



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21b/2016/10.24.18.16-TDI

AVALIAÇÃO DE CLASSIFICADORES POR ÁRVORE DE DECISÃO E ÁRVORE DE REGRESSÃO EM CENAS URBANAS DO SENSOR WORLDVIEW-2

Bruna Maria Pechini Bento

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelo Dr. Hermann Johann Heinrich
Kux, aprovada em 29 de agosto de
2016.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34P/3MLSFAH>>

INPE
São José dos Campos
2017

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GB)

Serviço de Informação e Documentação (SID)

Caixa Postal 515 - CEP 12.245-970

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/6921

Fax: (012) 3208-6919

E-mail: pubtc@inpe.br

COMISSÃO DO CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELECTUAL DO INPE (DE/DIR-544):

Presidente:

Maria do Carmo de Andrade Nono - Conselho de Pós-Graduação (CPG)

Membros:

Dr. Plínio Carlos Alvalá - Centro de Ciência do Sistema Terrestre (CST)

Dr. André de Castro Milone - Coordenação de Ciências Espaciais e Atmosféricas (CEA)

Dra. Carina de Barros Melo - Coordenação de Laboratórios Associados (CTE)

Dr. Evandro Marconi Rocco - Coordenação de Engenharia e Tecnologia Espacial (ETE)

Dr. Hermann Johann Heinrich Kux - Coordenação de Observação da Terra (OBT)

Dr. Marley Cavalcante de Lima Moscati - Centro de Previsão de Tempo e Estudos Climáticos (CPT)

Silvia Castro Marcelino - Serviço de Informação e Documentação (SID)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon

Clayton Martins Pereira - Serviço de Informação e Documentação (SID)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Simone Angélica Del Ducca Barbedo - Serviço de Informação e Documentação (SID)

Yolanda Ribeiro da Silva Souza - Serviço de Informação e Documentação (SID)

EDITORAÇÃO ELETRÔNICA:

Marcelo de Castro Pazos - Serviço de Informação e Documentação (SID)

André Luis Dias Fernandes - Serviço de Informação e Documentação (SID)



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21b/2016/10.24.18.16-TDI

AVALIAÇÃO DE CLASSIFICADORES POR ÁRVORE DE DECISÃO E ÁRVORE DE REGRESSÃO EM CENAS URBANAS DO SENSOR WORLDVIEW-2

Bruna Maria Pechini Bento

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelo Dr. Hermann Johann Heinrich
Kux, aprovada em 29 de agosto de
2016.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34P/3MLSFAH>>

INPE
São José dos Campos
2017

Dados Internacionais de Catalogação na Publicação (CIP)

Bento, Bruna Maria Pechini.

B446a Avaliação de classificadores por árvore de decisão e árvore de regressão em cenas urbanas do sensor Worldview-2 / Bruna Maria Pechini Bento. – São José dos Campos : INPE, 2017.
xxiv + 140 p. ; (sid.inpe.br/mtc-m21b/2016/10.24.18.16-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2016.
Orientador : Dr. Hermann Johann Heinrich Kux.

1. Sensoriamento remoto. 2. Alta resolução espacial.
3. WorldView-2. 4. GEOBIA. 5. Mineração de dados. I.Título.

CDU 528.831.1



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

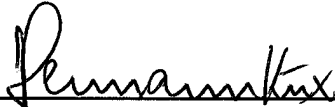
This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

Aluno (a): **Bruna Maria Pechini Bento**

Título: " AVALIAÇÃO DE CLASSIFICADORES POR ÁRVORE DE DECISÃO E ÁRVORE DE REGRESSÃO EM CENAS URBANAS DO SENSOR WORLDVIEW-2".

Aprovado (a) pela Banca Examinadora
em cumprimento ao requisito exigido para
obtenção do Título de **Mestre** em
Sensoriamento Remoto

Dr. Hermann Johann Heinrich Kux




Presidente / Orientador(a) / INPE / SJCampos - SP

Dra. Cláudia Maria de Almeida



Membro da Banca / INPE / São José dos Campos - SP

Dr. Thales Sehn Körting



Membro da Banca / INPE / São José dos Campos - SP

Dra. Cristiane Nunes Francisco



Convidado(a) / UFF / Rio de Janeiro - RJ

Este trabalho foi aprovado por:

maioria simples

unanimidade

São José dos Campos, 29 de Agosto de 2016

“To accept the challenge of the unknown is courage. The fears are there, but if you go on accepting the challenge again and again, slowly, slowly those fears disappear. The joy that the unknown brings, the great ecstasy that starts happening with the unknown, makes you strong enough, gives you a certain integrity, makes your intelligence sharp. You start feeling that life is not just a boredom. Life is an adventure. Slowly, slowly fears disappear and you go on seeking and searching for new adventures.

Courage is risking the known for the unknown, the familiar for the unfamiliar, the comfortable for the uncomfortable arduous pilgrimage to some unknown destination. One never knows whether one will be able to make it or not. It is a gambling, but only the gamblers know what life is. ”

OSHO

*Aos meus pais, Sônia e Mário
e irmãs, Cláudia e Patrícia,
pelo amor e apoio.*

AGRADECIMENTOS

Agradeço primeiramente a professora Dr.^a Evelyn Novo, que a partir da leitura do prefácio de seu livro criou dentro de mim o sonho de estudar no Instituto Nacional de Pesquisas Espaciais.

Em segundo lugar, a minha mãe Sônia Bento, que antes mesmo de mim, acreditou que este sonho seria possível.

Aos professores da Universidade Estadual Paulista Prof.^a Dr.^a Andréia Medinilha Panher, Prof. Dr. Roberto Braga e Prof. Dr. Sergio Nobre pela gentileza de me recomendarem.

Ao meu orientador Dr. Hermann Kux por permitir que este sonho pudesse ser realizado, pela confiança em meu trabalho, por sua imensa disposição nos trabalhos de campo e pela amizade criada ao longo desses anos.

O meu muito obrigada ao Dr. Thales Korting por aceitar me orientar, pelas pacientes explicações e grandes contribuições no decorrer do estudo.

À Dr.^a Cláudia Almeida por sempre me receber em sua sala com conversas esclarecedoras e sugestões.

Aos professores Dr. Flávio Ponzoni e Dr. Camilo Rennó pelo exemplo de docência.

Às amigas Anielli Rosane, Bruna Braga e Vanessa Camphora por todas as noites de estudo, apoio e incentivo em todos os momentos do mestrado.

À querida amiga Ana Carolina Pessoa, pela paz trazida em todos os dias dessa jornada.

Aos companheiros de sala do Sigma, Batcaverna, LTID e ASA que tornaram os longos dias de trabalho em motivantes dias de trabalho, em especial aos amigos Rennan Marujo e David França pela troca de materiais e conhecimentos.

À minha família que em suas orações me fortaleceram em todos os momentos.

Ao meu grande companheiro Danilo Corrêa, por fazer o possível e o impossível para me ajudar a realizar esse sonho.

As amigas Renata Lainetti, Monique Corrêa, Ana Beatriz Seron, Nathália Delgado e Thamires Santoro pela motivação e compreensão da longa ausência.

À Fundação de Aperfeiçoamento de Pessoal de Nível Superior - CAPES, pelo apoio financeiro à execução desta pesquisa.

A empresa Digital Globe que, gentilmente, cedeu a imagem para este estudo.

Ao Instituto Nacional de Pesquisas Espaciais, pela oportunidade de estudo, utilização de suas instalações e, principalmente, por permitir que eu conhecesse e fizesse parte de sua exemplar cultura de troca de conhecimento entre pesquisadores.

O meu sincero agradecimento a todos que contribuíram de alguma forma para a realização deste trabalho.

RESUMO

A Terceira Geração de Satélites Imageadores proporcionou a disponibilização de imagens orbitais com resoluções espaciais, espectrais, radiométricas e temporais mais detalhadas, abrindo novos caminhos para se explorar a complexidade espacial do fenômeno urbano. No entanto, a análise dessas imagens pelos métodos tradicionais, que envolvem classificadores pixel a pixel e por região, resultam em limitações no detalhamento de classes e conseqüentemente baixas acurácias. Dessa maneira, o aumento do conteúdo informativo deste novo tipo de imagens, exigiu dos usuários a busca por novas metodologias e ferramentas para analisá-los. A abordagem da análise de imagem baseada em objeto geográfico (GEOBIA – *Geographic Object-Based Image Analysis*) representou uma solução para superar essas limitações. A GEOBIA permite simular a visão contextual de um intérprete humano, através de modelos de conhecimento expressos por redes semânticas. A construção de modelos de conhecimento é uma tarefa complexa, a qual exige do intérprete o conhecimento prévio da cena e demanda um longo período para a sua realização. Neste sentido, técnicas de mineração de dados têm sido amplamente utilizadas como ferramenta de apoio para a construção da rede semântica. Estas vêm na vanguarda das tecnologias analisar de forma eficiente bancos de dados complexos, auxiliando os cientistas nas previsões não triviais. Um dos tipos de algoritmos mais utilizados na mineração de dados são as árvores de decisão. Na classificação de imagens orbitais, estes algoritmos selecionam de forma automática, dentre os atributos disponíveis, os mais adequados na caracterização das classes a serem discriminadas. O resultado é representado por uma árvore de decisão, que é um conjunto de regras aplicadas sobre os atributos disponíveis. Este conjunto de regras é posteriormente convertido em uma rede semântica, presente em plataformas de GEOBIA. Este trabalho propõe uma metodologia empregando conjuntamente abordagens cognitivas e de mineração de dados com o objetivo de analisar o desempenho dos algoritmos de árvore de decisão e árvore de regressão para a classificação de cobertura do solo urbano. Como base para esta análise foi utilizada uma área teste do município de São José dos Campos – SP a partir de uma cena da imagem do sistema sensor óptico de alta resolução espacial WorldView-2. Ambos algoritmos apresentaram boas acurácias, sendo que a acurácia da árvore de decisão apresentou em média valores ligeiramente maiores do que a árvore de regressão. Quanto aos modelos de árvore obtidos nos experimentos, o algoritmo de árvore de decisão apresentou melhor capacidade de generalização na formulação das regras por atributo e, portanto, recorreu a um número menor de atributos e gerou menores tamanhos de árvores do que os gerados por árvore de regressão. As árvores de decisão testadas se apoiaram em mais de um programa computacional para executar suas análises, impondo desafios aos pesquisadores no que diz respeito a integração de dados, conversão de formato dos dados, o conhecimento do *software* a ser utilizado, além da replicação de arquivos. Uma vez que área de estudo cobre uma área geográfica reduzida e obteve um

número elevado de objetos, quando for utilizada uma cena completa o volume de dados pode representar uma barreira ainda maior. Já as árvores de regressão testadas pertencem a uma plataforma integrada de GEOBIA, beneficiando o usuário quanto à redução de tempo para a realização de todas as etapas de análise de imagem.

Palavras-chave: Sensoriamento remoto. Alta resolução espacial. WorldView-2. GEOBIA. Mineração de dados.

ASSESSMENT OF CLASSIFIERS THROUGH DECISION TREE AND REGRESSION TREE IN URBAN AREAS USING THE WORLDVIEW-2 SENSOR

ABSTRACT

The Third Generation of Image Satellites has enabled the availability of more detailed orbital images with spatial, spectral, radiometric and temporal resolution. This opens new ways to explore the spatial complexity of the urban phenomenon. The analysis of those images through the traditional methods, which involves pixel-to-pixel and per region classifiers, results in limitations on class detail and, consequently, low accuracy. Therefore, the increase of the informative content of this new type of images has required from the users the search for new methodologies and tools to analyze them. The analysis approach of the image based on geographic object (GEOBIA –*Geographic Object-Based Image Analysis*) represents a solution to overcome those limitations. The GEOBIA allows simulating the contextual view of a human interpreter using models of knowledge expressed by semantic networks. The construction of knowledge models is a complex task, which requires from the interpreter the previous knowledge of the scene and demands an extensive period for its realization. In this sense, data mining techniques have been widely used as a support tool for the construction of the semantic network. These come in the forefront of the technology to efficiently analyze complex databases, assisting scientists in non-trivial predictions. The decision trees are one of the most used types of algorithms in data mining. In the classification of orbital images, those algorithms automatically select the most appropriate attributes to characterize the discriminated classes. The result is represented by a decision tree, which is a group of rules applied on the available attributes. This group of rules is afterwards converted in a semantic network, present in the GEOBIA platforms. The aim of this study is to analyze the performance of the algorithms of the decision tree and the regression tree to classify the urban land coverage. It proposes for that a methodology that uses jointly cognitive approaches and data mining. A test area of São José dos Campos – SP was used as the base for this analysis, which is a scene from the image of the spatial high resolution optic sensor WorldView-2. Both algorithms presented good accuracy and it is worth mentioning that the decision tree accuracy on average presented values slightly higher than the regression tree. In what regards the tree models obtained in the experiments, the decision tree algorithm showed better generalization capacity in the formulation of the rules by attribute. As a consequence, it resorted to a smaller number of attributes and generated smaller tree sizes than the ones generated by the regression tree. The tested decision trees were supported by several softwares in the execution of the

analyses. This posed as a challenge to the researchers in what regards the data integration, data format conversion, knowledge of the utilized software and also file replication. Albeit this study covered a reduced geographic area, it presented a high number of objects. Therefore, it is possible to conclude that, in a complete scene, the data volume may represent a bigger barrier. On the other hand, the regression trees that were tested belong to an integrated platform of GEOBIA, which benefits the user in reducing the time spent to execute all the image analysis stages.

Keywords: Remote sensing. High spatial resolution. WorldView-2. GEOBIA. Data mining.

LISTA DE FIGURAS

	<u>Pág.</u>
Figura 2.1 - Evolução da resolução espacial demonstradas a partir de recortes de imagens do mesmo local obtidas por 3 sensores diferentes. Conforme a resolução espacial da imagem aumenta, a escala de objetos discerníveis diminui. A. Landsat ETM+. B. ATLAS. C. QuickBird.....	8
Figura 2.2 - Resposta espectral das bandas pancromática e multiespectrais do sensor WorldView-2.	9
Figura 2.3 - Esquema da classificação orientada a objetos com dependência hierárquica subordinada ao conhecimento adquirido.	12
Figura 3.1 - Área de estudo.	21
Figura 3.2 - Fluxograma dos procedimentos metodológicos.	24
Figura 3.3 - Pontos de controle pré-selecionados.	26
Figura 3.4 - GPCs pré-selecionados na imagem pancromática WorldView-2. A: quina de borda de piscina. B: faixa de sinalização de trânsito. C: demarcação de quadra esportiva. D: quina de calçada.	27
Figura 3.5– D-GPS e RBMC. A e B: D-GPS Hiper Topcon na função Rover. C: estação RBMC SAT 91537.	29
Figura 3.6 - Representação da altitude ortométrica, geoidal e elipsoidal.....	30
Figura 3.7 - Correção geométrica.	31
Figura 3.8 – Fusão. A: imagem Pancromática World View-2. B: imagem Multiespectral WorldView-2. C: imagem Fusionada World View-2 pelo método de fusão Gram-Schmidt Pan Sharpening com reamostragem por vizinho mais próximo.	32
Figura 3.9 - Vetorização quadras e ruas.	33
Figura 3.10 - Quadras ordenadas.	34
Figura 3.11 - Reconhecimentos dos alvos urbanos em campo através de visão panorâmica. A: Quadra 3, onde está localizado o Parque Vicentina Aranha, predomínio de alvos naturais. B: Quadra 7, onde está localizado o condomínio Jardim Apollo, predomínio de ocupação residencial. C: Quadra 15, predomínio de prédios. D: Quadra 20, com predomínio de alvos metálicos.	35
Figura 3.12 - Conjunto de objetos extraídos manualmente.	38

Figura 3.13 - Níveis de segmentação. A: Nível 1: superobjetos quadras e ruas. B: Nível 2: objetos permeáveis e impermeáveis. C: Nível 3: identificação dos objetos urbanos. D: Nível 4: subclasses dos objetos urbanos.....	44
Figura 3.14 - 1º nível de segmentação.....	45
Figura 3.15 - Classificação Quadras e Ruas.....	46
Figura 3.16 - Recortes representativos da área de estudo. A: área com vegetação. B: área residencial. C: área com prédios. D: áreas metálicas.	47
Figura 3.17 - Classificação das quadras por tipo de predomínio dos alvos.	48
Figura 3.18 - Segmentação nível 2.	49
Figura 3.19 - Segmentação nível 3.	50
Figura 3.20 - Segmentação nível 4.	50
Figura 3.21 - Segmentação nível 5.	52
Figura 3.22 – Resultados das diferentes segmentações. A: Segmentação nível 4 (fina). B: Segmentação nível 5 (diferença espectral).....	52
Figura 3.23 - Conjunto amostral de treinamento.	58
Figura 3.24 - Verdade de campo ilustrada para quadra 1.	60
Figura 3.25 - Parâmetros ajustáveis na mineração de dados. A: plataforma eCognition, algoritmo CART. B: plataforma WEKA, algoritmo C4.5.	62
Figura 3.26 - Conjunto amostral de avaliação preliminar.	64
Figura 4.1 - Comparação das árvores de decisão geradas pelos algoritmos CART e C4.5.	70
Figura 4.2 - Árvore de decisão gerada pelo algoritmo CART com M=3.....	71
Figura 4.3 - Árvore de decisão gerada pelo algoritmo C4.5 com M=3.....	72
Figura 4.4 - Classificação da cobertura do solo urbano da imagem WorldView-2 utilizando pelo algoritmo CART com M=3.	74
Figura 4.5 - Classificação da cobertura do solo urbano da imagem WorldView-2 utilizando pelo algoritmo C4.5 com M=3.	75
Figura 4.6 - Mapa de concordância das classificações CART e C4.5 com M=3.....	77
Figura 4.7 - Gráfico de concordância de classe entre os objetos classificados pelos modelos de árvore de decisão a partir dos algoritmos CART e C4.5, com M=3.....	78
Figura 4.8 - Mapa de concordância por classes entre CART e C4.5 com M=3.	79
Figura 4.9 - Gráfico de concordância por classe entre os objetos classificados pelos modelos de árvore de decisão a partir dos algoritmos CART e C4.5, com M=3.....	80

Figura 4.10 - Comparação das acurácias obtidas nas classificações a partir dos algoritmos CART e C4.5, com M=3.....	81
Figura 4.11 - Matriz de confusão da classificação com o algoritmo CART, com M=3.	81
Figura 4.12 - Matriz de confusão da classificação com o algoritmo C4.5, com M=3....	82
Figura 4.13 - Comparação das profundidades das árvores de decisão geradas pelos algoritmos CART e C4.5.....	83
Figura 4.14 - Árvore de decisão gerada pelo algoritmo CART com M=10.....	85
Figura 4.15 - Árvore de decisão gerada pelo algoritmo C4.5 com M=10.....	86
Figura 4.16 - Classificação da cobertura do solo urbano da imagem WorldView-2 utilizando o algoritmo CART com M=10.....	88
Figura 4.17 - Classificação da cobertura do solo urbano da imagem WorldView-2 utilizando o algoritmo C4.5 com M=10.....	89
Figura 4.18 - Mapa de concordância das classificações CART e C4.5 com M=10.....	91
Figura 4.19 - Gráfico de concordância de classe entre os objetos classificados pelos modelos de árvore de decisão a partir dos algoritmos CART e C4.5, com M=10.....	92
Figura 4.20 - Mapa de concordância por classe entre CART e C4.5 com M=10.	93
Figura 4.21 - Gráfico de concordância por classe entre os objetos classificados pelos modelos de árvore de decisão a partir dos algoritmos CART e C4.5, com M=10.....	94
Figura 4.22 - Comparação das acurácias obtidas nas classificações a partir dos algoritmos CART e C4.5, com M=10.....	95
Figura 4.23 - Matriz de confusão da classificação com o algoritmo CART, M=10.	95
Figura 4.24 - Matriz de confusão da classificação com o algoritmo C4.5, M=10.	96
Figura 4.25 - Atributos simples selecionados no teste M=3.	98
Figura 4.26 - Atributos customizados selecionados no teste M=3.....	98
Figura 4.27 - Atributos simples selecionados no teste M=10.	102
Figura 4.28 - Atributos customizados selecionados no teste M=10.....	102

LISTA DE TABELAS

	<u>Pág.</u>
Tabela 3.1 - Classes identificadas na área de estudo.....	36
Tabela 3.2 - Classes do solo urbano separadas por seus níveis hierárquicos de segmentação.....	39
Tabela 3.3 - Chave de interpretação de classes de cobertura do solo.....	40
Tabela 3.4 - Chave de interpretação de classes classificadas manualmente.....	43
Tabela 3.5 - Parâmetros de segmentação multirresolução nível 1.....	45
Tabela 3.6 - Parâmetros de segmentação multirresolução níveis 2, 3 e 4.....	49
Tabela 3.7 - Parâmetros utilizados na segmentação de Diferença Espectral.....	51
Tabela 3.8 - Número de objetos criados por nível de segmentação.....	53
Tabela 3.9 - Índices de vegetação.....	54
Tabela 3.10 - Índices de água.....	55
Tabela 3.11 - Índices geológicos.....	56
Tabela 3.12 - Índices sugeridos por Leonardi (2010).....	56
Tabela 3.13 - Índices criados para o WorldView-2 (WOLF, 2012).....	57
Tabela 3.14 - Índices para destacar alvos argilosos.....	57
Tabela 3.15 - Número de amostras por classe.....	59
Tabela 4.1 - Área e número de amostras de validação por classe do modelo de árvore de decisão do algoritmo CART com M=3.....	65
Tabela 4.2 - Área e número de amostras de validação por classe do modelo de árvore de decisão do algoritmo C4.5 com M=3.....	66
Tabela 4.3 - Área e número de amostras de validação por classe do modelo de árvore de decisão do algoritmo CART com M=10.....	66
Tabela 4.4 - Área e número de amostras de validação por classe do modelo de árvore de decisão do algoritmo C4.5 com M=10.....	67
Tabela 4.5 - Atributos selecionados pelo algoritmo CART com M=3 para separação das classes de cobertura do solo urbano.....	100
Tabela 4.6 - Atributos selecionados pelo algoritmo C4.5 com M=3 para separação das classes de cobertura do solo urbano.....	101

Tabela 4.7 - Atributos selecionados pelo algoritmo CART com M=10 para separação das classes de cobertura do solo urbano.....	103
Tabela 4.8 - Atributos selecionados pelo algoritmo C4.5 com M=10 para separação das classes de cobertura do solo urbano.....	104

LISTA DE SIGLAS E ABREVIATURAS

ARFF	<i>Attribute-Relation File Format</i> . Formato do arquivo relacionado ao atributo
ARVI	<i>Atmospherically Resistant Vegetation Index</i> . Índice de vegetação resistente à atmosfera
BD	Banco de dados
CART	<i>Classification And Regression Trees</i> . Árvores de classificação e regressão
CIRETRAN	Circunscrição Regional de Trânsito
EVI	<i>Enhanced Vegetation Index</i> . Índice de realce da vegetação
GEOBIA	<i>Geographic Object-Based Image Analysis</i> . Análise de imagens baseada em objeto geográfico
GCP	<i>Ground Control Points</i> . Pontos de controle de campo
GNDVI	<i>Green Normalized Difference Vegetation Index</i> . Índice de vegetação por diferença normalizada verde
GNSS	<i>Global Navigation Satellite Systems</i> . Sistemas globais de navegação por satélite
GPL	<i>General Public Licence</i> . Licença pública geral
GPS	<i>Global Positioning System</i> . Sistema de posicionamento global
GRVI	<i>Green Ratio Vegetation Index</i> . Índice de vegetação por razão verde
IBGE	Instituto Brasileiro de Geografia e Estatística
ID3	<i>Interactive Dichotomizer 3</i> . Dicotomia interativa 3
INPE	Instituto Nacional de Pesquisas Espaciais
IOR	<i>Iron Oxide Ratio</i> . Razão de óxido de ferro
KDD	<i>Knowledge Discovery Databases</i> . Descoberta de conhecimento em banco de dados
M	Número mínimo de amostras por folha de árvore de decisão
ND	Número digital
NDBI	<i>Normalized Difference Built-Up Index</i> . Índice de construção por diferença normalizada
NDSI	<i>Normalized Difference Soil Index</i> . Índice de solo por diferença

	normalizada
NDVI	<i>Normalized Difference Vegetation Index</i> . Índice de vegetação por diferença normalizada
NDWI	<i>Normalized Difference Water Index</i> . Índice de água por diferença normalizada
NHFD	<i>Non-Homogeneous Feature Difference</i> . Diferença de atributo não homogênea
NII WV-2	<i>WorldView-2 New Iron Index</i> . Novo índice de ferro WorldView-2
PCA	<i>Principal Component Analysis</i> . Análise por componentes principais
RBMC	Rede Brasileira de Monitoramento Contínuo
SAVI	<i>Soil Adjusted Vegetation Index</i> . Índice de vegetação ajustado ao solo
SGB	Sistema Geodésico Brasileiro
SIG	Sistema de Informação Geográfica
SR	<i>Simple Ratio Index</i> . Índice por razão simples
UTM	<i>Universal Transversa de Mercator</i> .
WEKA	<i>Waikato Environment for Knowledge Analysis</i> . Ambiente waikato para análise do conhecimento

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
1.1. Justificativa	3
1.2. Objetivos	5
1.2.1. Objetivo Geral.....	5
1.2.2. Objetivos Específicos	5
2 FUNDAMENTAÇÃO TEÓRICA.....	7
2.1. Sensoriamento Remoto Urbano.....	7
2.2. Análise de Imagem Baseada em Objeto Geográfico - GEOBIA	10
2.2.1. Segmentação	12
2.2.2. Rede semântica.....	14
2.3. Mineração de dados	15
2.3.1. Árvore de Decisão	16
2.3.2. Algoritmos baseados em árvore de decisão e árvore de regressão	16
2.3.3. Algoritmo C4.5.....	17
2.3.4. Algoritmo CART: Árvores de Classificação e Regressão (Classification and Regression Trees)	18
3 MATERIAL E MÉTODOS.....	21
3.1. Área de estudo	21
3.2. Material.....	22
3.2.1. Dados	22
3.2.2. Softwares	22
3.2.3. Equipamentos.....	23
3.3. Metodologia	23
3.4. Ortorectificação	25
3.5. Fusão	31
3.6. Classes da cobertura do solo urbano.....	33
3.7. Segmentação Multirresolução.....	43
3.8. Segmentação Diferença Espectral.....	51
3.9. Cálculo dos Atributos.....	53
3.10. Coleta de amostras.....	58

3.11. Mineração de Dados.....	60
3.12. Classificação da cobertura do solo urbano	62
3.13. Avaliação das árvores de decisão	63
4 RESULTADOS E DISCUSSÃO.....	69
4.1. Análise dos modelos de árvores de decisão testados.....	69
4.1.1.Avaliação preliminar da acurácia dos modelos de árvores de decisão testados	69
4.1.2.Análise da complexidade dos modelos de árvores de decisão testados	82
4.1.3.Análise dos atributos dos modelos de árvores de decisão selecionados	97
5 CONCLUSÃO	105
REFERÊNCIAS BIBLIOGRÁFICAS.....	107
APÊNDICE A - ÁRVORES DE DECISÃO GERADAS PELO ALGORITMO C4.5	113
APÊNDICE B - ÁRVORES DE DECISÃO GERADAS PELO ALGORITMO CART..	127

1 INTRODUÇÃO

Nas últimas três décadas, houve uma grande mudança na forma de analisar imagens de sensoriamento remoto (HAY; BLASCHKE, 2010). Este desenvolvimento ocorreu devido aos novos desafios impostos pela disponibilização de imagens orbitais que apresentam maiores resoluções espaciais, espectrais, radiométricas e temporais. O aumento do conteúdo informativo da imagem tornou bastante complexa a automação do processo de extração de informação, exigindo dos usuários novas abordagens para a sua análise (FRANCISCO; ALMEIDA, 2012), bem como novas ferramentas para explorá-las adequadamente (HAY; CASTILLA, 2008).

As mudanças metodológicas na classificação automática de imagens podem ser resumidas em três grandes fases. Primeiramente considerando o valor individual de cada pixel, para rotulá-lo a uma dada classe; em seguida, agregando pixels em regiões, e finalmente, na terceira fase, os pixels são agrupados, formando objetos que se relacionam com outros objetos, em uma estrutura hierárquica, onde não apenas o número digital (ND) dos pixels é considerado, mas também a maneira como os seres humanos interpretam a paisagem através de informações foto interpretativas como textura, forma, vizinhança, contexto e tamanho, por meio de modelos de conhecimento expressos por redes semânticas (HAY; BLASCHKE, 2010; HAY; CASTILLA, 2008; PINHO, 2005; CHEN et al., 2009).

Este novo paradigma, passa a se difundir na comunidade de sensoriamento remoto principalmente como metodologia de classificação de imagens de alta resolução espacial, onde recebe o nome de GEOBIA, análise de imagens baseada em objeto geográfico (Geographic Object-Based Image Analysis) (FRANCISCO; ALMEIDA, 2012; HAY; CASTILLA, 2008).

Em 1982, Welch afirma que a resolução espacial dos sistemas sensores até então disponíveis era o fator técnico limitante para o progresso de estudos de sensoriamento remoto urbano. Passadas duas décadas, os sensores de

satélites imageadores se encontram em sua Terceira Geração permitindo que este antigo entrave seja ultrapassado por apresentar melhores resoluções espaciais as quais passam a compreender desde a alta (4 m) até a ultra alta resolução (0,31 cm) abrindo, portanto, novos caminhos para se explorar a complexidade espacial do fenômeno urbano (SOUZA et al., 2003; ALMEIDA, 2010).

O lançamento do sistema sensor orbital WorldView-2 representa um marco para estudos intraurbanos. A combinação de suas quatro novas bandas espectrais, com sua alta resolução espacial e radiométrica, quando associadas a classificadores orientados a objeto ampliou sobremaneira a capacidade de discriminação dos alvos terrestres que possuem comportamento espectral muito semelhante (PINHO, 2005; RIBEIRO et al., 2011).

As imagens deste sistema sensor são de grande aplicabilidade em mapeamentos detalhados de cobertura e uso do solo urbano, como desastres naturais em cidades, simulação e predição do crescimento urbano, planejamento de infraestrutura, inferências de contagem e densidade populacional, análise de adequabilidade de sítio, propósitos sociais, entre outras (RINDFUSS; STERN, 1998; PINHO, 2005; ALMEIDA, 2010; NOVACK et al., 2014).

Diante deste novo cenário, no qual um grande número de satélites com sistemas sensores de alta resolução espacial, orbita ao redor do nosso planeta, executando contínuo imageamento das superfícies do solo, oceanos e atmosfera, há uma produção contínua de grandes volumes de dados.

Em contrapartida aos avanços na geração de dados, a coleta dessas informações traz alguns obstáculos devido às dificuldades encontradas em seu armazenamento e métodos de processamento (DONNAY et al., 2001; TAN et al., 2009). Ainda, frente ao tamanho e a natureza espaço-temporal desses novos tipos de dados, a extração de informação é bastante desafiadora. Na medida em que aumenta a quantidade de dados gerados, aumentam também

as oportunidades dos pesquisadores de identificar padrões que regem o mundo físico (TAN et al., 2009; WITTEN et al., 2011).

No entanto, métodos tradicionais muitas vezes não são mais apropriados para analisar dados tão volumosos, conduzindo à necessidade de buscar novas técnicas e ferramentas (HAY; CASTILLA, 2008; TAN et al., 2009). O processo da mineração de dados vem na vanguarda das tecnologias analisar de forma inteligente os bancos de dados complexos, auxiliando os cientistas a fazerem previsões não triviais, as quais, sem o seu uso, poderiam não ocorrer (TAN. et al., 2009; WITTEN et al., 2011).

Algoritmos de árvore de decisão têm sido amplamente utilizados como ferramenta de mineração de dados. Sua ampla escolha deve-se ao fato de o seu processamento não requerer quantidade significativa de tempo, possuir um modelo de fácil compreensão, ter regras de classificação simples, que não requerem suposições sobre distribuições estatísticas nem com a independência de classes, além do fato de seus atributos representativos serem facilmente identificados e representados de forma numérica e categórica (AKSOY et al., 2004; KÖRTING et al., 2013; PINHO et al., 2008).

Uma classe de algoritmos é a baseada na indução de árvores de decisão. Exemplos incluem o algoritmo C4.5 (QUINLAN, 1993) e o algoritmo CART (*Classification And Regression Trees*) (BREIMAN et al., 1984) os quais estão entre os mais conhecidos da comunidade científica (QUINLAN, 1993; MOHRI, 2011; WU; KUMAR, 2009; RAMAKRISHNAN, 2009).

1.1. Justificativa

Embora o paradigma GEOBIA inclua poderosas ferramentas para simular a visão contextual de um intérprete humano, através das redes semânticas e múltiplos níveis de classificação interligados, ele impõe desafios para o usuário.

Em função do grande número de atributos disponíveis para a descrição do comportamento dos objetos frente às classes de interesse, somado à

possibilidade de se criar atributos customizados, a tarefa de modelar a rede semântica se torna muito difícil para o analista humano devido à sua complexidade e longo período para sua realização, além da exigência do conhecimento prévio da cena (ALMEIDA, 2010; PINHO et al., 2008).

Neste momento, o uso das técnicas de mineração de dados atua como recurso metodológico tanto no processo de seleção rápida dos melhores atributos para descrição de cada classe, como na construção da rede semântica (PINHO et al., 2008) derivada da adaptação de uma árvore de decisão.

À vista do panorama apresentado, pode-se afirmar que a capacidade de exploração dos dados coletados até agora não acompanhou as informações potencialmente presentes nos mesmos. No entanto, trabalhos recentes na literatura demonstram que os especialistas em sensoriamento remoto encontraram na GEOBIA e na mineração de dados as chaves para a interpretação dos dados provenientes dos sistemas sensores de alta resolução.

O uso do algoritmo C4.5 tem produzido bons resultados em grande número de trabalhos na área de classificação de imagens de sensoriamento remoto, como ferramenta de apoio para gerar a árvore de decisão, que é convertida para rede semântica no ambiente de GEOBIA (PINHO et al., 2008).

Dentre estes trabalhos, pode-se citar Silva et al. (2007), Pinho et al. (2008), Novack (2009), Leonardi (2010), Vieira (2010), Carvalho (2011), Pinho et al. (2012), Formaggio et al. (2012), Ribeiro e Fonseca (2013), Rodrigues (2014).

Dessa forma, este trabalho tem por objetivo contribuir com o sensoriamento remoto através da análise do desempenho de dois mineradores de dados, amplamente utilizados na atualidade, árvore de decisão e árvore de regressão, tendo como base para esta análise uma área teste do município de São José dos Campos- SP a partir da imagem de alta resolução espacial do sistema sensor orbital WorldView-2.

Tomando como base a seguinte premissa:

- A utilização de mineradores de dados auxilia na construção da rede semântica a partir das árvores de decisão geradas por eles e reduz o longo tempo gasto pelo analista na sua elaboração.

O presente estudo parte da seguinte hipótese:

- Os mineradores de dados C4.5 e CART podem ser equivalentes quanto aos seus desempenhos na classificação da cobertura do solo urbano.

1.2. Objetivos

1.2.1. Objetivo Geral

O principal objetivo deste trabalho é analisar o desempenho dos algoritmos de árvore de decisão e árvore de regressão para a classificação da cobertura do solo urbano, a partir de imagens orbitais de alta resolução espacial.

1.2.2. Objetivos Específicos

- Comparar a estrutura das árvores de decisão geradas a de partir dos mineradores de dados C4.5 e CART.
- Comparar os atributos escolhidos para melhor separabilidade dos alvos;
- Comparar as classificações geradas pelos dois algoritmos.

2 FUNDAMENTAÇÃO TEÓRICA

2.1. Sensoriamento Remoto Urbano

Paisagens urbanas são estruturas complexas, compostas por um conjunto diversificado de materiais naturais (água, vegetação, etc.) e artificiais (asfalto, concreto, telhas, metais, etc.) dispostos de forma intrincada pelo homem (SMALL, 2004; SOUZA, 2012).

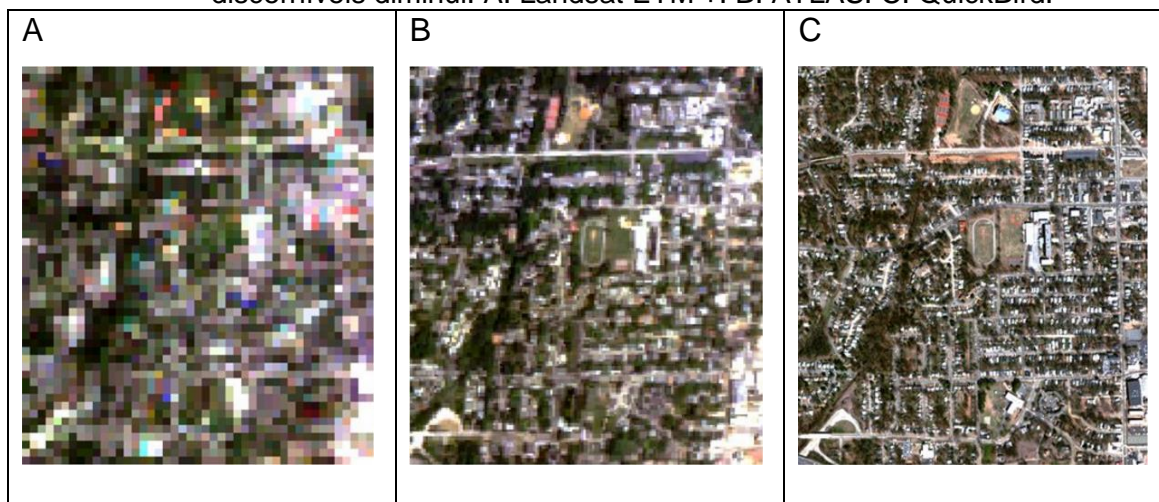
Informações sobre a cobertura e uso do solo em ambientes urbanos são necessárias para uma grande variedade de aplicações voltadas para o planejamento urbano. Dentre elas podemos citar a escolha de locais apropriados para instalações residenciais, industriais e comerciais, estimativas ou inferências espaciais, cobrança tributária, elaboração de regulamentos para zoneamento, entre outras (CULLINGWORTH, 1997; WILSON et al., 2003; SOUZA, 2012).

Dessa forma, é de suma importância para a gestão urbana ter conhecimento sobre os materiais biofísicos encontrados sobre a superfície terrestre, para compreender o ambiente no qual a cidade está inserida e assim elaborar, com base neste ambiente, um conjunto de ações orientadas, tanto em nível urbano quanto regional (JENSEN, 2011).

Para se entender o comportamento da dinâmica das cidades, é possível utilizar técnicas de extração de informações de imagens de sensoriamento remoto para a geração de mapas de uso e cobertura do solo urbano. Essas técnicas possibilitam ao analista conhecer a paisagem de forma ampliada, pois torna visíveis informações que sem essas ferramentas não seria possível, como por exemplo as informações extraídas a partir do infravermelho termal. Assim, diante da possibilidade de se observar os efeitos das ações humanas sobre o espaço, torna-se possível monitorar mudanças e fazer análises sobre o território, auxiliando no desenvolvimento de estratégias para gerenciá-lo (SOUZA, 2012).

O maior obstáculo na utilização das imagens orbitais em estudos urbanos estava anteriormente relacionado à baixa resolução espacial das imagens. Entretanto, avanços na tecnologia de sensoriamento remoto orbital trouxeram melhorias na resolução espacial das imagens, permitindo progressos nesses estudos, uma vez que se ampliou a capacidade de discriminação dos alvos terrestres em diferentes escalas (COWEN; JENSEN, 1998; DONNAY et al., 2001). Os avanços nos sensores também se estenderam à resolução espectral, radiométrica e temporal, contribuindo ainda mais para a extração de informações detalhadas do ambiente urbano (Figura 2.1) (PINHO, 2005; RIBEIRO et al., 2011).

Figura 2.1 - Evolução da resolução espacial demonstradas a partir de recortes de imagens do mesmo local obtidas por 3 sensores diferentes. Conforme a resolução espacial da imagem aumenta, a escala de objetos discerníveis diminui. A. Landsat ETM+. B. ATLAS. C. QuickBird.

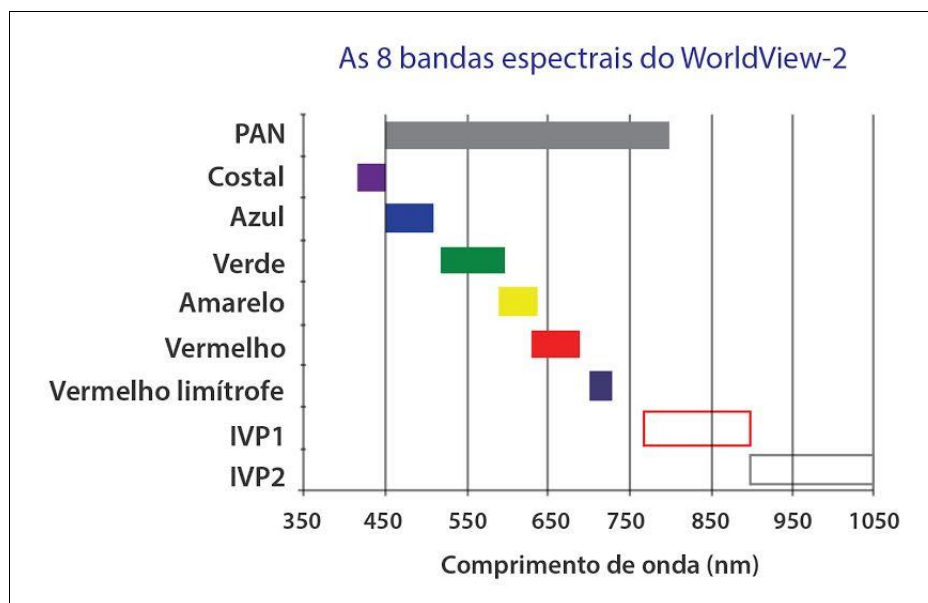


Fonte: Adaptada de NCRST-E (2009).

Lançado em 2009, WorldView-2 foi o primeiro satélite comercial de alta resolução espectral a operar com oito bandas multiespectrais e uma banda pancromática (Figura 2.2). Sua melhora na resolução espectral se dá pela adição de quatro novas bandas localizadas em faixas específicas do espectro eletromagnético, sendo elas costal (coastal) (400-450 nm), amarela (yellow) (585-625 nm), vermelho limítrofe (red edge) (705-745 nm) e infravermelho próximo 2 (near infrared 2) (860-1040 nm). Este sistema sensor fornece

resolução espacial de 0,46 m na banda pancromática e 1,85 m nas bandas multiespectrais, resolução radiométrica de 11 bits e resolução temporal média de 1,1 dia (DIGITAL GLOBE, 2010).

Figura 2.2 - Resposta espectral das bandas pancromática e multiespectrais do sensor WorldView-2.



Fonte: Adaptada pelo autor (Digital Globe, 2010).

A disponibilização de imagens do sensor WorldView-2 permitiu uma melhor separabilidade das classes de cobertura urbana graças a combinação de suas novas bandas espectrais com sua alta resolução espacial e radiométrica (DIGITAL GLOBE, 2010; PINHO, 2005; RIBEIRO et al., 2011; RODRIGUES, 2014).

Em virtude da maior quantidade de detalhes na cena, os objetos de interesse no ambiente intraurbano ficaram maiores do que os pixels dessas imagens, resultando em uma grande variabilidade interna do número digital (ND) dos pixels dentro de uma mesma classe (PINHO, 2005; RODRIGUES, 2014). Neste sentido, a técnica de análise de imagens baseada em objeto, em que a unidade mínima de análise passa a ser o agrupamento de pixels com características afins, designado de objeto, representou uma solução viável para essas

limitações (HAY; CASTILLA, 2008). Ainda, o agrupamento de pixels na criação de objetos simplifica de forma substancial os problemas presentes na classificação de imagens, reduzindo-os de milhares de pixels a apenas alguns objetos (NAVULUR, 2007).

2.2. Análise de Imagem Baseada em Objeto Geográfico - GEOBIA

Os modelos de processamento de imagens baseado em espectros dos pixels seguido pelo modelo de agrupamento de pixels em regiões, predominaram por mais de vinte anos na comunidade de sensoriamento remoto. Diante do novo cenário de imagens de alta resolução difunde-se, na década de 90 e 2000, uma nova forma de explorar as imagens de sensoriamento remoto, baseada no objeto (HAY; BLASCHKE, 2010).

A distinção das feições urbanas de interesse torna-se possível através da incorporação deste novo paradigma o qual, permite criar objetos agrupando não só pixels com características espectrais e espaciais similares, mas também leva em conta outros atributos como, forma, tamanho e contexto dos objetos na classificação das imagens de sensores remotos (PINHO, 2005).

A análise de imagem baseada em objeto geográfico é, portanto, uma subdisciplina da Geoinformática, que se dedica ao desenvolvimento de métodos automáticos para extrair atributos significativos a partir de imagens de sensoriamento remoto para dividi-las em objetos, bem como avaliar suas características através de escalas espaciais, espectrais e temporais. Seu objetivo principal é a geração de novas geointeligências a partir de conjuntos de dados multifonte relacionados (HAY; BLASCHKE, 2010; HAY et al., 2014).

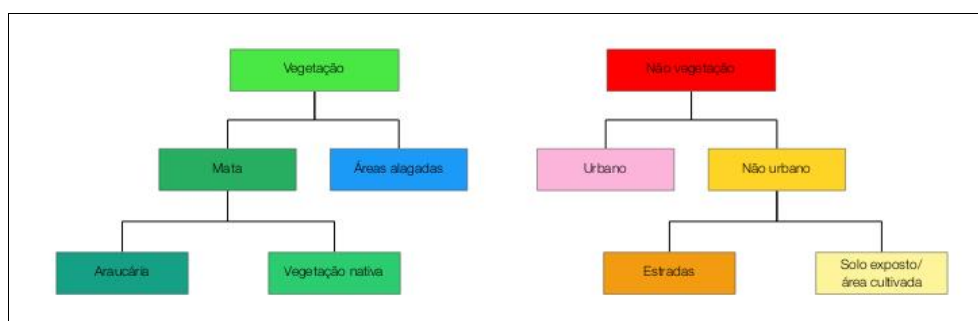
Esta abordagem permite que se tire vantagem de mais dimensões do sensoriamento remoto, levando ao aumento do poder do intérprete na análise de imagens, através do uso de novas ferramentas SIG, para se extrair mais informações. Dentre as dimensões para a extração de informações destacam-se (NAVULUR, 2007):

- Espectral: bandas multiespectrais, incluindo banda pancromática. Possibilidade de cálculo da média e do desvio padrão, análise por componentes principais (Principal Component Analysis- PCA), entre outros;
- Espacial: área do objeto, comprimento, largura, direção;
- Morfológica: parâmetros de forma;
- Textura;
- Contextual: relação aos vizinhos, análise de proximidade;
- Temporal: séries temporais.

Essa nova disciplina é fundamentada em métodos supervisionados não-paramétricos de classificação, ou seja, não infere em nenhuma distribuição estatística conhecida para descrever o comportamento dos dados. Seu grande diferencial está no pressuposto de a GEOBIA tem seu modelo de conhecimento atrelado ao processo de interpretação humana da cena (FRANCISCO; ALMEIDA, 2012) o qual simula a forma como os seres humanos conceitualmente organizam a paisagem para compreendê-la. Este é realizado através da definição de um conjunto de classes de interesse que são organizadas através das redes semânticas, podendo haver múltiplos níveis de classificação interligados.

Gonçalves et al. (2007) ilustra a classificação hierárquica com uma estrutura de classes e superclasses por meio de uma dependência subordinada ao conhecimento adquirido, formada por regras booleanas oriundas das propriedades que compõe os objetos (Figura 2.3).

Figura 2.3 - Esquema da classificação orientada a objetos com dependência hierárquica subordinada ao conhecimento adquirido.



Fonte: Adaptado de Gonçalves et al. (2007).

Neste estudo, apenas alguns recursos comumente empregados em GEOBIA serão utilizados.

2.2.1. Segmentação

A segmentação é o processo de particionamento da imagem em regiões homogêneas que, geralmente, representam objetos de interesse (DESCLÉE et al., 2006).

Na GEOBIA, a segmentação de imagens é a técnica utilizada para derivar as unidades básicas da imagem, os objetos. Estes são definidos como sendo uma região discreta internamente coerente e diferente de seus arredores, que são potencialmente representados individualmente ou em conjunto com outros vizinhos (HAY; CASTILLA, 2008a). Hay e Castilla (2008) caracterizam uma boa segmentação como aquela que não supersegmenta nem subsegmenta, sem a necessidade de ajuste fino excessivo nos parâmetros de entrada.

Uma vez que os objetos serão associados as classes da imagem, este pode ser entendido como a instância de uma classe, a qual representa um conjunto de objetos com características afins, denominados atributos. Já as funções para manipulá-los ou retratar seu comportamento são chamadas de métodos.

Neste trabalho, são utilizados dois segmentadores disponíveis no *software* eCognition. Comumente, o termo segmentação significa dividir algo em

partições menores. Porém, nesta plataforma, segmentação é qualquer operação que cria novos objetos de acordo com dois princípios básicos. O primeiro princípio adota uma estratégia top-down, de cima para baixo, na qual objetos grandes são subdivididos em objetos menores. Já o segundo adota a estratégia bottom-up, de baixo para cima, no qual pequenos objetos são unidos gerando objetos maiores. Isto significa que uma segmentação pode ser uma operação de subdivisão, fusão ou de reconfiguração dos objetos (TRIMBLE, 2016).

Um dos algoritmos de segmentação utilizados neste estudo trata-se do segmentador denominado Multirresolução (Baatz; Schäpe, 2000). Este algoritmo cria segmentos na imagem com base em cinco critérios, referentes à escala, cor, forma, suavidade e compacidade, sendo que o primeiro determina a heterogeneidade dos objetos, e os quatro últimos, a sua homogeneidade. Eles podem ser combinados de várias formas para que o usuário possa criar objetos homogêneos em qualquer resolução escolhida (NAVULUR, 2007).

O tamanho dos objetos da imagem pode ser alterado através da variação do valor do parâmetro de escala. Este determina a heterogeneidade máxima permitida dentro de um objeto. Ao aumentar o parâmetro de escala, há uma queda significativa do número de objetos o que, conseqüentemente, diminui o tamanho do arquivo gerado e, portanto, seu tempo de processamento (NAVULUR, 2007).

No quesito homogeneidade do objeto os pares a cor e a forma, compacidade e suavidade atuam de maneira complementar, ou seja, num total de 1, ao dar peso 0,4 para cor a forma recebe automaticamente peso 0,6. A homogeneidade da cor é baseada no desvio padrão das cores espectrais. Este parâmetro define com qual porcentagem os valores espectrais irão contribuir para todo o critério de homogeneidade, portanto, não é possível dar um peso maior que 0,9 para o parâmetro forma, pois assim anularia a informação espectral da imagem. A homogeneidade do objeto pode ser otimizada utilizando o critério de compacidade. Este deve ser usado quando os objetos

da cena são bastante compactos porém não são separados dos objetos não compactos que apresentam pouco diferença de contraste espectral (TRIMBLE, 2011b).

O segmentador multirresolução permite a criação de múltiplos níveis de segmentação. A criação de objetos em várias escalas é uma das vantagens da abordagem baseada em objeto. Os objetos das múltiplas escalas se relacionam preservando as relações de herança (parent-child) na construção de uma rede hierárquica de objetos da imagem. Desta maneira uma classe (subclasse) pode herdar de outra classe (superclasse) seus comportamentos (métodos) e variáveis possíveis (atributos) (BAATZ; SCHÄPE, 2000; FRANCISCO; ALMEIDA, 2012; HOFMANN, 2001; HOFMANN e REINHARDT, 2000; NAVULUR, 2007; PINHO, 2005). Neles, os níveis de segmentação podem ser mais finos ou mais grosseiros. Cada nível de segmentação está de acordo com os objetos de interesse de cada escala de detalhamento.

O segundo algoritmo de segmentação utilizado neste estudo se refere ao algoritmo Diferença Espectral (Spectral Difference). Este algoritmo foi desenvolvido para refinar resultados de uma segmentação produzida anteriormente através da fusão de objetos vizinhos de uma imagem que apresentam respostas espectrais semelhantes. Os objetos são unidos quando a diferença entre as suas intensidades espectrais médias forem menores que o valor dado no parâmetro de máxima diferença espectral (TRIMBLE, 2011a).

2.2.2. Rede semântica

A rede semântica representa o conhecimento humano por meio de um conjunto de nós conectados por arcos. Sua construção pode ser realizada de forma heurística, onde o usuário testa interativamente os descritores, as funções e os limiares para a discriminação das classes, ou de forma automática, através da transposição adaptada de uma árvore de decisão (FRANCISCO; ALMEIDA, 2012).

Diante do grande número de atributos disponíveis para a rotulação dos objetos às classes de interesse, as técnicas de mineração de dados auxiliam o analista na definição dos melhores atributos para separar essas classes.

2.3. Mineração de dados

Mineração de dados é definida como o processo de descoberta de padrões de dados. O processo deve ser automático ou, mais usualmente, semiautomático e os padrões devem ser significativos na medida em que levam a algum avanço no ganho de informações através da análise dos dados disponíveis em quantidades substanciais (WITTEN et al., 2011).

A mineração de dados é uma tecnologia que combina métodos tradicionais de análise de dados com algoritmos sofisticados para processá-los. Ela consiste em uma parte integral da descoberta de conhecimento em banco de dados (Knowledge Discovery in Databases- KDD), processo geral de conversão de dados brutos em informações através de uma série de passos de transformação, de pré-processamento dos dados, estendendo-se até o pós-processamento dos resultados da mineração de dados (TAN et al., 2009).

O propósito do pré-processamento é transformar os dados de entrada brutos em um formato apropriado para análises subsequentes. Os passos envolvidos no pré-processamento de dados incluem a fusão de dados de múltiplas fontes, limpeza dos dados para remoção de ruídos, observações duplicadas, seleção de registros e características que sejam relevantes à tarefa de mineração de dados. Já o pós-processamento assegura que apenas resultados válidos e úteis sejam incorporados ao sistema de apoio a decisões. Nesta etapa podem ser efetuados a visualização, medições estatísticas ou métodos de teste de hipóteses (TAN et al., 2009).

Com os dados de entrada preparados, é possível construir uma árvore de decisão a partir dos mesmos (WITTEN et al., 2011).

2.3.1. Árvore de Decisão

Dentre os algoritmos mais utilizados na mineração de dados, cita-se árvore de decisão, a qual relaciona o conjunto de atributos e o rótulo da classe dos dados de entrada (TAN et al., 2009; MOHRI, 2011).

A estrutura hierárquica da árvore de decisão consiste de nós e arestas direcionadas. Embora algumas das árvores sejam mais precisas que outras, encontrar a árvore ótima é computacionalmente inviável devido ao tamanho exponencial do espaço de pesquisa. Apesar disso, algoritmos eficientes têm sido desenvolvidos para induzir uma árvore de decisão razoavelmente precisa, embora não perfeita, em certo tempo computacional (TAN et al., 2009).

A abordagem geral para construção de um modelo de classificação por árvore de decisão consiste no fornecimento de um conjunto de treinamento cujos rótulos são conhecidos. A partir deste conjunto de treinamento é construído um modelo de classificação, que é posteriormente aplicado ao conjunto-teste, o qual consiste de registros com rótulos de classes desconhecidos (TAN et al., 2009).

Nesse sentido, a técnica de mineração de dados para definição de atributos numa árvore de decisão, será adotada nesta pesquisa com o intuito de indicar de forma automática, dentre os atributos disponíveis, aqueles mais adequados para a caracterização de cada classe de cobertura do solo a ser discriminada e para gerar o modelo de classificação.

Serão utilizados os algoritmos de mineração C4.5 dentro do sistema WEKA e o CART na plataforma eCognition, que empregam uma estratégia crescente numa árvore de decisão.

2.3.2. Algoritmos baseados em árvore de decisão e árvore de regressão

A estratégia de árvore de decisão crescente toma uma série de decisões localmente ótimas sobre qual atributo usar, para particionar os dados. O modelo gerado pelo algoritmo deve se adaptar bem aos dados de entrada e

prever corretamente os rótulos de classe de registros antes considerados. O objetivo chave do algoritmo de aprendizagem é construir modelos com boa capacidade de generalização (TAN et al., 2009).

Estes algoritmos adotam o método que consiste na divisão recursiva do conjunto de observações em subgrupos-filhos, construindo uma árvore da raiz para as folhas. Em cada passo, o algoritmo determina uma regra de classificação, selecionando uma variável em um ponto de corte nos valores dessa variável. O processo de divisão é repetido, até que não seja mais possível encontrar novas variáveis que permitam divisões dos dados estatisticamente significantes, sempre com o objetivo de dividir os dados em grupos homogêneos.

2.3.3. Algoritmo C4.5

ID3 (Iterative Dichotomizer 3) é um método desenvolvido por Quinlan (1986) que consiste em um processo de indução de árvores de decisão. O aprimoramento deste método gerou o algoritmo C4.5 (QUINLAN, 1993).

A construção da árvore é realizada de cima para baixo (top-down), com o objetivo de escolher sempre o melhor atributo para cada nó. Começa-se pela raiz, e aplica-se o mesmo algoritmo aos descendentes desse nó, até que certos critérios de parada sejam verificados. No caso do algoritmo C4.5 seleciona-se um atributo que maximize uma medida de entropia dos nós-filhos em relação ao nó-pai. Nos atributos com valores quantitativos, reordenam-se as instâncias de acordo com esse atributo, e procuram-se pontos extremos nos quais haja uma mudança de valor da classe. Um ponto de mudança de classe marca uma partição binária do conjunto das instâncias, mediante uma condição lógica do tipo $A > x$, sendo A o atributo numérico em causa e x um valor calculado a partir dos dois valores consecutivos de A nesses pontos. A escolha do atributo de partição é concretizada tendo em conta o ganho de informação (RODRIGUES, 2005).

O sistema WEKA, desenvolvido pela Universidade de Waikato na Nova Zelândia, é uma coleção de algoritmos de aprendizagem por máquina e ferramentas de processamento de dados. Seu sistema é escrito em Java e distribuído sob os termos da Licença Pública Geral (GPL- General Public License) (WITTEN et al., 2011). O algoritmo C4.5 foi implementado como o classificador J48 no WEKA. Dentre os parâmetros a serem configurados, destacam-se: o fator de confiança, o número mínimo de instâncias por nó-folha, o número de ramificações, a poda ou não-poda. Estes fatores controlam o tamanho da árvore de decisão através do número mínimo de casos em cada folha (CARVALHO, 2011; VIEIRA, 2010).

2.3.4. Algoritmo CART: Árvores de Classificação e Regressão (Classification and Regression Trees)

Os modelos baseados em árvore são úteis tanto para a classificação como para problemas de regressão. A análise de regressão é um termo genérico que gira em torno da construção de uma previsão a partir de uma amostra de aprendizagem (BREIMAN et al., 1984; NAVULUR, 2007).

Árvores de classificação e regressão (CART) representam o estado da arte em aprendizagem por máquina (TRIMBLE, 2011a). Ela se torna cada vez mais popular devido ao seu alto nível de automação, flexibilidade e capacidade de lidar com um grande número de atributos de entrada (HELLENSEN; MATIKAINEN, 2013).

Elas são calculadas com base em algoritmos de busca (um procedimento iterativo) descritos por Breiman et al. (1984), no qual a regra de divisão é baseada no índice de diversidade Gini. Este índice faz a seguinte pergunta: Qual divisão dicotômica em que a variável de previsão vai melhorar ao máximo a previsibilidade da variável dependente? Para tanta o índice busca encontrar a maior categoria homogênea que minimize a medida de impureza do nó ao máximo de acordo com um critério de otimização local dentro do conjunto de dados e isolá-la da parte restante dos dados. O mesmo ocorre com os nós

subsequentes, até as divisões binárias não serem mais possíveis, ou a árvore atingir uma profundidade máxima pré-determinada (HELLENSEN; MATIKAINEN, 2013; NAVULUR, 2007; RODRIGUES, 2005).

O eCognition Developer, apresenta na sua versão 8.7, lançada em 2011, a implementação do algoritmo CART, com o intuito de complementar seu ambiente de classificação baseado em objeto, afim de detectar com maior autonomia padrões sofisticados de dados para a análise e compreensão dos ecossistemas complexos (TRIMBLE, 2011a).

O método utiliza os dados de treinamento (segmentos) como entrada para a análise CART. Com base na informação dos atributos, é construído um modelo de árvore de classificação (HELLENSEN; MATIKAINEN, 2013).


3 MATERIAL E MÉTODOS

3.1. Área de estudo

A área de estudo localiza-se no município de São José dos Campos, São Paulo, com uma população estimada de 688 mil habitantes, ocupando uma área de 1.099 km² (IBGE, 2016b) (Figura 3.1).

Os bairros da área urbana deste município normalmente são restritos a um único tipo de uso, como residencial, comercial ou industrial. Assim, para a escolha de um setor representativo que abrangesse a maior heterogeneidade possível de alvos urbanos foi necessário abranger três bairros, sendo eles o Jardim Apollo I por possuir parques e áreas residenciais, Vila Jaci pela presença de áreas residenciais de prédios e áreas comerciais e o bairro Jardim São Dimas, o qual abrange em sua maioria áreas comerciais.

Figura 3.1 - Área de estudo.



Fonte: Produção do autor.

3.2. Material

3.2.1. Dados

- 1 cena do sistema imageador WorldView-2 disponibilizada pela empresa Digital Globe contendo uma imagem pancromática (PAN) com resolução espacial de 0,5 m e 8 imagens multiespectrais (MSS) com resolução espacial de 2,5 m representadas por suas bandas (azul, verde, amarelo, vermelho, vermelho limítrofe (VL), infravermelho próximo 1 (IVP1) e infravermelho próximo 2 (IVP2) do tipo *Ortho Ready Standard 2A*, obtidas no dia 24 de fevereiro de 2015 e resolução radiométrica de 11 bits.
- Banco de dados Cidade Viva (PMSJC, 2015): utilização da base digital de quadras.

3.2.2. Softwares

- Topcon Tools versão 8.0: utilizado para descarga e processamento dos dados observados dos receptores D-GPS L1/L2 Topcon Hiper-GGD.
- ProGrid versão 1, IBGE: utilizado na conversão das coordenadas geográficas para UTM.
- MapGeo 2015 versão 1.0, IBGE: conversão das coordenadas elipsoidais em ortométricas.
- PCI Geomatics: ortorretificação das imagens.
- ENVI 5.0: fusão das imagens WorldView-2.
- Spring 4.3.3: exportação dos dados vetoriais de quadras do banco de dados Cidade Viva.
- ArcGIS ArcMap 10.3.1, Esri: edição dos dados vetoriais de quadras, visualização da classificação gerada pelo algoritmo C4.5, elaboração dos mapas.
- eCognition 64 versão 9.0, Trimble: segmentação, extração de atributos e classificação CART.

- R 3.2.2: conversão dos arquivos em formato shapefile para formato CSV e seu retorno ao formato original.
- WEKA: para a mineração de dados visando a seleção dos atributos e geração da árvore de decisão pelo algoritmo C4.5.
- Notepad++ 6.9.2: edição dos arquivos em formato ARFF para formato CSV.

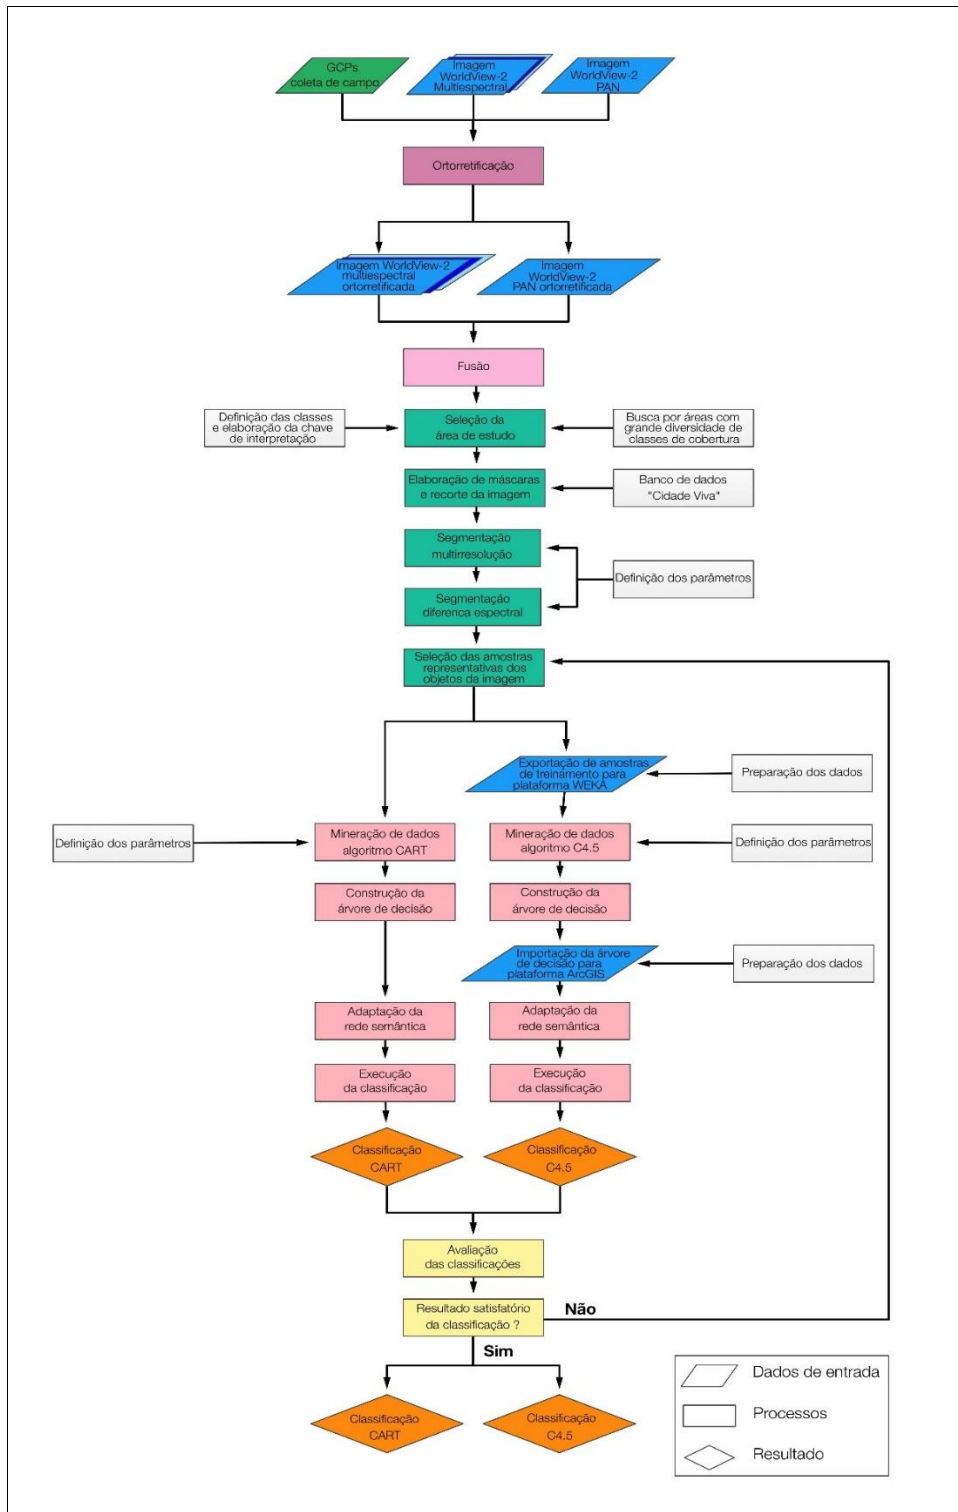
3.2.3. Equipamentos

- 2 receptores D-GPS L1/L2 da marca Topcon, modelo Hiper-GGD, utilizados como base e rover (móvel) para coleta dos pontos de controle de campo.
- 2 bases nivelantes da marca Topcon.
- 3 Tripés e bastão da marca Agrimen, AVR e Allcomp para suporte dos receptores.
- Receptor D-GPS da marca Garmin modelo 12XL para localização dos pontos de controle de campo pré-definidos.
- Trena para cálculo da altura da antena.
- Câmera fotográfica Sony para registro do reconhecimento da área de estudo e do local de coleta dos pontos de controle no terreno.

3.3. Metodologia

Os procedimentos metodológicos utilizados neste trabalho estão detalhados no fluxograma da Figura 3.2.

Figura 3.2 - Fluxograma dos procedimentos metodológicos.



Fonte: Produção do autor.

3.4. Ortorretificação

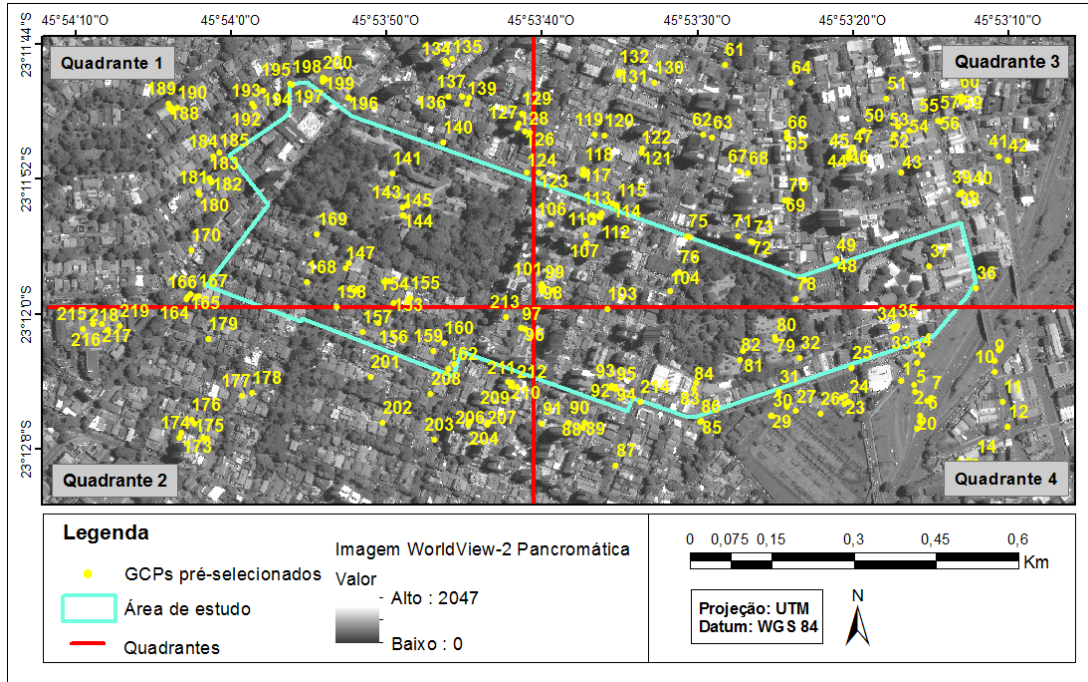
A ortorretificação consiste em corrigir as distorções geométricas inerentes ao processo de geração de imagens orbitais, estabelecendo uma correspondência entre o espaço-imagem e o espaço-objeto.

Apesar da Digital Globe ter fornecido uma imagem WorldView-2 no nível Ortho Ready Standard 2A, a qual já projeta para um plano (Universal Transversa de Mercator - UTM) e um Datum (WGS 84), Belfiore e Parente (2015) informam que um processo adicional de ortorretificação se faz necessário para aumentar a precisão posicional. Este fato se dá porque no nível acima mencionado não é considerada a variação altimétrica do terreno que é assumido como tendo uma altimetria média constante.

O modelo matemático empregado foi o baseado em Pontos de Controle de Campo (Ground Control Points -GCPs) obtidos com sua respectiva altimetria. Deste modo, a primeira etapa do processo de ortorretificação consiste na pré-seleção de pontos de controle. Estes devem estar bem distribuídos na área de estudo e serem claramente visíveis na imagem, para que durante sua coleta em campo não haja dúvidas do local exato em que o ponto se encontra e cobrir, preferencialmente, toda a variação altimétrica do terreno.

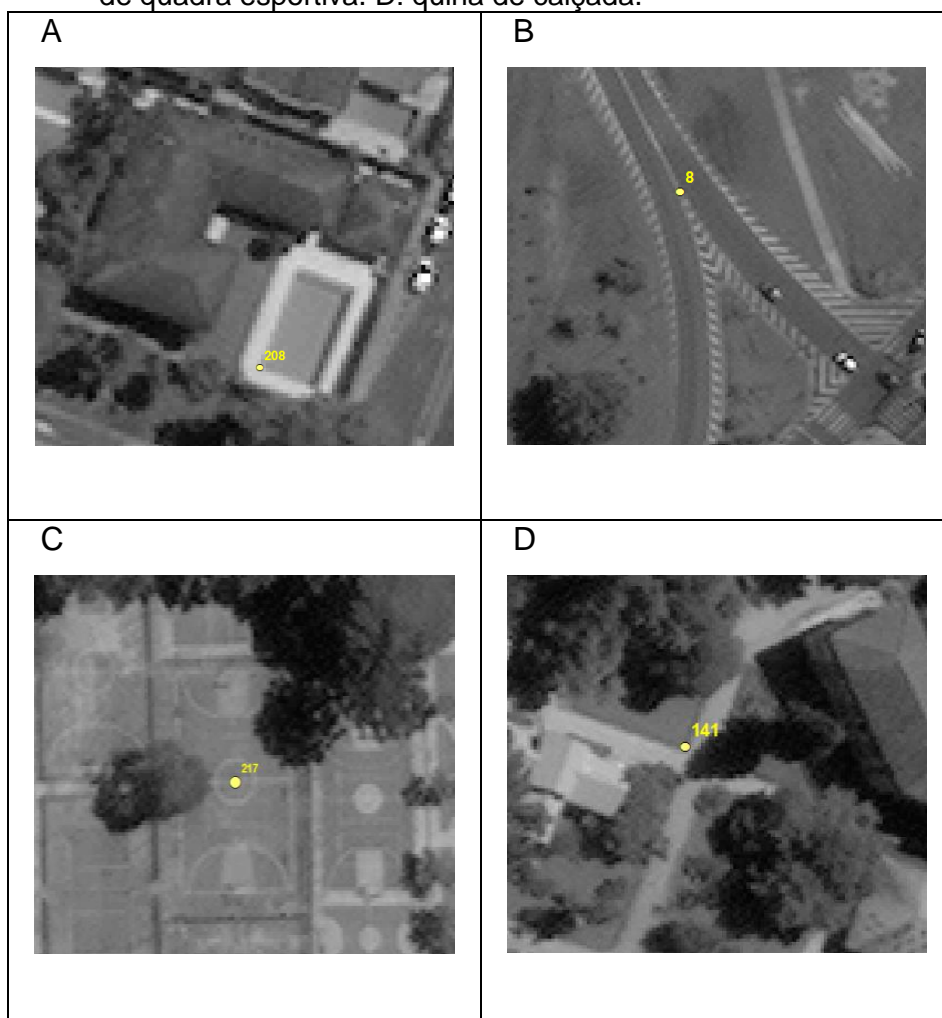
Neste estudo foram pré-selecionados 219 pontos na imagem pancromática WorldView-2 (Figura 3.3), como faixas de sinalização do trânsito, junções de calçadas, quinas de piscinas e demarcações de quadras esportivas (Figura 3.4). Também foi elaborado um questionário de reconhecimento de campo com o intuito de contextualizar o local em que os pontos se encontram, fornecendo informações sobre facilidade de acesso e de possíveis obstáculos que possam prejudicar a recepção de dados, como árvores, edifícios, fluxo de caminhões, ônibus e pessoas e se este apresenta algum risco à equipe e aos equipamentos levados à campo.

Figura 3.3 - Pontos de controle pré-selecionados.



Fonte: Produção do autor.

Figura 3.4 - GPCs pré-selecionados na imagem pancromática WorldView-2. A: quina de borda de piscina. B: faixa de sinalização de trânsito. C: demarcação de quadra esportiva. D: quina de calçada.



Fonte: Produção do autor.

Como estratégia de redução de custos de tempo foi adotada a estratégia de divisão da área de estudo em 4 quadrantes e para cada um foi elaborado um roteiro de visita de campo dos GPCs com o trajeto a ser percorrido, respectivos endereços, coordenadas, imagens do Google Earth em perspectiva vertical e horizontal do módulo Street View.

Após o reconhecimento de campo, realizado em Novembro de 2015, as informações colhidas auxiliaram tanto na tomada de decisão da escolha dos

GCPs quanto no roteiro de campo a ser percorrido, no que diz respeito a autorização e agendamento da coleta de pontos em locais privados, como prédios e escolas, bem como na previsão da necessidade de apoio da CIRETRAN (Circunscrição Regional de Trânsito) para auxílio da sinalização do trânsito em vias com grande fluxo de veículos.


Prevendo a possibilidade de não obtenção de todos os pontos de controle selecionados devido à imprevistos, estes foram categorizados de acordo com sua probabilidade positiva de coleta. Pontos localizados em parques, escolas e ruas tiveram prioridade 1 na sua coleta, enquanto aqueles em áreas de prédios ganharam prioridade 2 e aqueles que necessitavam do apoio da CIRETRAN para a sua coleta ficaram em última prioridade. A partir desta categorização, somada à estratégia de visita por quadrante, o roteiro de coleta dos GCPs foi elaborado.

Cada satélite transmite informações, nomeadas almanaque, sobre sua própria órbita e sobre as órbitas dos demais satélites em operação. Se o receptor tem um almanaque, é possível reduzir consideravelmente o tempo necessário para buscar e encontrar os sinais dos satélites e, portanto, localizar um ponto (TOPCON, 2003). Assim, para obter as informações dos horários de passagem dos satélites e otimizar o tempo necessário de observação para coleta dos GCPs foi realizada a atualização dos almanaques dos receptores D-GPS Topcon Hiper.

Nas aplicações geodésicas e topográficas dos Sistemas Globais de Navegação por Satélite (GNSS- *Global Navigation Satellite Systems*) está implícita a utilização do método relativo, no qual ao menos uma estação de coordenadas conhecidas é rastreada simultaneamente à ocupação dos pontos desejados (IBGE, 2016). Neste estudo, a estação RBMC SAT 91537 (Rede Brasileira de Monitoramento Contínuo) pertencente ao Sistema Geodésico Brasileiro (SGB), desempenhou o papel de coordenadas de referência conhecidas. Esta estação, localizada no Instituto Nacional de Pesquisas Espaciais (INPE) de São José dos Campos, juntamente com outro receptor D-GPS Hiper também com função

de estação de base, permaneceu estática durante todo processo de implantação dos pontos de controle e determinação de suas coordenadas, realizado com um receptor D-GPS Hiper na função de Rover (móvel) (Figura 3.5).

Figura 3.5– D-GPS e RBMC. A e B: D-GPS Hiper Topcon na função Rover. C: estação RBMC SAT 91537.




Fonte: Produção do autor.

Durante o campo, efetuado no mês de Dezembro de 2015, foram coletados 48 GCPs nos horários em que uma constelação com pelo menos 8 satélites estivesse visível ao receptor para alcance de uma melhor precisão posicional. A coleta de todos os pontos teve a duração de 30 minutos e todos os pontos que apresentaram ruído foram eliminados no seu processamento, após sua coleta de campo.

A altitude determinada pelo receptor GNSS está relacionada a um elipsoide de referência com dimensões específicas. Para que se possa obter a altitude acima do nível médio do mar, denominada altitude ortométricas, torna-se necessário conhecer a diferença entre as superfícies do geoide e do elipsoide (IBGE, 2015a). Vale ressaltar que a superfície do geoide é aquela referente ao nível médio do mar, nomeada de altura ou ondulação geoidal. Para converter as altitudes elipsoidais (h) obtidas pelo receptor GNSS em altitudes

ortométricas (H) se faz necessário utilizar o valor da altura geoidal (N) fornecida por um modelo de ondulação geoidal, utilizando a equação representada na Figura 3.6.

Figura 3.6 - Representação da altitude ortométrica, geoidal e elipsoidal.




Fonte: Adaptado de MAPGEO(2015).

O sistema MAPGEO fornece a ondulação geoidal (N) necessária à conversão de altitudes elipsoidais em altitudes ortométricas. Assim, as altitudes dos pontos obtidos no levantamento de campo foram convertidas em altitudes ortométricas com o auxílio desse sistema. Já as coordenadas geográficas foram convertidas para a projeção UTM com o auxílio do *software* ProGrid.

Modelos como os de funções racionais utilizam os GCPs para calcular uma transformação que distorce a imagem bruta para ajustar as coordenadas terrestres (Figura 3.7). Este processo é conhecido como correção geométrica e sua qualidade está diretamente relacionada a uma boa execução na coleta e ao número de pontos de controle recolhidos em campo (GEOMATICA, 2015).

Figura 3.7 - Correção geométrica.



Fonte: Adaptado de Geomatica (2015).

No ambiente OrhtoEngine do *software* PCI Geomatics foi possível ortorretificar a imagem PAN e as MSS através de um método de modelagem matemático racional de satélite óptico a partir de 20 pontos de controle.

Uma vez ortorretificada, as imagens geradas podem ser consideradas geometricamente fiéis ao mundo real em função nova perspectiva ortogonal conquistada, permitindo a construção de documentos cartográficos, cálculos mais precisos de áreas e de distâncias e integração com outros dados em SIG.

3.5. Fusão


Uma imagem multiespectral contém resolução espectral mais elevada do que uma imagem pancromática, em contrapartida uma imagem pancromática normalmente apresenta uma resolução espacial maior do que a primeira. O algoritmo Pan Sharpening (Panchromatic Sharpening) é utilizado no processo de fusão em que se utiliza uma imagem pancromática para refinar a resolução espacial uma imagem multiespectral.

Foi utilizado o método de fusão Gram-Schmidt Pan Sharpening com reamostragem por vizinho mais próximo, por este utilizar a função de resposta

espectral de um dado sensor, neste caso do WorldView-2, para estimar como os dados pancromáticos devem parecer (ENVI HELP, 2016). Outro motivo se deu por este método permitir a fusão das 8 bandas multiespectrais e por mais preservar as cores e bordas dos alvos quando comparado com diversos métodos disponíveis no *software* ENVI (Color Normalized (CN) Spectral Sharpening, Principal Components (PC) Spectral Sharpening, Color Normalized (Brovey) Sharpening e HSV Sharpening) (Figura 3.8).

O algoritmo Pan Sharpening inicia simulando uma banda pancromática a partir das bandas multiespectrais, onde a banda pancromática simulada está dentro do intervalo espectral das bandas multiespectrais. Em seguida, uma transformação de Gram-Schmidt é aplicada à banda simulada e às bandas multiespectrais, onde a pancromática simulada é considerada como a primeira banda. Posteriormente, a primeira banda Gram-Schmidt é trocada pela banda pancromática de alta resolução e uma transformação inversa é aplicada para formar a imagem sintética de saída (MENESES et al., 2012).

Figura 3.8 – Fusão. A: imagem Pancromática World View-2. B: imagem Multiespectral WorldView-2. C: imagem Fusionada World View-2 pelo método de fusão Gram-Schmidt Pan Sharpening com reamostragem por vizinho mais próximo.



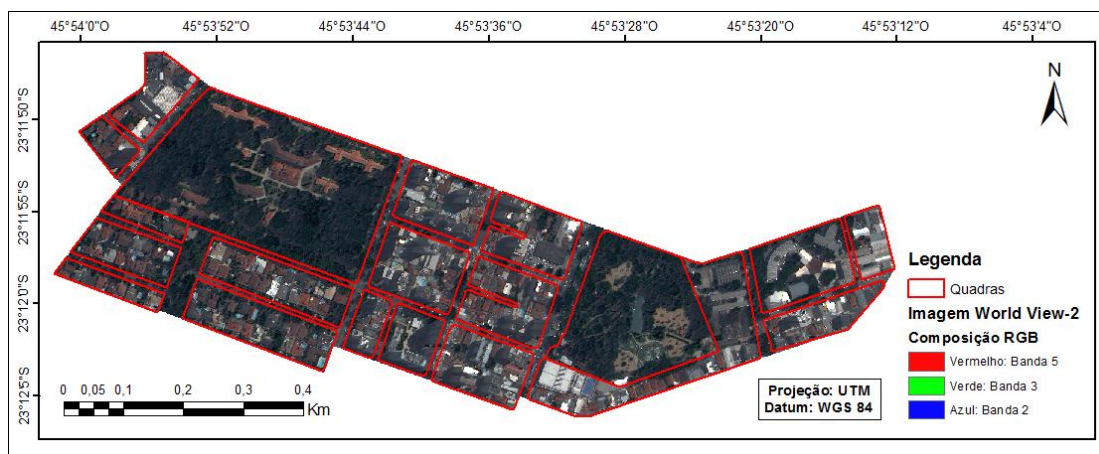
Fonte: Produção do autor.

3.6. Classes da cobertura do solo urbano

A definição e caracterização das classes de interesse da cobertura do solo urbano foi realizada com base na análise visual da imagem fusionada com o propósito de identificar os principais materiais que compõe os objetos existentes dentro das quadras. Por mais que o conhecimento empírico permita ao intérprete associar feições e tonalidades de cor da imagem aos objetos do mundo real, o estado de conservação dos objetos dificultou o processo de identificação das classes sendo, portanto, necessária visita em campo para reconhecer alguns alvos, realizada nos dias 15 a 17 de Julho e 6, 18 e 30 de Agosto de 2015.

Considerando que a classificação da imagem foi realizada apenas dentro das quadras, estas foram vetorizadas para que haja uma diferenciação do que há dentro das quadras e fora delas, no caso as ruas (Figura 3.9). Este procedimento foi efetuado com o *software* ArcGIS com auxílio dos dados vetoriais de quadras do banco de dados “Cidade Viva” disponibilizado pela Prefeitura Municipal de São José dos Campos. Foi necessário realizar a transformação do sistema de coordenadas de SAD 69 para o mesmo da imagem WorldView-2, a saber, WGS-84 com Projeção Universal Transversa de Mercator (UTM).


Figura 3.9 - Vetorização quadras e ruas.



Fonte: Produção do autor.

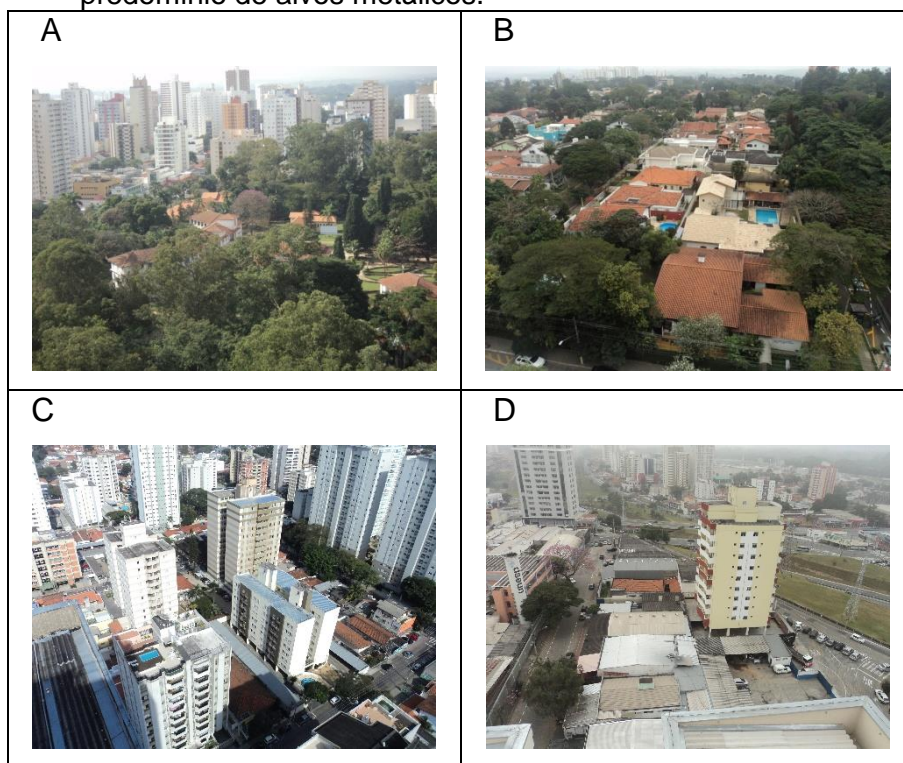
Para otimizar o trabalho de campo, foram consideradas as quadras já vetorizadas. Assim, as visitas foram ordenadas por quadras, sendo estas numeradas de 1 a 20 (Figura 3.10). Buscou-se encontrar uma visão panorâmica para observar e registrar os alvos de cada quadra, isto foi possível subindo no topo dos prédios localizados nestes arredores (Figura 3.11).

Figura 3.10 - Quadras ordenadas.



Fonte: Produção do autor.

Figura 3.11 - Reconhecimentos dos alvos urbanos em campo através de visão panorâmica. A: Quadra 3, onde está localizado o Parque Vicentina Aranha, predomínio de alvos naturais. B: Quadra 7, onde está localizado o condomínio Jardim Apollo, predomínio de ocupação residencial. C: Quadra 15, predomínio de prédios. D: Quadra 20, com predomínio de alvos metálicos.



Fonte: Produção do autor.

No total, 36 tipos de alvos urbanos foram identificados na cena e confirmados em campo (Tabela 3.1) permitindo que fosse desenvolvida uma verdade de campo por quadra.

Tabela 3.1 - Classes identificadas na área de estudo.

Classe	Subclasse
Cerâmica	Cerâmica alaranjada
	Cerâmica cinza
	Cerâmica com manta asfáltica aluminizada
	Cerâmica vermelha intemperizada
	Cerâmica vermelha nova
Metálicas	Metálica cor natural
	Metálica enferrujada
	Metálica com pintura branca
	Metálica com pintura cinza
Fibrocimento	Fibrocimento intemperizado
	Fibrocimento novo
Pavimentação Não Viária	Concreto intemperizado
	Concreto novo
	Concreto pintado de azul
	Concreto pintado de branco
	Concreto pintado de verde
	Concreto pintado de vermelho
Pedra mineira	
Piso esmaltado	
Pavimentação Viária	Asfalto
	Bloquete
Coberturas Diversas	Domus
	Fibra vegetal
	Madeira
	Telha de concreto
Corpos d'água	Toldo
	Lago
	Piscina

(continua)

Tabela 3.1 – Conclusão.

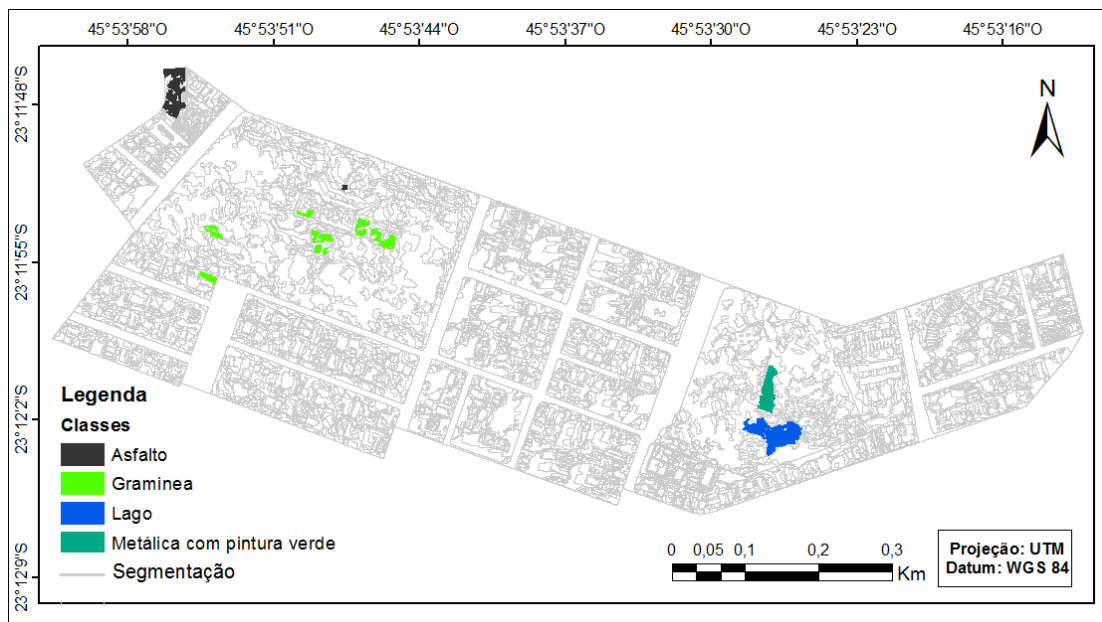
Solo Exposto	Saibro
	Saibro com cascalho
	Solo exposto
	Solo exposto com cascalho
	Solo exposto com cascalho e concreto
Vegetação	Arbórea
	Rasteira

Fonte: Produção do autor.

Apesar de haver um grande esforço na comunidade científica de se aumentar o nível de legenda da classificação urbana, como visto em Anjos (2016), algumas classes foram eliminadas e algumas subclasses foram unidas na mesma classe (Tabela 3.2).

A decisão sobre quais classes seriam utilizadas na classificação da imagem WorldView-2 foi feita da seguinte maneira: classes que aparecem uma ou pouquíssimas vezes na área de estudo, como por exemplo a classe madeira presente apenas na ponte do Parque Santos Dumont, foram descartadas por sua inexpressividade na área de estudo. Já as classes que não apresentam mais de 15 objetos na imagem, porém pertencem à classes relevantes na classificação urbana, foram classificadas manualmente pois não teriam amostras de treinamento e de validação suficientes para fazerem parte do processo de mineração de dados e pré-validação da classificação da imagem. Dentre elas estão as classes asfalto, lago, vegetação gramínea e metálico com pintura verde, conforme apresentado na Figura 3.12 abaixo.

Figura 3.12 - Conjunto de objetos extraídos manualmente.



Fonte: Produção do autor.

Para as classes (superclasses) que apresentam vários subtipos (subclasses) foi utilizada a análise do comportamento espectral destas, através do uso de histogramas e gráficos de dispersão, como método de decisão para separar ou unir as subclasses em uma só classe.

Tabela 3.2 - Classes do solo urbano separadas por seus níveis hierárquicos de segmentação.

Nível 1	Nível 2	Nível 3	Nível 4
Quadras	Coberturas Impermeáveis	Cerâmica	Cerâmica alaranjada Cerâmica cinza Cerâmica vermelha intemperizada Cerâmica vermelha nova
		Coberturas Metálicas	Metálicas brilhantes Metálica com pintura cinza
		Derivados de Cimento	Cimentos novos Cimentos intemperizados
		Pavimentação Não Viária	Pedra mineira
	Coberturas Permeáveis	Corpos d'água Solo Exposto Vegetação	Piscina Solo exposto Arbórea

Fonte: Produção do autor.

Além das classes apresentadas na tabela anterior, a classe sombra também se mostrou essencial na classificação devido a sua presença extensiva na imagem. Isto se dá em razão da presença substancial de edifícios altos na área de estudo, os quais sombreiam os objetos no seu entorno dificultando a detecção e identificação destes alvos.

A caracterização das classes foi auxiliada pela elaboração de chaves de interpretação para as classes de cobertura do solo urbano (Tabelas 3.3 e 3.4). Nesta chave as classes são discriminadas através dos elementos de interpretação da imagem consistindo, na maioria dos casos, da cor na composição das cores primárias vermelho, verde e azul (*RGB- Red, Green, Blue*), tonalidade, localização, contexto, forma, tamanho e textura.

Tabela 3.3 - Chave de interpretação de classes de cobertura do solo.

Classe	Amostra	Cor/ Tonalidade na composição RGB (5,3,2)	Localização/ Contexto	Forma, Tamanho e Textura
Cerâmica alaranjada		Variações de tons laranjas amarelados	Presença exclusiva nas quadras residenciais	Formas predominantemente retangulares de tamanho variáveis
Cerâmica cinza		Variações de tons de cinza médio a escuro	Presença exclusiva nas quadras residenciais	Formas predominantemente retangulares de tamanho variáveis
Cerâmica vermelha intemperizada		Variações de tons de marrom escuro	Presente ao longo de toda a área de estudo	Formas predominantemente retangulares de tamanho variáveis
Cerâmica vermelha nova		Variações de tons alaranjados escuros a vermelho	Presente ao longo de toda a área de estudo	Formas predominantemente retangulares de tamanho variáveis
Cimentos intemperizados		Tons de cinza escuro ao preto	Presente ao longo de toda a área de estudo	Tamanho e forma variados, na sua maioria retangulares com textura variáveis
Cimentos novos		Tons de cinza claro a médio	Presente ao longo de toda a área de estudo	Tamanho e formas variadas, na sua maioria retangulares com textura variáveis


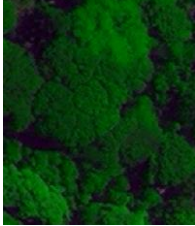
(Continua)

Tabela 3.3 - Continuação

Metálica com pintura cinza		Tons de cinza médio	Presença principalmente e nas quadras com predomínio de alvos metálicos	Formas retangulares, com diferentes tipos de textura
Metálicas brilhantes		Tons claros de azul, cinza, amarelo e branco	Presença principalmente e nas quadras com predomínio de alvos metálicos	Formas retangulares, com diferentes tipos de textura
Pedra mineira		Tons alaranjados, beges e muito claros	Sempre nas bordas das piscinas	Forma, tamanho e textura variados
Piscina		Tons de azul piscina a azuis médios escuros dependendo do material da piscina.	Localizadas na sua maioria nas quadras residenciais e nas áreas de lazer dos prédios	Tamanho e formas variadas, na sua maioria retangulares ou redondas de textura lisa
Solo exposto		Tons claros de laranja, marrom, creme e cinza claro	Presente nos parques, estacionamentos e terrenos	Formas irregulares, sendo retangulares nos estacionamentos e terrenos e alongadas nos caminhos dos parques. Texturas variadas.



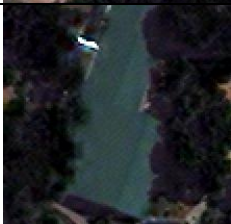

(continua)

Tabela 3.3 - conclusão

Sombra		Tons de cinza escuro ao preto	Presente principalmente nas quadras com predomínio de prédios e construções altas	Formas regulares com tamanho variado, sendo maior nas quadras com prédios e textura lisa
Vegetação arbórea		Composição RGB 5, 3 e 8, 2. Tons de verde claro a verde escuro, dependendo do tamanho, espécie e densidade da árvore	Predominante nos parques e nas bordas das quadras	Forma irregular, tamanho variado e textura mais ou menos rugosa dependendo da espécie

Fonte: Produção do autor.

Tabela 3.4 - Chave de interpretação de classes classificadas manualmente.

Classe	Amostra	Cor na composição RGB (5,3,2)	Localização/ Contexto	Forma, Tamanho e Textura
Asfalto		Tons de cinza médio a escuro	Presente em estacionamentos	Formas regulares com tamanho variado e textura lisa
Lago		Tons de cinza escuro	Presente no Parque Santos Dumont	Formas irregulares com tamanho variado e textura lisa
Metálica com pintura verde		Tons de verde escuro	Presente no Parque Santos Dumont	Formas retangulares com tamanho médio e textura lisa
Vegetação gramínea		Composição RGB 5, 3 e 8, 2. Tons de verde claro vivo	Presente em casas e parques	Formas regulares com tamanho variado e textura lisa

Fonte: Produção do autor.

Finalizada esta etapa as imagens foram exportadas para o *software* eCognition no formato TIFF e o layer vetorial de quadras foi exportado no formato Shapefile.


3.7. Segmentação Multirresolução

A técnica de segmentação de imagens foi utilizada para derivar os objetos da imagem. Visto que os objetos de interesse aparecem simultaneamente em diferentes escalas na imagem foi utilizado o algoritmo de Segmentação Multirresolução (*Multiresolution Segmentation*), já que este possibilita

segmentar uma mesma imagem em diferentes níveis de escala que se relacionam entre si, formando uma rede hierárquica de objetos.

Para a geração da rede hierárquica de objetos foi adotada a estratégia *top-down*, onde o processo inicia com objetos grandes que são subdivididos até se obter o nível de escala mais detalhado. Assim sendo, 4 níveis de segmentação foram propostos. O primeiro nível de segmentação foi criado com o propósito de separar as quadras das ruas. A partir da superclasse Quadras gerada no primeiro nível de segmentação, foi possível gerar o segundo nível, o qual buscou separar as áreas permeáveis das impermeáveis. Com base nos objetos permeáveis e impermeáveis gerados no nível 2 de segmentação foram criados novos subobjetos com a finalidade de individualizar os alvos urbanos. Por fim, o quarto nível de segmentação foi criado buscando refinar a classificação através da geração de subtipos dos alvos do nível 3 (Figura 3.13).

Figura 3.13 - Níveis de segmentação. A: Nível 1: superobjetos quadras e ruas. B: Nível 2: objetos permeáveis e impermeáveis. C: Nível 3: identificação dos objetos urbanos. D: Nível 4: subclasses dos objetos urbanos.



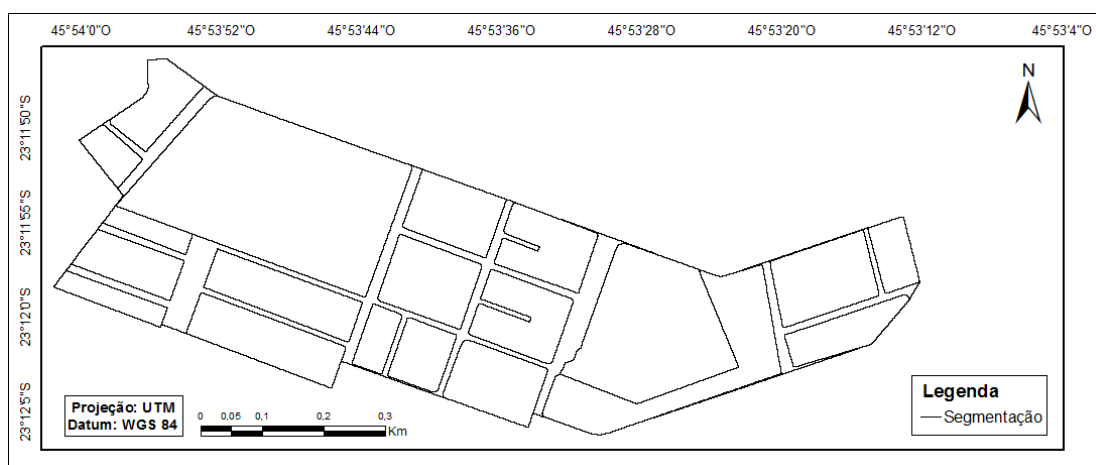
Fonte: Produção do autor.

Convém lembrar que neste procedimento o usuário precisa definir quatro parâmetros: fator de escala, pesos para os pares cor e forma, suavidade e compacidade, além de pesos para cada uma das bandas espectrais. Os pares cor e forma e suavidade e compacidade são complementares e seus valores variam de 0 a 1. Ao dar o valor 0.7, por exemplo, para cor, a forma recebe automaticamente seu peso complementar, de 0.3.

A obtenção dos pesos dos parâmetros mais adequados para a delimitação dos alvos urbanos em diferentes níveis de detalhamento foi realizada de forma empírica usando a abordagem de tentativa e erro.

Logo, o nível mais alto da hierarquia dos níveis da segmentação foi definido no primeiro processo de segmentação multirresolução, onde foram criados os objetos Quadras e Ruas. Para tanto a imagem foi segmentada considerando apenas o layer temático de quadras, dando peso zero para todas a bandas da imagem e peso 1 para o layer temático (Figura 3.14, Tabela 3.5).

Figura 3.14 - 1º nível de segmentação.



Fonte: Produção do autor.

Tabela 3.5 - Parâmetros de segmentação multirresolução nível 1.

Nível	Escala	Forma	Compacidade
Nível 1	5.000	0.9	0.9

Fonte: Produção do autor.

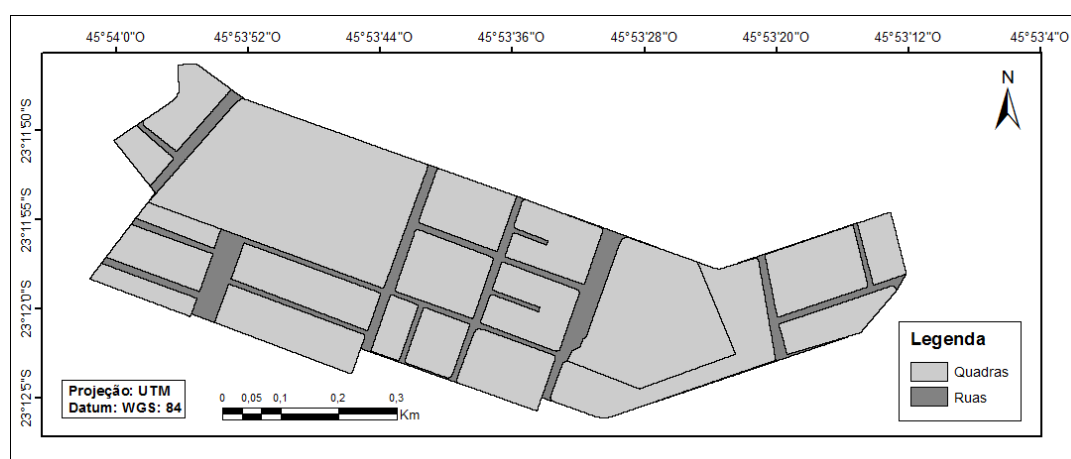
Como os objetos de interesse devem estar dentro das quadras, é necessário indicar nos próximos processos de segmentação esta restrição geográfica.

O atributo de análise espacial *Elliptic Fit* (Encaixe Elíptico) representa o quanto um objeto se encaixa numa elipse de proporções similares, no qual o valor 0

significa que este objeto não se encaixa e 1 se encaixa perfeitamente. Aplicando esta análise aos objetos gerados na segmentação anterior, quadras e ruas, foi possível visualizar que as quadras apresentaram valores que variam de 0,33 a 0,83 enquanto que as ruas apresentaram apenas o valor zero.

Assim, a partir desta análise foi possível classificar as quadras com o algoritmo *Assign Class* (Atribuir Classe) levando em conta o algoritmo *Elliptic Fit* com a condição de que todos os objetos que apresentassem valor maior ou igual a 0,33 deveriam ser classificados como quadras. Já as ruas foram classificadas com o algoritmo *Classification*, com filtro de classe *Unclassified* (Não Classificado) em que todos os objetos que não estavam classificados como Quadras foram considerados como sendo da classe Ruas (Figura 3.15).

Figura 3.15 - Classificação Quadras e Ruas.



Fonte: Produção do autor.

Para a escolha dos parâmetros de segmentação mais grosseiros definiram-se 4 recortes representativos da área de estudo para comparar os resultados obtidos. O primeiro recorte contém o Parque Vicentina Aranha, o qual permite analisar com maior detalhe como resultariam as segmentações em áreas com vegetação. O segundo recorte contém o Condomínio Apollo para analisar especialmente o comportamento das segmentações em áreas residenciais. Já o terceiro recorte apresenta uma área com elevado número de prédios e por último um recorte contendo a universidade Unesp para avaliar o resultado da segmentação em áreas com telhados metálicos (Figura 3.16).

Figura 3.16 - Recortes representativos da área de estudo. A: área com vegetação. B: área residencial. C: área com prédios. D: áreas metálicas.

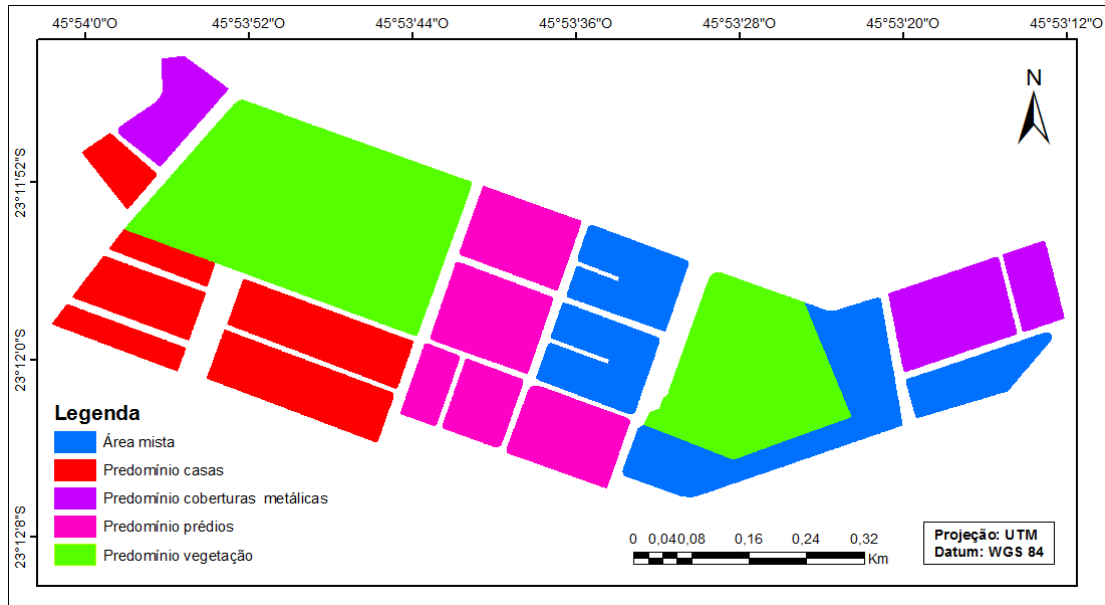


Fonte: Produção do autor.

A escolha dos parâmetros mais adequados para toda a cena foi uma tarefa bastante complexa pois muitas vezes um conjunto de parâmetros se ajustava muito bem a um recorte, porém não se adequava a outro. Cada recorte apresentava alvos similares entre si, mas muito diferentes quando comparados com os outros recortes. Isto ocorre pelo fato de cada recorte apresentar um padrão de tamanho e forma dos objetos recorrentes diferentes.

Notou-se a necessidade de se escolher parâmetros de segmentação para cada tipo de predomínio de alvos. Para a realização desta tarefa as quadras foram categorizadas de acordo com suas características em comum. Foram definidas 5 classes, sendo elas Predomínio de vegetação, Predomínio de prédios, Predomínio de casas, Predomínio de coberturas metálicas e Áreas mistas, para as quadras que apresentam uma todos os tipos de alvos (Figura 3.17).

Figura 3.17 - Classificação das quadras por tipo de predomínio dos alvos.



Fonte: Produção do autor.


Após a classificação dos tipos de quadras foi realizada uma nova segmentação, sendo que agora cada tipo de quadra tem um parâmetro único para sua segmentação no nível 2 (mais grosseiro), nível 3 (segmentos médios) e nível 4 (segmentos finos) (Tabela 3.6, Figuras 3.18, 3.19, 3.20). Todas as 8 bandas multiespectrais e a banda pancromática receberam peso 1 e o layer temático peso zero.

Tabela 3.6 - Parâmetros de segmentação multirresolução níveis 2, 3 e 4.

Classe	Segmentação	Escala	Forma	Compacidade
Áreas mistas	Nível 2	200	0.5	0.5
	Nível 3	70	0.6	0.5
	Nível 4	60	0.1	0.5
Predomínio casas	Nível 2	150	0.5	0.5
	Nível 3	40	0.9	0.5
	Nível 4	40	0.5	0.5
Predomínio coberturas metálicas	Nível 2	150	0.5	0.5
	Nível 3	80	0.5	0.5
	Nível 4	50	0.1	0.5
Predomínio prédios	Nível 2	150	0.3	0.5
	Nível 3	70	0.5	0.5
	Nível 4	40	0.5	0.5
Predomínio vegetação	Nível 2	330	0.5	0.5
	Nível 3	165	0.1	0.5
	Nível 4	60	0.1	0.5

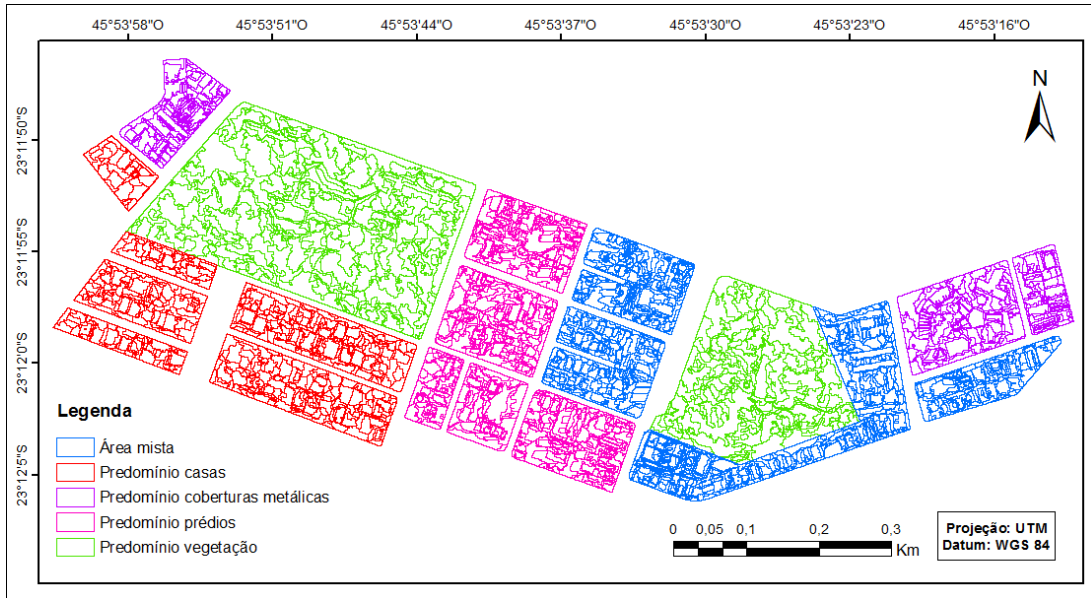
Fonte: Produção do autor.

Figura 3.18 - Segmentação nível 2.




Fonte: Produção do autor.

Figura 3.19 - Segmentação nível 3.



Fonte: Produção do autor.

Figura 3.20 - Segmentação nível 4.



Fonte: Produção do autor.

3.8. Segmentação Diferença Espectral

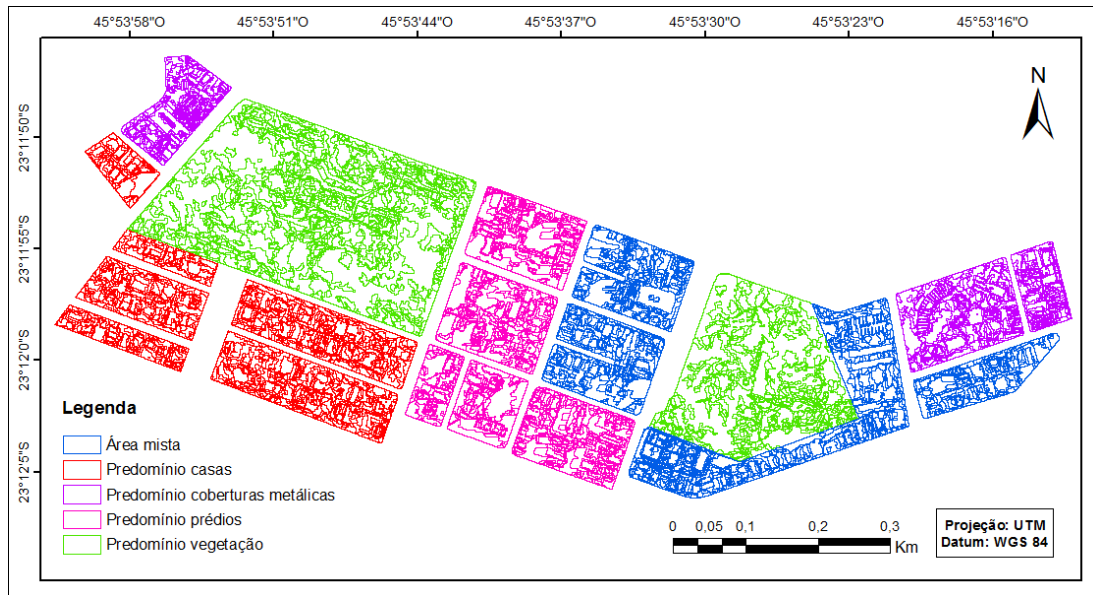
Pelo fato de existirem alvos muito pequenos na cena e haver o interesse de classificá-los foi necessário criar um nível de segmentação mais fino, ocasionando uma supersegmentação da imagem. Para refinar o resultado da segmentação existente utilizou-se o algoritmo de segmentação *Spectral Difference* (Diferença Espectral) o qual permite agrupar segmentos contíguos que em geral são estatisticamente semelhantes dentro de um determinado limiar de média sendo, portanto, uma segmentação *botton-up* (de baixo para cima). Todas as 8 bandas multiespectrais e a banda pancromática receberam peso 1 e o layer temático peso zero (Tabela 3.7, Figura 3.21).

Tabela 3.7 - Parâmetros utilizados na segmentação de Diferença Espectral.

Classe	Máxima Diferença Espectral
Áreas mistas	45
Predomínio casas	50
Predomínio coberturas metálicas	38
Predomínio prédios	56
Predomínio vegetação	50

Fonte: Produção do autor.


Figura 3.21 - Segmentação nível 5.



Fonte: Produção do autor.

Dessa maneira, foi possível chegar a um nível de segmentação desejado: alvos menores continuaram a ser discriminados como objetos na segmentação e alvos maiores deixaram de estar supersegmentados (Figura 3.22).

Figura 3.22 – Resultados das diferentes segmentações. A: Segmentação nível 4 (fina).
B: Segmentação nível 5 (diferença espectral).



Fonte: Produção do autor.

No total, 6380 objetos foram criados ao longo do desenvolvimento dos 5 níveis de segmentação, conforme pode ser observado na Tabela 3.8, abaixo.

Tabela 3.8 - Número de objetos criados por nível de segmentação.

Nível de segmentação	Nº de objetos criados
Nível 1: Segmentação quadras e ruas	23
Nível 2: Segmentação grosseira	1.458
Nível 3: Segmentação média	3.494
Nível 4: Segmentação fina	7.499
Nível 5: Segmentação Espectral	6.380
Diferença	

Fonte: Produção do autor.

3.9. Cálculo dos Atributos

O sistema eCognition permite explorar os objetos da imagem a partir de suas características espectrais, de formas e hierárquicas através de métricas disponibilizadas pelo próprio *software*, ou a partir de atributos customizados pelo usuário. Estes últimos podem ser criados e adaptados de acordo com as necessidades do estudo, visando o enriquecimento e a diversificação do conjunto de dados de entrada na classificação dos objetos da imagem (Trimble, 2011a).

Assim, os atributos customizados foram gerados baseados em operações aritméticas, utilizando os atributos de média, desvio padrão (DP), brilho, máxima diferença das 8 bandas multiespectrais e pancromática e análise por principais componentes (*Principal Component Analysis- PCA*) também produzidos. Em termos gerais, utilizou-se a soma e a multiplicação para realçar similaridades espectrais de diferentes bandas e a subtração e a divisão para realçar diferenças espectrais dos alvos, sempre com o intuito de encontrar parâmetros de inclusão ou exclusão de alvos específicos de interesse (MENESES et al., 2012).

Para tanto, foram usadas razões entre bandas e índices presentes na bibliografia científica, como os de vegetação, de água, geológico, de solo e áreas construídas (Tabelas 3.9, 3.10, 3.11, 3.12 e 3.14). Uma vez que o WorldView-2 dispõe de duas bandas para o infravermelho próximo (IVP1 e

IVP2) e duas bandas para o azul (Costal e Azul), alguns índices foram adaptados, usando uma banda de cada vez. Conforme proposto por Wolf (2012), índices adaptados para as bandas multiespectrais do WorlView-2 também foram utilizados (Tabela 3.13).

Tabela 3.9 - Índices de vegetação.

Índice (Sigla)	Equação	Descrição/ Referência
Índice de Vegetação Resistente à Atmosfera (ARVI)	$ARVI\ 1 = \frac{IVP1 - [\text{Vermelho} - \gamma(\text{Azul} - \text{Vermelho})]}{IVP1 + [\text{Vermelho} - \gamma(\text{Azul} - \text{Vermelho})]}$	Adotou-se $\gamma=1$. Reduz a dependência do NDVI nas propriedades atmosféricas (KAUFMAN e TANRÉ, 1992).
	$ARVI\ 2 = \frac{IVP2 - [\text{Vermelho} - \gamma(\text{Azul} - \text{Vermelho})]}{IVP2 + [\text{Vermelho} - \gamma(\text{Azul} - \text{Vermelho})]}$	
	$ARVI\ 3 = \frac{IVP1 - [\text{Vermelho} - \gamma(\text{Azul Costal} - \text{Vermelho})]}{IVP1 + [\text{Vermelho} - \gamma(\text{Azul Costal} - \text{Vermelho})]}$	
	$ARVI\ 4 = \frac{IVP2 - [\text{Vermelho} - \gamma(\text{Azul Costal} - \text{Vermelho})]}{IVP2 + [\text{Vermelho} - \gamma(\text{Azul Costal} - \text{Vermelho})]}$	
Índice de Realce de Vegetação (EVI)	$EVI\ 1 = \frac{2,5(IVP1 - \text{Vermelho})}{IVP1 + 6 * \text{Vermelho} - 7,5 * \text{Azul} + 1}$	Uma variação do NDVI, reduz a influência do solo e atmosfera no índice de vegetação (HUETE et al., 2002).
	$EVI\ 2 = \frac{2,5(IVP2 - \text{Vermelho})}{IVP2 + 6 * \text{Vermelho} - 7,5 * \text{Azul} + 1}$	
Índice de Vegetação por Diferença Normalizada Verde (GNDVI)	$GNDVI\ 1 = \frac{IVP1 - \text{Verde}}{IVP1 + \text{Verde}}$	Semelhante ao NDVI, mede o espectro verde em vez vermelho, sendo mais sensível à concentração de clorofila (GITELSON e MERZLYAK, 1998).
	$GNDVI\ 2 = \frac{IVP2 - \text{Verde}}{IVP2 + \text{Verde}}$	
Índice de Vegetação por Diferença Normalizada (NDVI)	$NDVI\ 1 = \frac{IVP1 - \text{Vermelho}}{IVP1 + \text{Vermelho}}$	Diferença Normalizada do espalhamento de folhas verdes no infravermelho próximo (IVP). Absorção de clorofila no vermelho (ROUSE et al., 1973).
	$NDVI\ 2 = \frac{IVP2 - \text{Vermelho}}{IVP2 + \text{Vermelho}}$	
Índice por Razão Simples (SR)	$SR\ 1 = \frac{IVP1}{\text{Vermelho}}$	Razão do espalhamento da folha verde no infravermelho próximo (IVP). Absorção da clorofila no vermelho (BIRTH e MCVEY, 1968).
	$SR\ 2 = \frac{IVP2}{\text{Vermelho}}$	

(continua)

Tabela 3.9 – Conclusão.

Índice de Vegetação por Razão Verde (GRVI)	$GRVI\ 1 = \frac{IVP1}{Verde}$	Este índice é sensível a taxas fotossintéticas em dosséis florestais, como refletâncias verdes e vermelhas são fortemente influenciadas por mudanças nos pigmentos das folhas. (SRIPADA et al., 2006).
	$GRVI\ 2 = \frac{IVP2}{Verde}$	
Índice de Vegetação Ajustado ao Solo (SAVI)	$SAVI = \frac{1,5 (IVP1 - Vermelho)}{IVP1 + Vermelho + 0,5}$	Reduz a influência do brilho do solo no índice de vegetação (HUETE, 1988).
	$SAVI\ 2 = \frac{1,5 (IVP2 - Vermelho)}{IVP2 + Vermelho + 0,5}$	

Fonte: Produção do autor.

Tabela 3.10 - Índices de água.

Índice (Sigla)	Equação	Descrição/ Referência
Índice da Água por Diferença Normalizada (NDWI)	$NDWI = \frac{Verde - IVP2}{Verde + IVP2}$	Índice sensível a mudanças no conteúdo de água da cobertura vegetal (GAO, 1995). Permite ressaltar feições de água e minimizar o restante dos alvos.
NDWI 2	$NDWI\ 2 = \frac{Verde - IVP1}{Verde + IVP1}$	Índice da Água por Diferença Normalizada (NDWI) (GAO, 1995) adaptada neste estudo para o World View-2.
AA 1	$AA\ 1 = \frac{Amarelo - IVP1}{Amarelo + IVP1}$	Desenvolvido neste estudo para ressaltar a água.
AA2	$AA\ 2 = \frac{Amarelo - IVP2}{Amarelo + IVP2}$	Desenvolvido neste estudo para ressaltar a água.

Fonte: Produção do autor.

Tabela 3.11 - Índices geológicos.

Índice (Sigla)	Equação	Descrição/ Referência
Razão de Óxido de Ferro (IOR)	$IOR = \frac{\text{Vermelho}}{\text{Azul}}$	Esta razão banda destaca alteração hidrotermal rochas que tenham sido submetidos a oxidação de sulfuretos que contém ferro (SEGAL, 1982).
IOR WV-2	$IOR WV - 2 = \frac{\text{Vermelho}}{\text{Verde}}$	Razão de Óxido de Ferro (IOR) (SEGAL, 1982) adaptada neste estudo para o World View-2.
Alvos metálicos (AM)	$AM = \frac{DP \text{ da Banda Pan} - DP \text{ Azul Costal}}{DP \text{ da Banda Pan} + DP \text{ Azul Costal}}$	Índice desenvolvido neste estudo para ressaltar alvos metálicos

Fonte: Produção do autor.

Tabela 3.12 - Índices sugeridos por Leonardi (2010).

Equação	Descrição/ Referência
$\text{Leonardi 1} = \frac{\text{Brilho} + \text{Azul}}{\text{Vermelho}}$	Sugerido por Leonardi, 2010.
$\text{Leonardi 2} = \text{Brilho} + \text{Azul} - \text{Vermelho}$	
$\text{Leonardi 3} = \text{Brilho} - \text{IVP1}$	
$\text{Leonardi 4} = \text{Brilho} - \text{IVP2}$	

Fonte: Produção do autor.

Tabela 3.13 -Índices criados para o WorldView-2 (WOLF, 2012).

Índice (Sigla)	Equação	Descrição/ Referência
Índice da Água por Diferença Normalizada (NDWI WV-2)	$NDWI-2 = \frac{\text{Azul Costal} - IVP2}{\text{Azul Costal} + IVP2}$	Identifica áreas de água parada em tamanhos maiores do que um pixel.
Índice de Vegetação por Diferença Normalizada (NDVI WV-2)	$NDVI WV-2 = \frac{\text{Vermelho} - IVP2}{\text{Vermelho} + IVP2}$	Identifica áreas de vegetação e determina a saúde de cada classe de vegetação.
Diferença de Atributo não Homogênea (NHFD WV-2)	$NHFD WV-2 = \frac{\text{Vermelho Limítrofe} - \text{Azul Costal}}{\text{Vermelho limítrofe} + \text{Azul Costal}}$	Identifica áreas que contrastam com o fundo, o que pode ser identificado como construções antrópicas.
Índice de Solo por Diferença Normalizada (NDSI WV-2)	$NDSI WV-2 = \frac{\text{Verde} - \text{Amarelo}}{\text{Verde} + \text{Amarelo}}$	Este índice utiliza as bandas do WorldView-2 para identificar pixels que consistem principalmente de solo.
Índice de Construção por Diferença Normalizada (NDBI WV-2)	$NDBI WV-2 = \frac{\text{Azul Costal} - \text{Vermelho Limítrofe}}{\text{Azul Costal} + \text{Vermelho Limítrofe}}$	Este índice utiliza as bandas WorldView-2 para calcular a diferença normalizada de áreas construídas.
Novo índice de Ferro WorldView-2 (NII WV-2)	$NII WV-2 = \frac{\text{Verde} * \text{Amarelo}}{(\text{Azul} * 1000)}$	Este índice utiliza as bandas do WorldView-2 para identificar pixels ricos em óxido de ferro.

Fonte: Produção do autor.

Tabela 3.14 -Índices para destacar alvos argilosos.

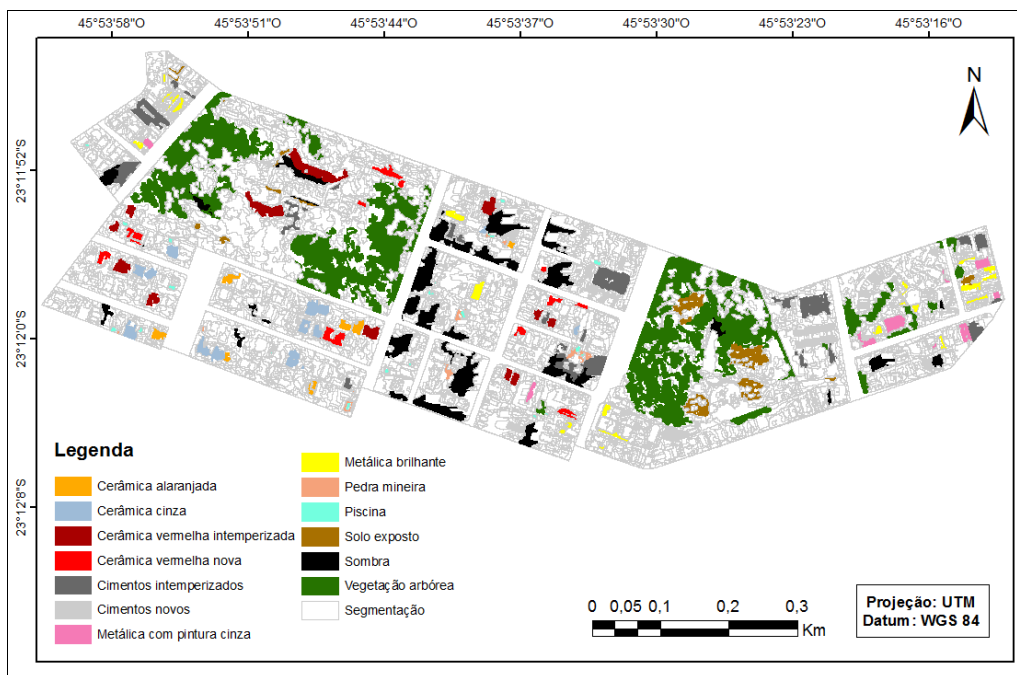
Equação	Descrição/ Referência
$AARG = \frac{\text{Amarelo}}{VL}$	Bandas para destacar alvos argilosos sugerido por Ribeiro (2010). Índice elaborado pelo autor.

Fonte: Produção do autor.

3.10. Coleta de amostras

Para a construção do conjunto amostral de treinamento procurou-se colher amostras bem distribuídas na área de estudo, selecionando os objetos de cada classe com tamanhos semelhantes e cobrindo o máximo da variabilidade interna das classes com diferentes tons, formas, texturas, brilho e estado de conservação a fim de representar o total da população de cada classe. No total, 218 amostras de treinamento foram colhidas no nível 5 de segmentação (Figura 3.23), variando entre 15 e 30 amostras por classe (Tabela 3.15). Vale ressaltar que a extração das amostras teve como dados de referência a chave de interpretação de classes e a verdade de campo (Figura 3.24).

Figura 3.23 - Conjunto amostral de treinamento.



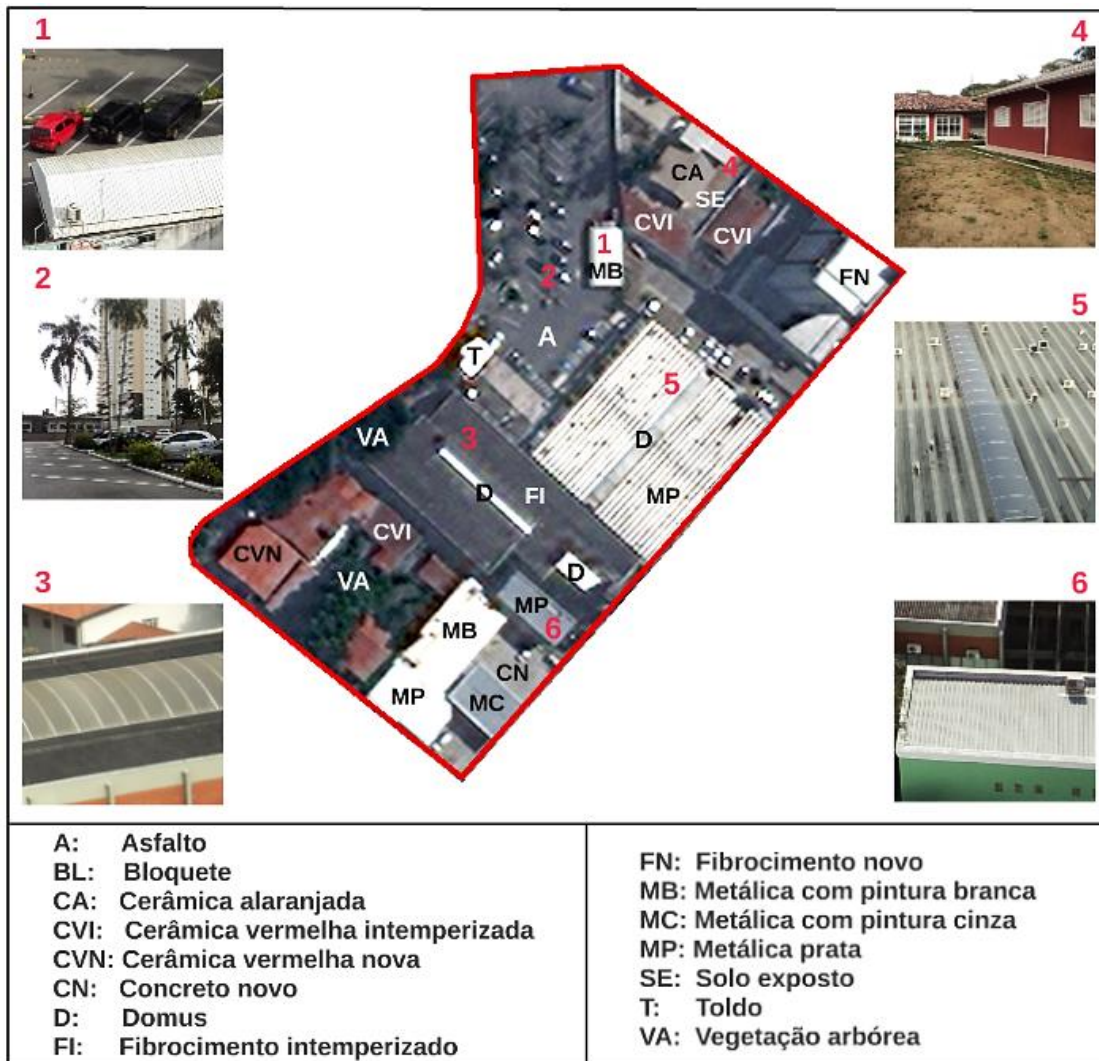
Fonte: Produção do autor.

Tabela 3.15 - Número de amostras por classe.

Classe	Nº de amostras
Arbórea	22
Cerâmica alaranjada	17
Cerâmica cinza	20
Cerâmica vermelha intemperizada	22
Cerâmica vermelha nova	21
Cimentos intemperizados	25
Cimentos novos	23
Metálica com pintura cinza	15
Metálicas brilhantes	30
Pedra mineira	22
Piscina	21
Solo exposto	16
Sombra	27

Fonte: Produção do autor.

Figura 3.24 - Verdade de campo ilustrada para quadra 1.



Fonte: Produção do autor.

3.11. Mineração de Dados

Diante da grande quantidade de atributos disponíveis ao usuário somados aos customizados, torna-se uma tarefa difícil determinar quais são os atributos mais adequados para a classificação dos alvos de interesse. Com o objetivo de encontrar, por meio de uma árvore de decisão, os melhores atributos e limiares que separassem as classes de interesse foram utilizados os algoritmos de mineração de dados CART e C4.5, o primeiro presente na plataforma eCognition e o segundo no *software* WEKA, nomeado como J48.

No experimento realizado na plataforma eCognition, a rotina de processos de mineração de dados é composta por três fases, as quais são suportadas pelo conjunto de objetos e de amostras de treinamento. Todas as três fases utilizam o algoritmo *Classifier* (Classificador). Na primeira fase a operação *Train* (treinamento) é executada para gerar um arquivo onde ficam armazenados os dados estatísticos gerados na análise das amostras em função dos atributos e a árvore de decisão indicando as variáveis e limiares determinantes para cada classe a partir dos parâmetros fornecidos pelo usuário para sua construção. Já na segunda fase, a operação *Query* (investigar) permite visualizar a árvore de decisão e, por conseguinte os limiares e atributos utilizados para classificar o dado. A terceira fase, por se tratar da classificação da imagem, será detalhada mais adiante.

No caso do experimento realizado no sistema WEKA, foi necessário primeiramente exportar as amostras de treinamento e os atributos em formato CSV (*Comma-Separated Values*) com o auxílio do *software* R. Já na plataforma WEKA foi possível realizar a conversão das amostras de treinamento do formato CSV para o formato ARFF (*Attribute-relation File Format*) com o propósito de adequar os dados ao método de armazenamento de dados nativo do WEKA (WITTEN et al., 2011).


Para tornar os modelos de classificação equivalentes, foram definidos os mesmos valores para os parâmetros dos algoritmos em ambos os testes, sendo eles o tipo de teste e o número mínimo de amostras por folha da árvore de decisão (M).

Escolheu-se como opção de teste o do tipo *Cross-Validation* (Validação Cruzada) com número 10 de validações cruzadas. Este número representa em quantas partes o conjunto de dados será dividido. Escolhendo o número 10 os dados são divididos em 10 partes aproximadamente iguais. Enquanto uma parte é usada para teste as outras são utilizadas para treinamento. Este procedimento é repetido 10 vezes de modo que ao final, cada parte foi utilizada apenas 1 vez para teste. Estudos têm demonstrado que a escolha de 10

validações cruzadas apresenta bons resultados sobre diferentes conjuntos de dados e diferentes técnicas de aprendizagem (WITTEN et al., 2011).

Quanto ao parâmetro número mínimo de instâncias por folha, foram realizados 14 testes para cada algoritmo, variando de 2 a 15 instâncias, já que o número 15 corresponde à quantidade mínima de amostras de treinamento colhidas para uma das classes (Figura 3.25).

Figura 3.25 - Parâmetros ajustáveis na mineração de dados. A: plataforma eCognition, algoritmo CART. B: plataforma WEKA, algoritmo C4.5.



Fonte: Produção do autor.

Este procedimento foi realizado com o intuito de se encontrar, diante de todos os testes realizados, a árvores de decisão mais adequada para cada algoritmo, ou seja, aquela que apresenta uma boa acurácia e em contrapartida não apresenta um *overfitting* (especialização) o que leva a geração de uma árvore com grande profundidade.

3.12. Classificação da cobertura do solo urbano

Na terceira fase da rotina de processos de mineração de dados na plataforma eCognition, foi realizada a classificação da imagem, a qual se deu apenas dentro das quadras. Esta se vale da operação *apply* (aplicar) do algoritmo

classifier (classificador) a qual também se utiliza do arquivo estatístico gerado na primeira fase do processo.

Já no experimento realizado com auxílio do *software* WEKA foi possível replicar o conhecimento do resultado da árvore de decisão gerada pelo algoritmo C4.5 para a rede semântica seguindo os limiares propostos para os atributos eleitos visando a separação das classes de interesse e finalmente classificar a imagem WorldView-2. Para realizar tal tarefa foi necessário exportar todos os objetos da imagem e seus respectivos cálculos de atributos em formato Shapefile. O mesmo método de conversão das amostras de treinamento para formato CSV e ARFF citado anteriormente foi utilizado para realizar a conversão deste conjunto de dados. Quando convertido ele pôde ser usado como amostras de teste através da opção de teste *supplied test set* no WEKA, em que as regras geradas na árvore de decisão serão testadas neste conjunto de dados classificando, portanto, todos os objetos da imagem. A classificação é então salva no formato padrão ARFF. Com auxílio do *software* Notepad++ o formato foi alterado para o padrão CSV que retornou ao formato original *shapefile* através do *script* desenvolvido para o *software* estatístico R podendo finalmente ser visualizado como mapa, neste caso no *software* ArcGIS.

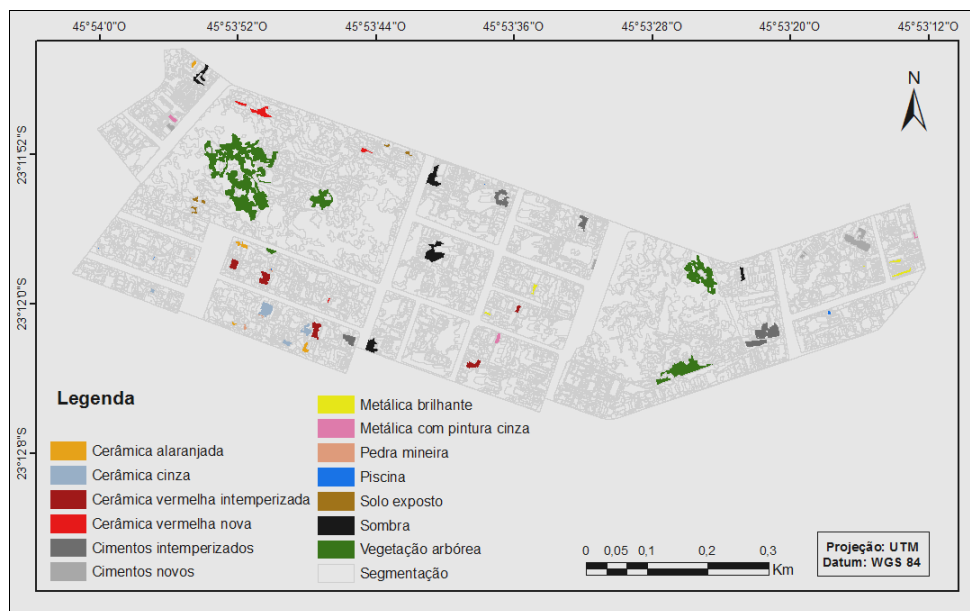
3.13. Avaliação das árvores de decisão

Em busca de se encontrar a árvore de decisão mais adequada para os experimentos com os algoritmos CART e C4.5, os modelos de árvores foram avaliados. Devido ao elevado número de testes obtidos em ambos os experimentos, totalizando 28 testes, foi necessário realizar uma avaliação preliminar da acurácia para se obter uma primeira observação de como seriam suas acurácias.

Como algumas classes apresentam um número limitado de objetos, o número de amostras se restringiu a 5 amostras por classe. Sendo assim o conjunto amostral de avaliação preliminar da acurácia apresenta 65 amostras as quais foram colhidas no nível 5 de segmentação sempre baseadas na chave de interpretação de classes e na verdade de campo (Figura 3.26). Esta primeira

observação permitiu comparar a acurácia obtida em cada teste e escolher, num primeiro momento, as árvores de decisão mais adequadas para cada algoritmo.

Figura 3.26 - Conjunto amostral de avaliação preliminar.



Fonte: Produção do autor.

Para comparar a classificação dada a cada objeto classificado na imagem dos dois testes, foi desenvolvido um mapa de concordância, o qual permite visualizar dentre todos os objetos quais foram classificados igualmente em relação aos dois algoritmos comparados. Este mapa também foi ajustado por classe.

Ainda, afim de se encontrar árvores de decisões que apresentem boas acurácias e sejam genéricas na definição de suas regras, a avaliação das árvores de decisão foi realizada tomando como base a complexidade das árvores de decisões. Para tanto, o valor da profundidade de cada árvore foi analisado. Este processo foi realizado através da contagem de todos os nós nela presentes, ou seja, suas folhas e suas decisões.

O desempenho dos modelos de testes selecionados, tanto para os com melhores acurácias preliminares como para os com boa capacidade de generalização, foram com o intuito de conhecer o grau de certeza associada a informação contida nas classificações de cobertura do solo urbano. Segundo

TAN et. al. (2009), a avaliação do desempenho de um modelo de classificação é baseada nas contagens de registros de testes previstos correta e incorretamente pelo modelo. A decisão sobre o número de amostras de validação foi realizada tomando como base o tamanho da área de cada classe para cada teste (Tabela 4.1, 4.2, 4.3 e 4.4). Estabelecido este valor, foi possível realizar o sorteio estratificado das amostras de validação por classe, as quais foram distribuídas aleatoriamente ao longo de cada classe.

Tabela 4.1 - Área e número de amostras de validação por classe do modelo de árvore de decisão do algoritmo CART com $M=3$.

Classe	Área (m ²)	Número de amostras
Piscina	1414,75	5
Pedra mineira	5865,50	10
Cerâmica alaranjada	9051,25	15
Metálica com pintura cinza	9405,25	20
Metálicas brilhantes	11931,50	25
Solo exposto	14141,50	30
Cerâmica vermelha intemperizada	15159,25	35
Cerâmica vermelha nova	17538,50	40
Cerâmica cinza	17904,50	45
Cimentos novos	18532,25	50
Cimentos intemperizados	52758,50	55
Sombra	61408,00	60
Arbórea	124221,50	65

Tabela 4.2 - Área e número de amostras de validação por classe do modelo de árvore de decisão do algoritmo C4.5 com M=3.

Classe	Área (m ²)	Número de amostras
Piscina	1874,00	5
Cerâmica alaranjada	5969,75	10
Metálica com pintura cinza	6115,75	15
Pedra mineira	8453,75	20
Cerâmica vermelha intemperizada	11696,75	25
Solo exposto	12699,25	30
Metálicas brilhantes	15211,25	35
Cimentos novos	15849,75	40
Cerâmica vermelha nova	22336,75	45
Cerâmica cinza	22361,00	50
Cimentos intemperizados	49602,00	55
Sombra	59136,25	60
Arbórea	123660,00	65

Tabela 4.3 - Área e número de amostras de validação por classe do modelo de árvore de decisão do algoritmo CART com M=10.

Classe	Área (m ²)	Número de amostras
Piscina	1874,00	5
Cerâmica alaranjada	5969,75	10
Metálica com pintura cinza	6115,75	15
Pedra mineira	8453,75	20
Cerâmica vermelha intemperizada	11696,75	25
Solo exposto	12699,25	30
Metálicas brilhantes	15211,25	35
Cimentos novos	15849,75	40
Cerâmica vermelha nova	22336,75	45
Cerâmica cinza	22361,00	50
Cimentos intemperizados	49602,00	55
Sombra	59136,25	60
Arbórea	123660,00	65

Tabela 4.4 - Área e número de amostras de validação por classe do modelo de árvore de decisão do algoritmo C4.5 com M=10

Classe	Área (m ²)	Número de amostras
Cerâmica alaranjada	1234,25	5
Piscina	1874,00	10
Metálica com pintura cinza	6115,75	15
Pedra mineira	7253,00	20
Cerâmica vermelha nova	11587,25	25
Solo exposto	12572,00	30
Metálicas brilhantes	17089,50	35
Cimentos novos	20103,50	40
Cerâmica vermelha intemperizada	24407,75	45
Cerâmica cinza	30871,50	50
Sombra	37783,50	55
Cimentos intemperizados	106181,50	60
Arbórea	120381,00	65

As contagens do número de classificações corretas em oposição às classificações preditas para cada classe foram tabuladas na matriz de confusão. A partir destas avaliações foi possível encontrar as acurácias do produtor e do usuário e exatidão global dos testes.

Por fim, os atributos selecionados na geração de regras de separação de classes pelas árvores de decisão foram comparados, com o intuito de responder se os mineradores de dados CART e C4.5 podem ser equivalentes quanto à definição de atributos para a classificação da cobertura do solo urbano.

4 RESULTADOS E DISCUSSÃO


4.1. Análise dos modelos de árvores de decisão testados

Uma vez que os parâmetros de testes foram estabelecidos foi possível obter 14 modelos de árvore de decisão gerados para cada algoritmo, CART e C4.5. As análises destes resultados serão apresentadas em 3 etapas, sempre em forma de análise comparativa. Inicialmente, as acurácias preliminares de cada teste serão avaliadas. Em seguida, com o intuito de se encontrar os modelos de árvores de decisão mais adequadas dos experimentos realizados, as profundidades das árvores serão observadas. Por fim, os atributos escolhidos pelos modelos serão explorados.

4.1.1. Avaliação preliminar da acurácia dos modelos de árvores de decisão testados

Para avaliar o desempenho dos modelos de classificação o grau de certeza associada a informação contida na classificação será apresentado através das acurácias preliminares obtidas em cada teste, as quais são exibidas abaixo (Figura 4.1). Vale ressaltar que o número mínimo de amostras por folha da árvore de decisão definido para cada teste é apresentado no gráfico após a sigla M, se o valor for 2, por exemplo, ele será representado como M2 e assim por diante.

Figura 4.1 - Comparação das árvores de decisão geradas pelos algoritmos CART e C4.5.




Fonte: Produção do autor.

A análise do gráfico permite afirmar que os resultados das acurácias preliminares dos dois testes permanecem estáveis conforme aumento do valor M, variando 4,6% nos testes com o algoritmo CART, 7,7% nos testes com o algoritmo C4.5 e 9,2% quando comparados entre si. É esperado que o aumento do valor M produza menores acurácias, como ocorre no caso do algoritmo CART, porém devido ao valor limitante 15 para M não foi possível verificar como seria o comportamento com valores de M maiores.

Ainda, ambas apresentam boa acurácia preliminar, no caso do CART as acurácias preliminares se concentram entre 72,3% e 76,9% e no caso do algoritmo C4.5 os resultados das acurácias preliminares se encontram no intervalo relativamente mais elevado de 73,8% a 81,5% o que corresponde a uma média superior em 3,8% do que as acurácias obtidas pelo classificador CART.

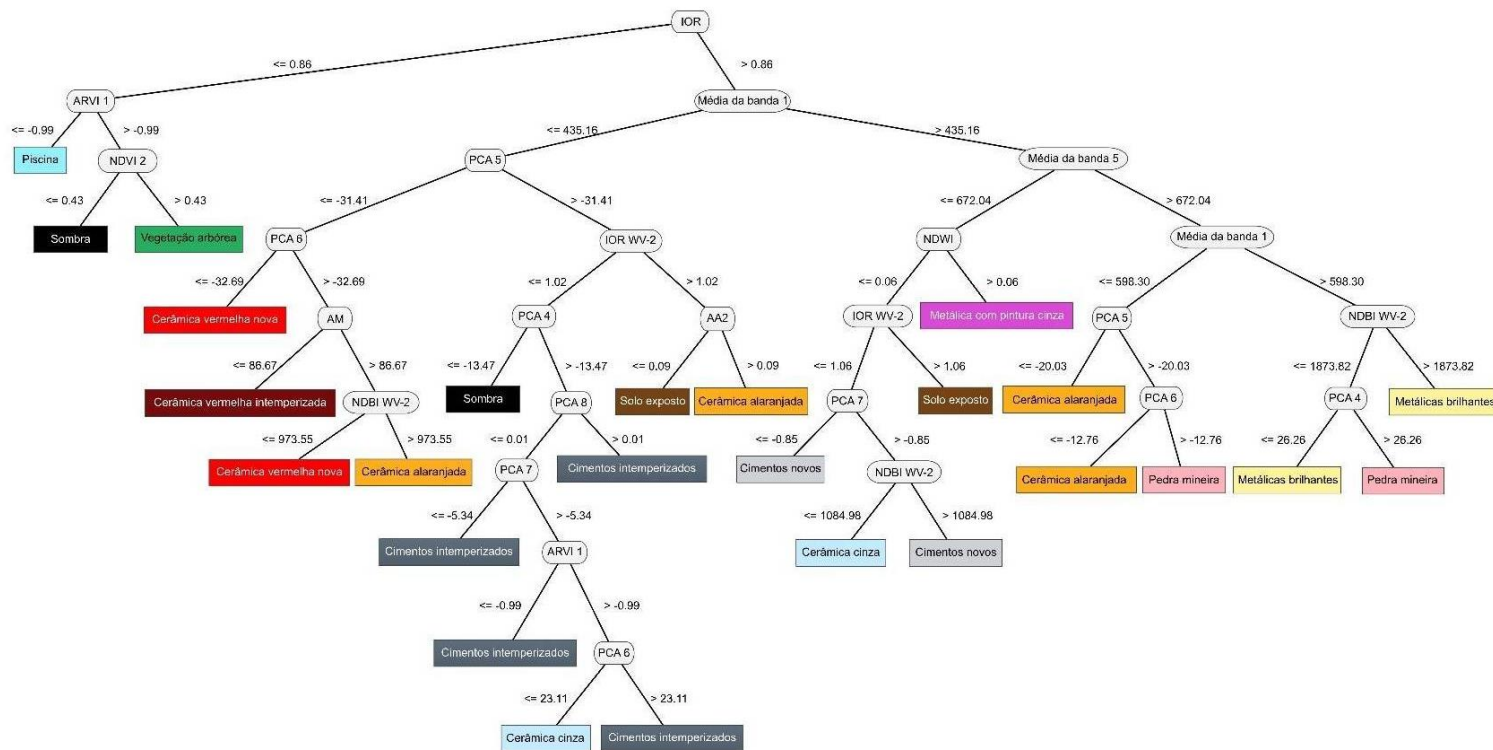
Num primeiro momento, a análise da diferença das performances das árvores de decisão geradas pelos dois algoritmos será realizada tomando como base o resultado que obteve a mesma acurácia preliminar para ambos os algoritmos, neste caso o teste que utilizou 3 instâncias como número mínimo para gerar uma regra, conforme apresentado anteriormente. Suas árvores de decisão são apresentadas a seguir (Figura 4.2 e 4.3).

Figura 4.2 - Árvore de decisão gerada pelo algoritmo CART com



Fonte: Produção do autor.

Figura 4.3 - Árvore de decisão gerada pelo algoritmo C4.5 com M=3.




Fonte: Produção do autor.

Embora as acurácias preliminares de ambas as árvores de decisão sejam idênticas, a árvore gerada pelo algoritmo C4.5 contém uma profundidade menor por apresentar 12 nós a menos do que a árvore gerada pelo algoritmo CART.

Seguindo os limiares dos atributos propostos para separação das classes de interesse os resultados das árvores de decisão foram transpostos para a rede hierárquica a fim de se obter a classificação da imagem WorldView-2 (Figura 4.4 e 4.5). Para que o leitor possa verificar a classe dada a cada objeto da imagem suas bordas foram mantidas.

Figura 4.4 - Classificação da cobertura do solo urbano da imagem WorldView-2 utilizando pelo algoritmo CART com M=3.

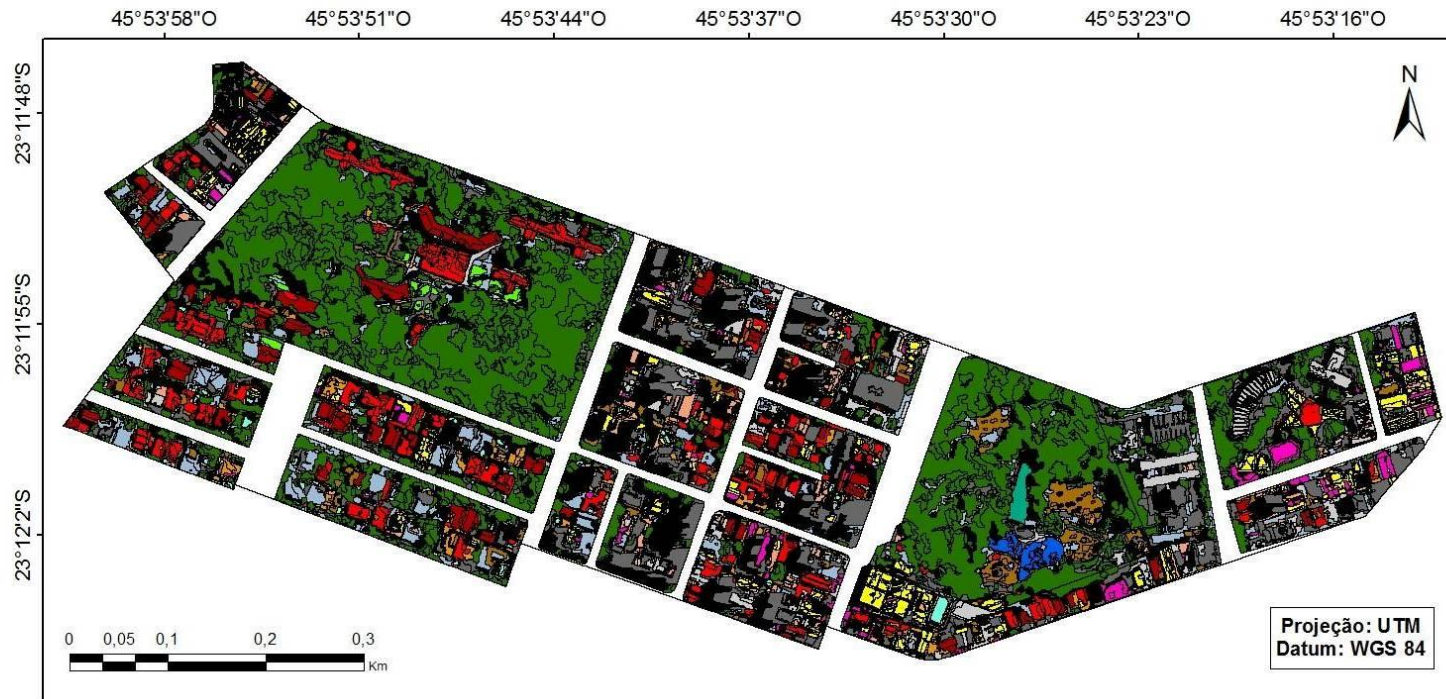


Legenda

Classificação semi-automática		Classificação manual	
Cerâmica alaranjada	Cimentos intemperizados	Asfalto	Piscina
Cerâmica cinza	Cimentos novos	Lago	Solo exposto
Cerâmica vermelha intemperizada	Metálica com pintura cinza	Sombra	Vegetação arbórea
Cerâmica vermelha nova	Metálicas brilhantes	Vegetação gramínea	
	Pedra mineira		

Fonte: Produção do autor.

Figura 4.5 - Classificação da cobertura do solo urbano da imagem WorldView-2 utilizando pelo algoritmo C4.5 com M=3.




Legenda

Classificação semi-automática		Classificação manual	
Cerâmica alaranjada	Cimentos intemperizados	Asfalto	Lago
Cerâmica cinza	Cimentos novos	Solo exposto	Metálica pintura verde
Cerâmica vermelha intemperizada	Metálica com pintura cinza	Sombra	Vegetação gramínea
Cerâmica vermelha nova	Metálicas brilhantes	Vegetação arbórea	
	Pedra mineira	Piscina	

Fonte: Produção do autor.

Através do desenvolvimento do mapa de concordância foi possível verificar se a classificação dada a cada objeto no teste realizado com o algoritmo CART foi a mesma dada no teste com o algoritmo C4.5 (Figura 4.6). Assim como no mapa de classificação do solo urbano as bordas dos objetos foram mantidas permitindo a observação de cada objeto individualmente.


Figura 4.6 - Mapa de concordância das classificações CART e C4.5 com M=3.



Fonte: Produção do autor.

A partir da análise do mapa de concordância foi possível verificar, dentre os 6380 objetos, quanto suas classificações concordam ou discordam (Figura 4.7).

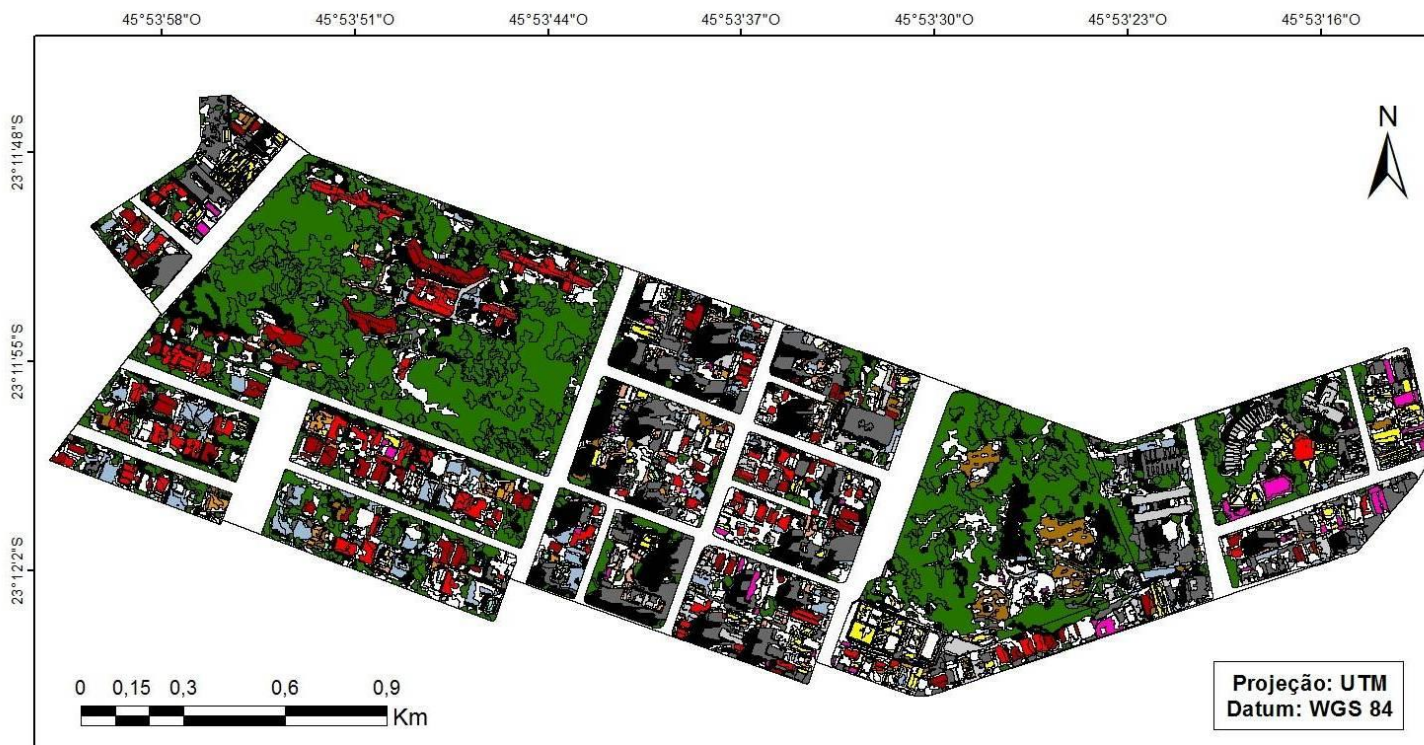
Figura 4.7 - Gráfico de concordância de classe entre os objetos classificados pelos modelos de árvore de decisão a partir dos algoritmos CART e C4.5, com $M=3$.



Fonte: Produção do autor.

Essa análise permitiu visualizar que os modelos de árvore de decisão gerados pelos algoritmos CART e C4.5 apresentam 61% de concordância nas suas classificações. Esta análise foi expandida por classe de cobertura do solo urbano conforme mapa de concordância por classe, apresentado na figura 4.8. Os objetos classificados igualmente receberam a cor representativa de sua classe, já os objetos classificados com classes diferentes não receberam nenhuma cor.

Figura 4.8 - Mapa de concordância por classes entre CART e C4.5 com M=3.




Legenda

Concordância de classes	Cerâmica vermelha intemperizada	Cimentos novos	Pedra mineira	Sombra
Cerâmica alaranjada	Cerâmica vermelha nova	Metálica com pintura cinza	Piscina	Vegetação arbórea
Cerâmica cinza	Cimentos intemperizados	Metálicas brilhantes	Solo exposto	Não concordam

Fonte: Produção do autor.

A partir da análise do mapa de concordância por classe foi possível verificar, dentre todos os objetos, quais as classificações por classes concordam (Figura 4.9).

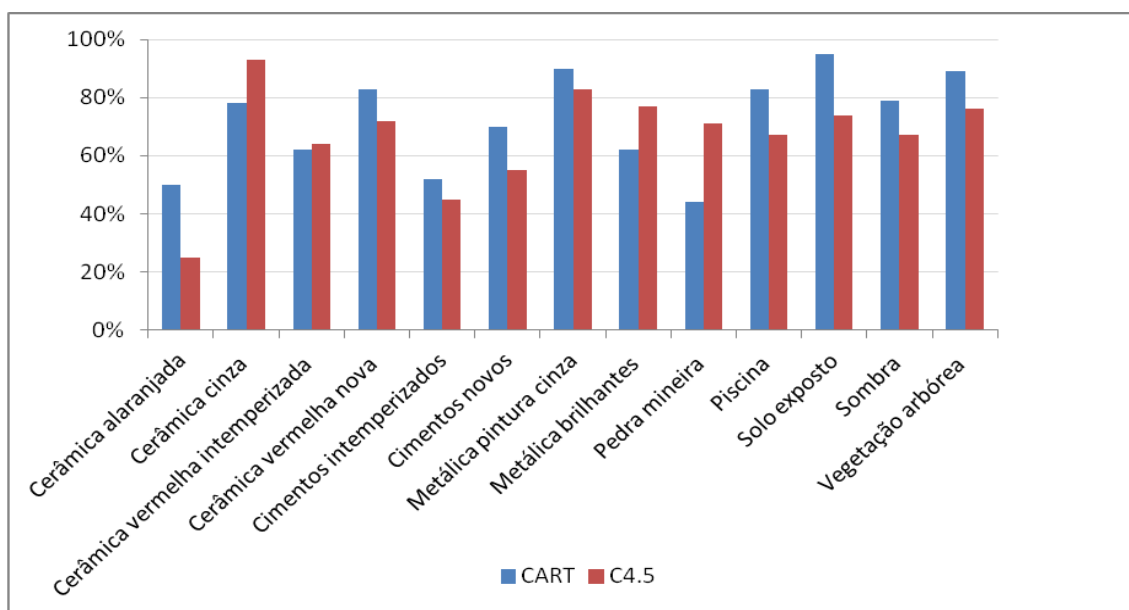
Figura 4.9 - Gráfico de concordância por classe entre os objetos classificados pelos modelos de árvore de decisão a partir dos algoritmos CART e C4.5, com M=3.



Fonte: Produção do autor.

Por fim, os acertos e erros dos mapas de classificação da cobertura urbana gerados pelos algoritmos CART e C4.5 foram avaliados. Suas acurácias foram analisadas por classe a partir da comparação da classe dada ao objeto presente no mapa classificado com a classe de referência dada pelas amostras de validação (Figura 4.10). Vale ressaltar que para esta análise foi utilizado o conjunto amostral de validação o qual possui um total de 455 amostras, equivalente a um conjunto 7 vezes maior que o conjunto amostral preliminar. Outra maneira de analisar de forma mais detalhada os erros e acertos entre mapa e referência se deu pela matriz de confusão (Figura 4.11 e Figura 4.12).

Figura 4.10 - Comparação das acurácias obtidas nas classificações a partir dos algoritmos CART e C4.5, com M=3.



Fonte: Produção do autor.

Figura 4.11 - Matriz de confusão da classificação com o algoritmo CART, com M=3.

Classificação	Cerâm. alaranjada	Cerâm. cinza	Cerâm. verm. intemp.	Cerâm. verm. nova	Cimentos intemp.	Cimentos novos	Metál. pint. cinza	Metál. brilhantes	Pedra mineira	Piscina	Solo exposto	Sombra	Veget. arbórea	Total	Exatidão do usuário
Cerâm. alaranjada	2	1	0	1	0	0	0	0	0	0	0	0	0	4	0,13
Cerâm. cinza	2	14	1	0	1	0	0	0	0	0	0	0	0	18	0,32
Cerâm. verm. intemp.	5	5	28	4	0	0	0	0	0	0	3	0	0	45	0,80
Cerâm. verm. nova	3	0	4	35	0	0	0	0	0	0	0	0	0	42	0,88
Cimentos intemp.	0	17	0	0	39	14	0	0	0	0	3	2	0	75	0,72
Cimentos novos	1	5	0	0	2	31	1	2	1	0	1	0	0	44	0,61
Metál. pint. cinza	0	0	0	0	0	0	9	0	0	0	1	0	0	10	0,45
Metál. brilhantes	2	0	0	0	1	0	9	23	2	0	0	0	0	37	0,92
Pedra mineira	1	0	0	0	0	5	0	0	7	0	3	0	0	16	0,70
Piscina	0	0	0	0	0	0	1	0	0	5	0	0	0	6	1,00
Solo exposto	0	0	0	0	0	1	0	0	0	0	18	0	0	19	0,60
Sombra	0	1	2	0	9	0	0	0	0	0	1	53	1	67	0,88
Veget. arbórea	0	1	0	0	2	0	0	0	0	0	0	5	64	72	0,98
Total	16	44	35	40	54	51	20	25	10	5	30	60	65	455	
Exatidão do produtor	0,50	0,78	0,62	0,83	0,52	0,70	0,90	0,62	0,44	0,83	0,95	0,79	0,89	455	
Exatidão Global	0,720879														

Fonte: Produção do autor.

Figura 4.12 - Matriz de confusão da classificação com o algoritmo C4.5, com M=3.

Classificação	Cerâm. alaranjada	Cerâm. cinza	Cerâm. verm. intemp.	Cerâm. verm. nova	Cimentos intemp.	Cimentos novos	Metál. pint. cinza	Metál. brilhantes	Pedra mineira	Piscina	Solo exposto	Sombra	Veget arbórea	Total	Exatidão do usuário
Cerâm. alaranjada	1	0	0	0	0	0	0	0	0	0	2	1	0	4	0,10
Cerâm. cinza	0	13	0	0	1	0	0	0	0	0	0	0	0	14	0,26
Cerâm. verm. intemp.	1	3	23	7	0	0	0	0	0	0	1	1	0	36	0,92
Cerâm. verm. nova	4	0	2	33	1	0	0	0	0	0	6	0	0	46	0,73
Cimentos intemp.	1	22	0	0	35	7	2	0	3	1	2	5	0	78	0,64
Cimentos novos	0	6	0	0	0	27	4	2	9	0	1	0	0	49	0,68
Metál. pint. cinza	1	0	0	0	0	0	5	0	0	0	0	0	0	6	0,33
Metál. brilhantes	0	0	0	0	0	4	4	33	2	0	0	0	0	43	0,94
Pedra mineira	1	0	0	0	0	0	0	0	5	0	1	0	0	7	0,25
Piscina	0	1	0	0	0	0	0	0	0	4	0	1	0	6	0,80
Solo exposto	1	1	0	0	1	1	0	0	1	0	14	0	0	19	0,47
Sombra	0	2	0	4	11	1	0	0	0	0	2	42	1	63	0,70
Veget. arbórea	0	2	0	1	6	0	0	0	0	0	1	10	64	84	0,98
Total	10	50	25	45	55	40	15	35	20	5	30	60	65	455	
Exatidão do produtor	0,25	0,93	0,64	0,72	0,45	0,55	0,83	0,77	0,71	0,67	0,74	0,67	0,76		
Exatidão Global	0,65714286														

Fonte: Produção do autor.

A partir das acurácias dadas pelo gráfico foi possível observar que as classes cerâmica alaranjada e cimentos intemperizados obtiveram os piores resultados em ambos os testes. A classe pedra mineira também apresentou baixa acurácia no teste realizado com o algoritmo CART e a classe cimentos novos para o teste com o algoritmo C4.5.

No caso da classe cerâmica alaranjada, a matriz de confusão permitiu visualizar que o algoritmo C4.5 cometeu erros de omissão desta, classificando-a como solo exposto e sombra. No caso do algoritmo CART esse erro se deu pela inclusão desta na classe cerâmica nova.

Quanto a classe cimentos intemperizados, houve grande confusão com classes que apresentam ND baixos. Dessa forma, esta classe foi confundida pelos classificadores C4.5 e CART com a classe cerâmica cinza. Ambos também a confundiram com sombra, cimentos novos e solo exposto. O classificador C4.5 também a confundiu com piscina.

Quanto a exatidão global, o modelo gerado pelo algoritmo CART obteve uma exatidão global 7% maior do que o gerado pelo algoritmo C4.5.


4.1.2. Análise da complexidade dos modelos de árvores de decisão testados

Valores de M baixos podem levar o algoritmo de mineração de dados a construir árvores de decisão complexas por subdividirem demasiadamente o conjunto de dados causando consequentemente um sobreajuste a área de

estudo em que estão sendo testadas. Isto impede que sua reprodução em outras áreas de estudo obtenha bons resultados.

Dessa forma, num segundo momento da análise dos resultados dos modelos de árvores de decisão testados, a análise da diferença das performances dos algoritmos CART e C4.5 será realizada tomando como base a complexidade das árvores de decisões. Para tanto o valor da profundidade de cada árvore será analisado. Estes podem ser observados no gráfico abaixo (Figura 4.13).

Figura 4.13 - Comparação das profundidades das árvores de decisão geradas pelos algoritmos CART e C4.5.

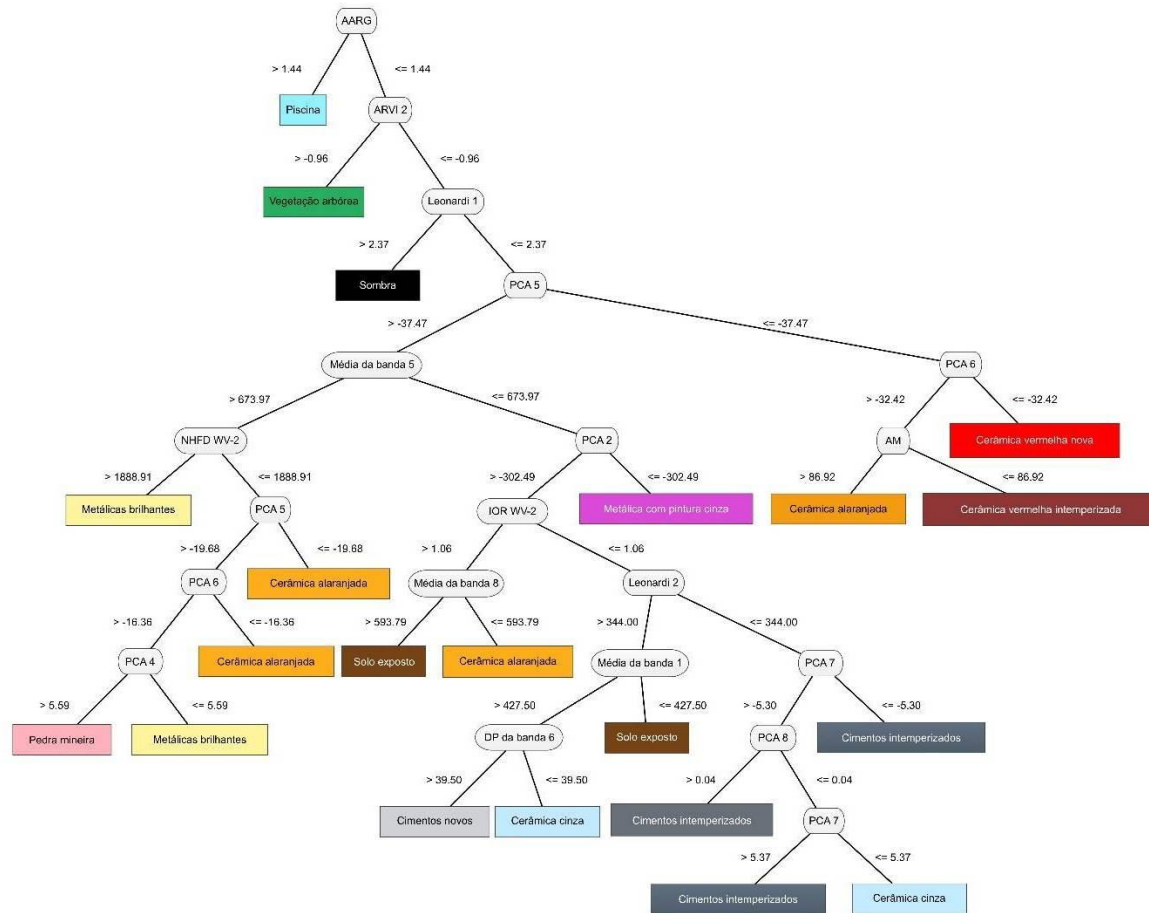


Fonte: Produção do autor.

Conforme esperado, ao aumentar o valor do M a profundidade das árvores tendem a diminuir. Isto se dá, pois, para o algoritmo gerar uma nova regra ele precisa que mais amostras respeitem a mesma condição, tornando mais difícil de se gerar uma regra. No caso dos testes realizados com o algoritmo CART a variação entre a maior e a menor árvore foi de 22 nós, enquanto que no caso do C4.5 os tamanhos das árvores variaram em 28 nós. Quando comparados, o algoritmo C4.5 apresenta uma diferença média de tamanho de 18 nós a menos do que as árvores geradas pelo algoritmo CART o que significa que o algoritmo C4.5 foi capaz de gerar árvores mais genéricas.

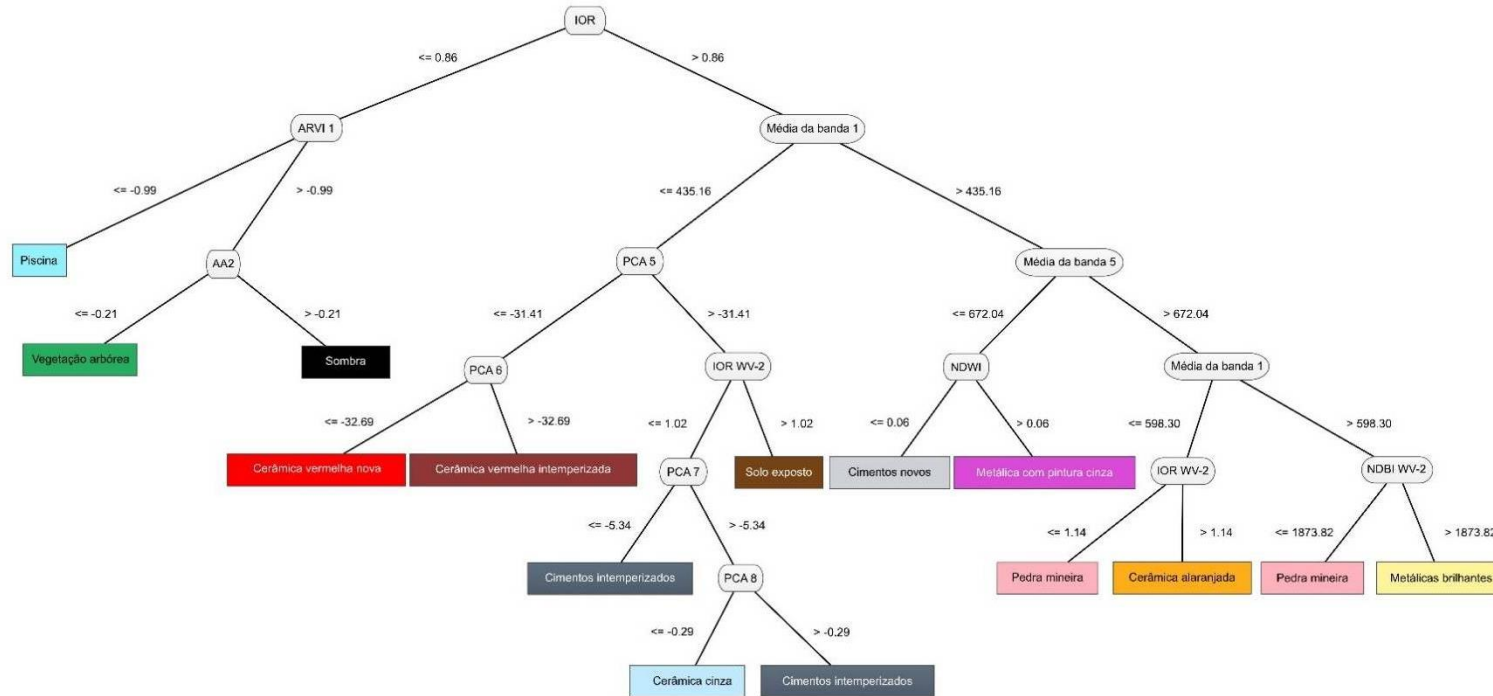
Em busca de uma árvore de decisão com boa capacidade de generalização e boa acurácia encontrou-se as árvores de decisão em que o modelo utilizou como parâmetro M o valor 10. Suas árvores de decisão são apresentadas a seguir (Figura 4.14 e 4.15).

Figura 4.14 - Árvore de decisão gerada pelo algoritmo CART com M=10.



Fonte: Produção do autor.

Figura 4.15 - Árvore de decisão gerada pelo algoritmo C4.5 com M=10.



Fonte: Produção do autor.


Conforme já apresentado, a acurácia do modelo gerado pelos algoritmos CART neste caso apresentou uma acurácia correspondente a 72,3% enquanto que o algoritmo C4.5 proporcionou uma acurácia levemente superior sendo esta de 73,8%, o que corresponde a uma diferença de 1,5%.

Quanto a profundidade das árvores de decisão, a árvore obtida pelo modelo CART apresentou 41 nós enquanto que a do modelo C4.5 29 nós, o que corresponde a uma diferença de 12 nós entre elas. Dessa forma, pode-se afirmar que a árvore do modelo C4.5 conseguiu atingir um maior nível de generalização.

No entanto quando estas árvores são comparadas com as árvores obtidas no teste com valor de M definido como 3, a diferença da profundidade entre os modelos é de 22 nós, o que significa que suas generalizações aumentaram para os modelos gerados pelo algoritmo CART e C4.5 com o valor dado a M igual a 10 em 35% e 43%, respectivamente.

Tendo os atributos mais adequados para a caracterização de cada classe de cobertura do solo e, portanto, o modelo de classificação gerado, a imagem WorldView-2 foi classificada conforme figuras 4.16 e 4.17.

Figura 4.16 - Classificação da cobertura do solo urbano da imagem WorldView-2 utilizando o algoritmo CART com M=10.



Legenda

Classificação semi-automática

- Cerâmica alaranjada
- Cerâmica cinza
- Cerâmica vermelha intemperizada
- Cerâmica vermelha nova

- Cimentos intemperizados
- Cimentos novos
- Metálica com pintura cinza
- Metálicas brilhantes
- Pedra mineira


- Piscina
- Solo exposto
- Sombra
- Vegetação arbórea

Classificação manual

- Asfalto
- Lago
- Metálica pintura verde
- Vegetação gramínea

Fonte: Produção do autor.

Figura 4.17 - Classificação da cobertura do solo urbano da imagem WorldView-2 utilizando o algoritmo C4.5 com M=10.



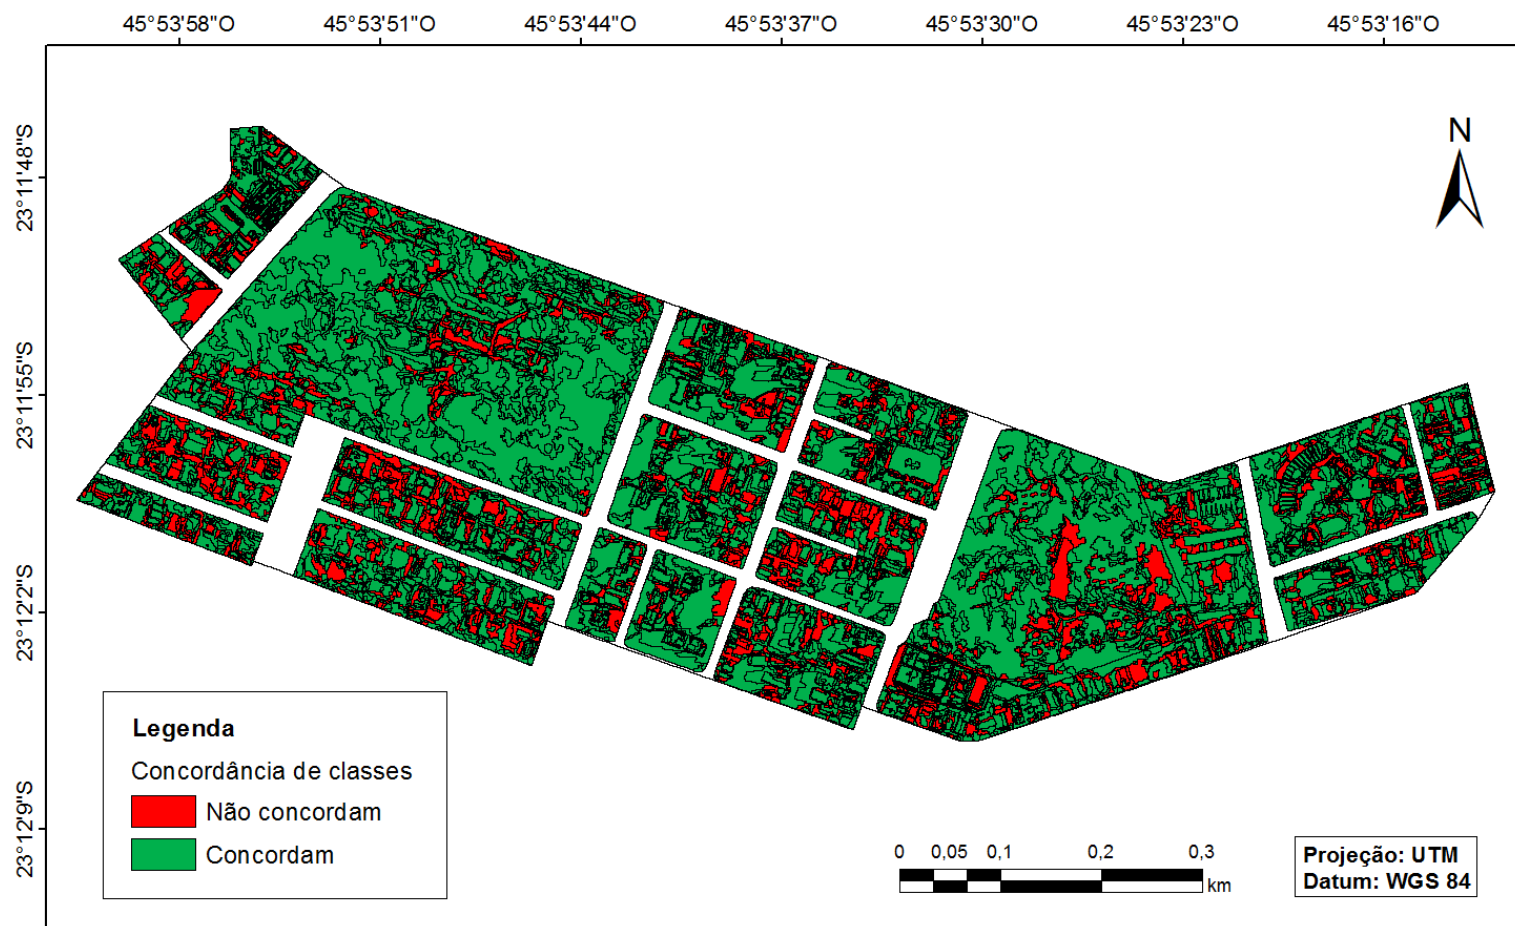
Legenda

Classificação semi-automática		Classificação manual	
Cerâmica alaranjada	Cimentos intemperizados	Piscina	Asfalto
Cerâmica cinza	Cimentos novos	Solo exposto	Lago
Cerâmica vermelha intemperizada	Metálica com pintura cinza	Sombra	Metálica pintura verde
Cerâmica vermelha nova	Metálicas brilhantes	Vegetação arbórea	Vegetação gramínea
	Pedra mineira		

Fonte: Produção do autor.

Para verificar se a classificação dos objetos do teste realizado com o algoritmo CART concordam ou discordam das classificações do teste com o algoritmo C4.5 foi desenvolvido o mapa de concordância no qual, para uma melhor visualização deste resultado, nos quais as bordas dos objetos foram mantidas permitindo a observação destes individualmente (Figura 4.18).


Figura 4.18 - Mapa de concordância das classificações CART e C4.5 com M=10.



Fonte: Produção do autor.

Os dados do mapa de concordância quando quantificados mostraram que 69% dos objetos de ambas as classificações concordam em suas classificações e 31% discordam (Figura 4.19).

Figura 4.19 - Gráfico de concordância de classe entre os objetos classificados pelos modelos de árvore de decisão a partir dos algoritmos CART e C4.5, com M=10.




Fonte: Produção do autor.

Quando o resultado do teste com valores de número mínimo de instâncias por folha definido como 10 é comparado com o resultado já apresentado com valor M igual a 3, é possível afirmar que os algoritmos que possuem parâmetros que geraram árvores de decisão mais genéricas tiveram resultados de classificações mais similares do que os modelos mais sobreajustados.

O cenário desta análise foi ampliado para todas as classes selecionadas para este estudo, o qual é apresentado abaixo (Figura 4.20). A simbologia segue a já apresentada anteriormente no mapa de concordância por classe para M igual a 3.

Figura 4.20 - Mapa de concordância por classe entre CART e C4.5 com M=10.




Legenda

Concordância de classes	Cerâmica vermelha intemperizada	Cimentos novos	Pedra mineira	Sombra
Cerâmica alaranjada	Cerâmica vermelha nova	Metálica com pintura cinza	Piscina	Vegetação arbórea
Cerâmica cinza	Cimentos intemperizados	Metálicas brilhantes	Solo exposto	Não concordam

Fonte: Produção do autor.

Para um melhor entendimento do resultado espacializado no mapa, estes foram quantificados de forma que se torna possível analisar quantos objetos de uma mesma classe concordam em sua classificação (Figura 4.21).


Figura 4.21 - Gráfico de concordância por classe entre os objetos classificados pelos modelos de árvore de decisão a partir dos algoritmos CART e C4.5, com M=10.



Fonte: Produção do autor.

Finalmente, as acurácias das classificações da cobertura urbana geradas pelos algoritmos CART e C4.5 com valor M igual a 10 são apresentadas. Seus resultados podem ser observados no gráfico de acurácia por classe (Figura 4.22) e matrizes de confusão (Figura 4.23 e Figura 4.24).

Figura 4.22 - Comparação das acurácias obtidas nas classificações a partir dos algoritmos CART e C4.5, com M=10.



Fonte: Produção do autor.

Figura 4.23 - Matriz de confusão da classificação com o algoritmo CART, M=10.

Classificação	Cerâm. alaranjada	Cerâm. cinza	Cerâm. verm. intemp.	Cerâm. verm. nova	Cimentos intemp.	Cimentos novos	Metál. pint. cinza	Metál. brilhantes	Pedra mineira	Piscina	Solo exposto	Sombra	Veget. arbórea	Total	Exatidão do usuário
Cerâm. alaranjada	3	2	0	0	0	1	0	0	0	0	0	0	0	6	0,07
Cerâm. cinza	1	12	0	0	1	0	0	0	0	0	0	1	0	15	0,24
Cerâm. verm. intemp.	19	5	25	2	0	0	0	0	0	0	0	0	0	51	1,00
Cerâm. verm. nova	12	0	0	28	0	0	0	0	0	2	0	0	0	42	0,93
Cimentos intemp.	0	20	0	0	52	5	2	1	0	0	1	3	0	84	0,87
Cimentos novos	3	2	0	0	0	27	0	1	5	0	1	0	0	39	0,68
Metál. pint. cinza	0	1	0	0	0	0	6	0	0	1	0	0	0	8	0,60
Metál. brilhantes	5	4	0	0	0	3	1	31	6	1	0	0	0	51	0,89
Pedra mineira	0	1	0	0	0	3	0	2	4	0	1	0	0	11	0,27
Piscina	0	0	0	0	0	0	0	0	0	3	0	0	0	3	0,60
Solo exposto	1	0	0	0	1	1	0	0	0	0	15	0	0	18	0,75
Sombra	1	2	0	0	5	0	1	0	0	0	0	51	0	60	0,93
Veget. arbórea	0	1	0	0	1	0	0	0	0	0	0	0	65	67	1
Total	45	50	25	30	60	40	10	35	15	5	20	55	65	455	
Exatidão do produtor	0,50	0,80	0,49	0,67	0,62	0,69	0,75	0,61	0,36	1,00	0,83	0,85	0,97		
Exatidão Global	0,70769231														

Fonte: Produção do autor.

Figura 4.24 - Matriz de confusão da classificação com o algoritmo C4.5, M=10.

Classificação Referência	Cerâm. alaranjada	Cerâm. cinza	Cerâm. verm. intemp.	Cerâm. verm. nova	Cimentos intemp.	Cimentos novos	Metál. pint. cinza	Metál. brilhantes	Pedra mineira	Piscina	Solo exposto	Sombra	Veget. arbórea	Total	Exatidão do usuário
Cerâm. alaranjada	3	0	1	0	0	0	0	0	0	0	3	0	0	7	0,60
Cerâm. cinza	0	7	1	0	2	2	0	0	2	0	0	0	0	14	0,15
Cerâm. verm. intemp.	0	2	35	0	0	0	0	0	0	0	6	0	0	43	0,78
Cerâm. verm. nova	0	0	5	25	0	1	0	0	0	0	0	0	0	31	1,00
Cimentos intemp.	0	20	1	0	41	9	6	0	2	4	2	0	0	85	0,65
Cimentos novos	1	1	0	0	1	23	1	1	2	0	0	0	0	30	0,58
Metál. pint. cinza	0	0	0	0	0	0	3	0	0	0	0	0	0	3	0,20
Metál. brilhantes	0	0	0	0	0	4	2	33	6	0	0	0	0	45	0,94
Pedra mineira	0	0	0	0	0	1	1	1	8	0	0	0	0	11	0,40
Piscina	0	0	0	0	0	0	1	0	0	6	0	0	0	7	0,60
Solo exposto	1	5	0	0	0	0	0	0	0	0	15	0	0	21	0,50
Sombra	0	8	2	0	14	0	1	0	0	2	0	54	3	84	0,98
Veget. arbórea	0	4	0	0	5	0	0	0	0	0	2	1	62	74	0,95
Total	5	47	45	25	63	40	15	35	20	10	30	55	65	455	
Exatidão do produtor	0,43	0,50	0,81	0,81	0,48	0,77	1,00	0,73	0,73	0,86	0,71	0,64	0,84		
Exatidão Global	0,69230769														

Fonte: Produção do autor.

De forma geral, as classificações obtiveram exatidões globais semelhantes, sendo que a classificação gerada pelo algoritmo CART apresentou um valor ligeiramente superior. O gráfico permitiu observar que ambos os algoritmos obtiveram baixas acurácias na classificação das classes cerâmica alaranjada e cimentos intemperizados. No primeiro caso a classificação foi incluída pelo algoritmo CART nas classes cerâmica cinza e cimentos novos. Já pelo algoritmo C4.5 como cerâmica vermelha intemperizada e solo exposto. No segundo caso, a confusão se deu com a classe cerâmica cinza, cimentos novos, metálicas com pintura cinza e solo exposto nos dois modelos. O algoritmo CART também a incluiu na classe sombra e o algoritmo C4.5 nas classes pedra mineira e piscina.

Ainda o algoritmo CART apresentou baixa acurácia na classificação das classes cerâmica vermelha intemperizada e pedra mineira. A primeira foi classificada como cerâmica alaranjada, cerâmica cinza e cerâmica vermelha nova enquanto que a classe pedra mineira foi incluída nas classes metálicas brilhantes, cerâmica cinza e solo exposto.

O algoritmo C4.5 apresentou baixa acurácia na classificação das classes cerâmica cinza e sombra. A primeira foi incluída nas classes cerâmica vermelha intemperizada e pedra mineira e a segunda nas classes cimentos intemperizados, sombra, cerâmica cinza, vegetação arbórea, cerâmica vermelha intemperizada e metálica com pintura cinza.

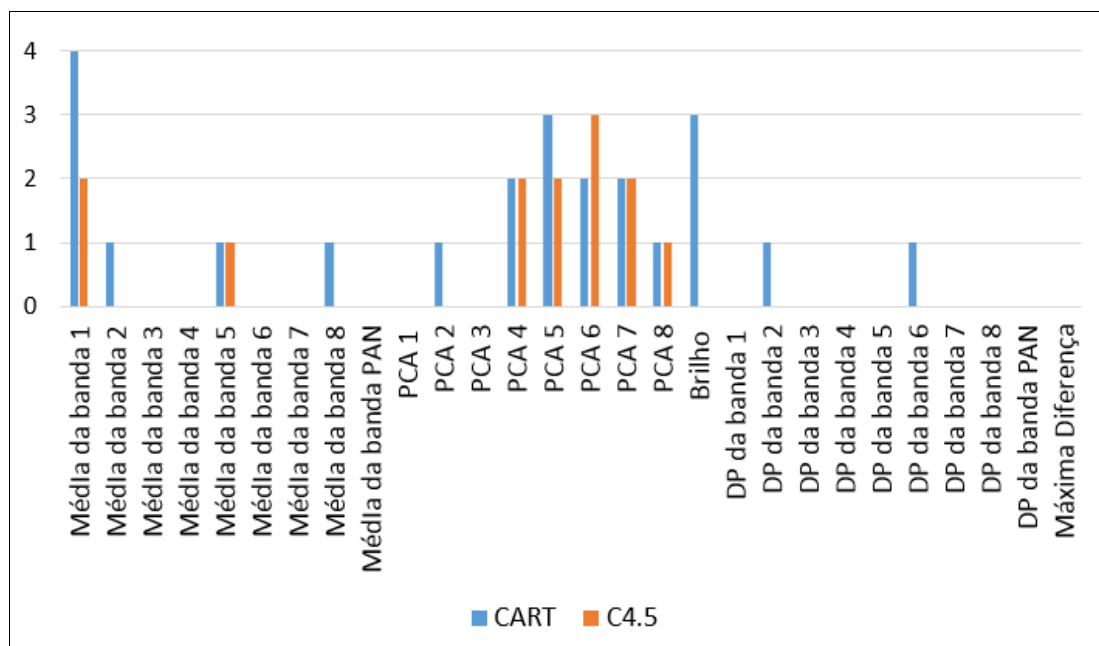
4.1.3. Análise dos atributos dos modelos de árvores de decisão selecionados

Diante do grande número de atributos desenvolvidos para este estudo o processo de mineração de dados atuou como recurso metodológico na seleção dos atributos mais adequados para a rotulação dos objetos às classes de interesse.

Assim, os atributos eleitos nos dois modelos de testes apresentados anteriormente serão explorados com o intuito de responder se os mineradores de dados CART e C4.5 são equivalentes quanto à definição de atributos para a classificação da cobertura do solo urbano.


Nas Figuras 4.25 e 4.26, dentre todos os atributos disponíveis aqueles selecionados para a separação das classes dos testes com acurácias idênticas ($M= 3$) são apresentados. Ainda, é possível verificar a quantidade de vezes em que estes são utilizados na geração de regras. Os atributos oferecidos pela plataforma eCognition foram nomeados como atributos simples e os atributos criados pelo usuário receberam a denominação de atributos customizados.

Figura 4.25 - Atributos simples selecionados no teste M=3.



Fonte: Produção do autor.

Figura 4.26 - Atributos customizados selecionados no teste M=3.



Fonte: Produção do autor.

A árvore de decisão CART precisou de 20 atributos para construir suas regras de separação dos objetos com diferentes classes, sendo 13 atributos simples e 7 atributos customizados, ao passo que a árvore C4.5 utilizou de um total de 15 atributos, 7 dos quais são simples e 8 customizados. Dentre estes atributos, 9 atributos foram utilizados tanto no teste CART quanto no teste C4.5, o que

significa que a 45% dos atributos do teste CART são os mesmos utilizados no teste C4.5 o que no teste C4.5 corresponde a 60% de atributos iguais. Eles são: média da banda 1, média da banda 5, PCA 4, PCA 5, PCA 6, PCA 7, PCA 8, IOR WV-2 e AM.

No caso do modelo com o algoritmo CART os atributos mais significativos na geração das regras foram média da banda 1, o qual foi utilizado 4 vezes, PCA 5 e brilho por terem sido requisitados 3 vezes e os atributos PCA4, PCA6 e PCA7 e Leonardi 1 os quais foram selecionados 2 vezes.

Já no modelo gerado pelo minerador C4.5 os atributos PCA 6 e NDBI WV-2 foram os mais utilizados, no caso 3 vezes, e os atributos ARVI 1, IOR WV-2, média da banda 1, PCA 4, PCA5 e PCA7 2 vezes.

De forma geral, é possível afirmar que dentre todos os atributos selecionados nas duas árvores de decisão em questão os que se mostraram mais relevantes na separação das classes são média da banda 1, PCA 4, PCA 5, PCA 6, PCA 7, tanto por terem sido utilizados pelos dois algoritmos quanto por terem sido responsáveis por criarem regras de partição dos objetos mais vezes.

Abaixo são apresentados os atributos utilizados para separar cada classe da cobertura do solo urbano (Tabela 4.5 e 4.6).

Tabela 4.5 - Atributos selecionados pelo algoritmo CART com M=3 para separação das classes de cobertura do solo urbano.

	AARG	AM	Brilho	DP da banda 2	DP da banda 6	Leonardi 1	Média da banda 1	Média da banda 2	Média da banda 8	PCA 2	PCA 4	PCA 5	PCA 6	PCA 7
Cerâmica alaranjada			x				x					x	x	
Cerâmica cinza					x			x						
Cerâmica vermelha intemperizada	x							x						
Cerâmica vermelha nova			x										x	
Cimentos intemperizados							x							x
Cimentos novos			x	x										
Metálica com pintura cinza							x		x					
Metálicas brilhantes			x				x			x				
Pedra mineira				x	x	x								
Piscina	x													
Solo exposto			x				x	x						
Sombra						x	x				x			
Vegetação arbórea											x			

Fonte: Produção do autor.

Tabela 4.6 - Atributos selecionados pelo algoritmo C4.5 com M=3 para separação das classes de cobertura do solo urbano.

	AA2	AARG	AM	ARVI 1	IOR WV-2	NDBI WV-2	NDVI 2	NDWI	PCA 4	PCA 5	PCA 6	PCA 7	PCA 8
Cerâmica alaranjada	x					x				x	x		
Cerâmica cinza						x					x		
Cerâmica vermelha intemperizada			x										
Cerâmica vermelha nova						x					x		
Cimentos intemperizados				x							x	x	x
Cimentos novos						x						x	
Metálica com pintura cinza								x					
Metálicas brilhantes						x			x				
Pedra mineira									x		x		
Piscina		x		x									
Solo exposto	x				x								
Sombra							x		x				
Vegetação arbórea							x						

Fonte: Produção do autor.

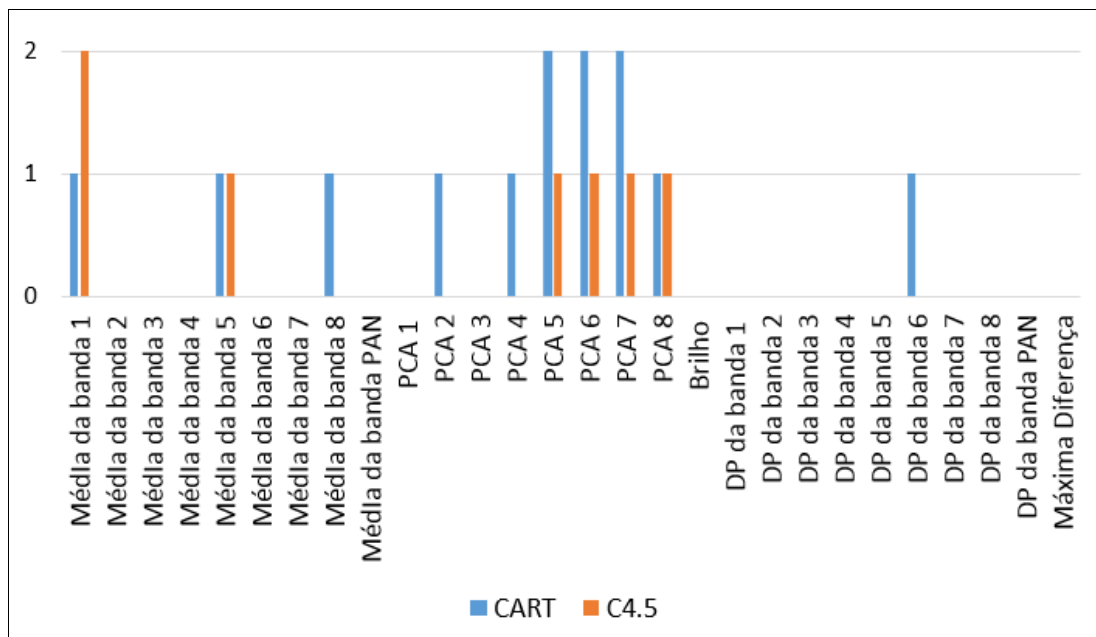
A análise da tabela acima nos mostra que mesmo tendo sido criados índices para tipos de alvos específicos, como os de vegetação e de água, nem sempre estes foram elegidos para a separação destas classes.

Neste contexto, apenas o modelo criado pelo algoritmo C4.5, no que diz respeito as classes vegetação arbórea e metálicos brilhantes, se utilizou dos índices de vegetação e de área construída, para a classificação destas classes, respectivamente.

Conforme apresentado na análise exploratória dos atributos, era esperado que 8 atributos fossem escolhidos pelo minerador de dados para a separação de 5 classes específicas de cobertura do solo urbano. No entanto, nenhum destes atributos foram utilizados pelo minerador. A similaridade se deu apenas na separação da classe vegetação onde se previa a utilização do atributo NDVI WV-2 e o atributo NDVI 2, que também se trata de um índice de vegetação, foi utilizado.


Por fim, os atributos selecionados para separação das classes nos testes com boa generalização das árvores (M= 10) são apresentados a seguir (Figura 4.27e 4.28).

Figura 4.27 - Atributos simples selecionados no teste M=10.



Fonte: Produção do autor.

Figura 4.28 - Atributos customizados selecionados no teste M=10.



Fonte: Produção do autor.

No caso das árvores mais genéricas construídas pelo algoritmo CART, 17 atributos foram utilizados para construir suas regras, sendo 10 atributos simples e 7 atributos customizados. Já o algoritmo C4.5 utilizou 12 atributos

dos quais 6 são simples e 6 customizados. Dentre estes, 7 atributos foram utilizados em ambos os modelos: IOR WV-2, média da banda 1, média da banda 5, PCA 5, PCA 6, PCA 7 e PCA 8. Este cenário representa 41% de paridade dos atributos selecionados no modelo CART com os do modelo C4.5. Para o modelo CART essa proporção equivale a 58%.

Os atributos mais significativos na geração das regras do modelo CART são PCA5, PCA6 e PCA7, os quais foram selecionados 2 vezes. No modelo C4.5 os atributos IOR WV-2 e média da banda 1 foram selecionados 2 vezes e, portanto, são os mais relevantes.

Com o intuito de visualizar quais atributos permitiram a rotulação das classes, estes são apresentados abaixo nas tabelas 4.4 e 4.5.

Tabela 4.7 - Atributos selecionados pelo algoritmo CART com M=10 para separação das classes de cobertura do solo urbano.

	AARG	AM	ARVI 2	DP da banda 6	Leonardi 1	Média da banda 1	Média da banda 8	NHFD WV-2	PCA 2	PCA 4	PCA 5	PCA 6	PCA 7	PCA 8
Cerâmica alaranjada		X					X				X	X		
Cerâmica cinza				X										
Cerâmica vermelha intemperizada		X												
Cerâmica vermelha nova												X		
Cimentos intemperizados													X	X
Cimentos novos				X										
Metálica com pintura cinza									X					X
Metálicas brilhantes								X		X				
Pedra mineira										X				
Piscina	X													
Solo exposto						X	X							
Sombra					X									
Vegetação arbórea			X											

Fonte: Produção do autor.

Tabela 4.8 - Atributos selecionados pelo algoritmo C4.5 com M=10 para separação das classes de cobertura do solo urbano.

	AA2	ARVI 1	IOR WV-2	NDBI WV-2	NDWI	PCA 6	PCA 7	PCA 8
Cerâmica alaranjada			X					
Cerâmica cinza								X
Cerâmica vermelha intemperizada						X		
Cerâmica vermelha nova						X		
Cimentos intemperizados							X	X
Cimentos novos					X			
Metálica com pintura cinza					X			
Metálicas brilhantes				X				
Pedra mineira			X	X				
Piscina		X						
Solo exposto			X					
Sombra	X							
Vegetação arbórea	X							

Fonte: Produção do autor.

A árvore de decisão construída pelo algoritmo CART selecionou o índice de vegetação para classificar este tipo de alvo, conforme esperado. Este algoritmo também utilizou o índice para identificar áreas com construções antrópicas para separar alvos metálicos brilhantes, situação também encontrada na árvore gerada pelo algoritmo C4.5. Vale destacar que este último algoritmo utilizou o atributo IOR WV-2 para separação de alvos cerâmicos análogo ao previsto na análise exploratória dos atributos.

5 CONCLUSÃO

Conforme apresentado, o desempenho dos algoritmos de árvore de decisão e árvore de regressão na classificação da cobertura do solo urbano, a partir de imagens orbitais de alta resolução espacial foram analisados se valendo dos algoritmos de mineração de dados C4.5, presente na plataforma WEKA, e CART, disponível na plataforma eCognition.

No quesito acurácia preliminar, o algoritmo C4.5 obteve, em geral, melhores resultados do que o algoritmo CART. No entanto, o cálculo das acurácias dos testes selecionados mostrou um cenário contrário ao anterior, ou seja, embora as acurácias de ambos os algoritmos sejam similares os do algoritmo CART se mostrou mais elevado. Diante deste cenário, recomenda-se para trabalhos futuros realizar estes cálculos para todos os 28 modelos testados.

Quanto aos modelos de árvore de decisão obtidos nos experimentos, o algoritmo C4.5 apresentou melhor capacidade de generalização na formulação das regras por atributo. Quanto ao número de atributos selecionados por algoritmo, o minerador CART recorreu a um número maior de atributos quando comparado ao algoritmo C4.5.

Conforme apresentado, o teste em que se utilizou o algoritmo C4.5, exigiu do usuário a migração do ambiente de GEOBIA para o de mineração de dados e, após a definição do modelo de classificação, seu retorno. O presente estudo, assim como a maioria da literatura científica apresentada ao longo deste trabalho, se apoia em mais de um programa computacional para executar suas análises, impondo desafios aos pesquisadores. Dentre eles podemos citar a integração de dados, a conversão de formato dos dados, o conhecimento do *software* a ser utilizado, além da replicação de arquivos.

Ainda que a área de estudo seja uma área piloto, cobrindo uma área geográfica reduzida, o número de objetos gerados foi considerado grande

(6.380 objetos). Para realizar o intercâmbio de dados entre diversos sistemas, quando for utilizada uma cena completa, pode acarretar em uma barreira imposta pelo volume de dados, visto que além das geometrias dos objetos, é preciso também computar o conjunto de atributos de cada objeto.

Consequentemente, a possibilidade de uma plataforma que integre todas as tarefas de análise de imagem, como segmentação, extração e seleção de atributos, coleta de amostras, geração da árvore de decisão e classificação, é um benefício para o usuário, no que diz respeito à redução de tempo para a realização de todas as etapas.

O cenário resume o teste realizado na plataforma eCognition com o algoritmo CART, a qual recentemente complementou sua plataforma com uma ferramenta de mineração de dados. Em contrapartida as vantagens descritas, o alto custo de licenciamento pode ser uma barreira para a sua utilização. Dessa maneira sugere-se como alternativa buscar ambientes computacionais que utilizem a política de *software* livre.

REFERÊNCIAS BIBLIOGRÁFICAS

AKSOY, S.; KOPERSKI, K.; TUSK, C.; MARCHISIO, G. Interactive Training of Advanced Classifiers for Mining Remote Sensing Image Archives.

ACM International Conference on Knowledge Discovery and Data Mining. Seattle, p. 773-782, 2004.

ALMEIDA, C. M. Aplicação dos sistemas de sensoriamento remoto por imagens e o planejamento urbano e regional. **Arq.Urb – Revista Eletrônica de Arquitetura e Urbanismo (USJT)**, n. 3, p. 98-123, 2010.

ANJOS, C. S. **Classificação de áreas urbanas com imagens multiespectrais e hiperespectrais utilizando métodos não-paramétricos**. 2016. 380p. Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2016. Disponível em: <<http://urlib.net/8JMKD3MGP3W34P/3LESGT2>>. Acesso em: 02 ago. 2016.

BAATZ, M.; SCHÄPE, A. Multiresolution segmentation – an optimization approach for high quality multi-scale image segmentation. In: *Angewandte Geographische Informationsverarbeitung XII. Beiträge Zum Agitsymposium Salzburg, 12., 2000, Karlsruhe*. **Proceedings...** Karlsruhe Herbert Wichmann Verlag, p. 12-23, 2000.

BELFIORE, O. R.; PARENTE, C. Orthorectification and Pan-Sharpening of WorldView-2 Satellite Imagery to Produce High Resolution Coloured Ortho-Photos. **Modern Applied Science**, v. 9, n. 9, p. 122-130, 2015.

BREIMAN, L.; FRIEDMAN, J. H.; OLSHEN, R. A.; STONE, C. J. **Classification and regression trees**. Boca Raton: Chapman & Hall/CRC, 1984. 293 p. ISBN(0-412-04841-8).

CARVALHO, M. V. A. **Classificação da cobertura e uso do solo com imagens WorldView-2 utilizando mineração de dados e análise baseada em objeto**. 2011. 211 p. (sid.inpe.br/mtc-m19/2011/09.05.20.27-TDI). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2011. Disponível em: <<http://urlib.net/8JMKD3MGP7W/3ACT3BL>>. Acesso em: 8 jan 2015.

CHEN, M.; SU, W.; LI, L.; ZHANG, C.; YUE, A.; LI, H. Comparison of Pixel-based and Object-oriented Knowledge-based Classification Methods Using SPOT5 Imagery. **WSEAS Transactions on Information Science and Application**, v. 6, Mar., p. 447-489, 2009.

COWEN, D. J.; JENSEN, J. R. Extraction and Modeling of Urban Attributes Using Remote Sensing Technology. In: LIVERMAN, D.; MORAN, E.F.; RINDFUSS, R. R.; STERN, P. C. (eds.). **People and pixels: linking remote sensing and social science**. Washington, D.C.: National Academy Press, 1 ed. 1998. Cap. 8, p. 164-188.

CULLINGWORTH, B. **Planning in the USA: policies, issues and processes**. London: Routledge, 280 p., 1997.

DESCLÉE, B.; BOGAERT, P.; DEFOURNY, P. Forest change detection by statistical object-based method. **Remote Sensing of Environment**, v. 102, p. 1–11, 2006.

DIGITAL GLOBE. **Radiometric use of WorldView-2 imagery**. Technical Note. 2010. Disponível em: <https://www.digitalglobe.com/sites/default/files/Radiometric_Use_of_WorldView-2_Imagery%20%281%29.pdf>. Acessado em: 8 jan 2015.

DONNAY, J. P.; BARNSLEY, M. J.; LONGLEY, P. A. **Remote Sensing and Urban Analysis**. New York: Taylor & Francis, 268 p., 2001.

FORMAGGIO, A. R.; VIEIRA, M. A.; RENNÓ, C. D. Object based image analysis (OBIA) and Data Mining (DM) in Landsat time series for mapping soybean in intensive agricultural regions. In: Geoscience and Remote Sensing Symposium (IGARSS), 2012, Munique. **Anais...** p. 2257-2260. Disponível em: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=6351047>>. Acesso em 16 jan 2015.

FRANCISCO, C. N.; ALMEIDA, C. M. Avaliação de desempenho de atributos estatísticos e texturais em uma classificação de cobertura da terra baseada em objeto. **Bol. Ciênc. Geod.**, sec. Artigos, Curitiba, v. 18, n. 2, p. 302-326, abr-jun, 2012.

GITELSON, A.; MERZLYAK, M. Remote Sensing of Chlorophyll Concentration in Higher Plant Leaves. **Advances in Space Research**, v. 22, p. 689-692, 1998.

HAY, G.; BLASCHKE, T. Special issue: Geographic Object-Based Analysis (GEOBIA). **Photogrammetric engineering & remote sensing**, v. 76, n. 2, p. 121-122, February 2010.

HAY, G.; CASTILLA, G. Geographic Object-Based Image Analysis (GEOBIA): A new name for a new discipline. In: BLASCHKE, T.; LANG, S.; HAY, G. **Object-based image analysis - spatial concepts for knowledge-driven remote sensing applications**. Berlin, Heidelberg: Springer-Verlag, 2008. cap. 1.4, p. 75-89.

HAY, G. J.; HEMACHANDRAN, B.; RAHMAN, M.; KARIM, B.; COULOIGNER, I.; KAMBEROV, R. **GEOBIA – evolving beyond segmentation**. Tessaloniki, Grécia, 2014. Apresentação realizada no evento GEOBIA, em 24 de maio de 2014.

HELLENSEN, T.; MATIKAINEN, L. An Object-Based Approach for Mapping Shrub and Tree Cover on Grassland Habitats by Use of LiDAR and CIR Orthoimages. **Remote Sens**, v. 5, p. 558-583, 2013.

HOFMANN, P. Detecting informal settlements from IKONOS image data using methods of object oriented image analysis – an example from Cape Town

(South Africa). In: INTERNATIONAL SYMPOSIUM REMOTE SENSING OF URBAN AREAS, 2., 2001, Regensburg, Germany. **Proceedings...** Regensburg, Germany: Institut für Geographie an der Universität Regensburg, 2001. p. 107-118.

HOFMANN, P.; REINHARDT, W. The extraction of GIS features from high resolution imagery using advanced methods based on additional contextual information – first experiences. In: CONGRESS OF THE ISPRS, 21, GEOINFORMATION FOR ALL, 2000, Amsterdam, Holanda. **Proceedings...** Amsterdam: IRPRS, v. 33/B4, p. 376-383.

HUETE, A. A Soil-Adjusted Vegetation Index (SAVI). **Remote Sensing of Environment**, v. 25, p. 295-309, 1988.

HUETE, A.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E. P.; GAO, X.; FERREIRA, L. G. Overview of the Radiometric and Biophysical Performance of the MODIS Vegetation Indices. **Remote Sensing of Environment**, v. 83, p. 195–213, 2002.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **RBMC: Rede Brasileira de Monitoramento Contínuo dos Sistemas GNSS.**

Disponível em:

<<http://www.ibge.gov.br/home/geociencias/geodesia/rbmc/rbmc.shtm>>. Acesso em: 22 mar. 2016a.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Dados estatísticos da cidade de São José dos Campos.** Disponível

em:<<http://cidades.ibge.gov.br/xtras/perfil.php?codmun=354990>>. Acesso em: 22 mar. 2016b.

JENSEN, J. R. Sensoriamento remoto da paisagem urbana. In: JENSEN, J. R. (ed.). **Sensoriamento Remoto do Ambiente: uma perspectiva em recursos terrestres.** 2. ed.. São José dos Campos: Parêntese, 2011. cap. 13, p. 445-510.

KAUFMAN, Y.; TANRE, D. Atmospherically Resistant Vegetation Index (ARVI) for EOS-MODIS. **IEEE Transactions on Geoscience and Remote Sensing**, v. 30, n. 2, p. 261-270, 1992.

KORTING, T. S.; FONSECA, L. M. G.; CÂMARA, G. GeoDMA – Geographic Data Mining Analyst. **Computer & Geosciences**, v. 57, p. 133-145, 2013.

LEONARDI, F. **Abordagens cognitivas e mineração de dados aplicadas a dados ópticos orbitais e de laser para a classificação de cobertura do solo urbano.** 2010. 162 p. INPE-16708-TDI/1648. Dissertação (Mestrado em Sensoriamento Remoto). INPE – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2010. Disponível em: <<http://sid.inpe.br/mtc-m19@80/2010/03.17.11.42>>. Acessado em: 7 jan 2015.

MENESES, P. R.; ALMEIDA, T. **Introdução ao processamento de imagens de sensoriamento remoto.** Brasília: UnB, 2012. 276 p. Disponível em:

<<http://www.cnpq.br/documents/10157/56b578c4-0fd5-4b9f-b82a-e9693e4f69d8>>.

MOHRI, M. **Introduction to machine learning lecture 10**. Apresentação realizada na New York University Computer Science, 2011. Disponível em: <http://www.cs.nyu.edu/~mohri/mlu/mlu_lecture_10.pdf>. Acesso em: 8 jan 2015.

NAVULUR, K. **Multispectral image analysis using the object-oriented paradigm**. Boca Raton: CRC Press, 165 p. 2007.

NOVACK, T. **Classificação da cobertura da terra e do uso do solo urbano utilizando o sistema InterIMAGE e imagens do sensor Quick-Bird**. 2009. 214 p. INPE-16594-TDI/1580. Dissertação (Mestrado em Sensoriamento Remoto). INPE – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2009.

NOVACK, T.; KUX, H. J. H.; FEITOSA, R. Q.; COSTA, G. A. O. P. A Knowledge-Based, transferable approach for Block-Based urban Land-Used classification. **International Journal of Remote Sensing**, v. 35, p. 4739-4757, 2014.

PINHO, C. M. D. **Análise orientada a objetos de imagens de satélites de alta resolução espacial aplicada à classificação de cobertura do solo no espaço intraurbano: o caso de São José dos Campos**. 2005. 180 p. INPE-14183-TDI/1095. Dissertação (Mestrado em Sensoriamento Remoto). INPE – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2005. Disponível em: <<http://urlib.net/sid.inpe.br/MTCm13@80/2005/11.23.13.40>>. Acesso em: 7 jan 2015.

PINHO, C. M. D.; FONSECA, L. M. G.; KORTING, T. S.; ALMEIDA, C. M.; KUX, H. J. H. Land-cover classification of an intra-urban environment using high-resolution images and object-based image analysis. **International Journal of Remote Sensing**, v. 33, n. 19, p. 5973-5995, 2012.

PINHO, C. M. D.; SILVA, F. C.; FONSECA, L. M. G.; MONTEIRO, A. M. V. Urban land cover classification from high-resolution images using the C4.5 algorithm. **The International Archives of the Photogrammetry, Remote sensing and Spatial Information Sciences**. v. 37,, part. B7,p. 695-700, Pequim, 2008.

QUINLAN, J. R. **C4.5: programs for machine learning**. San Mateo: Morgan Kaufmann Publishers, 1993. 302 p. ISBN(1-55860-238-0).

QUINLAN, J. R. Inducible of decisivos trees. **Machine Learning**, v. 1, Jan., p. 81-106, 1986.

RAMAKRISHNAN, N. C4.5. In: **The top ten algorithms in data mining**. Boca Raton: Taylor & Francis Group, cap. 1, p. 1-20, 2009.

RIBEIRO, B. M. G.; FONSECA, L. M. G. Urban Land-Cover Classification using WorldView-2 Images and C4.5 Algorithm. In: URBAN REMOTE SENSING

EVENT (JURSE), 2013, São Paulo. **Anais...** p. 250-253. Disponível em: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=6550712>>. Acesso em 16 jan 2015.

RIBEIRO, B. M. G.; FONSECA, L. M. G.; KUX, H. J. H. Mapeamento da cobertura do solo urbano utilizando imagens WorldView-II e o Sistema InterIMAGE. **Revista Brasileira de Cartografia**, v. 63, p. 51-63, 2011.

RINDFUSS, R. R.; STERN, P. C. **People and pixels: linking remote sensing and social science**. 1 ed. Washington D.C.: National Academy Press, 244 p., 1998.

RODRIGUES, M. A. S. **Árvores de classificação**. 2005. 32 p. (ID54.218). Monografia - Departamento de Matemática da Universidade dos Açores, Ponta Delgada. 2005.

RODRIGUES, T. C. S. **Classificação da cobertura e do uso da terra com imagens WorldView-2 de setores norte da Ilha do Maranhão por meio do aplicativo InterIMAGE e de mineração de dados**. 2014. 107 p. (sid.inpe.br/mtc-m21b/2014/03.31.19.30.37-TDI). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2014. Disponível em: <<http://urlib.net/8JMKD3MGP5W34M/3G3DA4C>>. Acesso em: 8 jan 2015.

ROUSE, J.; HAAS, R.; SCHELL, J.; DEERING, D. Monitoring vegetation systems in the great plains with ERTS. In: ERTS SYMPOSIUM, 1973. **Proceedings...** NASA, 1973. p. 309-317

SILVA, M. P. S.; CÂMARA, G.; ESCADA, M. I. S.; SOUZA, R.C.M.de. Remote Sensing Image Mining: Detecting Agents of Land Use Change in Tropical Forest Areas. **International Journal of Remote Sensing**, v.29, n.16, p. 4803-4822, 2007.

SMALL, C. The Landsat ETM+ Spectral Mixing Space. **Remote Sensing of Environment**, v. 93, p. 1-17, 2004.

SOUZA, I. M. **Sensoriamento remoto orbital aplicado a estudos urbanos**. 2012. 39 p. (sid.inpe.br/mtc-m19/2012/02.28.13.46-PUD). Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2012. Disponível em: <<http://urlib.net/8JMKD3MGP7W/3BEFCJH>>. Acesso em 15 jan 2015.

SOUZA, I. M.; PEREIRA, M. N.; FONSECA, L. M. G.; KURKDJIAN, M. L. N. O. Mapeamento do uso do solo urbano através da classificação por regiões baseada em medidas texturais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11. (SBSR), 2003, Belo Horizonte. **Anais...** São José dos Campos: INPE, 2003. p. 1967-1968. CD-ROM. ISBN 85-17-00017-X. (INPE-16180-PRE/10783). Disponível em: <<http://urlib.net/ltid.inpe.br/sbsr/2002/11.14.15.20>>. Acesso em: 16 jan 2015.

SRIPADA, R. P.; HEINIGER, R. W.; WHITE, J. G.; MEIJER, A. D. Aerial Color Infrared Photography for Determining Early In-season Nitrogen Requirements in Corn. **Agronomy Journal**, v. 98, p. 968-977, 2006.

TAN, P. N.; STEINBACH, M.; KUMAR, V. **Introdução ao DATA MINING - mineração de dados**. Rio de Janeiro: Ciência Moderna, 900 p., 2009.

TOPCON POSITIONING SYSTEMS. **Manual do operador (HiPer)**. Setembro, 2003. 173 p. (Part Number 7010-0419 Rev C).

TRIMBLE. **eCognition Developer 8.7**: reference book. Germany, 2011a, 438 p. Disponível em: <<http://www.ecognition.com/>>. Acesso em: 21/3/2016.

TRIMBLE. **eCognition Developer 8.7**: user guide. Germany, 2011b, 250 p. Disponível em: <<http://www.ecognition.com/>>. Acesso em: 25 fev 2015.

TRIMBLE. **Object levels and segmentation**. Disponível em: <<http://www.ecognition.com/?login=http://community.ecognition.com/home/object-levels-and-segmentation>>. Acesso em: 25 mar. 2016.

VIEIRA, M. A. **Análise de imagem orientada a objeto e mineração de dados aplicadas ao mapeamento da cultura de cana de açúcar**. 2010. 110 p. (sid.inpe.br/mtc-m19@80/2010/04.08.17.43-TDI). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2010. Disponível em: <<http://urlib.net/8JMKD3MGP7W/37A6SQ8>>. Acesso em: 8 jan 2015.

WELCH, R. Spatial resolution requirements for urban studies. **International Journal of Remote Sensing**, v. 3, p. 139-146, 1982.

WILSON, J. S.; CLAY, M.; MARTIN, E.; STUCKEY, D.; VEDDER-RISCH, K. Evaluating Environmental Influences of Zoning in Urban Ecosystems with Remote Sensing. **Remote Sensing of Environment**, v. 86, n. 3, p. 303-321, 2003.

WITTEN, I. H.; EIBE, F.; HALL, M. A. (3. Ed.). **DATA MINING. Practical machine learning tools and techniques**. Burlington, MA: Morgan Kaufmann, 665 p., 2011.

WOLF, A. Using WorldView 2 Vis-NIR MSI Imagery to Support Land Mapping and Feature Extraction Using Normalized Difference Index Ratios. **Proc. SPIE - Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XVIII**, v. 83900N, May, 2012.

WU, X.; KUMAR, V. **The top ten algorithms in data mining**. Boca Raton: Taylor & Francis Group, 232 p., 2009.

APÊNDICE A - ÁRVORES DE DECISÃO GERADAS PELO ALGORITMO

C4.5

A1 Árvore de decisão gerada pelo algoritmo C4.5 com $M=2$.

```
IOR <= 0.863827
| ARVI 1 <= -0.991984: Piscina (21.0)
| ARVI 1 > -0.991984
| | NDVI 2 <= 0.433798: Sombra (23.0)
| | NDVI 2 > 0.433798: Arborea (23.0/1.0)
IOR > 0.863827
| Média da banda 1 <= 435.160305
| | PCA5 <= -31.419397
| | | PCA6 <= -32.699301: Ceramica_Vermelha_Nova (19.0)
| | | PCA6 > -32.699301
| | | | AM <= 86.677488: Ceramica_Vermelha_Intemperizada (22.0)
| | | | AM > 86.677488
| | | | | NDBI WV-2 <= 973.55958: Ceramica_Vermelha_Nova (3.0/1.0)
| | | | | NDBI WV-2 > 973.55958: Ceramica_Alaranjada (3.0)
| | | PCA5 > -31.419397
| | | | IOR WV-2 <= 1.024065
| | | | | ARVI 1 <= -0.988254
| | | | | | PCA8 <= 0.012547
| | | | | | | PCA7 <= -5.34127: Cimentos_Intemperizados (7.0)
| | | | | | | PCA7 > -5.34127
| | | | | | | | ARVI 1 <= -0.993482: Cimentos_Intemperizados (3.0)
| | | | | | | | ARVI 1 > -0.993482
| | | | | | | | | EVI 1 <= 0.021959: Ceramica_Cinza (17.0/1.0)
| | | | | | | | | EVI 1 > 0.021959: Cimentos_Intemperizados (2.0)
| | | | | | | PCA8 > 0.012547: Cimentos_Intemperizados (12.0)
| | | | | | ARVI 1 > -0.988254: Sombra (2.0)
| | | | IOR WV-2 > 1.024065
| | | | | AA2 <= 0.093207: Solo_Exposto (13.0)
| | | | | AA2 > 0.093207: Ceramica_Alaranjada (3.0/1.0)
| Média da banda 1 > 435.160305
| | Média da banda 5 <= 672.040052
| | | NDWI <= 0.064064
| | | | IOR WV-2 <= 1.06691
| | | | | NDWI <= 0.047332: Cimentos_Novos (23.0/1.0)
| | | | | NDWI > 0.047332: Ceramica_Cinza (2.0)
| | | | | IOR WV-2 > 1.06691: Solo_Exposto (4.0/1.0)
| | | | NDWI > 0.064064: Metalica_Pintura_Cinza (14.0)
| | Média da banda 5 > 672.040052
| | | Média da banda 1 <= 598.301508
| | | | PCA5 <= -20.036842: Ceramica_Alaranjada (9.0)
| | | | PCA5 > -20.036842
| | | | | PCA6 <= -17.423828: Ceramica_Alaranjada (2.0)
| | | | | PCA6 > -17.423828: Pedra_Mineira (13.0/1.0)
| | | Média da banda 1 > 598.301508
| | | | NDBI WV-2 <= 1873.823866
| | | | | PCA4 <= 26.261194: Metalica_brilhante (7.0)
| | | | | PCA4 > 26.261194: Pedra_Mineira (11.0/1.0)
| | | | NDBI WV-2 > 1873.823866: Metalica_brilhante (23.0/1.0)
```

A2 Árvore de decisão gerada pelo algoritmo C4.5 com M=3.

```

IOR <= 0.863827
| ARVI 1 <= -0.991984: Piscina (21.0)
| ARVI 1 > -0.991984
| | NDVI 2 <= 0.433798: Sombra (23.0)
| | NDVI 2 > 0.433798: Arborea (23.0/1.0)
IOR > 0.863827
| Média da banda 1 <= 435.160305
| | PCA5 <= -31.419397
| | | PCA6 <= -32.699301: Ceramica_Vermelha_Nova (19.0)
| | | PCA6 > -32.699301
| | | | AM <= 86.677488: Ceramica_Vermelha_Intemperizada (22.0)
| | | | AM > 86.677488
| | | | | NDBI WV-2 <= 973.55958: Ceramica_Vermelha_Nova (3.0/1.0)
| | | | | NDBI WV-2 > 973.55958: Ceramica_Alaranjada (3.0)
| | PCA5 > -31.419397
| | | IOR <= 1.024065
| | | | PCA4 <= -13.477612: Sombra (3.0/1.0)
| | | | PCA4 > -13.477612
| | | | | PCA8 <= 0.012547
| | | | | | PCA7 <= -5.34127: Cimentos_Intemperizados (7.0)
| | | | | | PCA7 > -5.34127
| | | | | | | ARVI 1 <= -0.993482: Cimentos_Intemperizados (3.0)
| | | | | | | ARVI 1 > -0.993482
| | | | | | | | PCA6 <= 23.118182: Ceramica_Cinza (14.0)
| | | | | | | | PCA6 > 23.118182: Cimentos_Intemperizados (4.0/1.0)
| | | | | | | PCA8 > 0.012547: Cimentos_Intemperizados (12.0)
| | | | IOR > 1.024065
| | | | | AA2 <= 0.093207: Solo_Exposto (13.0)
| | | | | AA2 > 0.093207: Ceramica_Alaranjada (3.0/1.0)
| Média da banda 1 > 435.160305
| Média da banda 5 <= 672.040052
| | NDWI <= 0.064064
| | | IOR <= 1.06691
| | | | PCA7 <= -0.851499: Cimentos_Novos (19.0)
| | | | PCA7 > -0.851499
| | | | | NDBI WV-2 <= 1084.980738: Ceramica_Cinza (3.0)
| | | | | NDBI WV-2 > 1084.980738: Cimentos_Novos (3.0)
| | | | IOR > 1.06691: Solo_Exposto (4.0/1.0)
| | NDWI > 0.064064: Metalica_Pintura_Cinza (14.0)
| Média da banda 5 > 672.040052
| Média da banda 1 <= 598.301508
| | PCA5 <= -20.036842: Ceramica_Alaranjada (9.0)
| | PCA5 > -20.036842
| | | PCA6 <= -12.766716: Ceramica_Alaranjada (3.0/1.0)
| | | PCA6 > -12.766716: Pedra_Mineira (12.0/1.0)
| Média da banda 1 > 598.301508
| | NDBI WV-2 <= 1873.823866
| | | PCA4 <= 26.261194: Metalica_brilhante (7.0)
| | | PCA4 > 26.261194: Pedra_Mineira (11.0/1.0)
| | NDBI WV-2 > 1873.823866: Metalica_brilhante (23.0/1.0)

```

A3 Árvore de decisão gerada pelo algoritmo C4.5 com M=4.

```
IOR <= 0.863827
| ARVI 1 <= -0.991984: Piscina (21.0)
| ARVI 1 > -0.991984
| | NDVI 2 <= 0.433798: Sombra (23.0)
| | NDVI 2 > 0.433798: Arborea (23.0/1.0)
IOR > 0.863827
| Média da banda 1 <= 435.160305
| | PCA5 <= -31.419397
| | | PCA6 <= -32.699301: Ceramica_Vermelha_Nova (19.0)
| | | PCA6 > -32.699301
| | | | AM <= 86.677488: Ceramica_Vermelha_Intemperizada (22.0)
| | | | AM > 86.677488: Ceramica_Alaranjada (6.0/3.0)
| | | PCA5 > -31.419397
| | | | IOR WV-2 <= 1.024065
| | | | | PCA7 <= -5.34127: Cimentos_Intemperizados (12.0)
| | | | | PCA7 > -5.34127
| | | | | | PCA8 <= 0.012547
| | | | | | | PCA1 <= -16913.639469: Ceramica_Cinza (18.0/3.0)
| | | | | | | PCA1 > -16913.639469: Cimentos_Intemperizados (5.0/1.0)
| | | | | | | PCA8 > 0.012547: Cimentos_Intemperizados (8.0/1.0)
| | | | | IOR WV-2 > 1.024065
| | | | | | NDWI <= -0.085115: Solo_Exposto (12.0)
| | | | | | NDWI > -0.085115: Ceramica_Alaranjada (4.0/2.0)
| Média da banda 1 > 435.160305
| Média da banda 5 <= 672.040052
| | NDWI <= 0.064064
| | | IOR WV-2 <= 1.06691: Cimentos_Novos (25.0/3.0)
| | | IOR WV-2 > 1.06691: Solo_Exposto (4.0/1.0)
| | | NDWI > 0.064064: Metalica_Pintura_Cinza (14.0)
| Média da banda 5 > 672.040052
| | Média da banda 1 <= 598.301508
| | | PCA5 <= -20.036842: Ceramica_Alaranjada (9.0)
| | | PCA5 > -20.036842: Pedra_Mineira (15.0/3.0)
| | Média da banda 1 > 598.301508
| | | NDBI WV-2 <= 1873.823866
| | | | PCA4 <= 26.261194: Metalica_brilhante (7.0)
| | | | PCA4 > 26.261194: Pedra_Mineira (11.0/1.0)
| | | | NDBI WV-2 > 1873.823866: Metalica_brilhante (23.0/1.0)
```

A4 Árvore de decisão gerada pelo algoritmo C4.5 com M=5.

```
IOR <= 0.863827
| ARVI 1 <= -0.991984: Piscina (21.0)
| ARVI 1 > -0.991984
| | NDVI 2 <= 0.433798: Sombra (23.0)
| | NDVI 2 > 0.433798: Arborea (23.0/1.0)
IOR > 0.863827
| Média da banda 1 <= 435.160305
| | PCA5 <= -31.419397
| | | PCA6 <= -32.699301: Ceramica_Vermelha_Nova (19.0)
| | | PCA6 > -32.699301
| | | | AM <= 86.677488: Ceramica_Vermelha_Intemperizada (22.0)
| | | | AM > 86.677488: Ceramica_Alaranjada (6.0/3.0)
| | | PCA5 > -31.419397
| | | | IOR WV-2 <= 1.024065
| | | | | ARVI 1 <= -0.990003
| | | | | | PCA7 <= -5.34127: Cimentos_Intemperizados (12.0)
| | | | | | PCA7 > -5.34127
| | | | | | | PCA8 <= 0.012547
| | | | | | | | Leonardi_2 <= 303.658022: Ceramica_Cinza (13.0)
| | | | | | | | Leonardi_2 > 303.658022: Cimentos_Intemperizados (8.0/3.0)
| | | | | | | | PCA8 > 0.012547: Cimentos_Intemperizados (5.0)
| | | | | | | | ARVI 1 > -0.990003: Cimentos_Intemperizados (5.0/2.0)
| | | | | | | IOR WV-2 > 1.024065: Solo_Exposto (16.0/3.0)
| Média da banda 1 > 435.160305
| Média da banda 5 <= 672.040052
| | NDWI <= 0.064064
| | | IOR WV-2 <= 1.048834
| | | | PCA7 <= -0.851499: Cimentos_Novos (19.0)
| | | | PCA7 > -0.851499: Ceramica_Cinza (5.0/2.0)
| | | | IOR WV-2 > 1.048834: Solo_Exposto (5.0/2.0)
| | | NDWI > 0.064064: Metalica_Pintura_Cinza (14.0)
| Média da banda 5 > 672.040052
| | Média da banda 1 <= 598.301508
| | | PCA5 <= -20.036842: Ceramica_Alaranjada (9.0)
| | | PCA5 > -20.036842: Pedra_Mineira (15.0/3.0)
| | Média da banda 1 > 598.301508
| | | NDBI WV-2 <= 1873.823866
| | | | PCA4 <= 26.261194: Metalica_brilhante (7.0)
| | | | PCA4 > 26.261194: Pedra_Mineira (11.0/1.0)
| | | NDBI WV-2 > 1873.823866: Metalica_brilhante (23.0/1.0)
```

A5 Árvore de decisão gerada pelo algoritmo C4.5 com M=6.

```
IOR <= 0.863827
| ARVI 1 <= -0.991984: Piscina (21.0)
| ARVI 1 > -0.991984
| | AA2 <= -0.217715: Arborea (23.0/1.0)
| | AA2 > -0.217715: Sombra (23.0)
IOR > 0.863827
| Média da banda 1 <= 435.160305
| | PCA5 <= -31.419397
| | | PCA6 <= -32.699301: Ceramica_Vermelha_Nova (19.0)
| | | PCA6 > -32.699301
| | | | AM <= 86.677488: Ceramica_Vermelha_Intemperizada (22.0)
| | | | AM > 86.677488: Ceramica_Alaranjada (6.0/3.0)
| | | PCA5 > -31.419397
| | | | IOR WV-2 <= 1.024065
| | | | | PCA7 <= -5.34127: Cimentos_Intemperizados (12.0)
| | | | | PCA7 > -5.34127
| | | | | | PCA8 <= 0.012547
| | | | | | | Leonardi_2 <= 303.658022: Ceramica_Cinza (15.0/2.0)
| | | | | | | Leonardi_2 > 303.658022: Cimentos_Intemperizados (8.0/3.0)
| | | | | | | PCA8 > 0.012547: Cimentos_Intemperizados (8.0/1.0)
| | | | | | IOR WV-2 > 1.024065: Solo_Exposto (16.0/3.0)
| Média da banda 1 > 435.160305
| Média da banda 5 <= 672.040052
| | NDWI <= 0.064064
| | | Leonardi_1 <= 1.624192: Solo_Exposto (6.0/3.0)
| | | Leonardi_1 > 1.624192: Cimentos_Novos (23.0/2.0)
| | | NDWI > 0.064064: Metalica_Pintura_Cinza (14.0)
| Média da banda 5 > 672.040052
| | Média da banda 1 <= 598.301508
| | | PCA5 <= -20.036842: Ceramica_Alaranjada (9.0)
| | | PCA5 > -20.036842: Pedra_Mineira (15.0/3.0)
| | Média da banda 1 > 598.301508
| | | NDBI WV-2 <= 1873.823866
| | | | PCA4 <= 26.261194: Metalica_brilhante (7.0)
| | | | PCA4 > 26.261194: Pedra_Mineira (11.0/1.0)
| | | | NDBI WV-2 > 1873.823866: Metalica_brilhante (23.0/1.0)
```

A6 Árvore de decisão gerada pelo algoritmo C4.5 com M=7.

```
IOR <= 0.863827
| ARVI 1 <= -0.991984: Piscina (21.0)
| ARVI 1 > -0.991984
| | AA2 <= -0.217715: Arborea (23.0/1.0)
| | AA2 > -0.217715: Sombra (23.0)
IOR > 0.863827
| Média da banda 1 <= 435.160305
| | PCA5 <= -31.419397
| | | PCA6 <= -32.699301: Ceramica_Vermelha_Nova (19.0)
| | | PCA6 > -32.699301
| | | | AM <= 83.327938: Ceramica_Vermelha_Intemperizada (21.0)
| | | | AM > 83.327938: Ceramica_Alaranjada (7.0/4.0)
| | | PCA5 > -31.419397
| | | | IOR WV-2 <= 1.024065
| | | | | PCA7 <= -5.34127: Cimentos_Intemperizados (12.0)
| | | | | PCA7 > -5.34127
| | | | | | PCA8 <= 0.012547
| | | | | | | Leonardi_2 <= 303.658022: Ceramica_Cinza (15.0/2.0)
| | | | | | | Leonardi_2 > 303.658022: Cimentos_Intemperizados (8.0/3.0)
| | | | | | PCA8 > 0.012547: Cimentos_Intemperizados (8.0/1.0)
| | | | | IOR WV-2 > 1.024065: Solo_Exposto (16.0/3.0)
| Média da banda 1 > 435.160305
| | Média da banda 5 <= 672.040052
| | | NDWI <= 0.064064: Cimentos_Novos (29.0/7.0)
| | | NDWI > 0.064064: Metalica_Pintura_Cinza (14.0)
| | Média da banda 5 > 672.040052
| | | Média da banda 1 <= 598.301508
| | | | PCA5 <= -20.036842: Ceramica_Alaranjada (9.0)
| | | | PCA5 > -20.036842: Pedra_Mineira (15.0/3.0)
| | | Média da banda 1 > 598.301508
| | | | NDBI WV-2 <= 1873.823866
| | | | | PCA4 <= 26.261194: Metalica_brilhante (7.0)
| | | | | PCA4 > 26.261194: Pedra_Mineira (11.0/1.0)
| | | | NDBI WV-2 > 1873.823866: Metalica_brilhante (23.0/1.0)
```


A7 Árvore de decisão gerada pelo algoritmo C4.5 com M=8.

```
IOR <= 0.863827
| ARVI 1 <= -0.991984: Piscina (21.0)
| ARVI 1 > -0.991984
| | AA2 <= -0.217715: Arborea (23.0/1.0)
| | AA2 > -0.217715: Sombra (23.0)
IOR > 0.863827
| Média da banda 1 <= 435.160305
| | PCA5 <= -31.419397
| | | PCA6 <= -32.699301: Ceramica_Vermelha_Nova (19.0)
| | | PCA6 > -32.699301
| | | | AM <= 78.19583: Ceramica_Vermelha_Intemperizada (20.0)
| | | | AM > 78.19583: Ceramica_Alaranjada (8.0/5.0)
| | | PCA5 > -31.419397
| | | | IOR WV-2 <= 1.024065
| | | | | PCA7 <= -5.34127: Cimentos_Intemperizados (12.0)
| | | | | PCA7 > -5.34127
| | | | | | PCA8 <= 0.012547
| | | | | | | Leonardi_2 <= 303.658022: Ceramica_Cinza (15.0/2.0)
| | | | | | | Leonardi_2 > 303.658022: Cimentos_Intemperizados (8.0/3.0)
| | | | | | PCA8 > 0.012547: Cimentos_Intemperizados (8.0/1.0)
| | | | | IOR WV-2 > 1.024065: Solo_Exposto (16.0/3.0)
| Média da banda 1 > 435.160305
| | Média da banda 5 <= 672.040052
| | | NDWI <= 0.064064: Cimentos_Novos (29.0/7.0)
| | | NDWI > 0.064064: Metalica_Pintura_Cinza (14.0)
| | Média da banda 5 > 672.040052
| | | Média da banda 1 <= 598.301508
| | | | PCA5 <= -20.036842: Ceramica_Alaranjada (9.0)
| | | | PCA5 > -20.036842: Pedra_Mineira (15.0/3.0)
| | | Média da banda 1 > 598.301508
| | | | NDBI WV-2 <= 1873.823866
| | | | | PCA4 <= 46.5: Metalica_brilhante (10.0/2.0)
| | | | | PCA4 > 46.5: Pedra_Mineira (8.0)
| | | | NDBI WV-2 > 1873.823866: Metalica_brilhante (23.0/1.0)
```

A8 Árvore de decisão gerada pelo algoritmo C4.5 com M=9.

IOR \leq 0.863827

| ARVI 1 \leq -0.991984: Piscina (21.0)

| ARVI 1 $>$ -0.991984

| | AA2 \leq -0.217715: Arborea (23.0/1.0)

| | AA2 $>$ -0.217715: Sombra (23.0)

IOR $>$ 0.863827

| Média da banda 1 \leq 435.160305

| | PCA5 \leq -31.419397

| | | PCA6 \leq -32.699301: Ceramica_Vermelha_Nova (19.0)

| | | PCA6 $>$ -32.699301: Ceramica_Vermelha_Intemperizada (28.0/6.0)

| | PCA5 $>$ -31.419397

| | | IOR WV-2 \leq 1.024065

| | | | PCA7 \leq -5.34127: Cimentos_Intemperizados (12.0)

| | | | PCA7 $>$ -5.34127

| | | | PCA8 \leq -0.298246: Ceramica_Cinza (21.0/6.0)

| | | | PCA8 $>$ -0.298246: Cimentos_Intemperizados (10.0/2.0)

| | | IOR WV-2 $>$ 1.024065: Solo_Exposto (16.0/3.0)

| Média da banda 1 $>$ 435.160305

| | Média da banda 5 \leq 672.040052

| | | NDWI \leq 0.064064: Cimentos_Novos (29.0/7.0)

| | | NDWI $>$ 0.064064: Metalica_Pintura_Cinza (14.0)

| | Média da banda 5 $>$ 672.040052

| | | Média da banda 1 \leq 598.301508

| | | | PCA5 \leq -20.036842: Ceramica_Alaranjada (9.0)

| | | | PCA5 $>$ -20.036842: Pedra_Mineira (15.0/3.0)

| | | Média da banda 1 $>$ 598.301508

| | | | NDBI WV-2 \leq 1873.823866

| | | | | Solo_NDSI_ \leq 2095.258318: Metalica_brilhante (9.0/2.0)

| | | | | Solo_NDSI_ $>$ 2095.258318: Pedra_Mineira (9.0/1.0)

| | | | NDBI WV-2 $>$ 1873.823866: Metalica_brilhante (23.0/1.0)

A9 Árvore de decisão gerada pelo algoritmo C4.5 com M=10.

```
IOR <= 0.863827
| ARVI 1 <= -0.991984: Piscina (21.0)
| ARVI 1 > -0.991984
| | AA2 <= -0.217715: Arborea (23.0/1.0)
| | AA2 > -0.217715: Sombra (23.0)
IOR > 0.863827
| Média da banda 1 <= 435.160305
| | PCA5 <= -31.419397
| | | PCA6 <= -32.699301: Ceramica_Vermelha_Nova (19.0)
| | | PCA6 > -32.699301: Ceramica_Vermelha_Intemperizada (28.0/6.0)
| | PCA5 > -31.419397
| | | IOR WV-2 <= 1.024065
| | | | PCA7 <= -5.34127: Cimentos_Intemperizados (12.0)
| | | | PCA7 > -5.34127
| | | | PCA8 <= -0.298246: Ceramica_Cinza (21.0/6.0)
| | | | PCA8 > -0.298246: Cimentos_Intemperizados (10.0/2.0)
| | | IOR WV-2 > 1.024065: Solo_Exposto (16.0/3.0)
| Média da banda 1 > 435.160305
| | Média da banda 5 <= 672.040052
| | | NDWI <= 0.064064: Cimentos_Novos (29.0/7.0)
| | | NDWI > 0.064064: Metalica_Pintura_Cinza (14.0)
| | Média da banda 5 > 672.040052
| | | Média da banda 1 <= 598.301508
| | | | IOR WV-2 <= 1.14427: Pedra_Mineira (13.0/2.0)
| | | | IOR WV-2 > 1.14427: Ceramica_Alaranjada (11.0/1.0)
| | | Média da banda 1 > 598.301508
| | | | NDBI WV-2 <= 1873.823866: Pedra_Mineira (18.0/8.0)
| | | | NDBI WV-2 > 1873.823866: Metalica_brilhante (23.0/1.0)
```

A10 Árvore de decisão gerada pelo algoritmo C4.5 com M=11.

```
IOR <= 0.863827
| ARVI 1 <= -0.991984: Piscina (21.0)
| ARVI 1 > -0.991984
| | AA2 <= -0.217715: Arborea (23.0/1.0)
| | AA2 > -0.217715: Sombra (23.0)
IOR > 0.863827
| Média da banda 1 <= 435.160305
| | PCA5 <= -31.419397
| | | PCA6 <= -32.699301: Ceramica_Vermelha_Nova (19.0)
| | | PCA6 > -32.699301: Ceramica_Vermelha_Intemperizada (28.0/6.0)
| | | PCA5 > -31.419397
| | | IOR WV-2 <= 1.024065
| | | | PCA7 <= -5.34127: Cimentos_Intemperizados (12.0)
| | | | PCA7 > -5.34127
| | | | | PCA8 <= -2.277886: Ceramica_Cinza (14.0/3.0)
| | | | | PCA8 > -2.277886: Cimentos_Intemperizados (17.0/7.0)
| | | | IOR WV-2 > 1.024065: Solo_Exposto (16.0/3.0)
| Média da banda 1 > 435.160305
| | Média da banda 5 <= 672.040052
| | | NDWI <= 0.064064: Cimentos_Novos (29.0/7.0)
| | | NDWI > 0.064064: Metalica_Pintura_Cinza (14.0)
| | Média da banda 5 > 672.040052
| | | Média da banda 1 <= 598.301508
| | | | IOR WV-2 <= 1.14427: Pedra_Mineira (13.0/2.0)
| | | | IOR WV-2 > 1.14427: Ceramica_Alaranjada (11.0/1.0)
| | | Média da banda 1 > 598.301508
| | | | NDBI WV-2 <= 1873.823866: Pedra_Mineira (18.0/8.0)
| | | | NDBI WV-2 > 1873.823866: Metalica_brilhante (23.0/1.0)
```

A11 Árvore de decisão gerada pelo algoritmo C4.5 com M=12.

IOR \leq 0.863827

| ARVI 1 \leq -0.991984: Piscina (21.0)

| ARVI 1 $>$ -0.991984

| | AA2 \leq -0.217715: Arborea (23.0/1.0)

| | AA2 $>$ -0.217715: Sombra (23.0)

IOR $>$ 0.863827

| Média da banda 1 \leq 435.160305

| | PCA5 \leq -31.419397

| | | PCA6 \leq -32.699301: Ceramica_Vermelha_Nova (19.0)

| | | PCA6 $>$ -32.699301: Ceramica_Vermelha_Intemperizada (28.0/6.0)

| | PCA5 $>$ -31.419397

| | | IOR WV-2 \leq 1.024065

| | | | PCA7 \leq -5.34127: Cimentos_Intemperizados (12.0)

| | | | PCA7 $>$ -5.34127

| | | | PCA8 \leq -2.277886: Ceramica_Cinza (14.0/3.0)

| | | | PCA8 $>$ -2.277886: Cimentos_Intemperizados (17.0/7.0)

| | | IOR WV-2 $>$ 1.024065: Solo_Exposto (16.0/3.0)

| Média da banda 1 $>$ 435.160305

| | Média da banda 5 \leq 672.040052

| | | NDWI \leq 0.064064: Cimentos_Novos (29.0/7.0)

| | | NDWI $>$ 0.064064: Metalica_Pintura_Cinza (14.0)

| | Média da banda 5 $>$ 672.040052

| | | Média da banda 1 \leq 598.301508

| | | | IOR WV-2 \leq 1.131727: Pedra_Mineira (12.0/2.0)

| | | | IOR WV-2 $>$ 1.131727: Ceramica_Alaranjada (12.0/2.0)

| | | Média da banda 1 $>$ 598.301508

| | | | NDBI WV-2 \leq 1873.823866: Pedra_Mineira (18.0/8.0)

| | | | NDBI WV-2 $>$ 1873.823866: Metalica_brilhante (23.0/1.0)

A12 Árvore de decisão gerada pelo algoritmo C4.5 com M=13.

IOR \leq 0.863827

| ARVI 1 \leq -0.991984: Piscina (21.0)

| ARVI 1 $>$ -0.991984

| | AA2 \leq -0.217715: Arborea (23.0/1.0)

| | AA2 $>$ -0.217715: Sombra (23.0)

IOR $>$ 0.863827

| Média da banda 1 \leq 435.160305

| | PCA5 \leq -31.419397

| | | PCA6 \leq -32.699301: Ceramica_Vermelha_Nova (19.0)

| | | PCA6 $>$ -32.699301: Ceramica_Vermelha_Intemperizada (28.0/6.0)

| | PCA5 $>$ -31.419397

| | | IOR WV-2 \leq 1.024065

| | | | PCA8 \leq 0.012547

| | | | PCA6 \leq 20.796053: Ceramica_Cinza (16.0/4.0)

| | | | PCA6 $>$ 20.796053: Cimentos_Intemperizados (14.0/4.0)

| | | | PCA8 $>$ 0.012547: Cimentos_Intemperizados (13.0/1.0)

| | | IOR WV-2 $>$ 1.024065: Solo_Exposto (16.0/3.0)

| Média da banda 1 $>$ 435.160305

| | Média da banda 5 \leq 672.040052

| | | NDWI \leq 0.064064: Cimentos_Novos (29.0/7.0)

| | | NDWI $>$ 0.064064: Metalica_Pintura_Cinza (14.0)

| | Média da banda 5 $>$ 672.040052

| | | NDBI WV-2 \leq 1873.823866: Pedra_Mineira (42.0/20.0)

| | | NDBI WV-2 $>$ 1873.823866: Metalica_brilhante (23.0/1.0)

A13 Árvore de decisão gerada pelo algoritmo C4.5 com M=14.

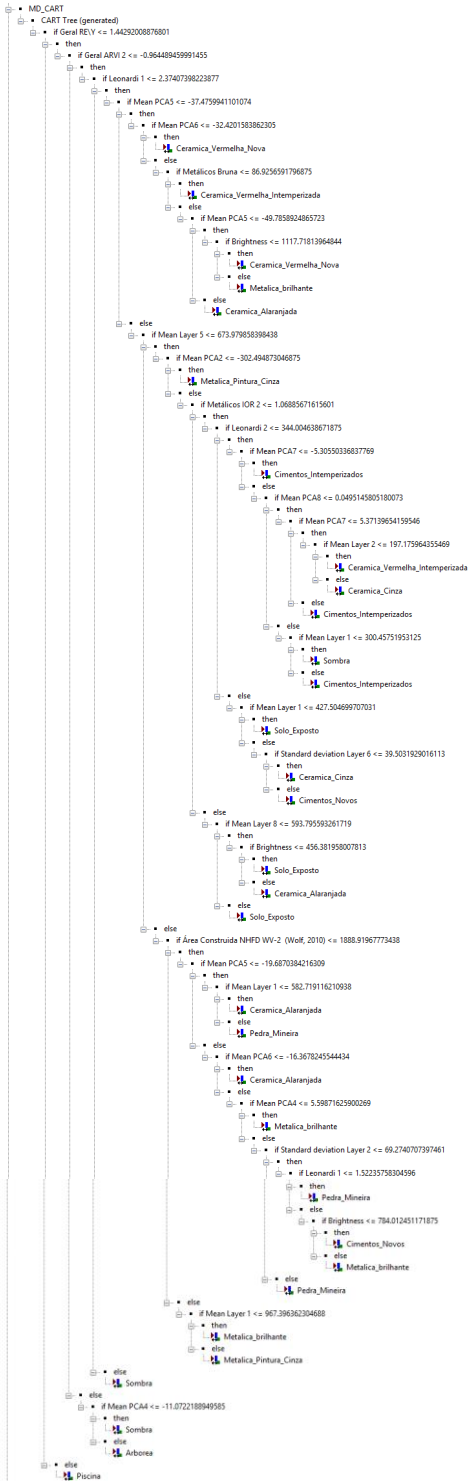
```
IOR <= 0.863827
| ARVI 1 <= -0.991984: Piscina (21.0)
| ARVI 1 > -0.991984
| | AA2 <= -0.217715: Arborea (23.0/1.0)
| | AA2 > -0.217715: Sombra (23.0)
IOR > 0.863827
| Média da banda 1 <= 435.160305
| | PCA5 <= -31.419397
| | | PCA6 <= -32.699301: Ceramica_Vermelha_Nova (19.0)
| | | PCA6 > -32.699301: Ceramica_Vermelha_Intemperizada (28.0/6.0)
| | PCA5 > -31.419397
| | | IOR WV-2 <= 1.024065
| | | | PCA7 <= -3.170347: Cimentos_Intemperizados (21.0/3.0)
| | | | PCA7 > -3.170347: Ceramica_Cinza (22.0/9.0)
| | | IOR WV-2 > 1.024065: Solo_Exposto (16.0/3.0)
| Média da banda 1 > 435.160305
| | Média da banda 5 <= 672.040052
| | | NDWI <= 0.064064: Cimentos_Novos (29.0/7.0)
| | | NDWI > 0.064064: Metalica_Pintura_Cinza (14.0)
| | Média da banda 5 > 672.040052
| | | NDBI WV-2 <= 1873.823866: Pedra_Mineira (42.0/20.0)
| | | NDBI WV-2 > 1873.823866: Metalica_brilhante (23.0/1.0)
```

A14 Árvore de decisão gerada pelo algoritmo C4.5 com M=15.

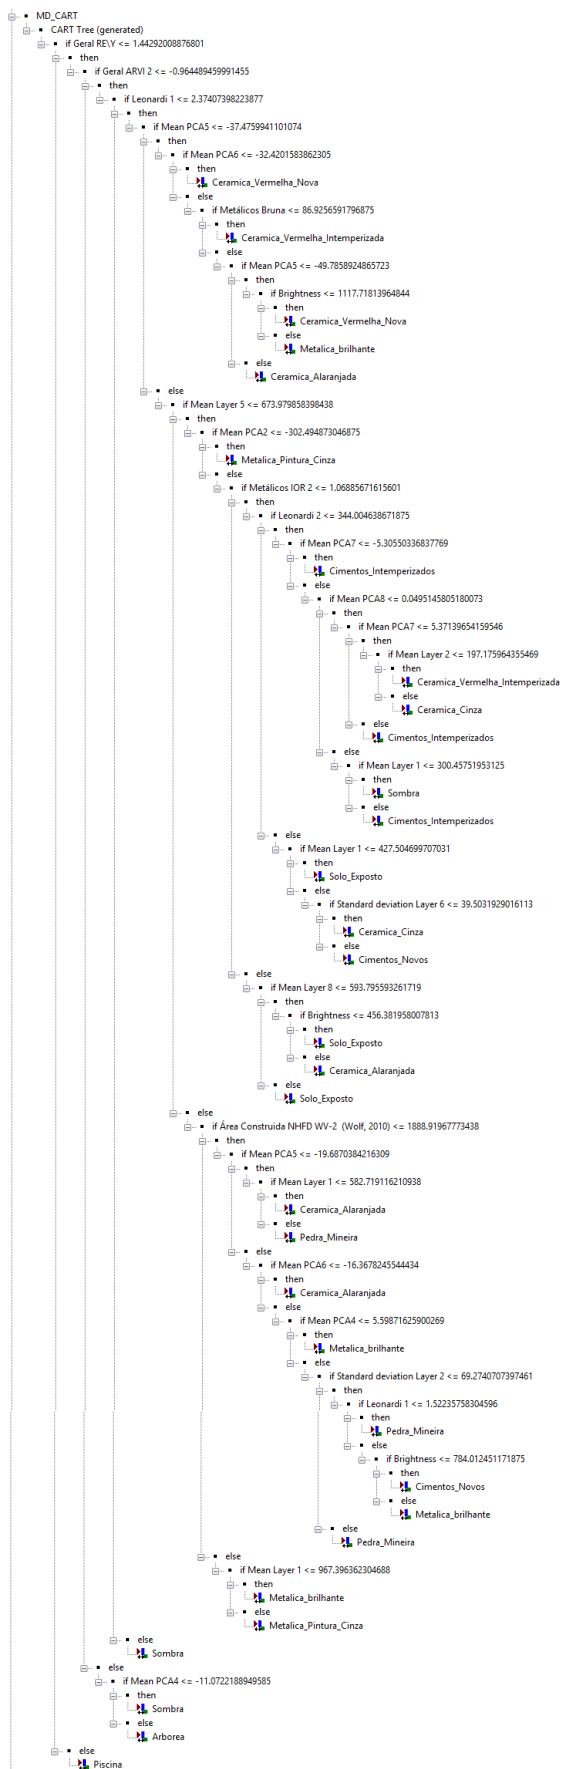
```
IOR <= 0.863827
| ARVI 1 <= -0.991984: Piscina (21.0)
| ARVI 1 > -0.991984
| | AA2 <= -0.217715: Arborea (23.0/1.0)
| | AA2 > -0.217715: Sombra (23.0)
IOR > 0.863827
| Média da banda 1 <= 435.160305
| | PCA5 <= -31.419397
| | | PCA6 <= -32.699301: Ceramica_Vermelha_Nova (19.0)
| | | PCA6 > -32.699301: Ceramica_Vermelha_Intemperizada (28.0/6.0)
| | PCA5 > -31.419397
| | | IOR WV-2 <= 1.024065
| | | | PCA7 <= -3.170347: Cimentos_Intemperizados (21.0/3.0)
| | | | PCA7 > -3.170347: Ceramica_Cinza (22.0/9.0)
| | | IOR WV-2 > 1.024065: Solo_Exposto (16.0/3.0)
| Média da banda 1 > 435.160305
| | Média da banda 5 <= 672.040052
| | | NDWI <= 0.047332: Cimentos_Novos (27.0/5.0)
| | | NDWI > 0.047332: Metalica_Pintura_Cinza (16.0/2.0)
| | Média da banda 5 > 672.040052
| | | NDBI WV-2 <= 1873.823866: Pedra_Mineira (42.0/20.0)
| | | NDBI WV-2 > 1873.823866: Metalica_brilhante (23.0/1.0)
```


APÊNDICE B - ÁRVORES DE DECISÃO GERADAS PELO ALGORITMO CART

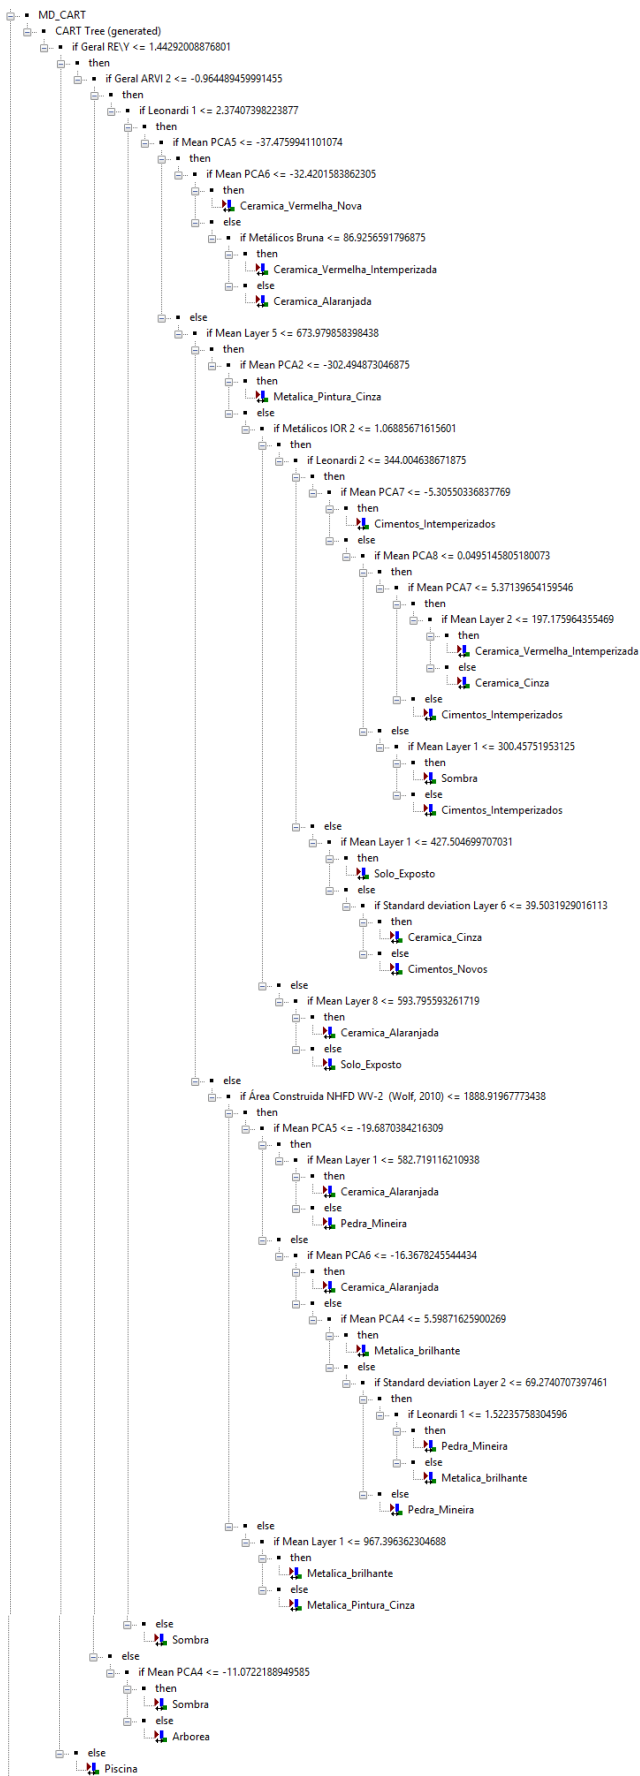
B1 Árvore de decisão gerada pelo algoritmo CART com M=2.



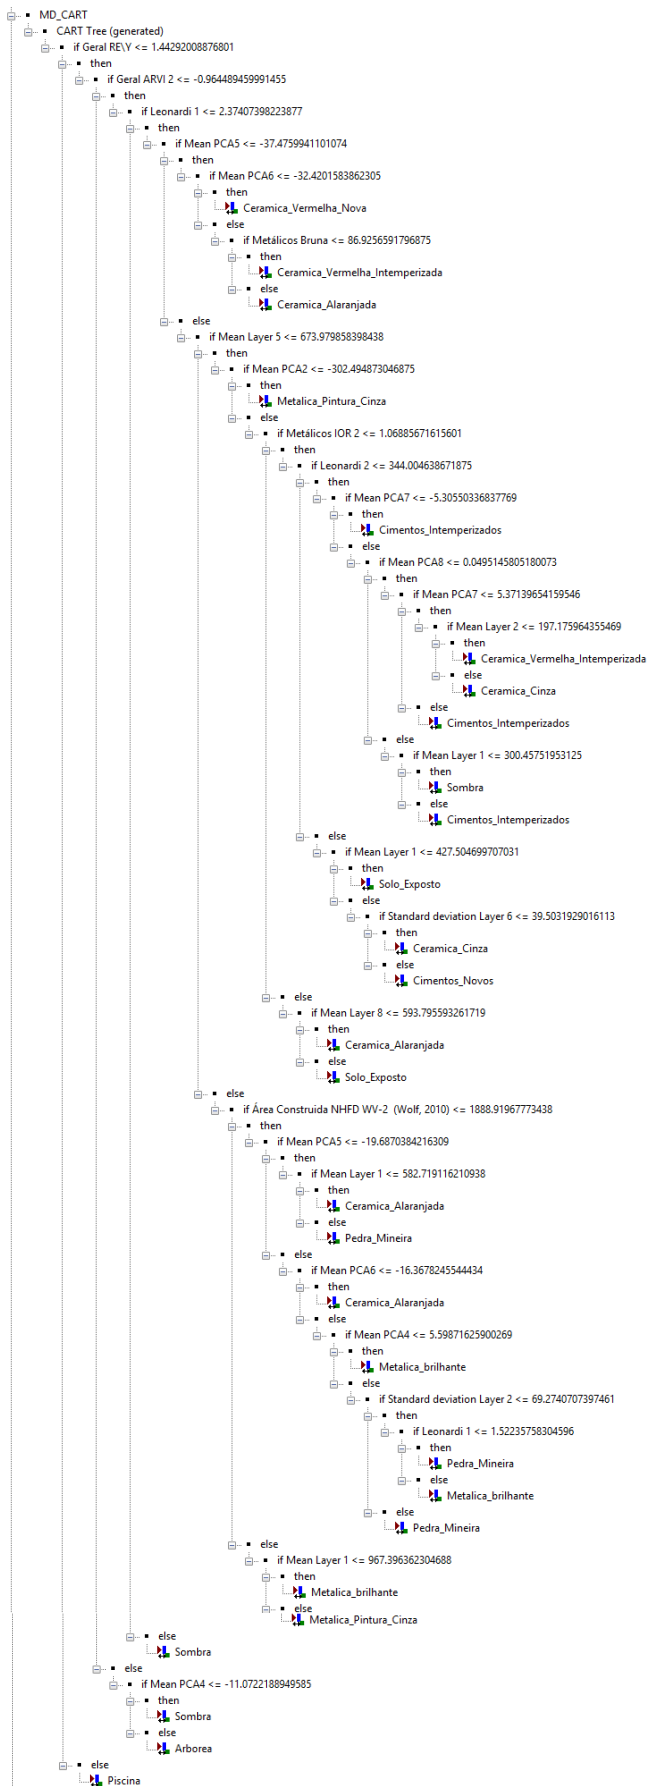
B2 Árvore de decisão gerada pelo algoritmo CART com M=3.



B6 Árvore de decisão gerada pelo algoritmo CART com M=7.



B7 Árvore de decisão gerada pelo algoritmo CART com M=8.



B9 Árvore de decisão gerada pelo algoritmo CART com M=10.



B10 Árvore de decisão gerada pelo algoritmo CART com M=11.



B11 Árvore de decisão gerada pelo algoritmo CART com M=12.



B12 Árvore de decisão gerada pelo algoritmo CART com M=13.



B13 Árvore de decisão gerada pelo algoritmo CART com M=14.



B14 Árvore de decisão gerada pelo algoritmo CART com M=15.

