



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

sid.inpe.br/mtc-m21b/2017/03.23.16.13-TDI

CLASSIFICAÇÃO DA COBERTURA DO SOLO URBANO USANDO ÁRVORES DE DECISÃO A PARTIR DE CENAS WORLDVIEW-2 E WORLDVIEW-3 PARA DIFERENTES NÍVEIS DE LEGENDA

Paulo Roberto da Silva Ruiz

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelas Dras. Cláudia Maria de
Almeida, e Camila Souza dos
Anjos Lacerda, aprovada em 21 de
fevereiro de 2017.

URL do documento original:

[<http://urlib.net/8JMKD3MGP3W34P/3NJ9GU8>](http://urlib.net/8JMKD3MGP3W34P/3NJ9GU8)

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/2017/03.23.16.13-TDI

CLASSIFICAÇÃO DA COBERTURA DO SOLO URBANO USANDO ÁRVORES DE DECISÃO A PARTIR DE CENAS WORLDVIEW-2 E WORLDVIEW-3 PARA DIFERENTES NÍVEIS DE LEGENDA

Paulo Roberto da Silva Ruiz

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelas Dras. Cláudia Maria de
Almeida, e Camila Souza dos
Anjos Lacerda, aprovada em 21 de
fevereiro de 2017.

URL do documento original:

[<http://urlib.net/8JMKD3MGP3W34P/3NJ9GU8>](http://urlib.net/8JMKD3MGP3W34P/3NJ9GU8)

INPE
São José dos Campos
2017

Dados Internacionais de Catalogação na Publicação (CIP)

Ruiz, Paulo Roberto da Silva.

R859c Classificação da cobertura do solo urbano usando árvores de decisão a partir de cenas worldview-2 e worldview-3 para diferentes níveis de legenda / Paulo Roberto da Silva Ruiz. – São José dos Campos : INPE, 2017.

xxii + 181 p. ; (sid.inpe.br/mtc-m21b/2017/03.23.16.13-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2017.

Orientadoras : Dras. Cláudia Maria de Almeida, e Camila Souza dos Anjos Lacerda.

1. WorldView-2. 2. WorldView-3. 3. Mineração de dados.
4. Classificação de cobertura do solo urbano. I.Título.

CDU 528.831



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](#).

This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](#).

Aluno (a): **Paulo Roberto da Silva Ruiz**

Título: "CLASSIFICAÇÃO DA COBERTURA DO SOLO URBANO USANDO ÁRVORES DE
DECISÃO A PARTIR DE CENAS WORLDVIEW-2 E WORLDVIEW-3 PARA
DIFERENTES NÍVEIS DE LEGENDA"

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

Dr. Thales Sehn Körting




Presidente / INPE / São José dos Campos - SP

Dra. Cláudia Maria de Almeida



Orientador(a) / INPE / São José dos Campos - SP

Dra. Camila Souza dos Anjos Lacerda




Orientador(a) / INPE / São José dos Campos - SP

Dr. Hermann Johann Heinrich Kux



Membro da Banca / INPE / SJCampos - SP

Dr. Elcio Hideiti Shiguemori



Convidado(a) / IEAv/DCTA / São José dos Campos - SP

Este trabalho foi aprovado por:

() maioria simples

(X) unanimidade

São José dos Campos, 21 de fevereiro de 2017

AGRADECIMENTOS

Primeiramente, a minha esposa Renata, pelo apoio e companheirismo incondicional em prol da realização deste trabalho e de nossos projetos pessoais. A meus pais, Pedro e Ivone que sempre me estimularam em estudar e crescer intelectualmente.

As minhas orientadoras Dras. Cláudia Almeida e Camila Lacerda por suas orientações, disponibilidade e ajuda constante, além de terem me concedido a oportunidade de realizar este trabalho.

Ao Ten. Marielcio Lacerda por sua valiosa ajuda na etapa de avaliação dos resultados das classificações.

Aos professores do curso de Sensoriamento Remoto por suas aulas e contribuições para com o aprendizado e o desenvolvimento deste trabalho.

Aos colegas de curso pelo companheirismo, ajuda e contribuições para a consecução desta pesquisa.

Aos amigos Reynier e Wantuir pelas inúmeras ajudas no estudo de estatística e física.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela bolsa concedida.

À Janaína Tucunduva e Weber Pires da SatMap e a Rodrigo J. Varela da DigitalGlobe pela concessão da imagem WorldView-3, utilizada neste trabalho.

E, por fim, a todos os brasileiros e brasileiras que contribuem com seus impostos para manter universidades e instituições públicas, como o INPE, além de diversas modalidades de bolsas para estudos científicos e tecnológicos.

RESUMO

A partir do final dos anos 1990, o sensoriamento remoto orbital passou a oferecer imagens de elevada resolução espacial. Desde então, essa novidade fez florescer novas possibilidades no panorama dos estudos urbanos. A alta resolução espacial permite identificar com mais eficiência os alvos característicos das cidades, inaugurando uma nova era no estudo do espaço intraurbano. Atualmente, como a maioria da população mundial reside em cidades, o planejamento urbano não pode prescindir de um eficiente mapeamento urbano. Nesse sentido, o sensoriamento remoto de alta resolução espacial possui papel decisivo, mas apresenta ainda inúmeros desafios. Um deles é aliar alta resolução espacial a mais de quatro bandas multiespectrais, que é o caso dos sensores WorldView-2 (WV-2), detentor de oito bandas, e WorldView-3 (WV-3), detentor de 16 bandas espectrais imageadoras da superfície terrestre. O mapeamento urbano ganha qualidade com o refinamento espectral, todavia métodos adequados de classificação devem ser investigados para otimizar essa tarefa. Nesse contexto, o presente trabalho busca avaliar o desempenho de dois algoritmos de indução de árvores de decisão para serem aplicados na classificação de duas cenas, uma do WV-2 e a outra do WV-3, referente a um transecto do campus da Universidade Estadual de Campinas, São Paulo. Para cada conjunto de dados, foram realizadas quatro classificações aplicando os algoritmos de árvore de decisão Best First Tree (BFTree) e Logistic Model Tree (LMT) em dois diferentes níveis de legenda de classificação. O Nível de Legenda 1 apresenta 11 classes de cobertura do solo urbano tanto para a cena do WV-2 como para aquela do WV-3, e o Nível de Legenda 2 apresenta 38 classes para a cena do WV-2 e 42 classes para a cena do WV-3. As classificações alcançaram acurácias consideradas muito boas, em que os índices *Kappa* variaram de 0,6129 a 0,7863 e as exatidões globais entre 64,41% e 82,27%. As comparações entre os resultados das classificações foram realizadas por meio de testes de hipótese. Os testes comparando o desempenho dos algoritmos para os distintos conjuntos de dados e níveis de legenda demonstraram que o algoritmo LMT foi significativamente superior ao algoritmo BFTree. No tocante ao desempenho dos conjuntos de dados de ambos os sensores, mesmo possuindo mais classes no Nível de Legenda 2, os dados do WV-3, quando classificados pelo algoritmo LMT, obtiveram desempenho superior em relação àqueles do WV-2, inclusive no Nível de Legenda 1. Por fim, o desenvolvimento deste trabalho elucidou a necessidade de melhoria das resoluções espaciais e espectrais dos dados orbitais para a identificação precisa dos alvos urbanos, bem como a adoção de algoritmos de mineração de dados apropriados para esse fim.

Palavras-chave: WorldView-2. WorldView-3. Mineração de dados. Classificação de Cobertura do Solo Urbano.

DECISION TREES-BASED URBAN LAND COVER CLASSIFICATION OF WORLDVIEW-2 AND WORLDVIEW-3 SCENES AT DIFFERENT LEGEND LEVELS

ABSTRACT

At the end of the 1990s, orbital remote sensing began to offer very high spatial resolution images. Since then, this novelty has fostered new possibilities of scientific investigation in the scope of urban studies. The very high spatial resolution enables a more accurate and efficient identification of urban targets, opening up new paths for studying the intraurban environment. Today, as most of the world population resides in cities, urban planning cannot be done without an efficient urban mapping. In this sense, remote sensing of high spatial resolution plays a decisive role, though still presents many challenges. One of these is to combine high spatial resolution with more than four multispectral bands, which is the case of WorldView-2 (WV-2), an eight-band system, and WorldView-3 (WV-3), which has 16 spectral bands meant for imaging the Earth surface. Urban mapping improves quality with spectral refinement, however suitable classification methods must be investigated to optimize this task. In this context, the present work seeks to evaluate the performance of two decision tree induction algorithms to be applied in the classification of two scenes, WV-2 and WV-3, covering a transect within the campus of the Campinas State University, São Paulo. For each dataset, four classifications were made applying the Best First Tree (BFTree) and Logistic Model Tree (LMT) algorithms at two different legend levels. Legend Level 1 presents 11 urban land use classes for both datasets (WV-2 and WV-3) and Legend Level 2 presents 38 classes for the WV-2 data and 42 classes for the WV-3 data. The classifications achieved very good accuracies, with *Kappa* indices ranging from 0.6129 to 0.7863 and the overall accuracy lying between 64.41% and 82.27%. The comparisons among the classifications results were performed by means of hypothesis tests. The tests comparing the algorithms performance for the different datasets and legend levels demonstrated that the LMT algorithm was significantly superior to the BFTree algorithm. Regarding the performance of the two datasets, even though the greater number of classes at the Legend Level 2, the WV-3 data when classified by the LMT algorithm performed better than the WV-2 data, also at the Legend Level 1. Finally, this work corroborated the need to improve the spatial and spectral resolutions of the orbital data for the precise identification of the urban targets as well as the adoption of appropriate data mining algorithms for this purpose.

Keywords: WorldView-2. WorldView-3. Data Mining. Urban Land Cover Classification.

LISTA DE FIGURAS

	<u>Pág.</u>
Figura 2.1 – Posições das bandas espectrais do WV-2.....	11
Figura 2.2 – Posições das bandas espectrais do SWIR do WV-3.....	12
Figura 3.1 – Localização da área de estudo.	26
Figura 3.2 – Fluxograma das etapas metodológicas do trabalho.	28
Figura 3.3 – Interface do eCognition 8.7 mostrando a coleta de amostras.	52
Figura 3.4 – Saída da classificação no WEKA (ferramenta Supplied test set)..	53
Figura 3.5 – Estrutura típica de uma árvore de decisão BFTree (A) e LMT (B).	59
Figura 3.6 – Imagem WV-2 da área de estudo em composição colorida verdadeira (à esquerda) e falsa-cor (à direita).	61
Figura 3.7 – Imagem WV-3 da área de estudo em composição colorida verdadeira (à esquerda) e falsa-cor (à direita).	62
Figura 3.8 – Mapas de verdade de campo referentes aos dados WV-2 para ambos os níveis de legenda.	63
Figura 3.9 – Mapas de verdade de campo referentes aos dados WV-3 para ambos os níveis de legenda.	64
Figura 4.1 – Frequência dos atributos utilizados pelo algoritmo BFTree no Nível de Legenda 1 para os dados WV-2.....	70
Figura 4.2 – Frequência dos atributos utilizados pelo algoritmo LMT no Nível de Legenda 1 para os dados WV-2.....	70
Figura 4.3 – Classificação da imagem WV-2 com o algoritmo BFTree referente ao Nível de Legenda 1.....	71
Figura 4.4 – Classificação da imagem WV-2 com o algoritmo LMT referente ao Nível de Legenda 1.	72
Figura 4.5 – Frequência dos atributos utilizados pelo algoritmo BFTree no Nível de Legenda 1 para os dados WV-3.....	75
Figura 4.6 – Frequência dos atributos utilizados pelo algoritmo LMT no Nível de Legenda 1 para os dados WV-3.....	76

Figura 4.7 – Classificação da imagem WV-3 com o algoritmo BFTree referente ao Nível de Legenda 1.....	77
Figura 4.8 – Classificação da imagem WV-3 com o algoritmo LMT referente ao Nível de Legenda 1.	78
Figura 4.9 – Frequência dos atributos utilizados pelo algoritmo BFTree no Nível de Legenda 2 para os dados WV-2.....	81
Figura 4.10 – Frequência dos atributos utilizados pelo algoritmo LMT no Nível de Legenda 2 para os dados WV-2.....	82
Figura 4.11 – Classificação da imagem WV-2 com o algoritmo BFTree referente ao Nível de Legenda 2.....	83
Figura 4.12 – Classificação da imagem WV-2 com o algoritmo LMT referente ao Nível de Legenda 2.	84
Figura 4.13 – Frequência dos atributos utilizados pelo algoritmo BFTree no Nível de Legenda 2 para os dados WV-3.....	88
Figura 4.14 – Frequência dos atributos utilizados pelo algoritmo LMT no Nível de Legenda 2 para os dados WV-3.....	89
Figura 4.15 – Classificação da imagem WV-3 com o algoritmo BFTree referente ao Nível de Legenda 2.....	90
Figura 4.16 – Classificação da imagem WV-3 com o algoritmo LMT referente ao Nível de Legenda 2.	91
Figura 4.17 – Índice Kappa para o Nível de Legenda 1.	95
Figura 4.18 – Índice Kappa para o Nível de Legenda 2.	96
Figura 4.19 – Tempo de processamento para o Nível de Legenda 1.	102
Figura 4.20 – Tempo de processamento para o Nível de Legenda 2.	102
Figura 4.21 – Tempo de classificação para o Nível de Legenda 1.	103
Figura 4.23 – Dados WV-2: Verdade de campo (A) e classificações para o Nível de Legenda 1: BFTree (B) e LMT(C).....	106
Figura 4.24 – Dados WV-3: Verdade de campo (A) e classificações para o Nível de Legenda 1: BFTree (B) e LMT(C).....	107
Figura 4.25 – Dados WV-2: Verdade de campo (A) e classificações para o Nível de Legenda 2: BFTree (B) e LMT(C).....	108

Figura 4.26 – Dados WV-3: Verdade de campo (A) e classificações para o Nível de Legenda 2: BFTree (B) e LMT(C).....	109
--	-----

LISTA DE TABELAS

	<u>Pág.</u>
Tabela 2.1 – Taxonomia dos sensores remotos em relação à resolução espacial.	8
Tabela 2.2 – Características dos satélites de alta resolução espacial.	9
(continua) 9	
Tabela 2.2 – Conclusão.	10
Tabela 3.1 – Atributos utilizados nas classificações BFTree e LMT.	31
Tabela 3.1 – Conclusão.	32
Tabela 3.2 – Níveis de legenda de classificação do solo urbano para os dados WV-2 e WV-3 e detalhes das classes.	35
Tabela 3.2 – Continuação.....	36
Tabela 3.2 – Continuação.....	37
Tabela 3.2 – Continuação.....	38
Tabela 3.2 – Continuação.....	39
Tabela 3.2 – Continuação.....	40
Tabela 3.2 – Continuação.....	41
Tabela 3.2 – Continuação.....	42
Tabela 3.2 – Continuação.....	43
Tabela 3.2 – Continuação.....	44
Tabela 3.2 – Continuação.....	45
Tabela 3.2 – Continuação.....	46
Tabela 3.2 – Continuação.....	47
Tabela 3.2 – Continuação.....	48
Tabela 3.2 – Continuação.....	49
Tabela 3.2 – Conclusão	50
Tabela 3.3 – Parâmetros das segmentações.....	51
Tabela 3.4 – Categorização do Índice Kappa.	67
Tabela 4.1 – Análise percentual dos acertos e confusões da classificação dos dados WV-2 com o algoritmo BFTree para o Nível de Legenda 1. 74	

Tabela 4.2 – Análise percentual dos acertos e confusões da classificação dos dados WV-2 com o algoritmo LMT para o Nível de Legenda 1.	74
Tabela 4.3 – Análise percentual dos acertos e confusões da classificação dos dados WV-3 com o algoritmo BFTree para o Nível de Legenda 1.	79
Tabela 4.4 – Análise percentual dos acertos e confusões da classificação dos dados WV-3 com o algoritmo LMT para o Nível de Legenda 1.	80
Tabela 4.5 – Análise percentual dos acertos e confusões da classificação dos dados WV-2 com o algoritmo BFTree para o Nível de Legenda 2.	86
Tabela 4.6 – Análise percentual dos acertos e confusões da classificação dos dados WV-2 com o algoritmo LMT para o Nível de Legenda 2.	87
Tabela 4.7 – Análise percentual dos acertos e confusões da classificação dos dados WV-3 com o algoritmo BFTree para o Nível de Legenda 2.	93
Tabela 4.8 – Análise percentual dos acertos e confusões da classificação dos dados WV-3 com o algoritmo BFTree para o Nível de Legenda 2.	94
Tabela 4.9 – Índice Kappa condicional do usuário e produtor referente às classificações dos dados WV-2 para o Nível de Legenda 1.	96
Tabela 4.10 – Índice Kappa condicional do usuário e produtor referente às classificações dos dados WV-3 para o Nível de Legenda 1.	97
Tabela 4.11 – Índice Kappa condicional do usuário e produtor referente às classificações dos dados WV-2 para o Nível de Legenda 2.	98
Tabela 4.12 – Índice Kappa condicional do usuário e produtor referente às classificações dos dados WV-3 para o Nível de Legenda 2.	99
Tabela 4.13 – Síntese comparativa das classes com menores índices Kappa condicionais e classes confundidas na matriz de confusão.	111
Tabela C.1: Matriz de confusão para os dados WV-2, com o algoritmo BFTree, para o Nível de Legenda 1.	171
Tabela C.2: Matriz de confusão para os dados WV-2, com o algoritmo LMT, para o Nível de Legenda 1.	172
Tabela C.3: Matriz de confusão para os dados WV-3, com o algoritmo BFTree, para o Nível de Legenda 1.	173

Tabela C.4: Matriz de confusão para os dados WV-3, com o algoritmo LMT, para o Nível de Legenda 1.	174
Tabela C.5: Matriz de confusão para os dados WV-2, com o algoritmo BFTree, para o Nível de Legenda 2.	175
Tabela C.6: Matriz de confusão para os dados WV-2, com o algoritmo LMT, para o Nível de Legenda 2.	176
Tabela C.7: Matriz de confusão para os dados WV-3, com o algoritmo BFTree, para o Nível de Legenda 2.	177
Tabela C.8: Matriz de confusão para os dados WV-3, com o algoritmo LMT, para o Nível de Legenda 2.	178
Tabela D.1: Testes de Hipóteses Individuais por classificação para analisar se os valores de Kappa são significativamente maiores que zero para o Nível de Legenda 1.	179
Tabela D.2: Testes de Hipóteses para comparar o desempenho dos algoritmos BFTree e LMT para o Nível de Legenda 1.	180
Tabela D.3: Testes de Hipóteses para comparar o desempenho dos sensores WV-2 e WV-3 para o Nível de Legenda 1.	180
Tabela D.4: Testes de Hipóteses individuais por classificação para analisar se os valores de Kappa são significativamente maiores que zero para o Nível de Legenda 2.	181

LISTA DE SIGLAS E ABREVIATURAS

AC	Atributo Customizado
BFTree	<i>Best First Tree</i> (Primeira Melhor Árvore)
CRFS	Cimento Reforçado com Fio Sintético
FLAASH	<i>Fast Line-of-Sight Atmospheric Analysis of Spectral Hypercubes</i>
GEOBIA	<i>GEographic Object-Based Image Analysis</i>
KDD	<i>Knowledge Discovery from Data</i> (Descoberta do Conhecimento)
Kp	<i>Kappa</i> Condicional Produtor
Ku	<i>Kappa</i> Condicional Usuário
LM	<i>Logistic Model</i> (Modelo Logístico)
LMT	<i>Logistic Model Tree</i> (Árvore de Modelo Logístico)
MDA	Modelo Digital de Altura
MDE	Modelo Digital de Elevação
MDS	Modelo Digital de Superfície
MDSn	Modelo Digital de Superfície Normalizado
MDT	Modelo Digital de Terreno
MNF	<i>Minimum Noise Fraction</i> (Fração Mínima de Ruído)
MODTRAN	<i>Moderate Resolution Transmittance</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
PCA	<i>Principal Component Analysis</i> (Análise de Componentes Principais)
QGIS	<i>Quantum Geographic Information System</i>
SAVI	<i>Soil Adjusted Vegetation Index</i> (Índice de Vegetação Ajustado ao Solo)
UNICAMP	Universidade Estadual de Campinas
UTM	<i>Universal Transverse Mercator</i> (Universal Transversa de Mercator)
WEKA	<i>Waikato Environment for Knowledge Analysis</i>
WGS-84	<i>World Geodetic System 1984</i>
WV-2	WorldView-2
WV-3	WorldView-3

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
1.1 Objetivo Geral	3
1.2 Objetivos Específicos.....	3
1.3 Hipótese	3
1.4 Justificativa	3
1.5 Organização do Trabalho	4
2 FUNDAMENTAÇÃO TEÓRICA.....	7
2.1 Sensoriamento Remoto de Alta Resolução Espacial	7
2.1.1 O Satélite WorldView-2.....	10
2.1.2 O Satélite WorldView-3.....	11
2.2 Processamento Digital de Imagens	12
2.2.1 Correção Atmosférica	13
2.2.2 Ortorectificação.....	13
2.2.3 Extração de Atributos (Feature Extraction)	14
2.2.4 Segmentação Multirresolução	16
2.2.5 Classificação de Imagens	17
2.2.5.1 Mineração de Dados	20
2.2.5.2 Árvores de Decisão	21
2.2.6 Avaliação da Qualidade da Classificação	22
3 MATERIAL E MÉTODOS.....	25
3.1 Área de Estudo	25
3.2 Dados de Entrada.....	27
3.3 Recursos Computacionais	27
3.4 Fluxograma Metodológico	27
3.5 Pré-Processamento.....	28
3.6 Extração de Atributos dos Dados WV-2 e WV-3	30
3.7 Segmentação e Classificação	33
3.8 Indução de Árvores de Decisão	54

3.9	Algoritmo BFTREE	56
3.10	Algoritmo LMT	57
3.11	Avaliação dos Resultados	60
4	RESULTADOS E DISCUSSÕES.....	69
4.1	Nível de Legenda 1	69
4.1.1	Imagem do Satélite WorldView-2.....	69
4.1.2	Imagem do Satélite WorldView-3.....	74
4.2	Nível de Legenda 2	80
4.2.1	Imagem do Satélite WorldView-2.....	80
4.2.2	Imagem do Satélite WorldView-3.....	88
4.3	Resultados do Índice Kappa e Testes de Hipótese	95
4.4	Tempos de Processamento	101
4.5	Discussão	104
5	CONCLUSÕES E RECOMENDAÇÕES.....	115
	REFERÊNCIAS BIBLIOGRÁFICAS	119
	APÊNDICE A – ÁRVORES DE DECISÃO PARA CENA WORLDVIEW-2.	127
A.1	Nível de Legenda 1	127
A.2	Nível de Legenda 2	148
	APÊNDICE B – ÁRVORES DE DECISÃO PARA CENA WORLDVIEW-3.	157
B.1	Nível de Legenda 1	157
B.2	Nível de Legenda 2	161
	APÊNDICE C – MATRIZES DE CONFUSÃO.....	171
	APÊNDICE D – TESTES DE HIPÓTESE.....	179

1 INTRODUÇÃO

A partir de 2007, a humanidade testemunhou a superação do contingente de população rural pelo contingente de população urbana (UNPD, 2014). No caso do Brasil, a população urbana atualmente supera o índice de 84% (IBGE, 2013). Portanto, o crescimento populacional urbano é um fenômeno que ocorre com grande rapidez, sendo considerado um processo irrefreável e irreversível. Com isso, as cidades necessitam de uma melhoria no planejamento urbano para atender às necessidades dos cidadãos quanto à qualidade de vida, à distribuição equitativa de bens e serviços e à sua inclusão socioeconômica (BRASIL, 2002).

Para contribuir com o desenvolvimento de estudos urbanos voltados ao planejamento das cidades, são necessárias novas fontes de dados. Nesse contexto, o sensoriamento remoto ganha destaque por possibilitar o mapeamento e a atualização cartográfica dessas áreas. A melhoria sistemática da qualidade geométrica dos sensores orbitais de alta resolução espacial e o imageamento em vários canais multiespectrais permitem detalhar os alvos urbanos. Esses recursos são requeridos para o mapeamento urbano, pelo fato de as cidades possuírem uma grande diversidade de alvos, geralmente de pequeno e médio porte (JENSEN, 2011).

O lançamento de satélites de alta resolução espacial, como o IKONOS-2 no final da década de 1990, significou novas possibilidades para o sensoriamento remoto do espaço urbano. Desde então, a alta resolução espacial dos diversos sensores colocados em operação permitiu a distinção cada vez mais refinada dos alvos no meio intraurbano. Contudo, a imensa maioria desses sensores ainda é limitada quanto à resolução espectral, a qual contribui para a identificação precisa das propriedades físicas e químicas dos alvos (MYINT et al., 2011). Muitos sensores com resolução espacial inferior a 1 m possuem apenas uma banda pancromática ou, em alguns casos, quatro bandas multiespectrais, que abrangem apenas as regiões do visível e do infravermelho

próximo, o que prejudica a classificação precisa de uma cena urbana (EMBRAPA, 2013).

Porém, essa limitação foi superada em 2009 com o lançamento do satélite WorldView-2, comercializado pela DigitalGlobe. A grande inovação foi a introdução de um sensor com oito bandas multiespectrais. Além das quatro bandas já disponíveis em outros sensores de alta resolução espacial, outras quatro bandas foram introduzidas, sendo elas: azul costeiro, amarelo, vermelho limítrofe e infravermelho próximo-2 (DIGITALGLOBE, 2009).

Nessa mesma linha de avanços tecnológicos, o ano de 2014 marca o lançamento do satélite WorldView-3, que significou uma importante ampliação das possibilidades de imageamento orbital da superfície terrestre. Esse novo satélite trouxe consigo inúmeras melhorias, sobretudo na resolução espacial, alcançando 0,3 m, e na resolução espectral, sendo acrescentadas oito novas bandas, compreendendo a região do SWIR (*ShortWave InfraRed* ou Infravermelho de Ondas Curtas), totalizando dezesseis bandas espectrais para imageamento da superfície terrestre (DIGITALGLOBE, 2013).

As elevadas resoluções espaciais e espectrais também significaram novos desafios para o sensoriamento remoto, uma vez que o refinamento de ambas resoluções exige melhores recursos computacionais para o processamento, manipulação e armazenamento dessas imagens. Nesse sentido, o presente trabalho propõe explorar as potencialidades e limitações dos sensores WorldView-2 e WorldView-3 para a classificação de alvos urbanos em diferentes níveis de legenda de classificação. O termo nível de legenda de classificação (em inglês, *level of legend*) é amplamente utilizado na literatura para se referir ao nível de detalhamento de uma classificação, expresso invariavelmente pelo número de classes constantes da legenda (HEROLD et al., 2004; JENSEN, 2011). Para isso, serão utilizados métodos não paramétricos de classificação de imagens baseados em árvores de decisão. A área de estudo localiza-se no interior de São Paulo, em um transecto localizado

no campus da Universidade Estadual de Campinas (UNICAMP), o qual contém grande diversidade de materiais de cobertura do solo.

1.1 Objetivo Geral

O trabalho propõe-se a avaliar comparativamente classificações de cobertura do solo urbano utilizando as oito bandas multiespectrais do WorldView-2 e as dezesseis bandas multiespectrais do WorldView-3. As classificações serão realizadas por meio de dois algoritmos de indução de árvore de decisão. O objetivo é investigar a acurácia das classificações em relação a cada um dos algoritmos de classificação e em relação aos dois conjuntos de dados, para dois níveis de legenda.

1.2 Objetivos Específicos

- a) Explorar diferentes algoritmos de indução de árvore de decisão para a classificação de imagens orbitais de alta resolução espacial.
- b) Avaliar comparativamente as classificações resultantes de cada algoritmo de árvore de decisão utilizado, analisando o comportamento dos atributos selecionados na indução das árvores de decisão e identificando aqueles de melhor desempenho em cada nível de legenda de classificação.

1.3 Hipótese

A hipótese deste trabalho é a seguinte:

O uso de alta resolução espacial acompanhado da melhora na resolução espectral em imagens orbitais possibilita adotar um nível de legenda mais refinado, distinguindo materiais visualmente semelhantes, na classificação de uma cena com mais de 30 classes de cobertura do solo urbano?

1.4 Justificativa

Eficientes métodos de classificação de imagens de alta resolução espacial têm sido continuamente almejados em face do grande volume de dados aportados por tais sensores e da necessidade de extração de informações precisas em curto espaço de tempo para as diversas aplicações urbanas, tanto por parte de gestores da esfera pública e privada, bem como por parte de pesquisadores e acadêmicos em geral. Segundo Anjos (II), "a discriminação detalhada de materiais de cobertura do solo urbano, os quais compreendem materiais de pavimentação viária e não viária, vegetação, corpos d'água, solo exposto e materiais de recobrimento de edificações (lajes, telhados, parapeitos, brises etc.), pode ser útil para fins de:

- (i) estimativas de reflectância desses materiais de superfície e da consequente determinação de sua contribuição para com o fenômeno de ilhas de calor urbanas,
- (ii) diferenciação entre coberturas vãs e permanentes, bem como detecção de piscinas irregularmente construídas para fins de tributação imobiliária urbana,
- (iii) identificação de materiais com compostos agressivos à saúde e/ou suposta ou reconhecidamente cancerígenos e da avaliação da sua relação com a incidência de patologias, entre outras finalidades investigativas e fiscalizatórias."

1.5 Organização do Trabalho

O trabalho aqui apresentado está organizado em cinco capítulos, sendo o primeiro deles esta introdução, com a exposição dos objetivos gerais e específicos, hipótese e justificativa. O Capítulo 2 aborda a fundamentação teórica, destacando o sensoriamento remoto de alta resolução espacial, bem como o processamento digital de imagens, desde o pré-processamento até a classificação de imagens por meio de mineração de dados e a avaliação da qualidade da classificação. O material e os métodos utilizados são apresentados no Capítulo 3, o qual contém a descrição da área de estudo e

apresenta o fluxograma metodológico. Por sua vez, o Capítulo 4 aborda os resultados alcançados por esta pesquisa, seguidos pelas discussões. Por fim, o Capítulo 5 apresenta as conclusões e recomendações finais do trabalho.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Sensoriamento Remoto de Alta Resolução Espacial

A alta resolução espacial de um sensor orbital permite a discriminação mais detalhada de alvos, sobretudo em ambientes urbanos. O uso desses dados aliado às informações contextuais dos objetos possibilita uma evolução nas análises do espaço intraurbano (ALMEIDA et al., 2009), e dessa forma, evidencia-se a importância da resolução espacial para as inúmeras aplicações urbanas. Myint et al. (2011) salientam que, tradicionalmente, a aerofotogrametria era a maior fonte de dados para esses estudos, mas a crescente disponibilização de dados orbitais de alta resolução espacial impactou favoravelmente a demanda por esse novo recurso do sensoriamento remoto.

Conforme Jensen e Cowen (1999), o sensoriamento remoto para estudo de áreas urbanas deve contemplar as chamadas “feições urbanas”, que por sua vez estão relacionadas às resoluções temporal, espacial e espectral disponíveis. A definição da resolução temporal abrange a duração de um ciclo de determinado fenômeno urbano e o tempo de revisita do sensor, que impactam na atualização de dada informação. A definição da resolução espacial está relacionada ao tamanho dos alvos de interesse, que nas áreas urbanas deve ser, pelo menos, a metade do tamanho do menor alvo de interesse (CAMPBELL, 2007). Para fins de classificação, a resolução espacial favorece o discernimento das propriedades dos alvos urbanos, como forma, textura, cor, sombra e contexto. Por sua vez, a resolução espectral deve ser adequada para discriminar as classes de cobertura do solo urbano, pois a variedade espectral dos alvos neste meio é muito grande (BLASCHKE et al., 2014).

Com a evolução dos sensores em relação às suas resoluções, atualmente há uma ampla gama de imagens orbitais oferecendo sobretudo resoluções espaciais mais finas. Para distinguir e categorizar os sistemas sensores em

relação às suas resoluções espaciais, será adotada a taxonomia proposta por Ehlers et al. (2002), apresentada na Tabela 2.1.

Tabela 2.1 – Taxonomia dos sensores remotos em relação à resolução espacial.

TAXONOMIA DOS SISTEMAS SENSORES						
Nomenclatura	Ultra-Alta (<i>Ultra High</i>)	Muito Alta (<i>Very High</i>)	Alta (<i>High</i>)	Média (<i>Medium</i>)	Baixa (<i>Low</i>)	Muito Baixa (<i>Very Low</i>)
Resolução Espacial	< 1m	1 - 4m	4 -10m	10 – 50m	50 – 250m	> 250m

Fonte: Adaptado de Ehlers et al. (2002).

Passadas algumas décadas do lançamento do satélite LANDSAT-1, o final dos anos 1990 marca uma nova era no sensoriamento remoto orbital – a alta resolução espacial, com os satélites IRS e IKONOS-2. O programa indiano de satélites de observação da Terra (*Indian Remote Sensing Satellite - IRS*) lança os pioneiros IRS 1C e IRS 1D respectivamente em 1996 e 1997, possuindo 5 m de resolução espacial no modo pancromático. Com a falha do lançamento do IKONOS-1, o projeto do IKONOS-2 foi adiantado, entrando em operação em setembro de 1999. Este foi o primeiro sensor a obter imagens pancromáticas e multiespectrais na região do visível e do infravermelho próximo com resoluções espaciais de 1 m e 4 m, respectivamente nas bandas pancromática e multiespectrais.

A Tabela 2.2 apresenta os anos de início e término de operação, as resoluções, a instituição responsável e o país de origem dos principais sensores de alta, muito alta e ultra-alta resoluções espaciais.

Tabela 2.2 – Características dos satélites de alta resolução espacial.

Satélite	Operação/ Término	Resoluções			Instituição/ País
		Espacial (m)	Espectral (μm)	Temp (Dias)	
IRS 1C e IRS 1D	1996 - 1997/2007	5	0,50-0,75	24	Indian Space Research Organization (ISRO) / Índia
		23,5	0,52-0,59 0,62-0,68 0,77-0,86	24	
IKONOS-2	1999/ativo	1	0,45-0,90	2,9	GeoEye/ EUA
		4	0,45-0,52 0,52-0,60 0,63-0,69 0,76-0,90	1,5	
EROS A	2000/ativo	1,9	0,50-0,90	4	ImageSat/Israel
QuickBird-2	2001/2007	0,6	0,44-0,90	1 a 3,5	DigitalGlobe/EUA
		2,4	0,45-0,52 0,52-0,60 0,63-0,69 0,76-0,90	1 a 3,5	
OrbView-3	2003/2007	1	0,45-0,90	~ 3	GeoEye/ EUA
		4	0,45-0,52 0,52-0,60 0,62-0,69 0,76-0,90	~ 3	
CARTOSAT-1; CARTOSAT-2 e CARTOSAT- 2B	2005; 2008 e 2010 /ativos	CART-1: 2,5; CART-2: 0,8; CART-2B: 0,8	0,50-0,85	5	ISRO/Índia
KOMPSAT-2 e KOMPSAT-3	2006 - 2012/ ativos	KOM-2: 1; KOM-3: 0,70	0,50-0,90	~ 3	Korea Aerospace Research Institute/ Coréia do Sul
		2: 4; 3: 2,8	0,45-0,52 0,52-0,60 0,63-0,69 0,76-0,90	~ 3	
GeoEye-1	2008/ativo	0,46	0,45-0,80	3	GeoEye/ EUA
		1,84	0,45-0,51 0,51-0,58 0,65-0,69 0,78-0,92	3	
WorldView-1	2007/ativo	0,46	0,40-0,90	1,7	DigitalGlobe/EUA
WorldView-2 e WorldView-3	2009 - 2014/ ativos	WV-2: 0,46; WV-3: 0,31	0,45-0,80	1,1	
		WV-2: 1,84; WV-3: 1,24	0,39-0,45 0,44-0,51 0,51-0,58 0,58-0,62 0,63-0,69 0,69-0,74 0,76-0,90 0,85-1,04	1,1	

(continua)

Tabela 2.2 – Conclusão.

Pleiades 1Ae Pleiades 1B	2011 – 2012/ ativos	0,5	0,47-0,83	1	<i>Centre National d'Etudes Spatiales/ França e Itália</i>
		2	0,43-0,55 0,50-0,62 0,59-0,71 0,74-0,94	1	
Gaofen 1 e Gaofen 2	2013 – 2014/ ativos	Gao 1: 2 Gao 2: 0,8	0,45-0,90	4	<i>China National Space Administration/ China</i>
		Gao 1: 8 Gao 2: 3,2	0,45-0,52 0,52-0,59 0,63-0,69 0,77-0,89	4	
SkySat – 1 e SkySat – 2	2013 – 2014 /ativos	0,9	0,45-0,90	5	Skybox Imaging Inc./ EUA
		2,0	0,45-0,51 0,51-0,59 0,60-0,69 0,74-0,90	5	

Fonte: adaptado de Embrapa (2013).


Analisando os sensores da Tabela 2.2, é possível verificar que a resolução ultra-alta (menor de 1m) foi alcançada em 2001 com o QuickBird-2; em 2008, com o GeoEye-1; em 2010, com o CARTOSAT-2B; em 2011; com o Pleiades 1A; em 2012, com o KOMPSAT-3 e o Pleiades 1B, e também com os três satélites da série WorldView a partir de 2007. A absoluta maioria dos sensores listados apresenta uma única banda pancromática e quatro bandas multiespectrais, entre 0,45 e 0,90 μm , compreendendo o espectro visível (azul, verde e vermelho) e infravermelho próximo. As únicas exceções nesse tocante são os sensores WorldView-2 e WorldView-3.

2.1.1 O Satélite WorldView-2

O satélite WV-2 foi lançado no dia 8 de outubro de 2009. Operado pela DigitalGlobe, possui como elementos marcantes os refinamentos das resoluções espaciais e espectrais, sendo pioneiro nessas características. Dessa forma, torna-se referência na identificação de objetos e feições em estudos de classificação urbana, dentre outras aplicações.

O sensor a bordo do WV-2 possui resolução espacial no nadir de 0,46 m no modo pancromático, reamostrada para 0,50 m devido a restrições de defesa impostas pelo governo norteamericano na época do lançamento, e 1,84 m no modo multiespectral. As imagens são quantizadas em 11 bits de resolução radiométrica. O sistema sensor possui, além dos canais espectrais convencionais do azul (450-510 nm), verde (510-580 nm), vermelho (630-690 nm) e infravermelho próximo (750-745 nm), bandas adicionais do azul costeiro (400-450 nm), amarelo (585-625 nm), vermelho limítrofe (705-745 nm) e infravermelho próximo 2 (860-1040 nm) (DIGITAL GLOBE, 2009). A Figura 2.1 apresenta as bandas do WV-2.

Figura 2.1 – Posições das bandas espectrais do WV-2.



Fonte: Adaptado de DigitalGlobe (2009).

Suas novas bandas espectrais possibilitam diversas aplicações, a exemplo da banda azul costeiro, que permite estudos oceanográficos, como análise batimétrica. A banda amarela é ideal para classificação, tanto em terra quanto na água. Já o vermelho limítrofe e infravermelho 2 são voltadas para análise e classificação vegetal e estudos de biomassa (DIGITALGLOBE, 2009).


2.1.2 O Satélite WorldView-3

O satélite WV-3 foi lançado em 13 de agosto de 2014, superando os refinamentos de resoluções de seu antecessor, o WV-2. O WV-3 transporta

sensores de alta resolução espacial que produzem imagens de até 0,31 m a nadir em sua banda pancromática, 1,24 m em suas bandas multiespectrais e 3,7 m em suas bandas de infravermelho de ondas curtas (SWIR).

As oito bandas multiespectrais do WV-3 estão localizadas nos mesmos intervalos das bandas do WV-2 (Figura 2.1). Em termos de resolução espectral, seu maior diferencial são suas oito novas bandas na região do SWIR (Figura 2.2), permitindo o imageamento na presença de CO₂ e vapor d'água. Adicionalmente, o WV-3 leva a bordo o sensor CAVIS (*Clouds, Aerosols, Vapor, Ice and Snow* ou Nuvens, Aerossóis, Vapor d'Água, Gelo e Neve), que permite estudos físico-químicos da atmosfera (DIGITALGLOBE, 2013).

Figura 2.2 – Posições das bandas espectrais do SWIR do WV-3.



Fonte: Adaptado de DigitalGlobe (2013).

2.2 Processamento Digital de Imagens

O processamento digital de imagens consiste em um conjunto de técnicas para facilitar o processo de extração de informação de uma imagem, buscando detectar e identificar fenômenos importantes em uma cena de modo a torná-la visualmente melhor, sendo inseridas no conjunto de ferramentas de análise de dados do sensoriamento remoto (JENSEN, 2011). Dessa maneira, o conjunto de procedimentos que será utilizado neste trabalho é descrito a seguir.

2.2.1 Correção Atmosférica

A atmosfera terrestre possui forte atuação entre o objeto na superfície terrestre e o sensor. Devido aos fenômenos de espalhamento, absorção e refração da energia eletromagnética, a atmosfera afeta a radiância refletida ou emitida captada pelo sensor. Assim, a correção atmosférica é utilizada para minimizar os efeitos da influência da atmosfera nas imagens orbitais.

Os principais efeitos atmosféricos nas imagens são a diminuição do brilho da superfície em regiões espectrais específicas e a presença de névoa, com perda de nitidez, nas regiões dos menores comprimentos de onda. Em vista de estas alterações impactarem negativamente a análise de dados de sensoriamento remoto, existem na literatura diversos métodos para correção atmosférica. É possível dividi-los em métodos alternativos e métodos físicos. Os alternativos utilizam apenas informações da própria imagem para determinar a contribuição da atmosfera em cada banda espectral. Por sua vez, os métodos físicos necessitam do conhecimento das propriedades ópticas da atmosfera, além do processo de interação da radiação com a atmosfera e a superfície (LATORRE et al., 2002).

2.2.2 Ortorretificação

Alguns aspectos de aquisição das imagens orbitais, como a plataforma, o ângulo de aquisição, o relevo, a curvatura e a rotação da Terra impactam na qualidade dos dados de sensoriamento remoto. Nesse sentido, o processo de ortorretificação visa corrigir deformações geométricas oriundas desses aspectos. Para Schowengerdt (1997), a ortorretificação é uma correção geométrica extremamente necessária em imagens de sensores remotos, especialmente quando as imagens representam superfícies muito irregulares e com declividades extremamente acentuadas.

Nos últimos anos, diversos modelos matemáticos foram desenvolvidos a fim de eliminar distorções causadas principalmente pela posição do satélite, pelo

relevo e pela curvatura da Terra. Com isso, a imagem passa de uma projeção cônica para uma projeção ortogonal para manter a mesma escala em toda a ortoimagem (JACOBSEN, 2002). Os modelos utilizados para essa finalidade podem ou não necessitar de informações do sensor.

Modelos que necessitam de informações do sensor baseiam-se em alguns parâmetros específicos, como calibração, órbita, dados de posição e atitude do sensor. Modelos que consistem no uso de Coeficientes Polinomiais Racionais (*Rational Polynomial Coefficients* - RPCs) são capazes de resgatar a geometria da imagem no instante de sua captura através do Modelo de Funções Racionais (*Rational Function Model* – RFM). Dentre os modelos que não necessitam de informações do sensor, destaca-se o uso de RPCs estimados por pontos de controle no terreno, bem como de modelos polinomiais não racionais, cujos coeficientes também são estimados por pontos de controle representativos da variabilidade planimétrica e altimétrica da cena (BALTSAVIAS et al., 2001).

2.2.3 Extração de Atributos (*Feature Extraction*)

Para realizar a classificação de imagens é necessária a definição do conjunto de atributos dos dados. Nesta etapa preliminar, é fundamental não se restringir o rol de atributos que alimentarão o minerador, uma vez que a seleção ideal de tais atributos torna mais eficaz a identificação das classes de cobertura do solo. Os algoritmos de mineração determinarão os atributos mais significativos para a distinção das classes de interesse, e assim, a definição de atributos apropriados é decisiva para a obtenção de bons resultados na classificação.

Diversos estudos destacam que a extração de atributos a partir da imagem original é eficaz para promover melhorias significativas na acurácia das classificações de cobertura do solo, como em Leonardi (2010), Tong et al. (2014), Anjos (2016). Os atributos utilizados neste trabalho, além da média e desvio padrão das bandas originais das imagens, são descritos a seguir:

- **Análise por Componentes Principais (*Principal Component Analysis* – PCA):** Consiste de uma técnica estatística que extrai as informações mais importantes de um conjunto de dados, criando novas variáveis, ortogonais que são denominadas componentes principais. No caso de imagens multiespectrais, as componentes são representadas por todas as bandas originais, resultando em novas bandas não correlacionadas. Assim, as primeiras bandas concentram a maior parte das informações da imagem, sendo um atributo muito relevante para qualquer classificação (JOLLIFFE, 2002; ANJOS, 2016).
- **Fração Mínima de Ruído (*Minimum Noise Fraction* – MNF):** Da mesma forma que o método PCA, a transformação MNF é usada para diminuir a dimensionalidade dos dados, realizando o ordenamento de suas componentes conforme a qualidade da imagem expressa pelo nível de ruído presente na cena. A transformação MNF é composta por duas transformações em cascata. A primeira delas se baseia em uma matriz de covariância estimada de ruído para remover a correlação interbandas e re-escalonar o ruído. A segunda consiste na transformação padrão por Componentes Principais, resultando em um novo conjunto de bandas que é ordenado segundo os autovalores que expressam a variância das bandas. A ordem crescente das componentes implica aumento do nível de ruído (LEE, et al., 1990; ANJOS, 2016).
- **Atributos Customizados:** Consistem em operações matemáticas realizadas com as bandas das imagens de entrada, tendo como resultado uma nova imagem customizada. Como são gerados por aritmética de bandas, os índices de vegetação também podem ser considerados customizados (ANJOS, 2016). Conforme Ponzoni e Shimabukuro (2010), os índices de vegetação são essenciais para explorar as propriedades espectrais da vegetação nas regiões do visível e do infravermelho próximo.

2.2.4 Segmentação Multirresolução

O processo de segmentação representa um passo importante para a maioria das abordagens de análise de imagem. Este passo pode determinar o eventual sucesso ou fracasso de uma análise. O ato de segmentar uma imagem consiste em agrupar pixels com características similares em termos tonais e texturais, formando regiões homogêneas (DLUGOSZ et al., 2009).

Em geral, os algoritmos de segmentação baseiam-se nas características de descontinuidade e similaridade dos tons de cinza de uma imagem. O método por descontinuidade considera a mudança abrupta dos valores de cinza (detecção de bacias ou *watershed*), ao passo que o método por similaridade fundamenta-se na agregação de pixels em função de sua semelhança com os pixels vizinhos (crescimento de regiões ou *region growing*) (GONZÁLES; WINTZ, 1987).

Dentre os algoritmos de segmentação, destaca-se o multirresolução ou multiescala desenvolvido por Baatz e Schäpe (2000). Esse algoritmo permite que novos níveis de segmentação sejam continuamente criados (tanto de resolução mais fina como mais grosseira), podendo ser utilizado em aplicações que se utilizam apenas de um único nível de segmentação. Diversos estudos demonstram a alta eficácia deste algoritmo, como apresentado em Burnett e Blaschke (2003), Kux et al. (2008), Almeida et al. (2009), Camargo et al. (2011) e Blaschke et al. (2014).

A principal característica da segmentação multirresolução é a possibilidade de segmentar uma mesma imagem em níveis de escala diferenciados que se relacionam entre si, formando uma rede hierárquica de objetos (BAATZ; SCHÄPE, 2000). Dessa forma, como destaca Leonardi (2010), essa característica é fundamentada no fato de que objetos pequenos podem ser adequadamente analisados em uma resolução mais fina, enquanto objetos maiores podem ser adequadamente analisados em uma resolução mais grosseira. Assim, a segmentação pode ser realizada em múltiplas resoluções,

pela variação do fator de escala deste algoritmo, o qual altera o nível de resolução do processamento.

Conforme Baatz e Schäpe (2000), a segmentação multirresolução adota o conceito de evolução de rede fractal (*Fractal Net Evolution Approach* – FNEA), abordagem por crescimento de regiões, a qual considera a imagem de sensoriamento remoto como de natureza fractal. Este procedimento segmenta a imagem em múltiplos níveis, com tamanhos diferenciados de segmentos, níveis estes cujas fronteiras de segmentos articulam-se entre si. No processo de segmentação, é utilizada uma função que inclui diversos parâmetros para alcançar a homogeneidade dos objetos. O parâmetro cor é utilizado para determinar a homogeneidade espectral dos objetos (tons de cinza); por sua vez, o parâmetro forma é utilizado para definir a homogeneidade textural dos objetos. O parâmetro forma possui uma subdivisão em dois outros parâmetros: suavidade e compacidade. A suavidade representa o grau de irregularidade do contorno de um objeto, buscando a geração de objetos com bordas suaves. O parâmetro compacidade representa a propriedade de junção ou união dos pixels de um determinado objeto. Um objeto de forma retangular é mais compacto que um objeto com forma de uma “estrela”, por exemplo. O tamanho dos objetos da segmentação é definido pelo parâmetro fator de escala, o qual define o desvio padrão máximo da composição de homogeneidade alcançada pelos parâmetros mencionados anteriormente (CAMARGO et al., 2011).

2.2.5 Classificação de Imagens

A classificação digital de imagens é um processo de extração de informações a partir de dados de sensoriamento remoto destinado a reconhecer padrões e objetos homogêneos, que são utilizados para mapear áreas de interesse da superfície terrestre (NOVO, 2008). De um modo geral, os métodos de classificação utilizam um conjunto de parâmetros para classificar os objetos de acordo com suas características e similaridades. Para isto, o classificador necessita de um conjunto de amostras, denominado conjunto de treinamento.

Quanto ao tipo de treinamento, a classificação pode ser supervisionada ou não supervisionada (THEODORIDIS; KOUTROUMBAS, 2003; WITTEN et al., 2011).

A classificação supervisionada é composta primeiramente da fase de treinamento, na qual, a partir de um conjunto de amostras rotuladas, o desenvolvimento do classificador consiste em obter uma função que mapeie cada amostra à sua respectiva classe. A seguir, na fase de validação e teste do modelo, o classificador é avaliado utilizando-se um novo conjunto de amostras que não foram utilizadas no treinamento. A eficácia do classificador é verificada por meio de sua capacidade de prever a classe à qual pertence cada amostra do conjunto de entrada. Dessa forma, a classificação supervisionada objetiva classificar padrões não rotulados a partir de dados pré-classificados na fase de treinamento. Por outro lado, a classificação não supervisionada utiliza algoritmos de agrupamento para associar cada amostra do conjunto de treinamento a um grupo, sendo desnecessário o conhecimento prévio do rótulo das diferentes classes presentes no conjunto amostral. Algoritmos de agrupamento dividem um conjunto de padrões não rotulados em grupos cujos elementos apresentem alguma similaridade (BISHOP, 2006; THEODORIDIS; KOUTROUMBAS, 2003).

Os métodos de classificação podem ser divididos em duas categorias: métodos paramétricos e não paramétricos. Enquanto os métodos paramétricos assumem a existência a priori de uma distribuição de probabilidades contínuas e métricas entre os dados, os métodos não paramétricos vão além dessa noção. O grande ganho dos métodos não paramétricos é poder incluir informações da vizinhança na classificação, dependendo da compreensão de toda a cena. Assim, os métodos não paramétricos caminham em direção a problemas discretos, que podem ser resolvidos através de reconhecimento de padrões baseados em regras de decisão (CORTIJO; LA BLANCA, 1997). Nesse sentido, a classificação de dados de grande dimensionalidade, como as imagens de alta resolução espacial WorldView-2, requer o uso de

classificadores que utilizem as mais variadas informações das cenas, objetivando elevar a qualidade da imagem classificada, a exemplo dos não paramétricos.

São inúmeros os algoritmos de classificação de imagens existentes, utilizando-se para isso de diferentes abordagens, como pixel a pixel, por regiões ou orientada a objeto, também denominado como classificação baseada em objeto. A classificação pixel a pixel objetiva identificar a classe de cada pixel por meio de comparações do vetor n-dimensional de cada elemento com o padrão de cada classe (CONGALTON; GREEN, 1999). Na década de 1980, significativas inovações foram introduzidas na tarefa de classificar imagens. Nessa época, foi concebida a classificação de imagens baseada em regiões, a qual introduz o conceito de segmento, que é entendido como um agrupamento rotulado de pixels contíguos segundo critérios de semelhança do valor digital e obedecendo a limiares de área específicos (FRANCISCO; ALMEIDA, 2012). Desta forma, a classificação baseada em regiões, ao invés de utilizar pontualmente a informação de cada pixel, considera a delimitação de segmentos com características espectrais homogêneas.

A literatura demonstra que os classificadores pixel a pixel possuem menor eficácia para identificar classes de alvos urbanos em imagens orbitais de alta resolução (MYINT, 2006; CAMPBELL, 2007; ZHOU et al., 2009; MYINT et al., 2011; JOHNSON, 2013; ESTOQUE et al., 2015). No início dos anos 2000, um passo importante para melhorar a qualidade da classificação foi introduzido pelo surgimento da análise de imagem baseada em objetos geográficos (*GEographic Object-Based Image Analysis* – GEOBIA), que conjuga a segmentação a classificadores supervisionados não paramétricos, possuindo sempre um modelo de conhecimento atrelado à interpretação da cena. Essa abordagem baseia-se no paradigma de Orientação a Objeto (OO), em que o objeto é entendido como a instância de uma classe, que representa um conjunto de objetos com características afins (DALL’OGGIO, 2009). A GEOBIA permite expressar o modelo de conhecimento por meio de uma rede

semântica, constituída por uma estrutura hierárquica de classes que associa os diversos objetos (i.e., segmentos) constituintes da imagem (FRANCISCO; ALMEIDA, 2012).

O presente trabalho propõe-se a utilizar recursos de GEOBIA – a segmentação multirresolução - embora restrita a um único nível de segmentação, aliada a métodos de mineração de dados baseados em árvores de decisão, que também se constituem em um modelo de representação do conhecimento, os quais serão abordados na seção seguinte.

2.2.5.1 Mineração de Dados

Atualmente, o mundo está vivenciando uma crescente produção de grandes quantidades de dados, provenientes da evolução tecnológica e do investimento em ferramentas para se obter e gerar cada vez mais dados. O sensoriamento remoto, a todo o momento, contribui com esta infinidade de dados que devem ser devidamente processados para a geração de informação útil à sociedade. Desta maneira, o uso de técnicas de mineração de dados torna-se crucial para a extração de informação e detecção de padrões de mudança no uso e cobertura da terra.

Conforme Fayyad et al. (1996), compreende-se como modelo tradicional de geração de conhecimento o processamento manual dos dados para a produção de relatórios que deverão ser posteriormente analisados. Obviamente, o grande volume de dados torna esse modelo impraticável. Nesse sentido, a fim de superar essa limitação, ganham destaque as técnicas de mineração de dados. Tais técnicas provêm da análise inteligente e automática de dados para descobrir padrões ou regularidades em grandes conjuntos de dados, através de métodos matemáticos e diversos tipos de algoritmos, os quais fazem parte do paradigma da Descoberta de Conhecimento em Bancos de Dados (DCBD ou do inglês *Knowledge Discovery in Databases* - KDD) (ADRIAANS; ZANTINGE, 1996).

KDD é uma tentativa de solucionar o problema da sobrecarga de dados causada pela chamada “era da informação”. Para Fayyad et al. (1996), KDD refere-se a todo o processo de descoberta de conhecimento, e a mineração de dados a uma das atividades deste processo. Nesse sentido, KDD evoluiu e continua a evoluir, a partir da interseção de campos de pesquisa, como aprendizagem de máquina, reconhecimento de padrões, bases de dados estatísticas, inteligência artificial, aquisição de conhecimento para sistemas especialistas, visualização de dados e computação de alto desempenho (CORADINE et al., 2011).

Assim, as técnicas de mineração de dados consistem na extração de conhecimento de uma base com grande volume de dados por meio de métodos inteligentes (WITTEN et al., 2011). O modelo derivado da mineração pode ser representado de várias formas, entre elas, as árvores de decisão, que também são utilizadas na classificação de imagens de sensoriamento remoto (KORTING, 2012; ANJOS, 2016).

2.2.5.2 Árvores de Decisão

Dados descritos em termos de uma coleção de atributos podem pertencer a diferentes classes. Considerando um conjunto de treinamento, a classe de cada dado será conhecida. Conforme Quinlan (1986), é possível desenvolver uma regra de classificação, que pode determinar a classe de qualquer dado a partir dos valores dos seus atributos. Tal regra de classificação pode ser expressa como uma árvore de decisão. Uma árvore de decisão é um grafo orientado, em que os nós folhas contêm as classes, e os nós intermediários representam atributos baseados em testes, com um ramo para cada possível saída. Para classificar um dado, começa-se com o nó raiz da árvore, aplica-se o teste e toma-se o ramo apropriado para aquela saída. O processo continua, e quando um nó folha é encontrado, o dado é classificado segundo a classe indicada naquele nó folha (RUIZ et al., 2009).

Construir uma árvore de decisão que classifique corretamente os dados no conjunto de treinamento sempre é possível, desde que os atributos sejam adequados. Para conseguir classificar corretamente dados fora do conjunto de treinamento, a árvore de decisão deve capturar alguma relação significativa entre a classe do dado e os valores de seus atributos. Quando se têm duas árvores de decisão que classificam corretamente um conjunto de treinamento, deve-se escolher a mais simples, uma vez que ela é mais adequada para capturar a estrutura inerente do problema, e assim, por ser mais generalizável, terá mais chances de classificar corretamente dados fora do conjunto de treinamento (QUINLAN, 1986).

Há diversas maneiras de uma árvore de decisão ser estruturada a partir de um conjunto de atributos. Um dos mais conhecidos é o algoritmo de Indução Descendente de Árvore de Decisão ou *Top-Down Induction of Decision Tree* (TDIDT). Em sua concepção, ele utiliza um processo conhecido como particionamento recursivo, produzindo regras de decisão de forma implícita. Nesse contexto, a árvore de decisão é construída por sucessivas divisões dos exemplos de acordo com os valores de seus atributos preditivos (BASGALUPP, 2010).

As principais vantagens do uso de árvores de decisão na classificação de imagens residem na sua eficiência em termos de tempo de processamento para lidar com grandes conjuntos de dados e fornecimento de um meio intuitivo de analisar os resultados. Por ser simples, a representação simbólica final do classificador facilita a compreensão por parte do intérprete. Diversos trabalhos comprovam o bom desempenho das árvores de decisão em classificações de imagens de alta resolução espacial, como em Leonardi (2010), Novack et al. (2011), Martins (2012), Moustakidis et al. (2012), Pinho et al. (2012), Zhang e Hu (2012), Francisco e Almeida (2013), Souza e Kux (2014), Meneghetti e Kux (2014), Anjos (2016), Brum-Bastos et al. (2016).

2.2.6 Avaliação da Qualidade da Classificação

Toda classificação está sujeita a erros dos mais diversos tipos e fontes, e em sensoriamento remoto isto não é diferente. A avaliação da acurácia dos dados extraídos das imagens está diretamente relacionada à qualidade da classificação realizada. Assim, todas as classes que compõem o mapa temático devem ser associadas a um controle de qualidade, para que possam ser validadas (ANTUNES; LINGNAU, 1997). Este passo é importante por determinar quão bom é o resultado da classificação em relação à realidade (verdade de campo) ou a um dado de referência (NOVO, 2008).

Geralmente, o desempenho da classificação é avaliado através de uma matriz de erros, também conhecida como matriz de confusão. Este recurso indica quais instâncias foram classificadas correta e incorretamente. A matriz de confusão é quadrada e de dimensão igual ao número de classes avaliadas. Os resultados da classificação são colocados nas colunas da matriz, sendo que na diagonal principal encontra-se o número de observações classificadas corretamente. Se todo elemento fora das diagonais é igual a zero tem-se uma classificação 100% correta (WITTEN et al., 2011).


A partir da matriz de confusão, pode-se obter uma série de medidas estatísticas para o processo de validação. Uma delas é o índice *Kappa*, que foi definido por Cohen (1960) como um coeficiente de concordância para escalas nominais, excluindo de sua análise a concordância atribuída à casualidade. Esse índice considera todos os elementos da matriz de confusão, incluindo além da diagonal principal, o somatório do produto entre os subtotais de linhas e colunas.

3 MATERIAL E MÉTODOS

3.1 Área de Estudo

A área de estudo situa-se na cidade de Campinas, interior paulista, com coordenada central de 22° 54' 3" S, 47° 3' 26" W e altitude média de 685 m. A cidade possui superfície de 794,571 km² e sua população estimada para 2015 foi de 1.164.098 habitantes. Atualmente, Campinas constitui-se no maior polo tecnológico da América Latina, contando com a presença de muitas indústrias, centros de pesquisas e universidades, sendo uma delas a Universidade Estadual de Campinas – UNICAMP (IBGE, 2014). Um transecto do campus da UNICAMP foi escolhido para a realização do presente trabalho. A área desse campus atinge aproximadamente 3,5 mil quilômetros quadrados e está repleta de prédios rodeados por parques e gramados (UNICAMP, 2016). A diversidade de alvos urbanos, a fácil acessibilidade aos edifícios e a disponibilidade de dados para este local foram as razões para a sua escolha nesta pesquisa (Figura 3.1).

Figura 3.1 – Localização da área de estudo.



Fonte: Adaptado de Google (2015).

3.2 Dados de Entrada

O presente trabalho foi realizado a partir de duas imagens orbitais dos sensores WorldView-2 e WorldView-3. A imagem proveniente do sensor WV-2 foi adquirida em 02/07/2010, com angulação de 6,75° *off nadir*, 38,4° de elevação solar e 0% de cobertura de nuvens. Por sua vez, a imagem WV-3 foi adquirida em 24/07/2015, com angulação de 6,52° *off nadir*, 40,6° de elevação solar e 0% de cobertura de nuvens.

3.3 Recursos Computacionais


As configurações de hardware e software utilizadas foram as seguintes:

- Processador: Intel® Core™ i3-4005U CPU @ 1.70GHZ.
- Memória RAM: 4,00 GB.
- Sistema Operacional Windows 7 64 bits.

3.4 Fluxograma Metodológico

A Figura 3.2 apresenta a sequência dos passos metodológicos do presente trabalho, os quais serão brevemente descritos a seguir.

Figura 3.2 – Fluxograma das etapas metodológicas do trabalho.



Fonte: Adaptado de Anjos (2016).

3.5 Pré-Processamento

Uma etapa essencial em qualquer estudo é a preparação dos dados de entrada. Essas atividades ocorrem no pré-processamento. Nesta etapa, foram realizados os seguintes procedimentos: conversão dos dados de nível de cinza para radiância, correção atmosférica e conversão dos dados em radiância para reflectância de superfície, fusão de bandas, ortorretificação e correção de registro. Como os dados WV-2, cedidos por Anjos (2016), já estavam pré-processados, foi necessária a realização do pré-processamento somente para os dados WV-3.

Uma vez que os dados WV-3 foram obtidos em valores de níveis de cinza, o primeiro passo do pré-processamento foi a conversão para a grandeza física de radiância. Este procedimento foi realizado utilizando-se a ferramenta

“Calibração Radiométrica” (*Radiometric Calibration*) do ENVI 5.3 (ENVI, 2006). Conforme DigitalGlobe (2016), especificamente para os dados WV-3, a radiância pode ser calculada por meio da Equação 3.1.

$$L_{\lambda pixel, banda} = GAIN * DN \left(\frac{abscalfactor}{effectivebandwidth} \right) + OFFSET, \quad (3.1)$$

onde $L_{\lambda pixel, banda}$ são os valores de radiância espectral no topo da atmosfera dados em $Wm^{-2}sr^{-1}\mu m^{-1}$; DN é o valor do nível de cinza do pixel da imagem; *GAIN* e *OFFSET* são os valores absolutos de calibração radiométrica por banda, divulgados pela DigitalGlobe; *abscalfactor* é o valor de correção radiométrica dos pixels e *effectivebandwidth* é a largura efetiva em μm de dada banda. Os dois últimos itens são disponibilizados no arquivo de metadados que acompanha a imagem.

A seguir, a imagem WV-3 agora com valores em radiância, foi transformada para reflectância de superfície por meio do aplicativo FLAASH (*Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes* ou "Análise Rápida de Linha de Visão Atmosférica de Hipercubos Espectrais") do ENVI 5.3. Para a utilização dessa ferramenta, é necessária a entrada de alguns parâmetros da cena e do sensor, como: funções de respostas dos filtros (presente na versão 5.3 do ENVI para o WV-3), coordenadas centrais da cena, elevação do terreno, altitude do sensor, tamanho do pixel, data e hora da aquisição da imagem, modelo atmosférico e modelo de aerossol.

De posse da imagem WV-3 corrigida atmosféricamente, o algoritmo de fusão Gram-Schmidt (LABEN; BROWER, 2000) foi utilizado com o intuito de melhorar a resolução espacial das bandas multiespectrais (PINHO et al., 2005; PINHO et al., 2012). Este procedimento foi realizado no ENVI 5.3 através da ferramenta *Image Sharpening* (ou Fusão de Imagem). Assim, as bandas multiespectrais, que possuem 1,24 m de resolução espacial, passaram a ter a resolução espacial da banda pancromática, ou seja, 0,31 m. Dessa forma, a razão de

fusão entre as resoluções das bandas multiespectrais e pancromática foi de 4:1. As bandas do SWIR, por possuírem resolução espacial de 3,7 m e por não cobrirem a faixa do espectro eletromagnético correspondente ao intervalo da banda pancromática, não se submeteram ao processo de fusão, tendo sido apenas reamostradas para a resolução da banda pancromática (0,31 m) e utilizadas exclusivamente na etapa de classificação.

O procedimento de ortorretificação da cena WV-3 foi realizado utilizando-se a ferramenta “Dispositivo de Ortorretificação” (*OrthoEngine*) do PCI Geomatics (GEOMATICA, 2014). Para isto, foi utilizado um Modelo Digital de Superfície (MDS) e pontos de DGPS coletados em campo, ambos cedidos por Anjos (2016).

Finalizado o processo de ortorretificação da cena WV-3, foi realizado o processo de corregristo com a imagem WV-2, pré-processada por Anjos (2016). Este procedimento foi realizado no ENVI 5.3 através da ferramenta de registro (*Registration*), com o objetivo foi proporcionar uma melhor correspondência espacial entre as cenas.

3.6 Extração de Atributos dos Dados WV-2 e WV-3

A partir das bandas originais dos dados WV-2 e WV-3, foram extraídos diversos atributos. As transformações PCA e MNF compõem a lista de atributos utilizados neste trabalho. Elas foram geradas no ENVI 5.3. Também nesta plataforma computacional, foram gerados os Atributos Customizados (ACs) por meio da ferramenta aritmética de bandas (*Band Math*). O primeiro deles, Modelo Digital de Altura (MDA), também chamado por alguns autores de Modelo Digital de Superfície Normalizado (MDSn), é resultante da subtração entre MDS e MDT (Modelo Digital de Terreno). A Tabela 3.1 apresenta os ACs, suas equações e respectivas referências bibliográficas.

Tabela 3.1 – Atributos utilizados nas classificações BFTree e LMT.

ATRIBUTO	EQUAÇÕES	REFERÊNCIA
MDA	$MDA = MDS - MDT$	Leonardi (2010)
BRIGHTNESS	$Brightness = \frac{\sum_{i=1}^n banda\ i}{n}$	Definiens (2007)
NDVI 1	$NDVI\ 1 = \frac{Banda_{832nm} - Banda_{660nm}}{Banda_{832nm} + Banda_{660nm}}$	Rouse et al. (1974)
NDVI 2	$NDVI\ 2 = \frac{Banda_{832nm} - Banda_{725nm}}{Banda_{832nm} + Banda_{725nm}}$	Adaptado de Rouse et al. (1974)
NDVI 3	$NDVI\ 3 = \frac{Banda_{950nm} - Banda_{660nm}}{Banda_{950nm} + Banda_{660nm}}$	Adaptado de Rouse et al. (1974)
NDVI 4	$NDVI\ 4 = \frac{Banda_{950nm} - Banda_{725nm}}{Banda_{950nm} + Banda_{725nm}}$	Adaptado de Rouse et al. (1974)
SAVI	$SAVI = \frac{(1 + L)(Banda_{832nm} - Banda_{660nm})}{Banda_{832nm} + Banda_{660nm} + L}$	Huete (1988)
AC 1	$AC\ 1 = \frac{Brightness + Banda_{480nm}}{Banda_{660nm}}$	Leonardi (2010)
AC 2	$AC\ 2 = \frac{Brightness + Banda_{480nm}}{Banda_{725nm}}$	Adaptado de Leonardi (2010)
AC 3	$AC\ 3 = Brightness + Banda_{480nm} - Banda_{660nm}$	Adaptado de Leonardi (2010)
AC 4	$AC\ 4 = Brightness + Banda_{480nm} - Banda_{725nm}$	Adaptado de Leonardi (2010)
AC 5	$AC\ 5 = Brightness - Banda_{832nm}$	Adaptado de Leonardi (2010)
AC 6	$AC\ 6 = Brightness - Banda_{950nm}$	Adaptado de Leonardi (2010)
AC 7	$AC\ 7 = \frac{Banda_{660nm}}{Banda_{832nm}}$	Richardson e Wiegand (1977)
AC 8	$AC\ 8 = \frac{Banda_{725nm}}{Banda_{832nm}}$	Adaptado de Richardson e Wiegand (1977)
AC 9	$AC\ 9 = \frac{Banda_{660nm}}{Banda_{950nm}}$	Adaptado de Richardson e Wiegand (1977)
AC 10	$AC\ 10 = \frac{Banda_{725nm}}{Banda_{950nm}}$	Adaptado de Richardson e Wiegand (1977)
AC 11	$AC\ 11 = \frac{Banda_{545nm}}{Banda_{832nm}}$	Bausch e Duke(1996)

(continua)

Tabela 3.1 – Conclusão.

AC 12	$AC\ 12 = \frac{Banda_{725nm}}{Banda_{832nm}}$	Adaptado de Bausch e Duke(1996)
AC 13	$AC\ 13 = \frac{Banda_{832nm} - Banda_{545nm}}{Banda_{832nm} + Banda_{545nm}}$	Gitelson et al. (1996)
AC 14	$AC\ 14 = \frac{Banda_{950nm} - Banda_{545nm}}{Banda_{950nm} + Banda_{545nm}}$	Adaptado de Gitelson et al. (1996)
AC 15	$AC\ 15 = \frac{Brightness + Banda_{425nm}}{Banda_{660nm}}$	Adaptado de Rouse et al. (1974)
AC 16	$AC\ 16 = \frac{Brightness + Banda_{425nm}}{Banda_{725nm}}$	Adaptado de Leonardi (2010)
AC 17	$AC\ 17 = Brightness + Banda_{480nm} - Banda_{725nm}$	Adaptado de Leonardi (2010)
AC 18	$AC\ 18 = Brightness + Banda_{480nm} - Banda_{832nm}$	Adaptado de Leonardi (2010)
AC 19	$AC\ 19 = \frac{Banda_{545nm} - Banda_{832nm}}{Banda_{545nm} + Banda_{832nm}}$	Jain et al. (2006) e Sarkar et al. (2012)

Fonte: Anjos (2016).

As equações apresentadas na Tabela 3.1 utilizam as seguintes bandas WV-2 e WV-3: B2 - azul (centrada em 480nm), B3 - verde (centrada em 545nm), B4 - amarelo (centrada em 605nm), B5 - vermelho (centrada em 660nm) e B7 - infravermelho próximo (centrada em 832nm). Estes dados apresentam outras bandas multiespectrais: B1 - azul costeiro (centrada em 425nm), B6 - vermelha limítrofe (centrada em 725nm), além de outra banda na região do infravermelho próximo: B8 - infravermelho próximo 2 (centrada em 950nm). Com isso, por meio de combinações lineares, outras equações foram adaptadas, perfazendo um total de 19 atributos customizados. Também foram criados quatro índices de vegetação com base na formulação original do Índice de Vegetação por Diferença Normalizada (NDVI) (porém alternando-se as bandas do vermelho e vermelho limítrofe, bem como do infravermelho próximo 1 e 2) e o Índice de Vegetação Ajustado ao Solo (SAVI). O *Brightness* (Brilho) e o MDA completam

a lista de atributos presentes na Tabela 3.1. Portanto, foram extraídos dos dados WV-2 e WV-3 o total de 26 atributos (ANJOS, 2016).

3.7 Segmentação e Classificação

Primeiramente, é necessária a definição das classes de interesse, sua estruturação em diferentes níveis de legenda e as respectivas chaves de interpretação. Neste sentido, a hierarquia de classes de cobertura do solo urbano foi adaptada do trabalho de Anjos (2016). Como as cenas WV-2 e WV-3 foram obtidas em datas diferentes, com uma diferença de cinco anos, a área de estudo sofreu uma série de modificações. Por isso, o Nível de Legenda 2 é diferenciado no número de classes. Para a imagem WV-2, obtida em 2010, são 38 classes. Por sua vez, para a imagem WV-3, obtida em 2015, são 42 classes de cobertura do solo urbano. A Tabela 3.2 apresenta os níveis de legenda de classificação utilizados neste trabalho.

Cabe destacar o significado de alguns tipos de coberturas presentes na Tabela 3.2. A sigla CRFS, que significa Cimento Reforçado com Fios Sintéticos, corresponde a um tipo de telha de fibrocimento visivelmente semelhante às telhas de fibrocimento com amianto, sem possuir este último componente em sua composição. Os diferentes tipos de galvalume representam coberturas metálicas compostas ou recobertas por camadas de alumínio, zinco e silício. Na cena WV-2, os galvalumes foram divididos em três tipos: A – ondulado com pintura eletrostática branca, B – trapezoidal sem pintura, C – ondulado sem pintura (ANJOS, 2016). Já na cena WV-3, devido à diversidade dos novos formatos, os galvalumes foram padronizados e distribuídos em dois tipos, sendo: A – com pintura eletrostática branca e B – sem pintura.

Embora não se tenham utilizado segmentações multiníveis neste trabalho, a segmentação dos dados WV-2 e WV-3 foi realizada por meio do algoritmo de segmentação multirresolução (*Multiresolution Segmentation*), disponível no software eCognition Developer 8.7 (TRIMBLE, 2011). Após a segmentação, foi executado o algoritmo de ajuste por diferença espectral (*Spectral Difference*),

que é utilizado para refinar os resultados da segmentação através da similaridade espectral entre os segmentos vizinhos (DEFINIENS, 2007).


As segmentações dos dados WV-2 e WV-3 utilizaram parâmetros diferenciados. Para os dados WV-2, foi utilizada a segmentação elaborada por Anjos (2016), que possui 79.464 segmentos. Devido às diferenças de resoluções, somente as bandas multiespectrais do visível e infravermelho próximo foram utilizadas na segmentação da imagem WV-3, resultando em 45.183 segmentos. A Tabela 3.3 apresenta os parâmetros utilizados na segmentação de cada uma das imagens.

Nível 1	Nível 2 – WV-2	Nível 2 – WV-3	Detalhe da Classe
Solo Exposto	Solo Exposto	Solo Exposto	
Piscina	Piscina de Azulejo	Piscina de Azulejo	
	Piscina de Vinil	Piscina de Vinil	

Tabela 3.2 – Níveis de legenda de classificação do solo urbano para os dados WV-2 e WV-3 e detalhes das classes.

(continua)

Tabela 3.2 – Continuação

Lago	Lago	Lago	
Vegetação Rasteira	Vegetação Rasteira	Vegetação Rasteira	
Vegetação Arbórea	Vegetação Arbórea	Vegetação Arbórea	

(continua)

Tabela 3.2 – Continuação

Pavimentação Não Viária	Carvão Coque	Carvão Coque	
	Pedra Mineira	Pedra Mineira	
Pavimentação Viária	Asfalto	Asfalto	


(continua)

Tabela 3.2 – Continuação

Pavimentação Viária	Asfalto Pintado de Branco	Asfalto Pintado de Branco	
	Asfalto Pintado de Vermelho	Asfalto Pintado de Vermelho	
	Bloquete	Bloquete	


(continua)

Tabela 3.2 – Continuação

Pavimentação Viária	-----	Pedregulho	
Materiais Mistos (Pavimentação)	Argamassa de Cimento	-----	
	-----	Arg. de Cimento Pint. Cinza	

(continua)

Tabela 3.2 – Continuação

Materiais Mistos (Pavimentação)	Arg. de Cimento Pint. Vermelho	Arg. de Cimento Pint. Vermelho	
	Arg. de Cimento Pint. Verde	Arg. de Cimento Pint. Verde	
	Concreto Pint. Amarelo	Concreto Pint. Amarelo	

(continua)

Tabela 3.2 – Continuação

Materiais Mistos (Pavimentação)	Concreto Pint. Vermelho	Concreto Pint. Vermelho	
	-----	Concreto Pint. Azul	
	Concreto	Concreto	


(continua)

Tabela 3.2 – Continuação

Materiais Mistos (Pavimentação)	Concreto Impermeabilizado	-----	
Materiais Mistos (Coberturas Diversas)	Vidro Aramado	Vidro Aramado	
	Fibra de Vidro	Fibra de Vidro	

(continua)

Tabela 3.2 – Continuação

Materiais Mistos (Coberturas Diversas)	Pastilha Esmaltada	Pastilha Esmaltada	
	Fibrocimento CRFS	Fibrocimento CRFS	
	Fibrocimento com Amianto	Fibrocimento com Amianto	


(continua)

Tabela 3.2 – Continuação

Materiais Mistos (Coberturas Diversas)	Policarbonato	Policarbonato	
	Acrílico	Acrílico	
	Plástico	Plástico	

(continua)

Tabela 3.2 – Continuação

Materiais Mistos (Coberturas Diversas)	Lona	-----	
	-----	Lona Azul	
	-----	Lona Verde	

(continua)

Tabela 3.2 – Continuação

Materiais Mistos (Coberturas Diversas)	Manta Asfáltica Aluminizada	Manta Asfáltica Aluminizada	
	-----	Compensado de Madeira	
	-----	Seixo de Argila	

(continua)

Tabela 3.2 – Continuação

Coberturas Metálicas	Aço Galvanizado Brilhante	Aço Galvanizado Brilhante	
	Aço Galvanizado com Ferrugem	Aço Galvanizado com Ferrugem	
	Aço Galvanizado Fosco	Aço Galvanizado Fosco	

(continua)

Tabela 3.2 – Continuação

Coberturas Metálicas	-----	Aço Galv. Fosco Manta Poliest.	
	Galvalume A	Galvalume A	
	Galvalume B	Galvalume B	

(continua)

Tabela 3.2 – Continuação

Coberturas Metálicas	Galvalume C	-----	
Coberturas Cerâmicas	Cerâmica Iluminada	Cerâmica Iluminada	
	Cerâmica Escura	Cerâmica Escura	

(continua)

Tabela 3.2 – Conclusão

Sombra	Sombra	Sombra	
--------	--------	--------	---

Fonte: Adaptado de Anjos (2016).

Tabela 3.3 – Parâmetros das segmentações.

Parâmetros	WV-2 ¹	WV-3
Escala	30	30
Forma	0,8	0,6
Compacidade	0,9	0,3
Peso	1 (todas bandas)	1 (bandas multiespectrais) 0 (bandas SWIR)
Diferença Espectral	500	160

¹Anjos (2016).

O passo seguinte é a extração de amostras para a posterior mineração dos dados e construção das árvores de decisão. Amostras significativas de cada classe foram extraídas no eCognition para possibilitar a caracterização de seus atributos. Foram utilizadas 602 amostras de treinamento para classificar a imagem WV-2, o que significa, no Nível de Legenda 1, uma média de 54,72 amostras por classe e 15,8 amostras por classe no Nível de Legenda 2. Já para classificar a imagem WV-3 foram utilizadas 513 amostras de treinamento, sendo no Nível de Legenda 1 a média de 46,63 amostras por classe e 12,2 amostras por classe no Nível de Legenda 2.


A Figura 3.3 apresenta a interface do eCognition 8.7 para a coleta de amostras das classes.

Após a fase de coleta de amostras, inicia-se a exportação em formato CSV dos atributos para cada uma das amostras selecionadas relativas às classes de interesse do respectivo nível de legenda. Além dos atributos elencados na Seção 3.5, a média e o desvio padrão de todas as bandas que compõem as imagens também foram exportados

Assim, as amostras foram importadas no formato CSV para o software WEKA (*Waikato Environment for Knowledge Analysis* ou Ambiente Waikato para Análise do Conhecimento), versão 3.7.12 (UNIVERSITY OF WAIKATO, 2010). As amostras das classes com os atributos foram utilizadas como conjunto de treinamento para a indução das árvores de decisão e a classificação dos

dados. O processo de mineração de dados desse software consiste na aplicação de algum algoritmo de Aprendizado de Máquina (*Machine Learning*) para a regressão, classificação, agrupamento ou seleção de atributos dos dados, dentre outros (HALL et al., 2009).


Figura 3.3 – Interface do eCognition 8.7 mostrando a coleta de amostras.



Os dados de entrada do WEKA são as amostras com os atributos de cada classe previamente selecionados no eCognition. A partir destes dados, que no WEKA são chamados de conjunto de treinamento, são induzidas as árvores de decisão. O procedimento de classificação de toda a cena foi realizado no próprio WEKA, por meio da ferramenta *Supplied test set* (ou conjunto de dados

de teste), em que se utiliza como dados de teste a cena toda. Essa ferramenta faz a classificação de um conjunto de dados a partir da árvore de decisão gerada. No caso, esse conjunto de dados constitui todos os segmentos com seus atributos rotulados como *unclassified* (sem classificação). A saída desse procedimento é a classificação de cada segmento, conforme as classes presentes na árvore de decisão que serviu de modelo para a classificação. A Figura 3.4 apresenta a saída da ferramenta *Supplied test set* do WEKA.

Figura 3.4 – Saída da classificação no WEKA (ferramenta Supplied test set)..



Na saída de dados presente na Figura 3.4, é possível visualizar a classe atual (*unclassified*) e aquela que foi classificada para cada um dos segmentos da imagem. A partir dessa saída, é possível visualizar o mapa de classificação em qualquer *software* de SIG (Sistema de Informações Geográficas). Neste trabalho, para este procedimento, foi utilizado o *software* QGIS 2.14.2 (QGIS, 2009).

As seções seguintes abordarão o processo de indução de árvore de decisão, bem como cada um dos algoritmos de árvore de decisão utilizados.

3.8 Indução de Árvores de Decisão

Dentre os diversos algoritmos descendentes de indução de árvore de decisão (*Top-Down Induction of Decision Tree* – TDIDT), neste trabalho foram adotados o *Best First Tree* – BFTree ou "Primeira Melhor Árvore" (SHI, 2007) e o *Logistic Model Tree* – LMT ou "Árvore de Modelo Logístico" (LANDWEHR et al., 2005).

O TDIDT, conforme exposto anteriormente, é um algoritmo recursivo de busca "gulosa" que procura, sobre um conjunto de atributos, aqueles que melhor dividem o conjunto de exemplos em subconjuntos, sendo sempre a melhor alternativa possível na iteração corrente. O critério de seleção define qual atributo preditivo será utilizado em cada nó teste. Este critério pode ser baseado na medida de impureza, a qual está relacionada ao número de exemplos para cada classe possível. A maior parte dos algoritmos de indução busca dividir os dados de um nó de forma a minimizar o grau de impureza dos nós filhos (BASGALUPP, 2010).

Uma das medidas baseadas em impureza é o ganho de informação, o qual usa entropia como medida de impureza. Em um conjunto de dados, a entropia é uma medida da falta de homogeneidade dos dados de entrada em relação à sua classificação (QUINLAN, 1986). O grau de entropia é definido pela

$$entropia(t) = - \sum_{i=1}^k p(i|t) \log_2 p(i|t), \quad (3.2)$$

Equação 3.2.

em que $p(i|t)$ é a fração dos exemplos pertencentes à classe i , no nó t , e k é o número de classes.

Para calcular o ganho de informação é necessário comparar o grau de entropia do nó pai, isto é, antes da divisão, com o grau de entropia dos nós filhos, ou seja, depois da divisão. O atributo que gerar uma maior diferença é escolhido como condição de teste na árvore. O ganho de informação é dado pela

$$ganho = entropia(pai) - \sum_{j=1}^n \frac{N(v_j)}{N} entropia(v_j), \quad (3.3)$$

Equação 3.3.

em que n é o número de valores do atributo, ou seja, o número de nós filhos, N é o número total de exemplos do nó pai e $N(v_j)$ é o número total de exemplos associados ao nó filho v_j .

Uma outra medida conhecida é o índice de Gini, desenvolvido por Conrado Gini em 1912 (GINI, 1912 apud BASGALUPP, 2010). Como este índice mede o grau de heterogeneidade dos dados, ele pode ser utilizado para medir a impureza de um nó de uma árvore de decisão (BASGALUPP, 2010). Para um problema de k classes, o $gini_{index}$ é definido pela Equação 3.4.

$$gini_{index}(t) = - \sum_{i=1}^k p(i|t)^2, \quad (3.4)$$

Assim, como no cálculo do ganho de informação, basta calcular a diferença entre o $gini_{index}$ antes e após a divisão. Esta diferença, $gini$, é representada pela Equação 3.5. Assim, é selecionado o atributo que gerar maior valor de $gini$.

$$Gini = gini_{index}(pai) - \sum_{j=1}^n \frac{N(v_j)}{N} gini_{index}(t), \quad (3.5)$$

Outro recurso utilizado na indução de árvores de decisão é o processo de poda. Ele pode ser realizado de duas formas. Uma delas é utilizada para parar o crescimento da árvore mais cedo, chamada de pré-poda ou poda descendente, ou seja, a poda é realizada enquanto a árvore é construída. Outra forma é realizar a chamada pós-poda ou poda ascendente, que acontece com a árvore já completa (QUINLAN, 1986).

O processo de poda pode ser feito da seguinte maneira: (1) inicialmente percorre-se a árvore em profundidade; (2) para cada nó de decisão calcula-se: (i) erro do nó, (ii) soma dos erros dos nós descendentes; (3) se o erro do nó é menor ou igual à soma dos erros dos nós descendentes então o nó é transformado em folha. A pré-poda é mais rápida, porém menos eficiente que a pós-poda pelo fato de haver o risco de se interromper o crescimento da árvore ao selecionar uma árvore subótima (BREIMAN et al., 1984).

A plataforma WEKA 3.7.12 possui diversos algoritmos de indução de árvores de decisão implementados na linguagem Java. As próximas seções detalham cada um dos algoritmos utilizados neste trabalho, os quais se encontram disponíveis nesta plataforma.

3.9 Algoritmo BFTREE

O algoritmo de indução de árvores de decisão BFTree, proposto por Shi (2007), baseia-se na heurística *best first*, a qual utiliza o conhecimento sobre o domínio do problema para encontrar soluções mais eficientes do que no caso de busca cega (WITTEN et al., 2011). O BFTree segue a abordagem TDIDT. Em cada nó interno da árvore é utilizado apenas um atributo como teste. Tanto para atributos numéricos como para categóricos a divisão é binária. Os atributos numéricos são divididos por meio de limiares, enquanto o tratamento dos

atributos categóricos é dependente do número de classes, isto é, em problemas de duas classes, os nós são representados por agrupamento em dois conjuntos, e em problemas de múltiplas classes, é utilizado um método heurístico de busca, que atinge um compromisso entre a redução da impureza e a velocidade de busca. (SHI, 2007; BASGALUPP, 2010).

Conforme Shi (2007), dado um conjunto de treinamento, o procedimento do BFTree é definido nos seguintes passos:

- Inicia-se no nó raiz e encontra-se o melhor atributo divisor dentro do conjunto de treinamento de acordo com o grau de impureza, baseado em entropia.
- Alcançado o melhor atributo, sua instância é salva no primeiro nó.
- Se a divisão do primeiro nó conduzir para um nó sucessor com mais instâncias ele é dividido em dois nós sucessores (ramos). Os melhores atributos divisores e suas instâncias de treinamento são separados em dois subconjuntos, um para cada ramo. Os atributos com melhor grau de impureza comporão os novos nós sucessores da árvore.
- O processo de construção é finalizado quando o grau de impureza dos nós adicionados é 0 (zero), ou então, quando o número fixo de expansões é alcançado.
- O algoritmo pode utilizar pré ou pós-poda. Ambos utilizam a validação cruzada para interromper ou descartar expansões da árvore.

Com isso, conclui-se que uma das principais vantagens do BFTree reside em sua capacidade de expandir os nós da árvore seguindo a heurística *best first*, ou seja, são analisadas todas as possibilidades e a melhor delas é utilizada. Essa é uma característica que o diferencia dos demais algoritmos de indução de árvores de decisão, os quais prezam por uma ordem fixa na expansão dos nós da árvore (SHI, 2007).

3.10 Algoritmo LMT

O algoritmo LMT apresentado por Landwehr et al. (2005) combina regressão logística e aprendizagem de árvore de decisão. A regressão logística é entendida como uma técnica estatística que objetiva produzir um modelo de predição de valores. A partir de um conjunto de observações, o modelo utiliza uma variável categórica, frequentemente binária, para representar uma série de variáveis contínuas e/ou binárias. Os modelos de regressão logística permitem selecionar os atributos relevantes de forma natural. Em comparação com as técnicas mais conhecidas de regressão, sobretudo a linear, a regressão logística distingue-se pelo fato de a variável resposta ser categórica (LANDWEHR et al., 2005; WITTEN et al., 2011).

Nesse contexto, a característica marcante da árvore de decisão gerada pelo algoritmo LMT é a sua estrutura com funções de regressão logística nas folhas. Possui em seus nós terminais, ao invés de classes únicas, vetores de variáveis (x_i) e de coeficientes (β_j) de todas as classes. Através desses valores é possível calcular a função LMT, definida nas Equações 3.6 e 3.7.

$$F(x) = x_i' \beta_j, \quad j = 1, \dots, J, \quad (3.6)$$

em que:

$$x_i' \beta_j = \sum_{k=0}^K \beta_{jk} x_{ik}, \quad (3.7)$$


com $x_{i0} = 1$ e x_i e β_j correspondendo a vetores (coluna) de dimensão $(K+1)$, similar ao modelo logístico em estágio único. As probabilidades das classes são calculadas através da Equação 3.8.

$$P_j = \frac{\exp F_j(x)}{\exp F_1(x) + \dots + \exp F_J(x)}, \quad j = 1, \dots, J - 1 \quad (3.8)$$

As probabilidades resultantes são para cada nó terminal, ou seja, serão válidas somente para aqueles dados que respeitarem a regra de decisão da árvore até o nó em questão.

A Figura 3.5 apresenta a estrutura de duas árvores de decisão. Em A, verifica-se a estrutura típica de uma árvore de decisão induzida pelo algoritmo BFTree. Por sua vez, a estrutura típica de uma árvore de decisão induzida pelo algoritmo LMT é verificada em B. Pela comparação, é possível observar que a única diferença da árvore LMT está nas folhas, pois, elas não correspondem exclusivamente à determinada classe, mas às suas estimativas de probabilidades.

Figura 3.5 – Estrutura típica de uma árvore de decisão BFTree (A) e LMT (B).



Fonte: Coelho (2010).

3.11 Avaliação dos Resultados

Neste trabalho, foram obtidas oito classificações da cobertura do solo urbano. Para cada um dos conjuntos de dados (WV-2 e WV-3), foram obtidas quatro classificações utilizando os algoritmos BFTree e LMT nos dois níveis de detalhamento.

A validação dos resultados foi realizada por meio da utilização de mapas de verdade de campo. Como existe uma diferença temporal na aquisição das imagens, WV-2 adquirida em 2010 e WV-3 em 2015, e conseqüentemente ocorreram mudanças na cobertura do solo, foi necessária a utilização de mapas de verdade de campo distintos para cada conjunto de dados. O mapa de verdade de campo para os dados WV-2 foi elaborado por Anjos (2016). Já para os dados WV-3, foi realizada visita ao Campus da Unicamp em 06/12/2016, para se adquirir informações sobre as mudanças de cobertura do solo, e assim, elaborar o correspondente mapa de verdade de campo relativo à imagem WV-3. Como as classes do Nível de Legenda 2 são subclasses do Nível de Legenda 1, primeiramente foi criado o mapa para o Nível 2, tendo este sido reconstituído de forma agregada, a fim de se gerar o mapa de verdade de campo do Nível 1.

As imagens WV-2 e WV-3 em duas composições coloridas são apresentadas, respectivamente, nas Figuras 3.6 e 3.7, a fim de possibilitar comparações com seus respectivos mapas de verdade de campo, que são apresentados nas Figuras 3.8 e 3.9.

Figura 3.6 – Imagem WV-2 da área de estudo em composição colorida verdadeira (à esquerda) e falsa-cor (à direita).




Figura 3.7 – Imagem WV-3 da área de estudo em composição colorida verdadeira (à esquerda) e falsa-cor (à direita).






Figura 3.8 – Mapas de verdade de campo referentes aos dados WV-2 para ambos os níveis de legenda.



Fonte: Anjos (2016).

Figura 3.9 – Mapas de verdade de campo referentes aos dados WV-3 para ambos os níveis de legenda.



A fim de promover a validação dos resultados das classificações, foram gerados oito conjuntos de coordenadas aleatórias dentro dos limites da imagem utilizando o *software Minitab 17 Statistical Software*. Estes conjuntos são individuais para cada uma das classificações. O Nível de Legenda 2 requereu um maior número de coordenadas aleatórias devido a quantidade de classes que elas possuem. O total de coordenadas aleatórias utilizadas na validação dos resultados foram:

- Para o algoritmo BFTree no Nível de Legenda 1 referente aos dados WV-2: 1538 coordenadas aleatórias.
- Para o algoritmo LMT no Nível de Legenda 1 referente aos dados WV-2: 1380 coordenadas aleatórias.
- Para o algoritmo BFTree no Nível de Legenda 1 referente aos dados WV-3: 1578 coordenadas aleatórias.
- Para o algoritmo LMT no Nível de Legenda 1 referente aos dados WV-3: 1957 coordenadas aleatórias.
- Para o algoritmo BFTree no Nível de Legenda 2 referente aos dados WV-2: 3102 coordenadas aleatórias.
- Para o algoritmo LMT no Nível de Legenda 2 referente aos dados WV-2: 3180 coordenadas aleatórias.
- Para o algoritmo BFTree no Nível de Legenda 2 referente aos dados WV-3: 3032 coordenadas aleatórias.
- Para o algoritmo LMT no Nível de Legenda 2 referente aos dados WV-3: 3195 coordenadas aleatórias.

Na sequência, cada conjunto de coordenadas foi importado para o *software QGIS 2.14.2*, no qual foi realizado o cruzamento espacial entre as classes do

mapa de verdade de campo e aquelas atribuídas aos pontos aleatórios oriundas da classificação. O resultado é uma tabela de atributos associando cada ponto aleatório à classe correspondente no mapa de verdade e na classificação. Assim, foram produzidas as matrizes de confusão para o cálculo da exatidão global, índice *Kappa*, índice *Kappa* condicional, bem como as acurácias do produtor e usuário para cada classe.

A matriz de confusão evidencia os erros de omissão e comissão. O primeiro deles, o de omissão, corresponde às amostras que não foram classificadas de acordo com a classe de referência. Já os erros de comissão são relacionados às amostras de referência classificadas erroneamente como pertencentes a outras classes. Diversos índices são calculados a partir da matriz de confusão, dentre eles: (a) exatidão global - relação entre as amostras classificadas corretamente e o total de amostras de referência; (b) acurácia do produtor - relativa aos erros de omissão, a qual representa a relação entre o número de amostras classificadas corretamente da classe *k* e o número total de amostras de referência da classe *k*; (c) acurácia do usuário - referente aos erros de comissão, a qual corresponde à relação entre o número de amostras classificadas corretamente da classe *k* e o número total de amostras classificadas da classe *k*; (d) índice *Kappa* (*K*) (Equação 3.9); além do (e) índice *Kappa* condicional do usuário (*K_u*), que avalia os erros de comissão (Equação 3.10) e (f) índice *Kappa* condicional do produtor (*K_p*), que avalia os erros de omissão, sendo estes dois últimos índices calculados em relação a cada classe (Equação 3.11) (CONGALTON; GREEN, 1999).

$$k = \frac{n \sum_{i=1}^k n_{ii} - \sum_{i=1}^k (n_{i+} n_{+i})}{n^2 - \sum_{i=1}^k (n_{i+} n_{+i})}, \quad (3.9)$$

$$k_u = \frac{n * n_{ii} - n_{i+} * n_{+i}}{n * n_{ii} - n_{i+} * n_{+i}}, \quad (3.10)$$

$$k_p = \frac{n * n_{ii} - n_{ii} * n_{+i}}{n * n_{i+} - n_{i+} * n_{i+}}, \quad (3.11)$$

em que n_{ii} é o número total de amostras corretamente classificadas da classe k ; n_{i+} é o número total de amostras classificadas da classe k ; n_{+i} é o número total de amostras coletadas da classe k , sendo n o número total de amostras.

A fim de categorizar o índice *Kappa*, Landis e Koch (1977) apresentam uma tabela com essa finalidade (Tabela 3.4). Os autores advertem, no entanto, que as divisões são arbitrárias, porém úteis como padrões de referência para a discussão dos resultados.

Tabela 3.4 – Categorização do Índice *Kappa*.

Valores	Categorização
<0	Péssima
0 – 0,2	Ruim
0,21 – 0,4	Razoável
0,41 – 0,6	Bom
0,61 – 0,8	Muito Bom
0,81 – 1,0	Excelente

Fonte: Landis e Koch (1977)

Para finalizar a avaliação da acurácia das classificações, os resultados foram comparados par a par por meio de teste de significância estatística. Tal procedimento é realizado para verificar a diferença entre os índices *Kappa*. Para isto, foi utilizado o teste Z, de acordo com a Equação 3.12 (CONGALTON;GREEN, 2009):

$$Z = \frac{K_2 - K_1}{\sqrt{\sigma_{k_2}^2 + \sigma_{k_1}^2}}, \quad (3.12)$$

em que K_1 é o índice *Kappa* da classificação 1; K_2 é o índice *Kappa* da classificação 2 e σ^2 é a variância do índice *Kappa*.

A comparação de desempenho dos classificadores será realizada através de testes de hipótese pareados em relação aos índices *Kappa* obtidos pelas classificações, considerando as hipóteses nula (H_0) e alternativa (H_1), conforme

$$H_0 : K_1 - K_2 = 0 , \text{ contra } H_1 : K_1 - K_2 \neq 0 , \quad (3.13)$$

Equação 3.13:

em que K_1 é o índice *Kappa* da classificação 1; K_2 é o índice *Kappa* da classificação 2. Para este teste calcula-se a estatística z bilateral para verificar se o valor encontra-se no intervalo de aceitação ou rejeição da hipótese nula.

4 RESULTADOS E DISCUSSÕES

Neste capítulo, serão apresentados, avaliados e comparados os resultados referentes às classificações da cobertura do solo nos dois níveis de detalhamento a partir das imagens dos satélites WorldView-2 e WorldView-3. As árvores de decisão geradas pelos algoritmos são apresentadas nos Apêndices A e B, respectivamente para os dados WV-2 e WV-3. As Figuras e Tabelas presentes nesta seção apresentam diversos tipos de classes denominadas Cimento, mas estas representam as argamassas de cimento, que por questões estéticas foram designadas apenas como Cimento.

4.1 Nível de Legenda 1

A seguir serão apresentados os resultados das classificações obtidas com os algoritmos BFTree e LMT para as imagens WorldView-2 e WorldView-3 no Nível de Legenda 1.

4.1.1 Imagem do Satélite WorldView-2

Dos dados WV-2 foram extraídos 76 atributos que foram utilizados nas classificações. Os grupo de atributos mais utilizado pelo algoritmo BFTree foram os NDVIs e Atributos Customizados, tendo como mais frequentes os atributos NDVI_2 e NDVI_3, utilizados por 3 vezes. A Figura 4.1 apresenta a frequência de utilização dos grupos de atributos. Por sua vez, o algoritmo LMT utilizou poucos atributos na indução da árvore contendo seis modelos logísticos. Para a definição das classes, os modelos logísticos utilizaram um número variado de atributos, tendo destaque o grupo dos desvios padrões das bandas 1 a 8, das bandas dos PCAs, dos MNFs e os atributos customizados, como evidenciado na Figura 4.2. O atributo mais frequente nos modelos logísticos foi o MDA, utilizado por 66 vezes.

Figura 4.1 – Frequência dos atributos utilizados pelo algoritmo BFTree no Nível de Legenda 1 para os dados WV-2.





Figura 4.2 – Frequência dos atributos utilizados pelo algoritmo LMT no Nível de Legenda 1 para os dados WV-2.



As Figuras 4.3 e 4.4 apresentam os resultados das classificações BFTree e LMT respectivamente, ambas para os dados WV-2 no Nível de Legenda 1.

Figura 4.3 – Classificação da imagem WV-2 com o algoritmo BFTree referente ao Nível de Legenda 1.





Figura 4.4 – Classificação da imagem WV-2 com o algoritmo LMT referente ao Nível de Legenda 1.



A classificação dos dados WV-2 no Nível de Legenda 1 utilizando o algoritmo BFTree apresentou 75% de exatidão global. Já classificação dos dados WV-2 no Nível de Legenda 1 utilizando o classificador LMT apresentou 79% de exatidão global.

As matrizes de confusão de todas as classificações serão apresentadas no Apêndice C, juntamente com os valores de acurácia do produtor e usuário para cada classe.

Para facilitar a interpretação dos resultados foi gerada a partir das matrizes de confusão tabelas que apresentam o percentual de acertos e/ou confusões entre classes. Assim, as tabelas 4.1 e 4.2 apresentam tais interpretações para as classificações dos dados WV-2 obtidas, respectivamente, pelos algoritmos BFTree e LMT.

Para todas as análises do Nível de Legenda 1, entenda-se por C1 a classe Cerâmica, C2 a classe Materiais Mistos e Coberturas Diversas, C3 a classe Coberturas Metálicas, C4 a classe Lago, C5 a classe Vegetação Arbórea, C6 a classe Vegetação Herbácea, C7 a classe Pavimentação Não-Viária, C8 a classe Pavimentação Viária, C9 a classe Piscina, C10 a classe Solo Exposto e C11 a classe Sombra.

Tabela 4.1 – Análise percentual dos acertos e confusões da classificação dos dados WV-2 com o algoritmo BFTree para o Nível de Legenda 1.

Classificação	C1	50,0					4,1		13,0	0,4	0,6	1,0
	C2		80,3					33,3		6,5		
	C3		15,3	88,3			17,6	33,3	8,7	6,9	1,4	6,1
	C4				100,0		2,0		13,0	4,0	2,9	4,2
	C5			0,6		100,0	0,7		4,3	1,1		
	C6		2,9	6,4			74,3			1,5	0,6	0,6
	C7							33,3				
	C8								52,2			0,3
	C9			1,2						73,1	22,5	1,6
	C10			1,2						6,2	54,5	2,3
	C11			0,6			1,4		8,7	0,4	17,6	83,9
		C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11
		Referência										

Tabela 4.2 – Análise percentual dos acertos e confusões da classificação dos dados WV-2 com o algoritmo LMT para o Nível de Legenda 1.

Classificação	C1	16,7				16,7	2,2		25,0	0,8	0,3	0,7
	C2		77,7				0,7			1,2		
	C3		16,5	86,9			17,0		5,0	8,8	0,3	2,9
	C4			0,7	100,0					0,4		0,4
	C5					83,3	3,7		5,0	1,6	0,3	
	C6		4,1	4,8			71,9			3,2	0,3	1,8
	C7							100,0				
	C8			0,7			2,2		65,0		0,3	3,6
	C9			1,4						74,5	6,5	4,0
	C10		0,8	2,1						9,2	79,5	8,0
	C11			0,7			2,2			0,4	12,4	78,5
		C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11
		Referência										

4.1.2 Imagem do Satélite WorldView-3

Por possuir uma melhor resolução espectral (16 bandas) estes dados geraram mais atributos (124 no total) em comparação ao WV-2, para o qual foram gerados 76 atributos.

Na construção da árvore de decisão, o algoritmo BFTree utilizou por mais vezes o grupo dos atributos baseados em índices de vegetação, tendo destaque o SAVI, utilizado por 7 vezes (Figura 4.5). O algoritmo LMT gerou um modelo logístico que utilizou diversos atributos para a determinação das classes. O grupo de atributos customizados, Componentes Principais (PCA) e Fração Mínima de Ruído (MNF) foram os mais frequentes (Figura 4.6). Os atributos mais utilizados foram: AC_1, banda 3 do MNF e banda 1 do PCA, utilizados por 7 vezes cada.

Figura 4.5 – Frequência dos atributos utilizados pelo algoritmo BFTree no Nível de Legenda 1 para os dados WV-3.





Figura 4.6 – Frequência dos atributos utilizados pelo algoritmo LMT no Nível de Legenda 1 para os dados WV-3.



As Figuras 4.7 e 4.8 apresentam os resultados das classificações BFTree e LMT respectivamente, ambas para os dados WV-3 no Nível de Legenda 1.

Figura 4.7 – Classificação da imagem WV-3 com o algoritmo BFTree referente ao Nível de Legenda 1.





Figura 4.8 – Classificação da imagem WV-3 com o algoritmo LMT referente ao Nível de Legenda 1.



A classificação dos dados WV-3 no Nível de Legenda 1 utilizando o algoritmo BFTree apresentou 76% de exatidão global. Já utilizando o algoritmo LMT apresentou 82% de exatidão global.

Para avaliar a porcentagem de acertos e/ou confusões entre classes em cada uma das classificações WV-3 do Nível de Legenda 1, são apresentadas as Tabelas 4.3 e 4.4, respectivamente, para os algoritmos BFTree e LMT.

Tabela 4.3 – Análise percentual dos acertos e confusões da classificação dos dados WV-3 com o algoritmo BFTree para o Nível de Legenda 1.

Classificação	C1	75,0		0,7		12,5			5,9		0,6	3,3
	C2		83,1							0,3		
	C3		13,6	85,1		12,5	8,7			16,4	3,1	5,8
	C4				100,0		2,2			0,9		
	C5			0,7		62,5	0,7			0,9	0,2	
	C6		0,8	8,5		12,5	84,8		29,4	3,8	1,0	14,6
	C7							100,0				
	C8						0,7		41,2			0,8
	C9			4,3						71,3	5,2	
	C10						2,2			5,0	75,5	6,3
	C11						0,7		23,5	1,5	14,3	69,2
		C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11
		Referência										

Tabela 4.4 – Análise percentual dos acertos e confusões da classificação dos dados WV-3 com o algoritmo LMT para o Nível de Legenda 1.

Classificação	C1	100,0		0,5						1,5	0,2	0,4
	C2		92,2							0,8	0,5	
	C3		6,0	94,1			9,8		5,0	10,1	1,9	9,3
	C4				100,0					1,3		
	C5					100,0	4,0			0,5		
	C6		0,6	2,7			81,6		15,0	2,5	0,7	1,8
	C7						0,6	66,7		0,3	0,4	
	C8		0,6					33,3	50,0	1,0	0,4	
	C9			1,1			1,1			71,4	2,3	
	C10		0,6	1,6			2,9			8,3	84,9	16,7
	C11								30,0	2,5	8,8	71,9
		C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11
		Referência										

4.2 Nível de Legenda 2

Os dados WV-2 e WV-3 também foram submetidos à classificação no Nível de Legenda 2, igualmente utilizando os algoritmos de árvore de decisão BFTree e LMT. Como as imagens foram obtidas em datas diferentes e novos alvos foram detectados em campo, as classificações possuem um número diferente de classes de cobertura do solo, sendo 38 para o WV-2 e 42 para o WV-3.

A seguir, serão apresentados os resultados das classificações para cada um dos dados.

4.2.1 Imagem do Satélite WorldView-2

Na construção da árvore de decisão, o algoritmo BFTree utilizou mais frequentemente os grupos de atributos baseados em índices de vegetação (Figura 4.9). Os atributos mais frequentes foram o SAVI (10 vezes) e NDVI_3 (6 vezes). Por sua vez, o algoritmo LMT gerou um modelo logístico que utilizou diversos atributos para a determinação das classes, em sua maioria sendo os grupos daqueles baseados na média e desvio padrão da Fração Mínima de Ruído e os atributos customizados (Figura 4.10). O atributo mais frequente foi o MDA (26 vezes).

As Figuras 4.11 e 4.12 apresentam os resultados das classificações BFTree e LMT respectivamente, ambas para os dados WV-2 no Nível de Legenda 2.

A classificação dos dados WV-2 no Nível de Legenda 2 utilizando o algoritmo BFTree apresentou 72,44% de exatidão global. Por sua vez a classificação dos dados WV-2 no Nível de Legenda 2 utilizando o algoritmo LMT apresentou 74,37 % de exatidão global. Para facilitar a interpretação dos resultados obtidos, as Tabelas 4.5 e 4.6 apresentam o percentual de acertos e/ou confusões entre classes, para as classificações do dado WV-2 para o Nível de Legenda 2 com os respectivos classificadores BFTree e LMT.

Figura 4.9 – Frequência dos atributos utilizados pelo algoritmo BFTree no Nível de Legenda 2 para os dados WV-2.




Figura 4.10 – Frequência dos atributos utilizados pelo algoritmo LMT no Nível de Legenda 2 para os dados WV-2.




Figura 4.11 – Classificação da imagem WV-2 com o algoritmo BFTree referente ao Nível de Legenda 2.





Figura 4.12 – Classificação da imagem WV-2 com o algoritmo LMT referente ao Nível de Legenda 2.



Para a análise dos dados WV-2, entenda-se por C1 a classe Aço Galvanizado Fosco, C2 a classe Aço Galvanizado com Ferrugem, C3 a classe Aço Galvanizado Fosco, C4 a classe Acrílico, C5 a classe Amianto, C6 a classe Asfalto, C7 a classe Asfalto Pintado de Branco, C8 a classe Asfalto Pintado de Vermelho, C9 a classe Bloquete, C10 a classe Carvão Coque, C11 a classe Cerâmica Escura, C12 a classe Cerâmica Iluminada, C13 a classe Argamassa de Cimento, C14 a classe Argamassa de Cimento Pintado de Verde, C15 a classe Argamassa de Cimento Pintado de Vermelho, C16 a classe Concreto, C17 a classe Concreto Impermeabilizado, C18 a classe Concreto Pintado de Amarelo, C19 a classe Concreto Pintado de Vermelho, C20 a classe CRFS, C21 a classe Fibra de Vidro, C22 a classe Galvalume A, C23 a classe Galvalume B, C24 a classe Galvalume C, C25 a classe Lago, C26 a classe Lona, C27 a classe Manta Asfáltica Aluminizada, C28 a classe Pastilha Esmaltada, C29 a Pedra Mineira, C30 a classe Piscina de Azulejo, C31 a classe Piscina de Vinil, C32 a classe Plástico, C33 a classe Policarbonato, C34 a classe Solo Exposto, C35 a classe Sombra, C36 a classe Vegetação Arbórea, C37 a classe Vegetação Herbácea e C38 a Vidro Aramado.

Tabela 4.5 – Análise percentual dos acertos e confusões da classificação dos dados WV-2 com o algoritmo BFTree para o Nível de Legenda 2.

[illegible]

Tabela 4.6 – Análise percentual dos acertos e confusões da classificação dos dados WV-2 com o algoritmo LMT para o Nível de Legenda 2.

[illegible]

4.2.2 Imagem do Satélite WorldView-3

Os dados WV-3 foram igualmente classificados no Nível de Legenda 2 por meio dos algoritmos BFTree e LMT. Conforme mencionado anteriormente na Seção 4.1.2, os dados WV-3 possuem uma melhor resolução espectral, constituindo-se em 16 bandas espectrais. Devido a essa característica, os algoritmos dispuseram de mais atributos para a geração das árvores de decisão, correspondendo exatamente a 124 atributos. Além da maior quantidade de atributos, o dado WV-3 foi classificado em 42 classes de cobertura do solo. Foram adicionadas quatro classes em relação às utilizadas nos dados WV-2.

O algoritmo BFTree, utilizou em sua concepção mais frequentemente o atributo SAVI foi utilizado por 22 vezes (Figura 4.13). Já o algoritmo LMT fez uso mais frequentemente do grupo de atributos das Componentes Principais e Fração Mínima de Ruído, além dos atributos customizados (Figura 4.14). A maior frequência verificada coube à banda 1 do PCA (18 vezes).

Figura 4.13 – Frequência dos atributos utilizados pelo algoritmo BFTree no Nível de Legenda 2 para os dados WV-3.





Figura 4.14 – Frequência dos atributos utilizados pelo algoritmo LMT no Nível de Legenda 2 para os dados WV-3.



As Figuras 4.15 e 4.16 apresentam os resultados das classificações C4.5 e RF respectivamente, ambas para os dados SpectTIR no Nível de Legenda 2.

A classificação dos dados WV-3 no Nível de Legenda 2 utilizando o algoritmo BFTree apresentou 64,41% de exatidão global. Já a classificação dos dados WV-3 no Nível de Legenda 2 utilizando o algoritmo LMT apresentou 78% de exatidão global.

As Tabelas 4.8 e 4.9 apresentam o percentual de acertos e/ou confusões entre classes, referente às classificações de dados WV-3 para o Nível de Legenda 2.

Figura 4.15 – Classificação da imagem WV-3 com o algoritmo BFTree referente ao Nível de Legenda 2.





Figura 4.16 – Classificação da imagem WV-3 com o algoritmo LMT referente ao Nível de Legenda 2.



Para a análise dos dados WV-3, entenda-se por C1 a classe Aço Galvanizado Fosco, C2 a classe Aço Galvanizado com Ferrugem, C3 a classe Aço Galvanizado Fosco, C4 a classe Aço Galvanizado Fosco recoberto com Manta de Poliéster, C5 a classe Acrílico, C6 a classe Amianto, C7 a classe Asfalto, C8 a classe Asfalto Pintado de Branco, C9 a classe Asfalto Pintado de Vermelho, C10 a classe Bloquete, C11 a classe Carvão Coque, C12 a classe Cerâmica Escura, C13 a classe Cerâmica Iluminada, C14 a classe Argamassa de Cimento Pintado de Cinza, C15 a classe Argamassa de Cimento Pintado de Verde, C16 a classe Argamassa de Cimento Pintado de Vermelho, C17 a classe Compensado de Madeira, C18 a classe Concreto, C19 a classe Concreto Pintado de Azul, C20 a classe Concreto Pintado de Amarelo, C21 a classe Concreto Pintado de Vermelho, C22 a classe CRFS, C23 a classe Fibra de Vidro, C24 a classe Galvalume A, C25 a classe Galvalume B, C26 a classe Lago, C27 a classe Lona Pintada de Azul, C28 Lona Pintada de Verde, C29 a classe Manta Asfáltica Aluminizada, C30 a classe Pastilha Esmaltada, C31 a classe Pedra Mineira, C32 a classe Pedregulho, C33 a classe Piscina de Azulejo, C34 a classe Piscina de Vinil, C35 a classe Plástico, C36 a classe Policarbonato, C37 a classe Seixo de Argila, C38 a classe Solo Exposto, C39 a classe Sombra, C40 a classe Vegetação Arbórea, C41 a classe Vegetação Rasteira e C42 a classe Vidro Aramado.

Tabela 4.7 – Análise percentual dos acertos e confusões da classificação dos dados WV-3 com o algoritmo BFTree para o Nível de Legenda 2.

[illegible]

Tabela 4.8 – Análise percentual dos acertos e confusões da classificação dos dados WV-3 com o algoritmo BFTree para o Nível de Legenda 2.

[illegible]

4.3 Resultados do Índice *Kappa* e Testes de Hipótese

Além da exatidão global, a avaliação da acurácia das classificações pode ser verificada por meio do índice *Kappa* para toda a cena e condicional por classe. Assim, nesta seção serão apresentados estes resultados objetivando uma melhor comparação entre as classificações realizadas.

As Figuras 4.17 e 4.18 apresentam os valores obtidos para os índices *Kappa* pelas quatro classificações do Nível de Legenda 1 e para as quatro classificações do Nível de Legenda 2, respectivamente para ambos os dados.

Figura 4.17 – Índice *Kappa* para o Nível de Legenda 1.





Figura 4.18 – Índice *Kappa* para o Nível de Legenda 2.



As Tabelas 4.9, 4.10, 4.11 e 4.12 apresentam os valores do índice *Kappa* condicional por classe para as oito classificações realizadas.

Tabela 4.9 – Índice *Kappa* condicional do usuário e produtor referente às classificações dos dados WV-2 para o Nível de Legenda 1.

Classes	Algoritmo BFTree		Algoritmo LMT	
	K _u	K _p	K _u	K _p
Coberturas Cerâmicas	0,2050	0,4916	0,0615	0,1551
Coberturas Metálicas	0,8109	0,7775	0,9118	0,7539
Coberturas Diversas	0,5525	0,8517	0,5699	0,8395
Lago	0,6964	1,0000	0,9671	1,0000
Paviment. Não Viária	0,5684	1,0000	0,2902	0,8307
Paviment. Viária	0,7876	0,7092	0,7237	0,6812
Piscina	0,4987	0,3322	1,0000	1,0000
Solo Exposto	0,7959	0,5154	0,4543	0,6408
Sombra	0,6098	0,6422	0,8003	0,6805
Vegetação Arbórea	0,8271	0,4404	0,7723	0,7158
Vegetação Rasteira	0,7199	0,7749	0,7691	0,7175

Tabela 4.10 – Índice *Kappa* condicional do usuário e produtor referente às classificações dos dados WV-3 para o Nível de Legenda 1.

Classes	Algoritmo BFTree		Algoritmo LMT	
	K _u	K _p	K _u	K _p
Coberturas Cerâmica	0,1737	0,7464	0,3551	1,0000
Coberturas Metálicas	0,9778	0,8153	0,9582	0,9136
Coberturas Diversas	0,4487	0,8154	0,5784	0,9291
Lago	0,9305	1,0000	0,9618	1,0000
Paviment. Não Viária	0,4128	0,6213	0,5234	1,0000
Paviment. Viária	0,5701	0,8197	0,8153	0,7944
Piscina	1,0000	1,0000	0,4981	0,6650
Solo Exposto	0,6312	0,4064	0,5204	0,4940
Sombra	0,8340	0,6286	0,9250	0,6477
Vegetação Arbórea	0,8544	0,6350	0,7595	0,7658
Vegetação Rasteira	0,5979	0,6135	0,7017	0,6627

Tabela 4.11 – Índice *Kappa* condicional do usuário e produtor referente às classificações dos dados WV-2 para o Nível de Legenda 2.

Classes	Algoritmo BFTree		Algoritmo LMT	
	K _u	K _p	K _u	K _p
Aço Galvan. Brilhante	0,4191	0,7957	0,3618	0,6061
Aço Galvan. Ferrugem	0,7456	0,0753	0,4981	0,3316
Aço Galvan. Fosco	0,6350	0,5819	0,5817	0,7618
Acrílico	0,1562	0,0331	0,4975	0,3311
Amianto	0,7818	0,8565	0,8215	0,7529
Asfalto	0,6985	0,7989	0,7946	0,6317
Asfalto Pint. Branco	0,3849	0,3849	0,2504	0,1662
Asfalto Pint. Vermelho	0,6109	0,6109	0,8302	0,9072
Bloquete	0,4891	0,1002	0,3510	0,2504
Carvão Coque	0,9696	0,8763	0,8913	0,6660
Cerâmica Escura	0,2426	0,3995	0,6822	0,1979
Cerâmica Iluminada	0,4601	1,0000	0,4154	1,0000
Cimento	0,7755	0,3016	1,0000	0,1990
Cimento Pint. Verde	1,0000	0,2793	0,8079	0,8487
Cimento P. Vermelho	0,7979	0,3449	1,0000	0,9159
Concreto	0,6443	0,4410	0,7368	0,5764
Concreto Impermeab.	0,6774	0,8220	0,7890	0,9458
Concreto Pint. Amarelo	0,8993	0,5605	0,8448	0,5475
Concreto P. Vermelho	0,3304	0,0988	1,0000	0,3481
CRFS	0,4410	0,2828	0,4983	0,7487
Fibra de Vidro	0,7201	0,7628	0,7970	0,9128
Galvalume A	0,7437	0,9250	0,8413	0,9008
Galvalume B	0,9519	0,9519	0,9469	0,8992
Galvalume C	0,6659	0,7995	0,3742	1,0000
Lago	1,0000	0,3224	1,0000	0,8567
Lona	0,2844	1,0000	0,1959	0,1631
Manta Asf. Alum.	0,8880	0,8880	0,7261	0,7991
Pastilha Esmaltada	0,4982	0,1242	0,5986	0,3737
Pedra Mineira	0,5157	1,0000	0,6471	0,7501
Piscina de Azulejo	0,9150	1,0000	0,7731	1,0000
Piscina de Vinil	0,5546	1,0000	0,7995	0,6660
Plástico	0,7302	0,4192	0,9493	0,5551
Policarbonato	-0,0081	-0,0063	0,0256	0,0157
Solo Exposto	0,4253	0,1498	0,6351	0,4947
Sombra	0,6936	0,8832	0,6225	0,8503
Vegetação Arbórea	0,7596	0,9096	0,7012	0,8601
Vegetação Rasteira	0,6215	0,9022	0,6444	0,8386
Vidro Aramado	0,4123	0,7451	0,9873	0,8862

Tabela 4.12 – Índice *Kappa* condicional do usuário e produtor referente às classificações dos dados WV-3 para o Nível de Legenda 2.

Classes	Algoritmo BFTree		Algoritmo LMT	
	K _u	K _p	K _u	K _p
Aço Galvan. Brilhante	0,6616	0,4083	0,4561	0,4745
Aço Galvan. Ferrugem	0,4659	0,4659	0,4460	0,4960
Aço Galvan. fosco	0,6719	0,8492	0,7000	0,8125
Aço G. F. Manta Pol.	1,0000	0,3330	1,0000	1,0000
Acrílico	1,0000	0,3555	0,8693	0,8573
Amianto	0,5841	0,7707	0,7934	0,7103
Asfalto	0,6559	0,7827	0,4804	0,2203
Asfalto Pint. Branco	0,3842	0,1896	0,8452	0,7319
Asfalto Pint. Vermelho	0,5540	0,7130	0,7112	0,5518
Bloquete	0,7297	0,4186	0,8941	0,8808
Carvão Coque	0,8697	0,6898	0,9772	0,6710
Cerâmica Escura	0,2906	0,3360	0,6648	0,4265
Cerâmica Iluminada	0,8317	0,2609	0,7497	1,0000
Cimento Pint. Cinza	0,6349	0,8743	1,0000	0,9051
Cimento Pint. Verde	0,8949	0,8647	1,0000	0,9252
Cimento P. Vermelho	0,9081	0,9081	0,6824	0,3873
Compensado Madeira	0,9405	0,6930	0,7992	0,7992
Concreto	0,1237	0,0751	0,8166	0,4065
Concreto Pint. Azul	0,7887	0,5713	0,8329	0,8329
Concreto Pint. Amarelo	0,4951	0,1034	0,6652	0,3621
Concreto P. Vermelho	0,8742	0,5816	1,0000	0,7514
CRFS	0,4979	0,3731	0,7261	0,9199
Fibra de Vidro	0,8719	0,4305	0,9159	1,0000
Galvalume A	0,8068	0,9787	0,7864	0,9170
Galvalume B	0,6890	0,8552	1,0000	0,9255
Lago	0,9789	0,9392	1,0000	0,8743
Lona Azul	1,0000	0,2774	0,5699	0,8883
Lona Verde	1,0000	0,4987	1,0000	0,2494
Manta Asf. Alum.	1,0000	1,0000	0,9577	0,9714
Pastilha Esmaltada	1,0000	0,1291	0,7841	0,8162
Pedra Mineira	0,8318	0,7121	0,4992	0,2494
Pedregulho	0,4909	0,0276	0,8881	0,8881
Piscina de Azulejo	0,8805	1,0000	0,8305	0,2344
Piscina de Vinil	1,0000	0,9086	0,9367	0,4653
Plástico	0,8964	0,1279	0,6368	0,8373
Policarbonato	1,0000	0,0599	0,6568	0,7908
Seixo de Argila	0,9448	0,8508	0,6569	0,8088
Solo Exposto	0,3452	0,2544	1,0000	0,8616
Sombra	0,3175	0,8858	1,0000	0,6747
Vegetação Arbórea	0,5385	0,8935	0,9541	0,8060
Vegetação Rasteira	0,6611	0,6737	1,0000	0,1984
Vidro Aramado	0,3528	0,1391	0,9436	0,9436

A fim de examinar comparativamente as classificações foram realizados testes de hipótese Z com nível de significância de 5%. Este teste objetiva averiguar se os índices *Kappa* das classificações comparadas são ou não significativamente diferentes. As análises foram realizadas entre os algoritmos para um mesmo conjunto de dados e para um mesmo algoritmo em conjunto de dados diferentes. Por apresentarem quantidade de classes diferentes, os conjuntos de dados no Nível de Legenda 2 não foram examinados comparativamente entre si para cada um dos algoritmos.

Seis testes de hipóteses Z foram realizados. As informações detalhadas destes testes de hipótese estão dispostas no Apêndice D. As hipóteses testadas e os resultados são apresentados a seguir:

- Teste 1 – Comparação entre os algoritmos BFTree e LMT para os dados WV-2 no Nível de Legenda 1.

O índice *Kappa* obtido pelo algoritmo LMT é significativamente maior que o índice *Kappa* obtido pelo algoritmo BFTree

- Teste 2 – Comparação entre os algoritmos BFTree e LMT para os dados WV-3 no nível de Legenda 1.

O índice *Kappa* obtido pelo algoritmo LMT é significativamente maior que o índice *Kappa* obtido pelo algoritmo BFTree.

- Teste 3 - Comparação entre os algoritmos BFTree e LMT para os dados WV-2 no nível de Legenda 2.

O índice *Kappa* obtido pelo algoritmo LMT é significativamente maior que o índice *Kappa* obtido pelo algoritmo BFTree.

- Teste 4 - Comparação entre os algoritmos BFTree e LMT para os dados WV-3 no nível de Legenda 2.

O índice *Kappa* obtido pelo algoritmo LMT é significativamente maior que o índice *Kappa* obtido pelo algoritmo BFTree.

- Teste 5 – Comparação entre os dados WV-2 e WV-3 para a classificação realizada pelo algoritmo BFTree para o Nível de Legenda 1.

Os índices *Kappa* não são significativamente diferentes.

- Teste 6 – Comparação entre os dados WV-2 e WV-3 para a classificação realizada pelo algoritmo LMT para o Nível de Legenda 1.

O índice *Kappa* do conjunto de dados WV-3 é significativamente maior que o índice *Kappa* WV-2.

4.4 Tempos de Processamento

Os algoritmos abordados neste trabalho apresentaram tempos de construção das árvores de decisão muito distintos. Como mencionado anteriormente, este procedimento foi realizado no *software* WEKA em sua configuração padrão. As Figuras 4.19 e 4.20 apresentam os tempos de processamento dos algoritmos para cada Nível de Legenda e em relação a cada dado.

Figura 4.19 – Tempo de processamento para o Nível de Legenda 1.





Figura 4.20 – Tempo de processamento para o Nível de Legenda 2.



Os gráficos evidenciam que o tempo de construção das árvores de decisão utilizando o algoritmo BFTree é menor em comparação ao tempo dispendido pelo algoritmo LMT. Mas, como a criação das árvores pode ser feita *off-line*, neste contexto, o tempo de classificação torna-se importante ser evidenciado. As Figuras 4.21 e 4.22 apresentam os tempos de classificação utilizados pelos algoritmos para cada Nível de Legenda e em relação a cada dado.

Figura 4.21 – Tempo de classificação para o Nível de Legenda 1.





Figura 4.22 – Tempo de classificação para o Nível de Legenda 2.



É possível observar pelas figuras 4.21 e 4.22 que os tempos de classificação são maiores na classificação da imagem WV-2, pois esta possui mais segmentos a serem classificados. Também, evidencia-se que o algoritmo BFTree apresenta tempo de classificação ligeiramente menor que o algoritmo LMT.

4.5 Discussão

Este trabalho analisou a diferença de desempenho entre os algoritmos de árvore de decisão BFTree e LMT para os dados WV-2 e WV-3 em dois níveis de detalhamento. O Nível de Legenda 1 possuindo 11 classes de cobertura do solo urbano e o Nível de Legenda 2 possuindo 38 classes para os dados WV-2 e 42 classes para os dados WV-3.

Os algoritmos utilizados neste trabalho apresentam características diferentes. Enquanto o BFTree corresponde a uma árvore de decisão clássica, o LMT representa uma árvore de decisão logística, onde seus nós terminais correspondem a funções logísticas para a identificação das classes. Neste sentido, os atributos utilizados foram diferentes, bem como a quantidade utilizada por cada um dos algoritmos.

O algoritmo BFTree utilizou mais atributos para gerar as árvores de decisão no Nível de Legenda 2, pois a quantidade de classes a serem identificadas impacta decisivamente nessa característica. Em geral, o algoritmo LMT criou uma árvore de decisão com apenas um modelo logístico para identificar as classes. O número de atributos utilizados nas funções logísticas de cada classe é variável, mas em média são utilizados de sete a oito atributos para a identificação de uma classe.

As Figuras 4.23, 4.24, 4.25 e 4.26 apresentam as classificações dispostas lado a lado, respectivamente com seus mapas de verdade de campo.

As classificações realizadas obtiveram exatidões globais entre 64,41% e 82,27%. A maior exatidão global foi alcançada pela classificação dos dados WV-3 no Nível de Legenda 1 com o algoritmo LMT. Já a menor exatidão global foi apresentada pela classificação dos dados WV-3 no Nível de Legenda 2 com o algoritmo BFTree. Por sua vez, os índices *Kappa* obtidos pelas classificações oscilaram entre 0,7068 e 0,7863 no Nível de Legenda 1 e entre 0,6129 e

0,7583 no Nível de Legenda 2, sendo categorizados como muito bons conforme Landis e Koch (1977).

Figura 4.23 – Dados WV-2: Verdade de campo (A) e classificações para o Nível de Legenda 1: BFTree (B) e LMT(C).




Figura 4.24 – Dados WV-3: Verdade de campo (A) e classificações para o Nível de Legenda 1: BFTree (B) e LMT(C).




Figura 4.25 – Dados WV-2: Verdade de campo (A) e classificações para o Nível de Legenda 2: BFTree (B) e LMT(C).





Figura 4.26 – Dados WV-3: Verdade de campo (A) e classificações para o Nível de Legenda 2: BFTree (B) e LMT(C).



Uma análise mais apurada dos índices *Kappa* condicionais por classe e das matrizes de confusão pode identificar as classes mais difíceis de serem classificadas e evidenciar as confusões geradas pelas diferentes classificações. A Tabela 4.13 apresenta uma síntese comparativa, na qual foram elencadas as classes com menores índices *Kappa* condicionais, dispostas por algoritmo e sensor. Também apresenta uma coluna, em que são apresentadas as classes que proporcionaram maiores confusões aos classificadores em relação àquelas classes com menores índices *Kappa* condicionais, conforme a matriz de confusão.

A análise destes dados permite afirmar que as classes que possuem os menores índices no Nível de Legenda 1 foram: cerâmica, piscina e solo exposto. Por sua vez, o Nível de Legenda 2 apresentou uma maior variabilidade de classes com menores índices, mas se destacaram: policarbonato, acrílico, lona, concreto. As classes que apresentaram maiores confusões nas classificações, conforme a matriz de confusão, de forma geral, foram aquelas que apresentam materiais visualmente semelhantes. Esta característica é corroborada pela presença de classes muito similares, sobretudo no Nível de Legenda 2, destacando-se: diferentes tipos de aço galvanizado, de galvalumes, de amianto, concreto, asfalto. Também, destacam-se as confusões geradas entre classes espectralmente semelhantes, como cerâmica com solo exposto e policarbonato intemperizado com asfalto.

Os testes de hipótese para os Níveis de Legenda 1 demonstraram que, para o algoritmo BFTree, os índices *Kappa* obtidos para os dados WV-2 e WV-3 não foram significativamente diferentes. Já para o algoritmo LMT, as classificações obtidas com dados WV-3 apresentaram resultados significativamente superiores às das classificações obtidas com os dados WV-2.

Tabela 4.13 – Síntese comparativa das classes com menores índices *Kappa* condicionais e classes confundidas na matriz de confusão.

	Algoritmo BFTree		Algoritmo LMT	
	Classes com menores índices	Classes que foram confundidas	Classes com menores índices	Classes que foram confundidas
WV-2 – Nível 1				
Kappa Condicional do Usuário	Coberturas Cerâmicas (0,2050)	Solo Exposto	Coberturas Cerâmicas (0,0615)	Pav. Viária
		Veget. Rasteira		Solo Exposto
	Piscina (0,4987)	Cob. Metálicas	Pav. Não Viária (0,2902)	Pav. Viária
				Sombra
Kappa Condicional do Produtor	Piscina (0,3322)	Cob. Metálicas	Coberturas Cerâmicas (0,1551)	Pav. Viária
		Cob. Diversas		-----
	Vegetação Arbórea (0,4404)	Sombra	Solo Exposto (0,6408)	Cerâmica
		Veget. Rasteira		Cob. Diversas
WV-3 – Nível 1				
Kappa Condicional do Usuário	Coberturas Cerâmicas (0,1737)	Veget. Arborea	Coberturas Cerâmicas (0,3551)	Sombra
		Veget. Rasteira		-----
	Pav. Não Viária (0.4128)	Sombra	Piscina (0,4981)	Veget. Arbórea
Kappa Condicional do Produtor	Solo Exposto (0,4064)	Pav. Viária	Solo Exposto (0,4940)	Pav. Viária
		Veget. Rasteira		Veget. Rasteira
	Vegetação Rasteira (0,6135)	Pav. Viária	Sombra (0,6477)	Cob. Diversas
		Veget. Arbórea		Veget. Arbórea
WV-2 – Nível 2				
Kappa Condicional do Usuário	Policarbonato (-0,0081)	Asfalto	Policarbonato (0,0256)	Concreto
		Sombra		Sombra
	Acrílico (0,1562)	Amianto	Lona (0,1959)	Aco G. Fosco
		Sombra		Veget Rasteira
Kappa Condicional do Produtor	Policarbonato (-0,0063)	Lago	Policarbonato (0,0157)	Asfalto
		Sombra		Sombra
	Acrílico (0,0331)	Aço G. Ferrugem	Lona (0,1631)	Acrílico
		Aço G. Fosco		Amianto
WV-3 – Nível 2				
Kappa Condicional do Usuário	Concreto (0,1237)	Amianto	Aço Galv. Ferrugem (0,4460)	Asfalto
		Sombra		Concreto
	Cerâmica Escura (0,2906)	Amianto	Aço Galv. Brilhante (0,4561)	Aco G. Ferr.
		Pedra Mineira		-----
Kappa Condicional do Produtor	Pedregulho (0,0276)	Amianto	Vegetação Rasteira (0,1984)	Concreto
				Veg. Arbórea
	Concreto (0,0751)	Asfalto	Piscina de Azulejo (0,2344)	Veg. Arbórea
		Asf. P. Branco		-----

No nível de detalhamento mais refinado, utilizando o algoritmo BFTree, os dados WV-2 com 38 classes obtiveram índice *Kappa* superior (0,6977) aos dados WV-3 com 42 classes (0,6129). Por outro lado, utilizando o algoritmo LMT, esta tendência não persistiu. O índice *Kappa* dos dados WV-3 foi superior (0,7583) ao alcançado pelos dados WV-2 (0,7210).

Os testes de hipótese comparando o desempenho dos algoritmos indicaram que o algoritmo LMT apresentou resultado de índice *Kappa* superior ao BFTree em todos os níveis de dados. Essa superioridade apresentada pelo algoritmo LMT reside na utilização de um modelo de regressão logística ao invés de regressão linear (caso do BFTree) para selecionar os atributos mais relevantes no conjunto de dados. Com isso, é possível obter a estimativa das probabilidades das classes ao invés de simplesmente obter uma única classe no nó terminal da árvore de decisão (LANDWEHR et al., 2005).

Quanto ao processo de poda, ambos algoritmos utilizam a validação cruzada. A validação cruzada é utilizada para combinar o crescimento da árvore com a seleção do número de expansões realizadas. Mesmo utilizando processos de poda baseadas em um mesmo conceito, as árvores de decisão geradas pelo algoritmo LMT são bem menores quando comparadas com o algoritmo BFTree. Landwehr et al. (2005) creditam as maiores acurácias geradas pelas classificações utilizando o algoritmo LMT para o processo de poda por este utilizar validação cruzada, bem como a adoção do uso de modelos de regressão logística.

Os testes de hipótese comparando o desempenho dos conjuntos de dados para cada um dos algoritmos apontaram uma superioridade dos dados WV-3. Esse fato é justificado por este sensor possuir melhores resoluções espaciais e espectrais, quando comparado com o sensor WV-2. O refinamento espectral é essencial para promover a separação de classes de objetos visivelmente semelhantes (JENSEN, 2011). No caso, o WV-3 por possuir oito bandas na

região de ondas curtas - SWIR (1209,1 nm a 2329,2 nm) possibilita maior eficácia na determinação das classes de cobertura do solo.

Outro aspecto em relação ao desempenho dos algoritmos é a diferença dos índices *Kappa* interníveis. Ambos algoritmos obtiveram melhores índices *Kappa* no Nível de Legenda 1, pois este nível contempla apenas onze classes de cobertura do solo. Ao passo que o número de classes aumenta, caso do Nível de Legenda 2, o desempenho dos algoritmos sofre uma piora mínima. Qualquer algoritmo apresenta dificuldades para identificar um número elevado de classes. O Nível de Legenda 2 para os dados WV-2 contempla 38 classes, já para os dados WV-3 esse número salta para 42 classes. Aí está a justificativa para o menor desempenho de ambos algoritmos no nível de detalhamento mais refinado (WITTEN et al., 2011).

Os tempos de processamento dos algoritmos para a indução das árvores de decisão foram distintos. Em todos os Níveis de Legenda e dados utilizados o algoritmo BFTree obteve menor tempo de construção das árvores de decisão. Ambos algoritmos apresentaram maiores tempos no processamento dos dados no Nível de Legenda 2 devido ao maior número de classes. O processamento dos dados WV-3 demandou mais tempo pela sua maior quantidade de atributos. Quando sua árvore de decisão possui mais de 1 modelo logístico, o algoritmo LMT demanda mais tempo de processamento, como no caso dos dados WV-2 no Nível de Legenda 1. O algoritmo LMT, apesar da melhor acurácia apresentada é muito lento para a construção das árvores de decisão. Este comportamento do algoritmo LMT é justificado pela complexidade dos modelos logísticos que utiliza um grande número de atributos para determinar as classes e pelo seu processo de poda que é muito complexo (LANDWEHR et al., 2005).

As classificações de imagens por meio de níveis de detalhamento muito refinados, isto é, considerando muitas classes de cobertura do solo urbano, são desafiadoras. Na literatura de sensoriamento remoto, trabalhos como

Longbotham et al. (2012), Khodadadzadeh et al. (2015) e Anjos (2016) evidenciam a necessidade de se conjugar altas resoluções espaciais e espectrais para classificar imagens com elevado número de classes de cobertura do solo urbano. Neste sentido, os resultados alcançados para os dados WV-3 revelam que as bandas do SWIR aliadas ao algoritmo LMT permitem obter melhores resultados na classificação de imagens com níveis de detalhamento muito refinados.

5 CONCLUSÕES E RECOMENDAÇÕES

O presente trabalho comparou diversas classificações de cobertura do solo urbano por meio de diferentes dados orbitais e algoritmos de árvore de decisão em dois níveis de legenda de classificação. No total, foram realizadas oito diferentes classificações, sendo quatro delas no Nível de Legenda 1, que considera 11 classes de cobertura do solo urbano, e as outras quatro no Nível de Legenda 2, que é mais refinado e engloba 38 e 42 classes de cobertura do solo urbano.

Os dados utilizados neste trabalho referem-se a imagens orbitais multiespectrais dos sensores WorldView-2 e WorldView-3. As classificações foram realizadas por meio dos algoritmos de árvore de decisão Best First Tree (BFTree) e Logistic Model Tree (LMT). O desempenho dos conjuntos de dados e dos algoritmos utilizados foram testados, considerando os diferentes níveis de detalhamento. As classificações para ambos conjuntos de dados apresentaram exatidões globais entre 75,03% e 82,27% e índices *Kappa* oscilando entre 0,7068 e 0,7863 no Nível de Legenda 1. Por sua vez, no Nível de Legenda 2 as exatidões globais oscilaram entre 64,41% e 78% e índices *Kappa* variando entre 0,6129 e 0,7583.

Os atributos mais utilizados pelos algoritmos foram os índices de vegetação, dentre eles os NDVIs e o SAVI, e os atributos customizados (AC). Como os algoritmos são diferentes nas concepções de elaboração de suas árvores de decisão, foram evidenciadas algumas particularidades. Conforme o número de classes aumenta, maior o número de atributos utilizados pelo algoritmo BFTree para a concepção de suas árvores. Por outro lado, o algoritmo LMT, frente a um maior número de classes, cria menos modelos logísticos para a identificação das mesmas. Ademais, o algoritmo LMT utiliza menos atributos na concepção da árvore de decisão quando comparado ao algoritmo BFTree.

Foram apresentados os tempos de processamentos dos algoritmos. Com isso, constatou-se que o algoritmo BFTree é o mais rápido na construção das

árvores de decisão em ambos sensores e Níveis de Legenda. Apesar da melhor acurácia apresentada, o algoritmo LMT demanda maior tempo de processamento.

Foram realizados testes de hipótese objetivando analisar a similaridade entre as classificações. O teste de similaridade Z demonstrou que, para todos os conjuntos de dados e nos dois níveis de detalhamento, os resultados alcançados pelo algoritmo LMT foram significativamente superiores aos resultados obtidos pelo algoritmo BFTree. Quanto à análise relativa aos conjuntos de dados, esta só foi passível de ser realizada no Nível de Legenda 1, devido à compatibilidade no número de classes. Neste caso, utilizando o algoritmo BFTree, as classificações não obtiveram *Kappa* significativamente diferentes para um intervalo de confiança de 95%. No entanto, as classificações utilizando o algoritmo LMT evidenciaram uma significativa superioridade de desempenho em relação aos dados WV-3.

É importante mencionar que, mesmo sem a possibilidade de comparações através de testes de hipótese, o resultado da classificação do algoritmo LMT para os dados WV-3 com 42 classes de cobertura do solo urbano foi superior ao resultado da classificação do mesmo algoritmo para os dados WV-2 com 38 classes. Isto evidencia a qualidade dos dados WV-3 e a boa adequação do algoritmo LMT na classificação de imagens com número muito elevado de classes de cobertura do solo.

Conforme exposto por Anjos (2016), os refinamentos tecnológicos experienciados pelos sensores orbitais de última geração, notadamente no que diz respeito ao incremento de suas resoluções (espectral, temporal, espacial e radiométrica), pressupõem um correspondente avanço nos métodos e nas possibilidades de extração de informação a partir de suas imagens. É natural supor que isto implique o aumento expressivo no número de alvos a serem identificados nessas cenas. Neste sentido, este trabalho, ao se apoiar nos achados desta autora, e ao mesmo tempo, representar uma continuidade ao

trabalho desenvolvido pela mesma, esforçou-se por aportar à comunidade científica de sensoriamento remoto uma contribuição voltada a sedimentar novos caminhos para a exploração de dados orbitais de elevada resolução espacial e espectral.

Recomenda-se para trabalhos futuros:

- a avaliação de novos algoritmos de classificação, como aqueles de Redes Neurais Artificiais. Sobretudo, o recente *Deep Learning* associado à Computação de Alto Desempenho.
- a avaliação e desenvolvimento de novos métodos de classificação de imagens, como a classificação hierárquica em árvore de decisão que particiona a imagem e classifica por partes a imagem total.
- a avaliação de novos algoritmos de segmentação de imagens para a realização da classificação final.

REFERÊNCIAS BIBLIOGRÁFICAS

ADRIAANS, P.; ZANTINGE, D. **Data mining**. Harlow: Addison-Wesley, 1996. 158p

ALMEIDA, C. M.; SOUZA, I. M.; DURAND, C. A.; PINHO, C. M. D.; FEITOSA, R. Q. métodos cognitivos de classificação aplicados a imagens QuickBird para a detecção de áreas residenciais homogêneas. **Revista Brasileira de Cartografia**, v. 61, n. 1, p. 1-12, 2009. Disponível em: <http://www.rbc.ufrj.br/_2009/61_1_01.htm>. Acesso em: 28 mar. 2017.

ANJOS, C. S. **Classificação de áreas urbanas com imagens multiespectrais e hiperespectrais utilizando métodos não-paramétricos**. 2016. 365 p. (sid.inpe.br/mtc-m21b/2016/04.04.19.03-TDI). Tese (Doutorado em Sensoriamento Remoto) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos - SP, 2016. Disponível em: <<http://urlib.net/8JMKD3MGP3W34P/3LESGT2>>.

ANTUNES, A. F. B.; LINGNAU, C. Uso de Índices de Acurácia para Avaliação de Mapas Temáticos Obtidos por Meio de Classificação Digital. In: CONGRESSO E FEIRA PARA USUÁRIOS DE GEOPROCESSAMENTO, 3., 1997,. Curitiba. **Anais...**, Curitiba: SAGRES, 1997.

BAATZ, M.; SCHÄPE, A. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. **Journal of Photogrammetry and Remote Sensing**, v. 58, p. 12–23, 2000.

BALTSAVIAS, E. P.; GRUEN, A.; VANGOOL, L. **Automatic extraction of man-made objects from aerial and satellite images III**. [S.l.]: Taylor & Francis, 2001. (Monte Verità, v. 3)

BASGALUPP, M. P. **LEGAL-Tree: um algoritmo genético multi-objetivo lexicográfico para indução de árvores de decisão**. Tese (Doutorado em Ciências da Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e Computação (ICMC-USP), São Carlos, 2010.

BAUSCH, W. C.; DUKE, H. R. Remote sensing of plant nitrogen status in corn. **Transactions of the ASAE**, v. 39, n. 5, p. 1869-1875, 1996.

BLASCHKE, T.; HAY, G. J.; KELLY, M.; LANG, S.; HOFMANN, P.; ADDINK, E.; QUEIROZ FEITOSA, R.; MEER, F. van der; WERFF, H. van der; COILLIE, F. van; TIEDE, D. Geographic object-based image analysis - towards a new paradigm. **ISPRS journal of photogrammetry and remote sensing: official publication of the International Society for Photogrammetry and Remote Sensing (ISPRS)**, v. 87, n. 100, p. 180–191, jan. 2014.

BISHOP, C. M. **Pattern recognition and machine learning**. Germany: Springer, 2006, 740p.

BRASIL. **Estatuto da cidade e legislação correlata**. Lei nº 10.257, de 10 de junho de 2001 – 2. ed. – Brasília: Senado Federal, Subsecretaria de Edições Técnicas, 2002. 80 p. ISBN 85-7018-223-6

BREIMAN, L.; FRIEDMAN, J. H.; OLSHEN, R.A.; STONE, C. J. **Classification and regression trees**. 2. ed. Pacific Grove, CA: Wadsworth, 1984.

BRUM-BASTOS, V. S.; RIBEIRO, B. M. G.; PINHO, C. M. D.; KORTING, T. S.; FONSECA, L. M. G. improvement evaluation on ceramic roof extraction using worldview-2 imagery and geographic data mining approach. **ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XLI-B7, p. 883-889, 2016.

BURNETT, C.; BLASCHKE, T. A multi-scale segmentation/object relationship modelling methodology for landscape analysis. **Ecological Modelling**. v. 168, p. 233–249, 2003.

CAMPBELL, J. **Introduction to remote sensing**. New York: The Guilford Press, 2007.

CAMARGO, F. F.; ALMEIDA, C. M.; FLORENZANO, T. G.; HEIPKE, C.; FEITOSA, R. Q.; COSTA, G. Aster/Terra imagery and a multilevel semantic network for semi automated classification of landforms in a subtropical area. **Photogrammetric Engineering and Remote Sensing**, v. 77, p. 619–629, 2011.

COELHO, F. F. **Comparação de métodos de mapeamento digital de solos através de variáveis geomorfológicas e sistemas de informações geográficas**. Dissertação (Mestrado em Sensoriamento Remoto) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2010.

COHEN, J. A coefficient of agreement of nominal scales. **Educational and Psychological Measurement**, v. 20, p. 37–46, 1960.

CONGALTON, R. G.; GREEN, R. **Assessing the accuracy of remotely sensed data: principles and practices**. Boca Raton: Lewis Publishers, 1999.

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. 2 ed. Boca Raton: CRC Press, 2009. 183 p.

CORADINE, L. C.; LOPES, R. V. V.; MACIEL, A. F. Mineração de dados: uma introdução. **Learning and Nonlinear Models (L&NLM) – Journal of the Brazilian Neural Network Society**, v. 9, n.3, p. 168-184, 2011.

CORTIJO, F. J.; LA BLANCA, N. P. A comparative study of some non-parametric spectral classifiers. Applications to problems with high-overlapping training sets. **International Journal of Remote Sensing**, v.18, n.6, p.1259-1275, 1997.

DALL'OGGIO, P. **Programando com Orientação a Objetos**. 2. ed. São Paulo: Novatec, 2009. 574 p.

DEFINIENS. **Definiens developer 7**: reference book. Munique: Definiens AG, 2007. 195 p. Disponível em: <<http://www.ecognition.cc/download/ReferenceBook.pdf>>. Acesso em: 15 jan. 2017.

- DIGITALGLOBE. **WorldView-2 data sheet**. 2009. 2 p. Disponível em: <https://www.digitalglobe.com/sites/default/files/DG_WorldView2_DS_PROD.pdf>. Acesso em: 26 fev. 2016.
- DIGITALGLOBE. **WorldView-3 data sheet**. 2013. 2 p. Disponível em: <https://www.digitalglobe.com/sites/default/files/DG_WorldView3_DS_forWeb_0.pdf>. Acesso em: 19 dez. 2016.
- DIGITALGLOBE. **Absolute radiometric calibration: 2015v2**. 2016. 5 p. Disponível em: <https://dg-cms-uploads-production.s3.amazonaws.com/uploads/document/file/209/DGConstellationAbsRadCalAdjustmentFactors_2015v2.pdf>. Acesso em: 15 jan. 2017.
- DLUGOSZ, F. L.; ROSOT, N. C.; ROSOT, M. A. D.; OLIVEIRA, Y. M. M. Índice para a avaliação de segmentação de imagens. **Floresta**, Curitiba, PR, v. 39, n. 1, p. 131-143, 2009.
- EHLERS, M.; JANOWSKY, R.; GAEHLER, M. New remote sensing concepts for environmental monitoring. **Remote Sensing for Environmental Monitoring, GIS Applications, and Geology**, v. 45, p. 1-12, January 2002.
- EMBRAPA. **Satélites de monitoramento**. Campinas: Embrapa Monitoramento por Satélite, 2013. Disponível em: <<http://www.sat.cnpem.embrapa.br>>. Acesso em: 19 fev. 2016.
- ENVI - **Guia do ENVI em português**. Sulsoft, 2000. Disponível em www.sulsoft.com.br. Acesso em 15 out. 2006.
- ESTOQUE, R. C.; MURAYAMA, Y.; AKIYAMA, C. M. Pixel-based and object-based classifications using high- and medium-spatial-resolution imageries in the urban and suburban landscapes. **Geocarto International**, v. 0, n. 0, p. 1–17, 2015. DOI: 10.1080/10106049.2015.1027291.
- FAYYAD, U.; PIATETSKY-SHAPIO, G.; SMYTH, P. From data mining to knowledge discovery in databases. **AI magazine**, v. 17, p. 37–53, 1996.
- FRANCISCO, C. N.; ALMEIDA, C. M. Avaliação de desempenho de atributos estatísticos e texturais em uma classificação de cobertura da terra baseada em objeto. **Boletim de Ciências Geodésicas**, v. 18, p. 302-326, 2012.
- FRANCISCO, C. N.; ALMEIDA, C. M. Mineração de dados e análise de imagens baseada em objeto aplicadas ao mapeamento de cobertura da terra. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, . 16. (SBSR), 2013, Foz do Iguaçu. **Anais...** São José dos Campos: INPE, 2013. p. 2282-2289. DVD, Internet. ISBN 978-85-17-00066-9 (Internet), 978-85-17-00065-2 (DVD). Disponível em: <<http://urlib.net/3ERPFQRTRW34M/3E7G6HN>>. Acesso em: 28 mar. 2017.
- GEOMATICA. **PCI geomatics announces release of geomatica 2014**. GATINEAU, Quebec, Canada: [s.n.], 2014. 5p. Disponível em: <http://www.pcigeomatics.com/pressnews/2014_PCI_Geomatica_2014.pdf>. Acesso em: 15 jan. 2017.

- GITELSON, A. A.; KAUFMAN, Y. J.; MERZLYAK, M. N. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sensing of Environment**, v. 58, n. 3, p. 289-298, 1996.
- GONZÁLES, R. C.; WINTZ, P. **Digital image processing**. Boston: Prodding, Addison Wesley, 1987.
- GOOGLE. **Google Earth**. Version 7.1. 2015. Campinas – SP. Disponível em <http://earth.google.com>. Acesso em: 06 mar. 2016.
- HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. H. **The WEKA data mining software**. [S.l.: s.n.], 2009. 10 p. ISSN 19310145. ISBN 1931-0145.
- HEROLD, M.; ROBERTS, D. A.; GARDNER, E. M.; DENNISON, P. E. Spectrometry for urban area remote sensing – Development and analysis of a spectral library from 350 to 2400 nm. **Remote Sensing of Environment**, v. 91, p. 304-319, 2004.
- HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, p. 53-70, 1988.
- IBGE. **Atlas do censo demográfico 2010**. Rio de Janeiro: IBGE, 2013. 156 p.
- IBGE. **Cidades@** - consulta por município. 2014. Disponível em: <<http://cod.ibge.gov.br/232TL>>.
- JACOBSEN, K. Calibration aspects in direct georeferencing of frame imagery. **International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences**, v. 34, p. 82–88, 2002.
- JAIN, S. K.; SARAF, A. K.; GOSWAMI, A.; AHMAD, T. Flood inundation mapping using NOAA AVHRR data. **Water Resources Management**, v. 20, n. 6, p. 949-959, 2006.
- JENSEN, J. R.; COWEN, D. C. Remote sensing of urban/suburban infrastructure and socio-economic attributes. **Photogrammetric Engineering and Remote Sensing**, v. 65, p. 611–622, 1999.
- JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos: Parêntese, 2011. Tradução José Carlos Neves Epiphanyo (coordenador).
- JOHNSON, B. A. High-resolution urban land-cover classification using a competitive multi-scale object-based approach. **Remote Sensing Letters**, v. 4, n. 2, p. 131–140, 2013.
- JOLLIFFE, I. T. **Principal component analysis**. 2. ed. New York: Springer-Verlag, 2002.
- KHODADADZADEH, M.; JUN LI; PLAZA, A.; BIOUCAS-DIAS, J.M. Hyperspectral image classification based on union of subspaces. In. URBAN

REMOTE SENSING EVENT (JURSE), 2015, Lausanne, Suíça. **Proceedings...** Suíça: IEEE, 2015. p.1-4. DOI 10.1109/JURSE.2015.7120510 Disponível em: < <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=7120510&isnumber=7120346>>. Acesso em: 02 Dez. 2016.

KORTING, T. S. **GEODMA: a toolbox integrating data mining with object-based and multi-temporal analysis of satellite remotely sensed imagery**. 2012, 96 p. Tese (Doutorado em Sensoriamento Remoto). Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2012. 119 p. (sid.inpe.br/mtc-m19/2012/07.31.18.22-TDI). Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2012. Disponível em: <<http://urlib.net/8JMKD3MGP7W/3CCH86S>>. Acesso em: 28 mar. 2017.

KUX, H. J. H.; ARAÚJO, E. H. G.; CARTWRIGHT, W.; GARTNER, G.; MENG, L.; PETERSON, M. P. Object-based image analysis using QuickBird satellite images and GIS data, case study Belo Horizonte (Brazil). In: BLASCHKE, T.; HAY, G. J.; LANG, S. (eds.). **Object-based image analysis: spatial concepts for knowledge-driven remote sensing applications**. Berlin: Springer-Verlag, 2008. v. cap. 6.3, p. 571-588. ISBN 978-3540-77057-2, 978-3-540-77058-9.

LABEN, C. A.; BROWER, B. V. **Process for enhancing the spatial resolution of multispectral imagery using pan-sharpening**. US 6011875 A. 2000.

LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical Data. **Biometrics**, v. 33, n. 1, p.159–174, 1977. DOI 10.2307/2529310. Disponível em: <<http://www.jstor.org/stable/pdf/2529310.pdf?acceptTC=true>>. Acesso em: 15 Dez. 2016.

LANDWEHR, N.; HALL, M.; Frank, E. Logistic model trees. **Mach. Learn.**, v. 59, n. 1-2, p. 161-205, 2005.

LATORRE, M.; CARVALHO, A. O. J. D.; CARVALHO, A. P. F.; SHIMABUKURO, Y. E. Correção atmosférica: conceitos e fundamentos. **Espaço & Geografia**, v. 5, p. 153–178, 2002.

LEE, J. B; WOODYATT, A. S.; BERMAN, M. Enhancement of high spectral resolution remote sensing data by a noise-adjusted principal components transform. **IEEE Transactions on Geoscience and Remote Sensing**, v.28, p. 295-304. 1990

LEONARDI, F. **Abordagens cognitivas e mineração de dados aplicadas a dados ópticos orbitais e de laser para classificação de cobertura do solo urbano**. 2010. 162 p. (sid.inpe.br/mtc-m19@80/2010/03.17.11.42-TDI). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2010. Disponível em: <<http://urlib.net/8JMKD3MGP7W/376H8M2>>. Acesso em: 28 mar. 2017.

LONGBOTHAM, N.; CHAAPEL, C.; BLEILER, L.; PADWICK, C.; EMERY, W.J.; PACIFICI, F. Very high resolution multiangle urban classification analysis. **IEEE Transactions on Geoscience and Remote Sensing**, v.50, n.4, p.1155-1170, 2012. DOI 10.1109/TGRS.2011.2165548. Disponível em:

<<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=6032741&isnumber=6172975>>. Acesso em: 06 Out. 2016.

MARTINS, N. M. N. **Utilização de imagens de satélite de alta resolução para a extracção de elementos em ambiente urbano**. Dissertação (Mestrado em Engenharia Geográfica) – Faculdade de Ciências da Universidade de Lisboa, Lisboa, 2012.

MENEGHETTI, G. T.; KUX, H. J. H. Mapeamento da cobertura da terra do município de Raposa (MA) utilizando imagens WorldView-II, o aplicativo INTERIMAGE e mineração de dados. **Revista Brasileira de Cartografia** (Online), v. 66, p. 365-377, 2014.

MOUSTAKIDIS, S.; MALLINIS, G.; KOUTSIAS, N.; THEOCHARIS, J. B.; PETRIDIS, V. SVM-based fuzzy decision trees for classification of high spatial resolution remote sensing images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 50, n. 1, p. 149-169, 2012.

MYINT, S. W. A new framework for effective urban land use land cover classification: A wavelet approach. **GIScience and Remote Sensing**, v. 43, p. 155–178, 2006.

MYINT, S. W.; GOBER, P.; BRAZEL, A.; GROSSMAN-CLARKE, S.; WENG, Q. Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery. **Remote sensing of environment**, v. 115, n. 5, p. 1145–1161, 2011.

NOVACK, T.; ESCH, T.; KUX, H. J. H.; STILLA, U. Machine Learning Comparison between WorldView-2 and QuickBird-2 simulated imagery regarding object-based urban land cover classification. **Remote Sensing**, v. 3, p. 2263-2282, 2011.

NOVO, E.M.L.M. **Sensoriamento remoto: princípios e aplicações**. 3. ed. São Paulo: Blucher, 2008. 363 p.

PINHO, C. M. D.; RENNÓ, C. D.; KUX, H. J. H. Avaliação das técnicas de fusão aplicadas à imagem Quickbird. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12., 2005, Goiânia, GO. **Anais...** São José dos Campos: INPE, 2005, p. 4225-4232. ISBN 85-17-00018-8. (INPE-12768-PRE/8058). Disponível em: <<http://urlib.net/ltid.inpe.br/sbsr/2004/11.22.20.14>>.

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. **Journal of Remote Sensing**, v. 33, n. 19, p. 5973-5995, 2012.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento remoto no estudo da vegetação**. São José dos Campos: Parêntese, 2010, 127p.

QGIS **Development team**. 2009. QGIS Geographic Information System. 2009. Open Source Geospatial Foundation. URL <http://qgis.osgeo.org>.

QUINLAN, J. R. Induction of decision trees. **Machine Learning**, v.1, n. 1, p. 81 – 106, 1986.

RICHARDSON, A. J.; WIEGAND, C. Distinguishing vegetation from soil background information. **Photogrammetric Engineering and Remote Sensing**, v. 43, p. 1541-1552, 1977.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W.; HARLAN, J. C. **Monitoring the vernal advancement of retrogradation of natural vegetation**. Greenbelt: NASA/GSFC, 1974. 371 p. Disponível em: <<http://ntrs.nasa.gov/archive/nasa/casi.ntrs.nasa.gov/19750020419.pdf>>. Acesso em: 10 Dez. 2016.

RUIZ, R. S. R.; CAMPOS VELHO, H. F.; SANTOS, R. D. C.; TREVISAN, M. Árvores de decisão na classificação de dados astronômicos. **Tendências em Matemática Aplicada e Computacional**, v.10, p. 75-86, 2009.

SARKAR, A.; GARG, R. D.; SHARMA, N. RS-GIS Based Assessment of River Dynamics of Brahmaputra River in India. **Journal of Water Resource and Protection**, v. 4, n. 02, p. 63-72, 2012.

SCHOWENGERDT, R. A. **Remote sensing: models and methods for image processing**. 2. ed. San Diego, USA: Academic Press, USA, 1997. 522p.

SHI, H. **Best-first decision tree learning**. Master's thesis. University of Waikato, Hamilton, NZ, 2007.

SOUZA, U. D. V.; KUX, H. J. H. Geobias e mineração de dados na classificação da cobertura do solo urbano em São Luis (MA) com imagens WorldView-2 e o sistema Interimage. **Revista Brasileira de Cartografia** (Online), v. 66, p. 433-450, 2014.

THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern recognition**. San Diego: Academic Press, 2003. 640p.

TONG, X; XIE, H; WENG, Q. Urban Land Cover Classification With Airborne Hyperspectral Data: What Features to Use?. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v.7, n.10, p.3998-4009, 2014. DOI 10.1109/JSTARS.2013.2272212 Disponível em: < <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=6566095&isnumber=6994884>> Acesso em: 04 Dez. 2016.

TRIMBLE. **eCognition developer 8.7 user guide**. Munich, Germany: [s.n.], 2011. 258 p. Disponível em: <<http://www.ecognition.com/>>.

UNICAMP. **A Unicamp**. 2016. Disponível em: < <http://www.unicamp.br/unicamp/a-unicamp>>. Acesso em janeiro de 2016.

UNIVERSITY OF WAIKATO. **Weka 3.7.12** – machine learning software in Java. Disponível no site da University of Waikato (2010). URL: <http://www.cs.waikato.ac.nz/ml/weka30>.

UNITED NATIONS. Department of Economic and Social Affairs. Population Division (UNPD). **World Urbanization Prospects: the 2014 Revision**. New York, 2014. 493 p. Disponível em: <http://esa.un.org/unpd/wup/Publications/Files/WUP2014-Report.pdf>>. Acesso em: 15 jan. 2017.

WITTEN, I. H.; FRANK, E; HALL, M. A. **Data mining: practical machine learning tools and techniques**. 3. ed. San Francisco: Morgan Kaufmann, 2011. 664p.

ZHANG, K.; HU, B. Individual urban tree species classification using very high spatial resolution airborne multi-spectral imagery using longitudinal profiles. **Remote Sensing**. v. 4, p. 1741-1757, 2012.

ZHOU, W.; HUANG, G.; TROY, A.; CADENASSO, M. Object-based land cover classification of shaded areas in high spatial resolution imagery of urban areas: A comparison study. **Remote Sensing of Environment**, v. 113, p. 1769–1777, 2009.

APÊNDICE A – ÁRVORES DE DECISÃO PARA CENA WORLDVIEW-2.

Este Apêndice apresenta as árvores de decisão implementadas durante o trabalho. Para total compreensão deste Apêndice consulte a lista de siglas e abreviaturas no início do documento.

A.1 Nível de Legenda 1

A.1.1 Árvore Algoritmo BFTree

```
Mean Layer 18 < 22.93794
| AC17 < -1256.86743
| | Mean Layer 20 < -2.06277
| | | SAVI < 0.28339
| | | | Standard deviation Layer 25 < 0.43847
| | | | | AC14 < 0.12402
| | | | | NDVI_1 < 0.08046: Pav Não Viaria(3.0/1.0)
| | | | | NDVI_1 >= 0.08046
| | | | | | Standard deviation Layer 7 < 662.48995: Cob. Diversas(3.0/0.0)
| | | | | | Standard deviation Layer 7 >= 662.48995
| | | | | | Standard deviation Layer 23 < 7.62941: Pav Viaria(17.0/0.0)
| | | | | | Standard deviation Layer 23 >= 7.62941: Cob. Diversas(3.0/0.0)
| | | | | AC14 >= 0.12402: Cob. Diversas(8.0/1.0)
| | | | Standard deviation Layer 25 >= 0.43847: Cob. Diversas(63.0/4.0)
| | | SAVI >= 0.28339: Vegetação Rasteira(11.0/0.0)
| | Mean Layer 20 >= -2.06277
| | Mean Layer 22 < -0.1209
| | | Mean Layer 3 < 9410.21782
| | | | AC3 < -3764.09628: Cob. Cerâmicas(5.0/0.0)
| | | | AC3 >= -3764.09628
| | | | | Mean Layer 25 < 0.61585
| | | | | SAVI < 0.23621: Pav Não Viaria(2.0/1.0)
| | | | | SAVI >= 0.23621: Lago(4.0/0.0)
| | | | | Mean Layer 25 >= 0.61585: Cob. Diversas(5.0/0.0)
| | | Mean Layer 3 >= 9410.21782
| | | | Mean Layer 1 < 13484.25: Pav Viaria(75.0/6.0)
| | | | Mean Layer 1 >= 13484.25
| | | | | AC4 < -1845.9682
| | | | | NDVI_3 < -0.3071: Cob. Cerâmicas(1.0/1.0)
| | | | | NDVI_3 >= -0.3071: Cob. Diversas(7.0/0.0)
| | | | AC4 >= -1845.9682: Cob. Metálicas(4.0/0.0)
| | Mean Layer 22 >= -0.1209
| | | AC1 < 0.64523
| | | | Mean Layer 13 < 133.62962
| | | | NDVI_2 < -0.01004
| | | | NDVI_3 < -0.2311: Pav Viaria(3.0/1.0)
| | | NDVI_3 >= -0.2311: Pav Não Viaria(7.0/0.0)
```

```

| | | | | NDVI_2 >= -0.01004
| | | | | Standard deviation Layer 6 < 771.71646
| | | | | Mean Layer 16 < 143.21373: Solo Exposto(19.0/1.0)
| | | | | Mean Layer 16 >= 143.21373: Cob. Diversas(1.0/1.0)
| | | | | Standard deviation Layer 6 >= 771.71646: Cob. Cerâmicas(2.0/0.0)
| | | | | Mean Layer 13 >= 133.62962
| | | | | Standard deviation Layer 22 < 5.75801: Cob. Cerâmicas(14.0/1.0)
| | | | | Standard deviation Layer 22 >= 5.75801: Cob. Diversas(1.0/1.0)
| | | | | AC1 >= 0.64523
| | | | | Mean Layer 17 < 40.09982
| | | | | NDVI_2 < 0.07986
| | | | | AC6 < -17591.99537: Pav Viaria(12.0/1.0)
| | | | | AC6 >= -17591.99537
| | | | | Standard deviation Layer 24 < 2.53985
| | | | | AC6 < -16944.17095: Solo Exposto(2.0/1.0)
| | | | | AC6 >= -16944.17095: Pav Viaria(3.0/0.0)
| | | | | Standard deviation Layer 24 >= 2.53985: Cob. Diversas(7.0/0.0)
| | | | | NDVI_2 >= 0.07986: Vegetação Rasteira(5.0/0.0)
| | | | | Mean Layer 17 >= 40.09982: Cob. Diversas(17.0/1.0)
| | | | | AC17 >= -1256.86743
| | | Standard deviation Layer 6 < 598.91436: Sombra(22.0/0.0)
| | | Standard deviation Layer 6 >= 598.91436: Vegetação Arborea(19.0/1.0)
| Mean Layer 18 >= 22.93794
| Mean Layer 20 < -14.0945
| | NDVI_3 < 0.08249: Cob. Diversas(34.0/0.0)
| | NDVI_3 >= 0.08249: Piscina(5.0/0.0)
| Mean Layer 20 >= -14.0945
| | NDVI_2 < -0.00311: Cob. Metálicas(159.0/22.0)
| | NDVI_2 >= -0.00311
| | | Standard deviation Layer 19 < 3.82708: Cob. Diversas(9.0/1.0)
| | | Standard deviation Layer 19 >= 3.82708: Cob. Metálicas(3.0/1.0)

```

Tamanho da árvore: 69

A.1.2 Árvore Algoritmo LMT

```

Mean Layer 5 <= 11595.759791: LM_1:94/188 (40)
Mean Layer 5 > 11595.759791
| Mean Layer 18 <= 22.720777
| | NDVI_2 <= 0.083674
| | | Mean Layer 2 <= 9560.851494: LM_2:94/470 (21)
| | | Mean Layer 2 > 9560.851494
| | | AC2 <= 0.644106: LM_3:94/564 (89)
| | | AC2 > 0.644106: LM_4:94/564 (198)
| | NDVI_2 > 0.083674: LM_5:94/376 (20)
| Mean Layer 18 > 22.720777: LM_6:94/282 (234)

```

Tamanho da árvore:11

LM_1:

Class Sombra :

$196.32 + [\text{SAVI}] * -12.2 + [\text{NDVI_12}] * 111.75 + [\text{AC8}] * -143.44 + [\text{AC7}] * -43.5 + [\text{AC5}] * 0 + [\text{AC17}] * 0.01 + [\text{AC16}] * 4.72 + [\text{Standard deviation Layer 25}] * -4.46 + [\text{Standard deviation Layer 22}] * -2.1 + [\text{Standard deviation Layer 21}] * -0.39 + [\text{Standard deviation Layer 19}] * 4 + [\text{Standard deviation Layer 18}] * 5.2 + [\text{Standard deviation Layer 15}] * -0.01 + [\text{Standard deviation Layer 11}] * 0.01 + [\text{Mean Layer 9}] * 0.01 + [\text{Mean Layer 6}] * 0 + [\text{Mean Layer 4}] * 0 + [\text{Mean Layer 25}] * -0.11 + [\text{Mean Layer 21}] * -0.2 + [\text{Mean Layer 20}] * 0.17 + [\text{Mean Layer 15}] * -0.2 + [\text{Mean Layer 14}] * 0.02 + [\text{Mean Layer 13}] * 0.01$

Class Coberturas Cerâmicas :

$-34.07 + [\text{NDVI_3}] * -40.88 + [\text{AC14}] * 13.38 + [\text{AC12}] * -3.58 + [\text{AC11}] * -16.47 + [\text{AC1}] * -39.81 + [\text{Standard deviation Layer 8}] * 0 + [\text{Standard deviation Layer 7}] * 0 + [\text{Standard deviation Layer 5}] * 0 + [\text{Standard deviation Layer 25}] * 0.34 + [\text{Standard deviation Layer 23}] * 0.35 + [\text{Standard deviation Layer 22}] * -0.11 + [\text{Standard deviation Layer 20}] * -0.14 + [\text{Standard deviation Layer 2}] * 0 + [\text{Standard deviation Layer 19}] * 0.23 + [\text{Standard deviation Layer 18}] * -0.67 + [\text{Standard deviation Layer 17}] * -0.39 + [\text{Standard deviation Layer 16}] * 0.01 + [\text{Standard deviation Layer 15}] * 0 + [\text{Standard deviation Layer 12}] * 0 + [\text{Standard deviation Layer 10}] * -0.01 + [\text{Mean Layer 25}] * 0.11 + [\text{Mean Layer 23}] * -0.15 + [\text{Mean Layer 19}] * 0.01 + [\text{Mean Layer 18}] * -0.1 + [\text{Mean Layer 17}] * -0.78 + [\text{Mean Layer 16}] * 0 + [\text{Mean Layer 11}] * 0$

Class Solo Exposto :

$5.65 + [\text{AC6}] * 0 + [\text{AC2}] * -8.59 + [\text{AC1}] * -56.7 + [\text{Standard deviation Layer 3}] * 0 + [\text{Standard deviation Layer 24}] * 0.79 + [\text{Standard deviation Layer 22}] * -0.17 + [\text{Standard deviation Layer 21}] * -0.17 + [\text{Standard deviation Layer 2}] * -0.01 + [\text{Standard deviation Layer 17}] * -0.66 + [\text{Standard deviation Layer 15}] * -0.01 + [\text{Standard deviation Layer 14}] * 0 + [\text{Standard deviation Layer 11}] * -0.01 + [\text{Standard deviation Layer 10}] * 0.01 + [\text{Standard deviation Layer 1}] * -0.02 + [\text{Mean Layer 25}] * -0.47 + [\text{Mean Layer 22}] * -0.03 + [\text{Mean Layer 21}] * 0.18 + [\text{Mean Layer 18}] * -0.57 + [\text{Mean Layer 17}] * -1.02 + [\text{Mean Layer 15}] * 0 + [\text{Mean Layer 14}] * 0 + [\text{Mean Layer 13}] * 0$

Class Lago :

$38.27 + [\text{NDVI_11}] * 51.66 + [\text{AC5}] * 0 + [\text{AC17}] * 0 + [\text{AC16}] * 6.37 + [\text{AC10}] * -11.31 + [\text{Standard deviation Layer 5}] * -0.01 + [\text{Standard deviation Layer 3}] * -0.02 + [\text{Standard deviation Layer 24}] * -17.94 + [\text{Standard deviation Layer 20}] * 2.24 + [\text{Standard deviation Layer 16}] * -0.05 + [\text{Standard deviation Layer 14}] * 0.07 + [\text{Mean Layer 25}] * -4.14 + [\text{Mean Layer 23}] * 0.56 + [\text{Mean Layer 17}] * -2.5 + [\text{Mean Layer 13}] * 0.03$

Class Vegetação Arbórea :

$-50.43 + [\text{SAVI}] * 34.12 + [\text{NDVI_3}] * -52.33 + [\text{NDVI_4}] * 34.01 + [\text{NDVI_2}] * 11.49 + [\text{NDVI_11}] * 31.03 + [\text{AC9}] * -4.75 + [\text{AC7}] * -149.07 + [\text{AC3}] * 0 + [\text{AC16}] * -4.09 + [\text{AC15}] * 37.54 + [\text{AC14}] * 9.74 + [\text{AC12}] * -5.54 + [\text{AC11}] * -67.68 + [\text{Standard deviation Layer 8}] * 0.03 + [\text{Standard deviation Layer 7}] * 0.01 + [\text{Standard deviation Layer 6}] * 0.01 + [\text{Standard deviation Layer 5}] * 0 + [\text{Standard deviation Layer 3}] * -0.02 + [\text{Standard deviation Layer 25}] * 1.4 + [\text{Standard deviation Layer 20}] * 2.03 +$

$[Standard\ deviation\ Layer\ 2] * -0.13 + [Standard\ deviation\ Layer\ 17] * 1.12 + [Standard\ deviation\ Layer\ 15] * 0.13 + [Standard\ deviation\ Layer\ 14] * 0.04 + [Standard\ deviation\ Layer\ 11] * 0.01 + [Standard\ deviation\ Layer\ 1] * 0.14 + [Mean\ Layer\ 5] * 0 + [Mean\ Layer\ 25] * -0.18 + [Mean\ Layer\ 23] * -0.16 + [Mean\ Layer\ 15] * 0.05 + [Mean\ Layer\ 12] * 0.01$

Class Pavimentação Não Viária :

$-89.85 + [NDVI_3] * -24.45 + [NDVI_2] * -53.86 + [NDVI_12] * 4.23 + [AC9] * 10.4 + [AC3] * 0 + [AC16] * 16.44 + [Standard\ deviation\ Layer\ 4] * 0 + [Standard\ deviation\ Layer\ 3] * 0 + [Standard\ deviation\ Layer\ 25] * 0.85 + [Standard\ deviation\ Layer\ 22] * -2.42 + [Standard\ deviation\ Layer\ 20] * -0.2 + [Standard\ deviation\ Layer\ 18] * 0.29 + [Standard\ deviation\ Layer\ 17] * 1.12 + [Standard\ deviation\ Layer\ 16] * -0.01 + [Standard\ deviation\ Layer\ 15] * -0.01 + [Standard\ deviation\ Layer\ 14] * -0.02 + [Standard\ deviation\ Layer\ 12] * 0 + [Standard\ deviation\ Layer\ 11] * 0 + [Standard\ deviation\ Layer\ 10] * 0 + [Standard\ deviation\ Layer\ 1] * 0 + [Mean\ Layer\ 25] * -0.34 + [Mean\ Layer\ 21] * -0.08 + [Mean\ Layer\ 19] * 0.12 + [Mean\ Layer\ 17] * -0.67 + [Mean\ Layer\ 14] * 0 + [Mean\ Layer\ 12] * 0$

Class Coberturas Metálicas :

$-92.96 + [SAVI] * -8.02 + [NDVI_2] * -18.51 + [AC7] * 17.66 + [AC2] * 4.34 + [AC16] * 9.07 + [AC14] * -13.76 + [Standard\ deviation\ Layer\ 8] * 0 + [Standard\ deviation\ Layer\ 6] * 0 + [Standard\ deviation\ Layer\ 5] * 0 + [Standard\ deviation\ Layer\ 4] * 0 + [Standard\ deviation\ Layer\ 25] * 0.35 + [Standard\ deviation\ Layer\ 21] * -0.1 + [Standard\ deviation\ Layer\ 2] * 0 + [Standard\ deviation\ Layer\ 18] * -0.25 + [Standard\ deviation\ Layer\ 17] * -0.58 + [Standard\ deviation\ Layer\ 16] * 0 + [Standard\ deviation\ Layer\ 14] * 0 + [Standard\ deviation\ Layer\ 12] * 0 + [Mean\ Layer\ 25] * 0.19 + [Mean\ Layer\ 23] * 0.1 + [Mean\ Layer\ 22] * 0.05 + [Mean\ Layer\ 18] * 0.08 + [Mean\ Layer\ 17] * -0.43 + [Mean\ Layer\ 16] * 0 + [Mean\ Layer\ 13] * 0 + [Mean\ Layer\ 10] * 0$

Class Vegetação Rasteira :

$139.24 + [AC9] * -219.3 + [AC2] * -34.15 + [Standard\ deviation\ Layer\ 25] * 4.95 + [Standard\ deviation\ Layer\ 23] * -2.82 + [Standard\ deviation\ Layer\ 20] * -1.3 + [Standard\ deviation\ Layer\ 19] * 3.11 + [Standard\ deviation\ Layer\ 15] * -0.01 + [Standard\ deviation\ Layer\ 14] * -0.01 + [Standard\ deviation\ Layer\ 13] * -0.01 + [Mean\ Layer\ 3] * 0 + [Mean\ Layer\ 25] * -0.14 + [Mean\ Layer\ 22] * 0.1 + [Mean\ Layer\ 21] * 0.25 + [Mean\ Layer\ 18] * -0.09 + [Mean\ Layer\ 17] * -0.47 + [Mean\ Layer\ 14] * 0$

Class Coberturas Diversas :

$-98.59 + [NDVI_3] * 0.86 + [NDVI_2] * 9.64 + [NDVI_12] * -1.56 + [AC3] * 0 + [AC16] * -2.68 + [Standard\ deviation\ Layer\ 8] * 0 + [Standard\ deviation\ Layer\ 7] * 0 + [Standard\ deviation\ Layer\ 6] * 0 + [Standard\ deviation\ Layer\ 4] * 0 + [Standard\ deviation\ Layer\ 3] * 0 + [Standard\ deviation\ Layer\ 25] * -0.92 + [Standard\ deviation\ Layer\ 24] * -0.08 + [Standard\ deviation\ Layer\ 20] * 0.13 + [Standard\ deviation\ Layer\ 2] * 0 + [Standard\ deviation\ Layer\ 19] * 0.02 + [Standard\ deviation\ Layer\ 17] * 0.36 + [Standard\ deviation\ Layer\ 16] * 0.01 + [Standard\ deviation\ Layer\ 14] * 0 + [Standard\ deviation\ Layer\ 12] * 0 + [Standard\ deviation\ Layer\ 11] * 0 + [Standard\ deviation\ Layer\ 10] * 0 + [Standard\ deviation\ Layer\ 1] * 0 + [Mean\ Layer\ 25] * 0.04 + [Mean\ Layer\ 23] * 0.02 + [Mean\ Layer\ 20] * -0.06 + [Mean\ Layer\ 17] * 0.38 + [Mean\ Layer\ 15] * 0 + [Mean\ Layer\ 14] * 0$

Class Pavimentação Viária :

$$\begin{aligned} & -91.83 + [\text{NDVI_2}] * -6.65 + [\text{AC6}] * 0 + [\text{Standard deviation Layer 8}] * 0 + \\ & [\text{Standard deviation Layer 7}] * 0 + [\text{Standard deviation Layer 6}] * 0 + [\text{Standard deviation Layer 5}] * 0 + \\ & [\text{Standard deviation Layer 4}] * 0 + [\text{Standard deviation Layer 3}] * 0 + [\text{Standard deviation Layer 25}] * 0.12 + [\text{Standard deviation Layer 23}] * \\ & 0.18 + [\text{Standard deviation Layer 21}] * 0.08 + [\text{Standard deviation Layer 20}] * -0.3 + \\ & [\text{Standard deviation Layer 19}] * -0.05 + [\text{Standard deviation Layer 18}] * 0.16 + \\ & [\text{Standard deviation Layer 17}] * 0.25 + [\text{Standard deviation Layer 16}] * -0.01 + \\ & [\text{Standard deviation Layer 15}] * 0 + [\text{Standard deviation Layer 14}] * 0.01 + [\text{Standard deviation Layer 12}] * 0 + \\ & [\text{Mean Layer 25}] * -0.52 + [\text{Mean Layer 23}] * -0.04 + [\text{Mean Layer 22}] * -0.19 + [\text{Mean Layer 19}] * 0.01 + \\ & [\text{Mean Layer 18}] * -0.03 + [\text{Mean Layer 17}] * 0.12 + [\text{Mean Layer 15}] * 0 + [\text{Mean Layer 14}] * 0 + \\ & [\text{Mean Layer 13}] * 0 + [\text{Mean Layer 10}] * 0 \end{aligned}$$

Class Piscina :

$$\begin{aligned} & -109.02 + [\text{SAVI}] * -20.45 + [\text{NDVI_3}] * 28.25 + [\text{NDVI_2}] * -17.92 + [\text{AC2}] * 7.63 + \\ & [\text{AC15}] * 3.33 + [\text{AC14}] * -14.48 + [\text{AC12}] * 6.94 + [\text{AC11}] * 1.54 + [\text{Standard deviation Layer 8}] * 0 + \\ & [\text{Standard deviation Layer 5}] * 0 + [\text{Standard deviation Layer 23}] * -0.13 + [\text{Standard deviation Layer 22}] * -3.7 + \\ & [\text{Standard deviation Layer 20}] * 1.2 + [\text{Standard deviation Layer 19}] * 0.44 + [\text{Standard deviation Layer 17}] * -3.25 + \\ & [\text{Standard deviation Layer 16}] * 0.07 + [\text{Standard deviation Layer 14}] * -0.02 + [\text{Standard deviation Layer 10}] * 0 + \\ & [\text{Mean Layer 25}] * -1.58 + [\text{Mean Layer 22}] * -0.17 + [\text{Mean Layer 20}] * -0.14 + [\text{Mean Layer 15}] * 0 \end{aligned}$$

LM_2:

Class Sombra :

$$\begin{aligned} & -55.25 + [\text{NDVI_12}] * 111.75 + [\text{AC8}] * -143.44 + [\text{AC7}] * -43.5 + [\text{AC5}] * 0 + [\text{AC17}] * \\ & 0.01 + [\text{AC16}] * 4.72 + [\text{Standard deviation Layer 22}] * -2.1 + [\text{Standard deviation Layer 21}] * -0.39 + \\ & [\text{Standard deviation Layer 19}] * 4 + [\text{Standard deviation Layer 18}] * 5.2 + [\text{Standard deviation Layer 15}] * -0.01 + \\ & [\text{Standard deviation Layer 11}] * 0.01 + [\text{Mean Layer 9}] * 0.01 + [\text{Mean Layer 7}] * 0 + [\text{Mean Layer 6}] * 0 + \\ & [\text{Mean Layer 4}] * 0 + [\text{Mean Layer 25}] * -0.11 + [\text{Mean Layer 21}] * -0.2 + [\text{Mean Layer 20}] * 0.17 + \\ & [\text{Mean Layer 14}] * 0.02 + [\text{Mean Layer 13}] * 0.01 \end{aligned}$$

Class Coberturas Cerâmicas :

$$\begin{aligned} & 132.42 + [\text{NDVI_3}] * -46.66 + [\text{NDVI_2}] * -174.65 + [\text{NDVI_12}] * 9.09 + [\text{NDVI_11}] * - \\ & 40.52 + [\text{AC4}] * -0.01 + [\text{AC14}] * 16.9 + [\text{AC12}] * -5.58 + [\text{AC11}] * -40.5 + [\text{AC1}] * - \\ & 246.56 + [\text{Standard deviation Layer 8}] * -0.01 + [\text{Standard deviation Layer 7}] * 0 + \\ & [\text{Standard deviation Layer 6}] * 0 + [\text{Standard deviation Layer 5}] * 0.01 + [\text{Standard deviation Layer 4}] * 0 + \\ & [\text{Standard deviation Layer 25}] * 0.93 + [\text{Standard deviation Layer 23}] * 0.82 + [\text{Standard deviation Layer 22}] * -0.11 + \\ & [\text{Standard deviation Layer 21}] * 0.12 + [\text{Standard deviation Layer 20}] * -0.36 + [\text{Standard deviation Layer 2}] * 0 + \\ & [\text{Standard deviation Layer 19}] * 0.48 + [\text{Standard deviation Layer 18}] * -0.91 + [\text{Standard deviation Layer 17}] * -1.91 + \\ & [\text{Standard deviation Layer 16}] * 0.03 + [\text{Standard deviation Layer 15}] * -0.02 + [\text{Standard deviation Layer 14}] * 0 + \\ & [\text{Standard deviation Layer 12}] * 0 + [\text{Standard deviation Layer 11}] * 0 + [\text{Standard deviation Layer 10}] * -0.01 + \\ & [\text{Mean Layer 5}] * 0 + [\text{Mean Layer 25}] * 0.11 + [\text{Mean Layer 23}] * -0.17 + [\text{Mean Layer 22}] * 0.11 + \\ & [\text{Mean Layer 19}] * 0.05 + [\text{Mean Layer 18}] * -0.1 + \end{aligned}$$

$[\text{Mean Layer 17}] * -1.21 + [\text{Mean Layer 16}] * 0 + [\text{Mean Layer 15}] * -0.03 + [\text{Mean Layer 14}] * 0 + [\text{Mean Layer 11}] * 0 + [\text{Mean Layer 10}] * 0$

Class Solo Exposto :

$124.77 + [\text{SAVI}] * -4.88 + [\text{NDVI_2}] * -89.32 + [\text{AC9}] * 25.69 + [\text{AC7}] * 6.26 + [\text{AC6}] * 0 + [\text{AC2}] * -18.21 + [\text{AC16}] * -6.32 + [\text{AC15}] * -28.2 + [\text{AC1}] * -112.15 + [\text{Standard deviation Layer 8}] * 0 + [\text{Standard deviation Layer 7}] * 0 + [\text{Standard deviation Layer 6}] * 0 + [\text{Standard deviation Layer 4}] * 0 + [\text{Standard deviation Layer 3}] * -0.01 + [\text{Standard deviation Layer 24}] * 3.02 + [\text{Standard deviation Layer 22}] * -1.03 + [\text{Standard deviation Layer 21}] * -1.33 + [\text{Standard deviation Layer 2}] * -0.02 + [\text{Standard deviation Layer 17}] * -0.91 + [\text{Standard deviation Layer 15}] * -0.03 + [\text{Standard deviation Layer 14}] * 0 + [\text{Standard deviation Layer 12}] * 0 + [\text{Standard deviation Layer 11}] * -0.03 + [\text{Standard deviation Layer 10}] * 0.01 + [\text{Standard deviation Layer 1}] * -0.02 + [\text{Mean Layer 3}] * 0 + [\text{Mean Layer 25}] * -0.95 + [\text{Mean Layer 24}] * 0 + [\text{Mean Layer 22}] * -0.19 + [\text{Mean Layer 21}] * 0.68 + [\text{Mean Layer 2}] * 0 + [\text{Mean Layer 18}] * -0.71 + [\text{Mean Layer 17}] * -2.62 + [\text{Mean Layer 16}] * 0 + [\text{Mean Layer 15}] * 0 + [\text{Mean Layer 14}] * 0 + [\text{Mean Layer 13}] * 0$

Class Lago :

$293.26 + [\text{NDVI_4}] * 0 + [\text{NDVI_11}] * 51.66 + [\text{AC6}] * 0.01 + [\text{AC5}] * 0 + [\text{AC17}] * 0 + [\text{AC16}] * 6.37 + [\text{AC15}] * -15.6 + [\text{AC12}] * 13.29 + [\text{AC10}] * -11.31 + [\text{AC1}] * -58.2 + [\text{Standard deviation Layer 8}] * 0 + [\text{Standard deviation Layer 6}] * 0 + [\text{Standard deviation Layer 5}] * -0.04 + [\text{Standard deviation Layer 3}] * -0.02 + [\text{Standard deviation Layer 24}] * -19.9 + [\text{Standard deviation Layer 22}] * -6.1 + [\text{Standard deviation Layer 21}] * -2.19 + [\text{Standard deviation Layer 20}] * 3.37 + [\text{Standard deviation Layer 2}] * -0.08 + [\text{Standard deviation Layer 18}] * -2.67 + [\text{Standard deviation Layer 16}] * -0.66 + [\text{Standard deviation Layer 14}] * 0.1 + [\text{Standard deviation Layer 1}] * 0.02 + [\text{Mean Layer 5}] * 0 + [\text{Mean Layer 3}] * 0 + [\text{Mean Layer 25}] * -9.57 + [\text{Mean Layer 23}] * 0.56 + [\text{Mean Layer 21}] * -2.06 + [\text{Mean Layer 20}] * 0 + [\text{Mean Layer 18}] * 1.75 + [\text{Mean Layer 17}] * -2.5 + [\text{Mean Layer 15}] * -0.02 + [\text{Mean Layer 13}] * 0.08 + [\text{Mean Layer 12}] * 0$

Class Vegetação Arbórea :

$-311.02 + [\text{SAVI}] * 26.92 + [\text{NDVI_3}] * -52.33 + [\text{NDVI_4}] * 34.01 + [\text{NDVI_2}] * 11.49 + [\text{NDVI_11}] * 31.03 + [\text{AC9}] * -4.75 + [\text{AC7}] * -149.07 + [\text{AC3}] * 0 + [\text{AC16}] * -4.09 + [\text{AC15}] * 37.54 + [\text{AC14}] * 9.74 + [\text{AC12}] * -5.54 + [\text{AC11}] * -67.68 + [\text{Standard deviation Layer 8}] * 0.01 + [\text{Standard deviation Layer 7}] * 0.01 + [\text{Standard deviation Layer 6}] * 0.01 + [\text{Standard deviation Layer 5}] * 0 + [\text{Standard deviation Layer 3}] * -0.02 + [\text{Standard deviation Layer 25}] * 1.4 + [\text{Standard deviation Layer 20}] * 1.11 + [\text{Standard deviation Layer 2}] * -0.02 + [\text{Standard deviation Layer 17}] * 1.12 + [\text{Standard deviation Layer 15}] * 0.13 + [\text{Standard deviation Layer 14}] * 0.04 + [\text{Standard deviation Layer 11}] * 0.01 + [\text{Mean Layer 5}] * 0 + [\text{Mean Layer 3}] * 0 + [\text{Mean Layer 25}] * -0.18 + [\text{Mean Layer 23}] * -0.16 + [\text{Mean Layer 12}] * 0.01$

Class Pavimentação Não Viária :

$-158.51 + [\text{NDVI_3}] * -41.22 + [\text{NDVI_2}] * -281.14 + [\text{NDVI_12}] * 4.23 + [\text{AC9}] * 104.25 + [\text{AC3}] * 0 + [\text{AC16}] * 35.3 + [\text{AC14}] * 8.12 + [\text{AC12}] * -24.82 + [\text{Standard deviation Layer 8}] * 0 + [\text{Standard deviation Layer 7}] * 0 + [\text{Standard deviation Layer 5}] * 0 + [\text{Standard deviation Layer 4}] * 0 + [\text{Standard deviation Layer 3}] * 0 + [\text{Standard deviation Layer 25}] * 1.9 + [\text{Standard deviation Layer 23}] * 0.18 + [\text{Standard deviation}$

Layer 22] * -4.06 + [Standard deviation Layer 21] * -0.34 + [Standard deviation Layer 20] * -0.71 + [Standard deviation Layer 18] * 1.21 + [Standard deviation Layer 17] * 2.1 + [Standard deviation Layer 16] * -0.01 + [Standard deviation Layer 15] * -0.02 + [Standard deviation Layer 14] * -0.03 + [Standard deviation Layer 12] * 0 + [Standard deviation Layer 11] * 0 + [Standard deviation Layer 10] * 0 + [Standard deviation Layer 1] * 0.02 + [Mean Layer 25] * -0.91 + [Mean Layer 22] * 0.39 + [Mean Layer 21] * -0.08 + [Mean Layer 19] * 0.23 + [Mean Layer 18] * 0.02 + [Mean Layer 17] * -1.33 + [Mean Layer 16] * 0 + [Mean Layer 14] * 0 + [Mean Layer 12] * 0 + [Mean Layer 10] * 0

Class Coberturas Metálicas :

-1129.29 + [SAVI] * -102.55 + [NDVI_2] * -551.37 + [AC9] * 368.87 + [AC7] * 17.66 + [AC2] * 133.35 + [AC18] * 0 + [AC16] * 87.21 + [AC14] * -13.76 + [AC12] * -0.7 + [AC1] * 545.77 + [Standard deviation Layer 8] * 0 + [Standard deviation Layer 6] * 0 + [Standard deviation Layer 5] * 0 + [Standard deviation Layer 4] * 0 + [Standard deviation Layer 3] * 0 + [Standard deviation Layer 25] * 0.35 + [Standard deviation Layer 23] * 3.16 + [Standard deviation Layer 22] * 0.11 + [Standard deviation Layer 21] * 0.06 + [Standard deviation Layer 20] * 0.38 + [Standard deviation Layer 2] * 0 + [Standard deviation Layer 19] * 0.6 + [Standard deviation Layer 18] * -0.25 + [Standard deviation Layer 17] * -0.72 + [Standard deviation Layer 16] * 0 + [Standard deviation Layer 14] * 0 + [Standard deviation Layer 13] * 0 + [Standard deviation Layer 12] * 0 + [Standard deviation Layer 10] * 0.01 + [Standard deviation Layer 1] * 0.01 + [Mean Layer 5] * 0 + [Mean Layer 25] * 0.4 + [Mean Layer 23] * 0.12 + [Mean Layer 22] * 0.06 + [Mean Layer 21] * -1.63 + [Mean Layer 20] * 0.01 + [Mean Layer 19] * -0.09 + [Mean Layer 18] * 0.09 + [Mean Layer 17] * -0.6 + [Mean Layer 16] * 0 + [Mean Layer 15] * 0 + [Mean Layer 14] * 0.09 + [Mean Layer 13] * 0.01 + [Mean Layer 12] * 0 + [Mean Layer 11] * 0 + [Mean Layer 10] * 0

Class Vegetação Rasteira :

86.38 + [AC9] * -219.3 + [AC2] * -34.15 + [AC16] * -1.54 + [AC15] * -20.08 + [AC1] * -34.36 + [Standard deviation Layer 7] * 0 + [Standard deviation Layer 5] * 0.01 + [Standard deviation Layer 3] * -0.01 + [Standard deviation Layer 25] * 10.63 + [Standard deviation Layer 23] * -5.4 + [Standard deviation Layer 22] * 0.42 + [Standard deviation Layer 21] * -0.65 + [Standard deviation Layer 20] * -1.3 + [Standard deviation Layer 19] * 3.88 + [Standard deviation Layer 15] * -0.02 + [Standard deviation Layer 14] * -0.07 + [Standard deviation Layer 13] * -0.01 + [Standard deviation Layer 12] * 0.02 + [Standard deviation Layer 10] * 0.01 + [Mean Layer 4] * 0 + [Mean Layer 3] * 0 + [Mean Layer 25] * -0.14 + [Mean Layer 22] * 0.1 + [Mean Layer 21] * 0.76 + [Mean Layer 19] * 0.05 + [Mean Layer 18] * -0.09 + [Mean Layer 17] * -0.81 + [Mean Layer 14] * -0.01

Class Coberturas Diversas :

-35.64 + [SAVI] * -64.17 + [NDVI_3] * 1.44 + [NDVI_4] * 2.46 + [NDVI_2] * -56.27 + [NDVI_12] * -1.56 + [NDVI_11] * -96.66 + [AC9] * 36.53 + [AC7] * 41.44 + [AC5] * 0 + [AC4] * 0.01 + [AC3] * 0 + [AC2] * 4.74 + [AC18] * 0 + [AC17] * 0 + [AC16] * -3.5 + [AC10] * 0.74 + [Standard deviation Layer 9] * 0 + [Standard deviation Layer 8] * 0.01 + [Standard deviation Layer 7] * 0 + [Standard deviation Layer 6] * 0 + [Standard deviation Layer 5] * 0 + [Standard deviation Layer 4] * 0 + [Standard deviation Layer 3] * 0 + [Standard deviation Layer 25] * -0.92 + [Standard deviation Layer 24] * -0.08 + [Standard deviation Layer 23] * -0.26 + [Standard deviation Layer

22] * -0.02 + [Standard deviation Layer 21] * -0.03 + [Standard deviation Layer 20] * 0.2 + [Standard deviation Layer 2] * 0 + [Standard deviation Layer 19] * 0.04 + [Standard deviation Layer 18] * -0.27 + [Standard deviation Layer 17] * 0.25 + [Standard deviation Layer 16] * 0.01 + [Standard deviation Layer 15] * 0 + [Standard deviation Layer 14] * -0.06 + [Standard deviation Layer 13] * 0 + [Standard deviation Layer 12] * 0 + [Standard deviation Layer 11] * 0 + [Standard deviation Layer 10] * 0 + [Standard deviation Layer 1] * 0.01 + [Mean Layer 4] * 0 + [Mean Layer 25] * 0.11 + [Mean Layer 24] * 0.03 + [Mean Layer 23] * 0.02 + [Mean Layer 21] * -0.02 + [Mean Layer 20] * -0.06 + [Mean Layer 19] * 0 + [Mean Layer 18] * 0.02 + [Mean Layer 17] * 0.39 + [Mean Layer 16] * 0 + [Mean Layer 15] * 0 + [Mean Layer 14] * -0.01 + [Mean Layer 12] * 0.01 + [Mean Layer 11] * 0

Class Pavimentação Viária :

-62.19 + [NDVI_4] * -8.19 + [NDVI_2] * -304.7 + [NDVI_11] * -100.55 + [AC9] * -2.96 + [AC7] * -14.22 + [AC6] * 0 + [AC4] * 0 + [AC3] * 0 + [AC14] * -4.8 + [AC12] * 1.42 + [Standard deviation Layer 9] * 0 + [Standard deviation Layer 8] * 0 + [Standard deviation Layer 7] * 0.01 + [Standard deviation Layer 6] * 0 + [Standard deviation Layer 5] * 0 + [Standard deviation Layer 4] * 0 + [Standard deviation Layer 3] * 0 + [Standard deviation Layer 25] * 0.12 + [Standard deviation Layer 23] * 0.08 + [Standard deviation Layer 22] * -0.01 + [Standard deviation Layer 21] * 0.03 + [Standard deviation Layer 20] * -0.36 + [Standard deviation Layer 2] * 0 + [Standard deviation Layer 19] * -0.05 + [Standard deviation Layer 18] * 0.44 + [Standard deviation Layer 17] * 0.45 + [Standard deviation Layer 16] * -0.01 + [Standard deviation Layer 15] * 0 + [Standard deviation Layer 14] * 0.01 + [Standard deviation Layer 13] * 0 + [Standard deviation Layer 12] * 0 + [Standard deviation Layer 11] * 0 + [Standard deviation Layer 10] * 0 + [Standard deviation Layer 1] * 0 + [Mean Layer 4] * 0 + [Mean Layer 25] * -0.44 + [Mean Layer 24] * 0.01 + [Mean Layer 23] * 0.05 + [Mean Layer 22] * -0.19 + [Mean Layer 19] * 0.01 + [Mean Layer 18] * -0.05 + [Mean Layer 17] * 0.19 + [Mean Layer 15] * 0 + [Mean Layer 14] * -0.01 + [Mean Layer 13] * 0 + [Mean Layer 10] * 0

Class Piscina :

-289.15 + [SAVI] * -44.36 + [NDVI_3] * 34.56 + [NDVI_2] * -52.38 + [AC7] * 7.95 + [AC6] * 0 + [AC2] * 10.83 + [AC15] * 3.33 + [AC14] * -30.78 + [AC12] * 16.27 + [AC11] * 1.54 + [Standard deviation Layer 8] * 0 + [Standard deviation Layer 5] * 0 + [Standard deviation Layer 23] * -0.13 + [Standard deviation Layer 22] * -6.63 + [Standard deviation Layer 20] * 1.69 + [Standard deviation Layer 19] * 0.73 + [Standard deviation Layer 17] * -4.65 + [Standard deviation Layer 16] * 0.12 + [Standard deviation Layer 14] * -0.03 + [Standard deviation Layer 13] * 0 + [Standard deviation Layer 10] * 0.01 + [Mean Layer 25] * -2.06 + [Mean Layer 22] * -0.3 + [Mean Layer 20] * -0.16 + [Mean Layer 17] * -0.1 + [Mean Layer 15] * 0 + [Mean Layer 13] * 0

LM_3:

Class Sombra :

-141.41 + [NDVI_12] * 111.75 + [AC8] * -143.44 + [AC7] * -43.5 + [AC5] * 0 + [AC17] * 0.01 + [AC16] * 4.72 + [Standard deviation Layer 22] * -2.1 + [Standard deviation Layer 21] * -0.39 + [Standard deviation Layer 19] * 4 + [Standard deviation Layer 18] * 5.2 + [Standard deviation Layer 15] * -0.01 + [Standard deviation Layer 11] * 0.01 + [Mean Layer 9] * 0.01 + [Mean Layer 7] * 0 + [Mean Layer 6] * 0 + [Mean Layer 4] *

0 + [Mean Layer 25] * -0.11 + [Mean Layer 21] * -0.2 + [Mean Layer 20] * 0.17 + [Mean Layer 14] * 0.02 + [Mean Layer 13] * 0.01

Class Coberturas Cerâmicas :

158.1 + [NDVI_3] * -46.66 + [NDVI_2] * -174.65 + [NDVI_12] * 18.6 + [NDVI_11] * -30.04 + [AC14] * 16.9 + [AC12] * -5.58 + [AC11] * -54.5 + [AC1] * -126.71 + [Standard deviation Layer 8] * -0.02 + [Standard deviation Layer 7] * 0 + [Standard deviation Layer 6] * 0 + [Standard deviation Layer 5] * 0.01 + [Standard deviation Layer 4] * -0.01 + [Standard deviation Layer 25] * 4.68 + [Standard deviation Layer 23] * 0.82 + [Standard deviation Layer 22] * -1.29 + [Standard deviation Layer 21] * 0.57 + [Standard deviation Layer 20] * -0.36 + [Standard deviation Layer 2] * 0.02 + [Standard deviation Layer 19] * 0.73 + [Standard deviation Layer 18] * -1.46 + [Standard deviation Layer 17] * -1.91 + [Standard deviation Layer 16] * 0.04 + [Standard deviation Layer 15] * -0.03 + [Standard deviation Layer 14] * 0 + [Standard deviation Layer 13] * 0 + [Standard deviation Layer 12] * 0 + [Standard deviation Layer 11] * 0 + [Standard deviation Layer 10] * -0.03 + [Mean Layer 5] * 0 + [Mean Layer 3] * 0 + [Mean Layer 25] * -0.01 + [Mean Layer 23] * -0.32 + [Mean Layer 22] * 0.11 + [Mean Layer 21] * -0.32 + [Mean Layer 19] * 0.05 + [Mean Layer 18] * -0.4 + [Mean Layer 17] * -1.54 + [Mean Layer 16] * 0 + [Mean Layer 14] * 0 + [Mean Layer 11] * 0 + [Mean Layer 10] * 0

Class Solo Exposto :

334.18 + [SAVI] * -11.9 + [NDVI_2] * -100.59 + [AC9] * 25.69 + [AC7] * 6.26 + [AC6] * 0 + [AC5] * 0 + [AC2] * -18.21 + [AC16] * -6.32 + [AC15] * -28.2 + [AC1] * -182.78 + [Standard deviation Layer 8] * 0 + [Standard deviation Layer 7] * -0.02 + [Standard deviation Layer 6] * 0 + [Standard deviation Layer 5] * 0 + [Standard deviation Layer 4] * 0.01 + [Standard deviation Layer 3] * -0.02 + [Standard deviation Layer 25] * 0.28 + [Standard deviation Layer 24] * 3.02 + [Standard deviation Layer 22] * -1.55 + [Standard deviation Layer 21] * -2.23 + [Standard deviation Layer 20] * -0.22 + [Standard deviation Layer 2] * -0.02 + [Standard deviation Layer 19] * -0.29 + [Standard deviation Layer 18] * 1.88 + [Standard deviation Layer 17] * -0.91 + [Standard deviation Layer 15] * -0.04 + [Standard deviation Layer 14] * 0.01 + [Standard deviation Layer 13] * -0.01 + [Standard deviation Layer 12] * 0 + [Standard deviation Layer 11] * -0.04 + [Standard deviation Layer 10] * 0.03 + [Standard deviation Layer 1] * -0.03 + [Mean Layer 8] * 0 + [Mean Layer 3] * 0 + [Mean Layer 25] * -1.13 + [Mean Layer 23] * -0.03 + [Mean Layer 22] * -0.21 + [Mean Layer 21] * 1.34 + [Mean Layer 20] * 0.03 + [Mean Layer 2] * 0 + [Mean Layer 18] * -0.71 + [Mean Layer 17] * -4.02 + [Mean Layer 16] * 0 + [Mean Layer 15] * 0 + [Mean Layer 14] * 0 + [Mean Layer 13] * -0.01

Class Lago :

204.99 + [NDVI_4] * 0 + [NDVI_11] * 51.66 + [AC6] * 0.01 + [AC5] * 0 + [AC17] * 0 + [AC16] * 6.37 + [AC15] * -15.6 + [AC10] * -11.31 + [AC1] * -58.2 + [Standard deviation Layer 8] * 0 + [Standard deviation Layer 6] * 0 + [Standard deviation Layer 5] * -0.04 + [Standard deviation Layer 3] * -0.02 + [Standard deviation Layer 24] * -19.9 + [Standard deviation Layer 22] * -6.1 + [Standard deviation Layer 21] * -2.19 + [Standard deviation Layer 20] * 3.37 + [Standard deviation Layer 2] * -0.08 + [Standard deviation Layer 18] * -2.67 + [Standard deviation Layer 16] * -0.66 + [Standard deviation Layer 14] * 0.1 + [Standard deviation Layer 1] * -0.02 + [Mean Layer 5] * 0 + [Mean Layer 3] * 0 + [Mean Layer 25] * -9.57 + [Mean Layer 23] * 0.56 + [Mean

Layer 21] * -2.06 + [Mean Layer 20] * 0 + [Mean Layer 17] * -2.5 + [Mean Layer 15] * -0.02 + [Mean Layer 13] * 0.08 + [Mean Layer 12] * 0

Class Vegetação Arbórea :

-397.19 + [SAVI] * 26.92 + [NDVI_3] * -52.33 + [NDVI_4] * 34.01 + [NDVI_2] * 11.49 + [NDVI_11] * 31.03 + [AC9] * -4.75 + [AC7] * -149.07 + [AC3] * 0 + [AC16] * -4.09 + [AC15] * 37.54 + [AC14] * 9.74 + [AC12] * -5.54 + [AC11] * -67.68 + [Standard deviation Layer 8] * 0.01 + [Standard deviation Layer 7] * 0.01 + [Standard deviation Layer 6] * 0.01 + [Standard deviation Layer 5] * 0 + [Standard deviation Layer 3] * -0.02 + [Standard deviation Layer 25] * 1.4 + [Standard deviation Layer 20] * 1.11 + [Standard deviation Layer 2] * -0.02 + [Standard deviation Layer 17] * 1.12 + [Standard deviation Layer 15] * 0.13 + [Standard deviation Layer 14] * 0.04 + [Standard deviation Layer 11] * 0.01 + [Mean Layer 5] * 0 + [Mean Layer 3] * 0 + [Mean Layer 25] * -0.18 + [Mean Layer 23] * -0.16 + [Mean Layer 12] * 0.01

Class Pavimentação Não Viária :

-287.06 + [NDVI_3] * -43.12 + [NDVI_2] * -287.53 + [NDVI_12] * 4.23 + [NDVI_11] * -28.66 + [AC9] * 119.42 + [AC7] * 92.32 + [AC5] * 0 + [AC3] * 0 + [AC2] * 238.34 + [AC16] * 35.3 + [AC14] * 51.97 + [AC12] * -11.8 + [Standard deviation Layer 8] * 0 + [Standard deviation Layer 7] * 0 + [Standard deviation Layer 5] * -0.01 + [Standard deviation Layer 4] * 0 + [Standard deviation Layer 3] * -0.01 + [Standard deviation Layer 25] * 2.2 + [Standard deviation Layer 23] * 0.18 + [Standard deviation Layer 22] * -16.58 + [Standard deviation Layer 21] * -0.48 + [Standard deviation Layer 20] * -0.71 + [Standard deviation Layer 19] * 0.17 + [Standard deviation Layer 18] * 3.33 + [Standard deviation Layer 17] * 3.38 + [Standard deviation Layer 16] * -0.02 + [Standard deviation Layer 15] * -0.04 + [Standard deviation Layer 14] * -0.04 + [Standard deviation Layer 13] * 0.01 + [Standard deviation Layer 12] * 0 + [Standard deviation Layer 11] * 0 + [Standard deviation Layer 10] * 0 + [Standard deviation Layer 1] * 0.02 + [Mean Layer 25] * 0.77 + [Mean Layer 23] * -0.03 + [Mean Layer 22] * 0.56 + [Mean Layer 21] * -1.44 + [Mean Layer 20] * -0.14 + [Mean Layer 19] * 0.25 + [Mean Layer 18] * 4.64 + [Mean Layer 17] * -1.66 + [Mean Layer 16] * 0 + [Mean Layer 15] * 0 + [Mean Layer 14] * 0 + [Mean Layer 12] * 0 + [Mean Layer 10] * -0.01

Class Coberturas Metálicas :

-1464.22 + [SAVI] * -102.55 + [NDVI_2] * -551.37 + [AC9] * 635.34 + [AC7] * 17.66 + [AC2] * 133.35 + [AC18] * 0 + [AC16] * 97.52 + [AC14] * -13.76 + [AC12] * -0.7 + [AC1] * 600.71 + [Standard deviation Layer 8] * 0 + [Standard deviation Layer 6] * 0 + [Standard deviation Layer 5] * 0 + [Standard deviation Layer 4] * 0 + [Standard deviation Layer 3] * 0 + [Standard deviation Layer 25] * 0.35 + [Standard deviation Layer 23] * 3.16 + [Standard deviation Layer 22] * 0.11 + [Standard deviation Layer 21] * 0.06 + [Standard deviation Layer 20] * 0.38 + [Standard deviation Layer 2] * 0 + [Standard deviation Layer 19] * 0.6 + [Standard deviation Layer 18] * -0.25 + [Standard deviation Layer 17] * -0.72 + [Standard deviation Layer 16] * 0 + [Standard deviation Layer 14] * 0 + [Standard deviation Layer 13] * 0 + [Standard deviation Layer 12] * 0 + [Standard deviation Layer 10] * 0.01 + [Standard deviation Layer 1] * 0.01 + [Mean Layer 5] * 0 + [Mean Layer 25] * 0.73 + [Mean Layer 23] * 0.12 + [Mean Layer 22] * 0.06 + [Mean Layer 21] * -1.63 + [Mean Layer 20] * 0.01 + [Mean Layer 19] * -0.09 + [Mean Layer 18] * 0.09 + [Mean Layer 17] * -0.6 + [Mean Layer 16] * 0 +

[Mean Layer 15] * 0 + [Mean Layer 14] * 0.09 + [Mean Layer 13] * 0.01 + [Mean Layer 12] * 0 + [Mean Layer 11] * -0.01 + [Mean Layer 10] * 0

Class Vegetação Rasteira :

0.21 + [AC9] * -219.3 + [AC2] * -34.15 + [AC16] * -1.54 + [AC15] * -20.08 + [AC1] * -34.36 + [Standard deviation Layer 7] * 0 + [Standard deviation Layer 5] * 0.01 + [Standard deviation Layer 3] * -0.01 + [Standard deviation Layer 25] * 10.63 + [Standard deviation Layer 23] * -5.4 + [Standard deviation Layer 22] * 0.42 + [Standard deviation Layer 21] * -0.65 + [Standard deviation Layer 20] * -1.3 + [Standard deviation Layer 19] * 3.88 + [Standard deviation Layer 15] * -0.02 + [Standard deviation Layer 14] * -0.07 + [Standard deviation Layer 13] * -0.01 + [Standard deviation Layer 12] * 0.02 + [Standard deviation Layer 10] * 0.01 + [Mean Layer 4] * 0 + [Mean Layer 3] * 0 + [Mean Layer 25] * -0.14 + [Mean Layer 22] * 0.1 + [Mean Layer 21] * 0.76 + [Mean Layer 19] * 0.05 + [Mean Layer 18] * -0.09 + [Mean Layer 17] * -0.81 + [Mean Layer 14] * -0.01

Class Coberturas Diversas :

-79.47 + [SAVI] * -64.17 + [NDVI_3] * 2.65 + [NDVI_4] * 2.46 + [NDVI_2] * -56.27 + [NDVI_12] * -1.56 + [NDVI_11] * -96.66 + [AC9] * 36.53 + [AC7] * 41.44 + [AC5] * 0 + [AC3] * 0 + [AC2] * 20.43 + [AC18] * 0 + [AC17] * 0 + [AC16] * -3.83 + [AC14] * -8.43 + [AC12] * -0.69 + [AC10] * 0.74 + [AC1] * 14.46 + [Standard deviation Layer 9] * 0 + [Standard deviation Layer 8] * 0.01 + [Standard deviation Layer 7] * 0 + [Standard deviation Layer 6] * 0 + [Standard deviation Layer 5] * 0 + [Standard deviation Layer 4] * 0 + [Standard deviation Layer 3] * 0 + [Standard deviation Layer 25] * -1.09 + [Standard deviation Layer 24] * -0.1 + [Standard deviation Layer 23] * -0.26 + [Standard deviation Layer 22] * -0.02 + [Standard deviation Layer 21] * -0.03 + [Standard deviation Layer 20] * 0.2 + [Standard deviation Layer 2] * -0.01 + [Standard deviation Layer 19] * 0.57 + [Standard deviation Layer 18] * -0.61 + [Standard deviation Layer 17] * 0.57 + [Standard deviation Layer 16] * 0.04 + [Standard deviation Layer 15] * 0 + [Standard deviation Layer 14] * -0.01 + [Standard deviation Layer 13] * 0 + [Standard deviation Layer 12] * 0 + [Standard deviation Layer 11] * -0.01 + [Standard deviation Layer 10] * 0 + [Standard deviation Layer 1] * 0.01 + [Mean Layer 3] * 0 + [Mean Layer 25] * 0.15 + [Mean Layer 24] * 0.09 + [Mean Layer 23] * 0.02 + [Mean Layer 21] * -0.28 + [Mean Layer 20] * -0.09 + [Mean Layer 19] * 0 + [Mean Layer 18] * 0.03 + [Mean Layer 17] * 0.41 + [Mean Layer 16] * 0 + [Mean Layer 15] * 0 + [Mean Layer 14] * -0.01 + [Mean Layer 12] * 0 + [Mean Layer 11] * 0

Class Pavimentação Viária :

20.41 + [NDVI_4] * -8.19 + [NDVI_2] * -304.7 + [NDVI_11] * -100.55 + [AC9] * -2.96 + [AC7] * -1.44 + [AC6] * 0 + [AC4] * 0 + [AC3] * 0 + [AC16] * 0.34 + [AC14] * 3.64 + [AC12] * -3.96 + [AC10] * -1.4 + [AC1] * -13.75 + [Standard deviation Layer 9] * 0 + [Standard deviation Layer 8] * 0 + [Standard deviation Layer 7] * 0.01 + [Standard deviation Layer 6] * 0 + [Standard deviation Layer 5] * 0 + [Standard deviation Layer 4] * 0 + [Standard deviation Layer 3] * 0 + [Standard deviation Layer 25] * 0.12 + [Standard deviation Layer 24] * 0.02 + [Standard deviation Layer 23] * 0.08 + [Standard deviation Layer 22] * 0.03 + [Standard deviation Layer 21] * 0.03 + [Standard deviation Layer 20] * -0.36 + [Standard deviation Layer 2] * 0 + [Standard deviation Layer 19] * -0.54 + [Standard deviation Layer 18] * 0.78 + [Standard deviation Layer 17] * 0.17 + [Standard deviation Layer 16] * -0.03 + [Standard deviation Layer 15] * 0

+ [Standard deviation Layer 14] * 0.01 + [Standard deviation Layer 13] * 0 +
 [Standard deviation Layer 12] * 0 + [Standard deviation Layer 11] * 0.01 + [Standard
 deviation Layer 10] * 0 + [Standard deviation Layer 1] * 0 + [Mean Layer 3] * 0 +
 [Mean Layer 25] * -0.61 + [Mean Layer 24] * -0.05 + [Mean Layer 23] * 0.05 + [Mean
 Layer 22] * -0.19 + [Mean Layer 21] * 0.35 + [Mean Layer 19] * 0.01 + [Mean Layer 18]
 * -0.07 + [Mean Layer 17] * 0.19 + [Mean Layer 16] * 0 + [Mean Layer 15] * 0 +
 [Mean Layer 14] * -0.01 + [Mean Layer 13] * 0 + [Mean Layer 10] * 0

Class Piscina :

-375.31 + [SAVI] * -44.36 + [NDVI_3] * 34.56 + [NDVI_2] * -52.38 + [AC7] * 7.95 +
 [AC6] * 0 + [AC2] * 10.83 + [AC15] * 3.33 + [AC14] * -30.78 + [AC12] * 16.27 +
 [AC11] * 1.54 + [Standard deviation Layer 8] * 0 + [Standard deviation Layer 5] * 0
 + [Standard deviation Layer 23] * -0.13 + [Standard deviation Layer 22] * -6.63 +
 [Standard deviation Layer 20] * 1.69 + [Standard deviation Layer 19] * 0.73 + [Standard
 deviation Layer 17] * -4.65 + [Standard deviation Layer 16] * 0.12 + [Standard deviation
 Layer 14] * -0.03 + [Standard deviation Layer 13] * 0 + [Standard deviation Layer 10]
 * 0.01 + [Mean Layer 25] * -2.06 + [Mean Layer 22] * -0.3 + [Mean Layer 20] * -0.16 +
 [Mean Layer 17] * -0.1 + [Mean Layer 15] * 0 + [Mean Layer 13] * 0

LM_4:

Class Sombra : -141.41 + [NDVI_12] * 111.75 + [AC8] * -143.44 + [AC7] * -43.5 +
 [AC5] * 0 + [AC17] * 0.01 + [AC16] * 4.72 + [Standard deviation Layer 22] * -2.1 +
 [Standard deviation Layer 21] * -0.39 + [Standard deviation Layer 19] * 4 + [Standard
 deviation Layer 18] * 5.2 + [Standard deviation Layer 15] * -0.01 + [Standard deviation
 Layer 11] * 0.01 + [Mean Layer 9] * 0.01 + [Mean Layer 7] * 0 + [Mean Layer 6] * 0
 + [Mean Layer 4] * 0 + [Mean Layer 25] * -0.11 + [Mean Layer 21] * -0.2 + [Mean
 Layer 20] * 0.17 + [Mean Layer 14] * 0.02 + [Mean Layer 13] * 0.01

Class Coberturas Cerâmicas :

80.6 + [NDVI_3] * -46.66 + [NDVI_2] * -174.65 + [NDVI_12] * 18.6 + [NDVI_11] * -40.52
 + [AC14] * 16.9 + [AC12] * -5.58 + [AC11] * -49.78 + [AC1] * -126.71 + [Standard
 deviation Layer 8] * -0.02 + [Standard deviation Layer 7] * 0 + [Standard deviation
 Layer 6] * 0 + [Standard deviation Layer 5] * 0.01 + [Standard deviation Layer 4] * 0
 + [Standard deviation Layer 3] * -0.01 + [Standard deviation Layer 25] * 3.01 +
 [Standard deviation Layer 23] * 0.82 + [Standard deviation Layer 22] * -0.44 +
 [Standard deviation Layer 21] * 0.12 + [Standard deviation Layer 20] * -0.36 +
 [Standard deviation Layer 2] * 0.01 + [Standard deviation Layer 19] * 0.73 + [Standard
 deviation Layer 18] * -0.91 + [Standard deviation Layer 17] * -1.91 + [Standard
 deviation Layer 16] * 0.04 + [Standard deviation Layer 15] * -0.03 + [Standard deviation
 Layer 14] * 0 + [Standard deviation Layer 13] * 0 + [Standard deviation Layer 12] *
 0 + [Standard deviation Layer 11] * 0 + [Standard deviation Layer 10] * -0.03 +
 [Mean Layer 9] * 0 + [Mean Layer 5] * 0 + [Mean Layer 25] * -0.01 + [Mean Layer
 23] * -0.27 + [Mean Layer 22] * 0.11 + [Mean Layer 21] * -0.32 + [Mean Layer 19] *
 0.05 + [Mean Layer 18] * -0.17 + [Mean Layer 17] * -1.54 + [Mean Layer 16] * 0 +
 [Mean Layer 14] * 0 + [Mean Layer 11] * 0 + [Mean Layer 10] * 0 + [Mean Layer
 1] * 0

Class Solo Exposto:

$140.73 + [\text{SAVI}] * -4.88 + [\text{NDVI_2}] * -89.32 + [\text{NDVI_11}] * 143.11 + [\text{AC9}] * 25.69 +$
 $[\text{AC7}] * 6.26 + [\text{AC6}] * 0 + [\text{AC2}] * -18.21 + [\text{AC16}] * -6.32 + [\text{AC15}] * -28.2 + [\text{AC1}] * -$
 $154.71 + [\text{Standard deviation Layer 8}] * 0 + [\text{Standard deviation Layer 7}] * 0 +$
 $[\text{Standard deviation Layer 6}] * 0 + [\text{Standard deviation Layer 5}] * 0 + [\text{Standard}$
 $\text{deviation Layer 4}] * 0 + [\text{Standard deviation Layer 3}] * -0.01 + [\text{Standard deviation}$
 $\text{Layer 25}] * 0.28 + [\text{Standard deviation Layer 24}] * 3.02 + [\text{Standard deviation Layer 22}]$
 $* -1.32 + [\text{Standard deviation Layer 21}] * -1.84 + [\text{Standard deviation Layer 2}] * -0.02 +$
 $[\text{Standard deviation Layer 17}] * -0.91 + [\text{Standard deviation Layer 15}] * -0.04 +$
 $[\text{Standard deviation Layer 14}] * 0 + [\text{Standard deviation Layer 12}] * 0 + [\text{Standard}$
 $\text{deviation Layer 11}] * -0.03 + [\text{Standard deviation Layer 10}] * 0.01 + [\text{Standard deviation}$
 $\text{Layer 1}] * -0.06 + [\text{Mean Layer 5}] * -0.01 + [\text{Mean Layer 3}] * 0 + [\text{Mean Layer 25}] * -$
 $2.44 + [\text{Mean Layer 23}] * -0.03 + [\text{Mean Layer 22}] * -0.21 + [\text{Mean Layer 21}] * 0.99 +$
 $[\text{Mean Layer 2}] * 0 + [\text{Mean Layer 18}] * -0.71 + [\text{Mean Layer 17}] * -3.36 + [\text{Mean}$
 $\text{Layer 16}] * 0 + [\text{Mean Layer 15}] * 0 + [\text{Mean Layer 14}] * 0 + [\text{Mean Layer 13}] * -$
 $0.01 + [\text{Mean Layer 10}] * 0.12$

Class Lago :

$204.99 + [\text{NDVI_4}] * 0 + [\text{NDVI_11}] * 51.66 + [\text{AC6}] * 0.01 + [\text{AC5}] * 0 + [\text{AC17}] * 0$
 $+ [\text{AC16}] * 6.37 + [\text{AC15}] * -15.6 + [\text{AC10}] * -11.31 + [\text{AC1}] * -58.2 + [\text{Standard}$
 $\text{deviation Layer 8}] * 0 + [\text{Standard deviation Layer 6}] * 0 + [\text{Standard deviation}$
 $\text{Layer 5}] * -0.04 + [\text{Standard deviation Layer 3}] * -0.02 + [\text{Standard deviation Layer 24}] *$
 $-19.9 + [\text{Standard deviation Layer 22}] * -6.1 + [\text{Standard deviation Layer 21}] * -2.19 +$
 $[\text{Standard deviation Layer 20}] * 3.37 + [\text{Standard deviation Layer 2}] * -0.08 + [\text{Standard}$
 $\text{deviation Layer 18}] * -2.67 + [\text{Standard deviation Layer 16}] * -0.66 + [\text{Standard}$
 $\text{deviation Layer 14}] * 0.1 + [\text{Standard deviation Layer 1}] * -0.02 + [\text{Mean Layer 5}] * 0$
 $+ [\text{Mean Layer 3}] * 0 + [\text{Mean Layer 25}] * -9.57 + [\text{Mean Layer 23}] * 0.56 + [\text{Mean}$
 $\text{Layer 21}] * -2.06 + [\text{Mean Layer 20}] * 0 + [\text{Mean Layer 17}] * -2.5 + [\text{Mean Layer 15}] *$
 $-0.02 + [\text{Mean Layer 13}] * 0.08 + [\text{Mean Layer 12}] * 0$

Class Vegetação Arbórea :

$-397.19 + [\text{SAVI}] * 26.92 + [\text{NDVI_3}] * -52.33 + [\text{NDVI_4}] * 34.01 + [\text{NDVI_2}] * 11.49 +$
 $[\text{NDVI_11}] * 31.03 + [\text{AC9}] * -4.75 + [\text{AC7}] * -149.07 + [\text{AC3}] * 0 + [\text{AC16}] * -4.09 +$
 $[\text{AC15}] * 37.54 + [\text{AC14}] * 9.74 + [\text{AC12}] * -5.54 + [\text{AC11}] * -67.68 + [\text{Standard}$
 $\text{deviation Layer 8}] * 0.01 + [\text{Standard deviation Layer 7}] * 0.01 + [\text{Standard deviation}$
 $\text{Layer 6}] * 0.01 + [\text{Standard deviation Layer 5}] * 0 + [\text{Standard deviation Layer 3}] * -$
 $0.02 + [\text{Standard deviation Layer 25}] * 1.4 + [\text{Standard deviation Layer 20}] * 1.11 +$
 $[\text{Standard deviation Layer 2}] * -0.02 + [\text{Standard deviation Layer 17}] * 1.12 + [\text{Standard}$
 $\text{deviation Layer 15}] * 0.13 + [\text{Standard deviation Layer 14}] * 0.04 + [\text{Standard deviation}$
 $\text{Layer 11}] * 0.01 + [\text{Mean Layer 5}] * 0 + [\text{Mean Layer 3}] * 0 + [\text{Mean Layer 25}] * -$
 $0.18 + [\text{Mean Layer 23}] * -0.16 + [\text{Mean Layer 12}] * 0.01$

Class Pavimentação Não Viária :

$625.71 + [\text{SAVI}] * -95.53 + [\text{NDVI_3}] * -268.06 + [\text{NDVI_4}] * -561.17 + [\text{NDVI_2}] * -$
 $287.53 + [\text{NDVI_12}] * 4.23 + [\text{AC9}] * 119.42 + [\text{AC6}] * 0 + [\text{AC3}] * 0 + [\text{AC16}] * 35.3$
 $+ [\text{AC14}] * 82.29 + [\text{AC12}] * -24.82 + [\text{Standard deviation Layer 9}] * 0.01 + [\text{Standard}$
 $\text{deviation Layer 8}] * 0 + [\text{Standard deviation Layer 7}] * 0 + [\text{Standard deviation}$
 $\text{Layer 5}] * 0.02 + [\text{Standard deviation Layer 4}] * 0 + [\text{Standard deviation Layer 3}] * -$
 $0.01 + [\text{Standard deviation Layer 25}] * 2.2 + [\text{Standard deviation Layer 23}] * 0.18 +$
 $[\text{Standard deviation Layer 22}] * -4.06 + [\text{Standard deviation Layer 21}] * -0.48 +$
 $[\text{Standard deviation Layer 20}] * -0.71 + [\text{Standard deviation Layer 19}] * 0.69 +$

[Standard deviation Layer 18] * 2.5 + [Standard deviation Layer 17] * -6.07 + [Standard deviation Layer 16] * 0 + [Standard deviation Layer 15] * -0.22 + [Standard deviation Layer 14] * -0.1 + [Standard deviation Layer 13] * 0.01 + [Standard deviation Layer 12] * 0 + [Standard deviation Layer 11] * 0 + [Standard deviation Layer 10] * 0 + [Standard deviation Layer 1] * 0.02 + [Mean Layer 3] * -0.01 + [Mean Layer 25] * -5.84 + [Mean Layer 23] * -4.46 + [Mean Layer 22] * 0.56 + [Mean Layer 21] * -0.08 + [Mean Layer 2] * -0.07 + [Mean Layer 19] * 0.25 + [Mean Layer 18] * 0.02 + [Mean Layer 17] * -1.66 + [Mean Layer 16] * 0 + [Mean Layer 14] * 0 + [Mean Layer 12] * 0 + [Mean Layer 10] * 0

Class Coberturas Metálicas :

-1462 + [SAVI] * -102.55 + [NDVI_2] * -551.37 + [AC9] * 680.65 + [AC7] * 17.66 + [AC2] * 133.35 + [AC18] * 0 + [AC16] * 97.52 + [AC14] * -13.76 + [AC12] * -0.7 + [AC1] * 635.4 + [Standard deviation Layer 8] * 0 + [Standard deviation Layer 6] * 0 + [Standard deviation Layer 5] * 0 + [Standard deviation Layer 4] * 0 + [Standard deviation Layer 3] * 0 + [Standard deviation Layer 25] * 0.35 + [Standard deviation Layer 23] * 3.16 + [Standard deviation Layer 22] * 0.11 + [Standard deviation Layer 21] * 0.06 + [Standard deviation Layer 20] * 0.38 + [Standard deviation Layer 2] * 0 + [Standard deviation Layer 19] * 0.6 + [Standard deviation Layer 18] * -0.25 + [Standard deviation Layer 17] * -0.72 + [Standard deviation Layer 16] * 0 + [Standard deviation Layer 14] * 0 + [Standard deviation Layer 13] * 0 + [Standard deviation Layer 12] * 0 + [Standard deviation Layer 10] * 0.01 + [Standard deviation Layer 1] * 0.01 + [Mean Layer 5] * 0 + [Mean Layer 25] * 0.73 + [Mean Layer 23] * 0.12 + [Mean Layer 22] * 0.06 + [Mean Layer 21] * -1.63 + [Mean Layer 20] * 0.01 + [Mean Layer 19] * -0.09 + [Mean Layer 18] * 0.09 + [Mean Layer 17] * -0.6 + [Mean Layer 16] * 0 + [Mean Layer 15] * 0 + [Mean Layer 14] * 0.1 + [Mean Layer 13] * 0.01 + [Mean Layer 12] * 0 + [Mean Layer 11] * -0.01 + [Mean Layer 10] * 0

Class Vegetação Rasteira :

0.21 + [AC9] * -219.3 + [AC2] * -34.15 + [AC16] * -1.54 + [AC15] * -20.08 + [AC1] * -34.36 + [Standard deviation Layer 7] * 0 + [Standard deviation Layer 5] * 0.01 + [Standard deviation Layer 3] * -0.01 + [Standard deviation Layer 25] * 10.63 + [Standard deviation Layer 23] * -5.4 + [Standard deviation Layer 22] * 0.42 + [Standard deviation Layer 21] * -0.65 + [Standard deviation Layer 20] * -1.3 + [Standard deviation Layer 19] * 3.88 + [Standard deviation Layer 15] * -0.02 + [Standard deviation Layer 14] * -0.07 + [Standard deviation Layer 13] * -0.01 + [Standard deviation Layer 12] * 0.02 + [Standard deviation Layer 10] * 0.01 + [Mean Layer 4] * 0 + [Mean Layer 3] * 0 + [Mean Layer 25] * -0.14 + [Mean Layer 22] * 0.1 + [Mean Layer 21] * 0.76 + [Mean Layer 19] * 0.05 + [Mean Layer 18] * -0.09 + [Mean Layer 17] * -0.81 + [Mean Layer 14] * -0.01

Class Coberturas Diversas :

-54.01 + [SAVI] * -64.17 + [NDVI_3] * 4.71 + [NDVI_4] * 2.46 + [NDVI_2] * -56.27 + [NDVI_12] * -1.56 + [NDVI_11] * -112.49 + [AC9] * 34.33 + [AC7] * 44.46 + [AC5] * 0 + [AC4] * 0 + [AC3] * 0 + [AC2] * 4.74 + [AC18] * 0 + [AC17] * 0 + [AC16] * -3.83 + [AC15] * -4.07 + [AC14] * -1.16 + [AC12] * -0.69 + [AC10] * 0.74 + [Standard deviation Layer 9] * 0 + [Standard deviation Layer 8] * 0.01 + [Standard deviation Layer 7] * 0 + [Standard deviation Layer 6] * 0 + [Standard deviation Layer 5] * -0.01 + [Standard deviation Layer 4] * 0 + [Standard deviation Layer 3] * 0 + [Standard deviation Layer 25] * -0.95 + [Standard deviation Layer 24] * -0.1 + [Standard

deviation Layer 23] * -0.1 + [Standard deviation Layer 22] * -0.08 + [Standard deviation Layer 21] * 0.05 + [Standard deviation Layer 20] * 0.27 + [Standard deviation Layer 2] * 0 + [Standard deviation Layer 19] * -0.39 + [Standard deviation Layer 18] * -0.87 + [Standard deviation Layer 17] * 0.91 + [Standard deviation Layer 16] * 0.01 + [Standard deviation Layer 15] * 0 + [Standard deviation Layer 14] * -0.01 + [Standard deviation Layer 13] * 0 + [Standard deviation Layer 12] * 0 + [Standard deviation Layer 11] * 0 + [Standard deviation Layer 10] * 0 + [Standard deviation Layer 1] * 0.01 + [Mean Layer 9] * 0 + [Mean Layer 25] * 0.1 + [Mean Layer 24] * 0.05 + [Mean Layer 23] * 0.02 + [Mean Layer 22] * 0.06 + [Mean Layer 21] * -0.03 + [Mean Layer 20] * -0.06 + [Mean Layer 19] * 0.01 + [Mean Layer 18] * -0.04 + [Mean Layer 17] * 0.48 + [Mean Layer 16] * 0 + [Mean Layer 15] * 0 + [Mean Layer 14] * -0.01 + [Mean Layer 13] * 0 + [Mean Layer 11] * 0 + [Mean Layer 10] * 0

Class Pavimentação Viária :

19.32 + [NDVI_3] * -2.07 + [NDVI_4] * -8.19 + [NDVI_2] * -304.7 + [NDVI_11] * -84.73 + [AC9] * -0.76 + [AC7] * -13.35 + [AC6] * 0 + [AC4] * 0 + [AC3] * 0 + [AC17] * 0 + [AC16] * 0.34 + [AC15] * 2.92 + [AC14] * -3.64 + [AC12] * 2.14 + [AC10] * -1.4 + [Standard deviation Layer 9] * 0 + [Standard deviation Layer 8] * 0 + [Standard deviation Layer 7] * 0.01 + [Standard deviation Layer 6] * 0 + [Standard deviation Layer 5] * 0 + [Standard deviation Layer 4] * 0 + [Standard deviation Layer 3] * 0 + [Standard deviation Layer 25] * 0.06 + [Standard deviation Layer 24] * 0.02 + [Standard deviation Layer 23] * -0.07 + [Standard deviation Layer 22] * 0.08 + [Standard deviation Layer 21] * -0.05 + [Standard deviation Layer 20] * -0.43 + [Standard deviation Layer 2] * 0 + [Standard deviation Layer 19] * 0.29 + [Standard deviation Layer 18] * 0.91 + [Standard deviation Layer 17] * 0.02 + [Standard deviation Layer 16] * -0.01 + [Standard deviation Layer 15] * 0 + [Standard deviation Layer 14] * 0.01 + [Standard deviation Layer 13] * 0 + [Standard deviation Layer 12] * -0.01 + [Standard deviation Layer 11] * 0 + [Standard deviation Layer 10] * 0 + [Standard deviation Layer 1] * 0 + [Mean Layer 9] * 0 + [Mean Layer 25] * -0.61 + [Mean Layer 24] * -0.01 + [Mean Layer 23] * 0.05 + [Mean Layer 22] * -0.25 + [Mean Layer 21] * 0.01 + [Mean Layer 19] * -0.01 + [Mean Layer 18] * -0.02 + [Mean Layer 17] * 0.12 + [Mean Layer 16] * 0 + [Mean Layer 15] * 0 + [Mean Layer 14] * -0.01 + [Mean Layer 13] * 0 + [Mean Layer 10] * 0

Class Piscina :

-375.31 + [SAVI] * -44.36 + [NDVI_3] * 34.56 + [NDVI_2] * -52.38 + [AC7] * 7.95 + [AC6] * 0 + [AC2] * 10.83 + [AC15] * 3.33 + [AC14] * -30.78 + [AC12] * 16.27 + [AC11] * 1.54 + [Standard deviation Layer 8] * 0 + [Standard deviation Layer 5] * 0 + [Standard deviation Layer 23] * -0.13 + [Standard deviation Layer 22] * -6.63 + [Standard deviation Layer 20] * 1.69 + [Standard deviation Layer 19] * 0.73 + [Standard deviation Layer 17] * -4.65 + [Standard deviation Layer 16] * 0.12 + [Standard deviation Layer 14] * -0.03 + [Standard deviation Layer 13] * 0 + [Standard deviation Layer 10] * 0.01 + [Mean Layer 25] * -2.06 + [Mean Layer 22] * -0.3 + [Mean Layer 20] * -0.16 + [Mean Layer 17] * -0.1 + [Mean Layer 15] * 0 + [Mean Layer 13] * 0

LM_5:

Class Sombra : 30.92 + [NDVI_12] * 111.75 + [AC8] * -143.44 + [AC7] * -43.5 + [AC5] * 0 + [AC17] * 0.01 + [AC16] * 4.72 + [Standard deviation Layer 22] * -2.1 + [Standard deviation Layer 21] * -0.39 + [Standard deviation Layer 19] * 4 + [Standard deviation

Layer 18] * 5.2 + [Standard deviation Layer 15] * -0.01 + [Standard deviation Layer 11] * 0.01 + [Mean Layer 9] * 0.01 + [Mean Layer 7] * 0 + [Mean Layer 6] * 0 + [Mean Layer 4] * 0 + [Mean Layer 25] * -0.11 + [Mean Layer 21] * -0.2 + [Mean Layer 20] * 0.17 + [Mean Layer 14] * 0.02 + [Mean Layer 13] * 0.01

Class Coberturas Cerâmicas :

-2.11 + [NDVI_3] * -40.88 + [NDVI_2] * -174.65 + [NDVI_11] * -40.52 + [AC14] * 13.38 + [AC12] * -3.58 + [AC11] * -25.33 + [AC1] * -63.92 + [Standard deviation Layer 8] * -0.01 + [Standard deviation Layer 7] * 0 + [Standard deviation Layer 5] * 0 + [Standard deviation Layer 25] * 0.7 + [Standard deviation Layer 23] * 0.43 + [Standard deviation Layer 22] * -0.11 + [Standard deviation Layer 20] * -0.2 + [Standard deviation Layer 2] * 0 + [Standard deviation Layer 19] * 0.23 + [Standard deviation Layer 18] * -0.91 + [Standard deviation Layer 17] * -0.88 + [Standard deviation Layer 16] * 0.02 + [Standard deviation Layer 15] * -0.01 + [Standard deviation Layer 14] * 0 + [Standard deviation Layer 12] * 0 + [Standard deviation Layer 11] * 0 + [Standard deviation Layer 10] * -0.01 + [Mean Layer 5] * 0 + [Mean Layer 25] * 0.11 + [Mean Layer 23] * -0.17 + [Mean Layer 19] * 0.02 + [Mean Layer 18] * -0.1 + [Mean Layer 17] * -0.9 + [Mean Layer 16] * 0 + [Mean Layer 14] * 0 + [Mean Layer 11] * 0 + [Mean Layer 10] * 0

Class Solo Exposto :

35.64 + [SAVI] * -4.88 + [NDVI_2] * -89.32 + [AC9] * 25.69 + [AC7] * 6.26 + [AC6] * 0 + [AC2] * -15.62 + [AC15] * -22.66 + [AC1] * -99.35 + [Standard deviation Layer 7] * 0 + [Standard deviation Layer 4] * 0 + [Standard deviation Layer 3] * -0.01 + [Standard deviation Layer 24] * 2.31 + [Standard deviation Layer 22] * -0.61 + [Standard deviation Layer 21] * -1 + [Standard deviation Layer 2] * -0.01 + [Standard deviation Layer 17] * -0.66 + [Standard deviation Layer 16] * 0.09 + [Standard deviation Layer 15] * -0.03 + [Standard deviation Layer 14] * 0 + [Standard deviation Layer 12] * 0 + [Standard deviation Layer 11] * -0.02 + [Standard deviation Layer 10] * 0.01 + [Standard deviation Layer 1] * -0.02 + [Mean Layer 5] * 0 + [Mean Layer 3] * 0 + [Mean Layer 25] * -0.8 + [Mean Layer 22] * -0.19 + [Mean Layer 21] * 0.27 + [Mean Layer 18] * -0.6 + [Mean Layer 17] * -1.58 + [Mean Layer 16] * 0 + [Mean Layer 15] * 0 + [Mean Layer 14] * 0 + [Mean Layer 13] * -0.05

Class Lago :

299.08 + [NDVI_11] * 51.66 + [AC6] * 0.01 + [AC5] * 0 + [AC17] * 0 + [AC16] * 6.37 + [AC15] * -15.6 + [AC10] * -11.31 + [AC1] * -58.2 + [Standard deviation Layer 8] * 0 + [Standard deviation Layer 5] * -0.04 + [Standard deviation Layer 3] * -0.02 + [Standard deviation Layer 24] * -19.9 + [Standard deviation Layer 22] * -6.1 + [Standard deviation Layer 21] * -2.19 + [Standard deviation Layer 20] * 2.24 + [Standard deviation Layer 18] * -5.47 + [Standard deviation Layer 16] * -0.66 + [Standard deviation Layer 14] * 0.07 + [Standard deviation Layer 1] * -0.06 + [Mean Layer 5] * 0 + [Mean Layer 3] * 0 + [Mean Layer 25] * -9.37 + [Mean Layer 23] * 0.56 + [Mean Layer 21] * -1.18 + [Mean Layer 17] * -2.5 + [Mean Layer 15] * -0.02 + [Mean Layer 13] * 0.1 + [Mean Layer 12] * 0

Class Vegetação Arbórea :

-225.32 + [SAVI] * 26.92 + [NDVI_3] * -52.33 + [NDVI_4] * 34.01 + [NDVI_2] * 11.49 + [NDVI_11] * 31.03 + [AC9] * -4.75 + [AC7] * -149.07 + [AC3] * 0 + [AC16] * -4.09 + [AC15] * 37.54 + [AC14] * 9.74 + [AC12] * -5.54 + [AC11] * -67.68 + [Standard

deviation Layer 8] * 0.01 + [Standard deviation Layer 7] * 0.01 + [Standard deviation Layer 6] * 0.01 + [Standard deviation Layer 5] * 0 + [Standard deviation Layer 3] * -0.02 + [Standard deviation Layer 25] * 1.4 + [Standard deviation Layer 20] * 1.11 + [Standard deviation Layer 2] * -0.02 + [Standard deviation Layer 17] * 1.12 + [Standard deviation Layer 15] * 0.13 + [Standard deviation Layer 14] * 0.04 + [Standard deviation Layer 11] * 0.01 + [Mean Layer 5] * 0 + [Mean Layer 3] * 0 + [Mean Layer 25] * -0.18 + [Mean Layer 23] * -0.16 + [Mean Layer 12] * 0.01

Class Pavimentação Não Viária :

-147.82 + [NDVI_3] * -39.22 + [NDVI_2] * -269.03 + [NDVI_12] * 4.23 + [AC9] * 81.26 + [AC3] * 0 + [AC16] * 26.04 + [AC14] * 3.57 + [AC12] * -8.64 + [Standard deviation Layer 8] * 0 + [Standard deviation Layer 7] * 0 + [Standard deviation Layer 5] * 0 + [Standard deviation Layer 4] * 0 + [Standard deviation Layer 3] * 0 + [Standard deviation Layer 25] * 1.58 + [Standard deviation Layer 23] * 0.18 + [Standard deviation Layer 22] * -3.71 + [Standard deviation Layer 21] * -0.11 + [Standard deviation Layer 20] * -0.71 + [Standard deviation Layer 18] * 0.7 + [Standard deviation Layer 17] * 2.1 + [Standard deviation Layer 16] * -0.01 + [Standard deviation Layer 15] * -0.02 + [Standard deviation Layer 14] * -0.03 + [Standard deviation Layer 12] * 0 + [Standard deviation Layer 11] * 0 + [Standard deviation Layer 10] * 0 + [Standard deviation Layer 1] * 0.01 + [Mean Layer 25] * -0.62 + [Mean Layer 22] * 0.22 + [Mean Layer 21] * -0.08 + [Mean Layer 19] * 0.19 + [Mean Layer 18] * 0.02 + [Mean Layer 17] * -1.06 + [Mean Layer 16] * 0 + [Mean Layer 14] * 0 + [Mean Layer 12] * 0 + [Mean Layer 10] * 0

Class Coberturas Metálicas :

-909.65 + [SAVI] * -102.55 + [NDVI_2] * -483.88 + [AC9] * 276.76 + [AC7] * 17.66 + [AC2] * 133.35 + [AC18] * 0 + [AC16] * 24.27 + [AC14] * -13.76 + [AC12] * -0.7 + [AC1] * 484.49 + [Standard deviation Layer 8] * 0 + [Standard deviation Layer 6] * 0 + [Standard deviation Layer 5] * 0 + [Standard deviation Layer 4] * 0 + [Standard deviation Layer 3] * 0 + [Standard deviation Layer 25] * 0.35 + [Standard deviation Layer 23] * 2.57 + [Standard deviation Layer 22] * 0.11 + [Standard deviation Layer 21] * 0.06 + [Standard deviation Layer 2] * 0 + [Standard deviation Layer 19] * 0.6 + [Standard deviation Layer 18] * -0.25 + [Standard deviation Layer 17] * -0.72 + [Standard deviation Layer 16] * 0 + [Standard deviation Layer 14] * 0 + [Standard deviation Layer 12] * 0 + [Standard deviation Layer 10] * 0.01 + [Mean Layer 25] * 0.4 + [Mean Layer 23] * 0.12 + [Mean Layer 22] * 0.06 + [Mean Layer 21] * -1.18 + [Mean Layer 20] * 0.01 + [Mean Layer 18] * 0.09 + [Mean Layer 17] * -0.6 + [Mean Layer 16] * 0 + [Mean Layer 15] * 0 + [Mean Layer 14] * 0.08 + [Mean Layer 13] * 0 + [Mean Layer 11] * 0 + [Mean Layer 10] * 0

Class Vegetação Rasteira :

198.93 + [AC9] * -219.3 + [AC2] * -34.15 + [AC16] * -1.54 + [AC15] * -20.08 + [AC1] * -34.36 + [Standard deviation Layer 7] * 0 + [Standard deviation Layer 5] * 0.01 + [Standard deviation Layer 3] * -0.01 + [Standard deviation Layer 25] * 16.6 + [Standard deviation Layer 23] * -5.4 + [Standard deviation Layer 22] * 0.42 + [Standard deviation Layer 21] * -0.65 + [Standard deviation Layer 20] * -1.3 + [Standard deviation Layer 19] * 3.88 + [Standard deviation Layer 15] * -0.02 + [Standard deviation Layer 14] * -0.07 + [Standard deviation Layer 13] * -0.01 + [Standard deviation Layer 12] * 0.02 + [Standard deviation Layer 10] * 0.01 + [Mean Layer 5] * 0 + [Mean Layer 4] * 0 + [Mean Layer 3] * 0 + [Mean Layer 25] * -0.14 + [Mean Layer 22] * 0.1 + [Mean Layer

21] * 0.76 + [Mean Layer 19] * 0.05 + [Mean Layer 18] * -0.09 + [Mean Layer 17] * -0.81 + [Mean Layer 14] * -0.01 + [Mean Layer 11] * -0.01

Class Coberturas Diversas :

-156.63 + [SAVI] * -64.17 + [NDVI_3] * 1.44 + [NDVI_2] * -70.09 + [NDVI_12] * -1.56 + [NDVI_11] * -96.66 + [AC9] * 33.91 + [AC7] * 31.15 + [AC5] * 0 + [AC3] * 0 + [AC2] * 4.74 + [AC18] * 0 + [AC17] * 0 + [AC16] * -3.5 + [AC10] * 0.74 + [Standard deviation Layer 8] * 0 + [Standard deviation Layer 7] * 0 + [Standard deviation Layer 6] * 0 + [Standard deviation Layer 5] * 0.03 + [Standard deviation Layer 4] * 0 + [Standard deviation Layer 3] * 0 + [Standard deviation Layer 25] * -0.92 + [Standard deviation Layer 24] * -0.08 + [Standard deviation Layer 23] * -0.23 + [Standard deviation Layer 22] * -0.1 + [Standard deviation Layer 21] * -0.08 + [Standard deviation Layer 20] * 0.13 + [Standard deviation Layer 2] * 0 + [Standard deviation Layer 19] * 0.04 + [Standard deviation Layer 17] * 0.36 + [Standard deviation Layer 16] * 0.01 + [Standard deviation Layer 15] * 0 + [Standard deviation Layer 14] * 0 + [Standard deviation Layer 12] * 0 + [Standard deviation Layer 11] * 0 + [Standard deviation Layer 10] * 0 + [Standard deviation Layer 1] * 0 + [Mean Layer 5] * 0 + [Mean Layer 25] * 0.07 + [Mean Layer 24] * -0.64 + [Mean Layer 23] * 0.02 + [Mean Layer 21] * -0.02 + [Mean Layer 20] * -0.06 + [Mean Layer 18] * 0.01 + [Mean Layer 17] * 0.39 + [Mean Layer 16] * 0 + [Mean Layer 15] * 0 + [Mean Layer 14] * -0.01 + [Mean Layer 11] * 0

Class Pavimentação Viária :

-74.02 + [NDVI_2] * -298.25 + [NDVI_11] * -100.55 + [AC7] * -1.43 + [AC6] * 0 + [AC4] * 0 + [AC14] * -4.8 + [Standard deviation Layer 8] * 0 + [Standard deviation Layer 7] * 0 + [Standard deviation Layer 6] * 0 + [Standard deviation Layer 5] * 0 + [Standard deviation Layer 4] * 0 + [Standard deviation Layer 3] * 0 + [Standard deviation Layer 25] * 0.12 + [Standard deviation Layer 23] * 0.08 + [Standard deviation Layer 21] * 0.08 + [Standard deviation Layer 20] * -0.36 + [Standard deviation Layer 2] * 0 + [Standard deviation Layer 19] * -0.05 + [Standard deviation Layer 18] * 0.16 + [Standard deviation Layer 17] * 0.25 + [Standard deviation Layer 16] * -0.01 + [Standard deviation Layer 15] * 0 + [Standard deviation Layer 14] * 0.01 + [Standard deviation Layer 13] * 0 + [Standard deviation Layer 12] * 0 + [Standard deviation Layer 10] * 0 + [Mean Layer 5] * 0 + [Mean Layer 25] * -0.57 + [Mean Layer 24] * 0.01 + [Mean Layer 23] * 0.05 + [Mean Layer 22] * -0.19 + [Mean Layer 19] * 0.01 + [Mean Layer 18] * -0.05 + [Mean Layer 17] * 0.19 + [Mean Layer 15] * 0 + [Mean Layer 14] * -0.01 + [Mean Layer 13] * 0 + [Mean Layer 10] * 0

Class Piscina :

-202.98 + [SAVI] * -44.36 + [NDVI_3] * 34.56 + [NDVI_2] * -52.38 + [AC7] * 7.95 + [AC6] * 0 + [AC2] * 10.83 + [AC15] * 3.33 + [AC14] * -30.78 + [AC12] * 16.27 + [AC11] * 1.54 + [Standard deviation Layer 8] * 0 + [Standard deviation Layer 5] * 0 + [Standard deviation Layer 23] * -0.13 + [Standard deviation Layer 22] * -6.63 + [Standard deviation Layer 20] * 1.69 + [Standard deviation Layer 19] * 0.73 + [Standard deviation Layer 17] * -4.65 + [Standard deviation Layer 16] * 0.12 + [Standard deviation Layer 14] * -0.03 + [Standard deviation Layer 13] * 0 + [Standard deviation Layer 10] * 0.01 + [Mean Layer 25] * -2.06 + [Mean Layer 22] * -0.3 + [Mean Layer 20] * -0.16 + [Mean Layer 17] * -0.1 + [Mean Layer 15] * 0 + [Mean Layer 13] * 0

LM_6:

Class Sombra :

$117.09 + [\text{NDVI_12}] * 111.75 + [\text{AC8}] * -143.44 + [\text{AC7}] * -43.5 + [\text{AC5}] * 0 + [\text{AC17}] * 0.01 + [\text{AC16}] * 4.72 + [\text{Standard deviation Layer 22}] * -2.1 + [\text{Standard deviation Layer 21}] * -0.39 + [\text{Standard deviation Layer 19}] * 4 + [\text{Standard deviation Layer 18}] * 5.2 + [\text{Standard deviation Layer 15}] * -0.01 + [\text{Standard deviation Layer 11}] * 0.01 + [\text{Mean Layer 9}] * 0.01 + [\text{Mean Layer 7}] * 0 + [\text{Mean Layer 6}] * 0 + [\text{Mean Layer 4}] * 0 + [\text{Mean Layer 25}] * -0.11 + [\text{Mean Layer 21}] * -0.2 + [\text{Mean Layer 20}] * 0.17 + [\text{Mean Layer 14}] * 0.02 + [\text{Mean Layer 13}] * 0.01$

Class Coberturas Cerâmicas :

$-12.91 + [\text{NDVI_3}] * -40.88 + [\text{NDVI_2}] * -67.78 + [\text{AC14}] * 13.38 + [\text{AC12}] * -3.58 + [\text{AC11}] * -23.18 + [\text{AC1}] * -58.56 + [\text{Standard deviation Layer 8}] * -0.01 + [\text{Standard deviation Layer 7}] * 0 + [\text{Standard deviation Layer 5}] * 0 + [\text{Standard deviation Layer 25}] * 0.34 + [\text{Standard deviation Layer 23}] * 0.43 + [\text{Standard deviation Layer 22}] * -0.11 + [\text{Standard deviation Layer 20}] * -0.14 + [\text{Standard deviation Layer 2}] * 0 + [\text{Standard deviation Layer 19}] * 0.23 + [\text{Standard deviation Layer 18}] * -0.91 + [\text{Standard deviation Layer 17}] * -0.88 + [\text{Standard deviation Layer 16}] * 0.01 + [\text{Standard deviation Layer 15}] * -0.01 + [\text{Standard deviation Layer 12}] * 0 + [\text{Standard deviation Layer 10}] * -0.01 + [\text{Mean Layer 5}] * 0 + [\text{Mean Layer 25}] * 0.11 + [\text{Mean Layer 23}] * -0.17 + [\text{Mean Layer 19}] * 0.02 + [\text{Mean Layer 18}] * -0.1 + [\text{Mean Layer 17}] * -0.9 + [\text{Mean Layer 16}] * 0 + [\text{Mean Layer 11}] * 0$

Class Solo Exposto :

$62.45 + [\text{NDVI_2}] * -11.25 + [\text{AC9}] * 4.88 + [\text{AC6}] * 0 + [\text{AC2}] * -15.62 + [\text{AC15}] * -12.61 + [\text{AC1}] * -95.02 + [\text{Standard deviation Layer 4}] * 0 + [\text{Standard deviation Layer 3}] * -0.01 + [\text{Standard deviation Layer 24}] * 1.69 + [\text{Standard deviation Layer 22}] * -0.61 + [\text{Standard deviation Layer 21}] * -0.74 + [\text{Standard deviation Layer 2}] * -0.01 + [\text{Standard deviation Layer 17}] * -0.66 + [\text{Standard deviation Layer 15}] * -0.02 + [\text{Standard deviation Layer 14}] * 0 + [\text{Standard deviation Layer 11}] * -0.02 + [\text{Standard deviation Layer 10}] * 0.01 + [\text{Standard deviation Layer 1}] * -0.02 + [\text{Mean Layer 3}] * 0 + [\text{Mean Layer 25}] * -0.63 + [\text{Mean Layer 22}] * -0.16 + [\text{Mean Layer 21}] * 0.22 + [\text{Mean Layer 18}] * -0.6 + [\text{Mean Layer 17}] * -1.53 + [\text{Mean Layer 15}] * 0 + [\text{Mean Layer 14}] * 0 + [\text{Mean Layer 13}] * 0$

Class Lago :

$284.09 + [\text{NDVI_11}] * 51.66 + [\text{AC6}] * 0.01 + [\text{AC5}] * 0 + [\text{AC17}] * 0 + [\text{AC16}] * 6.37 + [\text{AC15}] * -15.6 + [\text{AC10}] * -11.31 + [\text{AC1}] * -58.2 + [\text{Standard deviation Layer 5}] * -0.04 + [\text{Standard deviation Layer 3}] * -0.02 + [\text{Standard deviation Layer 24}] * -19.9 + [\text{Standard deviation Layer 22}] * -6.1 + [\text{Standard deviation Layer 21}] * -2.19 + [\text{Standard deviation Layer 20}] * 2.24 + [\text{Standard deviation Layer 16}] * -0.35 + [\text{Standard deviation Layer 14}] * 0.07 + [\text{Standard deviation Layer 1}] * -0.02 + [\text{Mean Layer 25}] * -7.47 + [\text{Mean Layer 23}] * 0.56 + [\text{Mean Layer 21}] * -0.48 + [\text{Mean Layer 17}] * -2.5 + [\text{Mean Layer 15}] * -0.02 + [\text{Mean Layer 13}] * 0.08 + [\text{Mean Layer 12}] * 0$

Class Vegetação Arbórea :

$-138.25 + [\text{SAVI}] * 26.92 + [\text{NDVI_3}] * -52.33 + [\text{NDVI_4}] * 34.01 + [\text{NDVI_2}] * 11.49 + [\text{NDVI_11}] * 31.03 + [\text{AC9}] * -4.75 + [\text{AC7}] * -149.07 + [\text{AC3}] * 0 + [\text{AC16}] * -4.09 + [\text{AC15}] * 37.54 + [\text{AC14}] * 9.74 + [\text{AC12}] * -5.54 + [\text{AC11}] * -67.68 + [\text{Standard deviation Layer 8}] * 0.01 + [\text{Standard deviation Layer 7}] * 0.01 + [\text{Standard deviation Layer 6}] * 0.01 + [\text{Standard deviation Layer 5}] * 0 + [\text{Standard deviation Layer 3}] * -$

$0.02 + [\text{Standard deviation Layer 25}] * 1.4 + [\text{Standard deviation Layer 20}] * 1.11 +$
 $[\text{Standard deviation Layer 2}] * -0.02 + [\text{Standard deviation Layer 17}] * 1.12 + [\text{Standard deviation Layer 15}] * 0.13 + [\text{Standard deviation Layer 14}] * 0.04 + [\text{Standard deviation Layer 11}] * 0.01 + [\text{Mean Layer 5}] * 0 + [\text{Mean Layer 25}] * -0.18 + [\text{Mean Layer 23}] * -0.16 + [\text{Mean Layer 12}] * 0.01$

Class Pavimentação Não Viária :

$902.65 + [\text{NDVI_3}] * -53.42 + [\text{NDVI_2}] * -199.74 + [\text{NDVI_12}] * -59.78 + [\text{AC9}] * 17.66 + [\text{AC8}] * 71.02 + [\text{AC3}] * 0 + [\text{AC2}] * -343.84 + [\text{AC16}] * -98.73 + [\text{AC14}] * 29.93 +$
 $[\text{Standard deviation Layer 8}] * 0 + [\text{Standard deviation Layer 7}] * 0 + [\text{Standard deviation Layer 6}] * 0 + [\text{Standard deviation Layer 5}] * 0.01 + [\text{Standard deviation Layer 4}] * 0 + [\text{Standard deviation Layer 3}] * 0 + [\text{Standard deviation Layer 25}] * -14.65 + [\text{Standard deviation Layer 22}] * -3.27 + [\text{Standard deviation Layer 20}] * -0.27 +$
 $[\text{Standard deviation Layer 18}] * 0.7 + [\text{Standard deviation Layer 17}] * 1.63 + [\text{Standard deviation Layer 16}] * -0.01 + [\text{Standard deviation Layer 15}] * -0.02 + [\text{Standard deviation Layer 14}] * -0.03 + [\text{Standard deviation Layer 12}] * 0 + [\text{Standard deviation Layer 11}] * 0 + [\text{Standard deviation Layer 10}] * 0 + [\text{Standard deviation Layer 1}] * 0.01 + [\text{Mean Layer 25}] * -2.18 + [\text{Mean Layer 22}] * 0.03 + [\text{Mean Layer 21}] * -0.08 +$
 $[\text{Mean Layer 19}] * 0.17 + [\text{Mean Layer 17}] * -19.64 + [\text{Mean Layer 16}] * 0 + [\text{Mean Layer 14}] * 0 + [\text{Mean Layer 12}] * 0 + [\text{Mean Layer 1}] * 0$

Class Coberturas Metálicas :

$43.57 + [\text{SAVI}] * -118.14 + [\text{NDVI_3}] * -23.46 + [\text{NDVI_4}] * 28.08 + [\text{NDVI_2}] * -49.73 + [\text{NDVI_11}] * -22.96 + [\text{AC9}] * -8.57 + [\text{AC7}] * 22.07 + [\text{AC4}] * 0 + [\text{AC3}] * 0 + [\text{AC2}] * -2.98 + [\text{AC18}] * 0 + [\text{AC16}] * 24.27 + [\text{AC14}] * 1.27 + [\text{AC12}] * -0.7 + [\text{AC1}] * -6.74 +$
 $[\text{Standard deviation Layer 8}] * 0 + [\text{Standard deviation Layer 7}] * 0 + [\text{Standard deviation Layer 6}] * 0 + [\text{Standard deviation Layer 5}] * 0 + [\text{Standard deviation Layer 4}] * 0 + [\text{Standard deviation Layer 3}] * 0 + [\text{Standard deviation Layer 25}] * 1 + [\text{Standard deviation Layer 23}] * -0.28 + [\text{Standard deviation Layer 22}] * 0.33 +$
 $[\text{Standard deviation Layer 21}] * -0.35 + [\text{Standard deviation Layer 20}] * -0.1 + [\text{Standard deviation Layer 2}] * 0 + [\text{Standard deviation Layer 19}] * 0.21 + [\text{Standard deviation Layer 18}] * -0.25 + [\text{Standard deviation Layer 17}] * -0.15 + [\text{Standard deviation Layer 16}] * -0.02 + [\text{Standard deviation Layer 15}] * 0 + [\text{Standard deviation Layer 14}] * 0 + [\text{Standard deviation Layer 13}] * 0 + [\text{Standard deviation Layer 12}] * 0 + [\text{Standard deviation Layer 11}] * 0 + [\text{Standard deviation Layer 1}] * -0.01 + [\text{Mean Layer 25}] * 0.06 + [\text{Mean Layer 23}] * 0.17 + [\text{Mean Layer 22}] * 0.06 + [\text{Mean Layer 21}] * -0.03 +$
 $[\text{Mean Layer 20}] * 0.01 + [\text{Mean Layer 19}] * -0.04 + [\text{Mean Layer 18}] * 0.21 + [\text{Mean Layer 17}] * -1.16 + [\text{Mean Layer 16}] * 0 + [\text{Mean Layer 15}] * 0 + [\text{Mean Layer 13}] * 0 + [\text{Mean Layer 12}] * 0 + [\text{Mean Layer 10}] * 0$

Class Vegetação Rasteira :

$165.91 + [\text{AC9}] * -219.3 + [\text{AC2}] * -34.15 + [\text{AC16}] * -1.54 + [\text{AC15}] * -8.34 + [\text{AC1}] * -17.68 + [\text{Standard deviation Layer 7}] * 0 + [\text{Standard deviation Layer 5}] * 0.01 +$
 $[\text{Standard deviation Layer 3}] * -0.01 + [\text{Standard deviation Layer 25}] * 6.96 + [\text{Standard deviation Layer 23}] * -5.4 + [\text{Standard deviation Layer 22}] * 0.42 + [\text{Standard deviation Layer 21}] * -0.65 + [\text{Standard deviation Layer 20}] * -1.3 + [\text{Standard deviation Layer 19}] * 3.88 + [\text{Standard deviation Layer 15}] * -0.01 + [\text{Standard deviation Layer 14}] * -0.03 +$
 $[\text{Standard deviation Layer 13}] * -0.01 + [\text{Standard deviation Layer 12}] * 0 + [\text{Standard deviation Layer 10}] * 0 + [\text{Mean Layer 4}] * 0 + [\text{Mean Layer 3}] * 0 + [\text{Mean Layer 1}] * 0$

25] * -0.14 + [Mean Layer 22] * 0.1 + [Mean Layer 21] * 0.58 + [Mean Layer 19] * 0.05 + [Mean Layer 18] * -0.09 + [Mean Layer 17] * -0.81 + [Mean Layer 14] * -0.01

Class Coberturas Diversas :

-56.9 + [SAVI] * 15.59 + [NDVI_3] * 24.92 + [NDVI_4] * -28.09 + [NDVI_2] * 38.25 + [NDVI_12] * -1.56 + [NDVI_11] * -73.7 + [AC9] * 19.16 + [AC7] * -0.91 + [AC5] * 0 + [AC4] * 0 + [AC3] * 0 + [AC2] * 7.33 + [AC18] * 0 + [AC17] * 0 + [AC16] * -3.5 + [AC14] * -15.05 + [AC10] * 0.74 + [AC1] * 13.37 + [Standard deviation Layer 8] * 0.01 + [Standard deviation Layer 7] * 0 + [Standard deviation Layer 6] * 0 + [Standard deviation Layer 5] * 0 + [Standard deviation Layer 4] * 0 + [Standard deviation Layer 3] * 0 + [Standard deviation Layer 25] * -1.57 + [Standard deviation Layer 24] * -0.08 + [Standard deviation Layer 23] * 0.07 + [Standard deviation Layer 22] * -0.31 + [Standard deviation Layer 21] * 0.19 + [Standard deviation Layer 20] * 0.23 + [Standard deviation Layer 2] * 0 + [Standard deviation Layer 19] * -0.17 + [Standard deviation Layer 17] * -0.21 + [Standard deviation Layer 16] * 0.03 + [Standard deviation Layer 15] * 0 + [Standard deviation Layer 14] * -0.01 + [Standard deviation Layer 13] * 0 + [Standard deviation Layer 12] * 0 + [Standard deviation Layer 11] * -0.01 + [Standard deviation Layer 10] * 0 + [Standard deviation Layer 1] * 0.01 + [Mean Layer 25] * 0.17 + [Mean Layer 24] * 0.01 + [Mean Layer 23] * -0.04 + [Mean Layer 21] * 0.03 + [Mean Layer 20] * -0.06 + [Mean Layer 19] * 0.04 + [Mean Layer 18] * -0.11 + [Mean Layer 17] * 0.88 + [Mean Layer 15] * 0 + [Mean Layer 14] * 0 + [Mean Layer 12] * 0 + [Mean Layer 11] * 0 + [Mean Layer 10] * 0

Class Pavimentação Viária :

106.91 + [NDVI_3] * -101.59 + [NDVI_2] * -133.17 + [NDVI_11] * -17.54 + [AC7] * -29 + [AC6] * 0 + [AC11] * -21.34 + [AC1] * -45.06 + [Standard deviation Layer 8] * 0 + [Standard deviation Layer 7] * 0 + [Standard deviation Layer 6] * 0 + [Standard deviation Layer 5] * 0 + [Standard deviation Layer 4] * 0 + [Standard deviation Layer 3] * 0 + [Standard deviation Layer 25] * -24.46 + [Standard deviation Layer 23] * 0.11 + [Standard deviation Layer 22] * 0.79 + [Standard deviation Layer 21] * 0.08 + [Standard deviation Layer 20] * -2.17 + [Standard deviation Layer 19] * 0.62 + [Standard deviation Layer 18] * 1.06 + [Standard deviation Layer 17] * 0.25 + [Standard deviation Layer 16] * -0.01 + [Standard deviation Layer 15] * 0 + [Standard deviation Layer 14] * 0.01 + [Standard deviation Layer 13] * 0 + [Standard deviation Layer 12] * -0.01 + [Mean Layer 25] * -4.04 + [Mean Layer 24] * -0.23 + [Mean Layer 23] * -0.11 + [Mean Layer 22] * -0.19 + [Mean Layer 21] * -0.08 + [Mean Layer 19] * 0.22 + [Mean Layer 18] * -0.05 + [Mean Layer 17] * -1.33 + [Mean Layer 16] * 0.01 + [Mean Layer 15] * 0.01 + [Mean Layer 14] * 0.03 + [Mean Layer 13] * 0 + [Mean Layer 12] * 0 + [Mean Layer 10] * 0

Class Piscina :

-28.2 + [SAVI] * -44.36 + [NDVI_3] * 34.56 + [NDVI_4] * 75.46 + [NDVI_2] * -52.38 + [NDVI_12] * 7.51 + [AC7] * 16.73 + [AC6] * 0 + [AC5] * 0 + [AC2] * 19.48 + [AC15] * 3.33 + [AC14] * -30.78 + [AC12] * 20.56 + [AC11] * 9.02 + [AC10] * -3.47 + [Standard deviation Layer 8] * 0 + [Standard deviation Layer 6] * 0 + [Standard deviation Layer 5] * 0 + [Standard deviation Layer 25] * -2.29 + [Standard deviation Layer 23] * -0.13 + [Standard deviation Layer 22] * -9.68 + [Standard deviation Layer 20] * 2.64 + [Standard deviation Layer 19] * 1.24 + [Standard deviation Layer 17] * -4.65 + [Standard deviation Layer 16] * 0.15 + [Standard deviation Layer 14] * -0.06 + [Standard deviation Layer 13] * 0 + [Standard deviation Layer 10] * 0.01 + [Standard

deviation Layer 1] * 0 + [Mean Layer 25] * -2.7 + [Mean Layer 22] * -0.3 + [Mean Layer 20] * -0.23 + [Mean Layer 19] * 0.16 + [Mean Layer 17] * -0.49 + [Mean Layer 15] * 0.01 + [Mean Layer 13] * 0

A.2 Nível de Legenda 2

A.2.1 Árvore Algoritmo BFTree

```

NDVI_4 < -0.06106
| Mean Layer 25 < 8.69869
| | AC3 < -7461.79573: Ceramica Iluminada(1.0/2.0)
| | AC3 >= -7461.79573: Galvalume A(59.0/1.0)
| Mean Layer 25 >= 8.69869
| | NDVI_2 < -0.05302: Galvalume B(4.0/0.0)
| | NDVI_2 >= -0.05302: Galvalume C(2.0/1.0)
NDVI_4 >= -0.06106
| AC5 < -19239.38402
| | Mean Layer 11 < -1527.41754
| | | AC3 < -1796.25245: Aco_galv_fosco(26.0/0.0)
| | | AC3 >= -1796.25245
| | | | NDVI_3 < 0.02936: Plastico(5.0/0.0)
| | | | NDVI_3 >= 0.02936: Piscina de Azulejo(4.0/0.0)
| | Mean Layer 11 >= -1527.41754
| | | Mean Layer 15 < -1097.04335
| | | | AC16 < 0.50272: Ceramica Iluminada(2.0/0.0)
| | | | AC16 >= 0.50272: Asfalto_Pintado_Vermelho(22.0/0.0)
| | | Mean Layer 15 >= -1097.04335
| | | | Mean Layer 20 < -14.94807
| | | | | Standard deviation Layer 3 < 1395.22628: Concreto
| | | | | Impermeabilizado(23.0/0.0)
| | | | | Standard deviation Layer 3 >= 1395.22628
| | | | | | NDVI_3 < -0.04655: Concreto(1.0/2.0)
| | | | | | NDVI_3 >= -0.04655: Manta Asfaltica Aluminizada(4.0/0.0)
| | | | | Mean Layer 20 >= -14.94807
| | | | | SAVI < 0.42079
| | | | | | Mean Layer 25 < -0.66738
| | | | | | AC2 < 0.70252
| | | | | | AC3 < -4937.95594
| | | | | | Mean Layer 17 < 40.83315
| | | | | | SAVI < 0.12206: Pedra Mineira(13.0/0.0)
| | | | | | SAVI >= 0.12206
| | | | | | Mean Layer 15 < 464.73267
| | | | | | Mean Layer 15 < -139.1792
| | | | | | Standard deviation Layer 20 < 3.84245: Ceramica
| | | | | | Escura(2.0/0.0)
| | | | | | Standard deviation Layer 20 >= 3.84245: Solo
| | | | | | Exposto(17.0/0.0)
| | | | | | Mean Layer 15 >= -139.1792

```



```

| | | | | Mean Layer 19 >= 14.2425
| | | | | SAVI < 0.11781: Aco_Galvanizado_Ferrugem(18.0/1.0)
| | | | | SAVI >= 0.11781
| | | | | AC6 < -18485.41321
| | | | | AC2 < 0.51131: Ceramica Iluminada(4.0/0.0)
| | | | | AC2 >= 0.51131: Solo Exposto(2.0/1.0)
| | | | | AC6 >= -18485.41321: Ceramica Escura(7.0/0.0)
| | | | | SAVI >= 0.42079: Vegetacao_Arborea(17.0/0.0)
| AC5 >= -19239.38402
| | NDVI_4 < 0.08798
| | | NDVI_3 < -0.30061
| | | SAVI < 0.25489
| | | NDVI_3 < -0.34578: Ceramica Escura(2.0/0.0)
| | | NDVI_3 >= -0.34578
| | | SAVI < 0.21101: Carvao_Coque(2.0/0.0)
| | | SAVI >= 0.21101: Bloquete(1.0/1.0)
| | | SAVI >= 0.25489: Lago(2.0/0.0)
| | | NDVI_3 >= -0.30061
| | | AC4 < -1050.27649: Asfalto(36.0/0.0)
| | | AC4 >= -1050.27649: Aco_galv_fosco(1.0/2.0)
| | NDVI_4 >= 0.08798
| | Mean Layer 14 < -117.65953: Amianto(24.0/1.0)
| | Mean Layer 14 >= -117.65953
| | | NDVI_4 < 0.1149
| | | Standard deviation Layer 2 < 436.6905
| | | NDVI_3 < -0.36653: Ceramica Escura(3.0/0.0)
| | | NDVI_3 >= -0.36653
| | | Standard deviation Layer 25 < 0.80935: Asfalto(1.0/2.0)
| | | Standard deviation Layer 25 >= 0.80935: Lago(3.0/0.0)
| | | Standard deviation Layer 2 >= 436.6905: Policarbonato(4.0/1.0)
| | | NDVI_4 >= 0.1149
| | | SAVI < 0.37232: Sombra(22.0/0.0)
| | | SAVI >= 0.37232: Vegetacao_Arborea(2.0/0.0)

```

Tamanho da árvore: 117

A.2.2 Árvore Algoritmo LMT

: LM_1:20/20 (602)

Tamanho da árvore: 1

LM_1:

Class Aço Galvanizado Fosco:

-12.49 + [NDVI_2] * -32.7 + [AC2] * 7.92 + [AC14] * -5.89 + [Standard deviation Layer 5] * 0 + [Standard deviation Layer 25] * 0.7 + [Standard deviation Layer 23] * 0.15 +

$[\text{Standard deviation Layer 12}] * 0 + [\text{Standard deviation Layer 1}] * 0.01 + [\text{Mean Layer 21}] * -0.14 + [\text{Mean Layer 20}] * 0.1 + [\text{Mean Layer 14}] * 0 + [\text{Mean Layer 11}] * 0$

Class Aço Galvanizado Brilhante :

$-15.77 + [\text{NDVI_3}] * 30.07 + [\text{NDVI_11}] * -45.72 + [\text{AC7}] * 27.98 + [\text{Standard deviation Layer 25}] * -0.98 + [\text{Standard deviation Layer 23}] * -0.41 + [\text{Standard deviation Layer 21}] * 0.18 + [\text{Standard deviation Layer 20}] * -0.24 + [\text{Standard deviation Layer 10}] * 0 + [\text{Mean Layer 23}] * 0.2 + [\text{Mean Layer 15}] * 0 + [\text{Mean Layer 14}] * 0$

Class Aço Galvanizado Ferrugem :

$6.31 + [\text{SAVI}] * -10.15 + [\text{AC7}] * 6.93 + [\text{Standard deviation Layer 8}] * 0 + [\text{Standard deviation Layer 5}] * 0 + [\text{Standard deviation Layer 21}] * -0.17 + [\text{Standard deviation Layer 2}] * 0 + [\text{Mean Layer 25}] * 0.38 + [\text{Mean Layer 22}] * 0.12 + [\text{Mean Layer 19}] * 0.07 + [\text{Mean Layer 17}] * -0.27 + [\text{Mean Layer 14}] * 0 + [\text{Mean Layer 13}] * 0$

Class Acrílico :

$-18.94 + [\text{SAVI}] * 18.18 + [\text{NDVI_2}] * 43.96 + [\text{Standard deviation Layer 9}] * 0 + [\text{Standard deviation Layer 6}] * 0 + [\text{Standard deviation Layer 4}] * 0 + [\text{Standard deviation Layer 20}] * -1.31 + [\text{Standard deviation Layer 14}] * -0.01 + [\text{Mean Layer 25}] * 0.42 + [\text{Mean Layer 21}] * 0.17 + [\text{Mean Layer 17}] * 0.25$

Class Amianto :

$6.35 + [\text{NDVI_4}] * 72.4 + [\text{AC9}] * -11.72 + [\text{Standard deviation Layer 7}] * 0 + [\text{Standard deviation Layer 4}] * 0 + [\text{Standard deviation Layer 17}] * 1.61 + [\text{Standard deviation Layer 11}] * 0 + [\text{Mean Layer 25}] * 0.43 + [\text{Mean Layer 23}] * 0.24 + [\text{Mean Layer 20}] * -0.09 + [\text{Mean Layer 15}] * 0 + [\text{Mean Layer 14}] * 0 + [\text{Mean Layer 11}] * 0$

Class Asfalto :

$49.71 + [\text{NDVI_2}] * -14.78 + [\text{AC5}] * 0 + [\text{AC18}] * 0 + [\text{AC17}] * 0 + [\text{Standard deviation Layer 9}] * 0 + [\text{Standard deviation Layer 8}] * 0 + [\text{Standard deviation Layer 25}] * 0.32 + [\text{Standard deviation Layer 24}] * 0.32 + [\text{Mean Layer 25}] * -0.18 + [\text{Mean Layer 24}] * 0.15 + [\text{Mean Layer 17}] * -0.5 + [\text{Mean Layer 11}] * 0$

Class Asfalto Pintado Branco :

$-1.64 + [\text{AC2}] * 3.49 + [\text{Standard deviation Layer 9}] * 0 + [\text{Standard deviation Layer 7}] * 0 + [\text{Standard deviation Layer 3}] * 0 + [\text{Standard deviation Layer 25}] * -0.88 + [\text{Standard deviation Layer 23}] * 0.24 + [\text{Standard deviation Layer 22}] * 0.2 + [\text{Standard deviation Layer 20}] * -0.61 + [\text{Standard deviation Layer 19}] * -0.24 + [\text{Standard deviation Layer 16}] * -0.01 + [\text{Standard deviation Layer 12}] * 0 + [\text{Mean Layer 25}] * -0.11 + [\text{Mean Layer 23}] * -0.19$

Class Asfalto Pintado Vermelho :

$-56.85 + [\text{NDVI_3}] * -6.86 + [\text{AC14}] * 12.04 + [\text{AC1}] * -6.4 + [\text{Standard deviation Layer 9}] * 0 + [\text{Standard deviation Layer 7}] * 0 + [\text{Standard deviation Layer 21}] * 0.5 + [\text{Mean Layer 25}] * -0.33 + [\text{Mean Layer 20}] * 0.04 + [\text{Mean Layer 17}] * 1.18 + [\text{Mean Layer 15}] * 0 + [\text{Mean Layer 13}] * 0 + [\text{Mean Layer 10}] * 0$

Class Bloquete :

35.74 + [AC9] * -7.77 + [AC2] * -5.02 + [AC1] * -27.54 + [Standard deviation Layer 3] * 0 + [Standard deviation Layer 25] * -0.61 + [Standard deviation Layer 24] * -1.08 + [Standard deviation Layer 17] * -0.99 + [Mean Layer 22] * 0.1 + [Mean Layer 20] * -0.05 + [Mean Layer 18] * -0.08 + [Mean Layer 15] * 0 + [Mean Layer 14] * 0

Class Carvão Coque :

46.1 + [AC5] * 0 + [AC11] * -12.7 + [Standard deviation Layer 21] * -1.7 + [Standard deviation Layer 19] * 1.19 + [Standard deviation Layer 18] * 1.3 + [Standard deviation Layer 15] * -0.02 + [Standard deviation Layer 13] * -0.04 + [Standard deviation Layer 1] * 0.01 + [Mean Layer 25] * -0.31

Class Cerâmica Escura :

35.37 + [NDVI_3] * -26.44 + [AC11] * -49.16 + [AC1] * -23.76 + [Standard deviation Layer 23] * 0.49 + [Standard deviation Layer 21] * 0.44 + [Standard deviation Layer 20] * -0.28 + [Standard deviation Layer 18] * -2.2 + [Mean Layer 21] * -0.3 + [Mean Layer 20] * 0.06 + [Mean Layer 14] * 0

Class Cerâmica Iluminada :

79.62 + [AC4] * 0 + [AC2] * -128.19 + [AC1] * -24.03 + [Standard deviation Layer 4] * 0 + [Standard deviation Layer 3] * 0 + [Standard deviation Layer 23] * 0.4 + [Standard deviation Layer 15] * 0.01 + [Standard deviation Layer 12] * 0.01 + [Standard deviation Layer 10] * 0 + [Mean Layer 22] * 0.08 + [Mean Layer 12] * 0

Class Cimento :

15 + [AC2] * -6.9 + [Standard deviation Layer 8] * 0 + [Standard deviation Layer 5] * 0 + [Standard deviation Layer 4] * 0 + [Standard deviation Layer 3] * 0 + [Standard deviation Layer 16] * -0.01 + [Standard deviation Layer 14] * -0.02 + [Mean Layer 25] * -0.15 + [Mean Layer 22] * -0.08 + [Mean Layer 21] * -0.18 + [Mean Layer 17] * -0.17 + [Mean Layer 16] * 0.01 + [Mean Layer 15] * 0.01

Class Cimento Pintado Verde :

-9.93 + [SAVI] * 33.56 + [NDVI_4] * 32.95 + [Standard deviation Layer 4] * -0.02 + [Standard deviation Layer 3] * -0.01 + [Standard deviation Layer 22] * 1.03 + [Standard deviation Layer 2] * 0 + [Standard deviation Layer 16] * 0.03 + [Mean Layer 24] * 0.6 + [Mean Layer 16] * -0.01

Class Cimento Pintado Vermelho :

-11.97 + [AC9] * 7.6 + [Standard deviation Layer 25] * -2.66 + [Standard deviation Layer 24] * 0.28 + [Standard deviation Layer 21] * -0.59 + [Standard deviation Layer 20] * 0.19 + [Standard deviation Layer 19] * 0.42 + [Standard deviation Layer 17] * 0.61 + [Standard deviation Layer 11] * -0.01 + [Standard deviation Layer 10] * -0.01 + [Mean Layer 20] * 0.13 + [Mean Layer 17] * 0.13 + [Mean Layer 15] * 0 + [Mean Layer 14] * 0 + [Mean Layer 13] * 0

Class Concreto :

15.91 + [AC5] * 0 + [AC3] * 0 + [Standard deviation Layer 8] * 0 + [Standard deviation Layer 25] * -0.8 + [Standard deviation Layer 21] * -0.33 + [Standard deviation Layer 19] * -0.32 + [Mean Layer 25] * -0.25 + [Mean Layer 23] * 0.06 + [Mean Layer 20] * -0.05 + [Mean Layer 17] * -0.25 + [Mean Layer 16] * 0 + [Mean Layer 15] * 0.01 + [Mean Layer 14] * 0

Class Concreto Impermeabilizado :

$$\begin{aligned} & -27.19 + [\text{AC2}] * 10.79 + [\text{AC14}] * -18.95 + [\text{AC12}] * 3.37 + [\text{Standard deviation Layer 23}] * -0.16 + [\text{Standard deviation Layer 22}] * 0.3 + [\text{Standard deviation Layer 19}] * 0.21 \\ & + [\text{Standard deviation Layer 17}] * 0.89 + [\text{Standard deviation Layer 16}] * 0 + [\text{Mean Layer 25}] * 0.13 + [\text{Mean Layer 23}] * -0.08 + [\text{Mean Layer 21}] * 0.16 + [\text{Mean Layer 20}] \\ & * -0.22 + [\text{Mean Layer 17}] * 0.18 + [\text{Mean Layer 15}] * 0 + [\text{Mean Layer 14}] * 0 \end{aligned}$$

Class Concreto Pintado Amarelo :

$$\begin{aligned} & 71.23 + [\text{AC7}] * -37.3 + [\text{AC1}] * -13.2 + [\text{Standard deviation Layer 18}] * -0.71 + [\text{Standard deviation Layer 12}] * 0 + [\text{Mean Layer 25}] * -0.16 + [\text{Mean Layer 23}] * -0.08 \\ & + [\text{Mean Layer 22}] * 0.34 + [\text{Mean Layer 17}] * -1.04 + [\text{Mean Layer 16}] * 0 + [\text{Mean Layer 15}] * 0.01 \end{aligned}$$

Class Concreto Pintado Vermelho :

$$\begin{aligned} & 2.33 + [\text{AC14}] * 6.36 + [\text{AC1}] * -19.78 + [\text{Standard deviation Layer 5}] * -0.01 + [\text{Standard deviation Layer 25}] * -1.13 + [\text{Standard deviation Layer 23}] * -0.71 + \\ & [\text{Standard deviation Layer 18}] * 0.66 + [\text{Standard deviation Layer 16}] * 0.02 + [\text{Standard deviation Layer 14}] * 0 + [\text{Standard deviation Layer 12}] * 0.01 + [\text{Mean Layer 17}] * \\ & 0.19 + [\text{Mean Layer 14}] * 0 \end{aligned}$$

Class CRFS :

$$\begin{aligned} & -25.15 + [\text{AC5}] * 0 + [\text{AC14}] * -3.31 + [\text{AC12}] * 3.15 + [\text{Standard deviation Layer 24}] * \\ & -0.82 + [\text{Standard deviation Layer 20}] * 0.25 + [\text{Standard deviation Layer 13}] * 0.01 + [\text{Standard deviation Layer 11}] * 0 + [\text{Mean Layer 25}] * 0.14 + [\text{Mean Layer 23}] * -0.14 \\ & + [\text{Mean Layer 17}] * 0.45 + [\text{Mean Layer 16}] * 0 \end{aligned}$$

Class Fibra de Vidro :

$$\begin{aligned} & -0.66 + [\text{NDVI}_2] * 22.34 + [\text{Standard deviation Layer 7}] * 0 + [\text{Standard deviation Layer 25}] * -3.78 + [\text{Standard deviation Layer 23}] * 1.47 + [\text{Standard deviation Layer 20}] * -0.31 + [\text{Standard deviation Layer 19}] * -0.23 + [\text{Standard deviation Layer 12}] * - \\ & 0.01 + [\text{Mean Layer 25}] * 0.25 + [\text{Mean Layer 24}] * -0.08 + [\text{Mean Layer 17}] * -0.18 \end{aligned}$$

Class Galvalume A :

$$\begin{aligned} & -48.76 + [\text{AC5}] * 0 + [\text{AC10}] * 37.17 + [\text{Standard deviation Layer 23}] * -0.19 + [\text{Standard deviation Layer 14}] * -0.01 + [\text{Mean Layer 25}] * -0.13 + [\text{Mean Layer 21}] * 0.1 \\ & + [\text{Mean Layer 19}] * -0.07 + [\text{Mean Layer 18}] * 0.17 + [\text{Mean Layer 15}] * 0 + [\text{Mean Layer 14}] * 0 \end{aligned}$$

Class Galvalume B :

$$\begin{aligned} & -10.47 + [\text{NDVI}_2] * -34.52 + [\text{AC9}] * 27.86 + [\text{AC14}] * -18.47 + [\text{Standard deviation Layer 25}] * 1.2 + [\text{Standard deviation Layer 24}] * -0.33 + [\text{Standard deviation Layer 15}] \\ & * -0.02 + [\text{Mean Layer 25}] * 0.55 + [\text{Mean Layer 19}] * -0.08 + [\text{Mean Layer 17}] * -0.7 + [\text{Mean Layer 15}] * 0.01 + [\text{Mean Layer 10}] * 0 \end{aligned}$$

Class Galvalume C :

$$\begin{aligned} & -64.59 + [\text{NDVI}_1] * -46.03 + [\text{AC8}] * 43.86 + [\text{AC1}] * 15.85 + [\text{Standard deviation Layer 25}] * 1.75 + [\text{Standard deviation Layer 23}] * 0.25 + [\text{Standard deviation Layer 22}] * 0.31 \\ & + [\text{Mean Layer 25}] * 0.75 + [\text{Mean Layer 22}] * 0.25 + [\text{Mean Layer 18}] * 0.04 + [\text{Mean Layer 16}] * -0.01 \end{aligned}$$

Class Lago :

$$5.28 + [AC5] * 0 + [AC16] * 8.14 + [AC15] * 13.73 + [Standard\ deviation\ Layer\ 5] * -0.01 + [Standard\ deviation\ Layer\ 3] * -0.02 + [Standard\ deviation\ Layer\ 24] * -1.98 + [Standard\ deviation\ Layer\ 20] * 0.77 + [Standard\ deviation\ Layer\ 16] * -0.04 + [Standard\ deviation\ Layer\ 13] * -0.01 + [Mean\ Layer\ 25] * -1.19 + [Mean\ Layer\ 13] * 0$$

Class Lona :

$$-20.02 + [AC15] * -34.74 + [Standard\ deviation\ Layer\ 5] * 0.01 + [Standard\ deviation\ Layer\ 24] * 1.09 + [Standard\ deviation\ Layer\ 21] * 0.25 + [Standard\ deviation\ Layer\ 15] * 0 + [Standard\ deviation\ Layer\ 13] * 0.01 + [Mean\ Layer\ 25] * -0.16$$

Class Manta Asfáltica Aluminizada :

$$-37.49 + [AC5] * 0 + [AC17] * 0 + [Standard\ deviation\ Layer\ 8] * 0.01 + [Standard\ deviation\ Layer\ 4] * 0 + [Standard\ deviation\ Layer\ 24] * 0.35 + [Mean\ Layer\ 25] * -0.08 + [Mean\ Layer\ 20] * -0.46 + [Mean\ Layer\ 10] * 0$$

Class Pastilha Esmaltada :

$$29.81 + [NDVI_2] * 25.8 + [Standard\ deviation\ Layer\ 7] * 0 + [Standard\ deviation\ Layer\ 5] * 0.01 + [Standard\ deviation\ Layer\ 24] * 0.24 + [Standard\ deviation\ Layer\ 21] * 0.31 + [Standard\ deviation\ Layer\ 17] * 0.78 + [Standard\ deviation\ Layer\ 15] * 0.01 + [Standard\ deviation\ Layer\ 10] * 0 + [Mean\ Layer\ 25] * 0.36 + [Mean\ Layer\ 17] * -1.51$$

Class Pedra Mineira :

$$0.94 + [NDVI_11] * -25 + [AC4] * 0 + [AC3] * 0 + [Standard\ deviation\ Layer\ 22] * -2.28 + [Standard\ deviation\ Layer\ 17] * 1.01 + [Standard\ deviation\ Layer\ 16] * -0.01 + [Mean\ Layer\ 22] * 0.21 + [Mean\ Layer\ 21] * -0.43 + [Mean\ Layer\ 17] * -0.33$$

Class Piscina de Azulejo :

$$-47.41 + [NDVI_1] * 57.59 + [AC9] * 21.69 + [AC3] * 0 + [AC2] * 11.64 + [Mean\ Layer\ 24] * 0.11 + [Mean\ Layer\ 22] * -0.15 + [Mean\ Layer\ 19] * -0.01 + [Mean\ Layer\ 12] * 0$$

Class Piscina de Vinil :

$$-21.88 + [NDVI_4] * -21.19 + [AC14] * -30.01 + [AC12] * 4.94 + [AC10] * 10.07 + [Standard\ deviation\ Layer\ 22] * -0.39 + [Standard\ deviation\ Layer\ 20] * 0.65 + [Standard\ deviation\ Layer\ 17] * -0.86 + [Standard\ deviation\ Layer\ 10] * 0 + [Mean\ Layer\ 25] * -0.72 + [Mean\ Layer\ 22] * -0.12 + [Mean\ Layer\ 16] * 0$$

Class Plástico :

$$-48.92 + [AC9] * -11.78 + [AC17] * 0 + [AC15] * 28.11 + [Standard\ deviation\ Layer\ 25] * 1.24 + [Standard\ deviation\ Layer\ 23] * -0.35 + [Standard\ deviation\ Layer\ 2] * 0 + [Standard\ deviation\ Layer\ 16] * 0.02 + [Mean\ Layer\ 25] * -0.14 + [Mean\ Layer\ 23] * 0.24 + [Mean\ Layer\ 20] * 0.33 + [Mean\ Layer\ 17] * 0.69 + [Mean\ Layer\ 13] * 0 + [Mean\ Layer\ 11] * 0$$

Class Policarbonato :

$$-38.69 + [NDVI_1] * 71.6 + [AC2] * 27.54 + [AC16] * 4.56 + [Standard\ deviation\ Layer\ 8] * -0.01 + [Standard\ deviation\ Layer\ 7] * -0.01 + [Standard\ deviation\ Layer\ 16] * 0.01 + [Standard\ deviation\ Layer\ 1] * 0.01 + [Mean\ Layer\ 22] * -0.23 + [Mean\ Layer\ 13] * -0.01$$

Class Solo Exposto :

$$41.69 + [AC2] * -25.39 + [AC1] * -17.89 + [Standard\ deviation\ Layer\ 2] * 0 + [Standard\ deviation\ Layer\ 14] * 0 + [Standard\ deviation\ Layer\ 11] * -0.01 + [Standard\ deviation\ Layer\ 1] * -0.02 + [Mean\ Layer\ 25] * -0.31 + [Mean\ Layer\ 22] * 0.12 + [Mean\ Layer\ 18] * -0.24 + [Mean\ Layer\ 17] * -0.18 + [Mean\ Layer\ 13] * 0$$

Class Sombra :

$$58.68 + [NDVI_1] * 76.47 + [AC8] * -54.35 + [AC5] * 0 + [AC17] * 0 + [AC16] * 7.4 + [AC11] * -13.88 + [Standard\ deviation\ Layer\ 6] * 0 + [Standard\ deviation\ Layer\ 19] * 0.74 + [Standard\ deviation\ Layer\ 15] * -0.02 + [Mean\ Layer\ 7] * 0 + [Mean\ Layer\ 20] * 0.19 + [Mean\ Layer\ 14] * 0.01$$

Class Vegetação Arbórea :

$$1.23 + [NDVI_3] * -14.26 + [NDVI_2] * 13.6 + [NDVI_11] * 14.92 + [AC7] * -35.09 + [AC3] * 0 + [AC15] * 36.69 + [AC14] * 3.6 + [AC11] * -9.96 + [AC10] * -16.73 + [Standard\ deviation\ Layer\ 7] * 0 + [Standard\ deviation\ Layer\ 20] * 0.88 + [Standard\ deviation\ Layer\ 12] * -0.01 + [Mean\ Layer\ 25] * 0.15 + [Mean\ Layer\ 22] * 0.22$$

Class Vegetação Rasteira :

$$47.19 + [AC9] * -47.85 + [AC12] * -4.42 + [Standard\ deviation\ Layer\ 25] * 0.68 + [Standard\ deviation\ Layer\ 23] * -0.6 + [Standard\ deviation\ Layer\ 21] * -0.68 + [Standard\ deviation\ Layer\ 19] * 0.4 + [Standard\ deviation\ Layer\ 15] * -0.02 + [Mean\ Layer\ 25] * -0.16 + [Mean\ Layer\ 22] * 0.19 + [Mean\ Layer\ 21] * 0.17 + [Mean\ Layer\ 18] * -0.08 + [Mean\ Layer\ 14] * 0$$

Class Vidro Aramado :

$$-13.43 + [NDVI_3] * -16.71 + [NDVI_1] * 25.73 + [Standard\ deviation\ Layer\ 5] * 0 + [Standard\ deviation\ Layer\ 3] * 0 + [Standard\ deviation\ Layer\ 23] * -0.44 + [Standard\ deviation\ Layer\ 18] * -1.48 + [Standard\ deviation\ Layer\ 16] * 0.01 + [Mean\ Layer\ 25] * 0.72 + [Mean\ Layer\ 21] * -0.27$$

APÊNDICE B – ÁRVORES DE DECISÃO PARA CENA WORLDVIEW-3.

B.1 Nível de Legenda 1

B.1.1 Árvore Algoritmo BFTree

```
AC_7 < 0.88173
| AC_16 < 0.48206
| | Mean Layer 2 < -94.64178
| | | SAVI < 1.18387: Sombra(2.0/0.0)
| | | SAVI >= 1.18387: Vegetacao Arborea(23.0/0.0)
| | Mean Layer 2 >= -94.64178
| | | Mean Layer 3 < 159.09893: Sombra(17.0/1.0)
| | | Mean Layer 3 >= 159.09893
| | | | Mean Layer 19 < -1364.12604
| | | | | SAVI < 0.41231
| | | | | SAVI < 0.21595: Diversas(2.0/0.0)
| | | | | SAVI >= 0.21595: Ceramica(2.0/0.0)
| | | | | SAVI >= 0.41231: Vegetacao Rasteira(18.0/0.0)
| | | Mean Layer 19 >= -1364.12604
| | | | Mean Layer 28 < 3.62156
| | | | | Standard deviation Layer 7 < 258.56794: Solo Exposto(15.0/1.0)
| | | | | Standard deviation Layer 7 >= 258.56794
| | | | | Mean Layer 36 < 4.52694
| | | | | | Mean Layer 39 < -3.53126: Diversas(8.0/1.0)
| | | | | | Mean Layer 39 >= -3.53126: Pav_Viaria(20.0/0.0)
| | | | | | Mean Layer 36 >= 4.52694: Ceramica(7.0/0.0)
| | | Mean Layer 28 >= 3.62156
| | | | AC_6 < -3037.38281: Pav_ao_Viaria(13.0/0.0)
| | | | AC_6 >= -3037.38281
| | | | | NDVI_2 < 0.29866
| | | | | | Standard deviation Layer 6 < 244.92269
| | | | | | SAVI < 0.71808
| | | | | | NDVI_2 < -0.03037: Lago(3.0/0.0)
| | | | | | NDVI_2 >= -0.03037: Pav_ao_Viaria(2.0/1.0)
| | | | | | SAVI >= 0.71808: Vegetacao Arborea(3.0/0.0)
| | | | | | Standard deviation Layer 6 >= 244.92269: Diversas(5.0/0.0)
| | | | | NDVI_2 >= 0.29866: Piscina(7.0/0.0)
| AC_16 >= 0.48206
| | Mean Layer 38 < 6.35114
| | | Mean Layer 17 < -0.09895
| | | | Mean Layer 6 < 1044.44389
| | | | SAVI < -0.70507: Piscina(3.0/0.0)
| | | | SAVI >= -0.70507
| | | | | AC_6 < -517.85855: Pav_ao_Viaria(2.0/1.0)
| | | | | AC_6 >= -517.85855: Sombra(3.0/0.0)
| | | | Mean Layer 6 >= 1044.44389
| | | | | Mean Layer 48 < 2.18397
| | | | | Standard deviation Layer 30 < 70.67038
```

```

| | | | | Mean Layer 49 < -0.81997: Pav_Varia(6.0/4.0)
| | | | | Mean Layer 49 >= -0.81997: Pav_Varia(40.0/2.0)
| | | | | Standard deviation Layer 30 >= 70.67038
| | | | | NDVI_4 < 0.10212: Ceramica(2.0/0.0)
| | | | | NDVI_4 >= 0.10212: Diversas(2.0/0.0)
| | | | | Mean Layer 48 >= 2.18397: Diversas(5.0/0.0)
| | | Mean Layer 17 >= -0.09895
| | | Mean Layer 21 < 238.44894
| | | | Standard deviation Layer 40 < 14.76662: Diversas(41.0/2.0)
| | | | Standard deviation Layer 40 >= 14.76662: Sombra(1.0/2.0)
| | | | Mean Layer 21 >= 238.44894
| | | | SAVI < 0.18194: Coberturas_Metalicas(4.0/0.0)
| | | | SAVI >= 0.18194: Sombra(1.0/2.0)
| | | Mean Layer 38 >= 6.35114
| | | Mean Layer 39 < 12.81022: Diversas(92.0/5.0)
| | | Mean Layer 39 >= 12.81022
| | | | AC_18 < -1160.42228: Pav_ao_Varia(3.0/0.0)
| | | | AC_18 >= -1160.42228: Diversas(1.0/1.0)
AC_7 >= 0.88173
| Mean Layer 13 < 1485.0206
| | AC_4 < 926.56904
| | | Standard deviation Layer 6 < 290.85972
| | | Standard deviation Layer 28 < 42.20703
| | | | NDVI_4 < -0.06364: Lago(2.0/0.0)
| | | | NDVI_4 >= -0.06364: Pav_Varia(1.0/2.0)
| | | | Standard deviation Layer 28 >= 42.20703: Coberturas_Metalicas(6.0/0.0)
| | | Standard deviation Layer 6 >= 290.85972: Diversas(14.0/1.0)
| | AC_4 >= 926.56904: Piscina(10.0/0.0)
| Mean Layer 13 >= 1485.0206
| | Mean Layer 7 < 1558.30044
| | | SAVI < -0.43621: Piscina(2.0/0.0)
| | | SAVI >= -0.43621: Diversas(2.0/0.0)
| | Mean Layer 7 >= 1558.30044: Coberturas_Metalicas(95.0/2.0)

```

Tamanho da árvore: 77

B.1.2 Árvore Algoritmo LMT

: LM_1:64/64 (513)

Tamanho da árvore: 1

LM_1:

Class Sombra :

$24.23 + [AC_19] * -8.58 + [AC_14] * 2.59 + [Standard\ deviation\ Layer\ 46] * 0.42 +$
 $[Standard\ deviation\ Layer\ 34] * 1.54 + [Standard\ deviation\ Layer\ 29] * 0.03 + [Standard$
 $deviation\ Layer\ 15] * 0 + [Mean\ Layer\ 8] * 0 + [Mean\ Layer\ 7] * -0.02 + [Mean$
 $Layer\ 6] * -0.01 + [Mean\ Layer\ 5] * 0 + [Mean\ Layer\ 42] * 1.38 + [Mean\ Layer\ 4] * -$

$0.03 + [\text{Mean Layer 33}] * -0.05 + [\text{Mean Layer 3}] * -0.01 + [\text{Mean Layer 25}] * -0.01 + [\text{Mean Layer 18}] * 0$

Class Lago :

$92.34 + [\text{Standard deviation Layer 5}] * -0.52 + [\text{Standard deviation Layer 4}] * -0.12 + [\text{Standard deviation Layer 20}] * -0.03 + [\text{Standard deviation Layer 14}] * -0.22 + [\text{Standard deviation Layer 13}] * -0.05 + [\text{Mean Layer 9}] * -0.01 + [\text{Mean Layer 8}] * -0.01 + [\text{Mean Layer 34}] * -0.07 + [\text{Mean Layer 17}] * -2.48 + [\text{Mean Layer 14}] * -0.04 + [\text{Mean Layer 12}] * -0.01 + [\text{Mean Layer 11}] * -0.01$

Class Pavimentação Viária :

$-1.3 + [\text{NDVI}_3] * -1.94 + [\text{NDVI}_1] * -0.57 + [\text{AC}_7] * 4.52 + [\text{AC}_3_Todas] * 0 + [\text{AC}_1_Todas] * -0.34 + [\text{AC}_{16_Todas}] * 0.59 + [\text{AC}_{15_Todas}] * -0.25 + [\text{AC}_{14}] * -3.77 + [\text{Standard deviation Layer 7}] * 0 + [\text{Standard deviation Layer 49}] * -0.13 + [\text{Standard deviation Layer 44}] * 0.23 + [\text{Standard deviation Layer 42}] * 0.11 + [\text{Standard deviation Layer 41}] * -0.06 + [\text{Standard deviation Layer 40}] * 0.09 + [\text{Standard deviation Layer 33}] * -0.01 + [\text{Standard deviation Layer 32}] * 0.02 + [\text{Standard deviation Layer 23}] * 0 + [\text{Standard deviation Layer 17}] * 0.3 + [\text{Standard deviation Layer 10}] * 0 + [\text{Mean Layer 49}] * 0.18 + [\text{Mean Layer 45}] * -0.04 + [\text{Mean Layer 43}] * -0.05 + [\text{Mean Layer 41}] * -0.07 + [\text{Mean Layer 38}] * -0.04 + [\text{Mean Layer 35}] * 0.02 + [\text{Mean Layer 33}] * 0.01 + [\text{Mean Layer 31}] * 0.03 + [\text{Mean Layer 30}] * 0 + [\text{Mean Layer 29}] * 0 + [\text{Mean Layer 23}] * 0 + [\text{Mean Layer 21}] * 0 + [\text{Mean Layer 2}] * 0 + [\text{Mean Layer 17}] * -0.11 + [\text{Mean Layer 16}] * 0$

Class Pavimentação Não Viária :

$-13.76 + [\text{NDVI}_2] * -22.56 + [\text{AC}_8] * 16.58 + [\text{AC}_1_Todas] * -0.64 + [\text{AC}_{16_Todas}] * -3.02 + [\text{Standard deviation Layer 39}] * 0.26 + [\text{Standard deviation Layer 36}] * 0.08 + [\text{Standard deviation Layer 35}] * -0.83 + [\text{Standard deviation Layer 33}] * 0.01 + [\text{Standard deviation Layer 3}] * 0 + [\text{Standard deviation Layer 28}] * -0.03 + [\text{Standard deviation Layer 27}] * 0.02 + [\text{Standard deviation Layer 24}] * -0.01 + [\text{Standard deviation Layer 21}] * 0.01 + [\text{Standard deviation Layer 11}] * 0 + [\text{Mean Layer 9}] * 0 + [\text{Mean Layer 48}] * -0.23 + [\text{Mean Layer 41}] * 0.05 + [\text{Mean Layer 40}] * 0.04 + [\text{Mean Layer 38}] * 0.11 + [\text{Mean Layer 37}] * 0.08 + [\text{Mean Layer 35}] * 0.04 + [\text{Mean Layer 32}] * -0.04 + [\text{Mean Layer 31}] * 0.02 + [\text{Mean Layer 29}] * 0 + [\text{Mean Layer 28}] * 0 + [\text{Mean Layer 25}] * 0 + [\text{Mean Layer 24}] * -0.01 + [\text{Mean Layer 23}] * 0 + [\text{Mean Layer 22}] * 0 + [\text{Mean Layer 17}] * -0.1 + [\text{Mean Layer 16}] * 0 + [\text{Mean Layer 1}] * 0$

Class Coberturas Diversas :

$-0.68 + [\text{NDVI}_4] * 4.5 + [\text{AC}_4_Todas] * 0 + [\text{AC}_1_Todas] * -0.3 + [\text{Standard deviation Layer 48}] * 0.61 + [\text{Standard deviation Layer 40}] * -0.06 + [\text{Standard deviation Layer 37}] * 0.06 + [\text{Standard deviation Layer 32}] * -0.03 + [\text{Standard deviation Layer 26}] * 0.01 + [\text{Standard deviation Layer 23}] * 0 + [\text{Standard deviation Layer 17}] * -1.03 + [\text{Mean Layer 49}] * 0.08 + [\text{Mean Layer 44}] * 0.2 + [\text{Mean Layer 40}] * 0.05 + [\text{Mean Layer 39}] * -0.09 + [\text{Mean Layer 38}] * 0.1 + [\text{Mean Layer 36}] * -0.03 + [\text{Mean Layer 35}] * -0.02 + [\text{Mean Layer 33}] * -0.01 + [\text{Mean Layer 30}] * 0 + [\text{Mean Layer 29}] * 0 + [\text{Mean Layer 25}] * 0 + [\text{Mean Layer 23}] * 0 + [\text{Mean Layer 20}] * 0 + [\text{Mean Layer 17}] * 0.3$

Class Solo Exposto :

-21.01 + [SAVI] * 3.22 + [NDVI_4] * -9.2 + [NDVI_2] * -22.46 + [NDVI_1] * 9.19 + [AC_8] * 11.5 + [AC_7] * 7.43 + [AC_1_Todas] * -0.66 + [AC_19] * -1.74 + [AC_17_Todas] * 0 + [AC_16_Todas] * -6.98 + [AC_10] * 6.28 + [Standard deviation Layer 2] * -0.01 + [Standard deviation Layer 18] * 0 + [Standard deviation Layer 1] * -0.01 + [Mean Layer 43] * -0.12 + [Mean Layer 33] * 0.01 + [Mean Layer 30] * -0.01 + [Mean Layer 24] * 0 + [Mean Layer 23] * 0 + [Mean Layer 22] * 0 + [Mean Layer 21] * 0 + [Mean Layer 2] * 0 + [Mean Layer 1] * 0

Class Coberturas Metálicas :

-10.98 + [NDVI_3] * 0.05 + [NDVI_1] * -0.35 + [AC_9] * -0.38 + [AC_1_Todas] * 2.27 + [AC_19] * 31.9 + [AC_12] * 0.65 + [AC_11] * 3.74 + [AC_10] * 3.52 + [Standard deviation Layer 8] * 0 + [Standard deviation Layer 6] * 0 + [Standard deviation Layer 49] * 0.2 + [Standard deviation Layer 40] * 0.11 + [Standard deviation Layer 39] * 0.04 + [Standard deviation Layer 38] * -0.13 + [Standard deviation Layer 37] * -0.08 + [Standard deviation Layer 36] * 0.1 + [Standard deviation Layer 35] * 0.09 + [Standard deviation Layer 32] * 0.02 + [Standard deviation Layer 31] * 0.02 + [Standard deviation Layer 30] * 0 + [Standard deviation Layer 29] * -0.01 + [Standard deviation Layer 26] * -0.01 + [Standard deviation Layer 17] * 0.74 + [Mean Layer 9] * 0 + [Mean Layer 45] * -0.07 + [Mean Layer 43] * 0.07 + [Mean Layer 42] * 0.04 + [Mean Layer 37] * -0.17 + [Mean Layer 35] * -0.04 + [Mean Layer 34] * 0.03 + [Mean Layer 3] * 0 + [Mean Layer 28] * 0 + [Mean Layer 20] * 0 + [Mean Layer 18] * 0 + [Mean Layer 17] * 0.1 + [Mean Layer 14] * 0 + [Mean Layer 10] * 0

Class Coberturas Cerâmicas :

-22.62 + [NDVI_4] * -4.31 + [AC_19] * -17.52 + [AC_16_Todas] * -1.54 + [AC_15_Todas] * -0.76 + [AC_11] * -11.23 + [Standard deviation Layer 48] * 0.19 + [Standard deviation Layer 47] * 0.35 + [Standard deviation Layer 38] * 0.22 + [Standard deviation Layer 34] * 0.11 + [Standard deviation Layer 32] * 0.03 + [Standard deviation Layer 24] * 0.01 + [Standard deviation Layer 22] * 0.01 + [Standard deviation Layer 21] * 0 + [Mean Layer 45] * -0.05 + [Mean Layer 42] * -0.13 + [Mean Layer 40] * -0.21 + [Mean Layer 38] * 0.11 + [Mean Layer 37] * 0.16 + [Mean Layer 36] * 0.04 + [Mean Layer 35] * -0.12 + [Mean Layer 30] * -0.01 + [Mean Layer 29] * 0.01 + [Mean Layer 22] * 0 + [Mean Layer 21] * 0 + [Mean Layer 17] * -0.28 + [Mean Layer 16] * 0 + [Mean Layer 1] * -0.01

Class Piscina :

-0.47 + [AC_4_Todas] * 0 + [AC_1_Todas] * 2.42 + [AC_19] * 29.07 + [AC_18_Todas] * 0 + [AC_15_Todas] * 0.81 + [AC_14] * -14.82 + [Mean Layer 8] * 0 + [Mean Layer 7] * -0.01 + [Mean Layer 45] * 0.48 + [Mean Layer 42] * 0.76 + [Mean Layer 3] * 0.01 + [Mean Layer 22] * 0 + [Mean Layer 21] * 0 + [Mean Layer 19] * 0 + [Mean Layer 17] * -1.25

Class Vegetação Arbórea :

-27.85 + [SAVI] * 2.28 + [NDVI_3] * 5.32 + [NDVI_1] * 3.18 + [AC_7] * -2.93 + [AC_5_Todas] * 0 + [AC_1_Todas] * -0.01 + [AC_18_Todas] * 0 + [AC_15_Todas] * 0.19 + [AC_14] * 2.02 + [Standard deviation Layer 8] * 0.01 + [Standard deviation Layer 42] * 1.65 + [Standard deviation Layer 38] * -0.71 + [Standard deviation Layer 35] * 0.83 + [Standard deviation Layer 3] * 0.03 + [Standard deviation Layer 27] * -0.04 + [Mean Layer 9] * 0.01 + [Mean Layer 5] * 0 + [Mean Layer 46] * 0.23 + [Mean Layer 4] * -0.01 + [Mean Layer 36] * 0.36 + [Mean Layer 35] * 0.12 + [Mean Layer 33] * 0.03

+ [Mean Layer 31] * 0.03 + [Mean Layer 3] * 0 + [Mean Layer 25] * -0.02 + [Mean Layer 22] * 0 + [Mean Layer 20] * 0 + [Mean Layer 2] * 0 + [Mean Layer 13] * 0 + [Mean Layer 1] * 0

Class Vegetação Rasteira :

-29.7 + [SAVI] * 3.58 + [NDVI_4] * 3.76 + [NDVI_3] * 2.11 + [AC_7] * -2.54 + [AC_5_Todas] * 0 + [AC_4_Todas] * 0 + [AC_19] * -23.06 + [AC_18_Todas] * 0 + [AC_14] * 11.09 + [AC_11] * -12.66 + [Standard deviation Layer 33] * -0.04 + [Standard deviation Layer 2] * -0.06 + [Standard deviation Layer 17] * 0.82 + [Standard deviation Layer 1] * -0.05 + [Mean Layer 8] * 0 + [Mean Layer 7] * 0 + [Mean Layer 49] * 0.87 + [Mean Layer 38] * -0.07 + [Mean Layer 37] * 0.06 + [Mean Layer 35] * 0.03 + [Mean Layer 27] * 0 + [Mean Layer 25] * 0.01 + [Mean Layer 2] * 0 + [Mean Layer 19] * 0

B.2 Nível de Legenda 2

B.2.1 Árvore Algoritmo BFTree

```

Mean Layer 4 < 4614.08506
| Mean Layer 2 < -94.64178
| | SAVI < 1.18387: Sombra(2.0/0.0)
| | SAVI >= 1.18387: Vegetacao Arborea(23.0/0.0)
| Mean Layer 2 >= -94.64178
| | Mean Layer 3 < 159.09893: Sombra(20.0/1.0)
| | Mean Layer 3 >= 159.09893
| | | Mean Layer 44 < -16.06221: Piscina de Azulejo(15.0/0.0)
| | | Mean Layer 44 >= -16.06221
| | | | Mean Layer 31 < -117.26917: Cimento Pintado de Verde(13.0/0.0)
| | | | Mean Layer 31 >= -117.26917
| | | | | Mean Layer 23 < -416.60882
| | | | | Mean Layer 26 < 94.35898
| | | | | Mean Layer 28 < 17.4283
| | | | | Standard deviation Layer 7 < 258.56794: Solo Exposto(15.0/2.0)
| | | | | Standard deviation Layer 7 >= 258.56794
| | | | | | Mean Layer 34 < 30.20742: Asfalto_Pintado_Vermelho(17.0/1.0)
| | | | | | Mean Layer 34 >= 30.20742
| | | | | | Mean Layer 45 < -9.3735: Ceramica_Iluminada(6.0/0.0)
| | | | | | Mean Layer 45 >= -9.3735
| | | | | | Standard deviation Layer 48 < 6.32668
| | | | | | SAVI < 0.19591: Pedra Mineira(1.0/1.0)
| | | | | | SAVI >= 0.19591: Ceramica_Escura(3.0/0.0)
| | | | | | Standard deviation Layer 48 >= 6.32668: Concreto Pint Verm
| | | | | Mean Layer 28 >= 17.4283: Pedra Mineira(15.0/0.0)
| | | | | Mean Layer 26 >= 94.35898: Cimento Pintado de Vermelho(16.0/0.0)
| | | | Mean Layer 23 >= -416.60882
| | | | AC_19 < -0.57621
| | | | | Mean Layer 38 < -0.28816: Vegetacao Rasteira(21.0/1.0)
| | | | | Mean Layer 38 >= -0.28816
| | | | | SAVI < 0.46958: Ceramica_Escura(4.0/0.0)

```

```

| | | | | SAVI >= 0.46958
| | | | | NDVI_4 < 0.55311
| | | | | SAVI < 1.05806
| | | | | SAVI < 0.70227: Amianto(1.0/1.0)
| | | | | SAVI >= 0.70227: Policarbonato(3.0/0.0)
| | | | | SAVI >= 1.05806: Vegetacao Arborea(3.0/0.0)
| | | | | NDVI_4 >= 0.55311: Lona_Azul(4.0/0.0)
| AC_19 >= -0.57621
| | AC_19 < -0.0959
| | Mean Layer 29 < 108.71498
| | Mean Layer 5 < 1475.08395
| | AC_14 < 0.37109
| | AC_6 < -603.72896
| | | Mean Layer 36 < 4.91846: Asfalto(17.0/1.0)
| | | Mean Layer 36 >= 4.91846: Carvao_Coque(1.0/1.0)
| | AC_6 >= -603.72896
| | | SAVI < 0.10642: Fibra de Vidro(4.0/0.0)
| | | SAVI >= 0.10642: Lago(1.0/3.0)
| AC_14 >= 0.37109
| | Mean Layer 37 < -24.49251: Seixo_Argila(7.0/0.0)
| | Mean Layer 37 >= -24.49251
| | | Mean Layer 48 < 0.03491
| | | AC_6 < -1697.02986: Concreto Pintado de Azul(6.0/0.0)
| | | AC_6 >= -1697.02986
| | | | Mean Layer 21 < -392.61873: Vidro Aramado(6.0/0.0)
| | | | Mean Layer 21 >= -392.61873
| | | | Mean Layer 26 < 46.86166
| | | | SAVI < 0.20864: Carvao_Coque(4.0/0.0)
| | | | SAVI >= 0.20864
| | | | NDVI_4 < 0.09155: Lago(2.0/0.0)
| | | | NDVI_4 >= 0.09155
| | | | SAVI < 0.28649: Sombra(2.0/0.0)
| | | | SAVI >= 0.28649: Concreto(2.0/1.0)
| | | | Mean Layer 26 >= 46.86166: Policarbonato(7.0/0.0)
| | Mean Layer 48 >= 0.03491
| | | Mean Layer 9 < 1957.98301
| | | Mean Layer 35 < 1.44506: Amianto(10.0/0.0)
| | | Mean Layer 35 >= 1.44506: Lona_Verde(5.0/1.0)
| | | Mean Layer 9 >= 1957.98301: Pedregulho(7.0/0.0)
| Mean Layer 5 >= 1475.08395
| | Mean Layer 15 < 924.91433
| | | Mean Layer 31 < -41.18571: Pastilha Esmaltada(2.0/1.0)
| | | Mean Layer 31 >= -41.18571: Asf. Pint Branco(15.0/0.0)
| Mean Layer 15 >= 924.91433
| | Mean Layer 45 < 5.46122
| | | Mean Layer 36 < -12.7369
| | | A_Bri < 922.2203: Madeira_Compensada(9.0/0.0)
| | | A_Bri >= 922.2203: Galvalume A(2.0/0.0)
| | Mean Layer 36 >= -12.7369
| | | Mean Layer 9 < 2334.39255

```


32.3 + [AC_8] * -2.85 + [AC_6] * 0 + [AC_19] * -2.61 + [AC_10] * -5.73 + [Standard deviation Layer 38] * 0.1 + [Standard deviation Layer 34] * 0.28 + [Mean Layer 8] * 0 + [Mean Layer 7] * 0 + [Mean Layer 6] * -0.01 + [Mean Layer 42] * 0.56 + [Mean Layer 4] * -0.01 + [Mean Layer 25] * -0.01 + [Mean Layer 18] * 0

Class Cerâmica Iluminada :

-13.85 + [SAVI] * -2.91 + [NDVI_3] * -7.24 + [NDVI_1] * -4.31 + [AC_7] * -24.49 + [AC_1] * -3.53 + [Standard deviation Layer 43] * 0.29 + [Standard deviation Layer 40] * 0.18 + [Standard deviation Layer 37] * 0.23 + [Standard deviation Layer 25] * 0.02 + [Mean Layer 8] * 0 + [Mean Layer 5] * 0 + [Mean Layer 45] * -0.4 + [Mean Layer 43] * -0.05 + [Mean Layer 37] * 0.08 + [Mean Layer 34] * 0.05 + [Mean Layer 26] * -0.01 + [Mean Layer 22] * 0 + [Mean Layer 21] * -0.01

Class Cerâmica Escura :

-9.67 + [AC_1] * -1.62 + [AC_19] * -15.99 + [AC_11] * -16.35 + [Standard deviation Layer 38] * 0.15 + [Standard deviation Layer 24] * 0.01 + [Mean Layer 48] * -0.32 + [Mean Layer 42] * -0.3 + [Mean Layer 41] * 0.09 + [Mean Layer 37] * 0.11 + [Mean Layer 3] * 0 + [Mean Layer 29] * 0.01 + [Mean Layer 22] * 0 + [Mean Layer 2] * 0 + [Mean Layer 19] * 0

Class Vegetação Arbórea :

5.15 + [SAVI] * 2.81 + [NDVI_1] * 2.98 + [AC_9] * -19.77 + [AC_7] * -4.46 + [AC_4] * 0 + [AC_2] * -17.51 + [AC_14] * 3.46 + [Standard deviation Layer 38] * -0.41 + [Standard deviation Layer 35] * 0.68 + [Standard deviation Layer 29] * -0.03 + [Mean Layer 6] * 0.01 + [Mean Layer 5] * -0.01 + [Mean Layer 40] * -0.11 + [Mean Layer 4] * 0 + [Mean Layer 38] * 0.06 + [Mean Layer 33] * 0.03 + [Mean Layer 20] * 0 + [Mean Layer 2] * 0 + [Mean Layer 14] * 0

Class Lago :

48.55 + [Standard deviation Layer 5] * -0.28 + [Standard deviation Layer 13] * -0.08 + [Mean Layer 34] * -0.04 + [Mean Layer 30] * -0.06 + [Mean Layer 17] * -0.29 + [Mean Layer 14] * -0.04 + [Mean Layer 12] * 0 + [Mean Layer 11] * -0.01

Class Bloquete :

-2.83 + [Standard deviation Layer 44] * -0.88 + [Standard deviation Layer 43] * 0.34 + [Standard deviation Layer 41] * -0.1 + [Standard deviation Layer 36] * 0.17 + [Standard deviation Layer 29] * -0.02 + [Standard deviation Layer 27] * 0.02 + [Standard deviation Layer 25] * 0.01 + [Standard deviation Layer 2] * -0.01 + [Standard deviation Layer 19] * 0 + [Standard deviation Layer 17] * 0.97 + [Mean Layer 49] * 0.98 + [Mean Layer 47] * -0.3 + [Mean Layer 44] * -0.12 + [Mean Layer 41] * -0.15 + [Mean Layer 40] * 0.05 + [Mean Layer 32] * -0.01 + [Mean Layer 29] * -0.01 + [Mean Layer 27] * -0.01 + [Mean Layer 24] * -0.01 + [Mean Layer 17] * -0.15

Class Galvalume A :

-26.29 + [NDVI_2] * -19.12 + [AC_5] * 0 + [AC_2] * 5.64 + [Standard deviation Layer 36] * -0.09 + [Standard deviation Layer 34] * -0.19 + [Standard deviation Layer 25] * -0.01 + [Standard deviation Layer 24] * 0.01 + [Standard deviation Layer 17] * -0.65 + [Mean Layer 6] * 0 + [Mean Layer 45] * -0.23 + [Mean Layer 36] * -0.03 + [Mean Layer 3] * 0 + [Mean Layer 23] * 0 + [Mean Layer 2] * 0 + [Mean Layer 19] * 0 + [Mean Layer 12] * 0 + [Mean Layer 10] * 0

Class Asfalto :

$15.89 + [\text{NDVI_4}] * -3.34 + [\text{AC_14}] * -2.88 + [\text{Standard deviation Layer 9}] * 0 + [\text{Standard deviation Layer 8}] * 0 + [\text{Standard deviation Layer 44}] * 0.27 + [\text{Standard deviation Layer 43}] * 0.31 + [\text{Standard deviation Layer 21}] * 0.01 + [\text{Standard deviation Layer 20}] * 0 + [\text{Standard deviation Layer 19}] * -0.01 + [\text{Standard deviation Layer 18}] * 0 + [\text{Mean Layer 8}] * -0.01 + [\text{Mean Layer 49}] * 1.42 + [\text{Mean Layer 41}] * 0.09 + [\text{Mean Layer 21}] * 0 + [\text{Mean Layer 17}] * -0.39$

Class Carvão Coque :

$43.36 + [\text{NDVI_2}] * -8.94 + [\text{AC_5}] * 0 + [\text{AC_18}] * 0 + [\text{Standard deviation Layer 49}] * -9.14 + [\text{Standard deviation Layer 44}] * -1.43 + [\text{Standard deviation Layer 39}] * 0.38 + [\text{Standard deviation Layer 36}] * 0.28 + [\text{Standard deviation Layer 3}] * -0.02 + [\text{Standard deviation Layer 29}] * -0.21 + [\text{Standard deviation Layer 28}] * -0.05 + [\text{Standard deviation Layer 23}] * -0.03 + [\text{Standard deviation Layer 2}] * -0.11 + [\text{Mean Layer 9}] * 0 + [\text{Mean Layer 7}] * 0 + [\text{Mean Layer 34}] * -0.12 + [\text{Mean Layer 24}] * 0.02 + [\text{Mean Layer 22}] * 0$

Class Amianto :

$18.5 + [\text{NDVI_4}] * 4.74 + [\text{AC_5}] * 0 + [\text{AC_18}] * 0 + [\text{AC_10}] * -12.84 + [\text{Standard deviation Layer 49}] * -0.35 + [\text{Standard deviation Layer 48}] * -0.44 + [\text{Standard deviation Layer 44}] * -0.36 + [\text{Standard deviation Layer 37}] * 0.11 + [\text{Standard deviation Layer 35}] * 0.15 + [\text{Standard deviation Layer 33}] * -0.02 + [\text{Standard deviation Layer 23}] * -0.01 + [\text{Mean Layer 9}] * 0 + [\text{Mean Layer 7}] * 0 + [\text{Mean Layer 48}] * 0.43 + [\text{Mean Layer 37}] * 0.04 + [\text{Mean Layer 33}] * 0.01 + [\text{Mean Layer 25}] * 0.01 + [\text{Mean Layer 23}] * 0 + [\text{Mean Layer 22}] * 0 + [\text{Mean Layer 17}] * 0.3$

Class Cimento Pintado Verde :

$-3.53 + [\text{SAVI}] * 4.16 + [\text{AC_8}] * -4.49 + [\text{AC_7}] * -11.73 + [\text{AC_18}] * 0 + [\text{AC_10}] * -3.7 + [\text{Standard deviation Layer 36}] * 0.14 + [\text{Mean Layer 48}] * 0.84 + [\text{Mean Layer 46}] * -0.15 + [\text{Mean Layer 40}] * 0.18 + [\text{Mean Layer 33}] * -0.01 + [\text{Mean Layer 31}] * -0.11 + [\text{Mean Layer 27}] * 0 + [\text{Mean Layer 19}] * 0$

Class Cimento Pintado Vermelho :

$-29.12 + [\text{NDVI_2}] * -38.06 + [\text{AC_8}] * 7.41 + [\text{Standard deviation Layer 2}] * -0.01 + [\text{Mean Layer 45}] * -0.45 + [\text{Mean Layer 40}] * 0.51 + [\text{Mean Layer 39}] * -0.06 + [\text{Mean Layer 38}] * 0.07 + [\text{Mean Layer 30}] * 0.01 + [\text{Mean Layer 29}] * 0.01 + [\text{Mean Layer 28}] * -0.02 + [\text{Mean Layer 25}] * 0 + [\text{Mean Layer 2}] * 0 + [\text{Mean Layer 17}] * -0.56 + [\text{Mean Layer 10}] * 0$

Class Asfalto Pintado Branco :

$9.41 + [\text{AC_15}] * -3.56 + [\text{Standard deviation Layer 6}] * 0.01 + [\text{Standard deviation Layer 49}] * -0.34 + [\text{Standard deviation Layer 45}] * 0.28 + [\text{Standard deviation Layer 43}] * -0.33 + [\text{Standard deviation Layer 42}] * -0.34 + [\text{Standard deviation Layer 33}] * -0.03 + [\text{Standard deviation Layer 28}] * -0.02 + [\text{Standard deviation Layer 27}] * -0.02 + [\text{Standard deviation Layer 23}] * -0.01 + [\text{Standard deviation Layer 17}] * -1.36 + [\text{Standard deviation Layer 1}] * 0.01 + [\text{Mean Layer 49}] * 0.27 + [\text{Mean Layer 41}] * -0.2 + [\text{Mean Layer 36}] * -0.05 + [\text{Mean Layer 34}] * -0.04 + [\text{Mean Layer 33}] * 0.02 + [\text{Mean Layer 31}] * 0.01 + [\text{Mean Layer 20}] * 0 + [\text{Mean Layer 16}] * 0 + [\text{Mean Layer 15}] * 0$

Class Aço Galvanizado :

$0.51 + [\text{SAVI}] * -9.33 + [\text{NDVI_4}] * -11.43 + [\text{NDVI_2}] * -21.69 + [\text{AC_8}] * 0.36 + [\text{AC_19}] * 4.59 + [\text{AC_14}] * -6.51 + [\text{AC_10}] * 4.93 + [\text{Standard deviation Layer 7}] * 0 + [\text{Standard deviation Layer 6}] * -0.01 + [\text{Standard deviation Layer 49}] * 0.39 + [\text{Standard deviation Layer 43}] * -0.4 + [\text{Standard deviation Layer 40}] * -0.11 + [\text{Standard deviation Layer 39}] * -0.07 + [\text{Standard deviation Layer 38}] * 0.14 + [\text{Standard deviation Layer 18}] * 0 + [\text{Mean Layer 8}] * 0 + [\text{Mean Layer 7}] * 0 + [\text{Mean Layer 35}] * -0.03 + [\text{Mean Layer 31}] * -0.01 + [\text{Mean Layer 30}] * -0.02 + [\text{Mean Layer 28}] * 0.01 + [\text{Mean Layer 2}] * 0 + [\text{Mean Layer 18}] * 0$

Class Pedra Mineira :

$-15.76 + [\text{AC_8}] * 3.15 + [\text{AC_16}] * -10.45 + [\text{Standard deviation Layer 49}] * -0.55 + [\text{Standard deviation Layer 33}] * 0.02 + [\text{Standard deviation Layer 18}] * 0 + [\text{Mean Layer 48}] * -0.15 + [\text{Mean Layer 44}] * -0.07 + [\text{Mean Layer 40}] * 0.05 + [\text{Mean Layer 38}] * 0.17 + [\text{Mean Layer 37}] * 0.1 + [\text{Mean Layer 34}] * 0.13 + [\text{Mean Layer 32}] * -0.03 + [\text{Mean Layer 28}] * 0 + [\text{Mean Layer 25}] * 0.02 + [\text{Mean Layer 24}] * -0.01 + [\text{Mean Layer 23}] * -0.01$

Class Piscina de Azulejo :

$0.66 + [\text{AC_1}] * 2.53 + [\text{AC_19}] * 5.32 + [\text{AC_14}] * -21.06 + [\text{Standard deviation Layer 35}] * -0.34 + [\text{Standard deviation Layer 30}] * 0.04 + [\text{Mean Layer 7}] * 0 + [\text{Mean Layer 5}] * 0 + [\text{Mean Layer 44}] * -0.13 + [\text{Mean Layer 42}] * 0.06 + [\text{Mean Layer 34}] * -0.07 + [\text{Mean Layer 31}] * -0.1 + [\text{Mean Layer 28}] * 0.01 + [\text{Mean Layer 17}] * -0.32$

Class Asfalto Pintado Vermelho :

$2.16 + [\text{AC_3}] * 0 + [\text{AC_12}] * -4.49 + [\text{Standard deviation Layer 47}] * -0.76 + [\text{Standard deviation Layer 45}] * -0.76 + [\text{Standard deviation Layer 44}] * 1.33 + [\text{Standard deviation Layer 39}] * -0.14 + [\text{Standard deviation Layer 32}] * -0.03 + [\text{Standard deviation Layer 22}] * 0 + [\text{Mean Layer 44}] * 0.05 + [\text{Mean Layer 43}] * -0.02 + [\text{Mean Layer 31}] * 0.06 + [\text{Mean Layer 30}] * 0.01 + [\text{Mean Layer 28}] * -0.01 + [\text{Mean Layer 2}] * 0 + [\text{Mean Layer 16}] * 0 + [\text{Mean Layer 10}] * 0$

Class CRFS :

$-8.26 + [\text{SAVI}] * -16.02 + [\text{AC_14}] * -10.27 + [\text{AC_10}] * 5.68 + [\text{Standard deviation Layer 47}] * 0.52 + [\text{Standard deviation Layer 43}] * 0.31 + [\text{Standard deviation Layer 41}] * -0.15 + [\text{Standard deviation Layer 36}] * -1.03 + [\text{Standard deviation Layer 30}] * -0.04 + [\text{Standard deviation Layer 29}] * 0.03 + [\text{Standard deviation Layer 26}] * 0.01 + [\text{Standard deviation Layer 20}] * 0 + [\text{Standard deviation Layer 17}] * -0.92 + [\text{Mean Layer 40}] * -0.08 + [\text{Mean Layer 37}] * 0.06 + [\text{Mean Layer 34}] * -0.13 + [\text{Mean Layer 30}] * 0 + [\text{Mean Layer 26}] * -0.02 + [\text{Mean Layer 24}] * 0 + [\text{Mean Layer 19}] * 0 + [\text{Mean Layer 17}] * 0.23 + [\text{Mean Layer 1}] * 0$

Class Solo Exposto :

$-6.26 + [\text{AC_8}] * 13.09 + [\text{AC_4}] * 0 + [\text{AC_2}] * -9.42 + [\text{AC_19}] * -5.79 + [\text{AC_16}] * -4.7 + [\text{AC_10}] * 3.68 + [\text{Standard deviation Layer 7}] * -0.01 + [\text{Standard deviation Layer 49}] * -3.12 + [\text{Standard deviation Layer 33}] * -0.03 + [\text{Standard deviation Layer 20}] * 0 + [\text{Standard deviation Layer 18}] * 0 + [\text{Mean Layer 23}] * 0 + [\text{Mean Layer 22}] * 0 + [\text{Mean Layer 2}] * 0 + [\text{Mean Layer 17}] * -0.1$

Class Concreto :

$5.19 + [AC_9] * -6.48 + [AC_12] * -1.75 + [Standard\ deviation\ Layer\ 49] * 0.29 +$
 $[Standard\ deviation\ Layer\ 48] * 0.43 + [Standard\ deviation\ Layer\ 47] * -0.21 +$
 $[Standard\ deviation\ Layer\ 45] * -0.18 + [Standard\ deviation\ Layer\ 42] * 0.27 +$
 $[Standard\ deviation\ Layer\ 41] * 0.11 + [Standard\ deviation\ Layer\ 38] * -0.04 +$
 $[Standard\ deviation\ Layer\ 35] * -0.08 + [Standard\ deviation\ Layer\ 25] * -0.02 +$
 $[Standard\ deviation\ Layer\ 22] * 0 + [Standard\ deviation\ Layer\ 20] * 0 + [Standard\ deviation\ Layer\ 2] * 0 +$
 $[Standard\ deviation\ Layer\ 17] * -1.23 + [Mean\ Layer\ 9] * 0 + [Mean\ Layer\ 49] * -0.15 +$
 $[Mean\ Layer\ 47] * 0.11 + [Mean\ Layer\ 44] * -0.06 + [Mean\ Layer\ 36] * 0.02 +$
 $[Mean\ Layer\ 25] * 0 + [Mean\ Layer\ 22] * 0 + [Mean\ Layer\ 21] * 0$

Class Piscina de Vinil :

$-1.48 + [AC_4] * 0.01 + [AC_3] * 0 + [AC_18] * 0 + [AC_17] * 0 + [Standard\ deviation\ Layer\ 34] * 0.18 +$
 $[Mean\ Layer\ 7] * 0 + [Mean\ Layer\ 6] * 0 + [Mean\ Layer\ 48] * -0.14 + [Mean\ Layer\ 44] * 0.18 +$
 $[Mean\ Layer\ 29] * 0.01 + [Mean\ Layer\ 22] * 0 + [Mean\ Layer\ 21] * 0 + [Mean\ Layer\ 17] * -0.21$

Class Cimento Pintado Cinza :

$-12.84 + [Standard\ deviation\ Layer\ 9] * -0.01 + [Standard\ deviation\ Layer\ 47] * 1.68 +$
 $[Standard\ deviation\ Layer\ 45] * 0.95 + [Standard\ deviation\ Layer\ 4] * 0 + [Standard\ deviation\ Layer\ 39] * -0.06 +$
 $[Standard\ deviation\ Layer\ 37] * -0.19 + [Standard\ deviation\ Layer\ 19] * -0.01 + [Standard\ deviation\ Layer\ 17] * 1.29 +$
 $[Standard\ deviation\ Layer\ 14] * 0 + [Standard\ deviation\ Layer\ 1] * -0.01 + [Mean\ Layer\ 9] * 0 + [Mean\ Layer\ 8] * 0 +$
 $[Mean\ Layer\ 44] * -0.35 + [Mean\ Layer\ 41] * 0.09 + [Mean\ Layer\ 37] * 0.14 + [Mean\ Layer\ 32] * 0.02 +$
 $[Mean\ Layer\ 29] * 0 + [Mean\ Layer\ 28] * 0.03$

Class Galvalume B :

$-18.23 + [Standard\ deviation\ Layer\ 6] * 0 + [Standard\ deviation\ Layer\ 43] * 0.18 +$
 $[Standard\ deviation\ Layer\ 36] * 0.05 + [Standard\ deviation\ Layer\ 30] * 0.01 + [Standard\ deviation\ Layer\ 29] * 0.02 +$
 $[Standard\ deviation\ Layer\ 21] * 0 + [Standard\ deviation\ Layer\ 17] * 1.55 + [Mean\ Layer\ 41] * 0.01 + [Mean\ Layer\ 37] * -0.01 +$
 $[Mean\ Layer\ 36] * 0.01 + [Mean\ Layer\ 35] * -0.01 + [Mean\ Layer\ 30] * 0 + [Mean\ Layer\ 3] * 0 +$
 $[Mean\ Layer\ 25] * 0 + [Mean\ Layer\ 18] * 0 + [Mean\ Layer\ 17] * 0.61$

Class Vegetação Rasteira :

$-1.31 + [SAVI] * 2.09 + [AC_9] * -3.07 + [AC_7] * -2.85 + [AC_4] * 0 + [AC_14] * 7.76 +$
 $[AC_11] * -13.02 + [AC_10] * -4.7 + [Standard\ deviation\ Layer\ 7] * 0 + [Standard\ deviation\ Layer\ 4] * -0.01 +$
 $[Standard\ deviation\ Layer\ 3] * -0.01 + [Standard\ deviation\ Layer\ 2] * -0.01 + [Standard\ deviation\ Layer\ 17] * 0.94 +$
 $[Mean\ Layer\ 8] * 0 + [Mean\ Layer\ 49] * 2.15 + [Mean\ Layer\ 43] * 0.09 + [Mean\ Layer\ 38] * -0.09 + [Mean\ Layer\ 35] * 0.09 +$
 $[Mean\ Layer\ 25] * 0.01 + [Mean\ Layer\ 19] * 0 + [Mean\ Layer\ 11] * 0$

Class Pedregulho :

$-1.2 + [AC_12] * -8.94 + [Standard\ deviation\ Layer\ 38] * 0.16 + [Standard\ deviation\ Layer\ 36] * -0.56 +$
 $[Standard\ deviation\ Layer\ 25] * -0.01 + [Standard\ deviation\ Layer\ 19] * 0 + [Standard\ deviation\ Layer\ 1] * -0.01 +$
 $[Mean\ Layer\ 46] * -0.14 + [Mean\ Layer\ 38] * -0.08 + [Mean\ Layer\ 36] * 0.06 + [Mean\ Layer\ 35] * 0.03 + [Mean\ Layer\ 27] * -0.01 +$
 $[Mean\ Layer\ 26] * -0.02 + [Mean\ Layer\ 24] * -0.01 + [Mean\ Layer\ 21] * 0.01 + [Mean\ Layer\ 19] * 0 +$
 $[Mean\ Layer\ 17] * -0.69$

Class Madeira Compensada :

-9.63 + [AC_17] * 0 + [Standard deviation Layer 9] * 0 + [Standard deviation Layer 49] * -0.39 + [Standard deviation Layer 48] * 0.23 + [Standard deviation Layer 44] * 0.7 + [Standard deviation Layer 39] * -0.06 + [Standard deviation Layer 26] * 0.01 + [Standard deviation Layer 17] * -3.61 + [Mean Layer 49] * -0.68 + [Mean Layer 48] * 0.66 + [Mean Layer 40] * 0.06 + [Mean Layer 38] * 0.04 + [Mean Layer 36] * -0.04 + [Mean Layer 33] * -0.03 + [Mean Layer 30] * 0.04 + [Mean Layer 24] * 0 + [Mean Layer 16] * 0

Class Aço Galvanizado Brilhante :

-9.79 + [AC_6] * 0 + [AC_19] * 4.65 + [Standard deviation Layer 9] * 0 + [Standard deviation Layer 6] * 0 + [Standard deviation Layer 5] * -0.01 + [Standard deviation Layer 49] * 0.55 + [Standard deviation Layer 41] * -0.07 + [Standard deviation Layer 40] * 0.04 + [Standard deviation Layer 36] * 0.16 + [Standard deviation Layer 28] * 0.02 + [Standard deviation Layer 22] * 0 + [Standard deviation Layer 17] * 0.59 + [Standard deviation Layer 14] * 0 + [Mean Layer 8] * 0 + [Mean Layer 49] * -0.16 + [Mean Layer 47] * 0.15 + [Mean Layer 46] * 0.08 + [Mean Layer 33] * 0.01 + [Mean Layer 3] * 0 + [Mean Layer 28] * 0.01

Class Seixo Argila :

9.48 + [NDVI_4] * 5.91 + [AC_5] * 0 + [AC_11] * -4.11 + [AC_10] * -13.23 + [Standard deviation Layer 5] * -0.01 + [Standard deviation Layer 43] * -0.45 + [Standard deviation Layer 3] * -0.01 + [Standard deviation Layer 25] * 0.02 + [Standard deviation Layer 11] * 0 + [Mean Layer 7] * 0 + [Mean Layer 49] * -1.19 + [Mean Layer 42] * -0.07 + [Mean Layer 40] * 0.05 + [Mean Layer 37] * -0.22 + [Mean Layer 32] * -0.01 + [Mean Layer 25] * 0 + [Mean Layer 23] * 0.01

Class Aço Galvanizado Fosco com Manta poliéster :

-11.72 + [AC_9] * 4.27 + [AC_14] * -10.67 + [Standard deviation Layer 8] * 0 + [Standard deviation Layer 32] * 0.03 + [Standard deviation Layer 17] * -22.91 + [Mean Layer 35] * -0.15 + [Mean Layer 27] * -0.01 + [Mean Layer 24] * 0 + [Mean Layer 23] * 0.01

Class Manta Asfáltica Aluminizada :

-46.96 + [AC_5] * 0 + [AC_18] * 0 + [AC_17] * 0 + [Standard deviation Layer 7] * 0 + [Standard deviation Layer 6] * 0 + [Standard deviation Layer 21] * 0.01 + [Standard deviation Layer 18] * 0 + [Standard deviation Layer 17] * -2.88 + [Mean Layer 7] * 0 + [Mean Layer 48] * 0.06 + [Mean Layer 46] * 0.43 + [Mean Layer 41] * 0.06 + [Mean Layer 40] * 0.26 + [Mean Layer 35] * -0.05 + [Mean Layer 32] * -0.03 + [Mean Layer 30] * -0.02

Class Lona Azul :

11.87 + [NDVI_4] * 3.22 + [NDVI_2] * 2.53 + [AC_8] * -5.35 + [AC_18] * 0 + [AC_10] * -18.98 + [Standard deviation Layer 41] * -0.37 + [Standard deviation Layer 33] * -0.11 + [Mean Layer 45] * 0.15 + [Mean Layer 44] * 0.03 + [Mean Layer 42] * -0.68 + [Mean Layer 35] * 0.12 + [Mean Layer 32] * 0.04 + [Mean Layer 31] * 0 + [Mean Layer 30] * 0.01 + [Mean Layer 29] * 0.01 + [Mean Layer 25] * 0.01

Class Policarbonato :

6.67 + [AC_9] * -6.23 + [AC_6] * 0 + [AC_5] * 0 + [AC_14] * 3.29 + [AC_12] * -3.15 + [Standard deviation Layer 5] * -0.01 + [Standard deviation Layer 45] * 0.54 +

$[\text{Standard deviation Layer 43}] * -0.61 + [\text{Standard deviation Layer 41}] * 0.13 + [\text{Mean Layer 7}] * 0 + [\text{Mean Layer 5}] * 0 + [\text{Mean Layer 49}] * 0.68 + [\text{Mean Layer 48}] * -0.76 + [\text{Mean Layer 39}] * -0.1 + [\text{Mean Layer 37}] * -0.14 + [\text{Mean Layer 3}] * 0 + [\text{Mean Layer 27}] * 0.01 + [\text{Mean Layer 26}] * 0.03$

Class Aço Galvanizado Ferrugem :

$-8.52 + [\text{NDVI_1}] * -17.4 + [\text{Standard deviation Layer 49}] * 0.7 + [\text{Standard deviation Layer 46}] * 0.66 + [\text{Standard deviation Layer 45}] * 0.31 + [\text{Standard deviation Layer 42}] * -0.05 + [\text{Standard deviation Layer 40}] * 0.1 + [\text{Standard deviation Layer 35}] * 0.04 + [\text{Standard deviation Layer 34}] * 0.08 + [\text{Standard deviation Layer 21}] * 0 + [\text{Standard deviation Layer 17}] * 1.07 + [\text{Mean Layer 43}] * -0.1 + [\text{Mean Layer 40}] * -0.06 + [\text{Mean Layer 33}] * 0 + [\text{Mean Layer 32}] * 0 + [\text{Mean Layer 25}] * 0 + [\text{Mean Layer 24}] * 0 + [\text{Mean Layer 20}] * 0 + [\text{Mean Layer 19}] * 0 + [\text{Mean Layer 17}] * 0.09 + [\text{Mean Layer 1}] * 0$

Class Plástico :

$7.38 + [\text{AC_8}] * -12.4 + [\text{Mean Layer 48}] * 0.67 + [\text{Mean Layer 43}] * 0.17 + [\text{Mean Layer 41}] * -0.08 + [\text{Mean Layer 38}] * 0.08 + [\text{Mean Layer 33}] * -0.02 + [\text{Mean Layer 32}] * 0.02 + [\text{Mean Layer 30}] * 0.03 + [\text{Mean Layer 29}] * 0.03 + [\text{Mean Layer 24}] * 0 + [\text{Mean Layer 22}] * 0 + [\text{Mean Layer 21}] * 0 + [\text{Mean Layer 20}] * 0 + [\text{Mean Layer 16}] * 0 + [\text{Mean Layer 12}] * 0$

Class Lona Verde :

$29.06 + [\text{NDVI_4}] * 7.27 + [\text{AC_9}] * -3.21 + [\text{AC_19}] * 3.84 + [\text{AC_10}] * -27.05 + [\text{Standard deviation Layer 38}] * 0.21 + [\text{Standard deviation Layer 36}] * 0.13 + [\text{Standard deviation Layer 18}] * 0 + [\text{Standard deviation Layer 17}] * -3.02 + [\text{Mean Layer 6}] * -0.01 + [\text{Mean Layer 47}] * 0.41 + [\text{Mean Layer 28}] * 0.01 + [\text{Mean Layer 21}] * 0 + [\text{Mean Layer 16}] * 0 + [\text{Mean Layer 12}] * 0 + [\text{Mean Layer 11}] * 0$

Class Pastilha Esmaltada :

$4.46 + [\text{AC_9}] * -8.27 + [\text{AC_2}] * -4.2 + [\text{AC_16}] * -3.16 + [\text{AC_10}] * -4.9 + [\text{Standard deviation Layer 8}] * 0 + [\text{Standard deviation Layer 48}] * 0.31 + [\text{Standard deviation Layer 45}] * 0.3 + [\text{Standard deviation Layer 24}] * 0.01 + [\text{Standard deviation Layer 22}] * 0.01 + [\text{Standard deviation Layer 21}] * -0.01 + [\text{Mean Layer 9}] * 0 + [\text{Mean Layer 47}] * 0.3 + [\text{Mean Layer 44}] * -0.29 + [\text{Mean Layer 37}] * 0.05 + [\text{Mean Layer 31}] * -0.01 + [\text{Mean Layer 29}] * -0.01 + [\text{Mean Layer 28}] * 0.02 + [\text{Mean Layer 25}] * 0.01 + [\text{Mean Layer 21}] * 0 + [\text{Mean Layer 17}] * 0.22 + [\text{Mean Layer 1}] * 0$

Class Vidro Aramado :

$5.34 + [\text{AC_6}] * 0 + [\text{AC_5}] * 0 + [\text{Standard deviation Layer 37}] * -0.36 + [\text{Standard deviation Layer 27}] * -0.05 + [\text{Standard deviation Layer 25}] * -0.04 + [\text{Standard deviation Layer 22}] * 0.01 + [\text{Mean Layer 8}] * 0 + [\text{Mean Layer 6}] * 0 + [\text{Mean Layer 48}] * -0.79 + [\text{Mean Layer 45}] * -0.44 + [\text{Mean Layer 44}] * -1.33 + [\text{Mean Layer 34}] * -0.11 + [\text{Mean Layer 2}] * 0 + [\text{Mean Layer 18}] * 0 + [\text{Mean Layer 17}] * 0.86$

Class Acrílico :

$-35.99 + [\text{Standard deviation Layer 8}] * 0.01 + [\text{Standard deviation Layer 7}] * 0.01 + [\text{Standard deviation Layer 24}] * 0.01 + [\text{Standard deviation Layer 2}] * 0.01 + [\text{Standard deviation Layer 17}] * -0.64 + [\text{Standard deviation Layer 16}] * -0.01 + [\text{Standard deviation Layer 12}] * 0 + [\text{Mean Layer 43}] * 0.61 + [\text{Mean Layer 17}] * 1.06$

Class Concreto Pintado Azul :

$2.54 + [\text{NDVI_4}] * 4.86 + [\text{AC_8}] * -1.62 + [\text{AC_4}] * 0 + [\text{AC_19}] * 6.08 + [\text{AC_15}] * 2.43 + [\text{AC_10}] * -2.26 + [\text{Standard deviation Layer 7}] * -0.02 + [\text{Standard deviation Layer 43}] * 0.36 + [\text{Standard deviation Layer 42}] * -1.33 + [\text{Standard deviation Layer 31}] * 0.03 + [\text{Standard deviation Layer 3}] * -0.02 + [\text{Standard deviation Layer 23}] * 0.01 + [\text{Mean Layer 49}] * 0.47 + [\text{Mean Layer 45}] * 0.17 + [\text{Mean Layer 41}] * 0.09 + [\text{Mean Layer 37}] * 0.08 + [\text{Mean Layer 33}] * -0.01 + [\text{Mean Layer 31}] * 0.03 + [\text{Mean Layer 26}] * 0 + [\text{Mean Layer 21}] * 0 + [\text{Mean Layer 2}] * 0 + [\text{Mean Layer 17}] * 0.17$

Class Concreto Pintado Amarelo :

$-9.74 + [\text{AC_7}] * -9.97 + [\text{Standard deviation Layer 48}] * 0.21 + [\text{Standard deviation Layer 47}] * -1 + [\text{Standard deviation Layer 33}] * -0.03 + [\text{Standard deviation Layer 31}] * 0.03 + [\text{Mean Layer 8}] * 0 + [\text{Mean Layer 48}] * 0.81 + [\text{Mean Layer 45}] * 0.26 + [\text{Mean Layer 42}] * -0.15 + [\text{Mean Layer 38}] * 0.14 + [\text{Mean Layer 34}] * 0.06 + [\text{Mean Layer 33}] * -0.03 + [\text{Mean Layer 29}] * -0.03 + [\text{Mean Layer 27}] * 0.01 + [\text{Mean Layer 26}] * -0.01 + [\text{Mean Layer 25}] * 0.01 + [\text{Mean Layer 23}] * 0 + [\text{Mean Layer 17}] * 0.27$

Class Concreto Pintado Vermelho :

$-26.55 + [\text{Standard deviation Layer 33}] * -0.04 + [\text{Standard deviation Layer 31}] * 0.02 + [\text{Standard deviation Layer 1}] * -0.01 + [\text{Mean Layer 49}] * -1 + [\text{Mean Layer 44}] * 0.07 + [\text{Mean Layer 43}] * -0.15 + [\text{Mean Layer 42}] * -0.16 + [\text{Mean Layer 39}] * -0.08 + [\text{Mean Layer 34}] * 0.14 + [\text{Mean Layer 32}] * 0.01 + [\text{Mean Layer 27}] * 0.01 + [\text{Mean Layer 26}] * -0.03 + [\text{Mean Layer 25}] * 0.01$

Class Fibra de Vidro :

$-15.95 + [\text{NDVI_3}] * -3.43 + [\text{NDVI_2}] * 7.17 + [\text{AC_9}] * 1.29 + [\text{AC_16}] * 4.43 + [\text{Standard deviation Layer 9}] * 0 + [\text{Standard deviation Layer 49}] * 0.71 + [\text{Standard deviation Layer 47}] * 0.62 + [\text{Standard deviation Layer 45}] * -0.32 + [\text{Standard deviation Layer 44}] * 0.68 + [\text{Standard deviation Layer 23}] * 0.01 + [\text{Mean Layer 42}] * -0.04 + [\text{Mean Layer 37}] * 0.07 + [\text{Mean Layer 33}] * -0.03 + [\text{Mean Layer 17}] * 0.26$

APÊNDICE C – MATRIZES DE CONFUSÃO.

Tabela C.1: Matriz de confusão para os dados WV-2, com o algoritmo BFTree, para o Nível de Legenda 1.

CLASSES		AMOSTRAS DE REFERÊNCIA											TOTAL
		Coberturas Cerâmica	Coberturas Metálicas	Coberturas Diversas	Lago	Pavimentação Não Viária	Pavimentação Viária	Piscina	Solo Exposto	Sombra	Vegetação Arbórea	Vegetação Rasteira	
CLASSIFICADAS	Coberturas Cerâmicas	4	0	0	0	0	6	0	3	1	2	3	19
	Coberturas Metálicas	0	110	3	0	0	0	1	0	18	0	0	132
	Coberturas Diversas	0	21	151	0	0	26	1	2	19	5	19	244
	Lago	0	1	0	108	0	3	0	3	11	10	13	149
	Pavimentação Não Viária	0	0	1	0	8	1	0	1	3	0	0	14
	Pavimentação Viária	2	4	11	0	0	110	0	0	4	2	2	135
	Piscina	0	1	0	0	0	0	1	0	0	0	0	2
	Solo Exposto	2	0	0	0	0	0	0	12	0	0	1	15
	Sombra	0	0	2	0	0	0	0	0	201	78	5	286
	Vegetação Arbórea	0	0	2	0	0	0	0	0	17	189	7	215
	Vegetação Rasteira	0	0	1	0	0	2	0	2	1	61	260	327
TOTAL		8	137	171	108	8	148	3	23	275	347	310	1.538
Acurácia do Produtor por Classe		50 %	83 %	61 %	72 %	57 %	81 %	33 %	52 %	73 %	54 %	83 %	Exatidão Global: 75%
Acurácia do Usuário por Classe		21 %	80 %	88 %	100 %	100 %	74 %	50 %	80 %	70 %	87 %	79 %	

Tabela C.2: Matriz de confusão para os dados WV-2, com o algoritmo LMT, para o Nível de Legenda 1.

CLASSES		AMOSTRAS DE REFERENCIA											TOTAL
		Coberturas Cerâmicas	Coberturas Metálicas	Coberturas Diversas	Lago	Pavimentação Não Viária	Pavimentação Viária	Piscina	Solo Exposto	Sombra	Vegetação Arbórea	Vegetação Rasteira	
CLASSIFICADAS	Coberturas Cerâmicas	1	0	0	0	1	3	0	5	2	1	2	15
	Coberturas Metálicas	0	94	4	0	0	1	0	0	3	0	0	102
	Coberturas Diversas	0	20	126	0	0	23	0	1	22	1	8	201
	Lago	0	0	1	97	0	0	0	0	1	0	1	100
	Pavimentação Não Viária	0	1	0	0	5	5	0	1	4	1	0	17
	Pavimentação Viária	5	5	7	0	0	97	0	0	8	1	5	128
	Piscina	0	0	0	0	0	0	3	0	0	0	0	3
	Solo Exposto	0	0	1	0	0	3	0	13	0	1	10	28
	Sombra	0	0	2	0	0	0	0	0	187	21	11	221
	Vegetação Arbórea	0	1	3	0	0	0	0	0	23	256	22	305
	Vegetação Rasteira	0	0	1	0	0	3	0	0	1	40	215	260
TOTAL		6	121	145	97	6	135	3	20	251	322	274	1.380
Acurácia do Produtor por Classe		16 %	77 %	86 %	100 %	83 %	71 %	100 %	65 %	74 %	79 %	78 %	Exatidão Global: 79%
Acurácia do Usuário por Classe		6 %	92 %	62 %	97 %	29 %	75 %	100 %	46 %	84 %	83 %	82 %	

Tabela C.3: Matriz de confusão para os dados WV-3, com o algoritmo BFTree, para o Nível de Legenda 1.

CLASSES		AMOSTRAS DE REFERENCIA											TOTAL
		Coberturas Cerâmicas	Coberturas Metálicas	Coberturas Diversas	Lago	Pavimentação Não Viária	Pavimentação Viária	Piscina	Solo Exposto	Sombra	Vegetação Arbórea	Vegetação Rasteira	
CLASSIFICADAS	Coberturas Cerâmicas	3	0	1	0	1	0	0	1	0	3	8	17
	Coberturas Metálicas	0	98	1	0	0	0	0	0	1	0	0	100
	Coberturas Diversas	0	16	120	0	1	12	0	0	56	15	14	234
	Lago	0	0	0	87	0	3	0	0	3	0	0	93
	Pavimentação Não Viária	0	1	1	0	5	1	0	0	3	1	0	12
	Pavimentação Viária	0	1	12	0	1	117	0	5	13	5	35	189
	Piscina	0	0	0	0	0	0	1	0	0	0	0	1
	Solo Exposto	1	0	0	0	0	1	0	7	0	0	2	11
	Sombra	0	2	6	0	0	0	0	0	244	25	0	277
	Vegetação Arbórea	0	0	0	0	0	3	0	0	17	364	15	399
	Vegetação Rasteira	0	0	0	0	0	1	0	4	5	69	166	245
TOTAL		4	118	141	87	8	138	1	17	342	482	240	1.578
Acurácia do Produtor		75 %	83 %	85 %	100 %	62 %	84 %	100 %	41 %	71 %	75 %	69 %	Exatidão Global: 76%
Acurácia do Usuário		17 %	98 %	51 %	93 %	41 %	61 %	100 %	63 %	88 %	91 %	67 %	

Tabela C.4: Matriz de confusão para os dados WV-3, com o algoritmo LMT, para o Nível de Legenda 1.

CLASSES		AMOSTRAS DE REFERENCIA											TOTAL
		Coberturas Cerâmicas	Coberturas Metálicas	Coberturas Diversas	Lago	Pavimentação Não Viária	Pavimentação Viária	Piscina	Solo Exposto	Sombra	Vegetação Arbórea	Vegetação Rasteira	
CLASSIFICADAS	Coberturas Cerâmicas	5	0	1	0	0	0	0	0	6	1	1	14
	Coberturas Metálicas	0	154	0	0	0	0	0	0	3	3	0	160
	Coberturas Diversas	0	10	177	0	0	17	0	1	40	11	26	282
	Lago	0	0	0	138	0	0	0	0	5	0	0	143
	Pavimentação Não Viária	0	0	0	0	10	7	0	0	2	0	0	19
	Pavimentação Viária	0	1	5	0	0	142	0	3	10	4	5	170
	Piscina	0	0	0	0	0	1	4	0	1	2	0	8
	Solo Exposto	0	1	0	0	0	0	2	10	4	2	0	19
	Sombra	0	0	2	0	0	2	0	0	284	13	0	301
	Vegetação Arbórea	0	1	3	0	0	5	0	0	33	484	47	573
	Vegetação Rasteira	0	0	0	0	0	0	0	6	10	50	202	268
	TOTAL	5	167	188	138	10	174	6	20	398	570	281	1.957
Acurácia do Produtor		100 %	92 %	94 %	100 %	100 %	81 %	66 %	50 %	71 %	84 %	71 %	Exatidão Global: 82%
Acurácia do Usuário		35 %	96 %	62 %	96 %	52 %	83 %	50 %	52 %	94 %	84 %	75 %	

Tabela C.5: Matriz de confusão para os dados WV-2, com o algoritmo BFTree, para o Nível de Legenda 2.

WV-2 BFTree Nível 2		Aço Galv. Brilh.	Aço Galv. Ferrug.	Aço Galv. Fosco	Acrílico	Amianto	Asfalto	Asfalto P. Branco	Asfalto P. Verm.	Bloquete	Carvão Coque	Cerâmica Escura	Cerâmica Ilumin.	Cimento	Cimento Verde	Cimento P. Verm.	Concreto	Concreto Imp.	Concreto P. Am.	Cimento P. Verm.	CRFS	Fibra de Vidro	Galvalume A	Galvalume B	Galvalume C	Lago	Lona	Manta Asf. Alum.	Pastilha Esmaltada	Pedra Mineira	Piscina de Azulejo	Piscina de Vinil	Plástico	Policarbo nato	Solo Exposto	Sombra	Vegetação Arbórea	Vegetação Rasteira	Vidro Aramado	TOTAL	
Aço Galv. Brilhante	20	1	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	25	
Aço Galv. Ferrugem	8	3	3	2	7	2	1	0	0	0	0	0	0	0	0	0	1	0	0	0	3	0	3	0	0	0	5	0	0	0	0	0	0	0	0	1	0	0	0	39	
Aço Galv. Fosco	1	0	44	2	10	2	1	0	0	0	0	0	0	0	0	0	0	1	0	0	0	4	2	0	0	0	1	0	0	0	0	0	2	0	0	4	0	0	0	74	
Acrílico	6	0	3	1	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	3	0	1	0	3	0	0	0	0	0	0	1	0	0	5	2	0	0	28	
Amianto	0	0	1	0	256	8	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	18	4	4	0	292	
Asfalto	0	0	1	0	3	195	17	0	0	0	0	0	0	0	0	3	1	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	1	0	14	1	0	0	237	
Asfalto Pint. Branco	0	0	2	0	0	2	22	0	0	0	0	0	0	0	0	13	10	0	0	0	0	0	0	0	0	0	1	0	0	0	0	3	0	0	0	2	0	0	0	55	
Asfalto Pint. Vermelho	0	0	0	0	0	0	0	16	0	0	5	4	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	26	
Bloquete	0	0	0	0	2	7	1	0	5	1	0	0	1	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	4	2	1	22	0	48	
Carvão Coque	0	0	0	0	0	6	0	0	0	66	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0	75	
Cerâmica Escura	0	0	0	0	0	0	0	8	0	0	9	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	1	0	0	22		
Cerâmica Iluminada	0	0	0	0	0	0	0	0	0	0	0	6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6		
Cimento	1	0	0	0	0	1	6	0	0	0	0	0	7	0	0	1	2	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	3	0	0	0	0	23	
Cimento Pint. Verde	0	0	0	0	1	21	2	0	1	0	0	0	0	20	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	4	2	16	0	70	
Cimento Pint. Vermelho	0	0	0	0	0	0	0	0	0	0	2	0	0	0	8	1	0	0	0	0	0	0	0	0	0	0	0	0	0	8	0	0	0	0	1	3	0	0	0	23	
Concreto	0	0	4	0	19	5	2	0	1	0	0	0	0	0	1	53	7	1	2	0	0	0	1	0	0	0	0	0	0	1	1	1	0	0	0	11	2	2	1	115	
Concreto Impermeab.	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	48	0	0	0	0	0	2	0	1	0	0	2	0	0	3	0	0	0	0	0	0	0	0	58	
Concreto Pint. Amarelo	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	2	0	9	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	2	1	0	0	16	
Concreto Pint. Verm.	0	0	0	0	1	0	0	2	0	0	5	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	10	
CRFS	5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4	1	3	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	14	
Fibra de Vidro	0	0	4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	13	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	17	
Galvalume A	2	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	51	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	55	
Galvalume B	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	20	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	21	
Galvalume C	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5	
Lago	0	0	0	0	1	8	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	94	0	0	0	3	0	0	1	7	0	42	37	61	13	268	
Lona	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4	0	0	0	0	0	0	0	0	0	0	0	4		
Manta Asf. Aluminizada	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	16	0	0	0	0	0	0	0	0	0	0	18		
Pastilha Esmaltada	0	0	4	0	1	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	1	0	0	8		
Pedra Mineira	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	34	0	0	0	0	0	0	0	0	34		
Piscina de Azulejo	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	44	0	0	0	0	0	0	0	44		
Piscina de Vinil	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5	0	0	0	0	0	0	0	5		
Plástico	0	0	1	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	11	0	0	7	0	0	5	26		
Policarbonato	0	0	0	1	1	3	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	12	0	0	0	18	
Solo Exposto	0	0	0	0	0	1	3	0	0	0	13	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	14	0	0	0	0	0	12	0	1	30	0	75
Sombra	0	0	0	0	5	4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5	0	428	14	7	6	469		
Vegetação Arbórea	0	0	0	0	1	0	0	0	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5	342	19	0	369	
Vegetação Rasteira	0	0	0	0	0	0	0	0	2	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0														

Tabela C.6: Matriz de confusão para os dados WV-2, com o algoritmo LMT, para o Nível de Legenda 2.

WV-2 LMT Nível 2	Aço Galv. Brilh.	Aço Galv. Ferrug.	Aço Galv. Fosco	Acrílico	Amianto	Asfalto	Asfalto P. Branco	Asfalto P. Verm.	Bloquete	Carvão Coque	Cerâmica Escura	Cerâmica Ilumin.	Cimento	Cimento Verde	Cimento P. Verm.	Concreto	Concreto Imp.	Concreto P. Am.	Cimento P. Verm.	CRFS	Fibra de Vidro	Galvalume A	Galvalume B	Galvalume C	Lago	Lona	Manta Asf. Alum.	Pastilha Esmaltada	Pedra Mineira	Piscina de Azulejo	Piscina de Vinil	Plástico	Policarbo nato	Solo Exposto	Sombra	Vegetação Arbórea	Vegetação Rasteira	Vidro Aramado	TOTAL	
Aço Galv. Brilhante	11	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0	0	0	0	2	0	0	2	0	0	0	0	0	0	0	0	18	
Aço Galv. Ferrugem	2	3	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3	0	0	0	0	9		
Aço Galv. Fosco	3	0	33	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	3	0	0	0	43	
Acrílico	1	0	0	4	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	2	0	0	0	0	0	0	0	0	1	2	0	0	12	
Amianto	0	0	2	2	259	4	0	0	1	0	0	0	0	0	0	3	0	0	0	1	0	0	0	0	0	2	0	2	0	0	0	0	1	0	25	8	19	1	330	
Asfalto	0	0	2	0	10	196	9	0	0	4	2	0	0	1	0	3	0	0	0	0	0	0	0	0	0	0	0	0	5	0	0	0	12	0	48	0	1	0	293	
Asfalto Pint. Branco	4	0	2	0	1	15	14	1	5	0	0	0	0	1	0	4	4	0	0	1	7	1	0	0	0	0	0	0	2	0	1	1	0	0	10	0	2	0	76	
Asfalto Pint. Vermelho	0	0	0	0	0	0	0	40	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	2	0	44	
Bloquete	0	0	0	0	1	0	1	0	12	0	2	0	0	0	0	3	0	0	0	0	0	0	0	0	0	0	0	0	4	0	0	0	0	0	0	0	3	20	0	46
Carvão Coque	0	0	2	0	2	5	1	1	1	78	0	0	0	0	0	1	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	2	0	5	5	11	0	115	
Cerâmica Escura	0	0	0	0	3	1	0	5	1	4	23	6	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	1	10	24	31	0	110	
Cerâmica Iluminada	0	0	0	0	0	0	0	0	0	0	0	5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5	
Cimento	1	0	0	0	0	0	7	0	0	0	0	0	3	0	0	4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	15	
Cimento Pint. Verde	0	0	0	0	0	0	0	0	0	0	0	0	0	17	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3	0	20
Cimento Pint. Vermelho	0	0	0	0	0	0	0	1	1	0	0	0	0	0	22	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	24
Concreto	1	0	3	0	8	10	17	0	3	0	0	0	0	1	0	109	5	1	0	1	0	0	0	1	0	1	0	0	0	4	1	0	0	1	0	7	0	7	0	181
Concreto Impermeab.	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	54	0	0	0	0	0	0	2	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	57
Concreto Pint. Amarelo	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	7	0	11	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	0	20
Concreto Pint. Verm.	0	0	1	0	2	0	1	0	0	0	4	0	0	0	0	2	0	0	7	0	0	0	0	0	0	0	0	0	1	0	0	0	0	1	0	0	1	0	20	
CRFS	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	6	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	8
Fibra de Vidro	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	32	0	0	1	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	35
Galvalume A	5	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	66	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	73
Galvalume B	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	18	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	20
Galvalume C	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3
Lago	0	0	0	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	94	0	0	0	0	0	0	0	0	1	5	2	5	0	109	
Lona	0	0	8	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	0	0	2	0	12	
Manta Asf. Aluminizada	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	8	0	0	0	0	0	0	0	0	0	0	0	0	10
Pastilha Esmaltada	1	0	0	0	0	0	0	0	0	0	1	0	0	0	0	2	0	0	0	0	0	0	0	0	0	0	0	3	0	0	0	0	0	0	0	0	1	0	8	
Pedra Mineira	0	1	0	0	0	0	0	0	4	0	0	1	0	0	0	0	0	1	0	0	0	1	0	0	0	1	0	0	34	0	0	0	0	2	0	0	0	0	45	
Piscina de Azulejo	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	49	0	0	0	0	0	0	0	49		
Piscina de Vinil	0	0	1	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4	0	0	0	0	0	0	0	6	
Plástico	0	0	2	0	0	1	0	0	0	0	0	0	0	0	0	1	1	0	0	0	0	2	0	0	0	0	0	0	0	1	0	19	0	0	5	0	2	0	34	
Policarbonato	0	0	0	0	1	1	0	0	0	1	0	0	0	0	0	3	1	0	0	0	1	2	1	0	0	0	0	0	0	8	0	0	1	0	16	1	2	0	39	
Solo Exposto	0	0	0	0	0	0	0	0	4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	16	1	0	9	0	32	
Sombra	0	0	0	0	5	3	0	0	0	0	1	0	0	0	0	2	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	7	0	334	17	9	0	379	
Vegetação Arbórea	0	0	0	0	2	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	15	326	24	0	368	
Vegetação Rasteira	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	1	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	1	2	46				

Tabela C.7: Matriz de confusão para os dados WV-3, com o algoritmo BFTree, para o Nível de Legenda 2.

WV-3 BFTree Nível 2	Aço G. Brilh.	Aço G. Fer.	Aço G. Fosco	A. G. Manta	Acrílico	Amianto	Asfalto	Asf. P. Br.	Asf. P. Verm.	Bloquete	Carv. Coque	Cerâm. Esc	Cerâm. Ilum.	Cim. P. Cinza	Cim. P. Verde	Cim. P. Verm.	Comp. Mad.	Concreto	Con. P. Azul	Com. P. Am,	Com. P. Ver.	CRFS	Fibra Vidro	Galval. A	Galval. B	Lago	Lona Azul	Lona Verde	M. A. Alumin.	Past. Esmalt.	Pedra Min.	Pedregulh o	Pisc. Azul.	Pisc. Vinil	Plástico	Policarb.	Seixo Argila	Solo Exposto	Sombra	Veg. Arbórea	Veg. Rasteira	Vidro Aram.	TOTAL	
Aço Galv. Brilhante	12	5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	1	0	7	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	29		
Aço Galv. Ferrugem	0	8	1	0	0	0	0	0	1	0	0	0	0	0	0	0	0	2	0	0	0	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3	0	0	0	17	
Aço Galv. Fosco	2	0	23	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	1	0	0	0	27		
Aço Galv. F. Manta	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3		
Acrílico	0	1	3	0	5	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	14	
Amianto	0	0	0	0	0	128	2	0	0	0	0	0	0	0	0	0	0	1	1	0	0	0	1	0	0	0	0	0	0	0	0	1	0	0	0	0	1	0	14	6	6	0	161	
Asfalto	0	0	1	0	0	2	197	11	0	1	0	0	0	0	0	0	0	3	0	0	0	0	0	0	0	0	2	0	0	0	1	0	0	0	1	0	1	0	20	0	1	1	242	
Asfalto P. Branco	1	0	0	0	0	0	12	10	0	0	0	0	0	0	0	0	0	17	0	0	0	1	0	1	0	0	0	0	0	0	3	0	0	0	0	0	0	0	3	1	1	0	50	
Asfalto P. Vermelho	0	0	0	0	0	0	2	0	5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	7		
Bloquete	0	0	0	0	0	0	4	0	1	11	0	0	0	0	0	0	1	6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	2	0	26
Carvão Coque	0	0	0	0	0	0	11	1	0	0	56	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4	0	0	8	80
Cerâmica Escura	0	0	1	0	0	4	0	0	0	0	0	9	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	3	0	0	0	0	0	0	0	1	6	0	1	0	26
Cerâmica Iluminada	0	0	0	0	0	0	0	0	0	0	0	13	5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	19	
Cimento P. Cinza	0	0	1	0	0	0	0	0	0	0	0	0	0	7	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	8	
Cimento P. Verde	0	0	0	0	0	0	0	0	0	0	0	0	0	0	26	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	0	30	
Cimento P. Verm.	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	20	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	22	
Compens. Madeira	0	0	1	0	0	0	0	0	0	2	0	0	0	0	0	0	16	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	23	
Concreto	0	0	0	0	0	12	5	0	0	1	0	0	0	0	2	1	0	8	0	0	0	0	0	0	2	0	0	0	0	0	0	1	0	0	0	0	0	0	37	0	1	11	81	
Concreto P. Azul	0	0	0	0	0	3	0	0	0	0	0	0	0	0	1	0	0	0	39	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	10	3	10	0	67	
Concreto P. Amar.	0	0	1	0	0	2	1	0	0	0	0	1	0	0	0	0	0	3	5	2	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	2	0	0	19	
Concreto P. Verm.	0	0	0	0	0	0	0	0	0	0	0	4	0	0	0	0	0	0	0	1	7	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	12	
CRFS	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3	0	0	3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	8	
Fibra Vidro	0	0	0	0	0	3	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	21	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	21	0	0	2	48
Galval. A	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	98	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100
Galval. B	1	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	18	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	21
Lago	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	98	0	0	0	0	0	0	0	0	0	0	0	1	2	0	2	0	104
Lona Azul	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	7	0	0	0	0	0	0	0	0	0	0	14	3	0	25		
Lona Verde	0	0	0	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5	0	0	0	0	0	0	0	0	0	0	1	2	0	0	10	
Manta A. Alumin.	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6	0	0	0	0	0	0	0	0	0	0	0	0	6		
Pastilha Esmalt.	0	0	1	0	0	5	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0	1	0	1	0	0	0	0	0	3	0	0	0	0	0	0	0	0	3	4	0	3	0	23
Pedra Mineira	0	0	0	0	0	2	0	0	0	0	0	0	0	1	0	0	0	2	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	5	0	2	0	57	
Pedreg.	0	0	0	0	0	13	0	0	0	0	2	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	3	2	12	1	35	
Piscina Azulejo	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	30	0	0	0	0	0	0	0	0	0	30		
Piscina Vinil	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	10	0	0	0	0	0	0	0	0	11		
Plástico	0	0	0	0	0	0	2	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3	1	0	0	0	0	0	0	0	2	0	9	0	0	0	13	13	24	0	68	
Policarb.	0	0	1	0	0	19	4	0	0	0	6	1	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	19	0	1	129	72	22	0	275		
Seixo Argila	0	0	0	0	0	3	0	0	0	0	0	0	0	3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	35	0	0	0	0	0	41		
Solo Exposto	0	0	0	0	0	0	3	1	2	0	0	1	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	6	6	0	2	0	23		
Sombra	0	0	0	0	0	6	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	243	13	0	1	264			
Veget. Arbórea	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	19	395	12	0	426			
Veget. Rasteira	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6	94	295	0	398			
Vidro Aramado	0	0	0	0	0	3	34	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0	2	4	15	96				
TOTAL	18	17	34	1	5	207	282	25	9	15	64	30	6	11	29	22	17	50	49	4	8	6	24	120	26	100	7	5	6	3	49	2	34	10	10	19	37	17	593	618	404	39	3.032	
Acurácia do Produtor por Classe	66,67 %	47,06 %	67,65 %	100 %	100 %	61,84 %	69,86 %	40%	55,56 %	73,3																																		

Tabela C.8: Matriz de confusão para os dados WV-3, com o algoritmo LMT, para o Nível de Legenda 2.

WV-3 LMT Nível 2	Aço G. Brilh.	Aço G. Fer.	Aço G. Fosco	A. G. Manta	Acrílico	Amianto	Asfalto	Asf. P. Br.	Asf. P. Verm.	Bloquete	Carv. Coque	Cerâm. Esc	Cerâm. Ilum.	Cim. P. Cinza	Cim. P. Verde	Cim. P. Verm.	Comp. Mad.	Concreto	Con. P. Azul	Com. P. Am.	Com. P. Ver.	CRFS	Fibra Vidro	Galval. A	Galval. B	Lago	Lona Azul	Lona Verde	M. A. Alumin.	Past. Esmalt.	Pedra Min.	Pedregulho	Pisc. Azul.	Pisc. Vinil	Plástico	Polcarb.	Seixo Argila	Solo Exposto	Sombra	Veg. Arborea	Veg. Rasteira	Vidro Aram.	TOTAL	
Aço Galv. Brilhante	12	5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	8	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	25		
Aço Galv. Ferrugem	1	9	1	0	0	0	2	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	1	0	0	0	18		
Aço Galv. Fosco	4	1	31	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	38		
Aço Galv. F. Manta	0	0	2	8	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	10		
Acrílico	0	0	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2		
Amianto	0	0	2	0	0	209	5	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5	9	3	0	240	
Asfalto	0	0	2	0	0	5	242	19	0	1	4	0	0	0	0	0	0	3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	38	2	7	0	325
Asfalto P. Branco	1	1	0	0	0	2	18	22	0	2	0	0	0	0	0	0	1	3	0	0	0	2	0	7	1	0	0	0	0	0	0	3	0	0	0	0	0	0	11	12	8	0	94	
Asfalto P. Vermelho	0	0	0	0	0	0	1	0	11	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	1	0	15		
Bloquete	1	0	0	0	0	1	3	0	0	15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	3	0	3	0	27	
Carvão Coque	0	0	0	0	0	0	1	0	0	0	61	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6	0	1	0	69		
Cerâmica Escura	0	0	0	0	0	0	0	0	0	0	0	44	2	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	0	0	0	0	7	8	1	0	65		
Cerâmica Iluminada	0	0	0	0	0	0	0	0	0	0	0	0	6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	8	0	0	0	14		
Cimento P. Cinza	0	0	0	0	0	0	0	0	0	0	0	0	0	3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3	
Cimento P. Verde	0	0	0	0	0	0	0	0	0	0	0	0	0	0	29	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	32	
Cimento P. Verm.	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	25	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	27		
Compens. Madeira	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	21	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	1	0	26	
Concreto	0	4	0	0	0	6	13	3	1	3	1	0	0	0	0	0	0	46	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	1	0	9	9	17	0	114	
Concreto P. Azul	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	57	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3	0	0	0	62	
Concreto P. Amar.	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	13	9	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	22	
Concreto P. Verm.	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6	
CRFS	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4	0	0	0	4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	11	
Fibra Vidro	1	0	1	0	0	1	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	37	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0	3	0	2	0	49	
Galval. A	5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	72	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	78
Galval. B	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	22	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	22	
Lago	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	104	0	0	0	0	0	0	0	0	0	0	0	0	0	8	0	0	0	112
Lona Azul	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	14	0	0	0	0	0	0	0	0	0	0	0	1	0	16		
Lona Verde	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	21	0	0	0	0	0	0	0	0	0	9	1	0	0	31		
Manta A. Alumin.	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	8	0	0	0	0	0	0	0	0	0	0	0	0	9		
Pastilha Esmalt.	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	2	0	0	0	0	0	0	0	1	0	4	0	8		
Pedra Mineira	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	70	0	0	0	0	0	0	0	0	1	0	72		
Pedreg.	0	0	0	0	0	2	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5	0	0	0	0	0	0	10	3	3	0	25	
Piscina Azulejo	1	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	41	0	0	0	0	1	5	0	0	50		
Piscina Vinil	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	3	0	0	0	4		
Plástico	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	16	0	0	0	0	1	0	18		
Polcarb.	0	0	0	0	0	1	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	10	0	16	10	3	0	42		
Seixo Argila	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	34	0	1	0	0	36		
Solo Exposto	0	0	0	0	0	1	1	0	1	0	0	0	1	1	0	0	0	2	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	15	3	1	5	0	32	
Sombra	0	0	0	0	0	3	3	0	0	0	1	1	0	0	0	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	437	47	3	0	498		
Veget. Arborea	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	10	0	0	2	0	0	27	417	40	0	497		
Veget. Rasteira	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	4	42	244	0	292				
Vidro Aramado	0	0	0	0	0	4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3	1	0	51	59			
TOTAL	26	20	44	10	2	237	295	44	13	21	68	45	9	4	29	25	22	66	72	11	6	6	37	98	24	104	14	21	14	2	73	5	52	2	18	12	36	16	616	575	350	51	3.195	
Acurácia do Produtor por Classe	46,15 %	45%	70,45 %	80%	100 %	88,19 %	82,03 %	50%	84,62 %	71,43 %	89,71 %	97,78 %	66,67 %	75%	100 %	100 %	95,45 %	69,70 %	79,14 %	81,82 %	83,33 %	66,67 %	100 %	73,47 %</																				

APÊNDICE D – TESTES DE HIPÓTESE.

Todos os testes de hipótese realizados no trabalho são detalhados neste apêndice.

Tabela D.1: Testes de Hipóteses Individuais por classificação para analisar se os valores de *Kappa* são significativamente maiores que zero para o Nível de Legenda 1.

WV2 Nível 1 BFTree	H0: $\kappa_1 = 0$
	H1: $\kappa_1 > 0$
	Z = 54,68
	Valor-P = 0,0000
	Alfa = 0,05
	Conclusão: rejeito H0, o κ_1 é significativamente maior que zero
WV2 Nível 1 LMT	H0: $\kappa_2 = 0$
	H1: $\kappa_2 > 0$
	Z = 58,64
	Valor-P = 0,0000
	Alfa = 0,05
	Conclusão: rejeito H0, o κ_2 é significativamente maior que zero
WV3 Nível 1 Bftree	H0: $\kappa_3 = 0$
	H1: $\kappa_3 > 0$
	Z = 56,46
	Valor-P = 0,0000
	Alfa = 0,05
	Conclusão: rejeito H0, o κ_3 é significativamente maior que zero
WV3 Nível 1 LMT	H0: $\kappa_4 = 0$
	H1: $\kappa_4 > 0$
	Z = 75,57
	Valor-P = 0,0000
	Alfa = 0,05
	Conclusão: rejeito H0, o κ_4 é significativamente maior que zero

Tabela D.2: Testes de Hipóteses para comparar o desempenho dos algoritmos BFTree e LMT para o Nível de Legenda 1.

WV2 Nível 1 BFTree e LMT	H0: $\kappa_1 - \kappa_2 = 0$
	H1: $\kappa_1 - \kappa_2 < 0$
	$Z = -2,64$
	Valor-P = 0,0042
	Alfa = 0,05
	Conclusão: rejeito H0, o κ_1 é significativamente menor que o κ_2 .
WV3 Nível 1 BFTree e LMT	H0: $\kappa_3 - \kappa_4 = 0$
	H1: $\kappa_3 - \kappa_4 < 0$
	$Z = -4,01$
	Valor-P = 0,0000
	Alfa = 0,05
	Conclusão: rejeito H0, o κ_3 é significativamente menor que o κ_4 .

Tabela D.3: Testes de Hipóteses para comparar o desempenho dos sensores WV-2 e WV-3 para o Nível de Legenda 1.

BFTree Nível 1 WV2 e WV3	H0: $\kappa_1 - \kappa_3 = 0$
	H1: $\kappa_1 - \kappa_3 < 0$
	$Z = -0,74$
	Valor-P = 0,2286
	Alfa = 0,05
	Conclusão: aceito H0, os κ s não são significativamente diferentes.
LMT Nível 1 WV2 e WV3	H0: $\kappa_2 - \kappa_4 = 0$
	H1: $\kappa_2 - \kappa_4 < 0$
	$Z = -1,90$
	Valor-P = 0,0287
	Alfa = 0,05
	Conclusão: rejeito H0, o κ_2 é significativamente menor que o κ_4 .

Tabela D.4: Testes de Hipóteses individuais por classificação para analisar se os valores de *Kappa* são significativamente maiores que zero para o Nível de Legenda 2.

WV2 Nível 2 BFTree	H0: $\kappa_1 = 0$
	H1: $\kappa_1 > 0$
	Z = 80,92
	Valor-P = 0,0000
	Alfa = 0,05
	Conclusão: rejeito H0, o κ_1 é significativamente maior que zero
WV2 Nível 2 LMT	H0: $\kappa_2 = 0$
	H1: $\kappa_2 > 0$
	Z = 86,16
	Valor-P = 0,0000
	Alfa = 0,05
	Conclusão: rejeito H0, o κ_2 é significativamente maior que zero
WV3 Nível 2 BFTree	H0: $\kappa_3 = 0$
	H1: $\kappa_3 > 0$
	Z = 212,92
	Valor-P = 0,0000
	Alfa = 0,05
	Conclusão: rejeito H0, o κ_3 é significativamente maior que zero
WV3 Nível 2 LMT	H0: $\kappa_4 = 0$
	H1: $\kappa_4 > 0$
	Z = 137,28
	Valor-P = 0,0000
	Alfa = 0,05
	Conclusão: rejeito H0, o κ_4 é significativamente maior que zero