PESQUISA

O resultado dessa análise subsidiou a escolha do processo para criação dos conjuntos de amostras utilizadas no treinamento dos classificadores e para validação da classificação nos *softwares* ArcGis e QGIS. Os resultados, representados pelos índices Kappa, apontaram baixa variação dos valores em cada teste, conforme Tabela 11.

Tabela 12 - Índice Kappa para classificação da imagem WorldView-II com diferentes processos de coleta de amostras de treinamento

Classificador	1º teste	2º teste	3º teste	Variação máxima
MaxVer	96,7%;	97,2%	96,1%	1,1%
SVM	98,9%	98,7%	98,8%.	0,2%

Após saber que o modo como é realizada a coleta de amostras na fase de treinamento do classificador não interfere no resultado final da classificação, optou-se pela adoção do primeiro arranjo (1º teste). Exemplos da coleta são apresentados na Figura 25, cujas amostras utilizadas para o treinamento aparecem na cor vermelha e para a validação na cor verde.

Figura 25 - Coleta de amostras das classes da cobertura e do uso da terra

4.6. Classificação das imagens

O processo metodológico do pré-processamento à classificação das imagens pelos *softwares* QGIS, ArcGis e eCognition é apresentado no fluxograma da Figura 26.

Figura 26 - Fluxograma do processo de classificação das imagens

De acordo com o fluxograma, observa-se que as imagens de satélite foram processadas previamente no *software* Orfeo Monteverdi, para que se realizasse a classificação semiautomática em cada classificador.

As imagens já processadas foram adicionadas ao ArcMap, no qual foram criadas camadas vetoriais (*shape*) contendo 25 amostras (polígonos) de cada classe de uso da terra, utilizadas para treinamento do classificador MaxVer. A imagem de maior resolução espacial (0,5m) permitiu a definição das classes de uso da terra e da categoria “sombra”. As imagens com menor resolução não permitiram a identificação desta categoria.

Foram coletadas um total de 200 amostras para a imagem WordView-II e 175 amostras para cada uma das imagens RapidEye e Landsat-8. As classes de uso da terra foram identificadas como:

- ✓ Uso residencial: dividido entre residências com telhado de barro e com telhado de metal. O uso industrial foi incluído nesta classe devido à baixa densidade de indústrias na área e por estas conterem o telhado de metal;
- ✓ Transporte: consistem em ruas, avenidas e estacionamentos pavimentados;
- ✓ Agricultura: plantação de cana-de-açúcar;
- ✓ Espaços abertos: divididos entre solos com vegetação rasteira (gramínea) e solo exposto;
- ✓ Matas: composta por vegetação arbórea natural e espécies de Pinus;
- ✓ Sombra: regiões escuras, devido às sombras de casas e árvores.

As terminologias das classes utilizadas nas legendas dos mapas de cobertura e do uso da terra, produtos das classificações, e aquelas utilizadas nas análises hidrológicas são apresentadas na Tabela 13.

Tabela 13 - Comparação entre as classes de uso da terra utilizadas na classificação e aquelas utilizadas nos cálculos hidrológicos

Classe de uso da terra		Descrição
Classificação semiautomática	Cálculos hidrológicos (USDA, 1986)	
Agricultura	Agricultura	Plantação de cana-de-açúcar
Espaço aberto	Vegetação rasteira	Vegetação rasteira caracterizada como gramínea
	Espaço aberto com solo exposto	Solo exposto e terra agricultável desprovido de vegetação
Floresta e sombra	Matas	Mata ciliar paludosa e plantação de Pinus
Transporte	Transporte	Ruas, avenidas e estacionamentos pavimentados
Uso residencial e sombra	Urbano	Comércios, residências e indústrias com telhado de barro e de metal

4.6.1 Classificação pelo método MaxVer e obtenção da matriz de confusão no ArcGis

Para realizar a classificação da cobertura e do uso da terra com o algoritmo MaxVer foi utilizada a extensão que contém as ferramentas de análise espacial (*Spatial Analyst Tools*) presente no ArcToolBox do ArcGis, seguido da função multivariada (*Multivariate*) e do

CAPÍTULO 4 - MÉTODO DE PESQUISA

algoritmo de criação de assinaturas (*Create Signatures*). Esse algoritmo transforma a camada vetorial, que contém o conjunto de amostras de treinamento, em um arquivo de assinatura espectral com extensão GSG (*ArcGIS Signature File*).

Após criar assinaturas, utilizou-se o algoritmo de classificação MaxVer (*Maximum Likelihood Classification*). Este solicita a imagem de satélite e o arquivo de assinatura espectral, em extensão GSG, e resulta na imagem classificada em formato geotiff. Este procedimento foi repetido para todas as imagens.

Com as imagens já classificadas foram utilizadas as camadas vetoriais, que contém o conjunto de amostras de validação, para produzir a matriz de confusão de cada imagem. As amostras de validação foram coletadas em locais diferentes e na mesma quantidade das amostras de treinamento.

O processo de validação no ArcGis consiste em combinar (*combine*) a tabela de atributos da imagem classificada com a camada vetorial contendo as amostras de validação. Para isso, é necessário transformar a camada vetorial em matriz (imagem) e articular (*Pivot*) a tabela de atributos combinada, permitindo que as informações das duas tabelas sejam utilizadas.

Na etapa de articulação (*Pivot*) das tabelas de atributos, uma janela é aberta para seleção dos conteúdos que formarão a matriz de confusão, sendo esses: i) no campo de entrada (*Input Field*) seleciona-se a coluna da tabela que contém os dados da classificação; ii) no campo de articulação (*Pivot Field*) seleciona-se a coluna que contém as amostras de treinamento; iii) no campo de valores (*Value Field*) seleciona-se a contagem de polígonos (*Count*). O resultado é um arquivo .dbf que pode ser convertido em .txt. O fluxograma do processo é apresentado na Figura 27.

Figura 27 - Processo de classificação de imagens e obtenção da matriz de confusão no ArcGIS

O resultado do processo é um arquivo de texto com a matriz de confusão. Este arquivo foi importado para o Excel para o cálculo dos índices avaliadores de cada imagem classificada.

A última etapa foi a extração das áreas de cada classe de uso da terra da imagem classificada, que é um dos principais dados de entrada do modelo hidrológico. Para isso, foi necessário converter a imagem classificada em camada vetorial, pois esta permite o acesso à tabela de atributos. Na conversão, utilizou-se o algoritmo (*Conversion Tools - Raster to Polygon*) presente no ArcToolBox. Dessa forma, é possível acessar a tabela de atributos que contém todos os polígonos criados na classificação e seus respectivos números de identificação.

Através do módulo *Statistic*, presente na tabela de atributos, é possível exportar os valores estatísticos dos polígonos, sendo eles: i) os valores totais de polígonos criados, ii) os valores mínimos, médios, máximos e de desvio padrão, e iii) o somatório referente ao atributo pesquisado (no caso, a área).

4.6.2. Classificação pelo método SVM e obtenção da matriz de confusão no QGIS

As camadas vetoriais com as amostras de treinamento e de validação, criadas no ArcGIS, foram unidas (*Merge*) para serem processadas no classificador do QGIS. Para comparar os resultados da classificação por diferentes algoritmos, é necessário utilizar os mesmos conjuntos de amostras. Tal método consiste em uma forma de análise dos classificadores independente.

A criação de uma única camada (treinamento+validação) é necessária, pois o classificador SVM (Orfeo ToolBox) utiliza apenas um arquivo de entrada para executar as seguintes rotinas: i) cálculo da média e do desvio padrão de cada faixa espectral das bandas da imagem (*Compute images second order statistics*); ii) treinamento do classificador (*TrainImages Classifier SVM*); iii) processamento da classificação da imagem (*Image Classification*).

Foram utilizados os seguintes dados na fase de treinamento: i) a imagem de satélite; ii) o arquivo contendo a estatística das bandas; iii) a razão entre a quantidade de amostras utilizadas para treinamento e validação (neste caso, 50%).

O resultado do processo consiste em três arquivos: i) imagem classificada; ii) matriz de confusão (extensão .csv); e iii) modelo utilizado (extensão .txt).

Após o processo de classificação, foram gerados mapas da cobertura e do uso da terra para cada imagem, bem como arquivos contendo as matrizes de confusão, os quais foram utilizados para os cálculos da exatidão da classificação. O fluxograma que representa o processo de classificação de imagem no Orfeo ToolBox, presente no QGIS, é apresentado na Figura 28.

Figura 28 - Processo de classificação de imagens no Orfeo ToolBox do QGIS

Para extrair as áreas de cada classe de uso da terra, foi necessário ativar um complemento (*Plugin*) denominado GroupStats, disponível no QGIS. Este complemento realiza cálculos estatísticos em camadas vetoriais, tais como: média, somatório (contagem de polígonos), máximo, mediana, mínimo, desvio padrão e variância.

Os passos seguidos para obtenção das áreas foram: i) no campo denominado **coluna**, foi selecionado o DN, referente ao número da classe; ii) no campo **valor** foi selecionada a variável “área” e a operação “somatório”; iii) ao clicar em “Calcular”, a janela esquerda da interface do programa é preenchida com os valores das áreas de cada classe em m². O programa é simples e intuitivo.

O GroupStats também dispõe de módulo de exportação, o qual possibilita salvar os dados em arquivo de extensão .csv e facilita a importação para o Excel. A interface do programa é apresentada na Figura 29.

Figura 29 - Interface do programa GroupStats presente no QGIS

4.6.3. Classificação por Análise Orientada a Objeto e obtenção da matriz de confusão no eCognition

A classificação de imagens no eCognition foi realizada no módulo QuickMap, que é caracterizado como uma versão simplificada do *software*. Este módulo possui três algoritmos básicos de segmentação: i) *Merge Option*; ii) *Multiresolution*; e iii) *Quadtree*; além de quatro algoritmos de classificação: i) *Nearest Neighbor* (NN); ii) *Optimal Box Classifier*; iii) *Clutterremoval*; e iv) *Brightness Threshold*. Para a classificação das imagens, foi utilizado o algoritmo multiresolução (*multiresolution*) e a classificação vizinho mais próximo (*nearest neighbor*), que foram os métodos mais encontrados nos trabalhos pesquisados.

O processo de classificação consiste em segmentar a imagem e criar um conjunto de regras de pertinência, para que o classificador execute sua função. Os parâmetros requeridos na segmentação influenciam na qualidade do produto final. Foram selecionados valores de 0,3 para forma e 0,7 para compacidade, e 15 para escala. O conjunto de regras de pertinência utilizado na imagem WorldView-II é apresentado na Figura 30.

Figura 30 - Fluxograma da regra Fuzzy para a classificação da imagem WorldView-II

Pelo fluxograma da Figura 30 observa-se que um objeto pode estar associado a várias classes, com diferentes graus de pertinência, sendo que estes são descritos numericamente pelos valores 0 (não pertence) e 1 (pertence). Para a definição de uma classe, considera-se o maior grau de pertinência.

Para exemplificar, no fluxograma da Figura 30, as amostras **Imagem** possuem valor 1, enquanto que as amostras **Não imagem** apresentam valor 0, sendo assim descartadas do processo. Este processo de decisão permanece até que se tenha atribuído valor a todas as classes presentes na imagem. O conjunto de regras de pertinência utilizado nas imagens RapidEye e Landsat-8 é apresentado na Figura 31.

Figura 31 - Fluxograma da regra Fuzzy para a classificação das imagens RapidEye e Landsat-8

O *software* possui um módulo para visualizar e exportar os resultados. A matriz de confusão elaborada pelo programa pode ser visualizada pelo *menu* "ferramentas", seguido de "avaliação da acuracidade" (*Tools - Accuracy Assessment*). Para isso, seleciona-se o tipo de estatística a ser visualizada, no caso a matriz de confusão baseada nas amostras, e as classes de interesse, apresentadas nas Figuras 30 e 31 na cor amarela.

Para exportar os resultados, é necessário acessar o *menu Export*, escolher o tipo de estatística, as classes de uso da terra e as funções que serão exportadas, tais como: as feições dos objetos, as variáveis das feições, os metadados, as feições relacionadas às classes, entre outras funções disponíveis. Os formatos exportados são o .csv e o .txt.

Portanto, foram importadas as matrizes de confusão das imagens classificadas para uma planilha do Excel e calculados os índices de avaliação da classificação. A imagem classificada em formato vetorial foi adicionada ao ArcGIS para impressão dos mapas da cobertura e do uso da terra e para o cálculo das áreas de cada classe.

4.6.4. Classificação manual

A imagem WorldView-II da bacia do Córrego do Mineirinho foi classificada de forma manual por Martins e Brandão (2015). Os valores das áreas de cada classe de uso da

terra obtidas neste trabalho foram utilizados para gerar o hidrograma de cheia simulado pelo modelo NRCS. Este hidrograma foi comparado ao hidrograma observado na bacia e utilizado como referência para avaliar as classificações semiautomáticas.

Para gerar o hidrograma observado foi utilizado o evento chuva-vazão menos complexo, ou seja, aquele que possui apenas um pico, pois os modelos utilizados (HU e NRCS) são bem representados por eventos menos complexos.

O objetivo desta simulação foi de comparar os resultados da classificação manual, que demanda mais tempo de processamento, com as classificações semiautomáticas da mesma imagem. O resultado dessa simulação é apresentado no capítulo 5 e discutido nos itens 5.1.1 ao 5.1.10.

4.7. Cálculo de índices avaliadores da classificação de imagens

As matrizes de confusão, em número de nove e referentes à combinação de três imagens com três classificadores, foram exportadas para o Excel para o cálculo dos índices avaliadores da classificação, sendo esses: Índice Kappa, Exatidão Global, Acuracidade do Produtor e Acuracidade do Usuário. Para isso, foram aplicadas às equações propostas por Congalton e Green (2009), apresentadas no item 3.7 do trabalho.

4.8. Processamento dos dados hidrológicos

Os dados dos equipamentos presentes na rede de monitoramento hidrológico foram armazenados em nuvem, sistema *on line* de armazenamento de dados. Os dados de precipitação, em formato de texto (.txt), foram organizados e resultaram em arquivos que contêm: i) as precipitações discretizadas em 2 minutos, para o período de 30/01/2013 a 15/07/2015; ii) arquivos de resumo de eventos com 511 eventos de duração superior a 4 horas e 61 eventos com precipitação acumulada maior ou igual a 10 mm; e iii) arquivo das precipitações relacionadas às condições antecedentes de umidade do solo, avaliada em escala temporal diária, de acordo com o método NRCS-CN.

CAPÍTULO 4 - MÉTODO DE PESQUISA

A partir desses arquivos, foram selecionados os três eventos com os maiores valores de precipitação total. Esses dados foram adicionados ao Excel e calculados os valores médios ponderados de precipitação pelo método de Thiessen. Este método foi aplicado em concordância com Tucci (2005, p. 330), que argumenta ser este o método mais utilizado quando comparado ao método das isoietas, devido à sua maior simplicidade. Os dados referentes às precipitações utilizadas são apresentados na Tabela 14.

Tabela 14 - Dados dos eventos de precipitação utilizados

Evento	Data	Total Precipitado (mm)	Duração do evento (horas)	Intensidade média (mm/h)	Volume precipitado (m ³)
Evento 1	07/11/2014	45,13	3,10	14,56	264.030
Evento 2	17/02/2015	52,53	4,00	13,13	307.300
Evento 3	25/02/2015	39,87	0,93	42,71	233.222

Os dados de vazão foram adicionados em planilha Excel e tabulados para o mesmo período de precipitação. Tais dados consistem em valores das vazões medidas próximas ao exutório da bacia e discretizadas em 2 minutos. Com esses hidrogramas foram obtidos os valores de: vazão de pico, tempo de pico, tempo de base, volume de ESD. Além disso, foram verificadas às condições de umidade antecedente do solo, conforme Tabela 15. Os hietogramas e hidrogramas resultantes são apresentados na Figura 32.

Tabela 15 - Dados dos eventos de vazão utilizados

Evento	Vazão de Pico (m ³ /s)	Tempo de Pico (minutos)	Tempo de base (minutos)	Volume ESD (m ³)	Situação de umidade do solo
Evento 1	5,74	52	402	42.511	II
Evento 2	7,12	370	940	68.641	I
Evento 3	12,46	64	234	49.925	III

Figura 32 - Eventos chuva-vazão utilizados na pesquisa

4.9. Hidrogramas simulados

As três imagens, em conjunto com os três classificadores semiautomáticos, resultaram em 9 mapas da cobertura e do uso da terra que, aplicados aos três hidrogramas observados, geraram 27 hidrogramas simulados pelo modelo NRCS-CN, conforme detalhado:

1) Atribuição dos valores de CN para cada classe de uso da terra, de acordo com as tabelas do United States Department of Agriculture (USDA, 1986; 2004), aplicadas aos solos do tipo hidrológico B (uniforme na bacia), conforme Tabela 16.

Tabela 16 - *Curve Number* aplicados

Classe de Uso da terra	CN	Descrição USDA (1986; 2004)
Agricultura	61	Cultivo de cana de açúcar em fileira com cobertura completa
Vegetação rasteira	61	Espaços abertos em boas condições com cobertura superior a 75% de gramínea
Matas	55	Matas em boas condições protegidas da pastagem com serrapilheira cobrindo o solo
Espaço aberto com solo exposto	79	Espaços abertos em condições ruins com cobertura inferior a 50% de gramínea
Transporte	98	Áreas impermeáveis
Urbano	85	Distrito residencial de acordo com o tamanho do lote: lotes urbanos com aprox. 500 m ²

Fonte: Tabela 2-2a para os espaços abertos, transporte e uso urbano; e tabela 2-2c para a floresta (USDA, 1986). Tabela 9-4 para plantio de cana de açúcar (USDA, 2004).

2) Cálculo dos valores de abstração inicial (I_a), de retenção potencial do solo (S), de chuva excedente (ESD) e de seus respectivos volumes para cada classe de uso da terra, pelo modelo NRCS. Além dos valores de CN, estes cálculos consideram a área e cada classe de uso da terra, que é a principal relação entre as classificações e o modelo hidrológico.

3) Cálculo das precipitações efetivas para cada classe de uso da terra.

4) Cálculo do tempo de concentração (T_c) da bacia pela equação apresentada por George Ribeiro (1961). Esta equação foi selecionada por melhor representar o T_c medido na bacia.

5) Construção dos HUS para cada simulação com duração da chuva unitária de dois minutos.

6) Aprimoramento do formato do HUS pelo *software* Maple. Este *software* é um sistema de computação algébrica, numérica e gráfica, desenhado para uso profissional na resolução de problemas que exigem métodos matemáticos.

7) Multiplicação dos valores de precipitação efetiva pelo HUS para gerar as vazões de ESD por processo de convolução. Este processo consiste na aplicação dos princípios da proporcionalidade e da sobreposição, que possibilita calcular o hidrograma resultante a partir de um HUS.

8) Obtenção dos hidrogramas de ESD para cada simulação.

4.10. Análise multicritério

Os resultados das classificações da cobertura e do uso da terra e dos hidrogramas foram analisados por meio da matriz multicritério TOPSIS. Nesta matriz, são relacionados os critérios a serem avaliados e atribuídos pesos de acordo com seu grau de importância. Em seguida, elaboradas as matrizes **de decisão** (de acordo com os pesos atribuídos), **normalizada** e **ponderada**. Foram determinadas as soluções ideais positivas e negativas e calcularam-se as distâncias que separam cada alternativa da positiva ideal, assim como da negativa ideal e, por último, calcularam-se as proximidades relativas de cada alternativa à solução ideal (melhor desempenho). A proximidade relativa da solução ideal à alternativa resulta na alternativa com melhor desempenho em relação aos critérios envolvidos.

A análise TOPSIS foi aplicada para dois conjuntos de quatro critérios: um conjunto para avaliar o desempenho dos classificadores semiautomáticos de imagens e outro a fim de avaliar a influência da qualidade das imagens de satélite nos hidrogramas de ESD. O peso atribuído ao critério foi determinado de acordo com a Tabela 17, conforme sua importância em relação aos demais critérios.

Tabela 17 - Tabela de importância utilizada para atribuição dos pesos aos critérios e as alternativas

Importância das alternativas	Peso
Não importa	0
Pouco importa	3
Importância média	5
Muito importante	7
Absolutamente importante	9

O fluxograma dos critérios envolvidos na análise dos classificadores é apresentado na Figura 33.

Figura 33 - Critérios utilizados na análise TOPSIS para avaliar os classificadores de imagens

Os critérios avaliados na análise das imagens de satélites são apresentados no fluxograma da Figura 34.

Figura 34 - Critérios utilizados na análise TOPSIS para avaliar as imagens de satélite

Após a construção das matrizes correspondentes à metodologia TOPSIS foram geradas as pontuações de cada alternativa analisada, sendo a maior pontuação atribuída à alternativa que teve melhor desempenho em relação às outras.

5.0 RESULTADOS E DISCUSSÃO

Neste capítulo são apresentados: os mapas da cobertura e do uso da terra resultantes dos classificadores MaxVer, SVM e NN e suas respectivas matrizes de confusão; os valores das áreas de cada classe de uso da terra e; os valores de acuracidade dos classificadores.

Os mapas da cobertura e do uso da terra, gerados por cada conjunto classificador-imagem, foram impressos no ArcGIS para a padronização de suas cores, em escala 1:15.000. Isto foi necessário porque o *software* eCognition não dispõe de módulo de impressão de mapas e o QGIS, apesar de apresentar um módulo para este fim, não se encontra bem desenvolvido na versão utilizada.

Para avaliar o ESD, a partir das classificações das imagens, foi utilizado o hietograma e o hidrograma observado no evento 3 (maior intensidade de precipitação) e comparado com os hidrogramas simulados. Além disso, foram simulados hidrogramas para cada classe de uso da terra de cada conjunto classificador-imagem.

Na etapa seguinte, são apresentados os gráficos dos hidrogramas simulados para cada classificador com as três imagens utilizadas.

Por fim, é realizada a análise dos hidrogramas em decorrência de cada conjunto classificador-imagem, a fim de responder as seguintes questões:

- 1 - Qual conjunto classificador-imagem obteve maior índice Kappa e menor número de confusões entre as classes (acuracidade)?
- 2 - Qual a importância da resolução espacial da imagem de satélite no processo de classificação para estudos hidrológicos em bacias urbanas e semiurbanas?
- 3 - Qual classificador se mostrou intuitivo e de fácil aplicação?
- 4 - Qual classificador e imagem obtiveram melhor desempenho?
- 5 - Quais são as vantagens e desvantagens de cada classificador?
- 6 - Qual conjunto classificador-imagem obteve o melhor índice de avaliação (coeficiente de Nash Sutcliffe) em relação às vazões observadas?

O conjunto de perguntas foi utilizado para a análise multicritério TOPSIS, que ordenou os classificadores e as imagens de satélites para apontar o melhor classificador e a melhor imagem em relação aos critérios adotados.

5.1. Classificadores de imagens

Com relação ao índice Kappa, os classificadores tiveram representatividade que variaram de boa a excelente, de acordo com as ponderações estabelecidas por Landis e Koch (1977). De acordo com os autores, os índices variam de: excelente (0,81 a 1,00); muito boa (0,61 a 0,80); boa (0,41 a 0,60); razoável (0,21 a 0,40); ruim (0,01 a 0,20); e péssima (0). Os índices avaliadores obtidos nas classificações são apresentados na Tabela 18.

Tabela 18 - Índices de exatidão obtidos nas matrizes de confusão para os classificadores de imagens

Matrizes de confusão	Índice Kappa	Exatidão Global	Índice Kappa	Exatidão Global	Índice Kappa	Exatidão Global
	WorldView-II		RapidEye		Landsat-8	
MaxVer	0,97	0,98	0,93	0,95	0,89	0,91
NN	0,93	0,94	0,58	0,64	0,70	0,75
SVM	0,99	0,99	0,98	0,98	0,83	0,86

De acordo com o Índice Kappa, que expressa a concordância dos dados de referência e a classificação semiautomática, o classificador que demonstrou maior desempenho, foi o SVM para as imagens WorldView-II (0,99) e RapidEye (0,98), seguido do classificador MaxVer para as imagens WorldView-II (0,97) e RapidEye (0,93).

O classificador NN apresentou melhor desempenho para a imagem WorldView-II (0,93). Para a imagem Landsat-8, a concordância foi de 70% e com a imagem RapidEye de 58%. A imagem Landsat-8 em conjunto com o classificador MaxVer apresentou desempenho de 89% e com o classificador SVM de 83%. O desempenho dos classificadores é apresentado na Figura 35.

Figura 35 - Desempenho dos classificadores de imagens

5.1.1. Classificação manual com imagem WorldView-II

A simulação hidrológica realizada com as áreas obtidas na classificação manual, de Martins e Brandão (2015), foi avaliada por meio do coeficiente de NS como muito boa (NS de 0,92). O coeficiente NS, utilizado para avaliar os picos de vazão, classifica a eficiência da calibração da seguinte forma: muito boa ($0,75 < NS < 1,00$); boa ($0,65 < NS < 0,75$); satisfatória ($0,50 < NS < 0,65$); e insatisfatória ($NS < 0,50$).

Os valores de áreas obtidos por Martins e Brandão (2015) e os resultados das vazões calculadas para cada classe nesta simulação são apresentados na Tabela 19.

Tabela 19 - Contribuição das vazões por classes de uso da terra na classificação manual da imagem WorldView-II

Classes de Uso da Terra	Vazão de pico (m ³ /s)	Contribuição (%)	Área de drenagem (km ²)	Contribuição (%)
Urbano	6,0	46,9	1,79	30,6
Vegetação rasteira	0,1	0,8	1,50	25,6
Floresta	0,0	0,0	1,02	17,4
Agricultura	0,1	0,8	0,59	10,1
Solo exposto	0,5	3,9	0,24	4,10
Transporte	6,1	47,7	0,71	12,1
Exutório	12,8	100	5,85	100,00

A análise desta simulação possui elevada importância para os resultados das classificações semiautomáticas por consistirem em resultados passíveis de comparação. Assim, os resultados da classificação manual foram considerados como a verdade de campo e serviram como base de comparação para a análise dos resultados das demais classificações.

A classificação manual foi realizada em imagem de alta resolução e é capaz de representar adequadamente os usos da terra presentes na bacia. Já a classificação semiautomática pode conter erros e a análise desses erros é fundamental para se obter uma classificação confiável.

A análise da contribuição na vazão de pico das classes de uso da terra é realizada para todas as classificações semiautomáticas e os valores foram comparados com os valores obtidos na classificação manual (referência).

A primeira análise é realizada para as vazões de pico entre os valores simulados e observados. A vazão de pico simulada de $12,8 \text{ m}^3/\text{s}$ comparada à vazão de pico observada de $12,5 \text{ m}^3/\text{s}$ foi representada por um coeficiente NS de 0,92, considerado muito bom. Os hidrogramas de cheia gerados para cada classe de uso da terra na simulação realizada a partir da classificação manual e do modelo NRCS são apresentados na Figura 36.

Figura 36 - Hidrogramas de ESD para classes de uso da terra definidas a partir de classificação manual

A boa representatividade dos dados de vazão de pico observados e simulados, com classificação manual, forneceu subsídio às análises dos resultados das classificações semiautomáticas.

As classes que mais contribuíram para gerar escoamento superficial nesta simulação foram: urbana (46,9%), transporte (47,7%) e solo exposto (3,9%), responsáveis por 98,5% da vazão total.

Sabendo-se que as classes que mais geram escoamento são as áreas para uso urbano, solo exposto e transporte, a discussão dos resultados das classificações semiautomáticas se volta para os erros de classificação referentes às confusões entre essas classes. Já as confusões entre as classes vegetadas não foram relevantes para os eventos simulados, devido à sua baixa contribuição para a vazão de pico, conforme apresentado na Tabela 19.

5.1.2. Classificador MaxVer com imagem WorldView-II

Utilizando-se das ferramentas do Spatial Analyst, presente no ArcToolbox, foi gerado o mapa da cobertura e do uso da terra e a matriz de confusão da imagem classificada da bacia do Córrego do Mineirinho.

As classes de uso da terra apresentadas no mapa são aquelas encontradas na imagem no processo de classificação. Dessa forma, a imagem WorldView-II contém 8 classes, incluindo a categoria “sombra”. Para a análise hidrológica foram consideradas apenas 6 classes, conforme informado na metodologia deste trabalho.

O mapa da cobertura e do uso da terra é apresentado na Figura 37 juntamente com a imagem original utilizada na classificação, possibilitando a comparação entre as imagens.

Figura 37 - (A) Mapa da cobertura e do uso da terra gerado pelo classificador MaxVer do ArcGis e (B) imagem WorldView-II com resolução espacial de 0,5 metros

Nota-se, pelo mapa da imagem classificada, a boa representação das classes existentes na imagem WorldView-II. Para verificar a exatidão do classificador foi gerada a matriz de confusão apresentada na Tabela 20.

Na primeira coluna da matriz de confusão estão os nomes das classes de uso da terra, sendo elas: 1) agricultura; 2) vegetação rasteira (gramínea); 3) floresta; 4) solo exposto; 5) transporte; 6) uso urbano com telhado de barro; 7) uso urbano com telhado de metal; e 8) categoria sombra.

Nas colunas denominadas “imagem classificada” estão os números de pixels classificados, sendo que na diagonal principal estão os pixels classificados corretamente. Já na parte inferior da matriz são apresentados os valores da acuracidade do produtor (AP), da acuracidade do usuário (AU), do Índice Kappa e da exatidão global. O zero implica que não há erro de classificação.

Tabela 20 - Matriz de confusão relacionada à imagem WorldView-II e a imagem classificada

WorldView II	Imagem Classificada								Σlinha
	Agricultura	Vegetação rasteira	Floresta	Solo Exposto	Transporte	Telha de barro	Telha de metal	Sombra	
Agricultura	143353	929	20	0	0	0	0	0	144302
Vegetação rasteira	3045	64145	2	106	0	0	0	0	67298
Floresta	685	24	2008	0	0	0	0	8	2725
Solo Exposto	0	0	0	45093	0	0	0	0	45093
Transporte	0	0	0	0	8994	0	0	5	8999
Telha de barro	0	14	0	1192	27	2578	0	0	3811
Telha de metal	0	0	0	0	20	0	7609	23	7652
Sombra	0	0	0	0	0	0	0	3817	3817
Σcoluna	147083	65112	2030	46391	9041	2578	7609	3853	283697
AP	97,5	98,5	98,9	97,2	99,5	100,0	100,0	99,1	
AU	99,3	95,3	73,7	100,0	99,9	67,6	99,4	100,0	
Índice Kappa		0,97		Exatidão Global		0,98			

As maiores confusões entre as classes ocorreram entre as superfícies com vegetação (vegetação rasteira, floresta e agricultura) e entre a classe telhado de barro e solo exposto. As confusões entre o uso urbano (telhados de barro) e o solo exposto significam que, apesar de 100% (AP) das áreas com telhados de barro serem corretamente identificadas como tal, apenas 67,6% (AU) dessa área contém de fato uso urbano com telhados de barro.

O mesmo ocorre entre as classes vegetadas, entretanto observa-se na Tabela 21 que a contribuição dessas áreas (máximo 1%) não foi significativa para a geração de ESD. As

classes que mais contribuíram foram: urbana, que contém parte dos telhados de barro confundidos com solo exposto; e transporte, que teve pouca confusão. A contribuição de cada classe de uso da terra para a vazão total simulada para o evento 3 é apresentada na Tabela 21.

Tabela 21 - Contribuição das vazões por classes de uso da terra na classificação MaxVer e imagem WorldView-II

Classes de Uso da Terra	Vazão de pico (m^3/s)	Contribuição (%)	Área de drenagem (km^2)	Contribuição (%)
Urbano	6,4	61,5	1,91	34,5
Vegetação rasteira	0,1	1,0	1,30	23,5
Floresta	0,0	0,0	1,02	18,4
Agricultura	0,1	1,0	0,56	10,1
Solo exposto	0,8	7,7	0,39	7,10
Transporte	3,0	28,8	0,35	6,30
Exutório	10,4	100	5,53	100,00

A vazão de pico do solo exposto de $0,8 \text{ m}^3/\text{s}$, $0,3 \text{ m}^3/\text{s}$ acima do valor encontrado na classificação manual ($0,5 \text{ m}^3/\text{s}$), se deve às confusões entre esta classe e os telhados de barro no uso urbano. A classe transporte foi confundida com os telhados de barro e de metal e sua área foi reduzida em 50,7%, em relação à classificação manual. Esta confusão resultou na redução do valor da vazão de pico (50,8%) da classe transporte.

A diferença entre esta simulação e a classificação manual está nos valores de área das classes urbana e solo exposto que foram superestimados e subestimado na classe transporte. Os hidrogramas de ESD de cada classe de uso da terra, assim como o hidrograma resultante simulado (obtido pelo modelo NRCS) e observado no evento 3 podem ser visualizados na Figura 38.

Figura 38 - Hidrogramas de ESD das classes de uso da terra no exutório da bacia para o evento 3

Apesar das confusões entre classes, o coeficiente NS (0,87) demonstrou relação considerada muito boa entre os dados simulados e observados. Tal resultado implica dizer que uma classificação semiautomática utilizada em estudos de drenagem urbana pode ser aplicada com alto grau de confiabilidade e com redução do tempo de trabalho, pois uma classificação manual representativa demanda tempo e recursos humanos e financeiros que nem sempre o usuário dispõe.

5.1.3 Classificação MaxVer com imagem RapidEye

As classes de uso da terra encontradas na imagem RapidEye são as mesmas da imagem anterior, com exceção da categoria “sombra”, que não foi identificada na imagem. O

resultado da classificação MaxVer é apresentado na Figura 39 e a matriz de confusão na Tabela 22.

Figura 39 - (A) Mapa da cobertura e do uso da terra gerado pelo classificador MaxVer do ArcGis e (B) imagem RapidEye com resolução espacial de 5 metros

Tabela 22 - Matriz de confusão relacionada à imagem RapidEye e a imagem classificada

Imagem RapidEye	Imagem Classificada							Σ linha
	Agricultura	Vegetação rasteira	Floresta	Solo Exposto	Transporte	Telha de barro	Telha de metal	
Agricultura	1066	64	0	0	0	0	0	1130
Vegetação rasteira	5	449	1	17	0	0	0	472
Floresta	0	0	260	0	0	0	0	260
Solo Exposto	1	0	0	351	1	3	0	356
Transporte	0	0	0	0	37	0	0	37
Telha de barro	0	0	0	32	0	31	0	63
Telha de metal	0	0	0	0	0	0	73	73
Σ coluna	1072	513	261	400	38	34	73	2391
AP	99,4	87,5	99,6	87,8	97,4	91,2	100,0	
AU	94,3	95,1	100,0	98,6	100,0	49,2	100,0	
Índice Kappa		0,93		Exatidão Global		0,95		

As maiores confusões ocorreram entre as classes: agricultura e vegetação rasteira; solo exposto e vegetação rasteira; e o solo exposto com os telhados de barro. Esta última é representada pela acuracidade do usuário que demonstrou que dos 91,2% das amostras classificadas como “telhados de barro”, apenas 49,2% são realmente pertencentes a esta classe.

As classes vegetadas pouco contribuíram para a geração de ESD, conforme os resultados da Tabela 23.

Tabela 23 - Contribuição das vazões das classes de uso da terra na classificação MaxVer e imagem RapidEye

Classes de Uso da Terra	Vazão de pico		Área de drenagem	
	(m ³ /s)	Contribuição (%)	(km ²)	Contribuição (%)
Urbano	3,0	22,6	0,90	15,5
Vegetação rasteira	0,2	1,5	1,67	28,7
Floresta	0,0	0,0	0,61	10,5
Agricultura	0,1	0,8	0,63	10,8
Solo exposto	2,2	16,5	1,09	18,8
Transporte	7,8	58,6	0,91	15,7
Exutório	13,3	100	5,81	100,00

As confusões entre a classe urbana e as demais classes resultaram em redução da vazão de pico de 50% do uso urbano e no aumento da vazão da classe solo exposto de 340% em relação à classificação manual. Na classe transporte houve aumento de 28% na vazão de pico. Os hidrogramas de ESD de cada classe de uso da terra, assim como o hidrograma resultante simulado (obtido pelo modelo NRCS) e observado no evento são apresentados na Figura 40.

CAPÍTULO 5 - RESULTADOS

Figura 40 - Efeito dos hidrogramas de ESD das classes de uso da terra no exutório da bacia para o evento 3

O Índice Kappa obtido com a imagem RapidEye (0,93) foi menor do que o da imagem WorldView-II (0,97), entretanto o coeficiente NS, de 0,91 nesta simulação, foi maior do que o simulado com a imagem WorldView-II (0,87), sugerindo que, para essa análise hidrológica, a resolução da imagem não se demonstrou importante.

5.1.4. Classificador MaxVer com imagem Landsat-8

Os resultados da classificação MaxVer com a imagem Landsat-8 são apresentados na Figura 41 e a matriz de confusão é apresentada na Tabela 24.

Figura 41 - (A) Mapa da cobertura e do uso da terra gerado pelo classificador MaxVer do ArcGis e (B) imagem Landsat-8 com resolução espacial de 15 metros

Tabela 24 - Matriz de confusão relacionada à imagem Landsat-8 e a imagem classificada

Imagem Landsat-8	Imagem Classificada							Σlinha
	Agricultura	Vegetação rasteira	Floresta	Solo Exposto	Transporte	Telha de barro	Telha de metal	
Agricultura	97	5	0	0	0	0	0	102
Vegetação rasteira	14	31	0	3	0	0	0	48
Floresta	0	0	60	0	0	0	0	60
Solo Exposto	0	5	0	26	2	1	0	34
Transporte	0	0	0	1	28	0	0	29
Telha de barro	0	0	0	0	0	33	0	33
Telha de metal	0	0	0	0	0	0	26	26
Σcoluna	111	41	60	30	30	34	26	332
AP	87,4	75,6	100,0	86,7	93,3	97,1	100,0	
AU	95,1	64,6	100,0	76,5	96,6	100,0	100,0	
Índice Kappa		0,89		Exatidão Global		0,91		

Nessa classificação, as confusões ocorreram entre as classes agricultura, vegetação rasteira e solo exposto. O solo exposto, por sua vez, foi confundido com o transporte e telhados de barro. Entretanto, apesar da menor resolução da imagem, observa-se um valor de Índice Kappa considerado excelente, e as maiores diferenças entre as acuracidades do produtor e do usuário foram de 13% para o solo exposto e 17% para as áreas com vegetação rasteira. Os valores de vazão simulados para cada classe de uso da terra são apresentados na Tabela 25.

Tabela 25 - Contribuição das vazões das classes de uso da terra na classificação MaxVer e imagem Landsat-8

Classes de Uso da Terra	Vazão de pico	Área de drenagem		
	(m ³ /s)	Contribuição (%)	(km ²)	Contribuição (%)
Urbano	6,8	42,0	2,00	29,1
Vegetação rasteira	0,1	0,6	0,65	9,4
Floresta	0,0	0,0	0,50	7,3
Agricultura	0,1	0,6	1,18	17,2
Solo exposto	4,0	24,7	1,94	28,2
Transporte	5,2	32,1	0,61	8,9
Exutório	16,2	100,0	6,88	100,00

As confusões entre o solo exposto com a vegetação rasteira e a agricultura (ambos com CN igual a 61) superestimaram o valor da área de solos expostos, passando de 0,24 km² (classificação manual) para 1,94 km². Esta área, que contribui de fato com apenas 3,9% da vazão de pico total, passou a contribuir com 24,7% da vazão.

As áreas do uso urbano tiveram aumento de 12%. Já as reduções nos valores de área e vazão de pico da classe transporte foram de 14% e 15% respectivamente.

CAPÍTULO 5 - RESULTADOS

Cabe salientar que o classificador considerou as bordas da imagem na classificação, que resultou no aumento de 18% da área total da bacia.

As confusões resultaram no aumento da vazão de pico total simulada ($16,2 \text{ m}^3/\text{s}$) em 27% em relação à vazão obtida na classificação manual ($12,8 \text{ m}^3/\text{s}$). O coeficiente NS (0,70) foi considerado bom. Os hidrogramas de cada classe de uso da terra simulados pelo modelo NRCS, o hidrograma resultante simulado e observado podem ser visualizados na Figura 42.

Figura 42 - Efeito dos hidrogramas de ESD das classes de uso da terra no exutório da bacia para o evento 3

Os hidrogramas simulados com o classificador MaxVer apresentaram um comportamento distinto. Com a imagem WorldView-II, a diferença entre a vazão de pico simulada e observada foi de 17% (subestimada). Com a imagem RapidEye, que teve maior correlação entre os dados de vazão (NS de 0,91) a diferença entre os valores de vazão de pico foi de 6% (superestimada). Com a imagem Landsat-8, essa diferença foi de 30%.

A imagem Landsat-8, de menor resolução, obteve os menores Índices Kappa e coeficientes NS, conforme Figura 43.

Figura 43 - Índices de avaliação da classificação MaxVer e das vazões simuladas

5.1.5. Classificador NN com imagem WorldView-II

Os arquivos vetoriais com a classificação das imagens, produzidos pelo classificador NN, foram adicionados ao ArcGIS para produção dos mapas da cobertura e do uso da terra. O mapa com a classificação do conjunto NN-WorldView-II é apresentado na Figura 44.

Figura 44 - (A) Mapa da cobertura e do uso da terra gerado pelo classificador NN do Ecognition e (B) imagem WorldView-II com resolução espacial de 0,5m

Segundo Paranhos Filho, Lastoria e Torres (2008), a classificação orientada a objetos tem sido utilizada principalmente para imagens de alta resolução, que por captarem muitos detalhes diferentes (calçadas, gramados, casas, asfalto e terrenos baldios) apresentam confusão espectral (padrão espectral complexo) e, por isso, permite o maior aproveitamento da imagem.

Corroborando essa afirmação, a imagem WorldView-II, neste classificador, apresentou o melhor Índice Kappa (0,93) em relação às outras imagens, porém foi o menor índice dentre os outros classificadores para essa imagem. As confusões entre as classes são apresentadas na Tabela 26.

Tabela 26 - Matriz de confusão relacionada à imagem WorldView-II e a imagem classificada

WorldView II	Imagem Classificada								Σ linha
	Agricultura	Vegetação rasteira	Floresta	Telha de barro	Telha de metal	Transporte	Solo exposto	Sombra	
Agricultura	268	11	7	0	0	0	0	0	286
Vegetação rasteira	0	108	0	0	0	0	0	0	108
Floresta	0	0	60	0	0	0	0	0	60
Telha de barro	0	0	0	77	0	0	1	0	78
Telha de metal	0	0	0	0	63	1	0	0	64
Transporte	0	0	0	1	4	79	0	0	84
Solo exposto	0	0	0	8	22	0	266	0	296
Sombra	0	0	0	2	0	0	0	48	50
NC	0	0	0	0	0	0	0	0	0
Σ coluna	268	119	67	88	89	80	267	48	1026
AP	100,0	90,8	89,6	87,5	70,8	98,8	99,6	100,0	
AU	93,7	100,0	100,0	98,7	98,4	94,1	89,9	96,0	
Índice Kappa		0,93		Exatidão Global			0,94		

Observa-se na matriz, as confusões entre as classes agricultura, vegetação rasteira e floresta. Essas confusões produziram pouco efeito no ESD, uma vez que a contribuição dessas classes foi inferior a 1% (ver Tabela 27).

O solo exposto foi confundido com o transporte, telhados de barro e metal. As classes que apresentaram maior confusão foram responsáveis por 98,5% da vazão total. O coeficiente NS nesta simulação foi de 0,89. As vazões geradas por classes de uso da terra são apresentadas na Tabela 27.

Tabela 27 - Contribuição das vazões das classes de uso da terra na classificação NN e imagem WorldView-II

Classes de Uso da Terra	Vazão de pico (m ³ /s)	Contribuição (%)	Área de drenagem (km ²)	Contribuição (%)
Urbano	6,6	48,2	1,94	33,3
Vegetação rasteira	0,1	0,7	0,53	9,1
Floresta	0,0	0,0	0,87	14,9
Agricultura	0,1	0,7	0,92	15,8
Solo exposto	2,0	14,6	0,99	17,0
Transporte	4,9	35,8	0,57	9,8
Exutório	13,7	100	5,82	100,00

As maiores discrepâncias entre essa simulação e a classificação manual são para as classes transporte e solo exposto, sendo que no transporte houve redução de 20% da área e no solo exposto aumento de 313%. Este aumento fez com que a vazão gerada pelo solo exposto fosse 300% maior que a vazão de pico obtida na classificação manual. Os hidrogramas de ESD são apresentados na Figura 45.

Figura 45 - Efeito dos hidrogramas de ESD das classes de uso da terra no exutório da bacia para o evento 3

5.1.6. Classificador NN com imagem RapidEye

O Índice Kappa desta classificação foi o menor dentre os classificadores e as imagens. A matriz de confusão é apresentada na Tabela 28 e o mapa da cobertura e do uso da terra do conjunto NN-RapidEye é apresentado na Figura 46.

Tabela 28 - Matriz de confusão relacionada à imagem RapidEye e a imagem classificada

Imagem Landsat-8	Imagem Classificada							Σ linha
	Agricultura	Floresta	Vegetação rasteira	Telha de barro	Telha de metal	Transporte	Solo exposto	
Agricultura	56	0	37	1	0	0	18	112
Floresta	0	193	0	0	0	5	0	198
Vegetação rasteira	0	0	37	0	0	4	5	46
Telha de barro	4	0	14	66	0	3	8	95
Telha de metal	0	0	0	0	85	0	0	85
Transporte	0	1	35	0	2	61	0	99
Solo exposto	53	0	129	4	1	0	85	272
NC	0	0	0	0	5	0	0	5
Σ coluna	113	194	252	71	93	73	116	912
AP	49,6	99,5	14,7	93,0	91,4	83,6	73,3	
AU	50,0	97,5	80,4	69,5	100,0	61,6	31,3	
Índice Kappa		0,58		Exatidão Global		0,64		

Com a imagem RapidEye, o classificador NN apresentou confusões entre todas as classes. A vegetação rasteira foi confundida com a agricultura, telhados de barro, transporte e solo exposto. O telhado de metal foi confundido com transporte e solo exposto. O transporte por sua vez, foi confundido com a floresta, os telhados de barro, e vegetação rasteira.

Figura 46 - (A) Mapa da cobertura e do uso da terra gerado pelo classificador NN do Ecognition e (B) imagem RapidEye com resolução espacial de 5m

Percebe-se no mapa da Figura 46 e, ainda, na matriz da Tabela 28, a grande confusão entre as classes com vegetação e solo exposto. Outra questão a ser levantada nesta classificação, são os valores de acuracidade do produtor e do usuário que, no caso da agricultura, mostra que apenas a metade das amostras dessa classe realmente pertencia à mesma. No caso do solo exposto, dos 73,3% dos pixels classificados como tal, apenas 31,3% realmente pertenciam a esta classe.

As vazões de ESD por classe são apresentadas na Tabela 29 e o gráfico com as vazões simuladas na Figura 47.

Tabela 29 - Contribuição das vazões das classes de uso da terra na classificação NN e imagem RapidEye

Classes de Uso da Terra	Vazão de pico	Contribuição (%)	Área de drenagem (km ²)	Contribuição (%)
Urbano	5,3	30,3	1,5	28,7
Vegetação rasteira	0,0	0,0	0,2	4,2
Floresta	0,0	0,0	0,8	14,5
Agricultura	0,0	0,0	0,4	7,9
Solo exposto	2,7	15,4	1,3	24,3
Transporte	9,5	54,3	1,1	20,4
Exutório	17,5	100,0	5,2	100,0

As vazões de pico foram superestimadas nas classes solo exposto e transporte em 440% e 56% respectivamente. Uma vez que as superfícies vegetadas não geraram ESD e as áreas classificadas erroneamente são aquelas com maior valor de CN, a vazão foi superestimada em 37%, resultando em coeficiente NS de 0,63, considerado satisfatório.

Figura 47 - Efeito dos hidrogramas de ESD das classes de uso da terra no exutório da bacia para o evento 3

5.1.7. Classificador NN com imagem Landsat-8

O conjunto NN-Landsat-8 apresentou melhor resultado no valor do Índice Kappa (0,70) em comparação à imagem RapidEye (0,58).

As confusões nesta classificação ocorreram entre as classes: vegetação rasteira, agricultura e transporte. A floresta foi confundida com o uso agrícola. Naturalmente, o solo exposto foi confundido com o telhado de barro. O transporte foi a classe mais confundida entre as outras, sendo estas: a agricultura, a vegetação rasteira, a floresta, e os telhados de barro. O solo exposto foi confundido com as classes agricultura, vegetação rasteira e telhados de barro.

O mapa de uso da terra gerado pelo NN e a imagem Landsat-8 é apresentado na Figura 48 e sua matriz de confusão na Tabela 30.

Figura 48 - (A) Mapa da cobertura e do uso da terra gerado pelo classificador NN do Ecognition (B) imagem Landsat-8 com resolução espacial de 15m

Tabela 30 - Matriz de confusão relacionada à imagem Landsat-8 e à imagem classificada

Imagem Landsat-8	Imagem Classificada							Σlinha
	Agricultura	Vegetação rasteira	Floresta	Telha de barro	Telha de metal	Transporte	Solo exposto	
Agricultura	21	6	1	0	0	11	13	52
Vegetação rasteira	0	3	0	0	0	2	1	6
Floresta	0	0	28	0	0	1	0	29
Telha de barro	0	0	0	37	0	9	2	48
Telha de metal	0	1	0	0	38	0	0	38
Transporte	0	0	0	0	0	11	0	12
Solo exposto	0	0	0	1	0	0	6	7
NC	0	0	0	0	0	0	0	0
Σcoluna	21	10	29	38	38	34	22	192
AP	100,0	30,0	96,6	97,4	100,0	32,4	27,3	
AU	40,4	50,0	96,6	77,1	100,0	91,7	85,7	
Índice Kappa		0,70		Exatidão Global		0,75		

Nessa simulação, a análise das acurácias do produtor e usuário é interessante. Na classe agricultura, por exemplo, apenas 40,4% das amostras realmente pertenciam à classe agricultura. No caso dos telhados de metal, 100% das amostras foram corretamente classificadas.

O valor da vazão de pico foi o mesmo da imagem RapidEye; entretanto, houve grande confusão das classes transporte e urbana, sendo que esta última representou 66,3% da vazão total. Esses valores são apresentados na Tabela 31.

Tabela 31 - Contribuição das vazões das classes de uso da terra na classificação NN e imagem Landsat-8

Classes de Uso da Terra	Vazão de pico (m ³ /s)	Contribuição (%)	Área de drenagem (km ²)	Contribuição (%)
Urbano	11,6	66,3	3,29	56,6
Vegetação rasteira	0,0	0,0	0,20	3,4
Floresta	0,0	0,0	0,68	11,7
Agricultura	0,1	0,6	0,88	15,1
Solo exposto	0,3	1,7	0,14	2,4
Transporte	5,5	31,4	0,62	10,7
Exutório	17,5	100,0	5,81	100,0

O valor da vazão gerada pelo uso urbano foi superestimado em 93%, assim como a área desta classe, superestimada em 84%. A redução das áreas com solo exposto de 42% resultou na redução da vazão de pico em 40% em relação aos valores de vazão obtidos por meio de classificação manual. O coeficiente NS neste evento foi de 0,61, considerado

satisfatório. As vazões simuladas em comparação às vazões observadas são apresentadas na Figura 49.

Figura 49 - Efeito dos hidrogramas de ESD das classes de uso da terra no exutório da bacia para o evento 3

O classificador NN apresentou o menor desempenho tanto na avaliação da exatidão do classificador quanto na avaliação dos hidrogramas de cheia. Os índices de avaliação são apresentados na Figura 50.

Figura 50 - Índices de avaliação da classificação NN e das vazões simuladas

5.1.8. Classificador SVM com imagem WorldView-II

O classificador SVM apresentou os melhores resultados para as imagens WorldView-II e RapidEye e teve menor valor de Índice Kappa para a imagem Landsat-8, em relação ao classificador MaxVer. Conforme Tabela 32, o Índice Kappa da classificação SVM, com imagem de alta resolução, foi de 0,99.

Tabela 32- Matriz de confusão relacionada à imagem WorldView-II e a imagem classificada

WorldView II	Imagem Classificada								Σlinha
	Agricultura	Vegetação rasteira	Floresta	Solo Exposto	Transporte	Telha de barro	Telha de metal	Sombra	
Agricultura	1001	32	7	0	0	0	0	0	1040
Vegetação rasteira	16	984	5	0	0	0	0	0	1005
Floresta	5	3	985	0	0	0	0	0	993
Solo Exposto	0	0	0	1059	0	4	0	0	1063
Transporte	0	0	0	2	928	0	0	0	930
Telha de barro	0	0	0	7	0	1012	0	0	1019
Telha de metal	0	0	0	0	0	0	1012	0	1012
Sombra	0	0	0	0	0	0	0	984	984
Σcoluna	1022	1019	997	1068	928	1016	1012	984	8046
AP	97,9	96,6	98,8	99,2	100,0	96,6	100,0	100,0	
AU	96,3	97,9	99,2	99,6	99,8	99,3	100,0	100,0	
Índice Kappa		0,99		Exatidão Global		0,99			

Observa-se na matriz da Tabela 32, que os valores de acuracidade do produtor e do usuário são similares para todas as classes, o que demonstra a boa representatividade das amostras e do classificador.

A matriz demonstrou que as maiores confusões estão entre as classes agricultura, vegetação rasteira e floresta, que são aquelas que pouco contribuem para a geração de ESD. Houve confusão também entre as classes solo exposto, telhado de barro e transporte, que são aquelas que mais contribuem para a geração de escoamento superficial.

Na Figura 51, é apresentado o mapa da cobertura e de uso da terra. Nele, é possível observar a boa representatividade das classes presentes na imagem WorldView-II, tais como o bom delineamento das vias pavimentadas, dos espaços com gramíneas (mesmo aqueles dentro das residências), e dos solos expostos.

Figura 51 - (A) Mapa da cobertura e do uso da terra gerado pelo classificador SVM do QGIS e (B) imagem WorldView-II com resolução espacial de 0,5m

Os valores de vazões simuladas para cada classe e sua porcentagem de contribuição para a vazão total são apresentados na Tabela 33, e o gráfico com os hidrogramas na Figura 52.

Tabela 33 - Contribuição das vazões das classes de uso da terra na classificação SVM e imagem WorldView-II

Classes de Uso da Terra	Vazão de pico (m ³ /s)	Contribuição (%)	Área de drenagem (km ²)	Contribuição (%)
Urbano	3,9	30,7	1,2	19,8
Vegetação rasteira	0,1	0,8	1,1	19,4
Floresta	0,0	0,0	0,9	16,0
Agricultura	0,1	0,8	0,7	12,4
Solo exposto	2,4	18,9	1,2	19,9
Transporte	6,2	48,8	0,7	12,4
Exutório	12,7	100,0	5,9	100,0

Figura 52 - Efeito dos hidrogramas de ESD das classes de uso da terra no exutório da bacia para o evento 3

Com relação à classificação manual, a vazão gerada pela classe transporte aumentou em 2% e sua área teve aumento de 3%. A boa representatividade da classificação nas áreas com transporte demonstra a habilidade do classificador para essa assinatura espectral.

O mesmo ocorre para as vazões geradas pelas áreas vegetadas que tiveram 100% de concordância com os dados obtidos com a classificação manual.

As maiores diferenças entre as áreas classificadas com o algoritmo SVM e a classificação manual foram para as classes urbanas, com redução de 35% e solo exposto com aumento de 388%. Ainda assim, a vazão de pico total foi 12,7 m³/s, sendo 1% abaixo da vazão de pico encontrada com a classificação manual. O coeficiente NS de 0,92, para a vazão simulada foi considerado muito bom e foi o mesmo valor encontrado na classificação manual.

5.1.9. Classificador SVM com imagem RapidEye

O conjunto SVM-RapidEye resultou em Índice Kappa igual a 0,98. Observa-se no mapa, que o bom delineamento relativo à classificação SVM com a imagem WorldView-II foi perdido, mas a representatividade das classes se mantém com bons resultados, conforme Figura 53.

Com relação aos erros da classificação, houve confusões entre as classes: i) agricultura e vegetação rasteira; ii) vegetação rasteira e floresta; iii) solo exposto e telhado de barro; iv) telhado de metal e transporte. A matriz de confusão é apresentada na Tabela 34.

Tabela 34 - Matriz de confusão relacionada à imagem RapidEye e a imagem classificada

Imagem RapidEye	Imagem Classificada							Σlinha
	Agricultura	Vegetação rasteira	Floresta	Solo Exposto	Transporte	Telha de barro	Telha de metal	
Agricultura	47	1	0	0	0	0	0	48
Vegetação rasteira	1	33	1	0	0	0	0	35
Floresta	0	0	41	0	0	0	0	41
Solo Exposto	0	0	0	47	0	0	0	47
Transporte	0	0	0	0	19	0	1	19
Telha de barro	0	0	0	1	0	11	0	12
Telha de metal	0	0	0	0	0	0	40	40
Σcoluna	48	34	42	48	19	11	40	242
AP	97,9	97,1	97,6	97,9	100,0	100,0	100,0	
AU	97,9	94,3	100,0	100,0	100,0	91,7	100,0	
Índice Kappa		0,98		Exatidão Global		0,98		

Os maiores erros ocorreram nas áreas da classe solo exposto, superestimada em 408% e uso urbano subestimado em 76%.

Figura 53 - (A) Mapa da cobertura e do uso da terra gerado pelo classificador SVM do QGIS e (B) imagem RapidEye com resolução espacial de 5m

As vazões geradas pelas superfícies vegetadas foram inferiores a 1% e a maior contribuição para a vazão total foi da classe transporte (subestimada em 16%). As vazões de pico por classe de uso da terra são apresentadas na Tabela 35, e os gráficos contendo os hidrogramas, na Figura 54.

Tabela 35 - Contribuição das vazões das classes de uso da terra na classificação SVM e imagem RapidEye

Classes de Uso da Terra	Vazão de pico (m ³ /s)	Contribuição (%)	Área de drenagem (km ²)	Contribuição (%)
Urbano	1,4	12,6	0,4	7,4
Vegetação rasteira	0,1	0,9	1,4	23,4
Floresta	0,0	0,0	0,9	14,7
Agricultura	0,1	0,9	1,1	19,1
Solo exposto	2,4	21,6	1,2	20,9
Transporte	7,1	64,0	0,9	14,5
Exutório	11,1	100,0	5,9	100,0

A vazão de pico total foi subestimada em 13% em relação à vazão obtida na classificação manual. O coeficiente NS considerou uma boa relação entre os dados, de 92%.

Figura 54 - Efeito dos hidrogramas de ESD das classes de uso da terra no exutório da bacia para o evento 3

5.1.10. Classificador SVM com imagem Landsat-8

O conjunto SVM-Landsat-8 resultou em valor de Índice Kappa igual a 0,83 e coeficiente NS de 0,91. A confusão ocorreu entre as classes: i) agricultura, vegetação rasteira e transporte; ii) espaços abertos com vegetação e solos exposto; iii) solo exposto e telhado de barro, conforme Tabela 36.

Tabela 36 - Matriz de confusão relacionada à imagem Landsat-8 e a imagem classificada

Imagem Lansat-8	Imagem Classificada							Σ linha
	Agricultura	Vegetação rasteira	Floresta	Solo Exposto	Transporte	Telha de barro	Telha de metal	
Agricultura	17	6	0	0	0	0	0	23
Vegetação rasteira	2	11	0	0	0	0	0	13
Floresta	0	0	19	0	0	0	0	19
Solo Exposto	0	2	0	10	0	0	0	12
Transporte	1	0	0	0	4	0	0	5
Telha de barro	0	0	0	1	0	7	0	8
Telha de metal	0	0	0	0	0	0	6	6
Σ coluna	20	19	19	11	4	7	6	86
AP	85,0	57,9	100,0	90,9	100,0	100,0	100,0	
AU	73,9	84,6	100,0	83,3	80,0	87,5	100,0	
Índice Kappa		0,83		Exatidão Global		0,86		

O mapa da cobertura e do uso do solo do conjunto SVM-landsat-8 é apresentado na Figura 55.

Figura 55 - (A) Mapa da cobertura e do uso da terra gerado pelo classificador SVM do QGIS (B) imagem Landsat-8 com resolução espacial de 15m

As superfícies vegetadas não geraram ESD significativo, enquanto que a maior contribuição ao ESD foi para a classe urbana, seguido de transporte e solo exposto, conforme Tabela 37.

Tabela 37 - Contribuição das vazões das classes de uso da terra na classificação SVM e imagem Landsat-8

Classes de Uso da Terra	Vazão de pico	Contribuição (%)	Área de drenagem (km ²)	Contribuição (%)
Urbano	4,8	41,7	1,4	24,3
Vegetação rasteira	0,1	0,9	1,2	20,1
Floresta	0,0	0,0	0,7	12,0
Agricultura	0,1	0,9	0,7	11,4
Solo exposto	3,0	26,1	1,5	25,1
Transporte	3,5	30,4	0,4	7,1
Exutório	11,5	100,0	5,8	100,0

As confusões entre as classes resultaram na redução da vazão de pico do uso urbano de 20%; aumento da vazão de pico de 500% na classe solo exposto e redução da vazão em 43% na classe transporte. Ainda assim, a vazão total foi subestimada em 10% em relação à vazão observada. As vazões geradas por cada classe de uso da terra são apresentadas na Figura 56.

Figura 56 - Efeito dos hidrogramas de ESD das classes de uso da terra no exutório da bacia para o evento 3

O classificador SVM apresentou bom desempenho em relação à classificação de imagens e às vazões observadas. Os hidrogramas apresentados mostraram boa aderência, uma vez que o coeficiente NS foi superior a 0,91, indicando boa concordância entre os dados das vazões simuladas e observadas, conforme Figura 57.

Figura 57 - Índices de avaliação da classificação SVM e das vazões simuladas

5.2. Análise das áreas da cobertura e do uso da terra nas diferentes imagens classificadas

As áreas de cada classe de uso da terra variaram em decorrência das diferentes resoluções de imagens e dos classificadores, sendo as classes que apresentaram maiores influência na geração do ESD: urbana, solo exposto e transporte.

Para realizar a análise das discrepâncias entre as áreas de cada classificação semiautomática foi selecionada a imagem WorldView-II. Esta imagem foi selecionada por ser a imagem utilizada na classificação manual. Os valores das áreas para os usos urbanos, solo exposto e transporte em comparação com os valores das áreas na classificação manual são apresentados na Figura 58.

Figura 58 - Variação nas áreas das classes de uso da terra que mais geraram escoamento superficial

Uma visão geral das porcentagens das áreas de todas as classes nas quatro simulações é apresentada na Tabela 38.

Tabela 38- Porcentagens das áreas de cada classe nas diferentes classificações

Classes de Uso da Terra	% das áreas de cada classe para as diferentes classificações			
	Manual	MaxVer	NN	SVM
Urbana	31	35	33	20
Vegetação rasteira	26	24	9	19
Floresta	18	18	15	16
Agricultura	10	10	16	12
Solo Exposto	4	7	17	20
Transporte	12	6	10	12

5.2.1. Classificador SVM

Analisando-se as diferenças nas áreas das classes de uso do solo em decorrência das diferentes imagens de satélite no classificador SVM, a maior diferença ocorreu para o uso

urbano, 13% menor na imagem RapidEye em relação à imagem WorldView-II, e 17% menor que a classificação com a imagem Landsat-8.

As áreas das classes transporte e agricultura também apresentaram diferenças notórias, com máximo de 8% entre todas as imagens. As demais classes apresentaram diferenças máximas de até 5% entre suas áreas. As porcentagens das áreas de cada classe de uso da terra na classificação SVM, com as imagens de diferentes resoluções, podem ser visualizadas na Figura 59; e os valores das áreas das classes em km², na Tabela 39.

Figura 59 - Área de cada classe de uso da terra para a classificação SVM e diferentes imagens de satélite

Tabela 39 - Valores das áreas obtidos pela classificação SVM

Classe de Uso da Terra	Valores de áreas das imagens Classificadas (km ²)			Porcentagem de Uso da Terra para cada Classe		
	WorldView-II	RapidEye	Landsat-8	WorldView-II	RapidEye	Landsat-8
Agricultura	0,73	1,12	0,68	12	19	12
Vegetação rasteira	1,14	1,37	1,17	19	23	20
Floresta	0,94	0,86	0,70	16	15	12
Espaço aberto com solo exposto	1,17	1,22	1,46	20	21	25
Transporte (vias)	0,73	0,85	0,41	12	15	7
Urbano	1,16	0,43	1,41	20	7	24
Total	5,87	5,85	5,82	100	100	100

5.2.2. Classificador NN

Na classificação NN, a maior diferença nas áreas das imagens classificadas ocorreu para a classe urbana, com valor máximo de 28%, sendo que o maior aumento ocorreu na imagem Landsat-8. Em segundo lugar, a classe solo exposto apresentou diferença máxima de 22% entre suas áreas, seguido das classes: transporte (10%), agricultura (8%), vegetação rasteira (6%) e floresta (3%).

As porcentagens das áreas distribuídas em cada classe de uso da terra para esta classificação podem ser visualizadas na Figura 60, e os valores das áreas das classes em km², para as diferentes imagens, são apresentados na Tabela 40, assim como as porcentagens dessas em relação à área total da bacia.

Figura 60 - Área de cada classe de uso da terra para a classificação NN e diferentes imagens de satélite

Tabela 40 - Valores das áreas obtidos pela classificação NN

Classe de Uso da Terra	Valores de áreas da imagens Classificadas (Km ²)			Porcentagem de Uso da Terra para cada Classe		
	WorldView-II	RapidEye	Landsat-8	WorldView-II	RapidEye	Landsat-8
Agricultura	0,92	0,41	0,88	16	8	15
Vegetação rasteira	0,53	0,22	0,20	9	4	3
Floresta	0,87	0,75	0,68	15	15	12
Espaço aberto com solo exposto	0,99	1,26	0,14	17	24	2
Transporte (vias)	0,57	1,06	0,62	10	20	11
Urbano	1,94	1,49	3,29	33	29	57
Total	5,82	5,19	5,81	100	100	100

5.2.3. Classificador MaxVer

Na classificação MaxVer, a maior diferença no valor das áreas em decorrência das diferentes imagens foi para a classe solo exposto, de 21%. Nas classes vegetação rasteira e urbana, a diferença máxima foi de 20%. As diferenças percentuais, de 11% e 10%, são atribuídas às classes floresta e transporte, respectivamente, e a menor diferença ocorreu para a classe agricultura, de 7%.

As porcentagens das áreas distribuídas em cada classe de uso da terra para esta classificação podem ser visualizadas na Figura 61, e os valores das áreas das classes em km², para as diferentes imagens, são apresentados na Tabela 41, assim como as porcentagens dessas em relação à área total da bacia.

Figura 61 - Área de cada classe de uso da terra para a classificação MaxVer e diferentes imagens de satélite

Tabela 41 - Valores das áreas obtidos pela classificação MaxVer

Classe de Uso da Terra	Valores de áreas das imagens Classificadas (km²)			Porcentagem de Uso da Terra para cada Classe		
	WorldView-II	RapidEye	Landsat-8	WorldView-II	RapidEye	Landsat-8
Agricultura	0,56	0,63	1,18	10	11	17
Vegetação rasteira	1,32	1,67	0,65	24	29	10
Floresta	1,02	0,61	0,50	18	10	7
Espaço aberto com solo exposto	0,39	1,09	1,94	7	19	28
Transporte (vias)	0,35	0,91	0,61	6	16	9
Urbano	1,91	0,90	2,00	34	16	29
Total	5,53	5,81	6,87	100	100	100

5.3. Análise dos classificadores de imagens na geração de escoamento superficial

No item 5.1.1, foram apresentados os hidrogramas de cheia para o evento chuva-vazão de número 3 e foram discutidos os hidrogramas simulados por cada classe de uso da terra. Os dados das vazões observadas foram comparados às vazões simuladas e avaliadas pelo coeficiente NS.

Os hidrogramas resultantes de cada classe de uso da terra, simulados com o evento 3, permitiram analisar a influência dos erros da classificação semiautomática de imagens no hidrograma de cheia. Esta análise foi facilitada devido ao evento 3 possuir apenas um pico de cheia, similar ao hidrograma unitário sintético, e por isso, os dados de precipitação simulados no modelo NRCS resultaram em hidrogramas representativos do observado.

Neste tópico, são realizadas análises dos três eventos chuva-vazão considerando apenas os hidrogramas resultantes (somatório dos hidrogramas de todas as classes) para avaliar o comportamento do classificador em relação à qualidade das imagens (resolução espacial). Nessa análise foram considerados os valores de vazão de pico simulados e comparados com os valores de vazão observados em cada evento.

5.3.1. Evento 1

O evento 1 ocorreu no dia 07 de novembro de 2014 e teve um total precipitado de 45 mm com duração de 3,1 horas. A vazão de pico totalizou **5,7 m³/s** e o volume total foi de 42.511 m³. A condição de umidade antecedente do solo foi considerada mediana (condição II).

O primeiro ponto interessante a ser destacado na análise do comportamento do classificador quanto à resolução da imagem, é que o classificador SVM demonstrou que este parâmetro tem pouca influência nos resultados dos hidrogramas de cheia, ou seja, a imagem de maior resolução espacial, a WorldView-II, resultou em valor de NS inferior aos das demais imagens.

Os coeficientes NS foram de: 0,65 para a vazão obtida com a imagem RapidEye, 0,56 para a vazão obtida com a imagem Landsat-8, e de 0,39 para a vazão obtida com a imagem WorldView-II.

Neste caso, a imagem que melhor representou a vazão de pico (6,5 m³/s) do hidrograma observado foi a imagem Landsat-8, seguido da imagem RapidEye com vazão de pico de 7,2 m³/s e, por último, a WorldView-II com vazão de pico de 7,7 m³/s, conforme mostra a Figura 62.

Figura 62 - Hidrogramas de ESD gerados a partir do classificador SVM para o evento 1

No classificador MaxVer, a imagem que obteve valor de vazão de pico mais próxima do valor observado também foi a imagem Landsat-8 ($5,6 \text{ m}^3/\text{s}$), sendo $0,1 \text{ m}^3/\text{s}$ abaixo do valor observado. Em segundo lugar tem-se a imagem WorldView-II com vazão de pico de $5,9 \text{ m}^3/\text{s}$ e, por último, a imagem RapidEye com vazão de pico de $8,4 \text{ m}^3/\text{s}$.

Os coeficientes NS referentes aos hidrogramas das imagens RapidEye e Landsat-8 foram de 0,22 e da imagem WorldView-II de 0,71. Este resultado mostra que o classificador MaxVer segue a lógica de que a melhor resolução da imagem gera o hidrograma de ESD mais representativo da vazão observada. Os hidrogramas de cada imagem são apresentados na Figura 63.

Figura 63 - Hidrogramas de ESD gerados a partir do classificador MaxVer para o evento 1

No classificador NN, o hidrograma de cheia mais representativo foi obtido com a imagem WorldView-II ($8,1 \text{ m}^3/\text{s}$), seguido da Landsat-8 ($10,5 \text{ m}^3/\text{s}$) e da RapidEye ($11,2 \text{ m}^3/\text{s}$). Os hidrogramas gerados são apresentados na Figura 64.

Figura 64 - Hidrogramas de ESD gerados a partir do classificador NN para o evento 1

5.3.2. Evento 2

O evento chuva-vazão 2 ocorreu no dia 17 de fevereiro de 2015, com precipitação total de 53 mm. Esta gerou um volume de ESD de 68.641m^3 e uma vazão de pico de **$7,1\text{ m}^3/\text{s}$** . A condição antecedente de umidade do solo foi a condição I, com chuvas menores que 13 mm nos 5 dias antecedentes ao dia 17/02/2015.

Neste evento, as imagens Landsat-8 e WorldView-II tiveram os mesmos valores de vazão de pico, de $10\text{ m}^3/\text{s}$, e a imagem que obteve vazão de pico mais próxima da observada foi a RapidEye ($8,7\text{ m}^3/\text{s}$), conforme Figura 65.

Figura 65 - Hidrogramas de ESD gerados a partir do classificador SVM para o evento 2

No classificador MaxVer, a imagem que produziu vazão de pico mais próxima da observada foi a WorldView-II ($8,8 \text{ m}^3/\text{s}$), seguida da imagem RapidEye ($10 \text{ m}^3/\text{s}$) e da Landsat-8 ($13,6 \text{ m}^3/\text{s}$). Os hidrogramas gerados pelo classificador MaxVer são apresentados na Figura 66.

Figura 66 - Hidrogramas de ESD gerados a partir do classificador MaxVer para o evento 2

No classificador NN, as vazões de pico foram de $11,1 \text{ m}^3/\text{s}$ para a imagem WorldView-II, de $12,4 \text{ m}^3/\text{s}$ para a RapidEye, e de $13,4 \text{ m}^3/\text{s}$ para a Landsat-8. Se comparadas com a vazão observada foram superestimadas em mais de 50%. Os hidrogramas de ESD gerados são apresentados na Figura 67.

Figura 67 - Hidrogramas de ESD gerados a partir do classificador NN para o evento 2

5.3.3. Evento 3

O evento 3 ocorreu no dia 25 de fevereiro de 2015, com precipitação total de 40 mm. Tal precipitação gerou um volume de ESD de 49.924 m^3 e uma vazão de pico de **$12,5 \text{ m}^3/\text{s}$** . A condição antecedente de umidade do solo foi a condição III, com chuvas maiores que 28 mm nos 5 dias antecedentes ao dia 25/02/2015.

A vazão de pico gerada com a imagem WorldView-II ($12,7 \text{ m}^3/\text{s}$) e classificador SVM foi o que melhor representou a vazão de pico observada, seguido das imagens Landsat-8 ($11,4 \text{ m}^3/\text{s}$) e RapidEye ($11,0 \text{ m}^3/\text{s}$). Os hidrogramas são apresentados na Figura 68.

Figura 68 - Hidrogramas de ESD gerados a partir do classificador SVM para o evento 3

No classificador MaxVer, a vazão gerada com a imagem WorldView-II foi subestimada ($10,2 \text{ m}^3/\text{s}$). A vazão gerada com a imagem RapidEye ($13,0 \text{ m}^3/\text{s}$) ficou mais próxima do valor observado, seguida da imagem Landsat-8 ($16,0 \text{ m}^3/\text{s}$). Os hidrogramas são apresentados na Figura 69.

Figura 69 - Hidrogramas de ESD gerados a partir do classificador MaxVer para o evento 3

No classificador NN, a imagem WorldView-II gerou o melhor resultado, com vazão de pico de $13,5 \text{ m}^3/\text{s}$, e as imagens RapidEye e Landsat-8 tiveram hidrogramas semelhantes com vazões de pico de $17,2$ e $17,3 \text{ m}^3/\text{s}$, respectivamente. Os hidrogramas de ESD gerados são apresentados na Figura 70.

Figura 70 - Hidrogramas de ESD gerados a partir do classificador NN para o evento 3

5.4. Importância da resolução espacial da imagem de satélite no processo de classificação para estudos hidrológicos

Diante da preocupação de se utilizar imagens de satélites de livre acesso e por saber que suas resoluções espaciais não atingem tal qualidade, quando comparada às imagens comerciais de alta resolução, buscou-se analisar o comportamento de certos classificadores de imagens em relação a este parâmetro.

Utilizando os valores de vazão de pico produzidos por cada conjunto classificador-imagem foi possível avaliar quais simulações obtiveram as melhores respostas em relação aos hidrogramas observados.

A primeira avaliação foi em relação à resolução das imagens, pois se acreditava que as imagens de maiores resoluções espaciais produziram os hidrogramas mais representativos. Tal hipótese não é verdadeira, pois se observou que nem todos os classificadores utilizados responderam desta maneira.

Sobre o classificador SVM, por exemplo, foi apresentado que além de produzir os melhores índices Kappa, demonstrou que a resolução das imagens de satélites não tem relação com o hidrograma mais representativo. Entretanto, uma imagem de baixa resolução, como é o caso da Landsat-8, pode apresentar resultados hidrológicos expressivos, evitando o uso da imagem WorldView-II que possui custo elevado.

Os classificadores MaxVer e NN demonstraram que a resolução da imagem influencia diretamente na geração de hidrogramas de ESD representativos, portanto, são obtidos a partir da imagem de maior resolução espacial.

Esta análise é importante quando abordamos os custos envolvidos nestes processos, uma vez que o classificador MaxVer, em conjunto com o ArcGis e a imagem WorldView-II, possuem custos elevados. O classificador MaxVer pode ser aplicado em outros *softwares* gratuitos de geoprocessamento.

5.5. Facilidades de aplicação das técnicas de classificação

As facilidades de aplicação das técnicas de classificação são importantes na escolha do classificador, quando se trata de grandes projetos. A fim de facilitar esta análise, este trabalho apresenta o classificador SVM do QGIS como o mais simples e intuitivo. Como apresentado na metodologia, com poucos processos é possível obter a imagem classificada e a matriz de confusão, já em formato (.csv). Tal formato é compatível com o Excel e facilita a aplicação dos cálculos do Índice Kappa e da exatidão global, que são as formas de se avaliar os resultados da classificação.

O conjunto de ferramentas Orfeo, no qual o classificador SVM está inserido, também dispõe de ferramentas para pré-processamento das imagens, tais como: sobreposição de sensores, cálculo das estatísticas de bandas e fusão das imagens.

O classificador MaxVer apresentou dificuldade média na obtenção dos processos em conjunto (classificação de imagem e obtenção da matriz de confusão). O processo de classificação, isoladamente, é simples, porém o segundo processo exige maior conhecimento do usuário.

A classificação NN aplicada no módulo simplificado do *software* eCognition é um processo complexo para um usuário comum, pois envolve uma lógica de pertinência para

definir as classes de uso da terra na imagem, conforme explicado na metodologia. Uma das facilidades do *software* é que, ao classificar a imagem, é possível obter a matriz de confusão juntamente com os valores de Índice Kappa e exatidão global, sem precisar realizar nenhum procedimento extra; basta acessar o módulo de resultados no *software* e exportá-los.

Na Tabela 42, são apresentadas as vantagens e desvantagens dos classificadores utilizados, de acordo com a experiência obtida neste trabalho.

Tabela 42 -Vantagens e desvantagens dos classificadores semiautomáticos de imagens

Classificador	Vantagens	Desvantagens
SVM +QGIS	A resolução das imagens tem pouca influência na geração de hidrogramas de ESD representativos. Facilidade de aplicação das técnicas de classificação e obtenção da matriz de confusão. Processos intuitivos. Licença pública.	Módulo de impressão de mapas do QGIS incompleto (versão 2.8).
MaxVer + ArcGis	Boa representatividade dos hidrogramas de ESD para as imagens de resolução alta. Módulo de impressão de mapas bem desenvolvido e intuitivo.	A boa representatividade do hidrograma de ESD depende da resolução das imagens. Dificuldade na geração da matriz de confusão em decorrência dos vários processos envolvidos. Licença comercial (alto custo).
NN + Ecognition	Facilidades de obtenção de parâmetros estatísticos, tanto das imagens quanto dos resultados da classificação.	Técnicas de classificação com lógica complexa. Não possui módulo de impressão de mapas. Licença comercial (alto custo).

5.6. Representação dos classificadores em relação às vazões observadas

Para avaliar a representatividade dos classificadores aplicados às diferentes resoluções de imagens, foram elaborados gráficos contendo as vazões de pico observadas e simuladas, apresentados no item 5.3.

Neste tópico são apresentadas as diferenças relativas entre a vazão de pico observada e a simulada para cada imagem, sendo que os valores negativos representam as vazões simuladas superestimadas e os valores positivos as vazões subestimadas, conforme Tabela 43

Tabela 43 - Erros relativos entre as vazões de pico observadas e simuladas

Classificador+Imagem	Erro Relativo (%)		
	Evento 1	Evento 2	Evento 3
WorldView-II+SVM	-26,0	-29,0	0,8
WorldView-II+MaxVer	-3,4	-19,3	22,5
WorldView-II+NN	-29,6	-36,0	-7,4
RapidEye+SVM	-20,8	-18,4	13,6
RapidEye+MaxVer	-32,1	-29,0	-3,8
RapidEye+NN	-49,1	-42,7	-27,3
Landsat-8+SVM	-12,3	-29,0	9,6
Landsat-8+MaxVer	1,8	-47,8	-21,9
Landsat-8+NN	-45,7	-47,0	-27,7

Observa-se na Tabela 43, em relação ao evento 1, que os menores erros percentuais ocorreram para a imagem WorldView-II e Landsat-8 com o classificador MaxVer. A imagem RapidEye com o mesmo classificador teve erro de 32% em relação à vazão de pico observada.

No evento 2, o menor erro percentual foi para o classificador SVM com a imagem RapidEye (18%), seguido do classificador MaxVer com a imagem WorldView-II (19%). O demais classificador contém erros maiores que 29%. Neste evento, todas as vazões de pico foram superestimadas.

O evento 3 produziu os menores erros, sendo que a classificação SVM com a imagem WorldView-II foi a mais representativa, ou seja, superestimou a vazão em apenas de 1%. O classificador MaxVer e a imagem RapidEye também apresentaram bons resultados, superestimando a vazão em 7%, assim como o conjunto SVM-Landsat-8, que subestimou a vazão em 8%.

O classificador SVM com a imagem RapidEye subestimou a vazão em 11% e o classificador NN com a imagem WorldView-II, superestimou a vazão em 10%. Na figura 71 são apresentados os valores das vazões de pico simuladas e as vazões observadas para os três eventos chuva-vazão.

Figura 71 - Vazões de pico simuladas e observadas

5.7. Análise multicritério

A análise multicritério TOPSIS, aplicada ao conjunto de alternativas e critérios, teve como finalidade classificar por pontuação os classificadores e as imagens de satélites. Os pesos atribuídos aos critérios para avaliação dos classificadores são apresentados na Tabela 44.

Tabela 44 - Peso dos critérios utilizados na análise dos classificadores de imagens

Critério	Relação entre critérios	Peso atribuído à alternativa em relação ao critério		
	Peso	SVM	MaxVer	NN
1 - Importância da resolução espacial da imagem de satélite	5	3	7	5
2 - Dificuldade de aplicação das técnicas de classificação	5	3	5	7
3 - Custo dos classificadores	7	0	7	9
4 - Representatividade do classificador quanto ao Índice Kappa	9	9	9	5

Para melhor entender o critério de atribuição de pesos, exemplifica-se a relação entre os critérios 3 e 1. Assim, segundo o critério 3 é considerado o custo do classificador como muito importante, tendo em vista que nem sempre o usuário dispõe de recursos para a compra da licença do *software* classificador e que existem *softwares* com a mesma finalidade disponíveis de forma gratuita. Já segundo o critério 1 foi atribuído o peso de importância média, pois é desejável que uma classificação representativa não dependa de imagens de alta resolução.

Em relação aos pesos atribuídos às alternativas, o critério 1 e o valor 3 demonstram que os valores de índice Kappa apresentaram pequenas diferenças em decorrência da resolução da imagem no classificador SVM, demonstrando pouca importância. Já no critério 2, o valor 3 para o classificador SVM significa que houve pouca dificuldade na aplicação das técnicas de classificação. Por outro lado, o MaxVer apresentou dificuldade média, pois a quantidade de processos envolvidos na obtenção da matriz de confusão é maior que nos outros classificadores.

No critério “Custo dos Classificadores”, foram atribuídos os pesos 0 para o SVM (gratuito) e 7 para o MaxVer, uma vez que sua licença possui custo oneroso e, por isso, é considerado muito importante. Ao classificador NN, presente no eCognition, foi atribuído importância absoluta por ser mais caro que o *software* da ESRI.

Quanto ao critério quatro, atribuiu-se importância absoluta ao classificador SVM, pois este apresentou menor número de confusão entre as classes; assim como o classificador MaxVer, pois foram obtidos bons resultados; e ao classificador NN atribuiu-se o valor 5 (importância média), pois seus valores de Índice Kappa foram os menores.

Os pesos atribuídos aos critérios para avaliação das imagens de satélite são apresentados na Tabela 45.

Tabela 45 - Peso dos critérios utilizados na análise das imagens de satélites

Critério	Relação entre critérios	Peso atribuído à alternativa em relação ao critério		
	Peso	WorldView-II	RapidEye	Landsat-8
1 - Influência da resolução das imagens na geração de ESD	5	5	3	3
2 - Facilidade da coleta das amostras de treinamento e validação	5	9	5	3
3 - Custo das imagens	9	5	0	0
4 - Pré-tratamento das imagens	7	7	0	7

Na atribuição de pesos das alternativas, o peso 5, relacionado à imagem WorldView-II, representa a importância que a mesma tem ao representar o hidrograma de ESD em relação ao hidrograma observado, sendo que, para as imagens RapidEye e Landsat-8, a importância foi considerada baixa, uma vez que essas imagens são de baixa resolução e tiveram bom desempenho na geração dos hidrogramas de cheia.

No critério dois, considerou-se importância absoluta na facilidade de coletar amostras para a a imagem WorldView-II; a imagem RapidEye apresentou mais restrição à facilidade, enquanto a imagem Landsat-8 apresentou pouca facilidade.

No critério 3, a importância absoluta foi atribuída à imagem WorldView-II, uma vez que seu custo foi elevado, e o valor 0 para as imagens gratuitas. Com relação à necessidade de pré-tratamento das imagens, atribuiu-se nota 7 para as imagens que necessitaram dos processos de PDI, sendo que tal importância foi dada em decorrência da necessidade dos conhecimentos na área de PDI.

O resultado da aplicação da metodologia TOPSIS para análise dos classificadores e das imagens é apresentado na Tabela 46.

Tabela 46 - Resultado da análise multicritério dos classificadores e das imagens de satélite

Análise TOPSIS para Classificadores de Imagens		Análise TOPSIS para Imagens de Satélite	
SVM	0,75	WorldView-II	0,62
MaxVer	0,57	RapidEye	0,55
NN	0,48	Landsat-8	0,75

O classificador SVM foi o primeiro colocado na análise TOPSIS, pois obteve a maior nota. Esta classificação se deve aos melhores resultados para os seguintes critérios: i) custos (sem custos); ii) representatividade do classificador obtida pelo Índice Kappa (0,99 para a imagem WorldView-II, 0,98 para a imagem RapidEye e 0,83 para a imagem Landsat-8); iii) importância da resolução espacial da imagem satélite quanto a qualidade da classificação, e iv) facilidades de aplicação das técnicas de classificação.

CAPÍTULO 5 - RESULTADOS

A importância da resolução espacial das imagens é um critério de grande valia para a análise do classificador, uma vez que é desejável que imagens de menor resolução espacial e, principalmente sem custos, sejam representativas para estudos hidrológicos.

O classificador SVM, por sua vez, demonstrou que independentemente da resolução espacial das imagens os hidrogramas de cheia simulados apresentaram valores de vazão de pico representativos dos valores de vazão de pico observadas, avaliadas pelo coeficiente NS.

Quanto às facilidades de aplicação das técnicas de classificação e obtenção da matriz de confusão, o classificador SVM merece destaque, pois as ferramentas são intuitivas e foram necessários apenas três processos para sua aplicação.

A segunda colocação do classificador MaxVer+ArcGIS, certamente ocorre devido ao seu custo e à importância que a resolução da imagem tem na obtenção dos hidrogramas de ESD representativos, pois é clara a influência das imagens nos resultados dos hidrogramas. Entretanto, a avaliação do Índice Kappa foi excelente, de 0,97 para a imagem WorldView-II, 0,93 para a imagem RapidEye e de 0,89 para a imagem Landsat-8.

A nota do classificador NN foi a mais baixa, sendo o menos preferido. Tal nota é explicada em decorrência do seu alto custo e da complexidade da lógica de pertinência no processo de classificação. A complexidade do processo é levada em conta, uma vez que existe uma grande variedade de *softwares* classificadores de imagens e o usuário sempre busca o menos complexo e que demande menos tempo de treinamento.

O critério “Representatividade da Classificação” também contribuiu para a colocação do classificador NN, pois apresentou os menores valores de Índice Kappa em relação aos outros classificadores.

A análise multicritério das imagens de satélite levantou uma questão de suma importância para os estudos hidrológicos, pois demonstrou que o conjunto SVM-Landsat-8, ambos gratuitos, pode ser utilizado para obter hidrogramas de ESD com boa representatividade (NS de 0,91).

A imagem WordView-II obteve a segunda colocação, pois apresentou bom desempenho para gerar os hidrogramas e maior facilidade na coleta de amostras de treinamento e de validação. Entretanto, seu elevado custo contribuiu para sua colocação. Outro critério que contribuiu para sua nota foi sua resolução, a qual teve influência na obtenção de hidrogramas de cheia representativos, fato este que se torna indesejável, uma vez que uma imagem de alta resolução implica em altos custos, recurso que nem sempre o usuário dispõe.

Devido à quantidade de dados que uma imagem de alta resolução espacial possui, seu tempo de processamento no *software* e o espaço necessário para seu armazenamento são maiores quando comparado às imagens de baixa resolução. Portanto é necessário dispor de computadores com maior capacidade de armazenamento e velocidade.

A imagem RapidEye obteve a terceira colocação na análise TOPSIS, o que ocorreu, principalmente, devido aos baixos valores de Índice Kappa e coeficientes de NS. Entretanto, a imagem é gratuita para instituições públicas, universidades e institutos tecnológicos.

6.0 CONCLUSÃO

Técnicas de processamento digital de imagens foram exploradas e imagens de satélites de diferentes resoluções espaciais foram utilizadas para classificar a cobertura e o uso da terra de uma bacia urbana. A partir de nove combinações entre classificador semiautomático e imagem de satélite, foram simulados 27 hidrogramas de cheia para avaliar o desempenho dos conjuntos classificador-imagem na obtenção desses hidrogramas.

Para cada mapa da cobertura e do uso da terra, foi aplicado o modelo hidrológico NRCS e simulado o hidrograma de cheia. Este foi comparado ao hidrograma de cheia observado a fim de avaliar o conjunto "classificador-imagem" mais representativo.

Dos resultados que esta pesquisa apresenta, são destacadas as conclusões quanto: i) ao desempenho dos classificadores no processo de classificação; ii) a quantificação do impacto da resolução espacial das imagens na simulação de hidrogramas de cheia por modelo hidrológico; iii) a apresentação das facilidades e dificuldades da aplicação de técnicas de processamento digital de imagens e geoprocessamento; iv) a apresentação de análise multicritério contendo o desempenho da classificação e das imagens; e vi) a apresentação da metodologia proposta.

6.1. Desempenho dos classificadores de imagem de satélite

As classificações foram avaliadas por meio dos índices: coeficiente Kappa, exatidão global, acuracidade do produtor e do usuário. De acordo com Mather (2004), a análise de apenas um coeficiente de avaliação não é capaz de representar a real acuracidade do mapa.

A acuracidade do usuário, por sua vez, traz uma análise interessante, pois apresenta a quantidade de pixels classificados corretamente em relação ao total de pixels classificados na imagem. Já a acuracidade do produtor diz respeito à concordância do classificador com as amostras de treinamento (selecionadas pelo usuário) e, nesse processo, o usuário é capaz de analisar se suas amostras são representativas para o classificador e, caso não sejam, poderá refazê-las.

Os índices avaliadores da classificação foram apresentados na matriz de confusão de cada conjunto "classificador-imagem". Essa matriz consiste no método mais comum para representar o grau de acuracidade de uma classificação e pode ser obtida por meio dos próprios *softwares*, como foi o caso dos classificadores utilizados.

Quando o objetivo do tomador de decisão é planejar o parcelamento da cobertura e do uso da terra e decidir futuros usos, como no Plano Diretor, é essencial que se conheça o conjunto "classificador-imagem" que produza a menor “confusão” entre as classes. Para isso, é necessário escolher ferramentas que produzam resultados adequados à verdade de campo.

Os resultados do estudo de caso desta pesquisa mostram que os classificadores SVM e MaxVer em conjunto com todas as imagens utilizadas (WorldView-II, RapidEye e Landsat-8) atingiram índices Kappa considerados como excelentes ($Kappa > 0,81$) por Landis e Koch (1977) e são apresentadas como as melhores soluções.

Portanto, a resposta à primeira hipótese de que as imagens de satélites com maior resolução espacial são as que geram os mapas da cobertura e do uso da terra mais representativos da verdade de campo não é verdadeira, pois nem todos os conjuntos classificador-imagem responderam da mesma maneira. Um exemplo disso é o caso do conjunto NN-RapidEye, com valor de índice Kappa de 0,58, sendo esse inferior ao valor obtido pelo conjunto NN-Landsat-8 (menor resolução espacial), de 0,70, o que demonstra que outros fatores, além da resolução espacial, devem ser levados em conta.

A segunda hipótese de que imagens de baixa resolução espacial não são representativas para pequenas bacias urbanas e semiurbanas não é verdadeira, tendo em vista que as imagens de baixa resolução espacial apresentaram índices avaliadores considerados como excelentes, como foi o caso da imagem Landsat-8 com os classificadores MaxVer (IK de 0,89) e SVM (IK de 0,83) e imagem RapidEye com os classificadores MaxVer (IK de 0,93) e SVM (IK de 0,98).

6.2. Impacto da resolução espacial das imagens nos hidrogramas de ESD

Para auxiliar na tomada de decisão sobre quais classificadores e as imagens de satélite utilizar em estudos sobre a drenagem urbana, este trabalho trouxe uma contribuição importante ao apresentar, como resultado, que a resolução espacial da imagem de satélite não

é necessariamente determinante na geração de hidrogramas de cheia representativos, o que faz refletir sobre a necessidade de adquirir uma imagem de alta resolução espacial, que normalmente implica custos elevados.

Esta afirmação é amparada nos resultados apresentados no capítulo 5, em que as imagens Landsat-8 e RapidEye em conjunto com o classificador SVM produziram índices Kappa considerados excelentes, superiores a 83%, e coeficientes NS considerados muito bons, superiores a 91%. O coeficiente NS, nestas simulações, apresentaram valores semelhantes ao obtido na classificação manual, de 92%.

O classificador MaxVer também apresentou bons resultados quanto ao índice Kappa para as imagens gratuitas ($IK > 0,89$) e, para representar a vazão observada, os coeficientes de NS foram superiores a 70%.

As confusões entre as classes da cobertura e do uso da terra geradas pelos classificadores semiautomáticos influenciaram nos resultados das vazões de pico, sendo que as principais classes responsáveis pela redução do coeficiente de NS foram: uso urbano, transporte e solo exposto.

Os solos expostos e os telhados de barro (urbano), devido às suas assinaturas espectrais semelhantes, são obstáculos para os classificadores semiautomáticos, assim como as áreas de transporte e as casas com telhados de metal. Essas confusões interferiram na representatividade da vazão de pico em relação à vazão observada com diferenças de até 49%.

Portanto, valida-se a hipótese de que há influência das confusões entre as classes da cobertura e do uso da terra no hidrograma de cheia simulado. A metodologia para a construção das matrizes de confusão, assim como sua análise, foram apresentadas neste trabalho.

6.3. Técnicas de processamento digital de imagens e geoprocessamento: facilidade e dificuldades

Dentre os objetivos do uso do geoprocessamento na área de recursos hídricos, encontra-se o de caracterizar a situação atual e simular cenários futuros para subsidiar a tomada de decisão. Nesse sentido, o geoprocessamento e o sensoriamento remoto, em

CAPÍTULO 6 - CONCLUSÕES

conjunto com a modelagem hidrológica, são ferramentas poderosas na criação de cenários ligados à drenagem urbana.

O trabalho detalhou uma metodologia prática sobre o processamento digital de imagens e o geoprocessamento. Portanto, é esperado que o usuário, ao ler este texto, seja capaz de realizar a classificação da cobertura e do uso da terra com facilidade.

O trabalho apresenta as dificuldades, vantagens e desvantagens de cada classificador (item 5.5) e as confusões entre as classes de uso da terra urbana que os algoritmos de cada classificador podem apresentar.

Quanto às facilidades de uso de cada classificador foi concluído que o classificador SVM do QGIS é o mais simples e intuitivo. O classificador MaxVer apresenta dificuldade média na obtenção dos processos em conjunto (classificação e obtenção da matriz de confusão). Já a classificação orientada a objeto apresenta complexidade alta, uma vez que envolve uma lógica de pertinência para definir as classes de uso da terra na imagem.

6.4. Análise multicritério

A análise dos classificadores de imagens envolveu os seguintes critérios: i) importância da resolução espacial da imagem de satélite; ii) dificuldade de aplicação das técnicas de classificação; iii) custo dos classificadores; iv) representatividade do classificador quanto aos índices avaliativos.

Para a análise das imagens de satélites foram utilizados os critérios: i) influência da resolução espacial das imagens na geração de ESD; ii) facilidade da coleta das amostras de treinamento e validação; iii) custo das imagens; e iv) pré-tratamento das imagens. Essas análises permitiram classificar as melhores imagens e classificadores em relação a esses critérios.

Em relação à análise do classificador, o SVM foi o primeiro colocado, com nota de 0,75, sendo considerado com melhor desempenho. Em segundo lugar, foi atribuída a nota de 0,57 ao classificador MaxVer e, por último, o classificador NN recebeu a nota 0,48.

Com relação às imagens de satélite, as preferências foram para: imagem Landsat-8 com nota de 0,75; em segundo lugar a imagem WorldView-II com nota de 0,62; e por último a imagem RapidEye com nota de 0,55.

CAPÍTULO 6 - CONCLUSÕES

Tais resultados permitem concluir que a integração entre o classificador SVM e a imagem Landsat-8 se apresenta como boa solução para simulações hidrológicas em estudos sobre a drenagem urbana, pois apresentaram o melhor desempenho. Tal resultado implica dizer que a hipótese de que a avaliação multicritério possa auxiliar na tomada de decisão em relação à busca da solução ideal é verdadeira.

6.5. Resumo da metodologia proposta

A metodologia proposta tem como objetivo avaliar o desempenho de pares classificador-imagem para produzir mapas da cobertura e do uso da terra a serem utilizados em modelos chuva-vazão e, assim, auxiliar os técnicos da área de recursos hídricos, em especial aqueles envolvidos com drenagem urbana, a obter hidrogramas de cheia a partir de técnicas de processamento digital de imagens, do sensoriamento remoto e do geoprocessamento.

Em conclusão, é possível produzir hidrogramas de escoamento superficial direto de boa qualidade a partir da classificação semiautomática de imagens e de um modelo hidrológico. A metodologia proposta consiste nos seguintes passos:

Passo 1 – Classificação de imagens de satélite. De acordo com os resultados desta pesquisa, o classificador semiautomático Support Vector Machine do *software* QGIS e a imagem do satélite Landsat-8 são boas opções. Além de serem gratuitos, seu desempenho técnico é compatível com a precisão requerida nos estudos de planejamento e concepção;

Passo 2 – Avaliação da classificação por meio da matriz de confusão e cálculo de índices avaliadores: Índice Kappa e Exatidão Global.

Passo 3 – Aplicação do modelo NRCS, ou outro modelo similar, para calcular a precipitação efetiva, sendo as áreas de cada classe de uso da terra, obtidas a partir do conjunto classificador-imagem, o principal dado de entrada. Atribuição dos valores de CN correspondentes a cada classe de acordo com USDA (1986).

Passo 4 – Geração dos hidrogramas simulados pelo modelo do hidrograma unitário sintético do NRCS, ou outro similar.

A comparação entre os hidrogramas simulados e os hidrogramas observados é importante na avaliação da representatividade de cada conjunto classificador-imagem. Tendo em vista que nem sempre se dispõe de dados de precipitação e vazão observados, ao ler esse trabalho, o usuário torna-se conhecedor de alguns conjuntos classificador-imagem representativos, que poderão ser aplicados em estudos sobre a drenagem urbana de bacias pequenas e médias com ocupação urbana e semiurbana.

Para melhor visualização dos resultados que permitiram fundamentar as conclusões desta tese e a metodologia proposta, é apresentada a Tabela 47, que contém um resumo da metodologia proposta e dos resultados obtidos na pesquisa.

Tabela 47 - Metodologia proposta e resumo dos resultados obtidos na pesquisa

Metodologia Proposta			
Passo 1	Passo 2	Passo 3 e 4	
Classificação de Imagens	Avaliação da Classificação pela Matriz de Confusão	Aplicação do modelo NRCS e do Hidrograma Unitário	
Resumo dos Resultados			
Conjunto Classificador-Imagem	Índice Kappa	Coefficiente de Nash Stuctiffe ($Q_{simulada} \times Q_{observada}$)	Colocação
1) SVM-WorldView-II	0,99	0,92	1º
2) SVM-RapidEye	0,98	0,92	
3) SVM-Landsat8	0,83	0,91	
4) MaxVer-WorldView-II	0,97	0,87	2º
5) MaxVer-RapidEye	0,93	0,91	3º
6) MaxVer-Landsat-8	0,89	0,70	
7) NN-WorldView-II	0,93	0,89	
8) NN-RapidEye	0,58	0,63	
9) NN-Landsat-8	0,70	0,61	

6.6. Recomendações para continuidade dos estudos

Com base nas conclusões desta pesquisa e das perguntas que ainda podem ser respondidas, recomenda-se:

- i) Classificar imagens com base em apenas imagens multiespectrais para verificar se há interferências nos valores dos pixels (DN) no processo de fusão.
- ii) Usar máscaras para excluir classes, tais como aquelas que não geraram ESD significativo (a categoria sombra e as classes vegetadas), e analisar a interferência dos erros entre as classes de uso da terra no hidrograma de cheia.

iii) Aplicar um modelo chuva-vazão distribuído para verificar se há maior correlação entre os dados simulados e observados.

iv) Avaliar os fatores que interferem na qualidade da classificação semiautomática de imagens além da resolução espacial da imagem.

7.0 REFERÊNCIAS BIBLIOGRÁFICAS

AFSHAR, A. et al. Fuzzy TOPSIS multi-criteria decision analysis applied to Karun reservoirs system. **Water Resources Management**, v. 25, n. 2, p. 545–563, 2011.

AMRO, I. et al. A Survey of classical methods and new trends in pansharpening of multispectral images. **EURASIP Journal on Advances in Signal Processing**, v. 2011, n. 79, p. 1-22, 2011.

ALBUQUERQUE, R. W. de. **Monitoramento da cobertura do solo no entorno de hidrelétricas utilizando o classificador SVM (*Support Vector Machines*)**. 2012. 107 f. Dissertação (Mestrado em Engenharia de Transportes) - Escola Politécnica, Universidade de São Paulo, São Paulo, 2012.

ANDREOLA, R. **Support vector machines na classificação de imagens hiperespectrais**. 2009. 130. f. Dissertação (Mestrado em Sensoriamento Remoto) - Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2009.

ANTUNES, A. F. B.; CORTESE, S. C. Determinação de áreas de ocupação irregulares por meio de análise orientada a objetos. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. **Anais...** Florianópolis: INPE, 2007. p. 481-487.

APRÍGIO, P. O. Avaliação de modelos de simulação de cargas difusas em bacias urbanas. 2012. 131 f. Dissertação (Mestrado em Hidráulica e Saneamento) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2012.

BATISTA, J. L. O.; SANTOS, L. R. A Caracterização do uso e ocupação do solo de uma zona semiárida entre 1993 a 2008 através da classificação supervisionada Maxver: o caso do município de Teofilândia, Bahia (BA) – Brasil. **Revista Geográfica Venezolana**, v. 54, n. 1, p. 99-111, 2013.

BATISTA, J. L. O. **Deteção de mudanças da cobertura e uso do solo a partir de índices espectrais de vegetação em ambientes semiárido: endoque para o município de Teofilândia, Bahia**. 2011. 154 f. Dissertação (Mestrado em Ciências Ambientais) – Programa de Pós-Graduação em Modelagem em Ciência da Terra e do Ambiente, Universidade Estadual de Feira de Santana, Feira de Santana, 2011.

BIELENKI JUNIOR, C.; BARBASSA, A. P. **Geoprocessamento e recursos hídricos: aplicações práticas**. São Carlos: EdUFSCAR, 2012.

BRASIL. **Constituição (1988)**. Constituição da República Federativa do Brasil. Brasília, DF: Senado, 1988.

BRASIL. Lei° 10.257, de 10 de julho de 2001. Regulamenta os arts. 182 e 183 da Constituição Federal, estabelece diretrizes gerais da política urbana e dá outras providências.

Diário Oficial [da] República Federativa do Brasil, Brasília, DF, 11 jul. 2001. Disponível em: <http://www.planalto.gov.br/ccivil_03/leis/LEIS_2001/L10257.htm>. Acesso em 21 maio 2016.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. Catálogo de imagens. Disponível em: <<http://www.dgi.inpe.br/CDSR/>>. Acesso em: 15 jan. 2016.

CAMPOS, J. N. **Lições em modelos e simulação hidrológica**. Fortaleza: ASTEF/EXPRESSÃO GRÁFICA. 2009.

CANHOLI, A. P. **Drenagem urbana e controle de enchentes**. 2. ed. São Paulo: Oficina de Textos, 2014.

CHOW, V. T.; MAIDMENT, D. R.; MAYS, L. W. *Applied hydrology*. Texas: McGraw-Hill, 1988.

COLLISCHONN, W.; DORNELLES, F. **Hidrologia para engenharia e ciências ambientais**. Porto Alegre: ABRH, 2013.

COLLISCHONN, W.; TASSI, R. **Introduzindo hidrologia**. Porto Alegre: IPH/UFRGS, 2008. Disponível em:

<https://hidropaisagem.files.wordpress.com/2014/04/livro_introduzindo-hidrologia.pdf>. Acesso em: 23 abr. 2016.

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. 2nd. Boca Raton: CRC Press, 2009.

CRÓSTA, A. P. **Processamento digital de imagens de sensoramento remoto**. Campinas, SP: IG/Unicamp, 1992.

DECINA, T. G. T. **Avaliação de medidas de controle de inundações na bacia hidrográfica do córrego do Gregório**. 2012. 175 f. Dissertação (Mestrado em Hidráulica e Saneamento) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2012.

DEFINIENS. eCognition, **User's guide 4.0**. Disponível em: <<http://ecognition.cc/download/userguide.pdf>>. Acesso em maio 2015.

DEMARCHI, J. C.; PIROLI, E. L.; ZIMBACK, C. R. L. Análise temporal do uso do solo e comparação entre os índices de vegetação NVDI e SAVI no município de Santa Cruz do Rio Pardo – SP usando imagens Landsat-5. **RA'E GA – O Espaço Geográfico em Análise**, n. 21, p. 234-271, 2011.

DIGITAL GLOBE. **WorldView-2**. Disponível em: <<http://www.digitalglobe.com/about-us/content-collection#worldview-2>>. Acesso em: 30 dez. 2013.

ENGESAT. **Imagens de satélite**. Disponível em: <<http://www.engesat.com.br/imagem-de-satelite/>>. Acesso em 20 mar. de 2016.

ESRI. **ArcGis for desktop**. Disponível em: <<http://www.esri.com/software/arcgis/arcgis-for-desktop>>. Acesso em 20 jan. 2016.

FERNANDES, S. C. **Avaliação de imagens de satélite de alta e muito alta resolução espacial para a discriminação de classes de uso e ocupação do solo**: aplicação ao caso da sub-bacia do córrego Capão Comprido no Distrito Federal. 2005. 106 f. Dissertação (Mestrado em Tecnologia Ambiental e Recursos Hídricos) - Faculdade de Tecnologia, Universidade de Brasília, Brasília, 2005.

FORGHANI, A.; CECHET, B.; NADIMPALLI, K. Object-based classification of multi-sensor optical imagery to generate terrain surface roughness information for input to wind risk simulation. Disponível em: <<http://www.ecognition.com/support/media-library#scientific-papers>>. Acesso em fev. de 2016.

GARCEZ, L. N.; ALVAREZ, G. A. **Hidrologia**. 2. ed. rev. e atual. São Paulo: Blucher, 1988.

GRIFFITHS, D.A., **Introduction to electrodynamics**, 3 edição, Prentice Hall, 1999.

GLOBALGEO. **RapidEye**. Disponível em: <<http://www.globalgeo.com.br/satelite/rapideye/>>. Acesso em: 20 set. 2015.

GÓES, C. A.; MELLO FILHO, W. L.; CARVALHO, M. Avaliação do desempenho de diferentes classificadores (Iseog, Bhattacharyya, Maxver e Maxver-ICM), utilizando imagens CCD/CBERS-1 e ETM+/Landsat-7 fusionadas. **Revista Ambiente e Água – An Interdisciplinary Journal of Applied Science**, v. 1, n. 2, p. 80-89, 2006.

GONZALES, R. C.; WOODS, R. E. **Processamento digital de imagens**. 3. ed. São Paulo: Pearson Prentice Hall, 2010.

HWANG C.L.; YOON, K. **Multiple attribute decision making**: lecture notes in economics and mathematical systems. Berlin: Springer, 1981.

ITK. **Insight Segmentation and Registration Toolkit**. Disponível em: <<http://www.itk.org/>>. Acesso em: 4 fev. 2015.

KLIBER, D. F. **Urban stormwater hydrology**. Washington: American Geophysical Union, 1982.

LANDIS, J. R.; KOCH, G. G. The Measurement of observer agreement for categorical data. **Biometrics**, v. 33, n. 1, p. 159-174, 1977.

LEE, G.; JUN, K. S.; CHUNG, E. S. Integrated multi-criteria flood vulnerability approach using fuzzy TOPSIS and Delphi technique. **Natural Hazards Earth System Sciences**, v. 13, n. 5, p. 1293–1312, 2013.

LEE, G.; JUN, K. S.; CHUNG, E. S. Robust spatial flood vulnerability assessment for Han River using fuzzy TOPSIS with α -cut level set. **Expert Systems with Applications**, v. 41, n. 2, p. 644–654, 2014.

MANAKOS, I.; SCHNEIDER, T.; AMMER U. A Comparison between the ISODATA and the eCognition classification methods on basis of field data. In: INTERNATIONAL SOCIETY FOR PHOTOGRAMMETRY AND REMOTE SENSING, 19., 2000, Amsterdam. **Proceedings...** [S.l.]: International Society for Photogrammetry and Remote Sensing, 2000. p. Disponível em: <<http://www.ecognition.com/support/media-library#scientific-papers>>. Acesso em: 5 fev. de 2016.

MANTELLI, S. **Introdução a visão computacional**: técnicas de segmentação simples de imagens. Disponível em: <<http://www.inf.ufsc.br/~visao/segmentos.pdf>>. Acesso em: 20 mar. de 2016.

MARTINS, R. G.; BRANDÃO, J. L. B. Influences of land use on the quantity and quality aspects of water resources in urban basins. In: IWA INTERNATIONAL CONFERENCE ON DIFFUSE POLLUTION AND EUTROPHICATION, 17., Berlin, 2015. **Proceedings...** [S.l.: s.n.], 2015.

MATHER, P. M. **Computer processing of remotely-sensed images**: an introduction. 3rd ed. Chichester: Wiley, 2004.

McCUEN, R. H. **Hydrologic analysis and design**. New Jersey: Prentice-Hall, 1989.

MESSAGE, L. B. **Classificação do uso e ocupação na bacia hidrográfica do córrego do Monjolinho, São Carlos - SP, utilizando SIG**. [S.l.: s.n.], 2013. Relatório Parcial do Programa de Iniciação Científica da FAPESP.

MISHRA, S. K.; SINGH, V. Soil Conservation Service Curve Number (SCS-CN) Methodology. **Water Science and Technology Library**, v. 42. 516 p. 2003.

MITRI, G. H.; GITAS, I. Z. The Development of an object-oriented classification model for operational burned area mapping on the Mediterranean island of Thasos using LANDSAT TM images. In: XAVIER VIEGAS, D. **Forest fire research & wildland fire safety**. Rotterdam: Milpress, 2002. p. 1-12. Disponível em: <<http://www.ecognition.com/support/media-library#scientific-papers>>. Acesso em 6 fev. de 2016.

MORAES, E. C. de. **Capítulo 1: fundamentos do sensoriamento remoto**. São José do Campos: INPE, 2002. Disponível em: <http://mtc-m12.sid.inpe.br/col/sid.inpe.br/sergio/2005/06.14.12.18/doc/CAP1_ECMoraes.pdf>. Acesso em: 18 mar. 2016.

NOVO, E. M. L. de M. **Sensoriamento remoto**: princípios e aplicações. 2. ed. São Paulo: Edgard Blücher, 1992.

ORFEO TOOL BOX. **The ORFEO tool box software guide updated for OTB - 5.2**: the ORFEO toolbox is not a black box. 2015. Disponível em: <<https://www.orfeo-toolbox.org/CookBook/>>. Acesso em 18 de dez. 2015.

PAIVA, J. B. D.; PAIVA, E. C. D. (Org.). **Hidrologia aplicada à gestão de pequenas bacias hidrográficas**. Porto Alegre: ABRH, 2003.

PARANHOS FILHO, A. C.; LASTORIA, G.; TORRES, T. G. **Sensoriamento remoto ambiental aplicado**: introdução às geotecnologias. Campo Grande: UFMS, 2008.

PIZARRO, P.; COMUNELLO, E.; MANTELLI, S. **Introdução a visão computacional**: segmentação por crescimento de regiões. Disponível em: <<http://www.inf.ufsc.br/~visao/regiongrow.pdf>>. Acesso de 20 mar. de 2016.

PREFEITURA MUNICIPAL SÃO CARLOS. **Dados da cidade**: geográfico e demográfico. Disponível em: <<http://www.saocarlos.sp.gov.br/index.php/conheca-sao-carlos/115442-dados-da-cidade-geografico-e-demografico.html>>. Acesso em: 30 dez. 2015.

RAGHAVENDRA, S. N., DEKA, P. Support vector machine applications in the field of hydrology: a review. **Applied Soft Computing**, v. 19, p. 373-386, 2014.

RIBEIRO, B. M. G.; FONSECA, L. M. G.; KUX, H. J. H. Avaliação das imagens WorldView-II para o mapeamento da cobertura do solo urbano utilizando o sistema InterIMAGE. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15., 2011, Curitiba. **Anais...** Curitiba: INPE, 2011. p. 7-22.

RIBEIRO, B. M. G.; KUX, H. J. H. Classificação orientada a objeto para mapeamento do uso do solo – métodos de análise de expansão urbana. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14., Natal, 2009. **Anais...** São José dos Campos: INPE/SELP, 2009. p. 7893-7900.

ROKNI, K. et al. A New approach for surface water change detection: integration of pixel level image fusion and image classification techniques. **International Journal of Applied Earth Observation and Geoinformation**, v. 34, p. 226-334, 2014.

SARTORI, A.; LOMBARDI NETO, F.; GENOVEZ, A. M. Classificação hidrológica de solos brasileiros para estimativa de chuva excedente com o método do serviço de conservação de solo dos Estados Unidos Parte 1: classificação. **Revista Brasileira de Recursos Hídricos**, v 10, p. 5-18, 2005.

SCHWARZ, M.; STEINMEIER, CH.; WASER L. Detection of storm losses in alpine forest areas by different methodic approaches using high-resolution satellite data. In: EUROPEAN ASSOCIATION OF REMOTE SENSING LABORATORIES, 20., 2001, Dresden. Lisse: A.A. Balkema, 2001. p. 14-16. Disponível em: <<http://www.ecognition.com/support/media-library#scientific-papers>>. Acesso em: 13 fev. de 2016.

STEFEN, C. A. **Introdução ao sensoriamento remoto**. Disponível em: <<http://www.inpe.br/unidades/cep/atividadescep/educasere/apostila.htm>>. Acesso em: 18 mar de 2016.

TORKAMANI, F.; FALLAH, S.; SAADATMAND, M. How urban managers can use DSS to facilitate decision making process: an application of fuzzy TOPSIS. **Journal of American Science**, v. 8, n. 5, p. 163-172, 2012.

TIMBLE. **Case studies**. Disponível em: <<http://www.ecognition.com/support/media-library#case-studies>>. Acesso em 20 jan. 2016.

TUCCI, C. E. M. et al. (Org.). **Hidrologia: ciência e aplicação**. 4. ed. Porto Alegre: UFRGS/ABRH, 2014.

TUCCI, C. E. M. **Modelos hidrológicos**. 2. ed. Porto Alegre: Editora da UFRGS, 2005.

TUCCI, C. E. M.; PORTO, R. L. L.; BARROS, M. T. L. **Drenagem urbana**. Porto Alegre: ABRH, 1995.

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL. **Dinâmica para o aprendizado em sensoriamento remoto**. Disponível em: <<http://www.ufrgs.br/engcart/PDASR/fusao.html>>. Acesso em: 20 mar. de 2016.

UNITED STATES DEPARTMENT OF AGRICULTURE. Hydrologic soil-cover complexes. In: _____. **Hydrology National Engineering Handbook**. Washington: Natural Resources Conservation Service, 2004. Part 630.

UNITED STATES DEPARTMENT OF AGRICULTURE. **Urban hydrology for small watersheds**. 2nd ed. Springfield: National Technical Information Service, 1986. Technical Release 55.

UNITED STATES GEOLOGICAL SURVEY. **Landsat Mission**. Disponível em: <http://landsat.usgs.gov/best_spectral_bands_to_use.php>. Acesso em: 26 maio 2015.