



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

sid.inpe.br/mtc-m21c/2018/10.03.18.55-TDI

**IDENTIFICAÇÃO DE FITOFISIONOMIAS DE
CERRADO NO PARQUE NACIONAL DE BRASÍLIA
UTILIZANDO RANDOM FOREST APLICADO A
IMAGENS DE ALTA E MÉDIA RESOLUÇÕES
ESPACIAIS**

Cesare Di Girolamo Neto

Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelos Drs. Leila Maria Garcia Fonseca, e Thales Sehn Körting, aprovada em 28 de agosto de 2018.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3RU6Q68>>

INPE
São José dos Campos
2018

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GBDIR)

Serviço de Informação e Documentação (SESID)

CEP 12.227-010

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/7348

E-mail: pubtc@inpe.br

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

Presidente:

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

Membros:

Dra. Carina Barros Mello - Coordenação de Laboratórios Associados (COCTE)

Dr. Alisson Dal Lago - Coordenação-Geral de Ciências Espaciais e Atmosféricas (CGCEA)

Dr. Evandro Albiach Branco - Centro de Ciência do Sistema Terrestre (COCST)

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

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

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação - (CPG)

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

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon

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

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

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

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

EDITORAÇÃO ELETRÔNICA:

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

Murilo Luiz Silva Gino - Serviço de Informação e Documentação (SESID)



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

sid.inpe.br/mtc-m21c/2018/10.03.18.55-TDI

**IDENTIFICAÇÃO DE FITOFISIONOMIAS DE
CERRADO NO PARQUE NACIONAL DE BRASÍLIA
UTILIZANDO RANDOM FOREST APLICADO A
IMAGENS DE ALTA E MÉDIA RESOLUÇÕES
ESPACIAIS**

Cesare Di Girolamo Neto

Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelos Drs. Leila Maria Garcia Fonseca, e Thales Sehn Körting, aprovada em 28 de agosto de 2018.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3RU6Q68>>

INPE
São José dos Campos
2018

Dados Internacionais de Catalogação na Publicação (CIP)

Girolamo Neto, Cesare Di.

G444i Identificação de fitofisionomias de Cerrado no Parque Nacional de Brasília utilizando Random Forest aplicado a imagens de alta e média resoluções espaciais / Cesare Di Girolamo Neto. – São José dos Campos : INPE, 2018.

xxiv + 188 p. ; (sid.inpe.br/mtc-m21c/2018/10.03.18.55-TDI)

Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2018.

Orientadores : Drs. Leila Maria Garcia Fonseca, e Thales Sehn Körting.

1. Sensoriamento Remoto. 2. Classificação. 3. Cerrado. 4. Textura. 5. Mineração de dados. I.Título.

CDU 528.854(213.54)



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

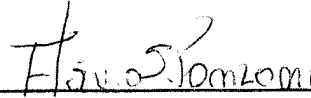
This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

Aluno (a): **Cesare Di Girolamo Neto**

Título: "IDENTIFICAÇÃO DE FITOFISIONOMIAS DE CERRADO NO PARQUE NACIONAL DE BRASÍLIA UTILIZANDO RANDOM FOREST APLICADO A IMAGENS DE ALTA E MÉDIA RESOLUÇÕES ESPACIAIS"

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

Dr. Flávio Jorge Ponzoni



Presidente / INPE / SJCampos - SP

() Participação por Vídeo - Conferência

Aprovado () Reprovado

Dra. Leila Maria Garcia Fonseca

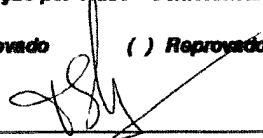


Orientador(a) / INPE / SJCampos - SP

() Participação por Vídeo - Conferência

Aprovado () Reprovado

Dr. Thales Sehn Körting



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

() Participação por Vídeo - Conferência

Aprovado () Reprovado

Dr. Dalton de Morisson Valeriano

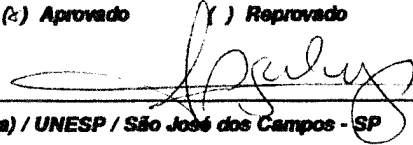


Membro da Banca / INPE / SJCampos - SP

() Participação por Vídeo - Conferência

Aprovado () Reprovado

Dr. Rogério Galante Negri

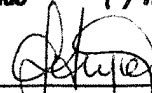


Convidado(a) / UNESP / São José dos Campos - SP

() Participação por Vídeo - Conferência

Aprovado () Reprovado

Dra. Camila Souza dos Anjos Lacerda



Convidado(a) / IFSULDEMINAS / Inconfidentes - MG

() Participação por Vídeo - Conferência

Aprovado () Reprovado

Este trabalho foi aprovado por:

() maioria simples

unanimidade

São José dos Campos, 28 de agosto de 2018

There is a passage I got memorized, seems appropriate for this situation:

The path of the righteous man is beset on all sides

by the inequities of the selfish and the tyranny of evil men.

Blessed is he who, in the name of charity and good will,

shepherds the weak through the valley of darkness,

for he is truly his brother's keeper and the finder of lost children.

And I will strike down upon thee with great vengeance and furious anger

those who attempt to poison and destroy my brothers

and they will know my name is the Lord when I lay my vengeance upon them.

Quentin Tarantino & Roger Avary

AGRADECIMENTOS

À minha orientadora, Leila Maria Garcia Fonseca, pela orientação no trabalho, paciência em lidar com situações difíceis e sempre cobrar seus alunos ao máximo, garantido qualidade e excelência nas atividades de pesquisa.

Ao meu orientador, Thales Sehn Körting, pela amizade e por sempre estar a disposição para conversar e trazer contribuições para o trabalho, sempre com muita bondade e paciência.

Aos professores Flávio Ponzoni e Dalton Valeriano, por passarem parte do valioso conhecimento que possuem sobre sensoriamento remoto e vegetação.

Ao doutor Rogério Galante Negri e a doutora Camila Souza dos Anjos Lacerda, por fazerem parte da banca e pelo interesse em contribuir com o trabalho

Aos demais professores do INPE que contribuíram com discussões para este trabalho e também para a minha formação profissional.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico pelo apoio financeiro.

Aos meus antigos mestres, Carlos Meira e Mariangela Amendola, que contribuíram para minha formação até aqui.

À todo o pessoal administrativo do INPE, em especial a Vera e a Luciana, por sempre serem prestativas e ajudarem sempre com a burocracia "inpeana".

À todos os amigos que fiz no INPE e também aos remanescentes da época da Embrapa, Feagri e Unicamp.

À minha namorada Alana, que é a melhor pessoa do mundo e sempre me ajudou como pode nessa etapa difícil.

À toda a minha família, em especial a minha mãe Fernanda, por sempre me encorajarem a nunca desistir e sempre fazer o certo.

À mais alguém, que provavelmente esqueci.

E a Deus.

RESUMO

Depois da Mata Atlântica, o Cerrado é o bioma Brasileiro que mais passou por alterações com a ocupação humana, com uma perda de cobertura vegetal de 978.745 km². Portanto, é estratégico que o bioma seja monitorado para combater o desmatamento e manter as áreas de preservação ambiental. Neste sentido, várias pesquisas têm sido desenvolvidas para estudar as alterações da cobertura e uso da terra, estimar as emissões de carbono, estudar o impacto do desmatamento e degradação da biodiversidade. A maioria dos trabalhos para classificar a cobertura vegetal do Cerrado tem utilizado imagens da classe Landsat, com 30 metros de resolução espacial, discriminando fitofisionomias de Campo, Savana e Floresta com taxas de acerto superiores a 80%. Todavia, ainda são encontradas dificuldades em classificar as fitofisionomias com uma legenda de classificação mais detalhada. Esse fato mostra a necessidade do uso de imagens de resolução espacial melhor, as quais se mostraram capazes de identificar a estrutura da vegetação em fitofisionomias semelhantes. Embora, o uso destas imagens permita classificar a cobertura vegetal do Cerrado com mais detalhes, não há na literatura pesquisas conclusivas sobre quais fitofisionomias podem ser mais bem discriminadas com imagens de resolução espacial da classe Landsat (30m) e alta resolução (1 a 4 m). Dentro deste contexto, o principal objetivo deste trabalho foi avaliar imagens de alta e média resoluções, combinadas com técnicas de extração de atributos, para mapear as fitofisionomias do Cerrado com um maior nível de detalhamento do que a literatura existente. Foram obtidas imagens (Landsat-8 e WorldView-2) para o Parque Nacional de Brasília, região que contém mais de 30 mil hectares de vegetação nativa de Cerrado. A partir destas imagens foram gerados dados de Reflectância, do Modelo Linear de Mistura Espectral, da Transformada *Tasseled Cap*, de Índices de Vegetação e de textura. Foram coletados pontos em campo e com interpretação visual para gerar um conjunto de dados com mais de mil amostras classificadas para quatro diferentes legendas. Estas legendas consideram as fitofisionomias de Ribeiro e Walter (2008) e foram propostas, contendo 3, 6, 8 e 10 diferentes classes, de acordo com seu nível de detalhamento. A escala mais simples diferenciou apenas as classes Campestre, Savânica e Florestal, e conforme o aumento da complexidade, foram identificadas classes como Campo Limpo, Campo Limpo Úmido, Campo Limpo Úmido com Murundu, Campo Sujo, Campo Rupestre, Cerrado Ralo, Cerrado Típico, Cerrado Denso, Veredas e Mata de Galeria. O comportamento espectral destas fitofisionomias revelou que elas são diferenciáveis apenas para a escala mais simples. Para níveis mais complexos, existe uma maior dificuldade de discriminação com dados de Reflectância. A classificação das imagens foi feita pelo algoritmo *Random Forest*. Dentre os principais resultados, a legenda mais simples de mapeamento mostra-se adequada para ambas às resoluções espaciais, obtendo taxas de acerto superiores a 87%. Com o aumento da complexidade de legenda, a imagem Landsat-8 passou a apresentar limitações na discriminação de classes como Campo Limpo, Campo Sujo e Campo Rupestre. As classes de Cerrado Ralo e Cerrado Denso apresentaram confusão com a classe de Cerrado Típico. Ainda foi constatado que estas imagens são deficientes em representar a transição entre as classes de Campo Sujo e Cerrado Ralo. A taxa de acerto para a legenda mais detalhada com a imagem Landsat-8 foi de 65,21%. Entretanto, a imagem WorldView-2 se mostrou capaz de identificar estas fitofisionomias com uma melhor taxa de acerto (74,17%). O uso de atributos relacionados à textura foi essencial para o aumento dessa taxa. Neste sentido, por meio da imagem WorldView-2 foi possível identificar a Classe de Campo Rupestre com melhor taxa de acerto, reduzindo erros entre as classes de Campo Limpo e Campo Sujo.

As classes de Cerrado Ralo e Cerrado Denso reduziram sua confusão com Cerrado Típico. O erro de transição entre Campo Sujo e Cerrado Ralo ainda persiste na imagem de alta resolução, porém com uma menor magnitude. Algumas classes como Veredas, Campo Limpo Úmido e Campo Limpo Úmido com Murundu não foram identificadas com boa precisão em ambas as imagens. Dentre as principais conclusões deste trabalho destacam-se o uso de atributos de textura para melhorar a discriminação de fitofisionomias do Cerrado. Estes atributos foram capazes de representar as variações entre regiões com vegetação arbórea intercaladas por regiões com vegetação herbáceo-arbustiva, melhorando a discriminação de fitofisionomias como Campo Sujo, Cerrado Ralo, Cerrado Típico e Cerrado Denso.

Palavras chaves: Sensoriamento Remoto, Classificação, Cerrado, Textura, Mineração de dados.

IDENTIFICATION OF BRAZILIAN SAVANNAH PHYSIOGNOMIES ON BRASÍLIA NATIONAL PARK USING RANDOM FOREST ON HIGH AND MEDIUM SPATIAL RESOLUTION IMAGES

ABSTRACT

After the Atlantic Forest, the Cerrado is the Brazilian biome that has presented most changes with human occupation, with a loss of vegetation cover of 978,745 km². Therefore, it is strategic that this biome is monitored in order to decrease deforestation and maintain the areas of environmental protection. In this sense, several researches have been developed to study changes in land cover and use, to estimate carbon emissions, to study the impact of deforestation and biodiversity degradation. Most of these studies classify Cerrado vegetation using Landsat like images, with 30 meters of spatial resolution, discriminating classes such as Grassland, Savanna and Woodland with accuracy higher than 80%. However, it is still difficult to classify Cerrado phytophysionomies with a more detailed classification legend. This fact shows the need of better spatial resolution images, which were able to identify vegetation structure in similar phytophysionomies. Although the use of these images allows classifying the Cerrado vegetation cover with more details, there is no conclusive research in the literature about which phytophysionomie can be discriminated with better accuracy with Landsat images (30m) and high resolution (1 to 4 m). In this context, the aim of this work was to evaluate high and medium resolution images, combined with feature extraction techniques, to map Cerrado phytophysionomies with a higher level of detail than the existing literature. A Landsat-8 image and a WorldView-2 image were obtained for the Brasilia National Park, a region that contains more than 30 thousand hectares of Cerrado native vegetation. Data of Reflectance, Spectral Linear Mixture Model, Tasseled Cap Transformation, Vegetation Indices and texture were obtained for these images. Samples for the classification were collected on field and by visual interpretation, generating a dataset with more than one thousand samples classified for four different legends. These legends adopts the phytophysionomies described by Ribeiro and Walter (2008) and were proposed containing 3, 6, 8 and 10 different classes, according to their level of detail. The simpler scale adopted the classes of Grassland, Savanna and Woodland. When the level of detail was increased, the following classes were used: Open Grassland, Flooded Grassland, Flooded Grassland with *Murundu*, Shrub Grassland, Rocky Grassland, Shrub Savanna, Typical Savanna, Dense Savanna, Flooded Plains with Palmtrees and Gallery Forest. The spectral behavior of these phytophysionomies revealed that they are distinguishable only for the simplest scale, for more complex levels, there is a greater difficulty of discrimination with Reflectance data. The classification of the images was done by the algorithm Random Forest. Among the main results, the simplest mapping legend is adequate for both spatial resolutions, obtaining hit rates higher than 87%. With the increase of the legend complexity, the Landsat-8 images started to present difficulties in discriminating classes like Open Grassland, Shrub Grassland and Rocky Grassland. The classes of Shrub Savanna and Dense Savanna were misclassified as Typical Savanna. It was still observed that these images are deficient in representing the transition between the classes of Shrub Grassland and Shrub Savanna. The hit rate for the most detailed legend with the Landsat-8 image was 65.21%. However, the WorldView-2 image was able to identify these phytophysionomies with a better accuracy (74.17%). The use of texture features was essential for this increase. In this sense, the WorldView-2 image

identified the Rock Grassland class with better accuracy and also reduced the misclassification between the Open Grasslands and Shrub Grasslands. The classes of Shrub Savanna and Dense Savanna reduced their confusion with Typical Savanna. The transition error between Shrub Grasslands and Shrub Savanna still persists in WorldView-2 image, but with a smaller magnitude. Some classes such as Flooded Plains with Palmtrees, Flooded Grassland and Flooded Grassland with *Murundu* were not identified with good accuracy on both images. The main conclusion of this study is that the use of texture features helped to improve the discrimination of Cerrado phytophysionomies. These features were able to represent the variations between regions with arboreal vegetation interspersed by regions with herbaceous-shrub vegetation, improving the discrimination of phytophysionomies such as Shrub Grasslands, Shrub Savanna, Typical Savanna and Dense Savanna.

Keywords: Remote Sensing, Classification, *Cerrado*, Texture, Data Mining.

LISTA DE FIGURAS

Figura 2.1: O Cerrado no território Brasileiro.....	6
Figura 2.2: Incremento anual do desmatamento para o Cerrado e Amazônia para os anos de 2001 a 2017.	8
Figura 2.3: Fitofisionomias do Cerrado Brasileiro.....	12
Figura 4.1: Exemplo de uma árvore de decisão.....	42
Figura 4.2: Esquema de construção de uma Random Forest.....	44
Figura 5.1: Área de estudo selecionada na região do Parque Nacional de Brasília.	46
Figura 5.2: Criação do SuperPixel na imagem WorldView-2.....	49
Figura 5.3: Legenda de classes com a hierarquia das fitofisionomias de Cerrado.....	51
Figura 5.4: Cálculo da matriz GLCM.....	57
Figura 5.5: Exemplo de imagem Landsat-7 para a banda do Vermelho com destaque para uma região com textura rugosa (a) e lisa (b).	59
Figura 5.6: Exemplo de imagens de textura	60
Figura 5.7: Pontos coletados em campo no Parque Nacional de Brasília.	61
Figura 5.8: Três diferentes estratégias de classificação utilizadas.	63
Figura 6.1: Caracterização das classes para a Legenda N1 em função da Reflectância.	66
Figura 6.2: Gráfico de dispersão Red x NIR das classes da Legenda N1 para as imagens WorldView-2 e Landsat-8.	67
Figura 6.3: Exemplo de cálculo dos centróides para as distribuições das classes da Legenda N1.....	69
Figura 6.4: Exemplo de cálculo da distância Euclidiana entre as classes de Savana/Floresta e Campo/Savana.....	70
Figura 6.5: Caracterização das classes para a Legenda N2 em função da Reflectância.	72
Figura 6.6: Exemplo de uma região de Vereda na Imagem WorldView-2.	73
Figura 6.7: Fotos de regiões de Veredas tiradas em campo.	73
Figura 6.8: Regiões de Campo Rupestre para o Parque Nacional de Brasília.....	74
Figura 6.9: Gráfico de dispersão Red x NIR das classes da Legenda N1.	75
Figura 6.10: Caracterização das classes para a Legenda N3 em função da Reflectância.	78
Figura 6.11: Centróides das classes da Legenda N3 nos gráficos Red x NIR, enfatizando o aumento de biomassa das classes de Cerrado Ralo, Cerrado Típico e Cerrado Denso.	79
Figura 6.12: Classes de Campo Limpo Úmido com Murundu e Campo Limpo Úmido.	81
Figura 6.13: Caracterização das classes para a Legenda N4 em função da Reflectância para a imagem WorldView-2.....	82
Figura 6.14: Caracterização das classes para a Legenda N4 em função da Reflectância para a imagem Landsat-8.....	83
Figura 6.15: Centróides das classes da Legenda N4 no gráfico Red x NIR, com destaque para o deslocamento da classe de Campo Limpo Úmido para regiões de solos úmidos.	83
Figura 6.16: Caracterização das classes em termos das componentes de solo, sombra e vegetação para a Legenda N1.	86
Figura 6.17: Dispersão das classes da Legenda N1 para as componentes de sombra e vegetação.	87
Figura 6.18: Caracterização das classes em termos das componentes de solo, sombra e vegetação para a Legenda N2.	88

Figura 6.19: Dispersão das classes da Legenda N2 para as componentes de sombra e vegetação.	89
Figura 6.20: Caracterização das classes em termos das componentes de solo, sombra e vegetação para a Legenda N3.	90
Figura 6.21: Caracterização das classes em termos das componentes de solo, sombra e vegetação para a Legenda N4 para a imagem WorldView-2.	91
Figura 6.22: Caracterização das classes em termos das componentes de solo, sombra e vegetação para a Legenda N4 para a imagem Landsat-8.....	92
Figura 6.23: Caracterização das classes em termos das componentes de <i>Greenness</i> , <i>Brightness</i> e <i>Wetness</i> na Legenda N1.	93
Figura 6.24: Caracterização das classes em termos das componentes de <i>Greenness</i> , <i>Brightness</i> e <i>Wetness</i> na Legenda N2.....	95
Figura 6.25: Caracterização das classes em termos das componentes de <i>Greenness</i> , <i>Brightness</i> e <i>Wetness</i> na Legenda N3.....	97
Figura 6.26: Caracterização das classes em termos das componentes de <i>Greenness</i> , <i>Brightness</i> e <i>Wetness</i> na Legenda N4 para a imagem WorldView-2.....	98
Figura 6.27: Caracterização das classes em termos das componentes de <i>Greenness</i> , <i>Brightness</i> e <i>Wetness</i> na Legenda N4 para a imagem Landsat-8.....	99
Figura 6.28: Correlação entre os Índices de Vegetação das imagens WorldView-2 e Landsat-8.	100
Figura 6.29: Caracterização das classes da Legenda N1 em função do NDVI.	101
Figura 6.30: Caracterização das classes da Legenda N2 em função do NDVI.	102
Figura 6.31: Caracterização das classes da Legenda N3 em função do NDVI.	103
Figura 6.32: Caracterização das classes da Legenda N4 em função do NDVI.	104
Figura 7.1: Mapas temáticos com detalhes para a Legenda N1.	112
Figura 7.2: Mapas temáticos com detalhes para a Legenda N2.	121
Figura 7.3: Mapas temáticos com detalhes para a Legenda N3.	130
Figura 7.4: Mapas temáticos com detalhes para a Legenda N4.	139
Figura 7.5: Atributos selecionados pelo método Correlation Feature Selection.	141
Figura 7.6: Mapas temáticos com e sem o uso de atributos de textura.	145
Figura B.1: Gráficos de dispersão das classes para as combinações de banda para a imagem WorldView-2 para a Legenda N1.....	179
Figura B.2: Gráficos de dispersão das classes para as combinações de banda para a imagem Landsat-8 para a Legenda N1.	180
Figura B.3: Gráficos de dispersão das classes para as combinações de banda para a imagem WorldView-2 para a Legenda N2.....	180
Figura B.4: Gráficos de dispersão das classes para as combinações de banda para a imagem Landsat-8 para a Legenda N2.....	181
Figura B.5: Gráficos de dispersão das classes para as combinações de banda para a imagem WorldView-2 para a Legenda N3.....	181
Figura B.6: Gráficos de dispersão das classes para as combinações de banda para a imagem Landsat-8 para a Legenda N3.....	182
Figura B.7: Gráficos de dispersão das classes para as combinações de banda para a imagem WorldView-2 para a Legenda N4.....	182
Figura B.8: Gráficos de dispersão das classes para as combinações de banda para a imagem Landsat-8 para a Legenda N4.....	183
Figura B.9: Gráficos de dispersão das classes para as componentes do Modelo Linear de Mistura Espectral para a Legenda N1.	184
Figura B.10: Gráficos de dispersão das classes para as componentes do Modelo Linear de Mistura Espectral para a Legenda N2.	185

Figura B.11: Gráficos de dispersão das classes para as componentes do Modelo Linear de Mistura Espectral para a Legenda N3.	186
Figura B.12: Gráficos de dispersão das classes para as componentes do Modelo Linear de Mistura Espectral para a Legenda N4.	186
Figura B.13: Gráficos de dispersão das classes para as componentes da Transformada <i>Tasseled Cap</i> para a Legenda N1.....	187
Figura B.14: Gráficos de dispersão das classes para as componentes da Transformada <i>Tasseled Cap</i> para a Legenda N2.	187
Figura B.15: Gráficos de dispersão das classes para as componentes da Transformada <i>Tasseled Cap</i> para a Legenda N3.	188
Figura B.16: Gráficos de dispersão das classes para as componentes da Transformada <i>Tasseled Cap</i> para a Legenda N4.	188

LISTA DE TABELAS

Tabela 2.1: Remanescente de vegetação natural do Cerrado Brasileiro.....	7
Tabela 2.2: Revisão sobre as fitofisionomias do Cerrado Brasileiro.	17
Tabela 2.3: Fotos em campo e imagens orbitais das fitofisionomias descritas por Ribeiro e Walter (2008).	19
Tabela 2.4: Compatibilização dos sistemas IBGE (2012) e Ribeiro e Walter (2008) proposto por Valeriano (2017).....	25
Tabela 3.1: Revisão dos artigos sobre mapeamento do Cerrado Brasileiro em função da resolução espacial e sistema de classificação utilizado.	33
Tabela 5.1: Características das imagens Landsat-8 e WorldView-2.....	48
Tabela 5.2: Índices de Vegetação.	55
Tabela 5.3: Coeficientes da Transformada Tasseled Cap para as imagens Landsat-8 e WorldView-2.	56
Tabela 5.4: Medidas de textura da matriz GLCM.	58
Tabela 5.5: Medidas de avaliação dos classificadores.	64
Tabela 6.1: Distância Euclidiana para a combinação de bandas Red x NIR e entre as classes da Legenda N1.....	70
Tabela 6.2: Distância Euclidiana para a combinação de bandas Red x NIR e entre as classes da Legenda N2.....	76
Tabela 6.3: Distância Euclidiana para a combinação de bandas Red x NIR e entre as classes da Legenda N3.....	80
Tabela 6.4: Distância Euclidiana para a combinação de bandas Red x NIR e entre as classes da Legenda N4.....	84
Tabela 7.1: Avaliação da classificação para a Legenda N1 – imagem Landsat-8.....	106
Tabela 7.2: Matriz de confusão para a imagem Landsat-8 – Legenda N1.	107
Tabela 7.3: Avaliação da classificação para a Legenda N1 – imagem WorldView-2.	109
Tabela 7.4: Matriz de confusão para a imagem WorldView-2 – Legenda N1.....	110
Tabela 7.5: Avaliação da classificação para a Legenda N2 – imagem Landsat-8.....	113
Tabela 7.6: Matriz de confusão para a imagem Landsat-8 – Legenda N2.	116
Tabela 7.7: Avaliação da classificação para a Legenda N2 – imagem WorldView-2.	117
Tabela 7.8: Matriz de confusão para a imagem WorldView-2 – Legenda N2.....	120
Tabela 7.9: Avaliação da classificação para a Legenda N3 – imagem Landsat-8.....	123
Tabela 7.10: Matriz de confusão para a imagem Landsat-8 – Legenda N3.	125
Tabela 7.11: Avaliação da classificação para a Legenda N3 – imagem WorldView-2.....	126
Tabela 7.12: Matriz de confusão para a imagem WorldView-2 – Legenda N3.....	128
Tabela 7.13: Avaliação da classificação para a Legenda N4 – imagem Landsat-8.....	132
Tabela 7.14: Matriz de confusão para a imagem Landsat-8 – Legenda N4.	134
Tabela 7.15: Avaliação da classificação para a Legenda N1 – imagem WorldView-2.....	135
Tabela 7.16: Matriz de confusão para a imagem WorldView-2 – Legenda N4.....	137
Tabela 7.17: Medidas de avaliação da classificação com e sem textura para a Legenda N4 – imagem WorldView-2.....	143
Tabela 7.18: Matriz de confusão para a imagem WorldView-2 e atributos de textura – Legenda N4.....	144
Tabela A.1: Distância Euclidiana para a combinação de bandas Blue x Green e entre as classes da Legenda N1.	165
Tabela A.2: Distância Euclidiana para a combinação de bandas Blue x Red e entre as classes da Legenda N1.....	165
Tabela A.3: Distância Euclidiana para a combinação de bandas Blue x NIR e entre as classes da Legenda N1.....	165

Tabela A.4: Distância Euclidiana para a combinação de bandas Green x Red e entre as classes da Legenda N1.	165
Tabela A.5: Distância Euclidiana para a combinação de bandas Green x NIR e entre as classes da Legenda N1.	166
Tabela A.6: Distância Euclidiana para a combinação de bandas Blue x Green e entre as classes da Legenda N2.	166
Tabela A.7: Distância Euclidiana para a combinação de bandas Blue x Red e entre as classes da Legenda N2.	167
Tabela A.8: Distância Euclidiana para a combinação de bandas Blue x NIR e entre as classes da Legenda N2.	167
Tabela A.9: Distância Euclidiana para a combinação de bandas Green x Red e entre as classes da Legenda N2.	168
Tabela A.10: Distância Euclidiana para a combinação de bandas Green x NIR e entre as classes da Legenda N2.	168
Tabela A.11: Distância Euclidiana para a combinação de bandas Blue x Green e entre as classes da Legenda N3.	169
Tabela A.12: Distância Euclidiana para a combinação de bandas Blue x Red e entre as classes da Legenda N3.	170
Tabela A.13: Distância Euclidiana para a combinação de bandas Blue x NIR e entre as classes da Legenda N3.	171
Tabela A.14: Distância Euclidiana para a combinação de bandas Green x Red e entre as classes da Legenda N3.	172
Tabela A.15: Distância Euclidiana para a combinação de bandas Green x NIR e entre as classes da Legenda N3.	173
Tabela A.16: Distância Euclidiana para a combinação de bandas Blue x Green e entre as classes da Legenda N4.	174
Tabela A.17: Distância Euclidiana para a combinação de bandas Blue x Red e entre as classes da Legenda N4.	175
Tabela A.18: Distância Euclidiana para a combinação de bandas Blue x NIR e entre as classes da Legenda N4.	176
Tabela A.19: Distância Euclidiana para a combinação de bandas Green x Red e entre as classes da Legenda N4.	177
Tabela A.20: Distância Euclidiana para a combinação de bandas Green x NIR e entre as classes da Legenda N4.	178

LISTA DE ABREVIATURAS E SIGLAS

ALOS	- Advanced Land Observing Satellite
BIRD	- International Bank for Reconstruction and Development
CBERS	- Satélite Sino-Brasileiro de Recursos Terrestres
CEI	- Crop Enhanced Index
CSF	- Correlation Feature Selection
De	- Distância Euclidiana
EMBRAPA	- Empresa Brasileira de Pesquisa Agropecuária
EO	- Erros de Omissão
ESUN	- Irradiância solar na exoatmosfera
ETM+	- Enhanced Thematic Mapper Plus
EVI	- Enhanced Vegetation Index
EVI2	- Enhanced Vegetation Index 2
FFAV	- Fração Fotossinteticamente Ativa da Vegetação
FIP	- Forest Investment Program
FN	- Falso Negativo
FP	- Falso Positivo
GLCM	- Grey Level Co-occurrence Matrix
HRC	- High Resolution Camera
HRG	- High Resolution Geometric
IAF	- Índice de Área Foliar
IBAMA	- Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis
IBGE	- Instituto Brasileiro de Geografia e Estatística
ICMBio	- Instituto Chico Mendes de Conservação da Biodiversidade
INPE	- Instituto Nacional de Pesquisas Espaciais
IPCC	- International Panel on Climate Change
IVs	- Índices de Vegetação
MLME	- Modelo Linear de Mistura Espectral
MMA	- Ministério do Meio Ambiente
MODIS	- Moderate Resolution Imaging Spectroradiometer
MSAVI2	- Modified Soil Adjusted Vegetation Index 2
ND	- Número Digital
NDVI	- Normalized Difference Vegetation Index

OLI	- Operational Land Imager
PALSAR	- Phased Array type L-band Synthetic Aperture Radar
PMABB	- Programa de Monitoramento Ambiental dos Biomas Brasileiros
PNB	- Parque Nacional de Brasília
PPCDAM	- Plano de Ação para Prevenção e Controle do Desmatamento na Amazônia
PPCerrado	- Plano de Ação para Prevenção e Controle do Desmatamento no Cerrado
SAM	- Spectral Angle Mapper
SAVI	- Soil Adjusted Vegetation Index
SPOT	- Pour l'Observation de la Terre
SVM	- Support Vector Machine
SWIR	- Short Wave Infrared
TA	- Taxa de Acerto Global
TAC	- Taxa de Acerto da Classe
TM	- Thematic Mapper
TTC	- Transformada Tasseled Cap
UFG	- Universidade Federal de Goiás
UFLA	- Universidade Federal de Lavras
UFU	- Universidade Federal de Uberlândia
VN	- Verdadeiro Negativo
VP	- Verdadeiro Positivo
WV2	- WorldView-2

SUMÁRIO

1.	INTRODUÇÃO	1
1.1.	Organização do documento	5
2.	O CERRADO BRASILEIRO	6
2.1.	Fitofisionomias do Cerrado brasileiro	10
2.1.1.	Formações florestais	13
2.1.2.	Formações savânicas.....	14
2.1.3.	Formações campestres	16
2.1.4.	Resumo sobre as fitofisionomias do Cerrado brasileiro	16
2.2.	Sistema de classificação do Cerrado proposto pelo IBGE	22
3.	REVISÃO BIBLIOGRÁFICA.....	26
3.1.	Imagens de baixa resolução espacial.....	26
3.2.	Imagens de média resolução espacial.....	27
3.3.	Imagens de alta resolução espacial.....	31
4.	MINERAÇÃO DE DADOS	38
4.1.	Seleção de atributos.....	39
4.2.	<i>Random Forest</i>	42
5.	METODOLOGIA	46
5.1.	Área de estudo	46
5.2.	Aquisição e pré-processamento dos dados	47
5.3.	Definição das legendas de classificação.....	49
5.4.	Definição dos atributos usados na classificação.....	51
5.4.1.	Reflectância espectral	52
5.4.2.	Componentes do modelo linear de mistura espectral	53
5.4.3.	Imagens de índices de vegetação	54
5.4.4.	Imagens da transformada <i>Tasseled Cap</i>	55
5.4.5.	Atributos de textura GLCM	56
5.5.	Seleção de amostras para caracterização das classes e classificação	61
5.6.	Separabilidade das classes pelo critério da distância Euclidiana	61
5.7.	Classificação por <i>Random Forest</i>	62
5.8.	Avaliação da classificação.....	64
6	CARACTERIZAÇÃO DAS FITOFISIONOMIAS DO CERRADO.....	65
6.1	Reflectância	65

6.2	Modelo linear de mistura espectral	85
6.3	Caracterização da transformada <i>Tasseled Cap</i>	92
6.4	Índices de vegetação.....	99
7	CLASSIFICAÇÃO BASEADA NO <i>RANDOM FOREST</i>	105
7.1	Classificação para a Legenda N1:	105
7.2	Classificação para a Legenda N2:	113
7.3	Classificação para a Legenda N3:	122
7.4	Classificação para a Legenda N4:	131
7.5	Classificação usando os atributos de textura.....	140
8	CONCLUSÃO	146
	REFERÊNCIAS BIBLIOGRÁFICAS	150
	APÊNDICE A: DADOS COMPLEMENTARES DE DISTÂNCIA EUCLIDIANA .	165
	APÊNDICE B: GRÁFICOS DE CARACTERIZAÇÃO ESPECTRAL.....	179

1. INTRODUÇÃO

O bioma Cerrado, definido pelo Mapa dos Biomas Brasileiros do Instituto Brasileiro de Geografia e Estatística (IBGE) de 2004, possui 2.036.448 km² de extensão (IBGE, 2004). Esse bioma corresponde a 24% do território Brasileiro e abrange os estados de Goiás, Tocantins, Mato Grosso, Mato Grosso do Sul, Distrito Federal, Minas Gerais, Bahia, Maranhão, Piauí, Rondônia, Paraná e São Paulo.

O Cerrado Brasileiro é reconhecido como a savana mais rica do mundo em termos de biodiversidade, com mais de 14 mil espécies de plantas nativas e animais (MMA, 2016). Sua região é cortada pelas três maiores bacias da América do Sul: Amazônica, São Francisco e Prata, o que faz do Cerrado um ecossistema estratégico em termos de disponibilidade hídrica. Além disso, de acordo com o IPCC (2003), o estoque de carbono no Cerrado é cerca de 29 t.C/ha na vegetação e 117 t.C/ha no solo (até 1 metro de profundidade), sendo o estoque total de carbono para o Bioma estimado em 5,9 bilhões de toneladas de carbono na vegetação e 23,8 bilhões de toneladas no solo (MMA, 2016). Em uma escala global, o Cerrado Brasileiro é considerado uma das 35 regiões prioritárias do planeta para manutenção e conservação da biodiversidade (MITTERMEIER *et al.*, 2011).

Existem três grandes formações de vegetação no Cerrado: as formações Savânicas, as Florestais e as Campestres. As formações Florestais representam áreas com predominância de espécies arbóreas e formação de dossel geralmente contínuo. Já as formações Savânicas referem-se às áreas com árvores e arbustos espalhados sobre um estrato de gramíneas, sem a formação de dossel contínuo. Por sua vez, as formações Campestres correspondem a áreas com predomínio de espécies herbáceas e algumas arbustivas, que podem ou não apresentar árvores e arbustos esparsos (RIBEIRO; WALTER, 2008).

Estas três grandes formações de vegetação natural representam as principais características da vegetação do Cerrado. Estas formações podem ser classificadas em um número maior de fitofisionomias¹ de acordo com a estrutura horizontal e vertical da

¹ Fitofisionomia pode ser definida como as características morfológicas de uma comunidade vegetal (GRABHERR; KOJIMA, 1993). As divisões de vegetação do Cerrado representadas por formações Campestres, Savânicas e Florestais também são fitofisionomias, entretanto, elas serão chamadas de grandes formações do Cerrado.

vegetação. Desta maneira, Ribeiro e Walter (2008) propuseram um sistema de classificação com detalhamento da vegetação de Cerrado em 14 fitofisionomias: Campo Rupestre, Campo Limpo, Campo Sujo, Cerrado Ralo, Cerrado Típico, Cerrado Denso, Cerrado Rupestre, Palmeiral, Vereda, Parque de Cerrado, Cerradão, Mata de Galeria, Mata Seca e Mata Ciliar. A discriminação fitofisionômica em uma maior quantidade implica em um detalhamento maior de ecossistemas locais. Essa maior discriminação também permite inferir, com maior precisão, sobre o estoque de carbono e possíveis emissões de gases do efeito estufa.

Depois da Mata Atlântica, o Cerrado é o bioma Brasileiro que mais passou por alterações com a ocupação humana. Até o ano de 2017, estima-se perda da cobertura vegetal do Cerrado de aproximadamente 978.745 km², segundo os dados produzidos pelo PRODES Cerrado (FIP CERRADO, 2018). Considerando o período de 2010 a 2017, o Cerrado perdeu 70.058 Km² de vegetação, sendo que o desmatamento tem se deslocado para nordeste do bioma, em especial na região de Matopiba (Maranhão, Tocantins, Piauí e Bahia), por onde mais se expande o agronegócio. Portanto, é estratégico que o bioma seja monitorado para combater o desmatamento e manter as áreas de preservação ambiental, produção de água, a biodiversidade e reduzir a emissão dos gases de efeito estufa.

Tendo em vista a importância do bioma Cerrado, várias pesquisas e projetos têm sido desenvolvidos para estudar as alterações da cobertura e uso da terra, estimar as emissões de carbono, estudar o impacto do desmatamento e a degradação da biodiversidade e recursos naturais. Dentro deste contexto, os principais projetos de monitoramento da cobertura vegetal e uso da terra do Cerrado, desenvolvidos por órgãos do governo, destacam-se o PRODES Cerrado (FIP CERRADO, 2018), DETER Cerrado (FIP CERRADO, 2018) e TerraClass Cerrado (MMA, 2015).

Os sistemas PRODES e DETER Cerrado estão sendo desenvolvidos no contexto do projeto Desenvolvimento de Sistemas de Prevenção de Incêndios Florestais e Monitoramento da Cobertura Vegetal do Cerrado Brasileiro (FIP CERRADO, 2018), financiado pelo programa *Forest Investment Program* (FIP) do Banco Mundial (*BIRD – International Bank for Reconstruction and Development*). Também está incluído neste projeto, o desenvolvimento de um mapa de cobertura vegetal natural do Bioma Cerrado para o ano 2000. A metodologia de mapeamento usa o sistema de classificação proposto

por Ribeiro e Walter (2008), e está sendo feito por interpretação visual por especialistas em sensoriamento remoto.

Em relação ao mapeamento do uso da terra, o projeto TerraClass Cerrado (MMA, 2015) foi executado por especialistas do Instituto Nacional de Pesquisas Espaciais (INPE), Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA), Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis (IBAMA), Universidade Federal de Uberlândia (UFU) e Universidade Federal de Goiás (UFG), no qual foram mapeadas as formações florestais e não florestais (savânicas e campestres) do Cerrado além das classes antrópicas como agricultura, área urbana, pastagem, silvicultura, e outras.

A maioria dos trabalhos para classificar a cobertura vegetal do Cerrado tem utilizado imagens dos satélites Landsat, com 30 metros de resolução espacial (FERREIRA *et al.*, 2007; OLIVEIRA *et al.*, 2007a; GRECCHI *et al.*, 2013; COSTA *et al.*, 2014; MULLER *et al.*, 2015; SCHWIEDER *et al.*, 2016). A discriminação entre as grandes formações de Campo, Savana e Floresta, nesta resolução, tem apresentado taxas de acerto superiores a 80%. Os maiores erros de classificação estão relacionados à discriminação entre formações Campestres e pastagens cultivadas e também nas regiões de transição entre formações Campestres e Savânicas.

Ferreira *et al.* (2007), Oliveira *et al.* (2007a), Costa *et al.* (2014) e Schwieder *et al.* (2016) usaram algumas classes do sistema proposto por Ribeiro e Walter (2008) para a discriminação das fitofisionomias do Cerrado, a partir de imagens de resolução espacial de 30m. Oliveira *et al.* (2007a) e Costa *et al.* (2014) obtiveram resultados semelhantes na classificação das fitofisionomias Campestres, com acurácia de classificação em torno de 65%. No entanto, a classificação de regiões de Campo Rupestre (campo com afloramento rochoso aparente) obteve taxa de acerto global aproximada de 55%, nos dois trabalhos. Os resultados apontam que a resolução espacial da classe Landsat (30m) não é adequada para identificação das classes do Cerrado com mais detalhamento, como proposto por Ribeiro e Walter (2008), usando técnicas de processamento digital de imagens.

A dificuldade na classificação mais detalhada da cobertura vegetal do Cerrado mostra a necessidade de se usar imagens de melhor resolução espacial. Teixeira *et al.* (2015), Silva e Sano (2016) e Girolamo Neto *et al.* (2017b) utilizaram imagens de alta resolução espacial (4 a 10m) para classificar a cobertura vegetal do Cerrado. Silva e

Sano (2016) classificaram apenas as grandes formações (Campo, Savana e Floresta). Teixeira *et al.* (2015) classificaram com mais detalhes algumas fitofisionomias Florestais, mas ainda mantiveram as formações de Campo e Savana. Girolamo Neto *et al.* (2017b) discriminaram as fitofisionomias de Campo Limpo, Campo Sujo, Cerrado Ralo, Cerrado Típico e Matas de Galeria usando classificação automática com o algoritmo de *Random Forest* (BREIMAN, 2001). Pinheiro e Durigan (2009) usaram imagens de alta resolução espacial (1 a 4m) para classificar, visualmente, as fitofisionomias propostas por Ribeiro e Walter (2008).

A maioria dos estudos sobre o mapeamento da cobertura vegetal do Cerrado tem usado poucas classes, principalmente as formações Florestais, Savânicas e Campestres, limitando o potencial do que é possível ser analisado. Além disso, os estudos não apresentam análises detalhadas sobre a caracterização e a discriminação das fitofisionomias do Cerrado. Dentro deste contexto, este trabalho tem como objetivo analisar a discriminação das fitofisionomias do bioma Cerrado usando legendas com maior nível de detalhamento de classes e imagens de média e alta resolução espacial. Neste trabalho, são usadas 4 legendas com níveis progressivos de detalhamento de classes baseadas no sistema de Ribeiro e Walter (2008). A análise das fitofisionomias é realizada com imagens dos satélites WorldView-2 e Landsat-8, que possuem bandas espectrais complementares. Para a caracterização das classes são usados os atributos espectrais: Reflectância, Modelo Linear de Mistura Espectral, Transformada *Tasseled Cap*, Índices de Vegetação e textura. As fitofisionomias, para cada uma da legendas, são classificadas usando o algoritmo *Random Forest* e técnicas de mineração de dados. Portanto, a hipótese deste trabalho é que imagens de alta resolução espacial combinadas com as técnicas de extração de atributos podem discriminar as classes do Cerrado com maior nível de detalhamento e melhor desempenho de classificação.

Os objetivos específicos deste trabalho são:

- * Caracterizar 10 classes propostas por Ribeiro e Walter (2008) em função dos atributos de Reflectância, componentes do Modelo Linear de Mistura Espectral, Transformada *Tasseled Cap* e Índices de Vegetação;

- * Compatibilizar a unidade mínima de mapeamento entre as imagens Landsat-8 (30m) e WorldView-2 (2m), para que os resultados sejam comparáveis;

* Explorar as informações das bandas espectrais complementares nas imagens do WorldView-2 (Amarelo, *Red-Edge*) e Landsat-8 (SWIR1, SWIR2);

* Classificar uma área teste do Cerrado e medir o desempenho da classificação baseado em dados de campo e interpretação visual.

1.1. Organização do documento

Este documento encontra-se organizado da seguinte forma:

O Capítulo 2 apresenta uma discussão sobre a importância do Cerrado brasileiro em termos ambientais e quais são suas principais fitofisionomias dos sistemas de classificação propostos por Ribeiro e Walter (2008) e IBGE (2012).

O Capítulo 3 avalia os trabalhos científicos relacionados a classificação de fitofisionomias do Cerrado. São apresentadas as dificuldades e pontos positivos na discriminação de fitofisionomias do com o uso de imagens de alta, média e baixa resoluções espaciais.

O Capítulo 4 apresenta uma revisão dos principais conceitos relacionados à mineração de dados, destacando-se o algoritmo de classificação *Random Forest*, o qual é utilizado neste trabalho.

A Metodologia é apresentada no Capítulo 5 onde são descritas as etapas de aquisição e pré-processamento dos dados, definição de legendas e extração de atributos utilizados na classificação, estratégias de classificação e validação dos resultados.

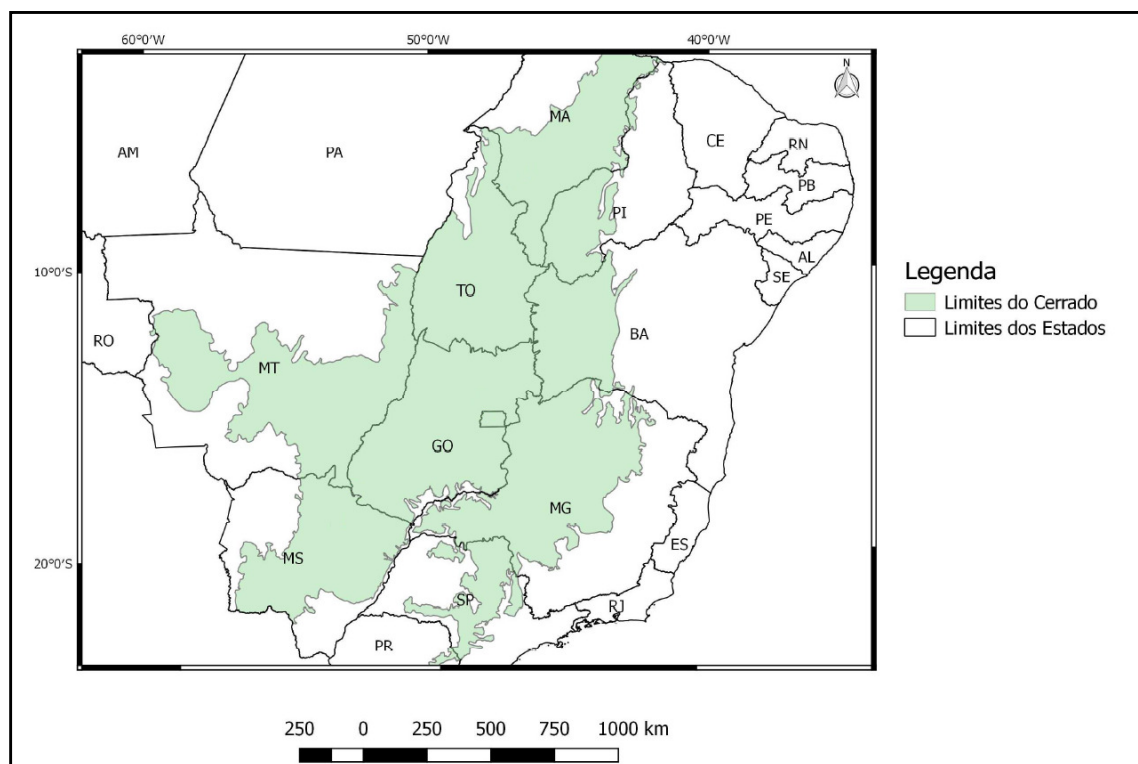
O Capítulo 6 apresenta a caracterização espectral das fitofisionomias em relação aos atributos de Reflectância, componentes do Modelo Linear de Mistura Espectral, Transformada *Tasseled Cap* e Índices de vegetação. Esta análise serve como subsídio para o melhor entendimento dos resultados da classificação por *Random Forest* e também para avaliar como cada tipo de atributo está contribuindo para a melhor discriminação de determinadas fitofisionomias, sendo que estas análises são feitas no Capítulo 7.

Finalmente, as conclusões sobre o trabalho e futuras pesquisas são apresentadas no Capítulo 8.

2. O CERRADO BRASILEIRO

Ocupando cerca de 24% do território nacional, o Cerrado faz fronteira com a Amazônia ao norte, Mata Atlântica ao sul e sudeste, Caatinga a nordeste e Pantanal a oeste. A região engloba os planaltos do Brasil Central e chapadões interiores dos Estados de Goiás, Maranhão, Mato Grosso, Mato Grosso do Sul, Minas Gerais, Piauí, Tocantins e Distrito Federal, além de algumas manchas nos Estados da Bahia e de São Paulo, além de áreas pontuais no Paraná e Rondônia (IBGE, 2004 – Figura 2.1.).

Figura 2.1: O Cerrado no território Brasileiro.



Fonte: Adaptado de Girolamo Neto *et al.* (2017a).

O Cerrado Brasileiro corresponde a uma das savanas mais úmidas do planeta, com estações seca e chuvosa bem definidas (FERREIRA *et al.*, 2003). O período seco inicia nos meses de abril e maio e se estende até setembro a outubro, já a estação chuvosa inicia nos meses de setembro a outubro e se estende até março e abril, com

variação do nível de precipitação média anual de 400 a 2200 mm (SILVA *et al.*, 2008). A temperatura média da região é amena ao longo do ano, variando, geralmente, entre 22 e 27° C. Os tipos de solo também são bastante diversos, sendo que em mais de 86% da região predominam os Latossolos, Neossolos Quartzarênicos, Argissolos e Plintossolos (EMBRAPA, 2003). Com relação a sua hidrografia, o Cerrado encontra-se recortado pelas três maiores bacias hidrográficas da América do sul: Amazônica, do São Francisco e do Prata (IBGE, 2004).

Sua vegetação é caracterizada pelo predomínio de gramíneas, geralmente intercaladas por árvores e arbustos de tamanhos variados (RIBEIRO; WALTER, 2008). Por ocupar grande extensão territorial e apresentar variação climática, de tipos de solo e de topografia, o Cerrado apresenta uma série de fitofisionomias que diferem quanto à estrutura e composição florística (GUSMÃO *et al.*, 1990). Além destes fatores, as fitofisionomias também são resultantes da frequência, época e intensidade de ocorrência de queimadas (COUTINHO, 2002). Com uma rica biodiversidade, o Cerrado contém mais de 14 mil espécies de plantas nativas e animais (MMA, 2016).

Entretanto, a grande biodiversidade do Cerrado encontra-se ameaçada devido ao avanço do desmatamento sob esta região. As perdas de sua vegetação natural são dificilmente quantificadas com precisão, todavia o remanescente de vegetação natural do Cerrado Brasileiro chega a pouco mais de um milhão de quilômetros quadrados, cerca de 52% de sua área total (FIP CERRADO, 2018). O remanescente de vegetação natural de Cerrado por período encontra-se na Tabela 2.1.

Tabela 2.1: Remanescente de vegetação natural do Cerrado Brasileiro.


Ano	Área total de Cerrado (km ²)	Remanescente Natural (km ²)	Remanescente Natural (%)	Desmatamento Total (km ²)
2000	2.036.448	1.323.067	64,97	706.547
2002		1.270.912	62,41	765.536
2004		1.212.927	59,56	823.521
2006		1.177.640	57,83	858.808
2008		1.147.871	56,37	888.577
2010		1.127.761	55,38	908.687
2013		1.094.530	53,75	941.918
2015		1.071.888	52,64	964.560
2017		1.057.703	51,94	978.745

Fonte: Adaptado de FIP CERRADO (2018).

O avanço do desmatamento e a necessidade de conservação da fauna e flora do Cerrado o coloca na lista dos 35 biomas de alta biodiversidade mais ameaçados do mundo (MITTERMEIER *et al.*, 2011). Segundo o Ministério do Meio Ambiente (2015), somente cerca de 175 mil quilômetros quadrados estão em unidades de conservação, ou seja, 8,6% de sua área. Além da degradação da vegetação, a introdução e invasão de espécies exóticas também é uma ameaça à biodiversidade do Cerrado.

Desde 1988, apenas o monitoramento da cobertura vegetal do bioma Amazônia (INPE, 2018) é realizada. O “esquecimento” do Cerrado é preocupante, principalmente pelo fato das mudanças do uso do solo nesta região ocorrer com maior intensidade do que na Amazônia (SANO *et al.*, 2001; SKOLE *et al.*, 2012). A Figura 2.2 mostra dados do PRODES Cerrado (FIP CERRADO, 2018) e Amazônia (INPE, 2018), onde o incremento anual de desmatamento do Cerrado foi superior ao da Amazônia em praticamente todos os anos para o período de 2006 até 2015.

Figura 2.2: Incremento anual do desmatamento para o Cerrado e Amazônia para os anos de 2001 a 2017.



Fonte: Adaptado de FIP CERRADO (2018) e INPE (2018).

Outro fator que contribui para a constante perda da cobertura vegetal do Cerrado é o fogo. A ocorrência de eventos de queimada no Cerrado é um fato que ocorre há,

pelo menos, 32 mil anos (MIRANDA *et al.*, 2009). As queimadas, quando ocorrem de forma natural, são consideradas importantes para a evolução de espécies no Cerrado (SIMON *et al.*, 2009). A presença de casca espessa nos galhos e troncos, uma das principais características de sua vegetação, foi uma evolução para que as plantas protegessem os tecidos internos de altas temperaturas. A principal consequência do fogo para o Cerrado é a mudança da estrutura de sua vegetação, que favorece as espécies herbáceas em detrimento das espécies arbóreas (MOREIRA, 2000). Algumas espécies ainda têm a produção de sementes estimulada por queimadas (MOREIRA; PAUSAS, 2012).

Apesar de ser um fator evolutivo importante, as queimadas também são responsáveis por aumentar a taxa de mortalidade de diversas espécies de animais e plantas do Cerrado. A recorrência de queimadas anuais faz com que algumas espécies mais jovens não desenvolvam a casca espessa para se proteger do fogo e, conseqüentemente, não conseguem sobreviver (MEDEIROS; MIRANDA, 2005). O fogo também prejudica a reprodução sexuada, reduz a produção de sementes no ano subsequente e pode causar a morte da copa, impedindo que alguns indivíduos atinjam classes de tamanho maiores (HOFFMANN *et al.*, 2009).

As queimadas também são apontadas como um dos maiores fatores que impulsionam a expansão agropecuária no Brasil, principalmente na Amazônia e no Cerrado (PIROMAL *et al.*, 2008). Embora o Cerrado seja uma vegetação adaptada aos eventos de queimada, o uso antrópico deste artifício para expansão de novas áreas agrícolas e pecuárias causa a perda de nutrientes, compactação e erosão do solo (KLINK; MACHADO, 2005).

Nesse contexto, as queimadas representam um papel importante para as emissões de carbono em áreas de Cerrado, pois são responsáveis pela liberação de gases do efeito estufa como dióxido de carbono (CO₂), metano (CH₄) e óxido nitroso (N₂O) (SANTOS *et al.*, 2014). O fogo é responsável por alterar a biomassa vegetal e, dessa forma, modificar os padrões de dominância e as interações entre as espécies. Ao considerar as extensas alterações na paisagem é igualmente esperado que ocorra alterações no estoque de carbono, principalmente pela alteração da quantidade de biomassa (CIANCIARUSO *et al.*, 2010).

A constante perda da biodiversidade do Cerrado representa um alto custo ambiental, causando problemas como a erosão do solo, degradação das formações

vegetais do bioma, poluição da água, mudanças nos eventos de fogo típicos, instabilidade do ciclo do carbono e prováveis modificações microclimáticas (KLINK; MACHADO, 2005). A destruição de áreas vegetação nativa ocasiona o processo de fragmentação da vegetação, e sua intensificação pode trazer perdas inestimáveis de exemplares de fauna e flora (MACHADO *et al.*, 1998; MENDONÇA; LINS, 2000). Algumas iniciativas do governo Brasileiro para promover o monitoramento dos biomas são as políticas de Proteção e Combate ao Desmatamento da Amazônia (2004) e do Cerrado (2010), respectivamente, PPCDAM (MMA, 2018a) e PPCerrado (MMA, 2018b), e o Programa de Monitoramento Ambiental dos Biomas Brasileiros (PMABB – MMA, 2018c), lançado em 27 de novembro de 2015.

O mapeamento de áreas tropicais heterogêneas, como o Cerrado, é um desafio devido os fatores biológicos naturais, climáticos e topográficos e as peculiaridades de suas fitofisionomias. Além da forte sazonalidade da vegetação natural e a diversidade de tipos de culturas agrícolas no espaço e no tempo, as semelhanças espectrais entre determinadas áreas dificultam a diferenciação destas coberturas no processo de classificação do uso e ocupação do solo com imagens orbitais (SANO *et al.*, 2010; GRECCHI *et al.*, 2013).

2.1. Fitofisionomias do Cerrado brasileiro


O termo fitofisionomia pode ser considerado como a primeira impressão causada pela vegetação (ALLEN, 1998). Em termos técnicos, pode ser traduzida como as características morfológicas de uma comunidade vegetal (GRABHERR; KOJIMA, 1993). Para a classificação de uma fitofisionomia considera-se, inicialmente, parâmetros baseados na forma, que é definida pela estrutura da vegetação, pelas formas de crescimento dominantes e por possíveis mudanças estacionais. Posteriormente, consideram-se aspectos do ambiente e da composição florística. Ribeiro e Walter (2008) descrevem o Cerrado como uma região composta de formações florestais, savânicas e campestres. Neste documento, as formações Florestais, Savânicas e Campestres serão chamadas de grandes formações naturais de Cerrado.

As formações Florestais representam áreas com predominância de espécies arbóreas, onde há a formação de dossel², contínuo ou descontínuo. No Cerrado, existem

² Cobertura que se forma pelas copas das árvores.

os seguintes grupos de formações Florestais: Mata Ciliar, Mata de Galeria, Mata Seca e Cerradão. Já as formações Savânicas referem-se às áreas com árvores e arbustos espalhados sobre um estrato de gramíneas, sem a formação de dossel contínuo. Os grupos de formações Savânicas que podem ser encontrados no Cerrado são: Cerrado Sentido Restrito (*Stricto sensu*), Parque de Cerrado, Palmeiral e Vereda. Por sua vez, as formações Campestres correspondem a áreas com predomínio de espécies herbáceas e algumas arbustivas, que podem ou não apresentar árvores e arbustos esparsos. As formações campestres do Cerrado são representadas pelos seguintes grupos: Campo Sujo, Campo Limpo e Campo Rupestre. A Figura 2.3 mostra a classificação das fitofisionomias do Cerrado Brasileiro, segundo Ribeiro e Walter (2008). As seções 2.1.1. a 2.1.3. mostram a descrição das fitofisionomias propostas por Ribeiro e Walter (2008).

Figura 2.3: Fitofisionomias do Cerrado Brasileiro.



Fonte: Ribeiro e Walter (2008); WWF (2015).

2.1.1. Formações florestais

Matas Ciliares: Ocupam áreas restritas ao longo dos cursos d'água de médio e grande porte, sendo normalmente estreitas e dificilmente ultrapassando 100 m de largura em cada margem. As Matas Ciliares, em geral, ocorrem em terrenos acidentados, não havendo uma transição evidente para outras fisionomias florestais. Diferencia-se da Mata de Galeria pela forma de queda das folhas e pela composição florística e da Mata Seca pela associação ao curso de água e pela estrutura, que é mais densa e mais alta.

Matas de Galeria: Acompanham rios de pequeno porte e córregos, formando corredores fechados (galerias) sobre o curso d'água. As Matas de Galeria têm como característica a presença permanentemente das folhas (perenifólia), sem queda significativa durante a estação seca. Normalmente, são circundadas por faixas de vegetação não florestal em ambas as margens e, em geral, ocorre uma transição brusca com formações savânicas e campestres. A transição é quase imperceptível quando ocorre com Matas Ciliares, Matas secas ou mesmo Cerradões. Podem ser divididas em subgrupos de Matas de Galeria Inundáveis ou Não Inundáveis, caso acompanhem o lençol freático exposto na superfície ou no subsolo, respectivamente.

Mata Seca: Formações florestais no bioma Cerrado que não possuem associação com cursos d'água, caracterizadas por diversos níveis de queda das folhas durante a estação seca. Este tipo de fisionomia ocorre, normalmente, nos níveis de relevos que separam os fundos de vales, em locais geralmente mais ricos em nutrientes. Em função do tipo de solo, da composição florística e da queda de folhas no período seco, a Mata Seca pode ser tratada sob três subgrupos: Mata Seca Sempre-verde, Mata Seca Semidecídua e Mata Seca Decídua. Em todos esses subgrupos, a queda de folhas contribui para o aumento da matéria orgânica no solo, mesmo na Mata Seca Sempre-verde.

Cerradão: Formação florestal com características esclerofilas (grande ocorrência de órgãos vegetais rijos, principalmente folhas) e xeromórficas (com características como folhas reduzidas, suculência, pilosidade densa ou com cutícula grossa que permitem conservar água e, portanto, suportar condições de seca). Do ponto de vista fisionômico é uma floresta, mas floristicamente se assemelha mais ao Cerrado *Stricto Sensu*. Apresenta dossel contínuo e cobertura arbórea que pode oscilar de 50 a 90%, sendo maior na estação chuvosa e menor na seca. Embora possa manter um volume constante de folhas nas árvores geralmente muitas espécies apresentam queda das folhas em

determinados períodos na estação seca. O Cerradão apresenta dois subgrupos o Cerradão Distrófico, que ocorre em solos de baixa fertilidade, e o Cerradão Mesotrófico, em solos com alta fertilidade.

2.1.2. Formações savânicas

Cerrado *Stricto Sensu*: Fitofisionomia caracterizada pela presença de árvores baixas, inclinadas, tortuosas, com ramificações irregulares e retorcidas, e geralmente com evidências de queimadas. Os troncos das plantas apresentam, em geral, cascas com cortiça espessa ou sulcada e as folhas são rígidas e com consistência de couro. Os arbustos e subarbustos encontram-se espalhados e algumas espécies permitem a rebrota após queima ou corte. As árvores não sofrem restrição de água durante a estação seca, pelo menos aquelas que possuem raízes profundas. Na época chuvosa as camadas arbustivas e herbáceas tornam-se exuberantes, devido ao rápido crescimento. Dado à complexidade dos fatores condicionantes (clima, fertilidade do solo, quantidade de chuvas, etc.) originam-se subdivisões fisionômicas (subgrupos) do Cerrado *Stricto Sensu*, sendo as principais o Cerrado Denso, o Cerrado Típico, o Cerrado Ralo e o Cerrado Rupestre.

- **Cerrado *Denso*:** Vegetação predominantemente arbórea, com cobertura de 50% a 70% e altura média de cinco a oito metros. Representa a forma mais densa e alta de Cerrado *Stricto Sensu*. As camadas de vegetação de arbustos e ervas são menos adensados, provavelmente devido ao sombreamento resultante da maior cobertura das árvores. Ocorre principalmente nos solos dos tipos Latossolos Vermelho, Latossolos Vermelho-Amarelo e Cambissolos.

- **Cerrado *Típico*:** Vegetação predominantemente arbóreo-arbustiva, com cobertura arbórea de 20% a 50% e altura média de três a seis metros. Trata-se de uma forma comum e intermediária entre o Cerrado Denso e o Cerrado Ralo. O Cerrado Típico pode ocorrer em solos como: Latossolo Vermelho, Latossolo Vermelho-Amarelo, Cambissolos, Neossolos Quartzarênicos, Neossolos Litólicos e Plintossolos Pétricos.

- **Cerrado *Ralo*:** Vegetação constituída de árvores e arbustos, com cobertura arbórea de 5% a 20% e altura média de dois a três metros. Representa a forma mais baixa e menos densa de Cerrado *Stricto Sensu*. A camada de arbustos se destaca em

relação aos outros subtipos, especialmente pela cobertura graminosa. Ocorre principalmente em como: Latossolo Vermelho Amarelo, Cambissolos, Neossolos Quartzarênicos, Plintossolos Pétricos, Gleissolos e Neossolos Litólicos.

- **Cerrado Rupestre:** O Cerrado Rupestre é um subtipo de vegetação arbóreo-arbustiva que ocorre em ambientes rupestres (rochosos). Possui cobertura arbórea variável de 5% a 20%, com altura média de dois a quatro metros, e camada arbustivo-herbácea destacada. Pode ocorrer em trechos contínuos, mas geralmente aparece em mosaicos. Embora possua estrutura semelhante ao Cerrado Ralo, seu substrato comporta uma vegetação sobre pouco solo entre afloramentos de rocha. Os solos desta paisagem são geralmente os Neossolos Litólicos.

Parque de Cerrado: É caracterizado pela presença de árvores agrupadas em pequenas elevações do terreno, algumas vezes imperceptíveis e outras com muito destaque. As árvores, nos locais onde se concentram, possuem altura média de três a seis metros. Considerando um trecho com os agrupamentos arbóreos e as depressões ou planos campestres entre eles, forma-se uma cobertura de 5% a 20%. Considerando somente os agrupamentos arbóreos a cobertura sobe para 50% a 70% e é praticamente 0% nas depressões.

Palmeiral: Vegetação caracterizada pela presença de uma única espécie de palmeira arbórea denominada Palmeiral. Neste tipo de formação vegetal não há destaque das árvores dicotiledôneas embora essas possam ocorrer com baixa frequência. No Cerrado podem ser encontrados pelo menos quatro subgrupos mais comuns de palmeirais, sendo que o nome da fitofisionomia leva o nome da palmeira (Macaubal, Guerobal, Babaçual e Buritizal). Em geral os palmeirais do Cerrado são encontrados em terrenos bem drenados, embora o Buritizal ocorra em terrenos mal drenados.

Vereda: Tipo de vegetação com a palmeira arbórea Buriti (*Mauritia flexuosa*) emergente, em meio a agrupamentos mais ou menos densos de espécies arbustivo-herbáceas. São circundadas por campos típicos, geralmente úmidos, e não formam dossel. Os Buritis adultos possuem altura média de 12 a 15 metros e a cobertura varia de 0% a 50%. Ocorrem em solos argilosos e mal drenados, geralmente ocupando vales pouco íngremes ou áreas planas, acompanhando linhas de drenagem mal definidas. Também são comuns numa posição intermediária do terreno, próximas às nascentes ou nas bordas das cabeceiras de Matas de Galeria.

2.1.3. Formações campestres

Campo Limpo: Vegetação predominantemente herbácea, com raros arbustos e ausência completa de árvores. Pode ser encontrado em diversas posições topográficas, com diferentes variações no grau de umidade, profundidade e fertilidade do solo. Entretanto, é encontrado com mais frequência nas encostas, chapadas, nascentes d'água, circundando as Veredas e na borda das Matas de Galeria. Quando ocorre em áreas planas, relativamente extensas, contíguas aos rios e inundadas periodicamente, também é chamado de Campo de várzea, várzea ou brejo. Na presença de um reservatório subterrâneo de água profundo há o Campo Limpo Seco. No caso do lençol freático próximo a superfície ocorre o Campo Limpo Úmido. Em áreas de microrrelevos mais elevados, tem-se o Campo Limpo com Murundus.

Campo Sujo: Tipo fisionômico exclusivamente arbustivo-herbáceo, com arbustos e subarbustos esparsos cujas plantas são menos desenvolvidas que as árvores do Cerrado *Stricto Sensu*. Este tipo de vegetação é encontrado em solos rasos, eventualmente com pequenos afloramentos rochosos de pouca extensão (sem caracterizar um Campo Rupestre), ou ainda em solos profundos e de baixa fertilidade (álícos ou distróficos). Devido a particularidades ambientais, o Campo Sujo pode apresentar três subgrupos fisionômicos distintos, com as mesmas divisões do Campo Limpo, ou seja, Campo Sujo seco, Campo Sujo Úmido e Campo Sujo com Murundus.

Campo Rupestre: Vegetação predominantemente herbáceo-arbustiva, com a presença eventual de árvores pouco desenvolvidas de até dois metros de altura. Abrange um complexo de vegetação que agrupa paisagens em microrrelevos com espécies típicas, ocupando trechos de afloramentos rochosos. Geralmente ocorre em altitudes superiores a 900 metros em áreas onde há ventos constantes e variações extremas de temperatura. A composição da flora em áreas de Campo Rupestre pode variar muito em poucos metros de distância. Há locais em que os arbustos praticamente dominam a paisagem, enquanto que em outros a flora herbácea predomina.

2.1.4. Resumo sobre as fitofisionomias do Cerrado brasileiro

A Tabela 2.2 apresenta um resumo das principais fitofisionomias do Cerrado, enquanto que a Tabela 2.3 apresenta imagens ópticas orbitais e fotos em campo destas fitofisionomias.

Tabela 2.2: Revisão sobre as fitofisionomias do Cerrado Brasileiro.

Grandes Formações	Fitofisionomias (Grupos)	Cobertura Principal	Características do dossel	Ocorrência	Subgrupos	Diferenciação dos subgrupos	
CAMPESTRE	Campo Limpo	Herbácea Arbustos raros Ausência de árvores	Não existe formação de dossel.	Maior frequência em encostas, chapadas. Principais tipos de solos: Neossolos e Plintossolos.	Campo Limpo Seco Campo Limpo Úmido Campo Limpo com Murundu	Lençol freático próximo à superfície e presença de microrrelevos.	
	Campo Sujo	Herbácea arbustiva Arbustos esparsos Ausência de árvores	Não existe formação de dossel.	Solos rasos com pouco afloramento rochoso ou profundos e de baixa fertilidade.	Campo Sujo Seco Campo Sujo Úmido Campo Sujo com Murundu	Lençol freático próximo à superfície e presença de microrrelevos.	
	Campo Rupestre	Herbácea arbustiva Arvoretas de até 2m.	Não existe formação de dossel.	Altitudes superiores a 900m em regiões rochosas. Solos com baixa disponibilidade de água	-	-	
SAVÂNICAS	Palmeiral	Presença de palmeira arbórea denominada Palmeiral. Altura de 8-20m dependendo da espécie	Locais com dossel contínuo e cobertura arbórea de 30-80%, dependendo da espécie.	Terrenos bem drenados (exceto buritizal). Pode ocorrer formação de galeria similar à vegetação florestal.	Macaubal Guerobal Babaçual Buritizal	Tipo da palmeira leva o nome da subdivisão da fitofisionomia.	
	Vereda	Herbácea arbustiva. Presença da palmeira arbórea Buriti (altura de 12-15m)	Cobertura arbórea de 0-50%, devido à proximidade de áreas alagadas.	Solos argilosos e mal drenados. Locais planos acompanhando linhas de drenagem deficientes e lençol freático.	-	-	
	Parque de Cerrado	Arbórea em pequenas elevações de terreno Altura de 3-6m	Locais com dossel contínuo e cobertura arbórea de 50-70%. Cobertura de 0% em depressões.	Ocorre em microrrelevos com altura de até 1,5m e largura de até 20m.	-	-	
	Cerrado <i>Stricto Sensu</i> *	Cerrado Rupestre	Arbórea arbustiva Altura de 2-4m Árvores podem aparecer nas fendas de rochas	Locais com dossel contínuo esparsos. Cobertura arbórea de 5-20%.	Mosaicos em meio a outras fitofisionomias. Solos pobres, ácidos e baixo teor de matéria orgânica (Neossolos).	Cerrado Rupestre	-
		Cerrado Ralo	Arbórea arbustiva Altura de 2-3m	Locais com dossel contínuo esparsos. Cobertura arbórea de 5-20%.	Solos variados na textura, coloração e permeabilidade (Latosolos, Neossolos e Cambissolos).	Cerrado Ralo	Porcentagem de cobertura arbórea e altura das árvores.
		Cerrado Típico	Arbóreo arbustivo Altura de 3-6m	Locais com dossel contínuo e cobertura arbórea de 20-50%.	Solos variados na textura, coloração e permeabilidade (Latosolos, Neossolos e Cambissolos).	Cerrado Típico	Porcentagem de cobertura arbórea e altura das árvores.
		Cerrado Denso	Predominantemente arbóreo. Altura de 5-8m	Locais com dossel contínuo e cobertura arbórea de 50-70%.	Solos argilosos e bem drenados (Latosolos e Cambissolos).	Cerrado Denso	Porcentagem de cobertura arbórea e altura das árvores.


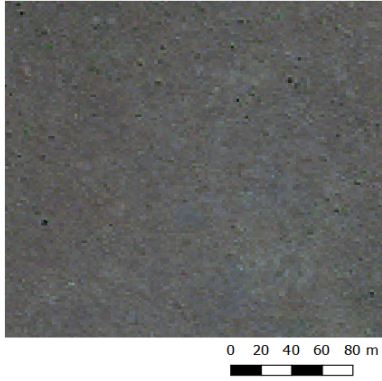

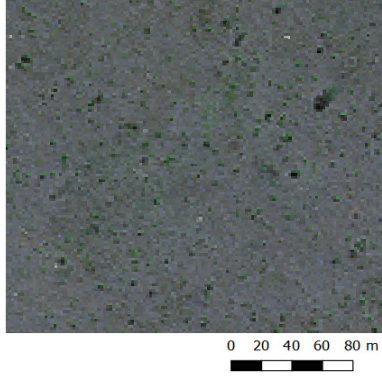

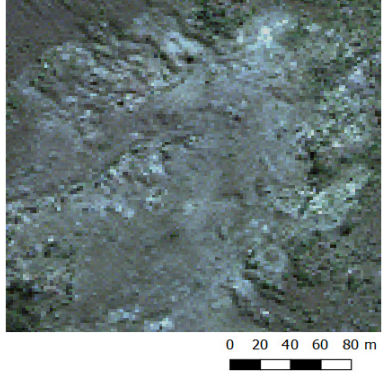

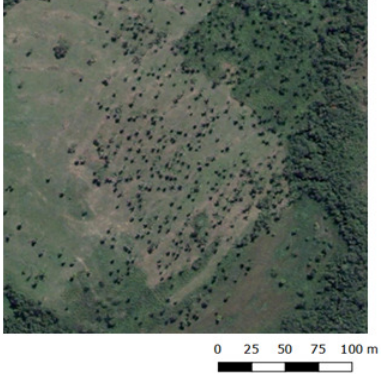
Tabela 2.2 – Conclusão.

Grandes Formações	Fitofisionomias (Grupos)	Cobertura Principal	Características do dossel	Ocorrência	Subgrupos	Diferenciação dos subgrupos
FLORESTAIS	Cerradão	Florestal Presença de espécies florestais em conjunto com savânicas Árvores de 8-15m	Dossel contínuo e cobertura arbórea de 50-90%.	Solos bem drenados e ácidos (Latosolos). Alto teor de matéria orgânica superficial	Cerradão Distrófico Cerradão Mesotrófico	Solos de fertilidade alta ou baixa.
	Mata Seca	Florestal Árvores de 15 a 25m.	Dossel contínuo e cobertura arbórea de 70-95% na época úmida e inferior a 50% na época seca	Não associadas a cursos d água. Ocorre em fundos de vales. Solos de alta fertilidade (Latosolos)	Mata Seca Sempre-verde Mata Seca Semidecídua Mata Seca Decídua	Condições químicas e físicas do solo Composição florística e queda das folhas.
	Mata de Galeria	Florestal Árvores de 20 a 30m.	Dossel contínuo e cobertura arbórea de 70-95%.	Fundos de vale ou cabeceiras de drenagem. Cambissolos, Plintossolos e Argissolos.	Mata de Galeria Inundável Mata de Galeria Não Inundável	Topografia e profundidade do lenço freático.
	Mata Ciliar	Florestal Árvores de 20 a 25m.	Dossel contínuo e cobertura arbórea de 50-90%.	Acompanha rios de médio e grande porte. Até 100m de largura. Terrenos acidentados.	-	-

*Dividido nos subgrupos para facilitar a explicação.


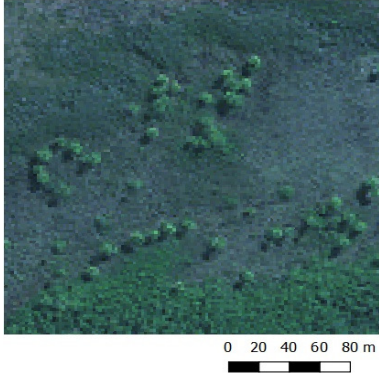

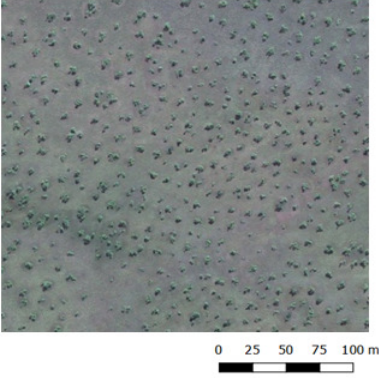

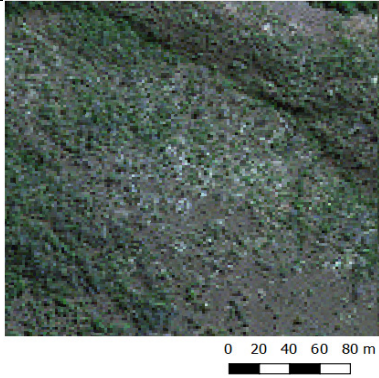

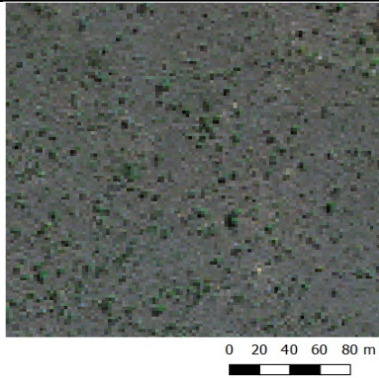
Fonte: Adaptado de Ribeiro e Walter (2008).

Tabela 2.3: Fotos em campo e imagens orbitais das fitofisionomias descritas por Ribeiro e Walter (2008).

Fitofisionomia	Foto em Campo	Imagem orbital de alta resolução
Campo Limpo		
Campo Sujo		
Campo Rupestre		
Palmeiral		


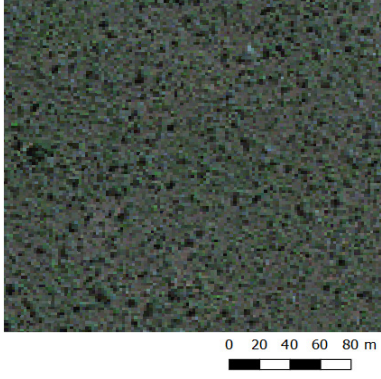

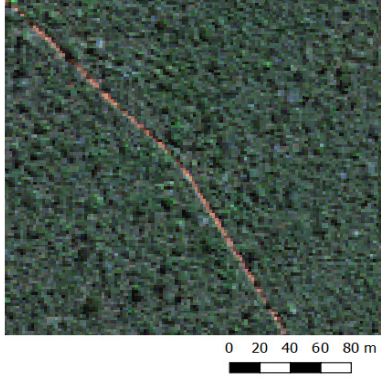

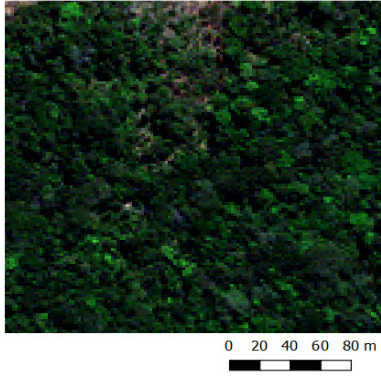


continua

Tabela 2.3 – Continuação

Fitofisionomia	Foto em Campo	Imagem orbital de alta resolução
Vereda		
Parque de Cerrado		
Cerrado Rupestre		
Cerrado Ralo		





continua

Tabela 2.3 – Continuação

Fitofisionomia	Foto em Campo	Imagem orbital de alta resolução
Cerrado Típico		
Cerrado Denso		
Cerradão		
Mata Seca		

continua

Tabela 2.3 – Conclusão

Fitofisionomia	Foto em Campo	Imagem orbital de alta resolução
Mata de Galeria	 <p>Foto: Jeanine Felini</p>	 <p>0 20 40 60 80 m</p>
Mata Ciliar	 <p>Foto: Bruno Walter</p>	 <p>0 20 40 60 80 m</p>

Fonte: Produção do autor.

2.2. Sistema de classificação do Cerrado proposto pelo IBGE

O sistema de classificação proposto pelo manual técnico da vegetação brasileira do Instituto Brasileiro de Geografia e Estatística (IBGE, 2012) é amplamente utilizado para a discriminação da cobertura vegetal natural do Cerrado. Savana, no sistema do IBGE, é definida como uma vegetação xeromorfa que ocorre em diversos tipos de clima, e que corre em zonas neotropicais, prioritariamente, no Brasil central. Este sistema difere consideravelmente do sistema proposto por Ribeiro e Walter (2008), no qual as formações Campestres e Savânicas são subdivididas em apenas quatro tipos fisionômicos. Cerradão é considerado como formação savânica pelo IBGE. Em seguida, a classificação do Cerrado definida pelo IBGE é apresentada.

Savana Gramíneo-lenhosa (Campo Limpo de Cerrado): constituem gramados entremeados por plantas lenhosas raquíticas que ocupam áreas extensas. Sua

vegetação é resistente ao fogo e ao pastoreio por apresentarem raízes profundas e capacidade de rebrota após estes eventos.

Savana Parque (Campo Sujo de Cerrado): refere-se aos campos sujos de Cerrado, sendo um extrato graminóide junto a arbustos e arvoretas isoladas, sendo relatada como a estrutura típica de um parque inglês (*Parkland*). Podem apresentar rochas aparentes em seu solo, caracterizando uma formação similar ao Cerrado Rupestre, dependendo da quantidade de arvoretas e arbustos.

Savana Arborizada (Cerrado *Stricto Sensu*): definida como uma formação que tem como principal característica a presença menos frequente de árvores do que a Savana Florestada e uma maior quantidade de vegetação arbustiva contínua do que a Savana Parque. Esta vegetação inclui basicamente todas as formações referentes ao Cerrado *Stricto Sensu*, definido na seção 2.1.2. Dependendo do adensamento da vegetação, pode ser um Cerrado Ralo, Típico ou Denso.

Savana Florestada (Cerradão): esta classe de vegetação é mais conhecida como o Cerradão. Tratado como vegetação savânica por este sistema de classificação, é caracterizado por apresentar um extrato arbustivo e árvores tortuosas com ramificações irregulares podendo ter altura superior a 10m em alguns casos. Formam dossel contínuo e se assemelham fisionomicamente às Florestas Estacionais.

Além das formações referentes à savana, o IBGE também caracteriza as formações florestais. No Cerrado, as formações florestais definidas por Ribeiro e Walter (2008), assemelham-se, geralmente, às Florestas Estacionais. Elas têm como principal característica a formação de um dossel contínuo na estação chuvosa e a queda das folhas em períodos secos (com exceção da Floresta Estacional Sempre-verde). As principais formações florestais do Cerrado são:

Floresta Estacional Decidual (Floresta Tropical Caducifólia): dentre as formações florestais do Cerrado, esta seria a que é mais afetada pelos períodos secos. Estima-se que mais de 50% dos indivíduos fiquem totalmente despidos de folhagem no período desfavorável. Essas florestas corresponderiam à Mata Seca Decídua, definida por Ribeiro e Walter (2008).

Floresta Estacional Semidecidual (Floresta Tropical Subcaducifólia): estas formações florestais do Cerrado são afetadas pelo período seco, mas não apresentam uma queda de folhas tão grande quanto a Floresta Estacional Decidual. A porcentagem

de árvores caducifólias está na faixa de 20% a 50%. Essas florestas correspondem à Mata Seca Semidecídua e a Mata Ciliar, definida por Ribeiro e Walter (2008).

Floresta Estacional Sempre-verde (Floresta Tropical Perenifólia): estas formações Florestais do Cerrado não são afetadas pela época seca. Conforme o próprio nome, esta formação não apresenta queda de folhas acentuada na estação seca. Correspondem à Mata Seca Sempre-verde no sistema de Ribeiro e Walter (2008).

Um ponto que merece destaque no sistema de classificação do IBGE refere-se às Matas de Galeria. Conforme mencionado na Seção 2.1.1., essas florestas seguem rios de pequeno porte e são matas permanentes, ou seja, não ocorre a queda significativa de folhas no período seco. Por essa característica, as Matas de Galeria poderiam ser classificadas como Floresta Estacional Sempre-verde no sistema IBGE. Entretanto, as classes de savana proposta por este sistema (exceto a Savana Florestada) apresentam subdivisões que podem conter ou não Matas de Galeria. Por exemplo, a formação de Savana Gramíneo-lenhosa que contém um extrato de Mata de Galeria pode ser classificada como Savana Gramíneo-lenhosa com Mata de Galeria. Caso não exista a presença da Mata de Galeria, a formação pode ser classificada como Savana Gramíneo-lenhosa sem Mata de Galeria. Para as demais classes teríamos Savana Parque com Mata de Galeria e Savana Arborizada com Mata de Galeria.

Seguindo este mesmo exemplo, a classe de Savana Gramíneo-lenhosa com Mata de Galeria acaba misturando duas formações muito diferentes do Cerrado (campos e florestas). Essa confusão foi alvo de estudo por Girolamo Neto *et al.* (2017a), onde os autores realizaram a segmentação e classificação de três regiões do Cerrado Brasileiro usando imagens de resolução espacial de 30m e com classes de vegetação correspondentes ao sistema de classificação proposto pelo IBGE. O processo de segmentação produziu regiões homogêneas nas áreas de Mata de Galeria. Entretanto, no sistema de classificação do IBGE, essas regiões foram rotuladas como Savana Gramíneo-lenhosa com Mata de Galeria. Desta maneira, os segmentos gerados nas imagens apresentaram valores muito diferentes em relação a alguns atributos utilizados para a classificação, como Índices de Vegetação por exemplo, mas eram pertencentes a mesma classe. Essa variação acarretou erros de classificação, prejudicando a identificação das fitofisionomias do Cerrado com o uso desta legenda.

Apesar da diferença entre os sistemas de classificação do Ribeiro e Walter (2008) e o do IBGE, há uma certa equivalência entre algumas classes. A

compatibilização de sistemas de classificação é uma tarefa difícil, pois nem sempre é possível relacionar as características fitofisionômicas das classes entre os dois sistemas. Entretanto, Valeriano (2017) propôs uma tabela de compatibilização (Tabela 2.4).

Tabela 2.4: Compatibilização dos sistemas IBGE (2012) e Ribeiro e Walter (2008) proposto por Valeriano (2017).

Ribeiro e Walter (2008)		IBGE (2012)	
Grande formação	Grupo / Subgrupos	Classes de Formação	Subformação
Campestre	Campo Limpo / Seco	Savana Gramíneo-lenhosa	Campo Limpo sem Mata de Galeria
	Campo Limpo / Úmido		Campo Limpo com Mata de Galeria
	Campo Limpo / Com Murundus		-
	Campo Sujo / Seco	Savana Parque	Campo Sujo
	Campo Sujo / Úmido		Campo Sujo com Mata de Galeria
	Campo Sujo / Com Murundu		Campo de Murundus
	Campo Rupestre	-	-
Savânica	Cerrado SS* / Cerrado Ralo	Savana Arborizada	Cerrado Ralo
	Cerrado SS* / Cerrado Típico		Cerrado Típico
	Cerrado SS* / Cerrado Denso		Cerrado Denso
	Cerrado SS / Cerrado Rupestre	Savana Parque	Campo Rupestre
	Parque de Cerrado		-
Palmeiral Vereda	Vegetação com influência fluvial e/ou lacustre	Herbácea com palmeiras	
Florestal	Cerradão	Savana Florestada	Cerradão
	Mata de Galeria / Inundável	Floresta Estacional	Sempre-verde Inundável
	Mata de Galeria / Não Inundável		Sempre-verde Aluvial
	Mata Ciliar		Semidecidual Aluvial
	Mata Seca Sempre-verde		Sempre-verde
	Mata Seca Semidecídua		Semidecidual Aluvial
	Mata Seca Decídua		Decidual

*Cerrado SS: Cerrado *Stricto Sensu*

Fonte: Adaptado de Valeriano (2017).

3. REVISÃO BIBLIOGRÁFICA

Este capítulo apresenta uma revisão de artigos científicos e projetos que apresentam resultados sobre o mapeamento das fitofisionomias do Cerrado Brasileiro. A revisão será dividida em função da resolução espacial das imagens usadas no mapeamento. Neste trabalho, imagens de baixa resolução espacial são aquelas que apresentam 50m ou mais de resolução espacial, imagens de média resolução possuem resolução espacial entre 10 e 50 m, imagens de alta resolução espacial são aquelas que têm resolução espacial de 10 m ou menos (EHLERS *et al.*, 2002).

3.1. Imagens de baixa resolução espacial

Ferreira *et al.* (2005) avaliaram atributos como o Índice de Área Foliar (IAF) e a Fração Fotossinteticamente Ativa da Vegetação (FFAV) para discriminar as fitofisionomias do Cerrado no estado de Goiás. Os autores avaliaram os atributos em relação a cada tipo de fitofisionomia usando uma série de um ano de imagens MODIS (16 em 16 dias) na resolução espacial de 1 km. Foram avaliadas as classes de vegetação Florestal, Áreas agrícolas, Pastagens cultivadas, Campo Limpo/Sujo, Campo Cerrado e Cerradão. As regiões Florestais foram identificadas com boa precisão, separando-as das demais classes. De maneira geral, o atributo FFAV teve melhor potencial na discriminação de Campo Cerrado e Cerradão do que o IAF.

Liesenberg *et al.* (2007a) avaliaram o uso de Índices de Vegetação e imagens de uma série de um ano de imagens MODIS (16 em 16 dias) de uma região no noroeste de Minas Gerais e sudoeste da Bahia. As seguintes coberturas foram discriminadas: Floresta Estacional Decidual, Floresta Estacional Semidecidual, Floresta Pluvial, Savana Arborizada e Savana Parque. Os Índices de Vegetação NDVI e o EVI (*Enhanced Vegetation Index*) foram usados na classificação baseada na distância euclidiana. Foram observados, para a Floresta Estacional Decidual, baixos valores de Índices de Vegetação na época seca e altos valores dos índices na estação úmida. Costa *et al.* (2015) também utilizaram uma série temporal de imagens MODIS (250 m) para mapear regiões Campestres. Dados de EVI foram extraídos para 23 instantes diferentes ao longo do ano. Além do índice de vegetação, diversas variáveis foram extraídas a partir da série temporal: valor mínimo, valor máximo, amplitude, soma, moda, média e

desvio padrão. As classes de interesse foram Campestre, Pastagem cultivada e outros usos e a melhor taxa de acerto obtida foi de 85,96%.

Borges e Sano (2014) utilizaram uma série de 276 imagens MODIS (250 m) referentes ao período de 2000 a 2011. As classes consideradas foram: Campo Sujo, Cerrado Ralo, Cerrado Típico, Cerrado Denso, Floresta Estacional Semidecidual, Floresta Estacional Decidual, Vegetação secundária e Culturas agrícolas. O algoritmo SAM (*Spectral Angle Mapper*) foi usado na classificação, com amostras de treinamento obtidas em campo em 2012. A taxa de acerto global foi de 84%. A classificação das classes Florestais tiveram acerto de 100%, mas essa taxa de acerto não se manteve para as classes de Cerrado Ralo, Cerrado Típico e Cerrado Denso. A classe de Campo Sujo teve apenas uma amostra para avaliação e o Cerrado Ralo obteve 40% de taxa de acerto, que se confundiu como Cerrado Típico. Os demais erros foram devido à confusão como Pastagens cultivadas e Culturas agrícolas.

3.2. Imagens de média resolução espacial

Sano *et al.* (2008) realizaram o mapeamento visual de todo o Cerrado com imagens ETM+ (*Enhanced Thematic Mapper Plus* a bordo do satélite Landsat-7), no projeto conhecido como Projeto de Conservação e Utilização Sustentável da Diversidade Biológica Brasileira (Probio). As imagens ETM+ foram adquiridas na estação seca em 2002. No processo de interpretação das imagens, dados auxiliares do censo agrícola e de topografia foram utilizados. O mapeamento contou com o trabalho de 30 intérpretes e durou cerca de três anos. Os autores utilizaram na classificação o sistema proposto pelo Manual Técnico da Vegetação Brasileira (IBGE, 2012). A taxa de acerto global do mapeamento foi de 74,19%. Entretanto, erros de classificação nas classes de savana foram observados. As classes Savana Gramíneo-lenhosa e Savana Arborizada tiveram uma taxa de acerto de 25% e 35%, respectivamente. A classe Savana Arborizada se confundiu com todas as outras classes de savana. A classe de Savana Parque teve uma taxa de acerto melhor, em torno de 68%, que se confundiu com as classes Savana Gramíneo-lenhosa e Savana Arborizada. A melhor taxa de acerto foi obtida pela classe de Savana Arborizada, com 86%.

O projeto TerraClass Cerrado (MMA, 2015) realizou o mapeamento, também por interpretação visual, de todo bioma Cerrado usando 121 imagens do sensor OLI

(*Operational Land Imager* a bordo do satélite Landsat-8) para o período seco de 2013 (maio e outubro). Foram consideradas as seguintes classes: Florestais e Não Florestais (formações Campestres e Savânicas agrupadas), Agricultura Anual e Perene, Pastagens Plantadas, Silvicultura, Áreas Urbanas e outras. A taxa de acerto global do mapeamento foi em torno de 80%. Com relação as classes de vegetação natural a taxa de acerto caiu para 60%.

Grecchi *et al.* (2013) usaram uma imagem do sensor TM (*Thematic Mapper* a bordo do satélite Landsat-5) para classificar as formações naturais do Cerrado (Mata de Galeria, Campestre e Savânica agrupadas em um grupo de vegetação natural), Pastagens cultivadas, Áreas urbanas, Áreas agrícolas e Corpos d'água na região de Primavera do Leste, Mato Grosso. Na classificação foram usados as médias das bandas 2, 4 e 7 e o índice de vegetação CEI (*Crop Enhancement Index*). A taxa de acerto global foi de 86%.

Muller *et al.* (2015) utilizou o algoritmo de *Random Forest* para classificar áreas de Cerrado no estado do Mato Grosso. Para caracterizar a cobertura vegetal, uma série temporal imagens TM e ETM+ no período de três anos (2009 até 2012) foi utilizada. Seis classes foram consideradas na classificação: Savana, Floresta, Áreas agrícolas, Pastagem cultivada, Corpos d'água e Áreas não vegetadas. A classe de Savana foi definida como a composição de Cerrado *Stricto Sensu* e Cerradão. Como atributos de classificação foram utilizados a média, mediana, desvio padrão, quartil de 75%, amplitude interquartil das bandas 1 a 5 e 7 e o índice SWIR (Reflectância das bandas do SWIR - *Short Wave Infrared*) dividido pela Reflectância da banda do NIR (*Near Infrared*). Este índice é apontado pelos autores para identificação de Pastagem e Áreas agrícolas. A classificação teve uma taxa de acerto média de 93%, e a taxa de acerto classe de savana também foi de 93%.

Costa *et al.* (2014) mapearam as formações Campestres na região da Serra da Canastra, Minas Gerais a partir de imagens TM e MODIS. A classificação baseada no SVM e Árvores de Decisão usou atributos de topografia, de Reflectância (média, amplitude e Entropia) das bandas 1 a 5 e 7 e o índice de vegetação EVI2 (*Enhanced Vegetation Index 2*) extraído do sensor MODIS. A verdade de campo foi obtida no inventário florestal realizado pela Universidade Federal de Lavras (UFLA), para o ano de 2009. Inicialmente, os autores trabalharam apenas com dados de topografia e o algoritmo de Árvores de Decisão, com 4 classes (Campo Limpo/Sujo, Campo Rupestre,

Pasto cultivado e outros) e obtiveram uma baixa taxa de acerto em torno de 60%. A grande confusão entre as classes de Campo Limpo/Sujo e Campo Rupestre levou a fusão destas classes na classe de formações Campestres. A melhor taxa de acerto obtida na classificação foi de 82,12%.

Oliveira *et al.* (2007a) realizaram mapeamento automático de uma região do Cerrado no Parque Nacional de Sete Cidades, Piauí. Eles usaram uma imagem TM da época seca para mapear 6 fitofisionomias do Cerrado: Mata de Galeria Inundável, Mata Seca, Cerradão, Cerrado Típico, Cerrado Rupestre e Campo Limpo. A classificação baseada na distância de Bhattacharya atingiu a taxa de acerto global de 65,7%, sendo que a classe com melhor taxa de acerto foi a Mata de Galeria Inundável, com 80% de acerto. A principal dificuldade observada foi a diferenciação de áreas de transição entre duas fitofisionomias e também a confusão entre Mata Seca e Cerradão. As classes de Campo Limpo e Cerrado Rupestre apresentaram erros similares aos obtidos por Costa *et al.* (2014).

Ferreira *et al.* (2007) avaliaram os atributos do MLME a classificação de fitofisionomias do Cerrado. Usando imagens ETM+ e a classificação por mínima distância de Mahalanobis, 5 classes de fitofisionomias do Cerrado foram utilizadas: Campo Limpo, Campo Sujo, Cerrado Ralo, Cerrado Típico e Mata de Galeria. A taxa de acerto global foi de 89%, sendo que a Mata de Galeria foi classificada com 99% de taxa de acerto. Entretanto, os autores observaram grande confusão entre as classes de Campo Sujo e Cerrado Ralo. Também houve confusão entre Campo Sujo e Campo Limpo e Cerrado Típico com Cerrado Ralo.

Schwieder *et al.* (2016) avaliaram o uso da transformação *Tasseled Cap* (KAUTH; TOMAS, 1976) extraída da série temporal de imagens TM e ETM+ na classificação baseada no método SVM para 6 fitofisionomias de Cerrado: Campo Limpo, Campo Sujo, Campo Cerrado, Cerrado *Stricto Sensu*, Cerrado Denso e Cerradão. As componentes de *Greenness*, *Brightness* e *Wetness* da Transformada *Tasseled Cap* foram extraídas da série de imagens. Os resultados indicaram uma taxa de acerto superior a 60% para as fitofisionomias de Campo Sujo, Campo Cerrado, Cerrado *Stricto Sensu* e Cerrado Denso. As Matas de Galeria foram as regiões com maior taxa de acerto, 86%. Foi observado confusão entre Campo Limpo e Campo Sujo e Campo Sujo com Campo Cerrado.

Carvalho *et al.* (2010) utilizaram imagens do ALOS/PALSAR (*Advanced Land Observing Satellite / Phased Array type L-band Synthetic Aperture Radar*) e do Landsat-5 para classificar 6 classes de cobertura: Solo exposto, Campo Cerrado, Campo Cerrado degradado, Cerradão, Cerradão degradado e Áreas alagadas, no município de Cônego Marinho, Minas Gerais. A partir da imagem TM, os atributos NDVI, componentes de sombra, solo e vegetação do MLME e componentes de *Brightness*, *Greenness* e *Wetness* da Transformada *Tasseled Cap* foram extraídos. Atributos de geometria (comprimento, largura, área, assimetria, razão comprimento/largura, índice de compacidade) e atributos de textura (Entropia, Contraste, Dissimilaridade, Correlação e Homogeneidade) também foram usados. A classificação foi baseada em Árvores de Decisão, e algumas combinações dos atributos foram usadas. A combinação de *Shape*+PALSAR apresentou a pior taxa de acerto na classificação, inferior a 40%. Já a combinação de *Shape*+PALSAR+TM apresentou a melhor taxa de acerto na classificação - 59,56%. As classes de Cerradão e Campo Cerrado obtiveram taxas de acerto de 49,25% e 43,63%, respectivamente.

Oliveira *et al.* (2005a,b e 2007b) utilizaram imagens fusionadas do sensor ETM+ com 15 m de resolução espacial para mapear as classes de Campo, Savana, Floresta, Pastagem cultivada, Culturas agrícolas, Solo exposto, Eucalipto plantado, Água e Sombra nas cidades de Paraopeba e Caetanópolis, região centro-norte de Minas Gerais. Os atributos utilizados foram: Índices de Vegetação, MLME, Transformada *Tasseled Cap* e um modelo digital de elevação. Em Oliveira *et al.* (2005a), os autores obtiveram uma melhor taxa de acerto usando Árvores de Decisão para a imagem fusionada (15m) do que para a imagem original do sensor ETM+. Oliveira *et al.* (2005b) melhoraram a taxa de acerto utilizando uma imagem do período seco e uma imagem do período úmido (ambas com 15m de resolução espacial). Oliveira *et al.* (2007b) usaram classificação por Árvores de Decisão e Redes Neurais Fuzzy e obtiveram taxas de acerto em torno de 97% na classificação.

França e Sano (2011) avaliaram a separabilidade de áreas de Campo Limpo Úmido de Campo Limpo na região do Distrito Federal. Os autores usaram imagens fusionadas dos sensores TM e HRC (*High Resolution Camera* a bordo do satélite CBERS-2B, com 2,7 m de resolução espacial) com resolução espacial de 10 m. A classificação foi baseada no método ISOSEG e a taxa de acerto obtida foi de 51,5%.

3.3. Imagens de alta resolução espacial

Teixeira *et al.* (2015) realizaram o mapeamento semi-automático da vegetação do Cerrado para uma região no município de Cuiabá, Mato Grosso. A legenda de classificação foi baseada no Manual Técnico da Vegetação Brasileira, que inclui as 5 classes de vegetação: Floresta Estacional Semidecidual, Floresta Estacional Decidual, Campo Cerrado e Cerrado *Stricto Sensu* e Áreas antrópicas. Os autores utilizaram imagens pancromáticas do sensor HRG (*High Resolution Geometric*) do satélite SPOT-5, com 5 m de resolução espacial para os anos de 2008 e 2009. Os autores avaliaram parâmetros de forma e brilho (nível de cinza) de cada classe e a classificação semi-automática foi realizada pelo algoritmo *Assign Class*. A taxa de acerto final foi de 94%. A classe Floresta Estacional Decidual Apresentou confusão com a classe de Campo Cerrado.

Silva e Sano (2016) utilizaram os atributos de Reflectância máxima e mínima para mapear formações Campestres, Savânicas e Florestais, além de culturas agrícolas e pastagens cultivadas nas regiões da Bahia, Tocantins e Goiás. Os autores usaram imagens do satélite *RapidEye* (5 m). Inicialmente, os autores conseguiram distinguir as formações Savânicas e Florestais das demais classes. Uma confusão foi observada na classificação das formações Campestres e Pastagens cultivadas, mas a taxa de acerto da classificação foi superior a 80%.

Imagens *RapidEye* também foram utilizadas por Orozco Filho (2017) e Girolamo Neto *et al.* (2017b) para o mapeamento de fitofisionomias de Cerrado. Entretanto os autores utilizaram legendas mais detalhadas do que o trabalho de Silva e Sano (2016). Orozco Filho (2017) avaliaram uma imagem *RapidEye* para a área de proteção ambiental da Serra Geral do Tocantins. Um classificador baseado em Árvores de Decisão foi usado para identificar 6 Classes: Áreas Queimadas, Campo com Solo Exposto, Campo Limpo Úmido com Veredas, Campo Limpo/Sujo, Cerrado *Stricto Sensu* e Floresta (Composição de Matas de Galeria mais Cerradão). Na classificação foram usados atributos de Reflectância espectral e Índices de Vegetação, com uma taxa de acerto global do classificador de 81%. A classe Campo Limpo Úmido com Veredas obteve a pior taxa de acerto, em torno de 62%. Essa classe se confundiu com todas as outras classes, exceto com as Áreas queimadas. A discriminação entre as classes Floresta e Cerrado *Stricto Sensu* também apresentou confusão. A melhor taxa de acerto foi na identificação do Campo Limpo/Sujo, com 89% de acerto.

Finalmente, Girolamo Neto *et al.* (2017b) usaram uma imagem RapidEye para mapear 5 classes de vegetação (Campo Limpo, Campo Sujo, Cerrado Ralo, Cerrado Típico e Matas de Galeria), usando o algoritmo *Random Forest* em uma região do Parque Nacional de Brasília (DF). Os autores utilizaram atributos de Reflectância, Índices de Vegetação, MLME e textura. A textura foi extraída a partir das bandas espectrais, dos Índices de Vegetação e das componentes MLME. Os atributos de textura mostraram potencial na discriminação das 5 classes. As Matas de Galeria obtiveram taxa de acerto de 95,8%. A maioria dos erros esteve associada à transição de regiões de campo para regiões de savana, que seria a transição de Campo Sujo para Cerrado Ralo. A taxa de acerto das classes Campo Sujo e Campo Limpo foram as mais baixas, em torno de 56,7% e 64,9%, respectivamente.

Pinheiro e Durigan (2009) realizaram o mapeamento do uso e cobertura do solo para uma estação ecológica do Cerrado na região de Assis, São Paulo. Este procedimento foi realizado para quatro datas diferentes: 1962, 1984, 1994 e 2006. Para as três primeiras datas, imagens de um sensor transportado com resolução espacial variando de 5 a 7 m foram utilizadas. Para 2006, uma imagem do satélite *QuickBird* fusionada (resolução espacial de 0,73 m) foi utilizada. As classes Mata Ciliar, Campo Limpo Úmido, Cerrado Ralo, Cerrado Típico, Cerrado Denso e Cerradão foram mapeadas por interpretação visual. A resolução espacial do satélite QuickBird permitiu discriminar todas as fitofisionomias utilizadas pelos autores.

As imagens de alta resolução espacial permitiram a identificação de algumas fitofisionomias normalmente não utilizadas nos trabalhos com imagens de média resolução espacial, como as classes de Campo Limpo Úmido, Cerrado Ralo, Cerrado Denso e Veredas. Entretanto, foi observado que a identificação da transição entre regiões de formações Campestres e Savânicas é difícil usando imagens de média resolução. A Tabela 3.1 apresenta uma descrição resumida dos trabalhos revisados, considerando aspectos importantes para o mapeamento das fitofisionomias do Cerrado: região mapeada, tipo de imagem, método de classificação, principais pontos observados nos resultados.

Tabela 3.1: Revisão dos artigos sobre mapeamento do Cerrado Brasileiro em função da resolução espacial e sistema de classificação utilizado.

Referência	Imagens e Local	Resolução Espacial	Sistema de Classificação	Metodologia	Validação	Fitofisionomias classificadas	Número de classes	Taxa de acerto	Dificuldades	Qualidades
Imagens de baixa resolução (≥ 250m)										
Ferreira <i>et al.</i> (2005)	Série MODIS, Estado de GO. Série com época seca + úmida.	1 km	Ribeiro e Walter (2008)*	Agrupamento por média, atributos IAF e FFAV.	Mapa de referência	Florestais, áreas agrícolas, pastagens cultivadas, Campo Limpo/sujo, Campo Cerrado e Cerradão.	6	-	IAF mostrou baixo potencial para discriminar classes savânicas. Alta similaridade dos índices para Campo Limpo/sujo	Atributo FFAV mais eficiente que o IAF para separar as fitofisionomias.
Liesenber <i>et al.</i> (2007a)	Série MODIS, Estados de MG e BA. Série com época seca + úmida.	250 m	Manual Técnico da Vegetação Brasileira (IBGE, 2012)	Avaliação de EVI e NDVI.	Amostras em mapa de referência do IBGE e dados de Campo.	Floresta Estacional Semidecidual, Floresta Estacional Decidual, Savana Arborizada, Savana Parque e Floresta Pluvial	6	-	Séries Landsat podem não identificar mudanças sutis no “verdeamento” da vegetação.	NDVI foi mais eficiente do que o EVI para discriminar as fisionomias. Discriminação das vegetações florestais das savânicas usando IVs.
Costa <i>et al.</i> (2015)	Série MODIS, Estado de MG. Série com época seca + úmida.	250 m	Campos nativos e cultivados.	Classificação automática – Árvores de Decisão, SVM e <i>Random Forest</i> . EVI e dados de série temporal.	Dados de referência obtidos com o inventário florestal de minas gerais e MMA.	Campestres, pastagens cultivadas e outros.	3	85,9%	Baixa taxa de acerto utilizando somente atributos da série temporal. Confusão entre formações campestres.	Uso combinado dos atributos da série temporal, juntamente com o índice de vegetação melhorou a taxa de acerto.
Borges e Sano (2014)	MODIS, Estado da BA. Série com época seca + úmida.	250 m	Ribeiro e Walter (2008) e Manual Técnico da Vegetação Brasileira (IBGE, 2012)	Classificação semi-automática Pixel a pixel, algoritmo SAM, Séries EVI.	Amostras classificadas visualmente a partir de uma imagem RapidEye.	Campo Sujo, Cerrado Ralo, Cerrado Típico, Cerrado Denso, Floresta Estacional, Vegetação secundária e Culturas agrícolas	7	84,0%	Erros relacionado ao tamanho do pixel do MODIS. Erros nas classes de Campo Sujo e Cerrado Ralo. Confusão entre Cerrado Típico e denso.	Séries temporais auxiliam na discriminação das fitofisionomias. Alta taxa de acerto na classificação das fitofisionomias florestais.

Tabela 3.1 – Continuação

Referência	Imagens e Local	Resolução Espacial	Sistema de Classificação	Metodologia	Validação	Fitofisionomias classificadas	Número de classes	Taxa de acerto	Dificuldades	Qualidades
Imagens de média resolução (Entre 10m e 50m)										
Sano <i>et al.</i> (2008) – Probio	Landsat-7 para todo o Cerrado na época seca ano de 2002.	30 m	Manual Técnico da Vegetação Brasileira (IBGE, 2012)	Visual – auxílio de dados do censo agrícola e de topografia.	Coleta de Pontos em trabalho de campo.	Savana Florestada, Savana Arborizada, Savana Parque e Savana Gramíneo-Lenhosa. Formações antrópicas, florestas Estacional e Ombrófila.	10	74,2%	Tempo de interpretação alto – 3 anos. Confusão entre Savana Arborizada e Florestada com Floresta Estacional. Mudanças de fitofisionomias na data da validação.	Avaliação da geometria para diferenciar campo natural de cultivado. Mapeamento de todo o bioma do Cerrado.
MMA (2015) – TerraClass Cerrado	Landsat-8 para todo o Cerrado na época seca ano de 2013.	30 m	Grandes formações de Ribeiro e Walter (2008)	Interpretação visual com segmentação a priori.	Validação de pontos pós classificação por especialistas.	Florestal, Savânica, Campestre, Agricultura, Urbano, Mineração, Mosaico de ocupação, Pastagem, Silvicultura, Solo Exposto e Água.	11	80,0%	Para as classes de formações naturais do Cerrado a taxa de acerto foi em torno de 60%.	Os autores agregaram as classe de Savana e Campestre em uma única classe chamada de formações não florestais. Mapeamento de todo o bioma do Cerrado.
Grecchi <i>et al.</i> (2013)	Landsat-5, Estado do MT. Época seca.	30 m	Grandes formações de Ribeiro e Walter (2008)	Segmentação e Classificação automática por vizinhos mais próximos.	Observação de pontos em campo.	Formações naturais, pastagens cultivadas, áreas urbanas, áreas agrícolas e corpos d'água	5	86,0%	Diferenciação de áreas agrícolas de pastagens cultivadas. Junção das formações de Cerrado em apenas uma classe.	Índice CEI apontado como essencial para diferenciar culturas agrícolas.
Muller <i>et al.</i> (2015)	Landsat-5 e Landsat-7, Estado do MT. Série com época seca + úmida.	30 m	Grandes formações de Ribeiro e Walter (2008)	Classificação por <i>Random Forest</i> . Dados de Reflectância e índice SWIR.	Campo e imagens (Quickbird – 2,8m e GeoEye 1, 7m)	Savânica, Florestal, áreas agrícolas, pastagem cultivada, corpos d'água e áreas não vegetadas.	5	93,0%	Superestimativa das classes de pastagem. Alguns erros entre savana e floresta.	Alta taxa de acerto para a classe de savana (93%). Calibração de parâmetros internos do classificador melhora a taxa de acerto.
Girolamo Neto <i>et al.</i> (2017a)	Imagens Landsat-8 época seca e úmida. Estados de GO, MA, DF.	30 m	Manual Técnico da Vegetação Brasileira (IBGE, 2012).	Segmentação, Classificação automática por <i>Random Forest</i> .	Validação visual e pelo mapa do RADAM BRASIL.	Savana Florestada, Savana Arborizada, Savana Parque e Savana Gramíneo-Lenhosa.	4	84,4%	Matas de Galeria classificadas como Savana Gramíneo-lenhosa devido a legenda. Erros entre transição de regiões.	Classes obtiveram taxa de acerto superior a 80%. Sugere o uso de imagens de alta resolução para uma melhor análise

Tabela 3.1 – Continuação

Referência	Imagens e Local	Resolução Espacial	Sistema de Classificação	Metodologia	Validação	Fitofisionomias classificadas	Número de classes	Taxa de acerto	Dificuldades	Qualidades
Costa <i>et al.</i> (2014)	Landsat-5, Estado de MG. Série de imagens com época seca + úmida.	30 m	Ribeiro e Walter (2008) – apenas campestres	Classificação automática por Árvores de Decisão e SVM. Dados de Reflectância, EVI2 e Topografia.	Dados de referencia obtidos com o inventário florestal de Minas Gerais.	Campo Limpo/sujo, Campo Rupestre, Pasto cultivado e outros.	3	82,1%	Confusão Campo Limpo/sujo com Campo Rupestre. Necessidade de juntá-los em uma classe para melhor taxa de acerto.	Uso combinado dos de Reflectância, índice de vegetação e Topografia gerou o modelo com melhorou a taxa de acerto.
Oliveira <i>et al.</i> (2007a)	Landsat-5 – Distrito Federal. Época seca.	30 m	Ribeiro e Walter (2008)*	Segmentação e classificação Automática - distância de Bhattacharya.	Pontos coletados em trabalho de campo.	Mata de Galeria Inundável, Mata Ciliar, Cerradão, Cerrado Típico, Cerrado Rupestre e Campo Limpo.	6	65,7%	Diferenciação entre fitofisionomias de transição, principalmente Campo Limpo e Cerrado Rupestre	Mapeamento de Matas de galeria com taxa de acerto de 80% e Mata Ciliar com 73%
Ferreira <i>et al.</i> (2007)	Landsat-7, Distrito Federal. Época seca	30 m	Ribeiro e Walter (2008)	Classificação automática pixel a pixel por distância de Mahalanobis e atributos do MLME.	Amostras em mapa de referencia produzido com imagens IKONOS (3,2m).	Campo Limpo, Campo Sujo, Cerrado Ralo, Cerrado Típico, Mata de Galeria e Água.	6	89,0%	Alta confusão entre Campo Sujo e Cerrado Ralo pelo MLME. Também houve confusão entre Campo Limpo e Sujo e Cerrado Típico com Ralo.	MLME (sem a classe de Mata de Galeria) reduziu a confusão de Campo Sujo com Cerrado Ralo.
Schwieder <i>et al.</i> (2016)	Landsat 5 e 7, Distrito Federal. Série com época seca + úmida	30 m	Ribeiro e Walter (2008)	Classificação automática pixel a pixel por SVM com Transformada TC.	Mapa de referência criado por Ferreira <i>et al.</i> (2007)	Campo Limpo, Campo Sujo, Campo Cerrado, Cerrado <i>Stricto Sensu</i> , Cerrado Denso, Cerradão e Mata de Galeria.	7	63%	Erros em classes adjacentes dado o gradiente de vegetação proposto por Ribeiro e Walter (2008).	O uso da Transformada TC aumenta a discriminação das classes estudadas.
Carvalho <i>et al.</i> (2010)	Landsat-5 e PALSAR, Estado de MG. Época seca.	30 m	Ribeiro e Walter (2008)* e classes de degradação	Segmentação, Classificação com Árvores de Decisão e NDVI, MLME, de Reflectância.	Imagens de alta resolução IKONOS (3,2m)	Solo exposto, Campo Cerrado, Campestres degradadas, Cerradão, Cerradão degradado e áreas alagadas.	6	59,6%	Fitofisionomias de transição. Confusão entre Campo Cerrado e Cerradão. Dificuldade em limitar as regiões entre classes.	Uso combinado do NDVI com atributos texturais e de Reflectância obtiveram resultados superiores.

Tabela 3.1 – Continuação

Referência	Imagens e Local	Resolução Espacial	Sistema de Classificação	Metodologia	Validação	Fitofisionomias classificadas	Número de classes	Taxa de acerto	Dificuldades	Qualidades
Oliveira <i>et al.</i> (2005a)	Landsat-7 fusionada, Estado de MG. Época seca.	15 m	Grandes formações de Ribeiro e Walter (2008)	Classificação baseada em Árvores de Decisão, dados de Reflectância NDVI, MLME e Topografia.	Coleta de dados em campo com GPS para classificar e validar.	Savânicas, Campestres, Florestais, pastagem cultivada, culturas agrícolas, solo exposto, eucalipto plantado água e sombra.	8	95,4%	Dificuldade na discriminação de florestal e savânica com culturas de eucalipto e entre si.	Alto taxa de acerto para mapear formações campestres (98%).
Oliveira <i>et al.</i> (2005b)	Landsat-7 fusionada, Estado de MG. Série com época seca + úmida.	15 m	Grandes formações de Ribeiro e Walter (2008)	Classificação baseada em Árvores de Decisão e MAXVER, atributos de Reflectância, NDVI, MLME e Topografia.	Coleta de dados em campo com GPS para classificar e validar.	Savânicas, Campestres, Florestais, pastagem cultivada, culturas agrícolas, solo exposto, eucalipto plantado água e sombra.	9	97,3%	Dificuldades na discriminação entre florestal e savânica com culturas de eucalipto e entre si.	O uso de imagens da época seca e úmida em mostraram melhor resultado do que usadas separadamente.
Oliveira <i>et al.</i> (2007b)	Landsat-7 fusionada, Estado de MG. Série com época seca + úmida.	15 m	Grandes formações de Ribeiro e Walter (2008)	Classificação: Árvores de Decisão, Redes Neurais e <i>fuzzy</i> . Reflectância, NDVI, MLME e Topografia.	Coleta de dados em campo com GPS para classificar e validar.	Savânicas, Campestres, Florestais, pastagem cultivada, culturas agrícolas, solo exposto, eucalipto plantado água e sombra.	9	97,0%	Diferenciação entre fitofisionomias de transição entre as classes Florestais e Campestre.	Técnicas <i>fuzzy</i> apresentaram melhores resultados do que as demais.
França e Sano (2011)	Landsat e Cbers-2b fusionadas, Distrito Federal. Época seca.	10 m	Ribeiro e Walter (2008) – apenas campestres	Segmentação e classificação baseada no algoritmo ISOSEG.	Pontos coletados em campo.	Campo Limpo e Campo Limpo Úmido	2	51,5%	Baixa taxa de acerto global e dificuldade em discriminar as classes de Campo Limpo e Campo Limpo Úmido.	Criação de buffers nos rios para determinar possíveis regiões de Campo Limpo Úmido

Tabela 3.1 – Conclusão

Referência	Imagens e Local	Resolução Espacial	Sistema de Classificação	Metodologia	Validação	Fitofisionomias classificadas	Número de classes	Taxa de acerto	Dificuldades	Qualidades
Imagens de alta resolução ($\leq 10m$)										
Teixeira <i>et al.</i> (2015)	SPOT-5, Estado do MT. Época Seca.	5 m	Ribeiro e Walter (2008)* e IBGE (IBGE, 2012)	Segmentos de maneira semi-automática, atributos de Reflectância e forma.	Avaliação visual da referencia obtida em campo.	Floresta Estacional Semidecidual, Decidual, Campo Cerrado e Cerrado <i>Stricto Sensu</i> e áreas antrópicas	5	94,0%	Dificuldade de selecionar polígonos puros para a classe de Mata Seca (transição de classes)	Alta taxa de acerto para a classe Savânica (97%).
Silva e Sano (2016)	Rapideye, Estados de GO, TO, BA. Época Seca	5 m	Grandes formações de Ribeiro e Walter (2008)	Segmentação semi-automática, atributos de Reflectância.	Interpretação visual da imagem de alta resolução.	Campestre, Savânica e Florestal, além de culturas agrícolas e pastagens cultivadas	5	80,0%	Erros na discriminação entre classes campestres e pastagens cultivadas.	Formações Savânicas com taxa de acerto de 76% e Florestais com 83%.
Orozco Filho (2017)	Rapideye, Estado do TO. Estação Seca.	5 m	Ribeiro e Walter (2008)	Segmentação e classificação automática com Árvores de Decisão. Reflectância mais IVs.	Interpretação visual da imagem de alta resolução.	Áreas Queimadas, Campo com Solo Exposto, Campo Limpo Úmido com Veredas, Campo Limpo/Sujo, Cerrado <i>Stricto Sensu</i> e Floresta	7	81,0%	Dificuldade na classificação de Campo Limpo úmido com Veredas.	Classe de Campo Limpo/sujo com a melhor taxa de acerto.
Girolamo Neto <i>et al.</i> (2017b)	Rapideye, Distrito Federal. Estação Seca.	5 m	Ribeiro e Walter (2008)	Segmentação e classificação automática com <i>Random Forest</i> . Reflectância, MLME, IVs e textura.	Interpretação visual de imagens de alta resolução.	Campo Limpo, Campo Sujo, Cerrado Ralo, Cerrado Típico e Mata de Galeria.	5	74,3%	Transição entre campo e savana apresentou muitos erros de classificação (Campo Sujo e Cerrado Ralo foram as piores taxas de acerto).	Atributo textura melhorou a taxa de acerto. Usou textura extraídas das bandas de Reflectância, componentes MLME e IVs.
Pinheiro e Durigan (2009)	QuickBird fusionado e imagens aerotransportadas – Estado de SP. Época Seca.	0,73 m	Ribeiro e Walter (2008)	Visual.	-	Mata Ciliar, Cerradão, Cerrado Denso, Cerrado Típico, Cerrado Ralo e Campo Limpo úmido.	6	-	Interpretação das imagens aéreas antigas – necessário entrevistas com moradores.	Facilidade de interpretação com a imagem QuickBird. Imagens de alta resolução permitem observar a sucessão de fitofisionomias

Fonte: Produção do Autor

4. MINERAÇÃO DE DADOS

Este capítulo apresenta um resumo sobre as técnicas de mineração de dados que serão utilizadas na classificação das imagens WorldView-2 e OLI (Landsat-8) realizadas neste trabalho. A mineração de dados (*data mining*) é uma das etapas do processo de descoberta de conhecimento em bases de dados (KDD - *Knowledge Discovery in Databases*), que envolve a extração de padrões potencialmente úteis e compreensíveis em grandes volumes de dados e seleção de atributos por meio da aplicação de algoritmos (FAYYAD *et al.*, 1996).

No sensoriamento remoto, a mineração de dados lida com o desafio de capturar padrões no espaço geográfico, extraindo conhecimento específico para entender ou decidir sobre tópicos relevantes, incluindo mudança de terra, variações climáticas e estudos de biodiversidade (KÖRTING, 2012). Em um conjunto de dados, diversos atributos estão relacionados com cada registro ou instância. Por exemplo, em uma imagem digital, cada pixel pode ser um registro ou instância e os valores de Reflectância de cada banda espectral podem ser os atributos dos pixels (NEVES, 2017).

Na prática, os dois objetivos principais da mineração de dados são a predição e a descrição. A predição envolve o uso de variáveis com valores conhecidos para prever um valor desconhecido ou futuro de outra variável (atributo meta). A descrição caracteriza propriedades gerais encontradas nos dados, com foco em padrões interpretáveis pelo ser humano. Esses objetivos podem ser alcançados por meio de vários tipos de tarefas específicas, sendo que a escolha de uma ou mais destas depende do problema em questão (FAYYAD *et al.*, 1996; HAN *et al.*, 2011).

As tarefas preditivas têm como objetivo a construção de classificadores, a partir de um conjunto de dados inicial, para posterior predição do comportamento de dados subsequentes. Uma das tarefas de predição é a classificação, a qual consiste em prever um valor categórico ou discreto do atributo meta, e busca a construção de classificadores a partir de um conjunto de exemplos pré-classificados corretamente, para posterior classificação de exemplos novos e desconhecidos (REZENDE, 2002).

Outra etapa importante da mineração de dados é a seleção de atributos, a qual refere-se ao processo de reduzir a quantidade de atributos para análise, trabalhando apenas com os atributos mais importantes e melhorando a taxa de acerto na classificação (GUYON; ELISSEEFF, 2003).

4.1. Seleção de atributos

Antes da classificação, podem ser aplicados métodos de seleção de atributos, ou seja, uma forma de refinamento do conjunto de treinamento pela escolha dos atributos mais importantes. O uso de métodos de seleção de atributos tem duas finalidades. Primeiramente, faz o treinamento e a aplicação de um classificador mais eficiente, diminuindo a quantidade de atributos e tornando o processo de modelagem menos custoso computacionalmente. Em segundo lugar, pode aumentar a precisão de um classificador, eliminando atributos que podem confundir-lo. Os atributos removidos do conjunto de dados poderiam levar a uma generalização incorreta de uma característica acidental do conjunto de treinamento e, conseqüentemente, a erros de classificação (DASH; LIU, 1997; GUYON; ELISSEEFF, 2003).

Todavia, os métodos de seleção de atributos podem levar a perda de informações úteis em conjuntos de dados. Em alguns estudos de caso, especialmente com imagens de alta resolução, os métodos de seleção de atributos não apresentaram melhora na taxa de acerto dependendo do classificador em questão (SAEYS, *et al.* 2007; MA *et al.*, 2017; ANJOS *et al.*, 2018). Desta maneira, MA *et al.* (2017) sugerem que sejam avaliados resultados da classificação com e sem a aplicação de métodos de seleção de atributos.

Existem diversos métodos de seleção de atributos. Um destes métodos é o *Wrapper*, o qual leva em consideração o algoritmo de classificação que estará sendo utilizado. Eles são baseados na avaliação de diversos subconjuntos, calculando a taxa de acerto para cada um destes perante o algoritmo de classificação. Destes subconjuntos, o que obtém a maior taxa de acerto é o selecionado. *Wrappers* tendem a levar a maior precisão, mas precisam de esforço computacional elevado quando comparados com outros métodos (JOHN; KOHAVI, 1997).

Outro método de seleção de atributos é o CFS (do inglês, *Correlation Feature Selection*). Inicialmente, um conjunto aleatório é escolhido e classificado de acordo com uma medida de correlação com a classe, chamada de mérito. O mérito é calculado baseado na correlação de Pearson, mas com todas as variáveis padronizadas. Quanto maior o mérito, mais o conjunto estará relacionado com a classe. O algoritmo busca novos conjuntos com méritos superiores ao primeiro e após um número de testes predefinidos com subconjuntos de mérito inferior, o conjunto atual é selecionado (HALL, 1999).

Além destes, existem medidas chamadas de *Infogain* e *Gainratio*, as quais correspondem a expressões sobre o ganho de informação e a taxa de ganho de informação entre atributos e classe (WITTEN *et al.*, 2011). A medida de ganho de informação pode ser calculada a partir da entropia do conjunto de dados. A entropia pode ser definida analogamente a “impureza” ou “confusão” de um subconjunto e com ela torna-se possível minimizar a quantidade de informação necessária para classificar um determinado registro (HAN *et al.*, 2011). O Cálculo da entropia de um conjunto de dados D com classes C_i , com $i=1, \dots, n$, pode ser descrito como:

$$Entropia(D) = - \sum_{i=1}^n p_i \log_2(p_i) \quad 4.1$$

onde, p_i é a probabilidade de uma amostra aleatória pertencer a uma classe C_i .

$$p_i = \frac{C_{i,D}}{D} \quad 4.2$$

e $C_{i,D}$ corresponde a quantidade de instâncias de D que pertencem a classe C_i .

Um atributo preditivo A , com k valores distintos (a_1, a_2, \dots, a_k) pode ser utilizado para particionar o conjunto de dados D em m partições, (D_1, D_2, \dots, D_m). Considerando que D_j representa amostras em D que tenham o valor de a_j , o valor da entropia de particionamento do atributo A pode ser definida por:

$$Entropia_A(D) = - \sum_{i=1}^n \frac{|D_j|}{|D|} * Entropia(D) \quad 4.3$$

Assim, pode-se determinar o ganho de informação pela equação seguinte. O atributo que possuir maior valor de ganho será o escolhido para o nó decisão.

$$Ganho(A) = Entropia(D) - Entropia_A(D) \quad 4.4$$

Apesar de ser uma métrica eficiente, o ganho de informação favorece atributos com muitos valores possíveis. Um conjunto de dados pode conter características que identificam uma instância de forma única, como, por exemplo, um identificador (ID). Neste caso, o ganho de informação para esta característica seria ótimo, entretanto, a regra de decisão criada para uma árvore, por exemplo, poderia não ter utilidade.

Assim, uma extensão do Ganho de Informação, chamada Razão de Ganho (*GainRatio*) foi desenvolvida. Esta extensão introduz um novo termo, que penaliza características que possuam muitos valores, além de superar o ganho de informação em termos de taxa de acerto e de reduzir a complexidade das árvores geradas (MITCHELL, 1997; COSTA, 2014). A razão de ganho pode ser calculada pela da seguinte fórmula:

$$GainRatio(A) = \frac{Ganho(A)}{Entropia\ de\ particionamento_A(D)} \quad 4.5$$


$$Entropia\ de\ particionamento_A(T) = - \sum_{i=1}^n \frac{|D_j|}{|D|} * \log_2\left(\frac{|D_j|}{|D|}\right) \quad 4.6$$

4.2. *Random Forest*

O algoritmo de *Random Forest* é um algoritmo de classificação baseado na construção de Árvores de Decisão. Uma árvore de decisão é uma técnica de mineração de dados utilizada para descobrir regras de classificação para um atributo a partir da subdivisão dos dados em um conjunto que está sendo analisado. Árvores de Decisão são simples representações de conhecimento e classificam exemplos em um número finito de classes (APTE; WEISS, 1997). Elas podem ser representadas graficamente por nós e ramos, semelhante a uma árvore no sentido invertido (Figura 4.1) (WITTEN *et al.*, 2011). Sua representação visual torna mais fácil para o usuário analisar e compreender os resultados (FAYYAD *et al.*, 1996).

O nó raiz é o primeiro nó da árvore, localizado no topo da estrutura. Os nós internos, incluindo o nó raiz, são nós de decisão. Cada um destes contém um teste sobre um atributo e seus resultados formam os ramos da árvore. Cada regra tem início no nó raiz da árvore e caminha até uma de suas folhas (REZENDE, 2002). Os algoritmos que constroem Árvores de Decisão buscam encontrar aqueles atributos e valores que provêm máxima segregação dos registros de dados, com respeito ao atributo que se quer classificar, a cada nível da árvore.

Figura 4.1: Exemplo de uma árvore de decisão.



Árvore de decisão gerada com o software WEKA para a classificação de fitofisionomias de Cerrado em função de valores do NDVI.

Fonte: Produção do Autor.

Random Forest é definido por Breiman (2001) como um classificador composto por uma coleção de Árvores de Decisão $\{h_k(x)\}$, $k=1,2,\dots,L$, onde T_k são amostras aleatórias independentes e identicamente distribuídas e cada árvore vota na classe mais popular para uma entrada X . Cada árvore de decisão é gerada a partir de um novo conjunto de atributos selecionado aleatoriamente por uma técnica chamada *Bootstrap*.

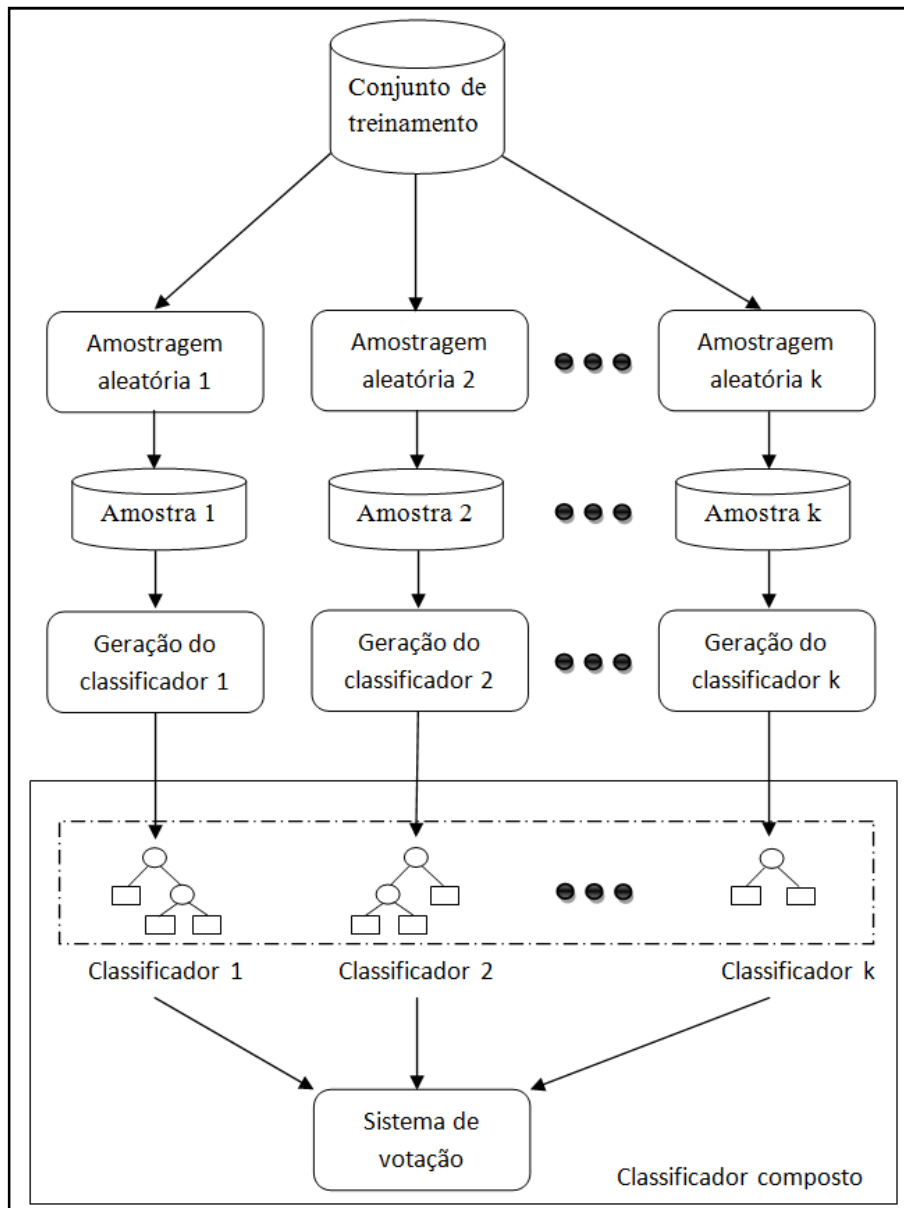
Bootstrap é uma técnica de amostragem com reposição. Para um conjunto de treinamento inicial T , são selecionados aleatoriamente exemplos para um novo subconjunto de treinamento T_k . Cada subconjunto gerado possui o mesmo tamanho do conjunto original e é utilizado para gerar uma Árvore de Decisão $\{h_k(x)\}$. Normalmente, o subconjunto T_k contém, em média, 63,2%³ dos exemplos do conjunto original T . Os exemplos que não foram utilizados no subconjunto T_k formam o conjunto *out-of-bag*, que são exemplos que não foram utilizados na construção do classificador h_k .

Cada árvore de decisão é construída usando esse novo subconjunto. A cada nó da árvore, um número aleatório m de atributos é selecionado. O melhor atributo é escolhido, normalmente, em função do ganho de informação, para dividir o nó. Este procedimento é repetido para os demais nós da árvore, que cresce sem poda. Um número k de árvores é gerado, formando a floresta (Figura 4.2).

O erro de classificação do *Random Forest* depende da força individual de cada árvore na floresta, ou seja, uma medida de desempenho para cada árvore, onde árvores com taxa de erro maior tem uma força individual maior, reduzindo o erro de classificação. A correlação entre estas árvores construídas também está relacionada com o erro de classificação, uma vez que a construção de diversas árvores e a seleção aleatória de atributos para cada nó são responsáveis por gerar árvores que sejam diferentes, diminuindo a correlação entre elas. a baixa correlação tende a diminuir o erro de classificação.

³ A probabilidade de uma amostra do conjunto T ser selecionada para o conjunto T_k é dada por $1 - \left(1 - \frac{1}{n}\right)^n$. Para um valor de n muito grande essa equação é, aproximadamente, $1 - \frac{1}{e} \approx 63,2\%$ (DIETTERICH, 2000).

Figura 4.2: Esquema de construção de uma *Random Forest*.



Fonte: Adaptado de Oshiro (2013).

O algoritmo de *Random Forest* pode lidar com conjuntos com um grande número de atributos. O uso da amostragem *bootstrap* torna o algoritmo mais poderoso do que uma simples árvore, apresentando boa taxa de acerto quando testado em diferentes conjuntos de dados (BELLE, 2008). A combinação de diversos modelos em Árvores de Decisão tende a uma melhor taxa de acerto, visto que o erro em uma única

classificação é sobreposto pela combinação de múltiplas classificações (SESNIE *et al.*, 2010; COSTA, 2014). As *Random Forests* são computacionalmente eficientes, além de evitarem o sobreajuste (*overfitting*) e serem menos sensíveis a ruídos (BREIMAN, 2001).

O Random Forest utiliza três parâmetros que devem ser calibrados: a profundidade das árvores, indicada pelo número de níveis da árvore, o número de atributos utilizados em cada nó da árvore e o número de árvores de decisão da floresta. Este trabalho utilizou as sugestões de Breiman (2001) e Hall *et al.* (2009), os quais sugerem 100 árvores na floresta, profundidade ilimitada e o número de atributos em cada nó definido pela seguinte expressão:

$$\text{Número de atributos no nós} = \text{INT}(\log_2(\#\text{número_total_de_atributos})+1) \quad 4.7$$

5. METODOLOGIA

5.1. Área de estudo

A área de estudo selecionada para este trabalho é uma região do Parque Nacional de Brasília – PNB (Figura 5.1). Localizada a noroeste do estado do Distrito Federal (15°35' a 15°45' de latitude sul e 47°53' a 48°05' de longitude leste), o PNB contém, aproximadamente, 30 mil hectares de vegetação de Cerrado. As fitofisionomias encontradas nessa região são Mata de Galeria, Veredas, Cerrado *Stricto Sensu*, Campo Sujo, Campo Limpo, Campo Rupestre, Campos úmidos e Campo de Murundus. O PNB ainda apresenta grande biodiversidade, com a presença de algumas espécies raras ou ameaçadas de extinção, como o lobo-guará, tamanduá-bandeira, tatu-canastra e jaguatirica. Essa região é uma região estratégica para o Distrito Federal, uma vez que abrange a barragem de Santa Maria, sendo responsável pelo fornecimento de 25% da água potável do estado (ICMBio, 2014a,b).

Figura 5.1: Área de estudo selecionada na região do Parque Nacional de Brasília.

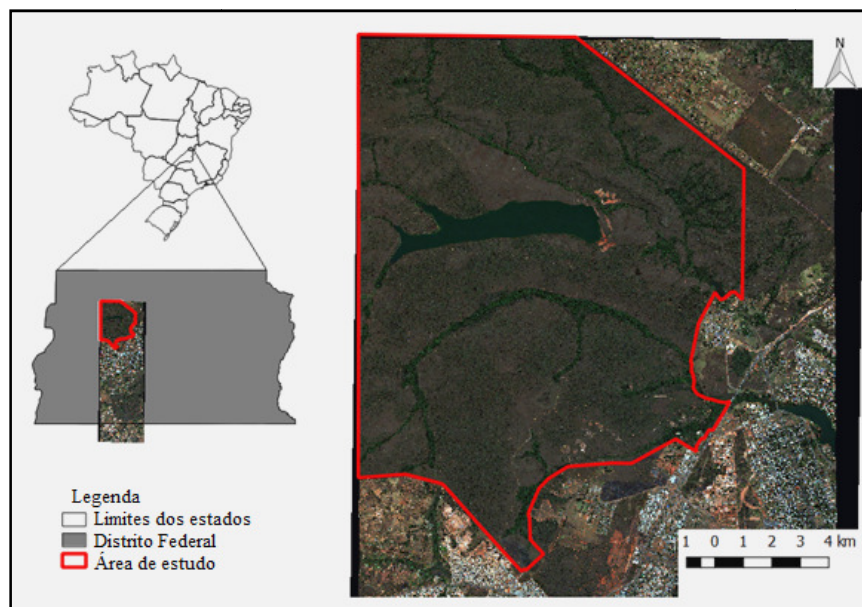


Imagem WorldView-2 com composição *True Color*.

Fonte: Produção do Autor.

O PNB ainda abriga uma base do ICMBio (Instituto Chico Mendes de Conservação da Biodiversidade) com uma brigada de incêndio, responsável pelo combate as queimadas, e agentes de fiscalização para inibir o roubo de madeira e tráfico de espécies exóticas. Essa infraestrutura é essencial para manter a conservação da vegetação do Cerrado. Além destes fatores essa área de estudo foi selecionada devido à disponibilidade das imagens da região, pelo fácil acesso (localizada a menos de 25 Km do aeroporto internacional de Brasília), contato prévio com a gerente do Parque e disponibilidade de recursos para trabalho de campo. Ferreira *et al.* (2007), França e Sano (2011), Schwieder *et al.* (2016) e Girolamo Neto *et al.* (2017b) também usaram o PNB com área de estudo.

5.2. Aquisição e pré-processamento dos dados

Antes de extrair informações das imagens, algumas etapas de pré-processamento das imagens Landsat-8⁴ e WorldView-2 devem ser realizadas. Estas etapas envolvem a aquisição das imagens ópticas orbitais, georreferenciamento, particionamento da imagem WorldView-2 e mascaramento da cobertura vegetação natural do Cerrado.

Para o desenvolvimento do trabalho, duas imagens que cobrem a área de estudo foram selecionadas: uma imagem do sensor OLI (*Operational Land Imager*) a bordo do satélite Landsat-8 e uma imagem do satélite WorldView-2, com resoluções espaciais de 30 m e 2 m, respectivamente. A imagem Landsat-8 foi adquirida no catálogo da USGS (*United States Geological Survey*) e a imagem WorldView-2 foi adquirida por meio de um contrato de cooperação acadêmica entre o INPE e a *Digital Globe Foundation* (INPE, 2016). As características das imagens são apresentadas na Tabela 5.1.

A imagem WorldView-2 tem duas bandas não presentes no Landsat-8 (Amarelo, *Red-Edge*). Por outro lado, o Landsat-8 tem duas bandas na região do SWIR (*Short-Wave Infrared*) que não está disponível no WorldView-2, como mostra a Tabela 5.1. As bandas *Coastal* não foram utilizadas no processamento.

As características de aquisição das duas imagens são semelhantes: datas de passagem dos satélites com pequena diferença (6 dias), o que não implica em alterações da cobertura vegetal, ângulos de inclinação solar próximos, que não afetam as condições de iluminação e aquisição ao NADIR, não envolvendo distorções geométricas.

⁴ Imagens do sensor OLI serão chamadas de imagens Landsat-8.

As imagens foram georreferenciadas utilizando o software ENVI, versão 5.2. (EXELIS, 2018), com erro menor que 1 metro.

Tabela 5.1: Características das imagens Landsat-8 e WorldView-2

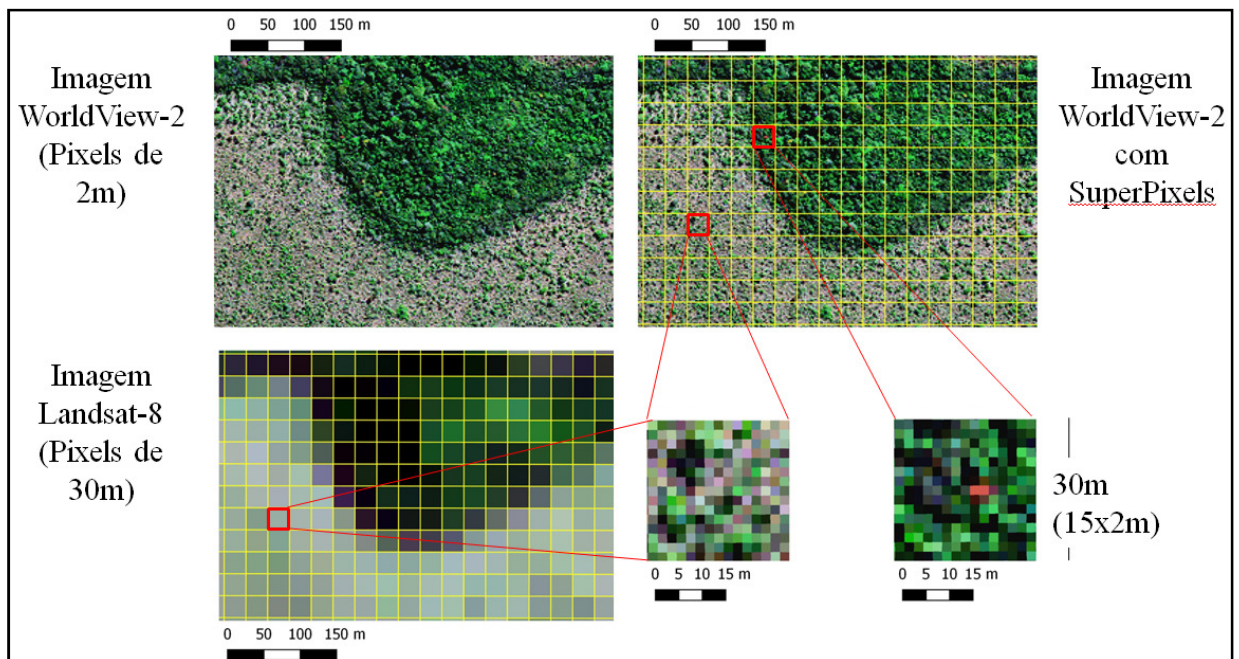
	Landsat-8	WorldView-2
Data de Passagem (dd/mm/aaaa)	16/07/2014	22/07/2014
Horário de Passagem (hh:mm:ss)	10:14:35	10:48:49
Ângulo de inclinação solar	-21,53 °	-20,48 °
Imagem em NADIR	SIM	SIM
Órbita/Ponto	221/71	-
Image ID	LC82210712014197LGN01	103001003373A600
Banda Coastal (nm)	435-451	400-450
Banda Azul (nm)	452-512	450-510
Banda Verde (nm)	533-590	510-580
Banda Amarelo (nm)	-	585-625
Banda Vermelho (nm)	636-673	630-690
Banda Red-Edge (nm)	-	705-745
Banda Infra-vermelho próximo - NIR (nm)	851-879	760-895
		960-1040
Banda Infra-Vermelho de ondas Curtas - SWIR (nm)	1566-1651	-
	2107-2294	-

Fonte: Produção do Autor.

A imagem WorldView-2 foi particionada em grupos de pixels (janela 15x15) que correspondem à área de um pixel do Landsat-8 (30 m). Denominaremos cada agrupamento da imagem WorldView-2 por SuperPixel, que tem um nível de detalhamento maior do que o pixel do Landsat-8. Assim um SuperPixel é representado por um grupo de 15x15 pixels (Figura 5.2).

Para considerar apenas as regiões de cobertura vegetal do Cerrado, as regiões de outros usos e coberturas da terra (urbano, estradas, queimadas, rios, solo exposto) foram mascaradas nas imagens. Todo o processamento será realizado pixel a pixel para imagens Landsat-8 e SuperPixel a SuperPixel para imagens WorldView-2. Para a geração dos atributos a partir da imagem WorldView-2, o cálculo dos valores dos atributos (exceto a textura) foi realizado para cada pixel contido no SuperPixel, e o valor atribuído ao SuperPixel é a média dos valores calculados para cada pixel.

Figura 5.2: Criação do SuperPixel na imagem WorldView-2.



Fonte: Produção do Autor

5.3. Definição das legendas de classificação

Devido a complexidade do sistema de classificação proposto por Ribeiro e Walter (2008), quatro (4) níveis legenda foram adotados neste trabalho para avaliar o potencial dos atributos na classificação das fitofisionomias do Cerrado.

Os níveis de legenda propostos são os seguintes:

Legenda N1: Este é o nível mais simples, compatível com o Projeto TerraClass (MMA, 2015) e diversos trabalhos como os de Oliveira *et al.* (2005 a,b; 2007b), Grecchi *et al.* (2013), Muller *et al.* (2015), Teixeira *et al.* (2015), Silva e Sano (2016). Este nível de legenda define as três classes das grandes formações, propostas por Ribeiro e Walter (2008): *Campestre, Savânica e Florestal*.

Legenda N2: O segundo nível de legenda apresenta a discriminação das formações Campestres nas classes de Campo Limpo, Campo Sujo e Campo Rupestre, bem como a separação das classes de Veredas e Cerrado *Stricto Sensu* das formações savânicas. As

formações Florestais referem-se às Matas de Galeria. O segundo nível de legenda considera 6 classes: *Campo Rupestre*, *Campo Limpo*, *Campo Sujo*, *Cerrado Stricto Sensu*, *Vereda*, *Mata de Galeria*.

Ferreira *et al.* (2005), Oliveira *et al.* (2007) e Costa *et al.* (2014) utilizaram legendas de classificação similares a esta legenda.

Legenda N3: Este terceiro nível de legenda considera as subdivisões do Cerrado *Stricto Sensu* em Cerrado Ralo, Cerrado Típico e Cerrado Denso, logo as 8 classes deste nível são: *Campo Rupestre*, *Campo Limpo*, *Campo Sujo*, *Cerrado Ralo*, Cerrado Típico, Cerrado Denso, *Vereda*, *Mata de Galeria*.

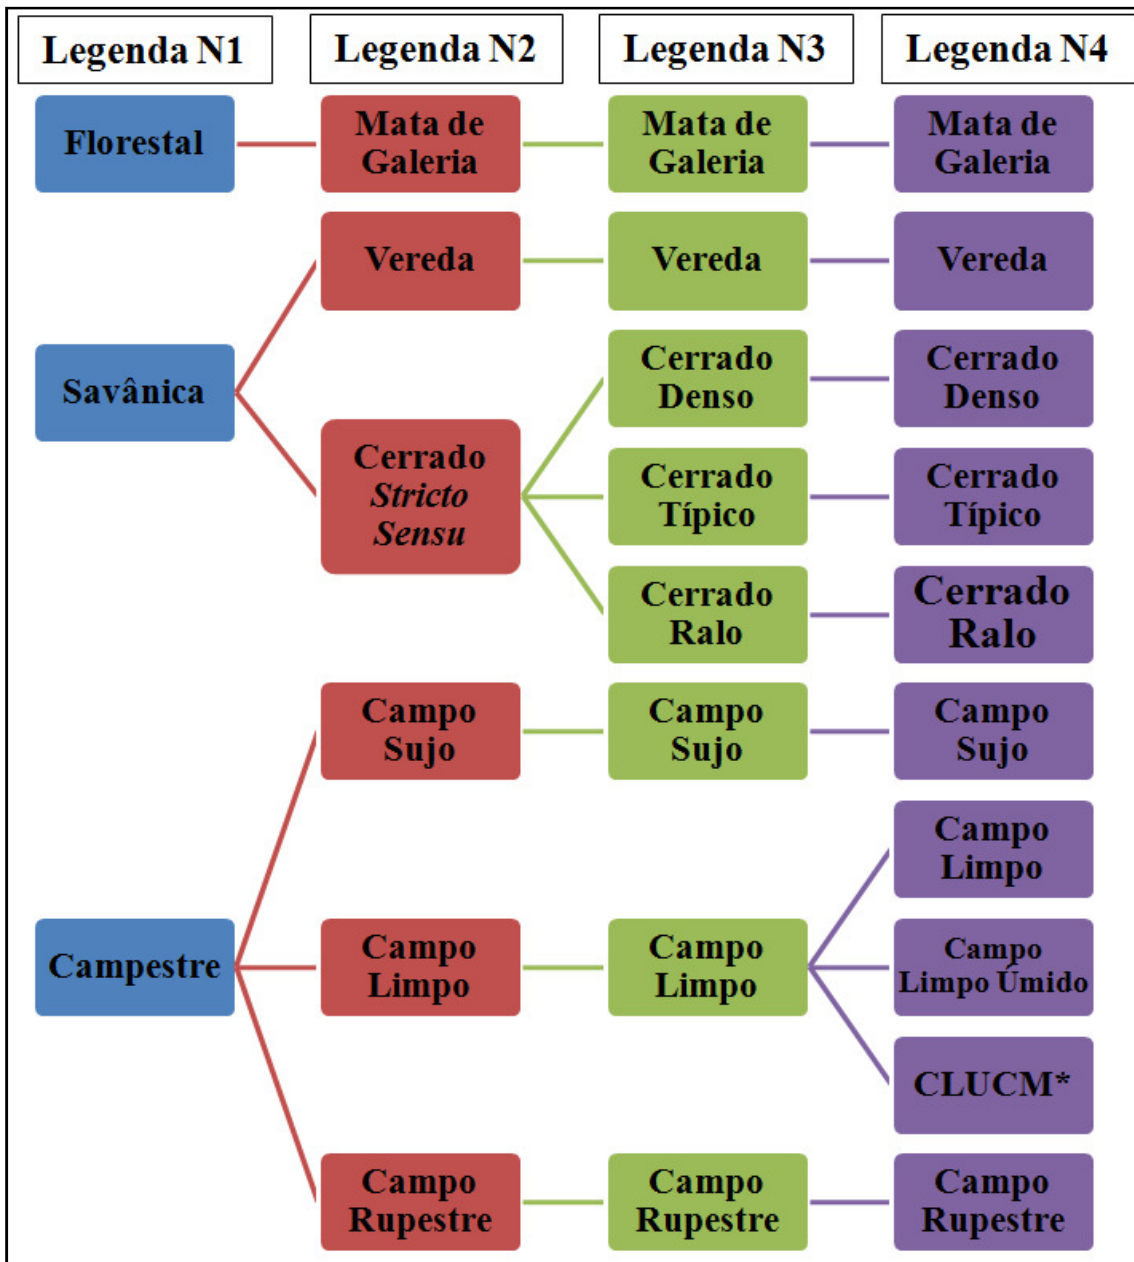
Este nível é compatível com as legendas de classificação utilizadas nos trabalhos de Oliveira *et al.* (2007a), Ferreira *et al.* (2007), Schwieder *et al.* (2016) e Girolamo Neto *et al.* (2017b).

Legenda N4: O quarto nível de legenda define todas as classes presentes no Parque Nacional de Brasília. Este nível difere do nível 3 pois inclui as subdivisões da fitofisionomia de Campo Limpo, como Campo Limpo Úmido e Campo Limpo Úmido com Murundu. Desta forma, o nível 4 define 10 classes: *Campo Rupestre*, *Campo Limpo Úmido*, *Campo Limpo Úmido com Murundu*, *Campo Limpo*, *Campo Sujo*, *Cerrado Ralo*, *Cerrado Típico*, *Cerrado Denso*, *Vereda*, *Mata de Galeria*.

Pinheiro e Durigan (2009) e Silva e Sano (2016) usam nos seus estudos a classe Campo Limpo Úmido, presente neste nível de legenda. Entretanto, Orozco Filho utilizou a classe Campo Limpo Úmido com Veredas, compatível com as classes Campo Limpo Úmido e Veredas.

A Figura 5.3 representa todos estes níveis em relação a hierarquia das classes proposta por Ribeiro e Walter (2008).

Figura 5.3: Legenda de classes com a hierarquia das fitofisionomias de Cerrado.



* Campo Limpo Úmido com Murundu

Fonte: Produção do Autor

5.4. Definição dos atributos usados na classificação

No processo de classificação serão utilizados os seguintes atributos: Reflectância das bandas, Índices de Vegetação, Modelo Linear de Mistura Espectral (MLME), Transformada *Tasseled Cap* (TC) e textura.

5.4.1. Reflectância espectral

A atmosfera é uma fonte primária de ruído para medição precisa da Reflectância de superfície com sensoriamento remoto óptico (HONKAVAARA *et al.*, 2009). Os efeitos atmosféricos são resultado da dispersão (retro espalhamento) e absorção molecular da radiação eletromagnética e influenciam a qualidade da informação obtida por sensores ópticos orbitais. Erros relacionados a correção atmosférica podem aumentar a incerteza de atributos como Índices de Vegetação (HADJIMITSIS *et al.*, 2010) e componentes do MLME (FERREIRA *et al.*, 2007). Portanto, a remoção dos efeitos atmosféricos é uma etapa de pré-processamento importante em muitas aplicações de Sensoriamento Remoto, uma vez que é necessário converter o número digital obtido pelos sensores orbitais em Reflectância de superfície (KAUFMAN; SENDRA, 1988). Além disso, se uma imagem for usada para fins de detecção de monitoramento de mudanças do uso e cobertura da terra, é essencial aplicar a correção atmosférica, para uniformizar as respostas espectrais de um mesmo objeto em todas as imagens (AGAPIOU *et al.*, 2011).

Diversos métodos de correção atmosférica são descritos na literatura (BERK *et al.*, 1987; CHAVEZ JUNIOR, 1988; PERKINS *et al.*, 2005; LYAPUSTIN *et al.*, 2011, BERK; HAWES, 2017). Dentre estes métodos, os que utilizam modelos de transferência radioativa na atmosfera tem apresentado bons resultados para correção de imagens de sensoriamento remoto (HADJIMITSIS *et al.*, 2004; PERKINS *et al.*, 2005). Neste contexto, esse trabalho utilizou o algoritmo FLAASH (PERKINS *et al.*, 2005) para converter Números Digitais em Reflectância de superfície das bandas dos satélites Landsat-8 e WorldView-2. Esse algoritmo segue os seguintes passos para o cálculo da Reflectância de superfície em uma imagem de sensoriamento remoto (PERKINS *et al.*, 2005; EXELIS, 2013; ZANTER, 2016):

1- Conversão de Número Digital para Radiância:

$$L_{\lambda} = M_L * Q_{cal} + A_L \quad 5.1$$

onde, L_{λ} é Radiância espectral do pixel ($W/(m^2 * sr * \mu m)$); M_L é o fator multiplicativo de Radiância para uma banda L; A_L é o fator aditivo de Radiância para uma banda L e Q_{cal} corresponde ao valor do pixel em ND (Número Digital).

2- Conversão de Radiância para Reflectância

$$\rho_{\lambda} = \frac{\pi * L_{\lambda} * d^2}{ESUN_{\lambda} * \cos\theta_s} \quad 5.2$$

onde, ρ_{λ} é a Reflectância no topo da atmosfera; L_{λ} é a Radiância espectral ($W/(m^2 * sr * \mu m)$); d é a distância Sol-Terra (U.A.); $ESUN_{\lambda}$ = Irradiância solar na exoatmosfera por comprimento de onda e θ_s corresponde ao ângulo solar zenital.

3- Aplicação do modelo de transferência radiativa e conversão para Reflectância de superfície.

Para o modelo deve ser definido os seguintes parâmetros: Latitude e Longitude do ponto central da cena, tipo e altitude do sensor, altitude da cena em relação ao nível do mar, data e horário de passagem, modelo de atmosfera (*Tropical, Mid-Latitude ou Artic*), modelo de aerossóis (Rural, Marítimo, Urbano ou Troposfera), visibilidade da atmosfera e dentre outros (EXELIS, 2013).

5.4.2. Componentes do modelo linear de mistura espectral

A mistura de alvos de um pixel permite aplicar a técnica do MLME para estimar a proporção dos componentes presentes neste pixel. Estes componentes são chamados de *endmembers* e são calculados a partir da informação espectral de pixels puros que caracterizam o alvo de interesse (ROBERTS *et al.*, 1998). Os *endmembers* mais comuns no estudo da vegetação são as componentes Solo, Sombra e Vegetação (SHIMABUKURO; SMITH, 1991). Ferreira *et al.* (2007), Carvalho *et al.* (2010) e Girolamo Neto *et al.* (2017b) usaram as componentes do MLME no processo de classificação das fitofisionomias do Cerrado.

Estas componentes podem inferir informações sobre quantidade de vegetação e solo exposto em uma dada região, os quais tem sido apontadas por Ribeiro e Walter (2008) com potencial para diferenciar determinadas fitofisionomias do Cerrado. As componentes MLME são calculadas da seguintes forma:

$$r_i = \sum_{j=1}^N (a_{ij} * x_j) + e_i \quad 5.3$$

onde, $j = 1, 2, \dots, N$ é número de *endmembers* assumidos para o problema; $i = 1, 2, \dots, M$ é número de bandas; r_i = média da Reflectância espectral para a i -ésima banda de um pixel com N componentes; a_{ij} = Reflectância espectral da j -ésima componente do pixel para a i -ésima banda; x_j = valor proporcional do j -ésimo componente do pixel; e_i = erro para a i -ésima banda.

Neste trabalho, 10 pixels puros para cada um dos *endmembers* Solo, Sombra e Vegetação foram selecionados para cada uma das imagens Landsat-8 e WorldView-2. Como cada SuperPixel da imagem WorldView-2 é representado por 15x15 pixels, o pixel central do SuperPixel foi selecionado como o pixel puro. As componentes MLME foram geradas no software ENVI⁵, versão 5.2 e processadas posteriormente por scripts em R (R CORE TEAM, 2013).

5.4.3. Imagens de índices de vegetação

Os Índices de Vegetação (IV) são utilizados para realçar a Reflectância da vegetação por meio da combinação de determinadas regiões do espectro eletromagnético (HUETE *et al.*, 2002). A combinação das bandas está baseada na Reflectância da vegetação, principalmente, nas regiões do visível (Vermelho) e no Infravermelho próximo (NIR). A Reflectância da vegetação está ligado aos pigmentos da planta que são responsáveis pela absorção, reflexão e transmissão da radiação eletromagnética incidente. Cinco (5) Índices de Vegetação foram utilizados como atributos e estão descritos na Tabela 5.2.

⁵ A construção do MLME no software ENVI foi feita com uma algoritmo parcialmente restrito. Neste algoritmo uma constante numérica é utilizada para aproximar a soma das frações em 1. Entretanto, devido a variância dos dados, podem ocorrer valores negativos e superpositivos (maiores do que 1) em determinadas frações (Roberts *et al.*, 1998; EXELIS, 2018).

Tabela 5.2: Índices de Vegetação.

Índice	Sigla	Fórmula	Referência	Eq.
<i>Normalized Difference Vegetation Index</i>	NDVI	$\frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}}$	Rouse Junior <i>et al.</i> (1973)	5.4
<i>Enhanced Vegetation Index</i>	EVI	$G * \frac{(\rho_{NIR} - \rho_{RED})}{(\rho_{NIR} + C_1 * \rho_{RED} - C_2 * \rho_{BLUE} + L_c)}$	Huete <i>et al.</i> (1998)	5.5
<i>Two Band Enhanced Vegetation Index</i>	EVI2	$G * \frac{(\rho_{NIR} - \rho_{RED})}{(\rho_{NIR} + 2,4 * \rho_{RED} + 1)}$	Jiang <i>et al.</i> (2008)	5.6
<i>Soil-Adjusted Vegetation Index</i>	SAVI	$(1 + L) * \frac{(\rho_{NIR} - \rho_{RED})}{(\rho_{NIR} + \rho_{RED} + L)}$	Huete (1988)	5.7
<i>Modified Soil Adjusted Vegetation Index 2</i>	MSAVI2	$\frac{(2 * \rho_{NIR} + 1 - \sqrt{(2 * \rho_{NIR} + 1)^2 - 8 * (\rho_{NIR} - \rho_{RED})})}{2}$	Qi <i>et al.</i> (1994)	5.8

onde, ρ_{GREEN} = Reflectância de superfície da banda Verde; ρ_{BLUE} = Reflectância de superfície da banda Azul; ρ_{RED} = Reflectância de superfície da banda Vermelha; ρ_{NIR} = Reflectância de superfície da banda do infravermelho próximo; L = Ajuste da linha do solo (1); G = Fator de ganho (2,5); C_1 e C_2 = Coeficiente de resistência de aerossóis (6,0 e 7,5); L_c = Fator de correção da cobertura vegetal.

Fonte: Produção do Autor.

5.4.4. Imagens da transformada *Tasseled Cap*

As componentes da Transformada *Tasseled Cap* (TC) representam relação tridimensional entre características relacionadas a identificação da vegetação. A componente *Greenness* está relacionada com a Reflectância característica da vegetação verde, o que pode ser muito útil para discriminação de fitofisionomias de Cerrado que apresentem vegetação amarelada ou com perda de pigmentos fotossintetizantes. Já a componente *Brightness* foi definida na direção de variação da Reflectância dos solos, podendo estar relacionada com a presença de solo exposto ou pouco coberto, regiões urbanas e variações na topografia. Por sua vez, a componente *Wetness* corresponde à variação da umidade do solo ou presença de água, mostrando potencial para discriminar algumas fitofisionomias que se encontrem em locais com alta disponibilidade de água no solo (KAUTH; THOMAS, 1976; CRIST; CICONE, 1984; ZHANG *et al.*, 2002; BAIG *et al.*, 2014; YARBROUGH *et al.*, 2014). Carvalho *et al.* (2010) e Schwieder *et*

al. (2016) utilizaram estas componentes para discriminação de fitofisionomias do Cerrado. A Transformada *TC* é descrita da seguinte forma:

$$U = R^T * X + D \quad 5.9$$

onde, *R* é uma matriz unitária tendo por colunas vetores unitários *R*₁, *R*₂... *R*_n; *n* é o número máximo de bandas a ser utilizado; *X* é o vetor de sinais das bandas do sensor; *D* é um vetor de deslocamento que pode ser utilizado para evitar valores negativos das componentes e *U* é o vetor da transformação *TC* (KAUTH; THOMAS, 1976).

Para gerar as imagens *TC*, a imagem Landsat-8 foi processada usando os coeficientes de transformação proposto por Baig *et al.* (2014), enquanto que a imagem WorldView-2 foi processada usando os coeficientes propostos por Yarbrough *et al.* (2014). A Tabela 5.3 apresenta os coeficientes usados no processamento.

Tabela 5.3: Coeficientes da Transformada *Tasseled Cap* para as imagens Landsat-8 e WorldView-2.

		Bandas do WorldView-2							
Componente <i>TC</i>	Azul	Verde	Amarelo	Vermelho	<i>Red-Edge</i>	NIR1	NIR2	SWIR1	SWIR2
<i>Brightness</i>	0,0121	0,1258	0,3130	0,0412	0,4827	-0,1606	0,6735	-	-
<i>Greenness</i>	-0,2062	-0,2158	-0,3144	-0,4108	0,0957	0,6005	0,5036	-	-
<i>Wetness</i>	-0,3157	-0,3172	-0,2425	-0,2564	-0,0965	-0,7425	0,2024	-	-
		Bandas do Landsat-8							
Componente <i>TC</i>	Azul	Verde	Amarelo	Vermelho	<i>Red-Edge</i>	NIR	NIR2	SWIR1	SWIR2
<i>Brightness</i>	0,3029	0,2786	-	0,4733	-	0,5599	-	0,5080	0,1872
<i>Greenness</i>	-0,2941	-0,2430	-	-0,5424	-	0,7276	-	0,0713	-0,1608
<i>Wetness</i>	0,1511	0,1973	-	0,3283	-	0,3407	-	-0,7117	-0,4559

Fonte: Adaptado de Baig *et al.* (2014) e Yarbrough *et al.* (2014).

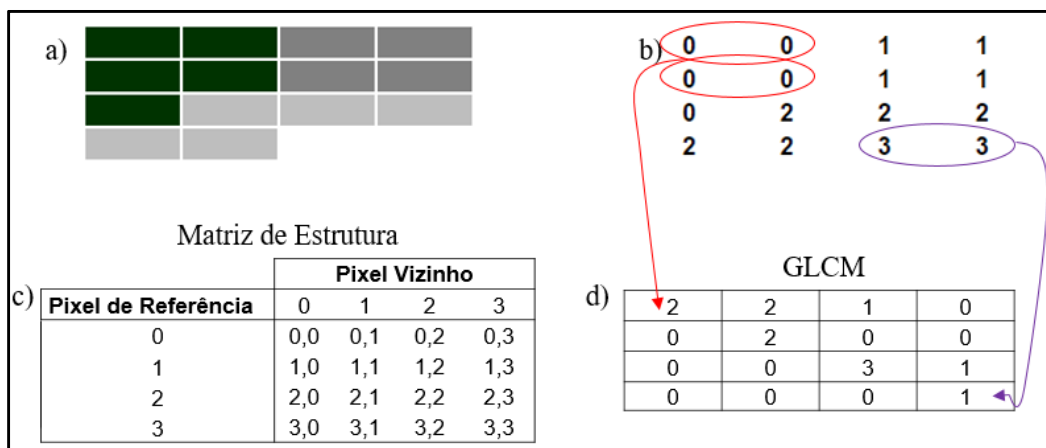
5.4.5. Atributos de textura GLCM

Os alvos em uma imagem óptica orbital também podem ser caracterizados por meio de atributos de textura. Uma textura mais uniforme está relacionada com pequenas variações de níveis de cinza dentro de uma janela de pixels na imagem. Diferentemente, a textura rugosa refere-se a grandes variações dos níveis de cinza na imagem

(HALL-BEYER, 2017). Essa informação é fundamental para discriminar as fitofisionomias do Cerrado, uma vez que a principal característica de classes como Cerrado Ralo, Cerrado Típico e Cerrado Denso é a presença de árvores intercalada por regiões de vegetação arbustiva, gerando variações na textura destes alvos de acordo com a porcentagem de cobertura de árvores para cada fitofisionomia. Para a representação da textura e de atributos relacionados a ela, Haralick *et al.* (1973) propôs a matriz de co-ocorrência de níveis de cinza (*Grey Level Co-occurrence Matrix – GLCM*).

A matriz GLCM corresponde a uma tabulação de todas as diferentes combinações de brilho de *pixel* (níveis de cinza) que ocorrem em uma imagem (ou região). Dado uma imagem digital (Figura 5.4a e 5.4b), a matriz GLCM é gerada de acordo com as combinações possíveis entre os *pixels* de referência e os *pixels* vizinhos (Figura 5.4c). A escolha dos vizinhos, que serão selecionados, depende da direção de deslocamento escolhida (0°, 45°, 90°, 135° ou todas as direções). Neste exemplo, a direção 0° foi utilizada. O preenchimento da matriz é realizada de acordo com a quantidade de ocorrência de cada combinação (Figura 5.4d).

Figura 5.4: Cálculo da matriz GLCM.



a) representação de uma janela de 4x4 pixels em uma imagem digital; b) Representação dessa janela com os valores de nível de cinza; c) Possíveis combinações entre diferentes níveis de cinza para gerar a matriz GLCM (Matriz de Estrutura). d) Cálculo da matriz GLCM com as combinações de pixels resultantes.

Fonte: Neves (2017) Adaptado de Hall-Beyer (2017).

A matriz deve ser transposta para ser simétrica em relação à diagonal e também deve ser normalizada para valores de probabilidade de ocorrência das combinações. A matriz resultante é quadrada e possui o mesmo número de linhas e colunas que o nível de quantização da imagem. Assim, uma imagem com 256 níveis de cinza formará uma matriz quadrada de 256 linhas por 256 colunas, totalizando 65.536 células. Dada uma GLCM com N células de valor P, as fórmulas das medidas de textura estão descritas na Tabela 5.4.


Tabela 5.4: Medidas de textura da matriz GLCM.

Medida	Fórmula	Equação
Contraste	$\sum_{i,j=0}^{N-1} P_{i,j}(i-j)^2$	5.10
Dissimilaridade	$\sum_{i,j=0}^{N-1} P_{i,j} i-j $	5.11
Homogeneidade	$\sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1+(i-j)^2}$	5.12
2º Momento Angular	$\sum_{i,j=0}^{N-1} P_{i,j}^2$	5.13
Entropia	$\sum_{i,j=0}^{N-1} P_{i,j}(-\ln P_{i,j})$	5.14
Correlação	$\sum_{i,j=0}^{N-1} P_{i,j} \left\{ \frac{(i-\mu_i) * (j-\mu_j)}{\sqrt{(\sigma_i)^2 * (\sigma_j)^2}} \right\}$	5.15

Fonte: Adaptado de Haralick *et al.*(1973) e Hall-Beyer (2007).

Um exemplo dos atributos descritos na Tabela 5.4 foram calculados para a Figura 5.5 e mostrados na Figura 5.6. Para este exemplo, os atributos foram calculados por meio de janelas móveis de 7x7 pixels, já neste trabalho os atributos serão extraídos para cada SuperPixel (janelas de 15x15 pixels)

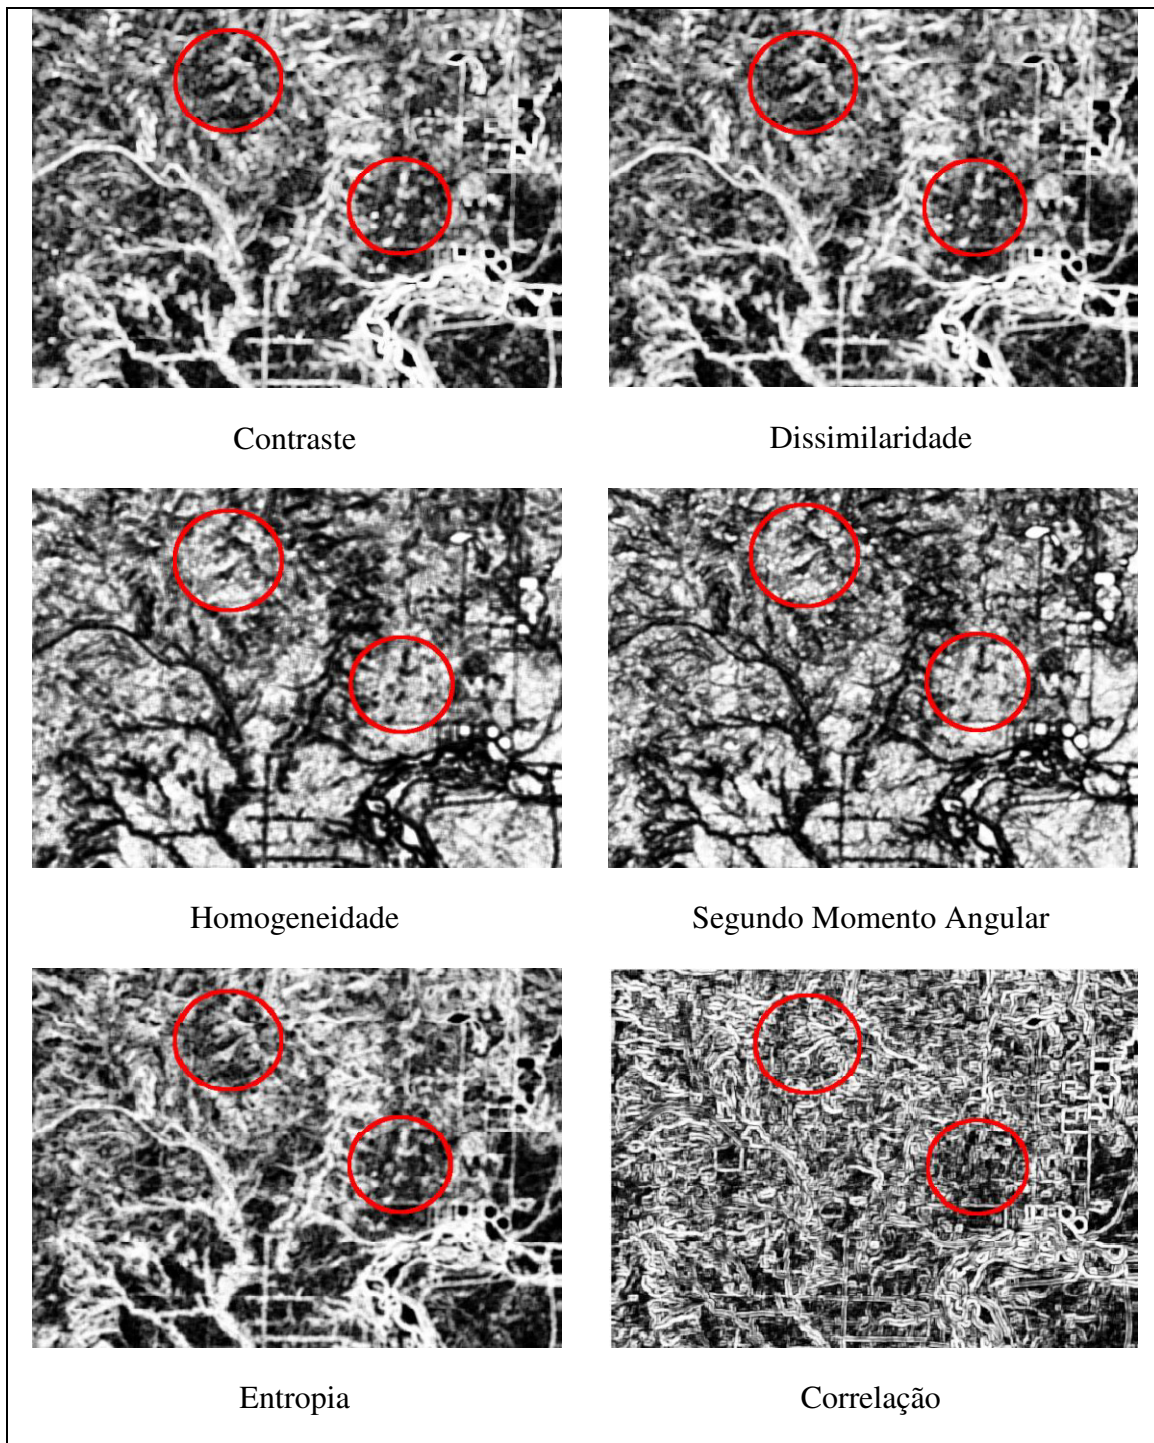
Figura 5.5: Exemplo de imagem Landsat-7 para a banda do Vermelho com destaque para uma região com textura rugosa (a) e lisa (b).



Fonte: Adaptado Hall-Beyer (2007).

Neste trabalho, os atributos de textura foram extraídos apenas para a imagem WorldView-2. Para cada SuperPixel da imagem, os atributos mostrados na Tabela 5.4 foram calculados. Estes atributos foram calculados para todos os atributos Reflectânciada imagem WorldView-2, componentes do MLME, Transformada *TC* e Índices de Vegetação, totalizando 18 componentes para cada um dos 6 tipos de atributos de textura, totalizando 108 atributos.

Figura 5.6: Exemplo de imagens de textura



Fonte: Hall-Beyer (2007).

5.5. Seleção de amostras para caracterização das classes e classificação

Para a seleção das amostras, foram sorteados 1062 pontos dentro da área de estudo. Cento e trinta pontos foram visitados no Parque Nacional de Brasília, no período de 04/06/2017 até 09/06/2017 (Figura 5.7). Para os demais pontos, foi realizada uma interpretação visual da imagem do WorldView-2 e outras imagens de alta resolução e datas próximas disponíveis no Google Earth. A cada um destes pontos foi atribuído um rótulo de classe, para cada Legenda (N1-N4) utilizada neste trabalho.

Figura 5.7: Pontos coletados em campo no Parque Nacional de Brasília.

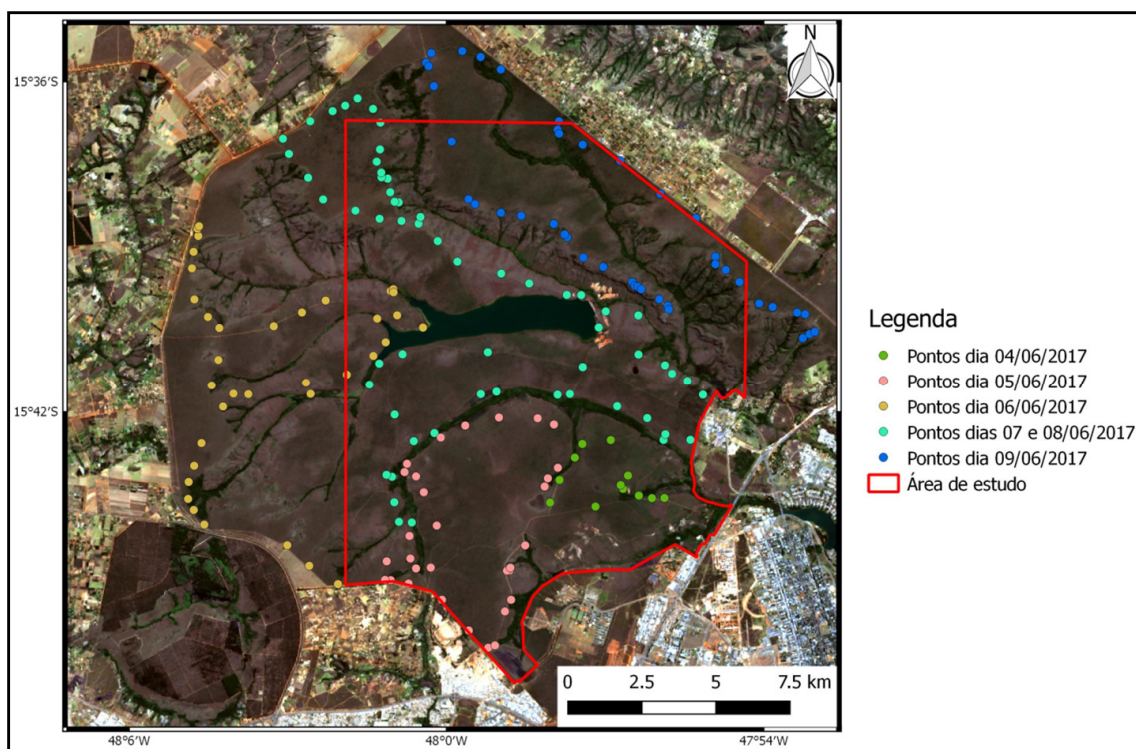


Imagem Landsat-8 e composição *True Color*.

Fonte: Produção do Autor.

5.6. Separabilidade das classes pelo critério da Distância Euclidiana

Um dos objetivos deste trabalho foi avaliar a separabilidade espectral de fitofisionomias. Para tanto foi usada como medida de referência a Distância Euclidiana. A Distância Euclidiana é medida de separabilidade amplamente utilizada no Sensoriamento Remoto (LIESENBERG *et al.* 2007b; SHIVAKUMAR; RAJASHEKARARADHYA, 2017). Analisando um espaço de atributos gerado a partir

de imagens de sensoriamento remoto, quanto menor a Distância Euclidiana, menor o potencial de discriminação entre um par de classes analisado (LIESENBERG *et al.*, 2007b; HAN *et al.*, 2011). Neste sentido, alguns trabalhos revisados no Capítulo 3 utilizaram algumas métricas de separabilidade entre fitofisionomias de Cerrado, como a Distância Euclidiana (LIESENBERG *et al.*, 2007a), Distância de Mahalanobis (FERREIRA *et al.*, 2007) e Distância de Bhattacharya (OLIVEIRA *et al.*, 2007a).

Neste trabalho, a avaliação de separabilidade entre as classes foi realizada considerando as distribuições das classes em um plano bidimensional, composto por atributos em comum entre os satélites. Essa distribuição foi representada pelo cálculo do centróide referente a cada classe. Os atributos utilizados para formar o plano bidimensional foram divididos em grupos e analisados em pares. O grupo de Reflectância refere-se às Reflectâncias das bandas Azul, Verde, Vermelho e NIR, o grupo do MLME refere-se às componentes de Solo, Sombra e Vegetação e o grupo da Transformada *TC* refere-se às componentes de *Greenness*, *Brightness* e *Wetness*. Este procedimento fornece premissas para o resultado da classificação, uma vez que os dados de um satélite podem apresentar uma maior separabilidade entre as classes do que outro. A Distância Euclidiana entre dois centróides foi calculada de acordo com a equação:

$$De = \sqrt{(p_x - q_x)^2 + (p_y - q_y)^2} \quad 5.16$$

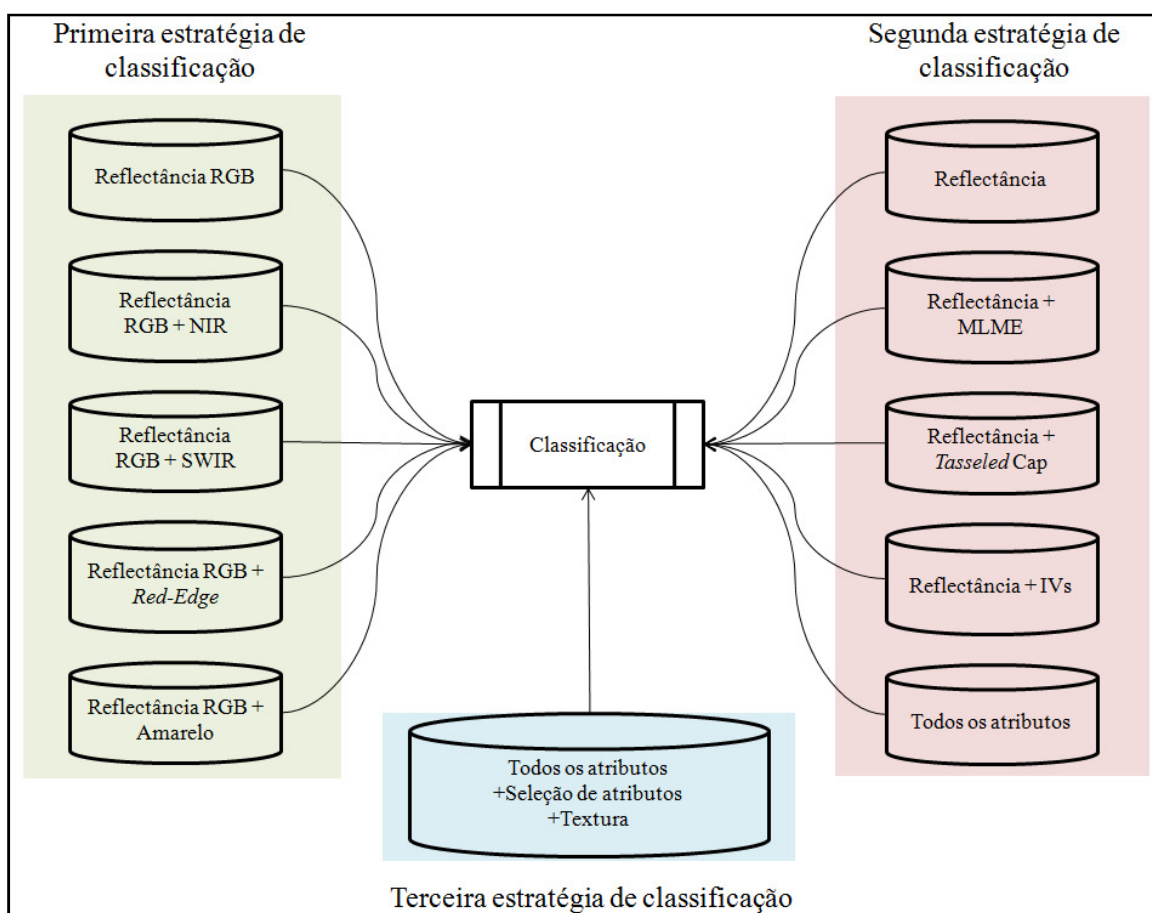
onde, P= (p_x,p_y) e Q= (q_x,q_y) são coordenadas dos centróides das classes P e Q.

5.7. Classificação por *Random Forest*

O método de classificação *Random Forest* (BREIMAN, 2001), disponível na plataforma WEKA (HALL *et al.*, 2009), versão 3.9.1, foi utilizado neste trabalho. O Weka é um *software* livre, gratuito (<http://www.cs.waikato.ac.nz/ml/weka/>), distribuído sob a licença de uso GPL (*General Public License*). O algoritmo *Random Forest* tem sido muito utilizado em aplicações de Sensoriamento Remoto com boa taxa de acerto na classificação (MULLER *et al.*, 2015; PENÃ; BRENNNG *et al.*, 2015; NEVES *et al.*, 2016; GIROLAMO NETO *et al.*, 2017b).

Este trabalho utilizou três estratégias de classificação (Figura 5.8). A primeira delas avaliou a contribuição das bandas de diferentes faixas espectrais na taxa de acerto do classificador, sendo que inicialmente foi avaliado um conjunto com dados de Reflectância das bandas RGB e, posteriormente, demais atributos de Reflectância adicionadas neste conjunto.

Figura 5.8: Três diferentes estratégias de classificação utilizadas.



Fonte: Produção do Autor.

Na segunda estratégia foi avaliada a contribuição dos outros atributos (MLME, Transformada *TC* e Índices de Vegetação) na classificação das fitofisionomias de Cerrado. Estes atributos foram adicionados separadamente ao conjunto contendo a Reflectância de todas as bandas. Após a avaliação individual, todos os atributos foram utilizados na classificação. A primeira e segunda estratégias de classificação foram realizadas separadamente para as imagens WorldView-2 e Landsat-8.

A terceira estratégia de classificação foi realizada somente para a imagem WorldView-2, sendo que foram utilizados os atributos de textura junto ao conjunto

contendo os demais atributos utilizados. Também foram utilizados métodos de seleção de atributos como *Wrapper*, *Correlation Feature Selection (CFS)*, *InfoGain*, *GainRatio*. Estes métodos foram utilizados visando melhorar a taxa de acerto nessa classificação, visando eliminar atributos redundantes e irrelevantes. Diversos métodos de seleção de atributos foram usados, pois cada método pode apresentar diferentes resultados dependendo da aplicação (DASH;LIU, 1997; HALL, 1999; JANECEK *et al.*, 2008).

Para cada conjunto de cada estratégia de classificação a classificação foi repetida 10 vezes, visando obter um intervalo de confiança. Cada uma dessas repetições foi realizada com a opção de validação cruzada com 10 *folds*.

5.8. Avaliação da classificação

Para avaliação dos resultados da classificação, a taxa de acerto global (*Overall Accuracy*), que é o percentual de acerto no processo de classificação (WITTEN *et al.*, 2011), será usada neste trabalho. Essa medida pode ser calculada a partir da matriz de confusão, assim como outras medidas de avaliação tais como a Taxa de acerto da classe e Erros de omissão (HAN *et al.*, 2011), como descritas na Tabela 5.5.

Para subsidiar as análises dos resultados da classificação, duas etapas de processamento foram realizadas neste trabalho: a caracterização das classes definidas nas Legendas N1-N4 de acordo com os atributos Reflectância, MLME, Transformada TC e Índices de Vegetação e a análise da separabilidade entre as classes em função da Distância Euclidiana, descritas no próximo capítulo.

Tabela 5.5: Medidas de avaliação dos classificadores.

Medidas de avaliação	Fórmula	Equação
Taxa de Acerto Global (TA)	$\frac{VP + VN}{n}$	5.17
Taxa de Acerto da Classe (TAC)	$\frac{VP}{(VP + FN)}$	5.18
Erro de Omissão (EO)	$1 - TAC$	5.19

As amostras são classificadas como: VP – Verdadeiro Positivo; VN – Verdadeiro Negativo; FP – Falso Positivo; FN – Falso Negativo; $n = TP+TN+FP+FN$.

Fonte: Produção o Autor.

6 CARACTERIZAÇÃO DAS FITOFISIONOMIAS DO CERRADO

Este capítulo analisa as características espectrais das fitofisionomias do Cerrado, definidas nas Legendas N1-N4, em função dos conjunto de atributos selecionados (Reflectância, componentes do Modelo Linear de Mistura Espectral (MLME), Transformada *Tasseled Cap* (TC) e Índices de Vegetação) para a caracterização das classes, nas duas imagens Landsat-8 e WorldView-2. As amostras utilizadas para realizar essa caracterização foram as mesmos utilizadas na avaliação da classificação.

6.1 Reflectância

Para este conjunto de atributos foram analisados os valores de Reflectância e a Distância Euclidiana para medir a separabilidade das classes.

Para a análise de Distância Euclidiana foram utilizadas as bandas do Azul, Verde, Vermelho e NIR⁶ para gerar o espaço bidimensional. Está análise foi feita para todas as combinações entre essas bandas. Para análise da separabilidade entre as classes, as Distâncias Euclidianas entre combinações de classes foram avaliadas para as imagens WorldView-2 e Landsat-8 e foram denominadas, respectivamente, $De_{Landsat-8}$ e $De_{WorldView-2}$.

Caso $De_{WorldView-2} > De_{Landsat-8}$, ocorre separabilidade maior para as classes com a imagem WorldView-2. Em contrapartida, se $De_{WorldView-2} < De_{Landsat-8}$, a separabilidade entre as classes é melhor para a imagem Landsat-8, caso $De_{WorldView-2} = De_{Landsat-8}$ não há diferença entre a separabilidade das classes entre ambas as imagens. A análise de separabilidade por Distância Euclidiana não foi mostrada para as componentes do MLME e para a Transformada TC pois não mostrou resultados conclusivos. Um exemplo de cálculo será mostrado para a Legenda N1.


Caracterização para a Legenda N1:

A Figura 6.1 ilustra a os valores de Reflectância espectral das classes Campestre, Savânica e Florestal. Os gráficos representam os valores do atributo de

⁶ Para o satélite WorldView-2 foi escolhida a banda NIR1.

Reflectância, para cada classe, em função das bandas espectrais das imagens, WorldView-2 e Landsat-8.

Figura 6.1: Caracterização das classes para a Legenda N1 em função da Reflectância.



a) Imagem WorldView-2 e b) Imagem Landsat-8.

Fonte: Produção do Autor.


Para as duas imagens, a Reflectância das classes na região do visível é baixa em relação a de outras bandas. A classe Florestal apresentou os menores valores de Reflectância para esta faixa espectral, o que é justificado pela absorção da radiação

eletromagnética por componentes das folhas. Já a classe Campestre apresentou maior valor de Reflectância do que as demais classes na região do visível. Essas formações são caracterizadas pela predominância de solo exposto ou vegetação herbácea.

Nas bandas *Red-Edge*, NIR1 e NIR2 do WorldView-2, a dinâmica da Reflectância foi similar para as 3 classes. Porém, a formação Florestal apresenta valores de Reflectância maiores na região do NIR do que as outras classes. Esse alto valor também foi observado para a banda NIR do Landsat-8. Na região do NIR ocorre uma inversão do comportamento espectral destas classes, ou seja, as formações com maior quantidade de biomassa passam a refletir mais do que as com mais solo exposto.

Com relação a região do SWIR do Landsat-8 pode-se observar maior diferença nos valores de Reflectância entre as classes Savânica e Campestre do que na região do NIR. As regiões Campestres têm cobertura vegetal menor do que as Savânicas, com mais predominância de solo exposto. Enquanto que as regiões Savânicas apresentam stress hídrico maior em relação as regiões Florestais, portanto composta por vegetação mais seca. Neste sentido, a classe de Savana apresenta valores de Reflectância superiores a classe de Floresta na região do SWIR. A Figura 6.2 mostra a dispersão das classes no domínio das bandas *Red* (Vermelho) x NIR.

Figura 6.2: Gráfico de dispersão *Red* x NIR das classes da Legenda N1 para as imagens WorldView-2 e Landsat-8.



Fonte: Produção do Autor.


Segundo Ponzoni e Shimabukuro (2009), a combinação *Red* x NIR pode mostrar pontos relacionados à linha de solo e seu respectivo teor de umidade assim como também a quantidade de biomassa presente na vegetação. Nesta figura, observa-se que as formações Campestres estão mais próximas da linha do solo nas duas imagens. As formações Savânicas estão em um gradiente ascendente para a região de maior biomassa. Essa região apresenta domínio das formações Florestais, por apresentarem dossel praticamente contínuo.

Distância Euclidiana para as classes da Legenda N1:

Um exemplo de cálculo da Distância Euclidiana para as bandas *Red* x NIR foi mostrado para esta legenda. A Figura 6.3 representa a distribuição das classes Campestre, Florestal e Savânica no plano bidimensional composto pelas bandas *Red* e NIR. A partir destas distribuições o centróide de cada classe foi calculado. Considerando estes centróides, a Distância Euclidiana entre pares de classes foi calculada (Figura 6.4). A partir das Distâncias Euclidianas $D_{\text{Landsat-8}}$ e $D_{\text{WorldView-2}}$ para cada combinação de classe, a separabilidade foi analisada (Tabela 6.1).

A Tabela 6.1 mostra que os dados de Reflectância do WorldView-2 apresentam maior separabilidade entre as classes da Legenda N1 para a combinação das bandas *Red* e NIR. Este procedimento foi replicado para as demais combinações de bandas existentes entre os sensores (Azul, Verde, Vermelho e NIR) e os resultados foram similares aos apresentados na Tabela 6.1. Praticamente não houve ocasiões em que $D_{\text{WorldView-2}} < D_{\text{Landsat-8}}$. Os valores de Distância Euclidiana que não foram apresentados nesta seção estão no Apêndice A.

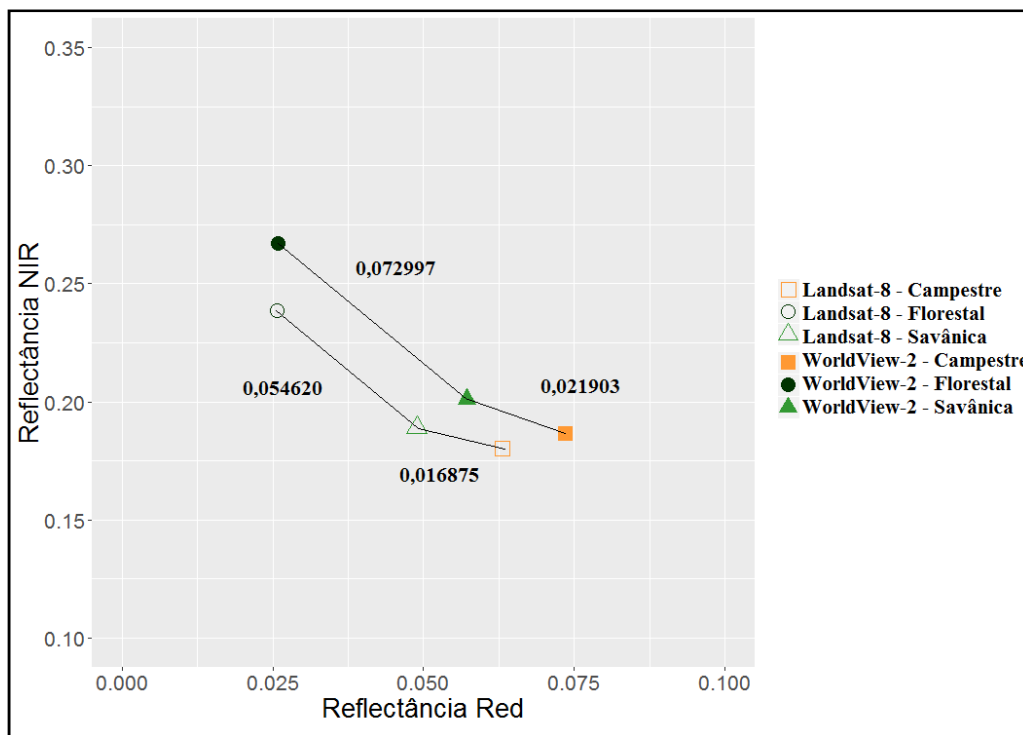
Figura 6.3: Exemplo de cálculo dos centróides para as distribuições das classes da Legenda N1.



a) Distribuição das classes da Legenda N1 para a imagem WorldView-2 b) Cálculo dos centróides de cada classe para a imagem WorldView-2 c) Distribuição das classes da Legenda N1 para a imagem Landsat-8 b) Cálculo dos centróides de cada classe para a imagem Landsat-8.

Fonte: Produção do Autor.

Figura 6.4: Exemplo de cálculo da distância Euclidiana entre as classes de Savana/Floresta e Campo/Savana.



Fonte: Produção do Autor.

Tabela 6.1: Distância Euclidiana para a combinação de bandas *Red* x NIR e entre as classes da Legenda N1.

	Distância Euclidiana entre as classes ($\times 10^{-2}$)		
	Campestre e Savânica	Campestre e Florestal	Savânica e Florestal
WorldView-2	2,1903	9,3574	7,2997
Landsat-8	1,6875	6,9305	5,4462

Fonte: Produção do Autor.

Caracterização para a Legenda N2:

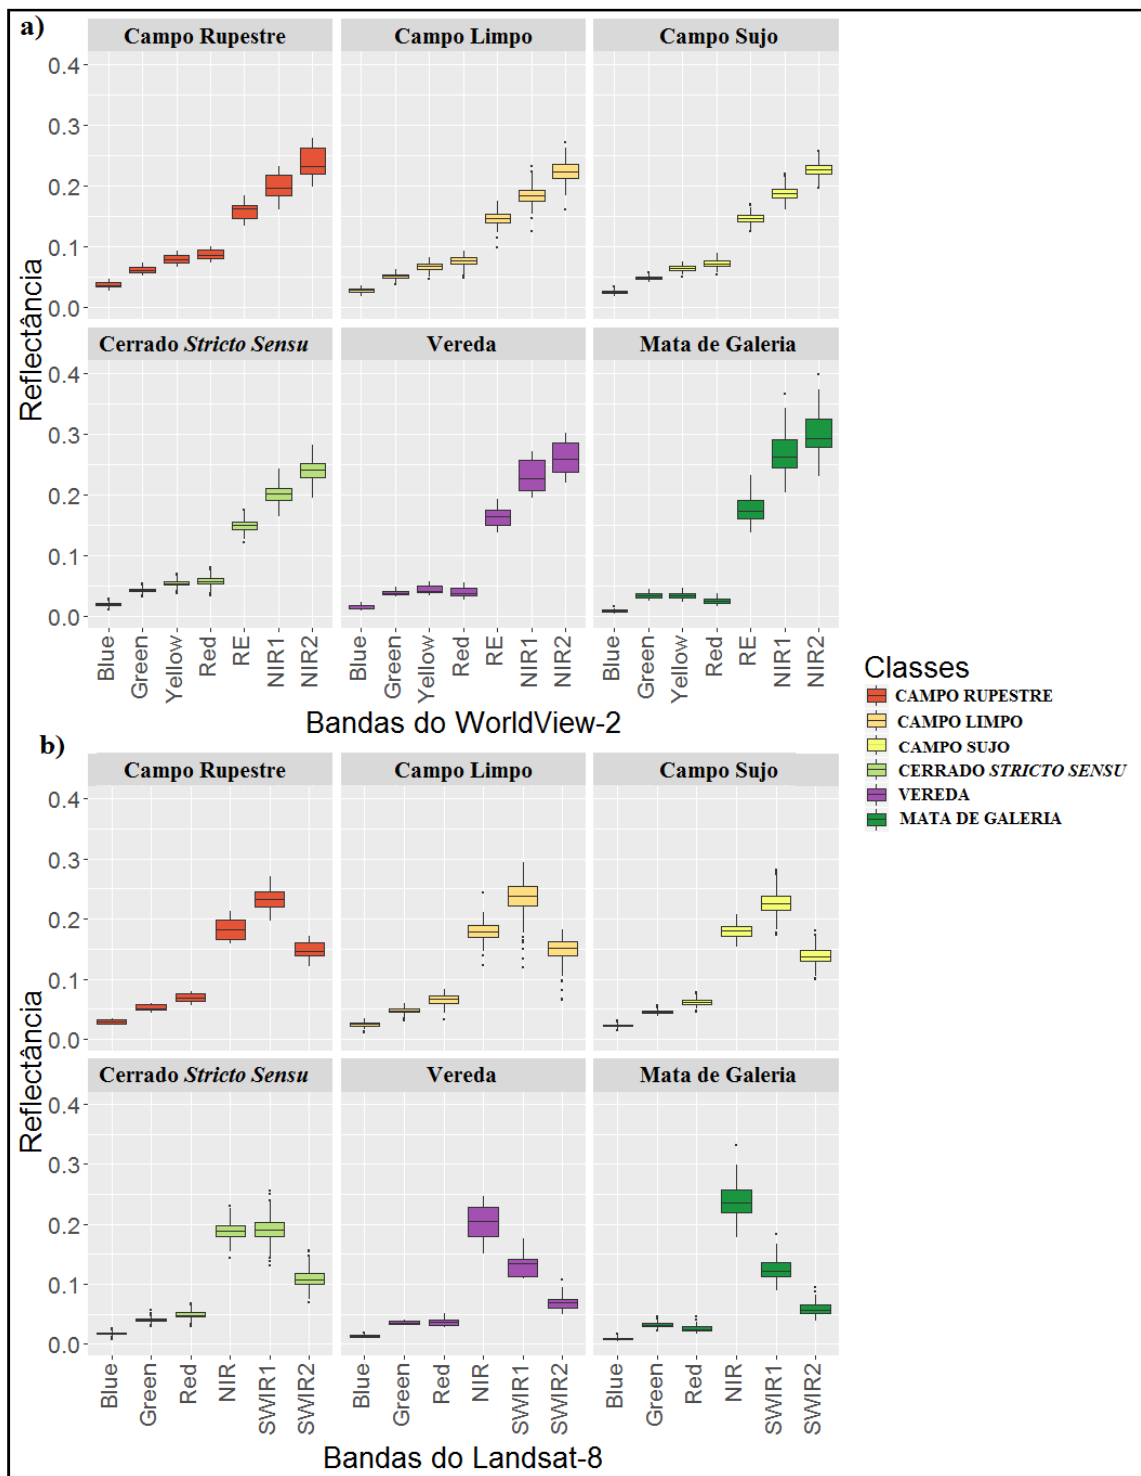
A Figura 6.5 mostra as respostas de Reflectância para as classes da Legenda N2 para as imagens WorldView-2 e Landsat-8. Na região do visível, os valores de Reflectância são baixos para todas as classes e as duas imagens. As classes com os maiores valores de Reflectância nessa região são as classes com predominância de solo exposto, como Campo Rupestre, Campo Limpo e Campo Sujo. Essas três classes apresentaram Reflectância semelhante, mas o WorldView-2 registrou valores de Reflectância um pouco superiores para a classe de Campo Rupestre.

Também foi observado que a classe de Veredas apresentou valores de Reflectância intermediários em relação às Matas de Galeria e o Cerrado *Stricto Sensu*. As Veredas e Mata de Galeria apresentaram valores de Reflectância similares nas bandas *Red-Edge*, NIR1 e NIR2 do WorldView-2. As classes Campo Limpo, Campo Sujo, Campo Rupestre e Cerrado *Stricto Sensu* também apresentaram respostas espectrais semelhantes nestas mesmas bandas, todavia com valores um pouco menores do que para as classes Mata Galeria e Veredas.

Em relação a imagem Landsat-8, as classes de Campo Limpo, Campo Sujo e Campo Rupestre apresentaram valores de Reflectância semelhantes nas bandas NIR, SWIR1 e SWIR2. Da mesma forma as classes Mata Galeria e Veredas apresentaram valores de Reflectância semelhantes para estas mesmas bandas, com valores de Reflectância um pouco maiores para a Classe Mata Galeria na banda NIR. A classe de Cerrado *Stricto Sensu* apresentou dinâmica da Reflectância diferente em relação a banda SWIR1, com valores de Reflectância muito próximos a banda NIR. As demais classes do problema apresentaram diferenças maiores nos valores de Reflectância para estas duas bandas.

As regiões de Vereda apresentam-se circundadas por vegetação arbustiva bastante verde, devido à alta disponibilidade de água, formando o aspecto de um “tapete” verde com agrupamentos de palmeiras. Essa característica da vegetação é responsável pelo valores de Reflectância similares a Mata de Galeria. A região de veredas não ocorre em muitas regiões do PNB e foi de difícil acesso para validação de pontos em campo. As Figuras 6.6 e 6.7 ilustram regiões de Veredas.


Figura 6.5: Caracterização das classes para a Legenda N2 em função da Reflectância.



a) Imagem WorldView-2 e b) Imagem Landsat-8.

Fonte: Produção do Autor.


Figura 6.6: Exemplo de uma região de Vereda na Imagem WorldView-2.



Composição *True Color*.

Fonte: Produção do Autor.

Figura 6.7: Fotos de regiões de Veredas tiradas em campo.



a) Região de Veredas com acesso fácil. b) Solo próximo as Veredas com traços de queimada e presença de água. c) Região de Veredas com acesso difícil.

Fonte: Produção do Autor.

Um fator que influencia o valor de Reflectância da classe de Campo Rupestre é o tipo de solo destas formações. Os solos predominantes na região do PNB são os Latossolos Vermelhos e Latossolos Vermelho-Amarelos, com textura argilosa ou média. Entretanto, as regiões de Campo Rupestre estão presentes, predominantemente, em uma área de Cambissolos com textura variável (argilosa a arenosa) e a presença de cascalho na superfície (FARIAS *et al.*, 2008 - Figura 6.8). Neste sentido, Cambissolos com essas características tendem a ter Reflectância mais elevada do que os Latossolos mencionados para essa região (DEMATTE *et al.*, 2005). Conseqüentemente, a classe de Campo Rupestre tende a apresentar maiores valores de Reflectância do que as classes de Campo Limpo e Sujo, entretanto essa característica espectral só foi verificada para a imagem WorldView-2.

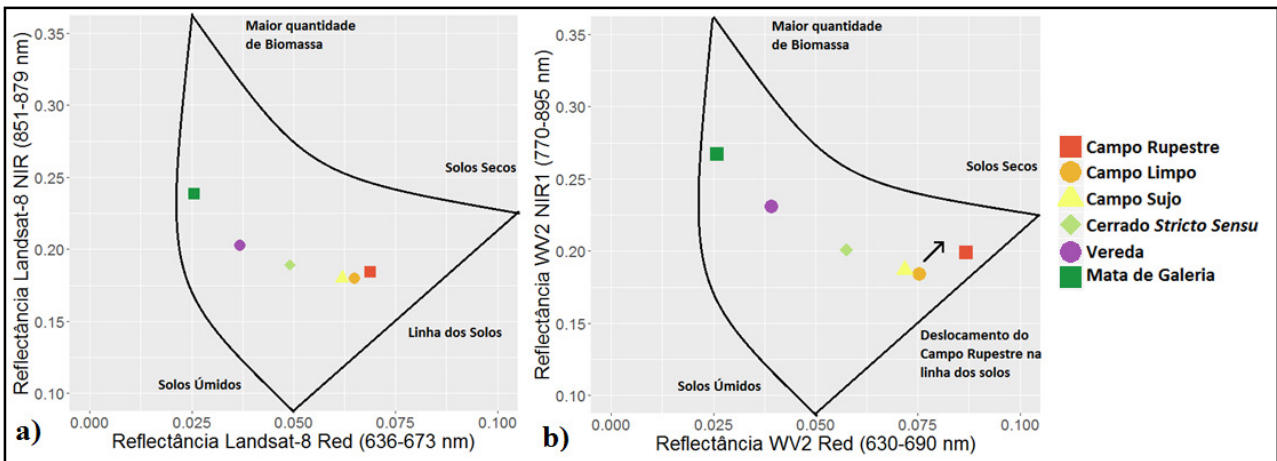
Figura 6.8: Regiões de Campo Rupestre para o Parque Nacional de Brasília.



Fonte: Produção do Autor.

A Figura 6.9 mostra os gráficos de distribuição das classes para as bandas *Red* e *NIR*. Na imagem WorldView-2 existe concentração de pontos da classe Campo Rupestre próximos ao extremo de solo exposto seco na linha dos solos. Já para a imagem Landsat-8 essa dispersão não é tão clara. Para melhor visualizar essa informação, optou-se por mostrar o mesmo gráfico com os centróides de cada uma das distribuições. O centróide relacionado à classe de Campo Rupestre está deslocado na linha dos solos em direção a região de solo exposto seco para os dados da imagem WorldView-2.

Figura 6.9: Gráfico de dispersão *Red x NIR* das classes da Legenda N1.



a) Centróides para as classes do Landsat-8 e b) Centróides para as classes do WorldView-2 com destaque para o deslocamento da classe de Campo Rupestre.

Fonte: Produção do Autor.

Ainda com relação às demais classes, nota-se que o Campo Sujo tem um centróide um pouco acima na linha de biomassa do que o Campo Limpo. Mesmo essa diferença sendo muito pequena ela está coerente, uma vez que existe a presença de arbustos e arvoretas com maior frequência na classe de Campo Sujo. A classe de Cerrado *Stricto Sensu* apresenta formação de dossel em certos pontos e, conseqüentemente, tem maior biomassa que as regiões campestres, assim a diferença para esta fitofisionomia é relevante em relação às classes de Campo Limpo e Campo Sujo.

Distância Euclidiana para as classes da Legenda N2:

A Tabela 6.2 mostra que os dados de Reflectância do WorldView-2 apresentam uma maior separabilidade entre todas as classes da Legenda N2 para a combinação das bandas *Red* e *NIR*. Destaca-se os valores da Distância Euclidiana para a classe Campo Rupestre em comparação as classes Campo Sujo e Campo Limpo, enfatizando sua maior separabilidade com a imagem WorldView-2. Os resultados foram similares para as demais combinações de bandas, enfatizando a maior separabilidade das classes na imagem WorldView-2.

Tabela 6.2: Distância Euclidiana para a combinação de bandas *Red* x *NIR* e entre as classes da Legenda N2⁷.

Imagem	Classe	Distância Euclidiana entre as classes (x10 ⁻²)				
		CRup	CL	CS	CSS	VE
WV2	CL	1,8548				
L8		0,5981				
WV2	CS	1,9244	0,4308			
L8		0,8091	0,2982			
WV2	CSS	2,9399	2,4104	1,9833		
L8		2,0230	1,8247	1,5592		
WV2	VE	5,7554	5,9105	5,4990	3,5608	
L8		3,6979	3,6339	3,3912	1,8561	
WV2	MG	9,1392	9,6296	9,2361	7,3556	3,8276
L8		6,9179	7,0531	6,8695	5,4743	3,7289

WV2 - WorldView-2; L8 - Landsat-8; CRup - Campo Rupestre; CL - Campo Limpo; CS - Campo Sujo; CSS - Cerrado *Stricto Sensu*; MG - Mata de Galeria.

Fonte: Produção do Autor.

Caracterização espectral para a Legenda N3:

A caracterização espectral das classes da Legenda N3 é apresentada na Figura 6.10 para as imagens WorldView-2 e Landsat-8. Para esta legenda a classe de Cerrado *Stricto Sensu* foi fragmentada em suas subdivisões, ou seja, os extratos de Cerrado Ralo, Cerrado Típico e Cerrado Denso. Ribeiro e Walter (2008) apontam que estas classes apresentam uma variação de porcentagem de cobertura de dossel de 5% a 70%. Essa característica é fundamental para avaliação do seus valores de Reflectância.

Para a região do visível, notou-se que essas três classes apresentaram valores de Reflectância baixos e semelhantes. Para a banda Red do WorldView-2 foi possível notar

⁷ Para determinar o valor de Distância Euclidiana basta escolher a classe no eixo Y e a projeção da variável que se deseja comparar no eixo X. Exemplo1: A Distância Euclidiãna entre as classes de Campo Limpo e Campo Rupestre é de 1,8548 para a imagem WorldView-2 e 0,5981 para a imagem Landsat-8. Exemplo2: A Distância Euclidiana entre as classes de Vereda e Campo Sujo é de 5,4990 para a imagem WorldView-2 e 3,3912 para a imagem Landsat-8.


um decaimento sutil da Reflectância para a classe de Cerrado Denso, caracterizando a maior quantidade de vegetação nessa classe.

Considerando as bandas *Red-Edge*, NIR1 e NIR2 do WorldView-2, os valores de Reflectância foram, novamente, muito similares para essas três classes. Pode-se notar que as bandas NIR1 e NIR2 apresentam valores de Reflectância crescentes no sentido da classe de Cerrado Ralo para a classe de Cerrado Denso. Mesmo este aumento sendo bastante sensível, ele retrata o aumento da cobertura arbórea crescente neste mesmo sentido.

Para a imagem Landsat-8, as bandas do SWIR1 e SWIR2 mostram ainda mais a separação destas três classes. Os valores de Reflectância para essas bandas foram inferiores para a classe de Cerrado Denso em relação as outras classes. Esses valores representam a maior quantidade de vegetação nessa faixa espectral. Em contrapartida, a classe de Cerrado Ralo apresentou os maiores valores de Reflectância dentre essas três classes, enfatizando a menor cobertura vegetal nessa classe do que nas demais. Por sua vez, a classe de Cerrado Típico apresentou valores intermediários de Reflectância em relação as classes de Cerrado Ralo e Cerrado Denso. Uma vez que essa classe é composta pela presença de vegetação arbórea e também pontos característicos de solo coberto com vegetação herbácea.

A Figura 6.11 mostra os centróides das distribuições de cada classe desta legenda para combinação de bandas *Red* e NIR, sendo que as classes de Cerrado Ralo, Cerrado Típico e Cerrado Denso encontram-se na linha de aumento de biomassa. O gradiente de vegetação do Cerrado começa baixo para as fitofisionomias de Campo Limpo e Campo Sujo, aumenta para as classes de Cerrado Ralo, Cerrado Típico e Cerrado Denso, na respectiva ordem, e chega as Matas de Galeria.


Figura 6.10: Caracterização das classes para a Legenda N3 em função da Reflectância.



a) Imagem WorldView-2 e b) Imagem Landsat-8.

Fonte: Produção do Autor.

Figura 6.11: Centr ides das classes da Legenda N3 nos gr ficos *Red x NIR*, enfatizando o aumento de biomassa das classes de Cerrado Ralo, Cerrado T pico e Cerrado Denso.



a) Imagem Landsat-8 e b) Imagem WorldView-2

Fonte: Produ o do Autor.

Dist ncia Euclidiana para as classes da Legenda N3:

A Tabela 6.3 mostra que os dados de Reflect ncia do WorldView-2 apresentam uma maior separabilidade entre todas as classes da Legenda N3 para a combina o das bandas *Red* e NIR. Os resultados foram similares para as demais combina es de bandas, enfatizando a maior separabilidade das classes na imagem WorldView-2 (AP NDICE B).

Tabela 6.3: Distância Euclidiana para a combinação de bandas *Red* x NIR e entre as classes da Legenda N3.

Imagem	Classe	Distância Euclidiana entre as classes ($\times 10^{-2}$)						
		CRup	CL	CS	CR	CT	CD	VE
WV2	CL	1,8548						
L8		0,5982						
WV2	CS	1,9244	0,4309					
L8		0,8091	0,2983					
WV2	CR	2,3092	1,4095	0,9800				
L8		1,3872	1,0716	0,7903				
WV2	CT	3,1214	2,6534	2,2264	1,2487			
L8		2,2207	2,0420	1,7790	1,0010			
WV2	CD	4,2198	3,9664	3,5404	2,5631	1,3144		
L8		2,9571	2,8305	2,5744	1,8006	0,7996		
WV2	VE	5,7554	5,9105	5,4990	4,5469	3,3233	2,0730	
L8		3,6979	3,6340	3,3913	2,6324	1,6373	0,8487	
WV2	MG	9,1393	9,6296	9,2361	8,3161	7,1243	5,9005	3,8276
L8		6,9180	7,0531	6,8696	6,1996	5,2727	4,5479	3,7290

WV2 - WorldView-2; L8 - Landsat-8; Crup - Campo Rupestre; CL - Campo Limpo; CS - Campo Sujo; CR - Cerrado Ralo; CT - Cerrado Típico; CD - Cerrado Denso; MG - Mata de Galeria.

Fonte: Produção do Autor.


Caracterização espectral para a Legenda N4:

A Legenda N4 introduziu as classes de Campo Limpo Úmido e Campo Limpo Úmido com Murundu, ilustradas na Figura 6.12. Para estas classes, a presença de água é um fator determinante para a sua caracterização espectral. A umidade presente no solo e na vegetação tende a reduzir a Reflectância em todas as faixas do espectro.

As Figura 6.13 e 6.14 mostram que os valores de Reflectância são semelhantes para as classes de Campo Limpo Úmido e Campo Limpo Úmido com Murundu na região do visível, sendo que os valores de Reflectância foram baixos e inferiores aos da classe de Campo Limpo. As bandas *Red-Edge*, NIR1 e NIR2 se apresentaram valores de

Reflectância inferior para a classe de Campo Limpo Úmido em relação a classe de Campo Limpo úmido com Murundu na imagem WorldView-2. A Figura 6.15 mostra o deslocamento da classe de Campo Limpo Úmido na linha dos solos em direção a região com maior umidade.

Figura 6.12: Classes de Campo Limpo Úmido com Murundu e Campo Limpo Úmido.




a) Campo Limpo Úmido com Murundu e b) Campo Limpo Úmido.

Fonte: Produção do Autor.


Para a imagem Landsat-8, os valores da banda NIR para estas classes também foram parecidos, entretanto as banda do SWIR1 e SWIR2 destacaram valores de Reflectância diferenciados destas classes em relação as classes de Campo Limpo e Campo Sujo. Os valores de Reflectância nestas bandas para as classes de Campo Limpo Úmido e Campo Limpo Úmido com Murundu se assemelharam mais aos valores das classes de Cerrado Ralo e Cerrado Típico.

Figura 6.13: Caracterização das classes para a Legenda N4 em função da Reflectância para a imagem WorldView-2



Fonte: Produção do Autor.

Figura 6.14: Caracterização das classes para a Legenda N4 em função da Reflectância para a imagem Landsat-8.



Fonte: Produção do Autor.

Figura 6.15: Centróides das classes da Legenda N4 no gráfico *Red x NIR*, com destaque para o deslocamento da classe de Campo Limpo Úmido para regiões de solos úmidos.



Fonte: Produção do Autor.

Distância Euclidiana para as classes da Legenda N4:

A Tabela 6.4 mostra que os dados de Reflectância do WorldView-2 apresentam maior separabilidade entre todas as classes da Legenda N4 para a combinação das bandas *Red* e NIR. Estes resultados ainda mostram que existiu baixos valores de Distância Euclidiana para as classes de Campo Limpo Úmido e Campo Limpo Úmido com Murundu em relação as classes de Campo Sujo, Cerrado Ralo e Cerrado Típico, enfatizando a similaridade entre elas com dados de Reflectância.

Tabela 6.4: Distância Euclidiana para a combinação de bandas *Red* x NIR e entre as classes da Legenda N4.

Imagem	Classe	Distância Euclidiana entre as classes ($\times 10^{-2}$)								
		CLU	CLU _{CM}	CRup	CL	CS	CR	CT	CD	VE
WV2	CLU _{CM}	2,8836								
L8		2,0995								
WV2	CRup	3,5327	2,3219							
L8		2,1237	1,6844							
WV2	CL	2,1016	2,6170	1,7178						
L8		1,9615	2,0895	0,5507						
WV2	CS	1,6188	1,8408	1,9244	0,9304					
L8		1,3147	1,5281	0,8091	0,7759					
WV2	CR	1,8727	1,0273	2,3092	1,8903	0,9800				
L8		1,1611	0,9764	1,3872	1,5445	0,7903				
WV2	CT	2,7894	0,8372	3,1214	3,1186	2,2264	1,2487			
L8		1,7862	0,7900	2,2207	2,4967	1,7790	1,0010			
WV2	CD	3,9506	1,9273	4,2198	4,4250	3,5404	2,5631	1,3144		
L8		2,4767	1,3340	2,9571	3,2754	2,5744	1,8006	0,7996		
WV2	VE	6,0236	3,7151	5,7554	6,3283	5,4990	4,5469	3,3233	2,0730	
L8		3,3117	2,0181	3,6979	4,0620	3,3913	2,6324	1,6373	0,8487	
WV2	MG	9,8509	7,4042	9,1393	10,0061	9,2361	8,3161	7,1243	5,9005	3,8276
L8		7,0238	5,3453	6,9180	7,3985	6,8696	6,1996	5,2727	4,5479	3,7290

Crup - Campo Rupestre; CLU - Campo Limpo Úmido; CLU_{CM} - Campo Limpo Úmido com Murundu; CL - Campo Limpo; CS - Campo Sujo; CR - Cerrado Ralo; CT - Cerrado Típico; CD - Cerrado Denso; MG - Mata de Galeria.

Fonte: Produção do Autor.

6.2 Modelo linear de mistura espectral

Esta seção apresenta a caracterização das fitofisionomias do Cerrado em relação às componentes de solo, sombra e vegetação do MLME.


Caracterização das componentes do MLME para a Legenda N1:

A Figura 6.16 representa a caracterização das fitofisionomias em função das componentes Solo, Vegetação e Sombra do MLME, para a Legenda N1. No Apêndice B, alguns resultados complementares são apresentados.

Como esperado a classe de Floresta apresenta valores da componente Vegetação altos, com ausência de Solo exposto. Uma região de floresta também apresenta valores altos da componente de sombra, uma vez que a diferença entre altura, idade e espécie das árvores gera textura mais rugosa, e, conseqüentemente, regiões escuras (sombra) na imagem. O valor médio da componente de sombra na imagem WorldView-2 foi de cerca de 40% e para a imagem Landsat-8 foi 25%. A alta resolução espacial do WorldView-2 mostrou a capacidade de detectar pixels mais puros da componente de sombra, gerando assim valores médios maiores do que o Landsat-8.

Para as formações Campestres este resultado foi praticamente inverso. Essa classe apresentou valores altos da componente de solo e baixos para a componente de vegetação. A ausência de vegetação arbórea nessa classe também influenciou diretamente na geração de elementos de sombra, sendo praticamente inexistentes para as formações campestres. A classe de formações savânicas apresentam valores intermediários de todas as componentes do MLME, indicando a mistura entre solo e vegetação comentada anteriormente. A Figura 6.17 mostra a dispersão destas classes para as componentes de sombra e vegetação.


Figura 6.16: Caracterização das classes em termos das componentes de solo, sombra e vegetação para a Legenda N1.



a) WorldView-2 e b) Landsat-8.

Fonte: Produção do Autor.

Figura 6.17: Dispersão das classes da Legenda N1 para as componentes de sombra e vegetação.



a) Imagem WorldView-2 e b) Imagem Landsat-8.

Fonte: Produção do Autor.

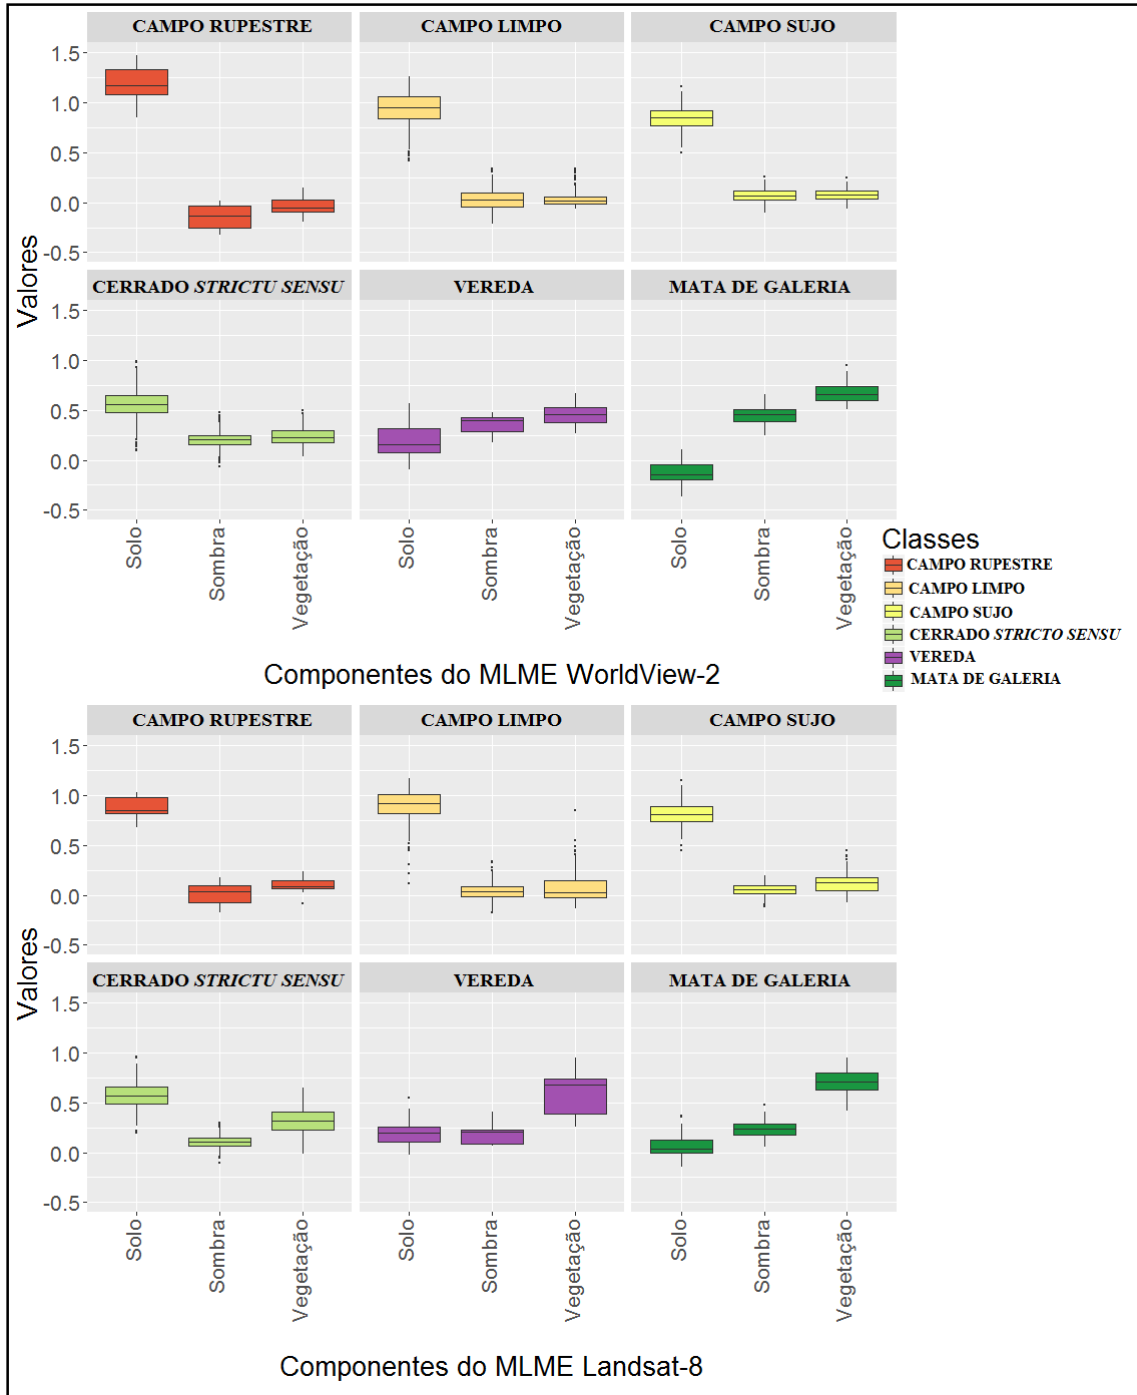
Caracterização das componentes do MLME para a Legenda N2:

De forma geral, os gráficos na Figura 6.18, mostram que as componentes Solo e Vegetação ou Solo e Sombra podem discriminar melhor as classes e Campo Rupestre, Campo Limpo e Campo Sujo, na imagem WorldView-2. Essas classes também apresentaram valores das componentes de Sombra e Vegetação muito baixos, indicando a ausência destes elementos para essas classes e o potencial de diferenciá-las de classes com uma maior quantidade de vegetação, com as classes de Mata de Galeria e Veredas. Os gráficos de dispersão entre as componentes de Sombra e Vegetação mostram essa separabilidade, ressaltando uma concentração de pontos da classe de Campo Rupestre próximos a origem para os dados da imagem WorldView-2 (Figura 6.19).

As classes de Cerrado *Stricto Sensu* e Veredas apresentaram variações menores entre as componentes MLME do que as classes anteriores. Os atributos Sombra, Vegetação e Solo na imagem Landsat-8 apresentaram menor variação para todas as classes, indicando que pode ocorrer dificuldade na discriminação das mesmas. A diferença entre os valores das componentes MLME é baixa para o Landsat-8 em comparação ao WorldView-2. A Figura 6.19 ainda mostra que houve dificuldade visual

em distinguir algumas classes com os componentes de Sombra e Vegetação na imagem Landsat-8.


Figura 6.18: Caracterização das classes em termos das componentes de solo, sombra e vegetação para a Legenda N2.



a) Imagem WorldView-2 e b) Imagem Landsat-8.

Fonte: Produção do Autor.

Figura 6.19: Dispersão das classes da Legenda N2 para as componentes de sombra e vegetação.




a) Imagem WorldView-2 e b) Imagem Landsat-8.

Fonte: Produção do Autor.

Caracterização das componentes do MLME para a Legenda N3:

Nos gráficos da Figura 6.20, pode-se observar que a componentes de Sombra apresentou praticamente os mesmos valores para as classes de Cerrado Ralo, Cerrado Típico e Cerrado Denso para ambas as imagens, não sendo útil para discriminá-las. Houve uma variação maior para a componente de Vegetação para estas classes considerando a imagem do Landsat-8, sendo que os valores foram maiores para a classe de Cerrado Denso. A componente de Solo apresentou boa capacidade em discriminar estas fitofisionomias em ambas as imagens, uma vez que sua variação foi inversamente proporcional a componente de Vegetação. A classe de Cerrado Denso, que apresentou maior valor na componente de Vegetação, apresentou o menor valor da componente de Solo. Para o Cerrado Ralo esse comportamento foi inverso. Já o Cerrado Típico sempre apresentou valores para as componentes do MLME entre os valores obtidos por estas duas classes, enfatizando a mistura de solo com vegetação nessa classe.

Figura 6.20: Caracterização das classes em termos das componentes de solo, sombra e vegetação para a Legenda N3.




a) Imagem WorldView-2 e b) Imagem Landsat-8.

Fonte: Produção do Autor.

Caracterização das componentes do MLME para a Legenda N4:


As classes de Campo Limpo Úmido e Campo Limpo Úmido com Murundu apresentaram resultados similares em relação a componente de Solo do MLME, para ambas as imagens (Figuras 6.21 e 6.22). Entretanto, as componentes de Sombra e Vegetação apresentaram comportamento inverso para ambas as classes. A classe de Campo Limpo Úmido com Murundu apresentaram maiores valores da componente de Vegetação para ambas as imagens. Os maiores valores dessa componente indicam maior presença de vegetação nessa classe do que na classe de Campo Limpo Úmido. As componentes Sombra e Vegetação, sutilmente, aparentam ser melhores para discriminar estas duas classes usando imagem WorldView-2.

Figura 6.21: Caracterização das classes em termos das componentes de solo, sombra e vegetação para a Legenda N4 para a imagem WorldView-2.



Fonte: Produção do Autor.

Figura 6.22: Caracterização das classes em termos das componentes de solo, sombra e vegetação para a Legenda N4 para a imagem Landsat-8.



Fonte: Produção do Autor.

6.3 Caracterização da transformada *Tasseled Cap*

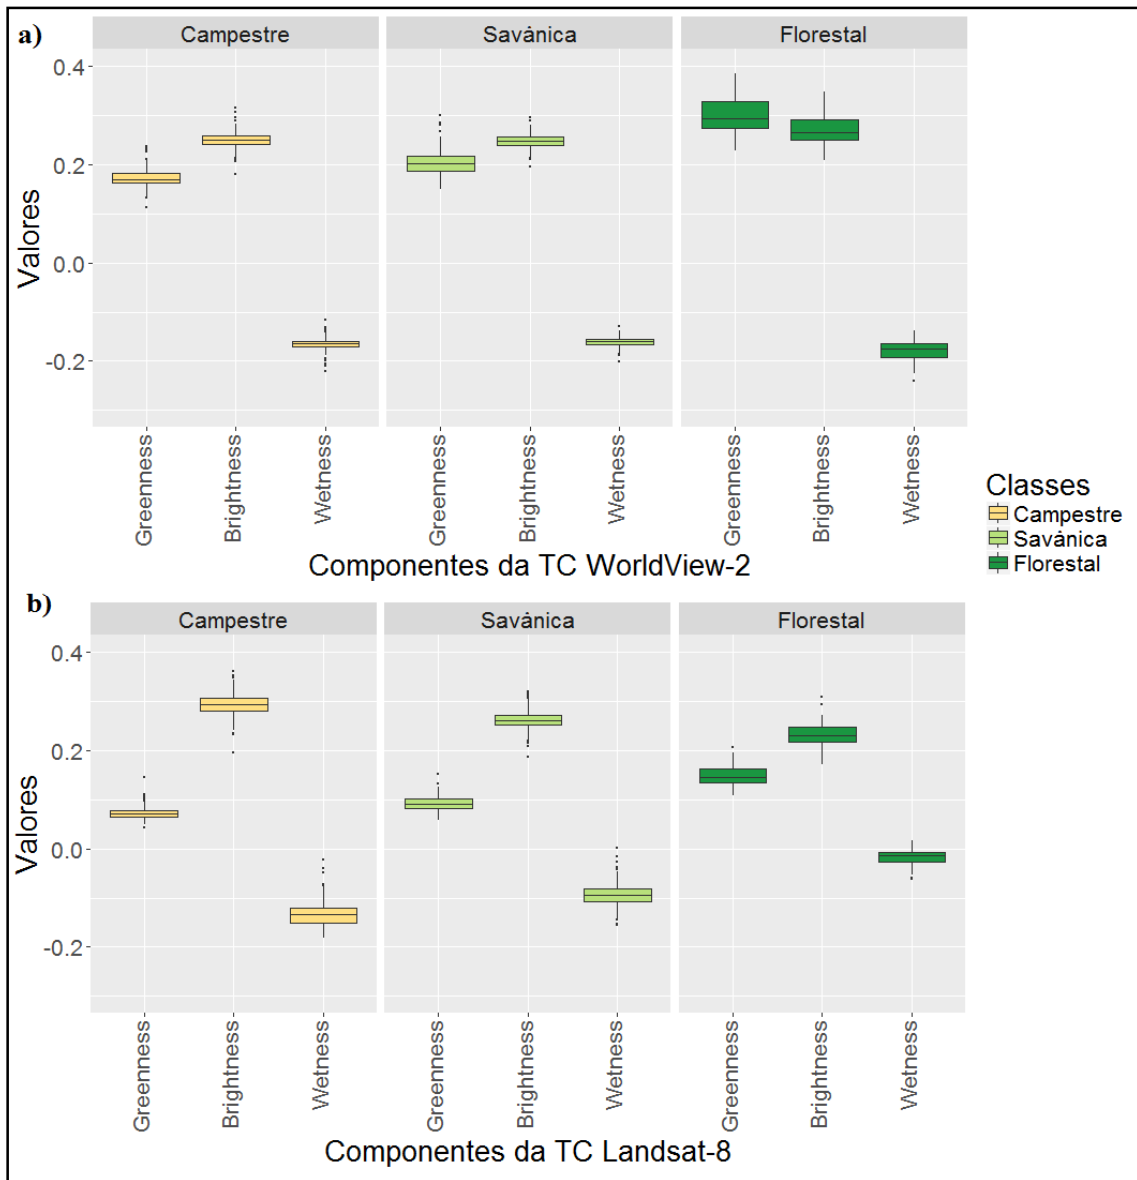
Esta seção mostra a caracterização das fitofisionomias do Cerrado Brasileiro com base nas componentes de *Greenness*, *Brightness* e *Wetness* da Transformada *TC*. As componentes *TC* foram calculadas com todas as bandas do WorldView-2 e Landsat-8 (exceto as bandas *Coastal*).

Caracterização das componentes da Transformada TC a Legenda N1:

Os valores das componentes de *Greenness* foram muito similares para ambos os sensores, sendo que as formações Florestais sempre obtiveram valores mais elevados do que as demais classes. Por sua vez, as formações Campestres obtiveram os valores médios mais baixos dessa componente e as formações Savânicas obtiveram valores intermediários as demais classes (Figura 6.23).

As componentes de *Brightness* e *Wetness* apresentaram maiores variações nas imagens do Landsat-8. Para essa imagem ainda foi verificado uma relação inversamente proporcional para estas componentes. A medida que a classe Campestre apresentou maior valor da componente de *Brightness* e menor valor da componente de *Wetness*, a classe Florestal apresentou menor valor da componente de *Brightness* e maior valor da componente de *Wetness*. Para a imagem WorldView-2 Essas componentes apresentaram valores muito próximos para todas as classes, mostrando menor potencial em distinguir essas classes.

Figura 6.23: Caracterização das classes em termos das componentes de *Greenness*, *Brightness* e *Wetness* na Legenda N1.



a) Imagem WorldView-2 e b) Imagem Landsat-8.


Fonte: Produção do Autor.

Caracterização das componentes da Transformada TC a Legenda N2:

A Figura 6.24 mostra que as componentes de *Brightness* e *Wetness* para a imagem do WorldView-2 apresentaram valores médios muito próximos para todas as fitofisionomias. A componente de *Greenness* obteve valores mais elevados para as classes de Mata de Galeria e Veredas, mostrando a capacidade de separar fitofisionomias com alta quantidade de biomassa.

Para as componentes *TC* da imagem Landsat-8, notou-se que as classes de Campo Limpo, Campo Sujo e Campo Rupestre apresentaram valores similares para as três componentes da Transformada *TC*. Considerando as classes de Veredas e Matas de Galeria, ocorre uma diminuição nos valores da componente de *Brightness* (devido à redução de componentes de solo exposto nestas regiões) e aumento das componentes de *Wetness* e *Greenness*, justamente pela presença de uma vegetação com mais vigor vegetativo.

Figura 6.24: Caracterização das classes em termos das componentes de *Greenness*, *Brightness* e *Wetness* na Legenda N2.



a) Imagem WorldView-2 e b) Imagem Landsat-8.


Fonte: Produção do Autor.

Caracterização das componentes da Transformada TC para a Legenda N3:

A Figura 6.25 mostra que as componentes de *Brightness* e *Wetness* para a imagem WorldView-2 apresentaram valores muito próximos para as classes de Cerrado Ralo, Cerrado Típico e Cerrado Denso. A componente de *Greenness* apresentou variação maior para fitofisionomias como Mata de Galeria e Veredas, mas carece no potencial de discriminar as classes de Cerrado Ralo, Cerrado Típico e Cerrado Denso.

Para a imagem Landsat-8 as três componentes apresentaram diferenças sutis na componente de *Brightness* e *Wetness* para as classes de Cerrado Ralo, Cerrado Típico e Cerrado Denso. A diferença de vegetação entre essas três classes não foi caracterizada pela componente de *Greenness* para o Landsat-8, uma vez que os valores desta componente foram praticamente os mesmos.

Figura 6.25: Caracterização das classes em termos das componentes de *Greenness*, *Brightness* e *Wetness* na Legenda N3.



a) Imagem WorldView-2 b) Imagem Landsat-8


Fonte: Produção do Autor.

Caracterização das componentes da Transformada TC a Legenda N4:

A Figura 6.26 mostra que a combinação das componentes de *Brightness* e *Wetness* contribuem mais para a separabilidade das classes Campo Limpo Úmido e Campo Limpo Úmido com Murundu, na imagem Landsat-8. Essas classes ainda apresentaram valores mais elevados da componente de *Wetness* do que as classes de Campo Limpo e Campo Sujo.


As componentes de *Greenness*, *Brightness* e *Wetness* apresentaram valores muito próximos para as classes de Campo Limpo Úmido e Campo Limpo Úmido com Murundu para a imagem WorldView-2 (Figura 6.27).

Figura 6.26: Caracterização das classes em termos das componentes de *Greenness*, *Brightness* e *Wetness* na Legenda N4 para a imagem WorldView-2.



Fonte: Produção do Autor.

Figura 6.27: Caracterização das classes em termos das componentes de *Greenness*, *Brightness* e *Wetness* na Legenda N4 para a imagem Landsat-8.




Fonte: Produção do Autor.

6.4 Índices de vegetação

Os cinco Índices de Vegetação (NDVI, EVI, EVI2, SAVI e MSAVI2) apresentaram valores altos para o coeficiente de correlação de *Pearson* (Figura 6.28). Este coeficiente foi calculado entre todos os índices e apenas com os dados observados. Portanto, a caracterização das fitofisionomias do Cerrado foi feita somente para o atributo NDVI (*Normalized Difference Vegetation Index*).

Figura 6.28: Correlação entre os Índices de Vegetação das imagens WorldView-2 e Landsat-8.




Fonte: Produção do Autor.

Caracterização do NDVI para a Legenda N1:

A Figura 6.29 mostra os valores de NDVI para as fitofisionomias na Legenda N1 e para as imagens WorldView-2 e Landsat-8. As formações Florestais apresentaram maiores valores do NDVI, devido a maior presença de vegetação nessa classe do que nas demais. Em contrapartida, a classe Campestre teve os menores valores e menor variação deste atributo (*boxplot* com menor amplitude). As classes Campestre e Savânica representam fitofisionomias mais detalhadas, o que pode justificar a maior variabilidade do NDVI.

Existe limitação no uso do NDVI devido ao comportamento espectral assintótico da vegetação na transição do visível (vermelho) para a região do NIR, que pode levar à saturação do NDVI para altos valores de biomassa ou índice de área foliar (TUCKER, 1979). Todavia, para as imagens usadas neste trabalho, não foi verificada a saturação os valores obtidos de NDVI saturação.

Figura 6.29: Caracterização das classes da Legenda N1 em função do NDVI.




a) Imagem WorldView-2 e b) Imagem Landsat-8.

Fonte: Produção do Autor.

Caracterização do NDVI para a Legenda N2:

A Figura 6.30 mostra a caracterização das fitofisionomias para a Legenda N2, em função dos valores de NDVI. As classes Campo Rupestre, Campo Limpo e Campo Sujo apresentaram baixos valores de NDVI, com valores mais próximos entre si o que pode dificultar a separabilidade entre estas 3 classes. Por outro lado, o valor de NDVI para as classes de Cerrado *Stricto Sensu*, Veredas e Mata de Galeria foram um pouco maiores e distintos para as duas imagens, favorecendo a discriminação entre estas classes. Pode-se observar que classe Campo Limpo apresentou grande quantidade de *outliers*.

Figura 6.30: Caracterização das classes da Legenda N2 em função do NDVI.



a) Imagem WorldView-2 e b) Imagem Landsat-8.


Fonte: Produção do Autor.

Caracterização do NDVI para a Legenda N3:

A caracterização das fitofisionomias esta legenda destacou as classes de Cerrado Ralo, Cerrado Típico e Cerrado Denso (Figura 6.31). O *boxplot* amplo para a classe de Cerrado *Stricto Sensu* da legenda N2 anterior se desfez e foram gerados *boxplots* mais específicos para cada uma de suas subclasses. Esses gráficos seguiram o padrão de

aumento de biomassa destas fitofisionomias, com menores valores NDVI para a classe de Cerrado Ralo e maiores valores de NDVI para a classe de Cerrado Denso.

Figura 6.31: Caracterização das classes da Legenda N3 em função do NDVI.




a) Imagem WorldView-2 e b) Imagem Landsat-8.

Fonte: Produção do Autor.

Caracterização do NDVI para a Legenda N4:

Com as classes de Campo Limpo Úmido e Campo Limpo Úmido com Murundu, o alto número de *outliers* para a classe de Campo Limpo desapareceu (Figura 6.32). Entretanto um *boxplot* muito amplo foi gerado para a classe de Campo Limpo Úmido, o que indicou que existe heterogeneidade para a mesma. Essa conclusão está correta pois as regiões de Campo Limpo Úmido podem apresentar vegetação herbácea alta (circundando as Veredas) ou gramínea baixa. Já a classe de Campo Limpo Úmido com Murundu não apresentou uma variabilidade tão grande, sendo que sua distribuição assemelhou-se muito as distribuições das classes de Cerrado Ralo e Cerrado Típico.

Figura 6.32: Caracterização das classes da Legenda N4 em função do NDVI.



a) Imagem WorldView-2 e b) Imagem Landsat-8.

Fonte: Produção do Autor.

7 CLASSIFICAÇÃO BASEADA NO *RANDOM FOREST*

Este capítulo apresenta os resultados da classificação das imagens Landsat-8 e WorldView-2 usando o algoritmo *Random Forest*, de acordo com a metodologia descrita na seção 5.7. A avaliação da classificação é baseada nas médias das medidas de Taxa de Acerto Global (TA), Taxa de Acerto da Classe (TAC) e Erros de Omissão (EO) e também no desvio padrão destas medidas. Essas análises foram feitas para as Legendas N1-N4 de maneira incremental. Para as análises subsequentes, as medidas de avaliação dos classificadores foram comparadas por um teste de significância (teste-t) (BUSSAB; MORETTIN, 2010).

7.1 Classificação para a Legenda N1:

Landsat-8:

Os resultados da classificação da imagem Landsat-8 para a Legenda N1 são apresentados na Tabela 7.1. A TA para o conjunto contendo apenas as bandas Azul, Verde e Vermelho⁸ foi de 83,63%. A classe Campestre apresentou uma TAC inferior as demais classes nesta Legenda, a qual foi de 75,08%. As classes Savânica e Florestal obtiveram valores de TAC de 85,75% e 88,71%, respectivamente.

A inclusão da banda NIR aumentou a TA para 85,09%, sendo que a classe que apresentou melhora mais significativa foi a classe Florestal, a qual passou a ter uma TA de 92,39%. A região espectral do NIR representou uma mudança drástica nos valores de Reflectância da vegetação, obtendo valores mais elevados de Reflectância do que as demais classes. Em contrapartida, a inclusão das bandas SWIR1 e SWIR2 aumentou a TA para 86,23%, sendo que o maior ganho em TA foi para a classe Campestre (78,17%). Nesta região do espectro, essa classe mostrou maiores valores de Reflectância, enquanto que estes valores foram mais baixos para as classes Savânica e Florestal. Desta maneira, a melhor separabilidade desta classe nessa faixa espectral.

Quando todos os atributos de Reflectância foram utilizados, os ganhos trazidos pelas bandas NIR, SWIR1 e SWIR2 foram combinados. Em comparação ao conjunto RGB,

⁸ O conjunto contendo as bandas Azul, Verde e Vermelho foi chamado de conjunto RGB.

as TA de todas as classes apresentaram médias estatisticamente superiores ⁹com o uso de todas as bandas espectrais. A TA foi de 86,11%, sendo que não apresentou diferença estatística em relação a TA obtida pelo conjunto com as bandas do SWIR. Entretanto, o uso de todas as bandas espectrais apresentou uma TAC da classe Florestal maior (93,50%), justamente pelo efeito da banda NIR para essa classe.

Tabela 7.1: Avaliação da classificação para a Legenda N1 – imagem Landsat-8.

Conjunto	Classes	TAC	EO	Taxa de acerto Global
RBG	Campestre	75,08 ± 0,77	24,92 ± 0,77	83,63 ± 0,52
	Savânica	87,57 ± 0,45	12,43 ± 0,45	
	Florestal	88,71 ± 0,73	11,29 ± 0,73	
RGB +NIR	Campestre	75,83 ± 0,48	24,17 ± 0,48	85,09 ± 0,33
	Savânica	88,91 ± 0,36	11,09 ± 0,36	
	Florestal	92,39 ± 0,35	7,61 ± 0,35	
RBG +SWIR	Campestre	78,17 ± 0,41	21,83 ± 0,41	86,23 ± 0,25
	Savânica	89,85 ± 0,36	10,15 ± 0,36	
	Florestal	90,52 ± 0,70	9,48 ± 0,70	
Reflectância	Campestre	77,42 ± 0,35	22,58 ± 0,35	86,11 ± 0,29
	Savânica	89,60 ± 0,53	10,40 ± 0,53	
	Florestal	93,50 ± 0,00	6,50 ± 0,00	
Reflectância +MLME	Campestre	77,75 ± 0,55	22,25 ± 0,55	86,21 ± 0,25
	Savânica	89,51 ± 0,30	10,49 ± 0,30	
	Florestal	94,05 ± 0,58	5,95 ± 0,58	
Reflectância +TC	Campestre	77,90 ± 0,63	22,07 ± 0,64	86,20 ± 0,35
	Savânica	89,32 ± 0,39	10,68 ± 0,39	
	Florestal	94,60 ± 0,00	5,40 ± 0,00	
Reflectância +IVs	Campestre	77,99 ± 0,77	22,01 ± 0,77	86,87 ± 0,27
	Savânica	90,62 ± 0,36	9,38 ± 0,36	
	Florestal	93,30 ± 0,42	7,70 ± 0,42	
TODOS	Campestre	79,19 ± 0,95	21,81 ± 0,95	87,30 ± 0,46
	Savânica	90,57 ± 0,42	9,43 ± 0,42	
	Florestal	94,16 ± 0,56	5,64 ± 1,17	

+MLME – adição do conjunto com dados do Modelo Linear de Mistura Espectral; +TC – adição do conjunto com dados da Transformada *Tasseled Cap*; +IVs adição do conjunto com dados dos Índices de Vegetação; +NIR – Adição da banda NIR; +SWIR – Adição das bandas SWIR1 e SWIR2.

Fonte: Produção do Autor.

⁹ O p valor para o teste-t entre o conjunto RGB e o conjunto RGB+NIR foi de $3 \cdot 10^{-7}$, enquanto que o p valor entre o conjunto RGB e o conjunto RGB+SWIR foi de $4 \cdot 10^{-5}$.

A adição das componentes do MLME e Transformada TC, separadamente, ao conjunto de Reflectância não melhorou a taxa de acerto da classificação. Entretanto, a adição dos Índices de Vegetação apresentou TA estatisticamente superior (p valor do teste-t = $5,74 * 10^{-6}$) ao conjunto de Reflectância, chegando a 86,87%. O uso destes índices na classificação melhorou a TA da classe Savânica, reduzindo os erros de omissão. Estes resultados estão consistentes com os resultados obtidos por Liesenberg *et al.* (2007a) Carvalho *et al.* (2010) e Costa *et al.* (2014).

A inclusão de todos os atributos levou à melhoria na classificação, com uma TA de 87,30%, que é estatisticamente superior a todas as demais combinações de atributos (p valor do teste-t = $1,11 * 10^{-6}$). A matriz de confusão ilustrada na Tabela 7.2 mostra o do melhor resultado de classificação (melhor TA dentre as dez vezes que este classificador foi gerado), obtido com todos os atributos.

Tabela 7.2: Matriz de confusão para a imagem Landsat-8 – Legenda N1.

		Classe Real		
		Campestre	Savana	Florestal
Predição	Campestre	269	52	0
	Savana	65	579	5
	Florestal	1	3	88

Fonte: Produção do Autor.

De maneira geral, os dados Landsat-8, mesmo quando apenas o conjunto RGB é utilizado na classificação, podem distinguir com boa precisão as classes do Cerrado da Legenda N1. Considerando os resultados da classificação com todos os atributos, a classe Florestal obteve TAC de 94,16%, a qual é superior a trabalhos com imagens de resolução espacial inferior, como Borges e Sano (2014) com TAC de 88% e também a grandes projetos de mapeamento do Cerrado, como o Probio com TAC de 52% (Sano *et al.*, 2008) e TerraClass Cerrado com TAC de 62% (MMA, 2015). Muller *et al.* (2015) obtiveram TAC de 91% para esta mesma classe.

A classificação da classe Savânica obteve TAC de 90,57%. Este resultado é novamente superior aos trabalhos discutidos no parágrafo anterior, com exceção dos resultados obtidos por Muller *et al.* (2015). Entretanto, os autores utilizaram séries temporais de 3 anos de imagens *Landsat-like* para obter uma TAC de 93% para essa

classe. Por sua vez, a classe Campestre obteve a menor TAC (79,19%), valor que ainda é superior aos registrados por Sano *et al.* (2008), MMA (2015) e Borges e Sano (2014). Muller *et al.* (2015) obtiveram valores novamente superiores aos obtidos neste trabalho (94%), entretanto, além do uso da série temporal, os autores consideraram pastagens cultivadas como pertencentes a classe Campestre para obter estes resultados. Sano *et al.* (2008) aponta que erros entre a classe Campestre e pastagens cultivadas são comuns, conseqüentemente, a alta taxa de acerto obtida por Muller *et al.* (2015).

WorldView-2:

A Tabela 7.3 mostra os resultados da classificação para a imagem WorldView-2 para a Legenda N1. A TA para o conjunto RGB foi de 85,15%. A classe com melhor TAC foi a classe Florestal, com um valor de 94,49%. A TAC foi um pouco inferior para a classe Savânica (89,03%) e os valores mais baixos foram obtidos para a classe Campestre (75,20%). O uso combinado da banda do Amarelo ao conjunto RGB não resultou em uma alteração estatística na TA.

A inclusão das bandas *Red-Edge*, NIR1 e NIR2, mostraram resultados muito similares. Em ambos os casos houve aumento da TA em relação ao conjunto RGB, sendo que o aumento foi maior para a inclusão das bandas NIR1 e NIR2. Houve aumento da TAC para a classe florestal, como aconteceu para a imagem Landsat-8. Porém, a classe Campestre foi a classe que apresentou maior alteração com a inclusão dessas bandas, obtendo TA de 77,66% com a banda *Red-Edge* e TA de 79,91% com as bandas NIR1 e NIR2.

O uso de todas as bandas deste sensor melhorou ainda mais a TA, a qual foi de 88,26%. Os valores de TAC para a classe Campestre foram ainda maiores, chegando a 81,41%. A classe de Florestal também registrou aumento na TAC, atingindo valores de 97,60%. Em contrapartida, não houve ganho para a classe Savânica. Além da variação do comportamento da vegetação discutido para a imagem Landsat-8, a faixa do NIR também registra aumento crescente na Reflectância de regiões de solo exposto até aproximadamente 1350 nm (FORMAGGIO *et al.*, 1996; DEMATTÊ *et al.*, 2005). Conseqüentemente, o uso combinado das bandas *Red-Edge*, NIR1 e NIR2 traz um detalhamento maior dessa faixa espectral e tende a melhorar diferenciação da classe Campestre da Savânica e Florestal.

Tabela 7.3: Avaliação da classificação para a Legenda N1 – imagem WorldView-2.

Conjunto	Classes	TAC	EO	Taxa de acerto Global
RBG	Campestre	75,20 ± 0,53	24,80 ± 0,53	85,15 ± 0,17
	Savânica	89,03 ± 0,32	10,97 ± 0,32	
	Florestal	94,49 ± 0,81	5,51 ± 0,81	
RGB +Amarelo	Campestre	75,71 ± 0,68	24,29 ± 0,68	84,87 ± 0,34
	Savânica	88,26 ± 0,38	11,74 ± 0,38	
	Florestal	94,71 ± 0,35	5,29 ± 0,35	
RGB +RE	Campestre	77,66 ± 0,44	22,34 ± 0,44	86,79 ± 0,23
	Savânica	90,29 ± 0,34	9,71 ± 0,34	
	Florestal	95,70 ± 0,73	4,30 ± 0,73	
RGB +NIR	Campestre	79,91 ± 1,03	20,09 ± 1,03	87,54 ± 0,35
	Savânica	90,36 ± 0,16	9,64 ± 0,16	
	Florestal	95,91 ± 0,84	4,09 ± 0,84	
Reflectância	Campestre	81,41 ± 0,47	18,59 ± 0,47	88,26 ± 0,20
	Savânica	90,50 ± 0,36	9,50 ± 0,36	
	Florestal	97,60 ± 0,42	2,40 ± 0,42	
Reflectância +MLME	Campestre	80,27 ± 0,80	19,73 ± 0,80	88,21 ± 0,20
	Savânica	90,78 ± 0,33	9,22 ± 0,34	
	Florestal	99,34 ± 0,56	0,66 ± 0,56	
Reflectância +TC	Campestre	80,81 ± 0,42	19,19 ± 0,42	87,73 ± 0,27
	Savânica	90,43 ± 0,29	9,57 ± 0,29	
	Florestal	96,67 ± 1,05	3,33 ± 1,05	
Reflectância +IVs	Campestre	80,57 ± 0,49	19,43 ± 0,50	88,62 ± 0,26
	Savânica	91,29 ± 0,31	8,71 ± 0,31	
	Florestal	98,79 ± 0,35	1,21 ± 0,35	
TODOS	Campestre	80,96 ± 0,31	19,04 ± 0,30	88,95 ± 0,23
	Savânica	91,63 ± 0,35	8,37 ± 0,34	
	Florestal	98,90 ± 0,00	1,10 ± 0,00	

+MLME – adição do conjunto com dados do Modelo Linear de Mistura Espectral; +TC – adição do conjunto com dados da Transformada *Tasseled Cap*; +IVs adição do conjunto com dados dos Índices de Vegetação; +NIR – Adição da banda NIR1 e NIR2; +RE – Adição da banda do *Red-Edge*; +Amarelo – Adição da banda do Amarelo.

Fonte: Produção do Autor.

A adição das componentes do MLME ao conjunto base ao conjunto base não mostrou alteração estatística nos valores da TA. Todavia, essa manutenção dos valores da TA esteve relacionada à um aumento da TAC da classe Florestal em detrimento da TAC da classe Campestre. As componentes do MLME mostraram, para a Legenda N1,

uma maior similaridade entre as classes Campestre e Savânica, e, conseqüentemente, uma separabilidade maior da classe Florestal. Estes resultados foram observados nesta etapa de classificação.

Quando as componentes da Transformada TC foram adicionadas ao conjunto de dados de Reflectância, houve uma queda estatisticamente significativa no valor de TA (p valor do teste-t = $3,19 * 10^{-3}$). O uso da Transformada TC também piorou a TAC da classe Florestal, reduzindo-a de 99,34% para 96,67%. As componentes de Wetness e Brightness apresentaram valores muito próximos entre as classes Savânica e Florestal, o que pode explicar a queda na taxa de acerto na Classe Florestal. Todavia, o uso dos Índices de Vegetação junto com o conjunto de Reflectância melhorou estatisticamente a TA (88,62%) (p valor do teste-t = $6,17 * 10^{-3}$). Estes índices apresentavam boa capacidade em discriminar as fitofisionomias na Legenda N1.

O uso de todos os dados em conjunto mostrou o melhor resultado da classificação para a Legenda N1. A TA foi de 88,95%. Essa TA foi inferior a obtida por Teixeira *et al.* (2015) que foi de 94%. Entretanto, avaliando a região de estudo dos autores, nota-se que apenas cerca de 15% desta área apresentava região de savana. Logo, as altas taxas de acerto obtidas por estes autores podem estar relacionadas a ausência de áreas de transição entre campo e savana Essa transição é apresentada por Oliveira *et al.* (2007a), Ferreira *et al.* (2007), Carvalho *et al.* (2010), Schwieder *et al.* (2016) e Girolamo Neto *et al.* (2017b) como principal fonte de erro na classificação de fitofisionomias do Cerrado. A Tabela 7.4 mostra que estes também foram os principais erros de classificação neste trabalho. Em contrapartida, os valores de TA obtidos por Silva e Sano (2016) foram inferiores a todos obtidos neste trabalho.

Tabela 7.4: Matriz de confusão para a imagem WorldView-2 – Legenda N1.

		Classe Real		
		Campestre	Savana	Florestal
Predição	Campestre	273	48	0
	Savana	62	583	1
	Florestal	0	3	92

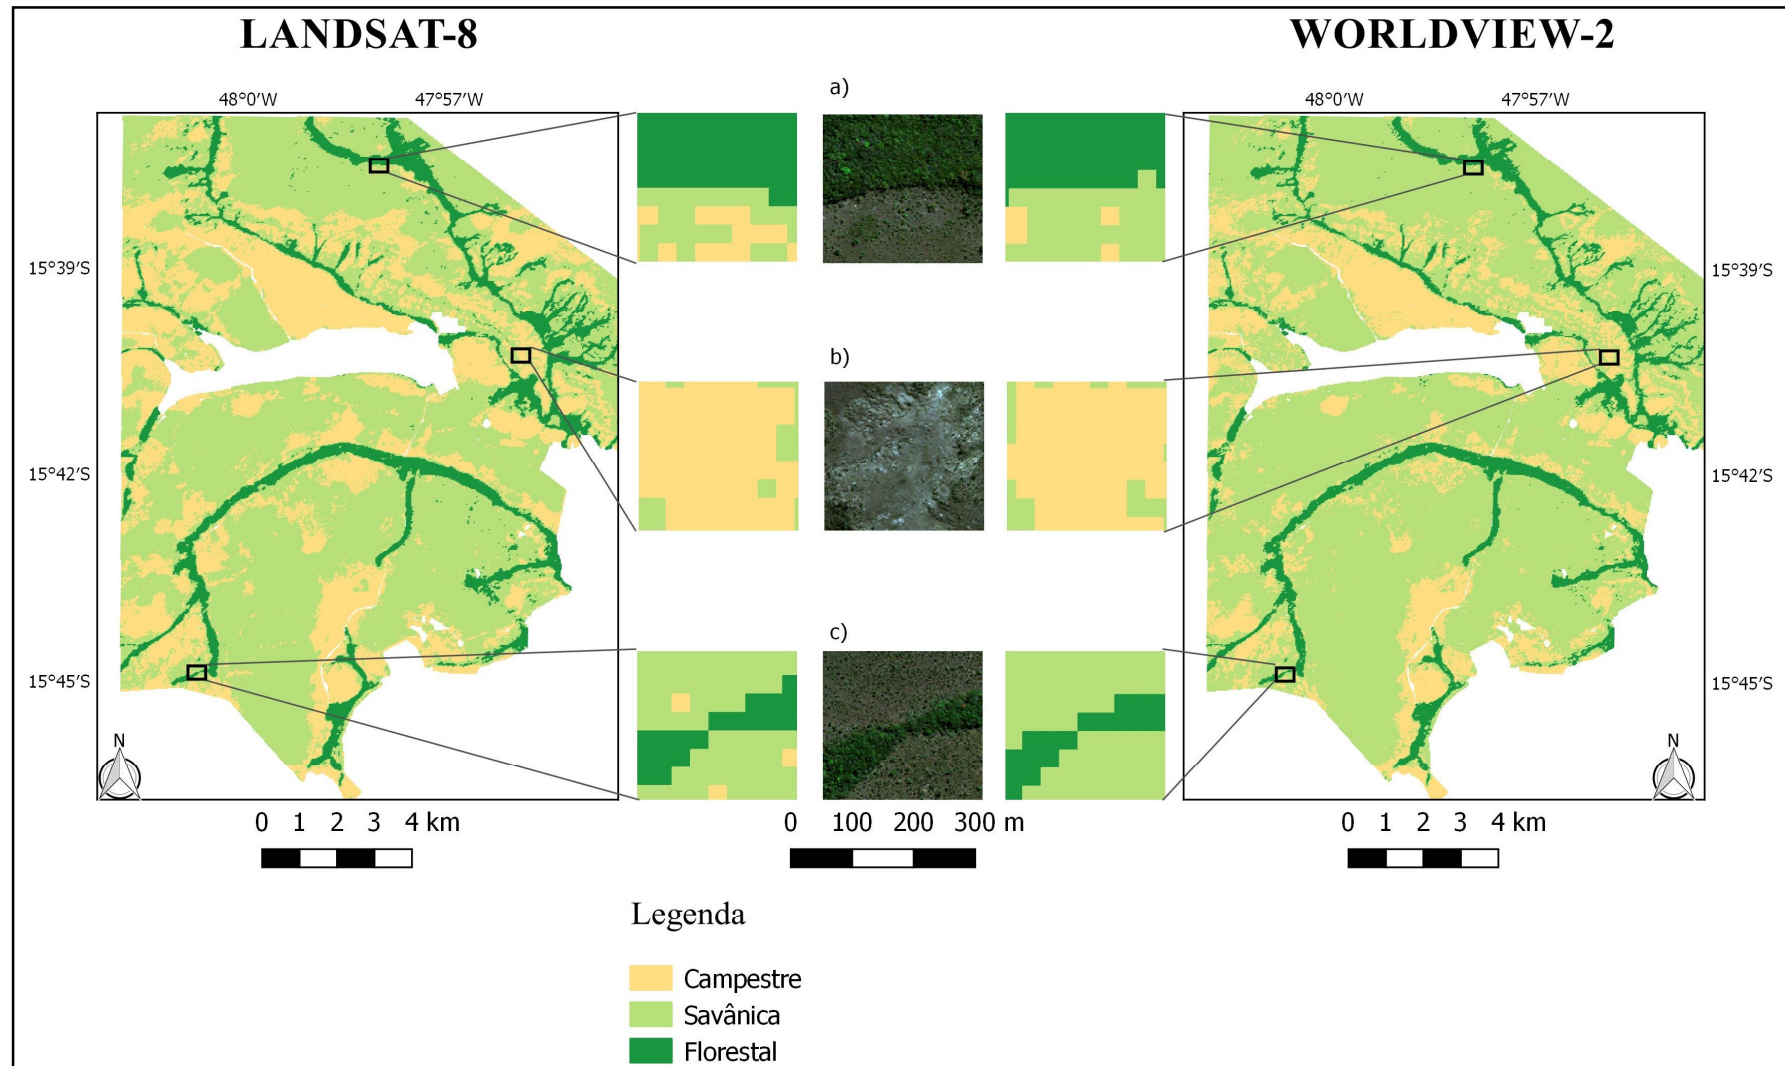
Fonte: Produção do Autor.

Comparação Landsat-8 vs WorldView-2:

A classificação com a imagem WorldView-2 foi melhor do que a do Landsat-8. Entretanto, essa melhora foi sutil, a melhor TA para o WorldView-2 foi de 88,95% enquanto que para o Landsat-8 foi de 87,30%. A maior diferença foi notada pela melhor TAC obtida pela classe Florestal com a imagem WorldView-2 (98,90% contra 94,16%). A TAC das classes Campestre e Savânica também foram discretamente melhores com a imagem WorldView-2.

Os mapas temáticos gerados para a área de estudo para ambas as imagens encontram-se na Figura 7.1. Desta maneira, verifica-se que a Legenda N1 é adequada para mapear o Cerrado com imagens de resolução espacial de 30m.

Figura 7.1: Mapas temáticos com detalhes para a Legenda N1.



a) e c) Bom delineamento de regiões de Mata de Galeria b) região campestre detectada com boa precisão

Fonte: Produção do autor.

7.2 Classificação para a Legenda N2

Landsat-8:

Os resultados da classificação da imagem Landsat-8 para a Legenda N2 são apresentados na Tabela 7.5. O conjunto RGB apresentou uma TA de 76,35%, bastante inferior ao obtido para a Legenda N1. A TAC das classes de Cerrado *Stricto Sensu* (89,27%) e Mata de Galeria (90,41%) foram as melhores esta legenda. Em contrapartida, a classe de Vereda não foi classificada corretamente em nenhum momento, obtendo EO de 100%. A divisão da classe Campestre e três classes não resultou em bons resultados, classe de Campo Sujo foi a que apresentou melhor TAC dentre as três (54,74%). Costa *et al.* (2014) também constatou essa dificuldade.

Tabela 7.5: Avaliação da classificação para a Legenda N2 – imagem Landsat-8.

Conjunto	Classes	TAC	EO	Taxa de acerto Global
RGB	Campo Rupestre	32,47 ± 2,62	67,53 ± 2,62	76,35 ± 0,27
	Campo Limpo	44,89 ± 0,93	55,11 ± 0,93	
	Campo Sujo	54,74 ± 1,31	45,26 ± 1,31	
	Cerrado <i>Stricto Sensu</i>	89,27 ± 0,32	10,73 ± 0,32	
	Vereda	0,00 ± 0,00	100,00 ± 0,00	
	Mata de Galeria	90,41 ± 0,62	9,59 ± 0,62	
RGB +NIR	Campo Rupestre	25,00 ± 0,00	75,00 ± 0,00	76,80 ± 0,32
	Campo Limpo	38,58 ± 1,02	61,42 ± 1,02	
	Campo Sujo	55,94 ± 1,32	44,06 ± 1,32	
	Cerrado <i>Stricto Sensu</i>	90,60 ± 0,24	9,40 ± 0,24	
	Vereda	0,00 ± 0,00	100,00 ± 0,00	
	Mata de Galeria	92,50 ± 0,50	75,00 ± 0,50	
RGB +SWIR	Campo Rupestre	22,51 ± 4,01	77,49 ± 4,01	78,09 ± 0,25
	Campo Limpo	43,93 ± 0,78	56,07 ± 0,78	
	Campo Sujo	58,14 ± 0,80	41,86 ± 0,80	
	Cerrado <i>Stricto Sensu</i>	90,72 ± 0,29	9,28 ± 0,29	
	Vereda	31,00 ± 5,68	69,00 ± 5,68	
	Mata de Galeria	93,17 ± 0,50	6,83 ± 0,50	
Reflectância	Campo Rupestre	19,19 ± 4,01	80,81 ± 4,01	77,51 ± 0,36
	Campo Limpo	39,93 ± 1,28	60,07 ± 1,28	
	Campo Sujo	56,74 ± 1,72	43,26 ± 1,72	
	Cerrado <i>Stricto Sensu</i>	90,70 ± 0,34	9,30 ± 0,34	
	Vereda	30,00 ± 0,00	70,00 ± 0,00	
	Mata de Galeria	94,16 ± 0,57	5,84 ± 0,57	

continua

Tabela 7.5: Conclusão

Conjunto	Classes	TAC	EO	Taxa de acerto Global
Reflectância +MLME	Campo Rupestre	24,17 ± 2,62	75,83 ± 2,62	77,65 ± 0,32
	Campo Limpo	39,93 ± 1,47	60,07 ± 1,47	
	Campo Sujo	56,40 ± 1,21	43,60 ± 1,21	
	Cerrado <i>Stricto Sensu</i>	91,13 ± 0,33	8,87 ± 0,33	
	Vereda	12,00 ± 4,22	88,00 ± 4,22	
	Mata de Galeria	94,71 ± 0,35	5,29 ± 0,35	
Reflectância +TC	Campo Rupestre	16,70 ± 0,00	83,30 ± 0,00	77,59 ± 0,39
	Campo Limpo	39,30 ± 1,41	60,70 ± 1,41	
	Campo Sujo	57,07 ± 1,63	42,93 ± 1,63	
	Cerrado <i>Stricto Sensu</i>	90,93 ± 0,44	9,07 ± 0,44	
	Vereda	22,00 ± 4,22	78,00 ± 4,22	
	Mata de Galeria	94,60 ± 0,00	5,40 ± 0,00	
Reflectância +IVs	Campo Rupestre	25,83 ± 2,62	74,17 ± 2,62	78,59 ± 0,31
	Campo Limpo	42,00 ± 0,85	58,00 ± 0,85	
	Campo Sujo	59,81 ± 0,68	40,19 ± 0,68	
	Cerrado <i>Stricto Sensu</i>	91,40 ± 0,39	8,60 ± 0,39	
	Vereda	4,00 ± 5,16	96,00 ± 5,16	
	Campo Rupestre	95,37 ± 0,74	4,63 ± 0,74	
Todos	Campo Rupestre	25,83 ± 2,62	74,17 ± 2,62	78,93 ± 0,26
	Campo Limpo	42,71 ± 1,31	57,29 ± 1,31	
	Campo Sujo	58,61 ± 1,09	41,39 ± 1,09	
	Cerrado <i>Stricto Sensu</i>	91,77 ± 0,41	8,23 ± 0,41	
	Vereda	23,00 ± 4,83	77,00 ± 4,83	
	Mata de Galeria	95,37 ± 0,74	4,63 ± 0,74	

*+MLME – adição do conjunto com dados do Modelo Linear de Mistura Espectral; +TC – adição do conjunto com dados da Transformada *Tasseled Cap*; +IVs adição do conjunto com dados dos Índices de Vegetação; +NIR – Adição da banda NIR; +SWIR – Adição das bandas SWIR1 e SWIR2.

Fonte: Produção do Autor.

A inclusão da banda NIR aumentou a TA para 76,80%. O uso dessa banda espectral mostrou aumentos da TAC para as classes com predominância de vegetação, como Cerrado *Stricto Sensu* (90,60%) e Mata de Galeria (92,50%). As classes Campo Limpo e Campo Rupestre apresentaram redução na TAC, enquanto que a classe de Campo Sujo não mostrou alteração estatisticamente significativa (p valor do teste-t = $8,48 \cdot 10^{-2}$). Para a imagem Landsat-8 os valores de Reflectância espectral destas três classes foi muito parecido, e, conseqüentemente, a confusão na classificação.

O uso das bandas do SWIR1 e SWIR2 na classificação aumentou a TA para

78,09%. Novamente, as classes Campo Rupestre e Campo Limpo apresentaram redução nos valores de TAC em relação ao conjunto RGB. Ambas as classes apresentam valores de Reflectância muito parecidos para estas bandas. Já a classe de Campo Sujo, melhorou sua TAC para 58,14%. Devido a essa classe apresentar uma maior quantidade de arbustos e árvores esparsas do que as classes de Campo Limpo e Campo Rupestre, valores mais baixos de Reflectância foram obtidos nestas bandas, auxiliando na sua diferenciação.

As Veredas passaram de uma TAC de 0% para 31%. Mesmo este valor sendo baixo, o salto apresentado pode indicar que a região do SWIR contribuiu para discriminar esta classe. Essa região do espectro está intimamente relacionada com a presença de água na vegetação, característica das Veredas (JENSEN, 2009; PONZONI; SHIMABUKURO, 2009).

A TA quando todas as bandas espectrais foram utilizadas foi de 77,51%, sendo estatisticamente superior a TA obtida pelo conjunto RGB (p valor do teste-t = $4,19 \cdot 10^{-9}$). As classes Campo Rupestre e Campo Limpo mostraram queda na TAC, mostrando a influência das bandas NIR, SWIR1 e SWIR2. Para as demais classes houve uma melhora na TAC, principalmente para Mata de Galeria (94,16%) e Veredas (30,00%). A adição dos atributos do MLME e Transformada TC, separadamente, ao conjunto de Reflectância não mostrou melhora estatística na TA.

Em contrapartida, o uso dos Índices de Vegetação melhorou a TA da Legenda N2 para 78,59%. A melhora deste valor esteve relacionada a pequenas melhoras em todas as classes, exceto a classe Vereda. Essa classe passou, a exemplo do que ocorreu com o conjunto RGB, a ser omitida da classificação (EO de 96%). As Veredas foram classificadas incorretamente como Cerrado *Stricto Sensu* e Mata de Galeria, classes com valores semelhantes de Índices de Vegetação às Veredas.

O conjunto de dados composto por todos os atributos apresentou a melhor TA nesta legenda, 78,93%, a Tabela 7.6 mostra sua matriz de confusão.

Mesmo com o uso de todos os atributos, a discriminação das classes Campo Rupestre, Campo Limpo e Campo Sujo não apresentou bons resultados com a imagem Landsat-8. A classe Campo Rupestre obteve TAC de 25,83% e apresentou confusão com as demais classes campestres. A classe Campo Limpo também apresentou uma

TAC baixa, de 42,71%, enquanto que a classe Campo Sujo obteve TAC de 58,61%. A confusão entre essas duas classes ficou evidente para esta imagem.

Erros de classificação relacionados as classes Campo Limpo e Campo Sujo também foram encontrados por Schwieder *et al.* (2016). Mesmo utilizando uma legenda mais detalhada, as classes de Campo Limpo e Campo Sujo foram as mesmas. Os autores obtiveram uma TAC de 66% para a classe de Campo Limpo e 64% para a classe de Campo Sujo. Costa *et al.* (2014) também encontrou dificuldade em classificar estas classes. A TA obtida pelos autores foi inferior a 60% para as três classes. Resultados melhores foram obtidos quando foi realizada a junção das classe de Campo Limpo, Campo Sujo e Campo Rupestre em apenas uma classe. Oliveira *et al.* (2007a) também apresentou baixa TAC para a classe Campo Rupestre (56%).

Tabela 7.6: Matriz de confusão para a imagem Landsat-8 – Legenda N2.

		Classe Real					
		Campo Rupestre	Campo Limpo	Campo Sujo	Cerrado <i>Stricto Sensu</i>	Vereda	Mata de Galeria
Predição	Campo Rupestre	3	0	1	0	0	0
	Campo Limpo	4	49	32	3	0	0
	Campo Sujo	4	43	126	47	0	0
	Cerrado <i>Stricto Sensu</i>	1	19	52	572	4	3
	Vereda	0	0	0	1	2	1
	Mata de Galeria	0	1	0	1	4	89

Fonte: Produção do Autor.

As classes de Cerrado *Stricto Sensu* e Mata de Galeria apresentaram boas TAC, sendo de 91,77% e 95,37%, respectivamente. Estes valores foram superiores aos obtidos por Oliveira *et al.* (2007a), que foram de 68% e 73%, respectivamente. A classe Vereda obteve uma PA muito baixa, sendo de 23,0%. Essa classe é uma classe complexa por apresentar uma variação muito grande do dossel. Pode ter cobertura arbórea variando de 0% até 80% (considerando as coberturas possíveis para as classes de Vereda e Palmeiral). Orozco Filho (2017) trabalhou com a classificação de uma classe chamada de Vereda com Campo Limpo Úmido. Mesmo utilizando imagens de 5m de resolução espacial, a TAC para essa classe foi de apenas 60%.

WorldView-2:

Os resultados da classificação da imagem WorldView-2 para a Legenda N2 são apresentados na Tabela 7.7. O conjunto RGB apresentou uma TA de 77,37%, a qual foi inferior a obtida pelo mesmo conjunto na Legenda N1 (85,15%). As melhores TAC foram obtidas pelas mesmas classes da imagem Landsat-8, ou seja, Cerrado *Stricto Sensu* (90,16%) e Mata de Galeria (94,71%). Além destas classes, o Campo Rupestre apresentou uma TAC com valor de 59,98%. A confusão entre Campo Limpo e Campo Sujo e a classificação das Veredas se mantiveram para a imagem de alta resolução.

Tabela 7.7: Avaliação da classificação para a Legenda N2 – imagem WorldView-2.

Conjunto	Classes	TAC	EO	Taxa de acerto Global
RGB	Campo Rupestre	59,98 ± 3,54	40,02 ± 3,54	77,37 ± 0,33
	Campo Limpo	44,03 ± 1,23	55,97 ± 1,23	
	Campo Sujo	53,91 ± 1,03	46,19 ± 1,03	
	Cerrado <i>Stricto Sensu</i>	90,16 ± 0,34	9,84 ± 0,34	
	Vereda	10,00 ± 0,00	90,00 ± 0,00	
	Mata de Galeria	94,71 ± 0,35	5,29 ± 0,35	
RGB +Amarelo	Campo Rupestre	65,02 ± 3,53	34,65 ± 3,53	77,17 ± 0,48
	Campo Limpo	42,00 ± 1,20	56,76 ± 1,20	
	Campo Sujo	55,59 ± 0,53	44,60 ± 0,53	
	Cerrado <i>Stricto Sensu</i>	89,50 ± 0,71	10,82 ± 0,71	
	Vereda	10,00 ± 0,00	89,00 ± 0,00	
	Mata de Galeria	94,60 ± 0,00	5,50 ± 0,00	
RGB +Red-Edge	Campo Rupestre	57,48 ± 4,73	42,52 ± 4,73	79,00 ± 0,34
	Campo Limpo	49,82 ± 2,50	50,18 ± 2,50	
	Campo Sujo	56,73 ± 1,24	43,27 ± 1,24	
	Cerrado <i>Stricto Sensu</i>	90,71 ± 0,28	9,29 ± 0,28	
	Vereda	2,00 ± 4,22	98,00 ± 4,22	
	Mata de Galeria	96,98 ± 0,82	3,02 ± 0,82	
RGB +NIR	Campo Rupestre	55,81 ± 4,01	44,19 ± 4,01	80,11 ± 0,27
	Campo Limpo	52,97 ± 1,34	47,03 ± 1,34	
	Campo Sujo	59,03 ± 1,05	40,97 ± 1,05	
	Cerrado <i>Stricto Sensu</i>	91,03 ± 0,27	8,97 ± 0,27	
	Vereda	8,00 ± 4,22	92,00 ± 4,22	
	Mata de Galeria	98,35 ± 0,58	1,65 ± 0,58	
Reflectância	Campo Rupestre	52,49 ± 4,01	47,51 ± 4,01	80,81 ± 0,59
	Campo Limpo	55,12 ± 1,73	44,88 ± 1,73	
	Campo Sujo	60,67 ± 1,77	39,33 ± 1,77	
	Cerrado <i>Stricto Sensu</i>	91,23 ± 0,38	8,77 ± 0,38	
	Vereda	4,00 ± 5,16	96,00 ± 5,16	
	Mata de Galeria	99,34 ± 0,56	0,66 ± 0,56	

continua

Tabela 7.7: Conclusão

Conjunto	Classes	TAC	EO	Taxa de acerto Global
Reflectância +MLME	Campo Rupestre	50,83 ± 2,62	49,17 ± 2,62	81,00 ± 0,24
	Campo Limpo	54,95 ± 1,06	45,05 ± 1,06	
	Campo Sujo	61,42 ± 1,18	38,58 ± 1,18	
	Cerrado <i>Stricto Sensu</i>	91,37 ± 0,29	8,63 ± 0,29	
	Vereda	0,00 ± 0,00	100,00 ± 0,00	
	Mata de Galeria	99,89 ± 0,34	0,11 ± 0,34	
Reflectância +TC	Campo Rupestre	52,49 ± 4,01	45,01 ± 4,01	80,87 ± 0,18
	Campo Limpo	54,67 ± 1,37	43,86 ± 1,37	
	Campo Sujo	61,29 ± 0,87	38,7 ± 0,87	
	Cerrado <i>Stricto Sensu</i>	91,22 ± 0,32	9,17 ± 0,32	
	Vereda	0,00 ± 0,00	100,00 ± 0,00	
	Mata de Galeria	99,56 ± 0,56	1,05 ± 0,56	
Reflectância +IVs	Campo Rupestre	59,14 ± 2,65	40,86 ± 02,65	81,45 ± 0,38
	Campo Limpo	57,76 ± 1,08	42,24 ± 1,08	
	Campo Sujo	60,67 ± 0,70	39,33 ± 0,70	
	Cerrado <i>Stricto Sensu</i>	91,87 ± 0,48	8,13 ± 0,48	
	Vereda	0,00 ± 0,00	100,00 ± 0,0	
	Mata de Galeria	98,90 ± 0,00	1,10 ± 0,0	
Todos	Campo Rupestre	55,81 ± 4,01	44,19 ± 4,01	81,63 ± 0,32
	Campo Limpo	57,64 ± 0,75	42,36 ± 0,75	
	Campo Sujo	59,85 ± 0,74	40,15 ± 0,74	
	Cerrado <i>Stricto Sensu</i>	92,30 ± 0,36	7,70 ± 0,36	
	Vereda	0,00 ± 0,00	100,00 ± 0,00	
	Mata de Galeria	100,00 ± 0,00	0,00 ± 0,00	

*+MLME – adição do conjunto com dados do Modelo Linear de Mistura Espectral; +TC – adição do conjunto com dados da Transformada *Tasseled Cap*; +IVs adição do conjunto com dados dos Índices de Vegetação; +NIR – Adição da banda NIR1 e NIR2; +RE – Adição da banda do *Red-Edge*; +Amarelo – Adição da banda do Amarelo.

Fonte: Produção do Autor.

O uso combinado da banda do Amarelo e conjunto RGB não resultou em variação significativa entre os valores de TA, os quais foram considerados iguais pelo teste-t (p valor do teste-t = $1,7 * 10^{-1}$). Todavia, notou-se uma melhora na TAC da classe de Campo Rupestre. Essa classe apresentou valores mais altos de Reflectância na região do visível para a imagem WorldView-2 do que as classes de Campo Limpo e Cerrado Ralo. Novamente, um melhor detalhamento dessa faixa espectral apresentou uma melhora na separabilidade dessa classe.

A adição das bandas do NIR1 e NIR2 ao conjunto RGB melhorou a TA, obtendo valor de 80,08%. As classes Campo Limpo e Campo Sujo apresentaram os melhores aumentos na TAC com estas bandas (52,97% e 59,03%, respectivamente), todavia a classe de Campo Rupestre apresentou valores mais baixos do que o conjunto RGB (55,81%). A adição da banda *Red-Edge* apresentou os mesmos resultados, porém com menores valores de TAC.

O conjunto com todos os dados de Reflectância obteve uma TA de 80,81%, sendo que houve aumento na TAC de todas as classes em relação ao conjunto RGB, exceto as classes Campo Rupestre e Veredas. A classe Veredas ainda não foi classificada corretamente na imagem WorldView-2 (EO de 96%), enquanto que a classe Campo Rupestre reduziu sua TIC de 59,98% para 52,49% devido a presença das regiões *Red-Edge*, NIR1 e NIR2.

A adição dos atributos do MLME e Transformada TC, separadamente, ao conjunto de Reflectância não mostrou diferença estatística nos valores de TA. Mais uma vez a adição dos Índices de Vegetação ao conjunto de Reflectância mostrou um aumento significativo nos valores médios das taxas de acerto globais (p valor do teste-t = $4,53 * 10^{-3}$).

Avaliando-se a matriz de confusão (Tabela 7.8) e as medidas de de avaliação da classificação com todos os atributos, é perceptível a dificuldade da classificação de regiões campestres. As classes de Campo Limpo, Campo Sujo e Campo Rupestre apresentaram TAC variando entre valores de 55% a 60%. Estes valores foram bem inferiores a outras classes como Cerrado *Stricto Sensu* (92,30%) e Mata de Galeria (100,0%). Problemas de confusão entre as classes de Campo Limpo e Campo Sujo também foram notados para os dados de alta resolução espacial por outros autores. Sem utilizar a classe de Campo Rupestre, Girolamo Neto *et al.* (2017b) obtiveram baixos valores inferiores de TAC para a classe de Campo Sujo 56%, já a classe de Campo Limpo obteve uma TAC melhor, de 71%.

Outro problema que persistiu da Legenda N1, foi a transição entre a classe Campo Sujo e Cerrado *Stricto Sensu*, que simboliza a transição entre campo e savana nessa legenda. Mesmo com estes erros, a TAC da classe de Cerrado *Stricto Sensu* foi 92,30%. Este valor foi superior a outros trabalhos com imagens de alta resolução que utilizaram essa classe, como os 83% obtidos por Ozorco Filho (2017). Com um problema similar ao que ocorreu com imagens Landsat-8, a classe Veredas apresentou

altos valores de EO, indicando que não foi classificada para a imagem WorldView-2. Em contrapartida, as Matas de Galeria foram classificadas com 100,0% de TAC.

Tabela 7.8: Matriz de confusão para a imagem WorldView-2 – Legenda N2.

		Classe Real					
		Campo Rupestre	Campo Limpo	Campo Sujo	Cerrado <i>Stricto Sensu</i>	Vereda	Mata de Galeria
Predição	Campo Rupestre	7	1	0	0	0	0
	Campo Limpo	2	64	23	2	0	0
	Campo Sujo	3	32	128	41	0	0
	Cerrado <i>Stricto Sensu</i>	0	15	60	579	7	0
	Vereda	0	0	0	1	0	0
	Mata de Galeria	0	0	0	1	3	93

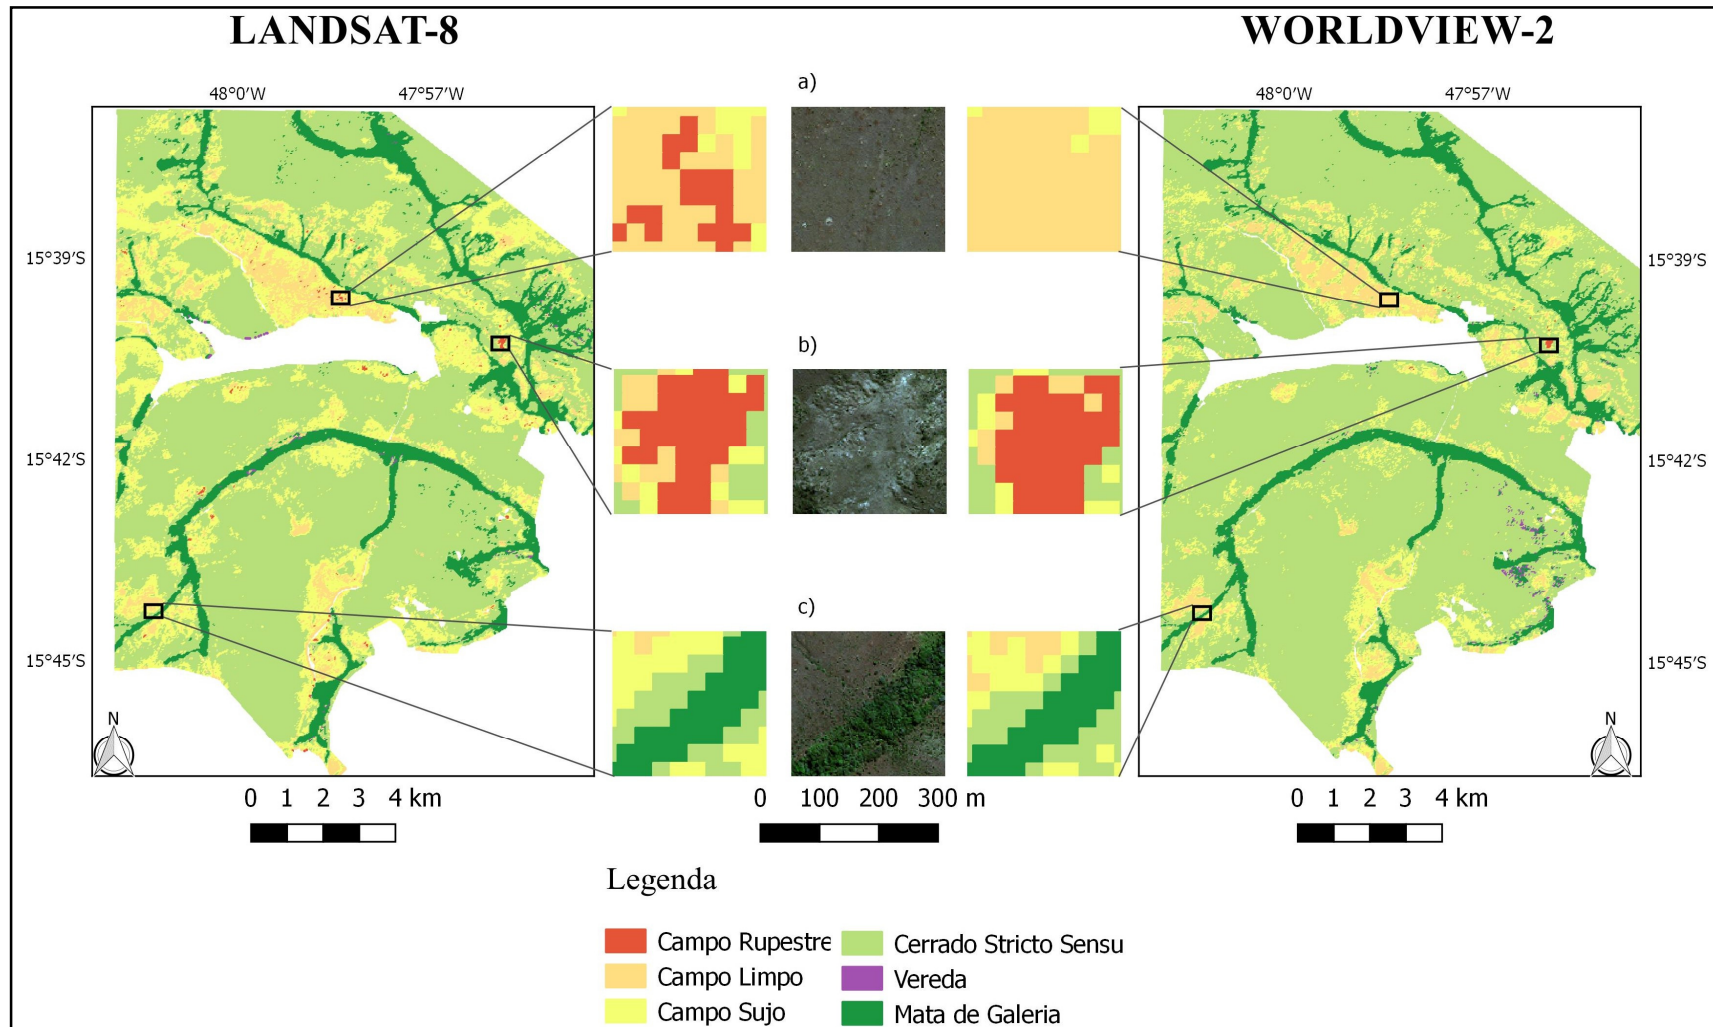
Fonte: Produção do Autor.

Comparação Landsat-8 vs WorldView-2:

A classificação para a imagem WorldView-2 foi melhor do que para a imagem Landsat-8. A TA para a primeira foi de 81,63%, enquanto que para a segunda foi de 78,93%. Aparentemente, essa diferença parece pequena, entretanto os valores da TAC para as classes Campo Rupestre e Campo Limpo foram superiores na imagem WorldView-2. A classe de Campo Rupestre mostrou uma maior separabilidade com dados de Reflectância para o WorldView-2, e, conseqüentemente, a melhor TAC. As classes de Mata de Galeria e Cerrado *Stricto Sensu* apresentaram altas TAC para ambas as imagens, entretanto, todas as amostras de Mata de Galeria foram classificadas corretamente para a imagem WorldView-2. As Veredas mostram baixa TAC para ambas as imagens, sendo que não foram classificadas corretamente em nenhum momento para a imagem WorldView-2.

A Legenda N2 é recomendada para imagens de alta resolução. O uso de imagens de média resolução aumenta os erros entre as Classes de Campo Limpo e Campo Sujo, bem como existe o baixo potencial em discriminar a classe de Campo Rupestre. Erros de transição entre Campo Sujo e Cerrado *Stricto Sensu* foram notados para as duas imagens. A Figura 7.2 mostra os mapas temáticos gerados para esta legenda.

Figura 7.2: Mapas temáticos com detalhes para a Legenda N2.



a) região de Campo Limpo com erros na imagem Landsat-8; b) região de Campo Rupestre com boa detecção para ambas as imagens; c) bom delineamento de uma Mata de Galeria.

Fonte: Produção do autor.

7.3 Classificação para a Legenda N3:

Landsat-8:

Os resultados da classificação da imagem Landsat-8 considerando a Legenda N3 são apresentados na Tabela 7.9. A TA para o conjunto RGB foi de 58,41%. Esse valor foi bastante inferior ao obtido na Legenda N2 com este mesmo conjunto (76,35%). A subdivisão da classe de Cerrado *Stricto Sensu* em três classes foi responsável por essa redução na TA. As classes Cerrado Ralo e Cerrado Denso apresentaram baixos valores de TA, 30,77% e 23,96%, respectivamente. Em contrapartida, a classe de Cerrado Típico obteve uma TA alta, de 80,44%.

O uso da banda NIR junto ao conjunto RGB aumentou a TA para 60,96%, mostrando ganhos para estas três classes. O maior aumento ocorreu para a classe com maior quantidade de vegetação, ou seja, o Cerrado Denso. Já a região do SWIR aumentou somente a TA da classe das classes de Cerrado Ralo e Típico. Porém, foi notada, novamente, a contribuição das bandas do SWIR1 e SWIR2 para a identificação da classe de Veredas, a qual aumentou sua TA de 0% para 36%.

O uso de todas as bandas aumentou a TAC para todas as classes do N3, exceto as classes de Campo Rupestre e Campo Limpo, de maneira análoga a Legenda N2. A inclusão de dados do MLME ao conjunto de Reflectância não mostrou diferença estatística nos valores de TA. Já o uso da Transformada TC aumentou a TA para 64,05%. Os ganhos foram concentrados nas classes de Cerrado Ralo, Cerrado Típico e Cerrado Denso. Segundo Schweider *et al.* (2016) estas componentes são essenciais para capturar variações nestas fitofisionomias do Cerrado. Os autores também trabalharam com imagens Landsat e na região do Parque Nacional de Brasília. O uso dos atributos de Índices de Vegetação apresentou resultados similares aos mostrados para as componentes TC.

Tabela 7.9: Avaliação da classificação para a Legenda N3 – imagem Landsat-8.

Conjunto	Classes	TAC	EO	Taxa de acerto Global
RGB	Campo Rupestre	29,98 ± 4,29	70,02 ± 4,29	58,41 ± 0,35
	Campo Limpo	42,80 ± 1,35	57,20 ± 1,35	
	Campo Sujo	52,21 ± 1,24	47,79 ± 1,24	
	Cerrado Ralo	30,77 ± 1,08	69,23 ± 1,08	
	Cerrado Típico	80,44 ± 0,43	19,56 ± 0,43	
	Cerrado Denso	23,96 ± 2,44	76,04 ± 2,44	
	Vereda	0,00 ± 0,00	100,00 ± 0,00	
	Mata de Galeria	92,30 ± 0,46	7,70 ± 0,46	
RGB +NIR	Campo Rupestre	24,17 ± 6,12	75,83 ± 6,12	60,96 ± 0,50
	Campo Limpo	40,02 ± 1,11	59,98 ± 1,11	
	Campo Sujo	55,56 ± 1,34	44,44 ± 1,34	
	Cerrado Ralo	31,72 ± 1,53	68,28 ± 1,53	
	Cerrado Típico	84,87 ± 0,70	15,13 ± 0,70	
	Cerrado Denso	29,22 ± 2,60	70,78 ± 2,60	
	Vereda	0,00 ± 0,00	100,00 ± 0,00	
	Mata de Galeria	94,60 ± 0,00	5,40 ± 0,00	
RGB +SWIR	Campo Rupestre	16,70 ± 0,00	83,30 ± 0,00	61,83 ± 0,46
	Campo Limpo	42,08 ± 1,54	57,92 ± 1,54	
	Campo Sujo	58,75 ± 0,73	41,25 ± 0,73	
	Cerrado Ralo	33,60 ± 1,18	66,40 ± 1,18	
	Cerrado Típico	84,46 ± 0,71	15,54 ± 0,71	
	Cerrado Denso	24,44 ± 1,35	75,56 ± 1,35	
	Vereda	36,00 ± 5,16	64,00 ± 5,16	
	Mata de Galeria	93,90 ± 0,52	7,10 ± 0,52	
Reflectância	Campo Rupestre	16,70 ± 0,00	83,30 ± 0,00	62,80 ± 0,63
	Campo Limpo	41,01 ± 1,61	58,99 ± 1,61	
	Campo Sujo	59,05 ± 0,96	40,95 ± 0,96	
	Cerrado Ralo	34,41 ± 1,30	65,59 ± 1,30	
	Cerrado Típico	86,29 ± 0,66	13,71 ± 0,66	
	Cerrado Denso	27,00 ± 3,37	73,00 ± 3,37	
	Vereda	30,00 ± 0,00	70,00 ± 0,00	
	Mata de Galeria	94,60 ± 0,00	5,40 ± 0,00	
Reflectância +MLME	Campo Rupestre	16,70 ± 0,00	83,30 ± 0,00	63,23 ± 0,40
	Campo Limpo	39,30 ± 1,52	60,70 ± 1,52	
	Campo Sujo	57,53 ± 1,01	42,47 ± 1,01	
	Cerrado Ralo	33,13 ± 1,98	66,87 ± 1,98	
	Cerrado Típico	88,39 ± 0,87	11,61 ± 0,87	
	Cerrado Denso	29,37 ± 2,12	70,63 ± 2,12	
	Vereda	24,00 ± 6,99	76,00 ± 6,99	
	Mata de Galeria	95,70 ± 0,00	4,30 ± 0,00	

continua

Tabela 7.9: Conclusão

Conjunto	Classes	TAC	EO	Taxa de acerto Global
Reflectância +TC	Campo Rupestre	16,70 ± 0,00	83,30 ± 0,00	64,05 ± 0,54
	Campo Limpo	41,62 ± 2,37	58,38 ± 2,37	
	Campo Sujo	59,63 ± 1,11	40,37 ± 1,11	
	Cerrado Ralo	36,00 ± 1,13	64,00 ± 1,13	
	Cerrado Típico	87,62 ± 0,99	12,38 ± 0,99	
	Cerrado Denso	31,74 ± 2,09	68,26 ± 2,09	
	Vereda	25,00 ± 5,27	75,00 ± 5,27	
	Mata de Galeria	95,59 ± 0,34	4,41 ± 0,34	
Reflectância +IVs	Campo Rupestre	16,70 ± 0,00	83,30 ± 0,00	64,93 ± 0,40
	Campo Limpo	41,99 ± 2,22	58,01 ± 2,22	
	Campo Sujo	61,51 ± 1,50	38,49 ± 1,50	
	Cerrado Ralo	39,59 ± 1,12	60,41 ± 1,12	
	Cerrado Típico	87,87 ± 0,85	12,13 ± 0,85	
	Cerrado Denso	30,80 ± 1,83	69,20 ± 1,83	
	Vereda	10,00 ± 4,71	90,00 ± 4,71	
	Mata de Galeria	94,82 ± 0,46	5,18 ± 0,46	
TODOS	Campo Rupestre	16,70 ± 0,00	83,30 ± 0,00	65,16 ± 0,58
	Campo Limpo	41,44 ± 2,09	58,56 ± 2,09	
	Campo Sujo	62,14 ± 1,52	37,86 ± 1,52	
	Cerrado Ralo	38,61 ± 1,42	61,39 ± 1,42	
	Cerrado Típico	88,03 ± 0,42	11,97 ± 0,42	
	Cerrado Denso	32,22 ± 2,78	67,78 ± 2,78	
	Vereda	21,00 ± 3,13	79,00 ± 3,13	
	Mata de Galeria	95,81 ± 0,34	4,19 ± 0,34	

*+MLME – adição do conjunto com dados do Modelo Linear de Mistura Espectral; +TC – adição do conjunto com dados da Transformada *Tasseled Cap*; +IVs adição do conjunto com dados dos Índices de Vegetação; +NIR – Adição da banda NIR; +SWIR – Adição das bandas SWIR1 e SWIR2.

Fonte: Produção do Autor.

O conjunto com todos os atributos apresentou a TA mais alta, de 65,16%. Esse valor é superior ao obtido por Schwieder *et al.* (2016) e inferior ao obtido por Ferreira *et al.* (2007). Schwieder *et al.* (2016) utilizaram classes muito similares as utilizadas na Legenda N3, exceto a classe de Campo Rupestre, o que pode explicar a TA de superior obtida pelos autores para a classe Campo Limpo (66%). As classes de Campo Sujo, Cerrado Típico e Mata de Galeria obtiveram valores superiores neste estudo. Cabe ressaltar que Schwieder *et al.* (2016) realizaram a classificação com base em uma série temporal de um ano com imagens de 8 em 8 dias. Ferreira *et al.* (2007) classificou apenas 5 classes de Cerrado e, no cálculo de sua TA, foram contados acertos da classe

de água (essa classe obteve TAC de 100%). Um ponto em comum levantado por ambos os autores e também por este trabalho é a dificuldade de discriminar a transição entre a região de campo com a região de savana, que refere-se as classes de Campo Sujo e Cerrado Ralo (Tabela 7.10).

Tabela 7.10: Matriz de confusão para a imagem Landsat-8 – Legenda N3.

		Classe Real							
		Campo Rupestre	Campo Limpo	Campo Sujo	Cerrado Ralo	Cerrado Típico	Cerrado Denso	Vereda	Mata de Galeria
Predição	Campo Rupestre	2	0	1	0	0	0	0	0
	Campo Limpo	3	50	27	1	1	0	2	0
	Campo Sujo	6	42	138	47	4	0	0	0
	Cerrado Ralo	1	7	34	76	26	0	0	0
	Cerrado Típico	0	10	10	63	327	39	1	1
	Cerrado Denso	0	1	1	1	14	22	1	3
	Vereda	0	1	0	0	0	0	2	0
	Mata de Galeria	0	1	0	0	1	2	4	89

Fonte: Produção do Autor.

WorldView-2:

Os resultados da classificação para o WorldView-2 para a Legenda N3 estão na Tabela 7.11. O Conjunto RGB apresentou uma TA de 62,40%. As classes Cerrado Ralo e Cerrado Denso não apresentaram boas TAC, a exemplo do que ocorreu com a imagem Landsat-8. Já a classe Cerrado Típico obteve TAC de 83,72%. As Veredas passaram a ser classificadas nesta legenda, mesmo que com uma TAC de apenas 20,00%.

A inclusão da banda do Amarelo apresentou uma TA estatisticamente equivalente a do conjunto de Reflectância com as bandas RGB (p valor do teste- $t = 2,44 * 10^{-1}$). Entretanto, foi notado uma melhora na TA da classe Campo Sujo em detrimento da TA das classes Cerrado Típico e Mata de Galeria. Já as bandas do NIR1 e NIR2 melhoram a TAC para todas as classes da Legenda N3, exceto as classes de Campo Rupestre e Veredas. A Classe de Campo Rupestre reduz sua TA, a exemplo do que aconteceu com a Legenda N2, enquanto que as Veredas passam a ter altos valores de EO (94%). Em contrapartida, essa região melhora a TAC das classes de Cerrado Ralo (40,08%), Cerrado Típico (85,76%) e Cerrado Denso (43,02%). A banda *Red-Edge* apresenta resultados similares, porém com menos magnitude.

Tabela 7.11: Avaliação da classificação para a Legenda N3 – imagem WorldView-2.

Conjunto	Classes	TAC	EO	Taxa de acerto Global
RGB	Campo Rupestre	58,30 ± 0,00	41,70 ± 0,00	62,40 ± 0,61
	Campo Limpo	43,24 ± 1,62	56,76 ± 1,62	
	Campo Sujo	55,56 ± 1,03	44,44 ± 1,03	
	Cerrado Ralo	33,24 ± 1,24	66,76 ± 1,24	
	Cerrado Típico	83,72 ± 0,85	16,28 ± 0,85	
	Cerrado Denso	38,10 ± 1,85	61,90 ± 1,85	
	Vereda	20,00 ± 4,71	80,00 ± 4,71	
	Mata de Galeria	95,99 ± 0,53	4,00 ± 0,53	
RGB +Amarelo	Campo Rupestre	59,14 ± 2,66	40,86 ± 2,66	62,18 ± 0,54
	Campo Limpo	40,65 ± 1,36	59,35 ± 1,36	
	Campo Sujo	58,38 ± 1,38	41,62 ± 1,38	
	Cerrado Ralo	32,44 ± 1,41	67,56 ± 1,41	
	Cerrado Típico	82,68 ± 0,95	17,32 ± 0,95	
	Cerrado Denso	39,54 ± 1,59	60,46 ± 1,59	
	Vereda	15,00 ± 8,50	85,00 ± 8,50	
	Mata de Galeria	94,83 ± 1,11	5,17 ± 1,11	
RGB +RE	Campo Rupestre	58,30 ± 0,00	41,70 ± 0,00	65,26 ± 0,46
	Campo Limpo	49,28 ± 0,93	50,72 ± 0,93	
	Campo Sujo	59,46 ± 1,09	40,54 ± 1,09	
	Cerrado Ralo	39,85 ± 1,05	60,15 ± 1,05	
	Cerrado Típico	85,18 ± 0,88	14,82 ± 0,88	
	Cerrado Denso	40,50 ± 2,03	59,50 ± 2,03	
	Vereda	2,00 ± 4,22	98,00 ± 4,22	
	Mata de Galeria	96,69 ± 0,35	3,31 ± 0,35	
RGB +NIR	Campo Rupestre	54,16 ± 5,89	45,84 ± 5,89	66,67 ± 0,49
	Campo Limpo	53,06 ± 1,42	46,94 ± 1,42	
	Campo Sujo	60,81 ± 1,51	39,19 ± 1,51	
	Cerrado Ralo	40,08 ± 1,78	59,92 ± 1,78	
	Cerrado Típico	85,76 ± 0,68	14,24 ± 0,68	
	Cerrado Denso	43,02 ± 1,88	56,98 ± 1,88	
	Vereda	6,00 ± 5,16	94,00 ± 5,16	
	Mata de Galeria	97,80 ± 0,00	2,20 ± 0,00	
Reflectância	Campo Rupestre	50,00 ± 0,00	50,00 ± 0,00	67,09 ± 0,58
	Campo Limpo	55,57 ± 1,00	44,43 ± 1,00	
	Campo Sujo	63,42 ± 2,00	36,58 ± 2,00	
	Cerrado Ralo	37,46 ± 1,74	62,54 ± 1,74	
	Cerrado Típico	86,51 ± 0,49	13,49 ± 0,49	
	Cerrado Denso	40,33 ± 2,27	59,67 ± 2,27	
	Vereda	2,00 ± 4,22	98,00 ± 4,22	
	Mata de Galeria	98,68 ± 0,70	1,32 ± 0,70	

continua

Tabela 7.11: Conclusão

Conjunto	Classes	TAC	EO	Taxa de acerto Global
Reflectância +MLME	Campo Rupestre	50,83 ± 2,62	49,17 ± 2,62	66,79 ± 0,58
	Campo Limpo	53,60 ± 1,04	46,40 ± 1,04	
	Campo Sujo	62,56 ± 1,28	37,44 ± 1,28	
	Cerrado Ralo	38,30 ± 1,32	61,70 ± 1,32	
	Cerrado Típico	86,28 ± 0,68	13,72 ± 0,68	
	Cerrado Denso	38,74 ± 1,55	61,26 ± 1,55	
	Vereda	0,00 ± 0,00	100,00 ± 0,00	
	Mata de Galeria	100,00 ± 0,00	0,00 ± 0,00	
Reflectância +TC	Campo Rupestre	50,83 ± 2,62	49,17 ± 2,62	67,08 ± 0,49
	Campo Limpo	54,77 ± 1,04	45,23 ± 1,04	
	Campo Sujo	64,13 ± 0,99	35,87 ± 0,99	
	Cerrado Ralo	38,50 ± 0,95	61,50 ± 0,95	
	Cerrado Típico	85,81 ± 0,78	14,19 ± 0,78	
	Cerrado Denso	39,22 ± 1,51	60,78 ± 1,51	
	Vereda	1,00 ± 3,16	99,00 ± 3,16	
	Mata de Galeria	99,45 ± 0,58	0,55 ± 0,58	
Reflectância +IV	Campo Rupestre	54,98 ± 4,28	45,02 ± 4,28	68,10 ± 0,37
	Campo Limpo	57,04 ± 1,33	42,96 ± 1,33	
	Campo Sujo	64,70 ± 1,21	35,30 ± 1,21	
	Cerrado Ralo	39,64 ± 1,07	60,36 ± 1,07	
	Cerrado Típico	86,43 ± 0,56	13,57 ± 0,56	
	Cerrado Denso	45,07 ± 2,48	54,93 ± 2,48	
	Vereda	0,00 ± 0,00	100,00 ± 0,00	
	Mata de Galeria	98,90 ± 0,00	1,10 ± 0,00	
TODOS	Campo Rupestre	54,16 ± 5,89	45,84 ± 5,89	68,08 ± 0,53
	Campo Limpo	57,23 ± 1,03	42,77 ± 1,03	
	Campo Sujo	64,85 ± 1,19	35,15 ± 1,19	
	Cerrado Ralo	40,71 ± 1,31	59,29 ± 1,31	
	Cerrado Típico	85,93 ± 0,49	14,07 ± 0,49	
	Cerrado Denso	42,39 ± 2,35	57,61 ± 2,35	
	Vereda	0,00 ± 0,00	100,00 ± 0,00	
	Mata de Galeria	98,90 ± 0,00	1,10 ± 0,00	

*+MLME – adição do conjunto com dados do Modelo Linear de Mistura Espectral; +TC – adição do conjunto com dados da Transformada *Tasseled Cap*; +IVs adição do conjunto com dados dos Índices de Vegetação; +NIR – Adição da banda NIR1 e NIR2; +RE – Adição da banda do *Red-Edge*; +Amarelo – Adição da banda do Amarelo.

Fonte: Produção do Autor.

O conjunto de dados com todas as bandas obteve uma TA de 67,09%, sendo que, em comparação ao conjunto RGB, houve melhora da TAC para todas as classes exceto Veredas e Cerrado Rupestre, seguindo o que ocorreu com as bandas *Red-Edge*, NIR1 e

NIR2. Novamente, a adição dos atributos do MLME e Transformada TC, separadamente, ao conjunto de Reflectância não mostrou alteração significativa na TA. Em contrapartida, os Índices de Vegetação aumentaram a TA para 68,10%. Valor que foi praticamente o mesmo para quando todos os dados foram utilizados. A matriz de confusão para o melhor classificador obtido com todos os dados está na Tabela 7.12.

Tabela 7.12: Matriz de confusão para a imagem WorldView-2 – Legenda N3.

		Classe Real							
		Campo Rupestre	Campo Limpo	Campo Sujo	Cerrado Ralo	Cerrado Típico	Cerrado Denso	Vereda	Mata de Galeria
Predição	Campo Rupestre	6	2	0	0	0	0	0	0
	Campo Limpo	3	65	19	2	2	0	0	0
	Campo Sujo	3	31	142	45	3	0	0	0
	Cerrado Ralo	0	7	39	81	31	0	0	0
	Cerrado Típico	0	7	11	60	322	35	2	0
	Cerrado Denso	0	0	0	0	15	27	4	1
	Vereda	0	0	0	0	0	0	0	0
	Mata de Galeria	0	0	0	0	0	1	4	92

Fonte: Produção do Autor.

Os resultados mostram que a TAC se manteve da Legenda N2 para as classes de Campo Rupestre e Campo Limpo, entretanto houve um aumento na TAC da classe de Campo Sujo de 59,85% para 64,85% na Legenda N3. A divisão da classe de Cerrado Cerrado *Stricto Sensu* restringiu os erros de transição entre campo e savana para as classes de Campo Sujo e Cerrado Ralo. Estes erros também foram notados para imagens de alta resolução (GIROLAMO NETO *et al.*, 2017b). Outros trabalhos com imagens de alta resolução como Teixeira *et al.* (2015) e Orozco Filho (2017), utilizaram a classe de Cerrado *Stricto Sensu* não permitindo uma avaliação mais precisa da transição entre esse erros.

Baixos valores de TAC foram encontrados para as classes de Cerrado Ralo e Cerrado Denso (40,7% e 42,4%, respectivamente). Mesmo as imagens de alta resolução sendo capazes de distinguir estas fitofisionomias (PINHEIRO; DURIGAN, 2009), a classificação automática ainda encontra dificuldades. Os erros de classificação destas classes estavam relacionados à inclusão das mesmas como Cerrado Típico. Estes erros também foram observados por Girolamo Neto *et al.* (2017), os quais obtiveram uma TA

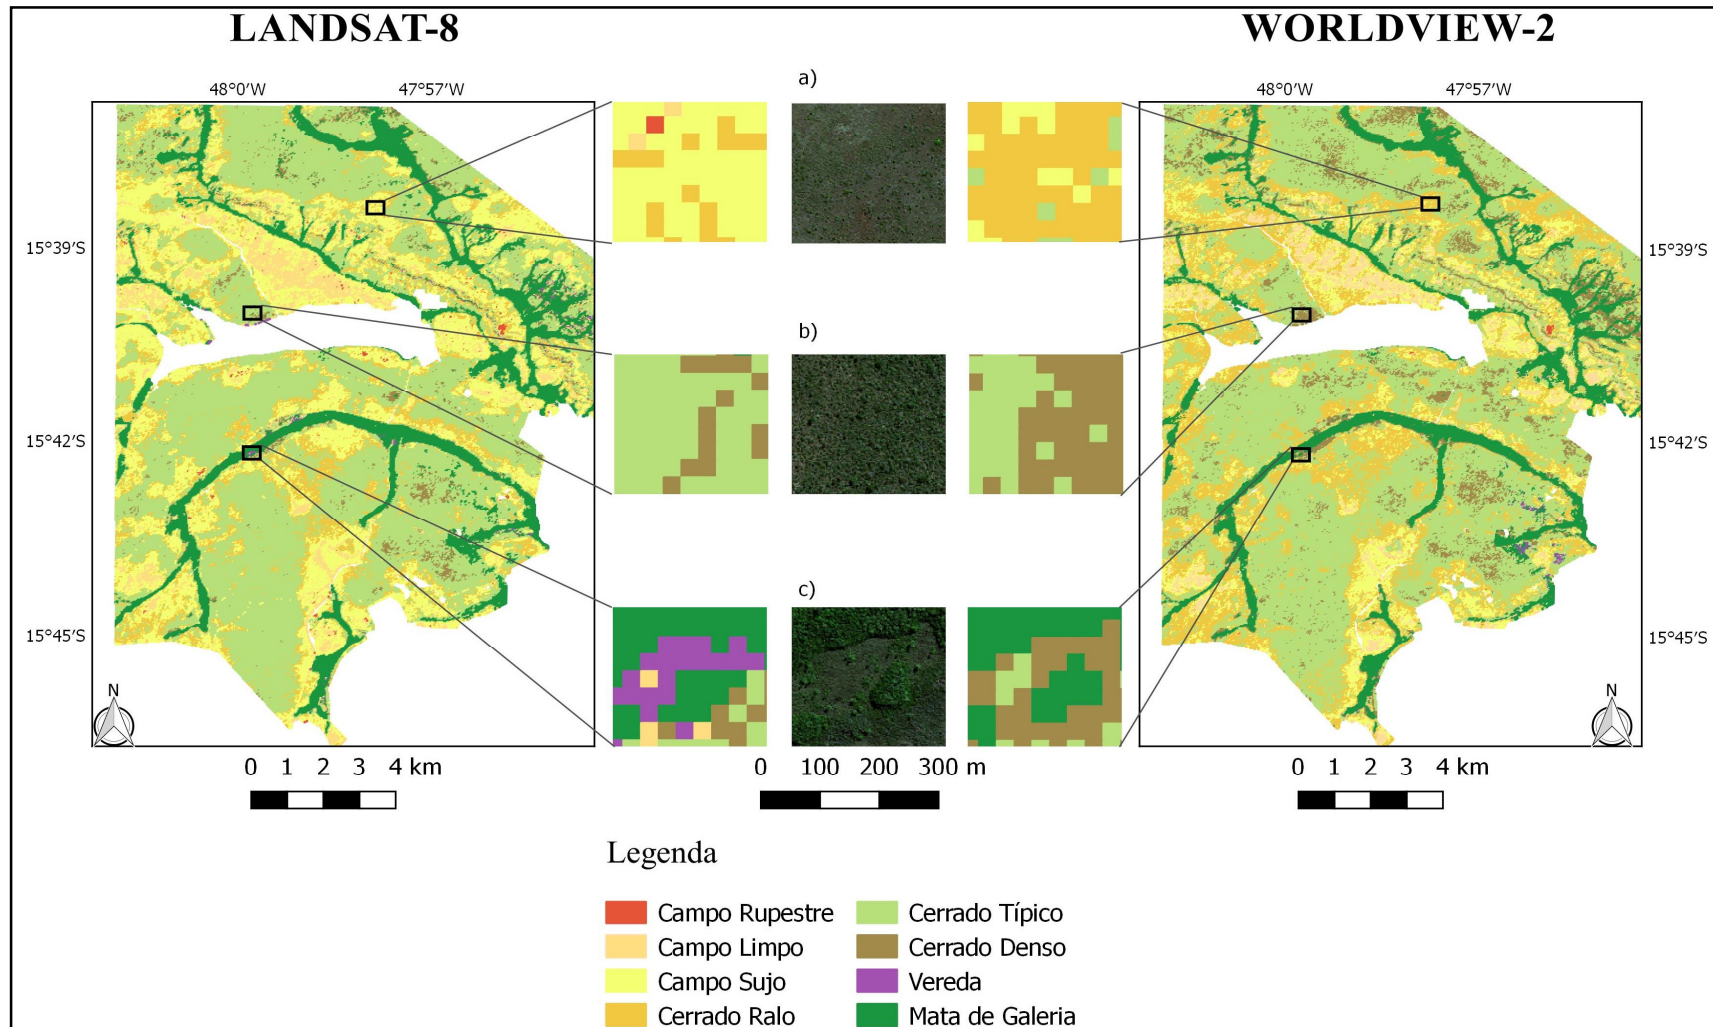
superior a desta legenda (74,3%). Todavia os autores não discriminaram as classes de Veredas nem de Cerrado Denso, que apresentaram dificuldades na classificação com imagens de alta resolução

Comparação Landsat-8 vs WorldView-2:

Novamente, a classificação da imagem WorldView-2 apresentou melhores resultados do que a imagem Landsat-8. As TA foram de 68,08% e 65,16%, respectivamente. As diferenças obtidas na Legenda N2 se mantêm para classes em comum (Campo Rupestre, Campo Limpo e Campo Sujo), entretanto as classes de Cerrado Ralo e Cerrado Denso apresentaram baixas TAC para as duas imagens, os melhores resultados foram de 40,71% e 42,39% para a imagem WorldView-2, respectivamente. A classe de Cerrado Típico apresentou boas TA para ambas as imagens, sendo que para a imagem WorldView-2 esse valor foi de 85,93%. Os mapas gerados para ambas as imagens estão na Figura 7.3.

A Legenda N3 é bastante detalhada em termos de variação da vegetação em relação a porcentagem de cobertura do dossel e apresenta dificuldades na classificação. A discriminação das subdivisões do Cerrado *Stricto Sensu* (Cerrado Ralo e Cerrado Denso, principalmente) ainda é uma tarefa árdua para o sensoriamento remoto. Embora essas dificuldades, a Legenda N3 obteve melhores resultados com a imagem WorldView-2.

Figura 7.3: Mapas temáticos com detalhes para a Legenda N3.



a) região majoritária de Cerrado Ralo com melhor detecção para a imagem WorldView-2; b) região de transição entre Cerrado Típico e Cerrado Denso, com melhor detecção para a imagem WorldView-2; c) região de veredas detectada apenas para a imagem Landsat-8.

Fonte: Produção do autor.

7.4 Classificação para a Legenda N4:

Landsat-8:

A Legenda N4 apresentou as classes de Campo Limpo Úmido e Campo Limpo Úmido com Murundu. Entretanto, elas não foram identificadas com boa TAC na imagem Landsat-8 (Tabela 7.13). Os valores de TAC para essas classes no conjunto RGB foi de 6,49% e 1,42%, indicando que elas praticamente não foram classificadas corretamente em nenhuma ocasião. O uso das bandas do Amarelo, *Red-Edge*, NIR1 e NIR2 também não melhorou os valores de TAC para as duas classes. O conjunto com todos os dados de Reflectância aumentou a TAC para a classe Campo Limpo Úmido para 11,77%, mas o valor ainda é muito baixo.

O uso dos atributos do MLME junto ao conjunto de Reflectância ainda elevou a TAC da classe Campo Limpo Úmido para 19,97%, sendo este o maior valor obtido para a Legenda N4. A classe de CLUCM apresentou valores de EO sempre superiores a 97%, indicando que esta classe não é classificada corretamente em nenhum momento.

Mesmo as classes de Campo Limpo Úmido e Campo Limpo Úmido com Murundu não apresentando bons valores de TAC, a matriz de confusão revela que estas classes são, comumente, classificadas como Cerrado Ralo ou Cerrado Típico. Conforme mostrado na caracterização espectral, essas fitofisionomias se assemelharam as classes de Cerrado Ralo e Cerrado Típico, tanto em termos de Reflectância das bandas, quanto em valores das componentes do MLME. Para a Tabela 7.14, podemos notar que existe uma concentração de erros de classificação destas duas classes com as classes de Campo Sujo, Cerrado Ralo e Cerrado Típico. Isso mostra que a principal dificuldade de classificação destas áreas é com outras fitofisionomias que não são variações do Campo Limpo. França e Sano (2011) obtiveram dificuldade em separar a classe de Campo Limpo Úmido de Campo Limpo, entretanto, com a avaliação dos dados deste trabalho, pode-se concluir que os desafios encontram-se em separar estas classes com relação à fitofisionomias de Campo Sujo, Cerrado Ralo e Cerrado Típico. Os autores obtiveram uma TA de 51,5%.

Tabela 7.13: Avaliação da classificação para a Legenda N4 – imagem Landsat-8.

Conjunto	Classes	TAC	EO	Taxa de acerto Global
RGB	Campo Rupestre	29,98 ± 4,29	70,02 ± 4,29	58,34 ± 0,40
	CLU	6,49 ± 1,87	93,51 ± 1,87	
	CLU com Murundu	1,42 ± 2,99	98,58 ± 2,99	
	Campo Limpo	53,97 ± 1,65	46,03 ± 1,65	
	Campo Sujo	52,18 ± 1,50	47,82 ± 1,50	
	Cerrado Ralo	31,07 ± 0,79	68,93 ± 0,79	
	Cerrado Típico	81,02 ± 0,50	18,98 ± 0,50	
	Cerrado Denso	25,08 ± 1,65	74,92 ± 1,65	
	Vereda	0,00 ± 0,00	100,00 ± 0,00	
	Mata de Galeria	90,74 ± 0,93	9,26 ± 0,93	
RGB +NIR	Campo Rupestre	25,00 ± 0,00	75,00 ± 0,00	60,37 ± 0,23
	CLU	5,90 ± 2,78	94,10 ± 2,78	
	CLU com Murundu	0,00 ± 0,00	100,00 ± 0,00	
	Campo Limpo	50,87 ± 1,85	49,13 ± 1,85	
	Campo Sujo	55,64 ± 1,09	44,36 ± 1,09	
	Cerrado Ralo	32,28 ± 1,07	67,72 ± 1,07	
	Cerrado Típico	84,50 ± 0,35	15,5 ± 0,35	
	Cerrado Denso	27,48 ± 1,32	72,52 ± 1,32	
	Vereda	0,00 ± 0,00	100,00 ± 0,00	
	Mata de Galeria	91,95 ± 0,58	8,05 ± 0,58	
RGB SWIR	Campo Rupestre	17,53 ± 2,62	82,47 ± 2,62	61,93 ± 0,40
	CLU	5,31 ± 4,35	94,69 ± 4,35	
	CLU com Murundu	2,13 ± 3,43	97,87 ± 3,43	
	Campo Limpo	53,10 ± 2,02	46,90 ± 2,02	
	Campo Sujo	59,47 ± 1,48	40,53 ± 1,48	
	Cerrado Ralo	33,29 ± 0,94	66,71 ± 0,94	
	Cerrado Típico	84,89 ± 0,55	15,11 ± 0,55	
	Cerrado Denso	26,04 ± 2,16	73,96 ± 2,16	
	Vereda	30,00 ± 4,71	70,00 ± 4,71	
	Mata de Galeria	93,73 ± 0,68	6,27 ± 0,68	
Reflectância	Campo Rupestre	23,34 ± 5,25	76,66 ± 5,25	63,15 ± 0,50
	CLU	11,77 ± 4,78	88,23 ± 4,78	
	CLU com Murundu	0,71 ± 2,25	99,29 ± 2,25	
	Campo Limpo	51,75 ± 2,06	48,25 ± 2,06	
	Campo Sujo	60,00 ± 1,46	40,00 ± 1,46	
	Cerrado Ralo	34,03 ± 1,02	65,97 ± 1,02	
	Cerrado Típico	86,68 ± 0,88	13,32 ± 0,88	
	Cerrado Denso	27,63 ± 2,14	72,37 ± 2,14	
	Vereda	29,00 ± 3,16	71,00 ± 3,16	
	Mata de Galeria	94,71 ± 0,35	5,29 ± 0,35	

Tabela 7.13: Conclusão

Conjunto	Classes	TAC	EO	Taxa de acerto Global
Reflectância +MLME	Campo Rupestre	25,00 ± 0,00	75,00 ± 0,00	63,67 ± 0,47
	CLU	19,97 ± 4,10	80,03 ± 4,10	
	CLU com Murundu	0,00 ± 0,00	100,00 ± 0,00	
	Campo Limpo	48,65 ± 2,69	51,35 ± 2,69	
	Campo Sujo	58,44 ± 1,34	41,56 ± 1,34	
	Cerrado Ralo	33,71 ± 1,29	66,29 ± 1,29	
	Cerrado Típico	88,50 ± 0,62	11,50 ± 0,62	
	Cerrado Denso	33,95 ± 2,39	66,05 ± 2,39	
	Vereda	27,00 ± 4,83	73,00 ± 4,83	
	Mata de Galeria	96,36 ± 0,56	3,64 ± 0,56	
Reflectância +TC	Campo Rupestre	17,53 ± 2,62	82,47 ± 2,62	64,06 ± 0,39
	CLU	15,28 ± 2,99	84,72 ± 2,99	
	CLU com Murundu	0,71 ± 2,24	99,29 ± 2,24	
	Campo Limpo	48,27 ± 1,80	51,73 ± 1,80	
	Campo Sujo	60,85 ± 1,41	39,15 ± 1,41	
	Cerrado Ralo	36,11 ± 1,58	63,89 ± 1,58	
	Cerrado Típico	87,86 ± 0,66	12,14 ± 0,66	
	Cerrado Denso	33,97 ± 2,79	66,03 ± 2,79	
	Vereda	25,00 ± 7,07	75,00 ± 7,07	
	Mata de Galeria	95,70 ± 0,00	4,30 ± 0,00	
Reflectância +IVs	Campo Rupestre	15,84 ± 6,16	84,16 ± 6,16	65,12 ± 0,46
	CLU	18,20 ± 3,32	81,8 ± 3,32	
	CLU com Murundu	0,00 ± 0,00	100,00 ± 0,00	
	Campo Limpo	51,75 ± 1,78	48,25 ± 1,78	
	Campo Sujo	62,84 ± 1,18	37,16 ± 1,18	
	Cerrado Ralo	40,53 ± 1,86	59,47 ± 1,86	
	Cerrado Típico	88,07 ± 0,65	11,93 ± 0,65	
	Cerrado Denso	28,28 ± 1,81	71,72 ± 1,81	
	Vereda	8,00 ± 4,21	92,00 ± 4,21	
	Mata de Galeria	95,48 ± 0,46	4,52 ± 0,46	
TODOS	Campo Rupestre	18,35 ± 5,27	81,65 ± 5,27	65,21 ± 0,42
	CLU	18,19 ± 1,87	81,81 ± 1,87	
	CLU com Murundu	0,71 ± 2,25	99,29 ± 2,25	
	Campo Limpo	47,16 ± 1,40	52,84 ± 1,40	
	Campo Sujo	63,32 ± 1,13	36,68 ± 1,13	
	Cerrado Ralo	39,15 ± 0,93	60,85 ± 0,93	
	Cerrado Típico	88,25 ± 0,72	11,75 ± 0,72	
	Cerrado Denso	34,10 ± 1,73	65,90 ± 1,73	
	Vereda	21,00 ± 3,16	79,00 ± 3,16	
	Mata de Galeria	95,70 ± 0,00	4,30 ± 0,00	

*+MLME – adição do conjunto com dados do Modelo Linear de Mistura Espectral; +TC – adição do conjunto com dados da Transformada *Tasseled Cap*; +IVs adição do conjunto dos Índices de Vegetação;

Fonte: Produção do Autor.

Tabela 7.14: Matriz de confusão para a imagem Landsat-8 – Legenda N4.

		Classe Real									
		Campo Rupestre	CLU	CLU com Murundu	Campo Limpo	Campo Sujo	Cerrado Ralo	Cerrado Típico	Cerrado Denso	Vereda	Mata de Galeria
Predição	Campo Rupestre	3	0	0	0	1	0	0	0	0	0
	CLU	0	3	0	1	1	1	0	0	1	0
	CLU com Murundu	0	0	1	0	1	0	1	0	0	0
	Campo Limpo	2	2	0	39	27	0	0	0	0	0
	Campo Sujo	6	6	3	39	137	49	4	1	0	0
	Cerrado Ralo	1	0	4	2	33	73	24	0	0	0
	Cerrado Típico	0	4	6	0	10	64	332	38	2	1
	Cerrado Denso	0	0	0	0	1	1	11	22	1	2
	Vereda	0	1	0	0	0	0	0	1	2	1
	Mata de Galeria	0	1	0	0	0	0	1	1	4	89

CLU – Campo Limpo Úmido

Fonte: Produção do Autor.

WorldView-2:

As classes de Campo Limpo Úmido e Campo Limpo Úmido com Murundu não foram discriminadas com boa precisão para a imagem WorldView-2 (Tabela 7.15). O conjunto RGB apresentou TAC de 0,59% e 1,42% para estas classes, respectivamente. A banda do Amarelo não contribuiu para identificação dessas classes. Já o uso das bandas *Red-Edge*, NIR1 e NIR2 mostrou um aumento na TAC da classe de Campo Limpo Úmido. O conjunto com todos os dados de Reflectância apresentou um valor de 26,45% para a classe de Campo Limpo Úmido. O uso dos Índices de Vegetação ainda aumentou esse valor para 32,35% e, quando todos os atributos foram utilizados na classificação a melhor TAC para a classe de Campo Limpo Úmido foi obtida (35,30%).

A Tabela 7.16 representa a matriz de confusão para o melhor classificador com o conjunto contendo todos os dados e corrobora com a discussão feita para a imagem Landsat-8, de que as classes de Campo Limpo Úmido e Campo Limpo Úmido com Murundu se assemelham as classes de Campo Sujo, Cerrado Ralo e Cerrado Típico.

Tabela 7.15: Avaliação da classificação para a Legenda N1 – imagem WorldView-2.

Conjunto	Classes	TAC	EO	Taxa de acerto Global
RGB	Campo Rupestre	68,36 ± 3,50	31,64 ± 3,50	63,21 ± 0,53
	CLU	0,59 ± 1,87	99,41 ± 1,87	
	CLU com Murundu	1,42 ± 2,99	98,58 ± 2,99	
	Campo Limpo	53,95 ± 1,17	46,05 ± 1,17	
	Campo Sujo	59,14 ± 1,27	40,86 ± 1,27	
	Cerrado Ralo	34,40 ± 0,90	65,60 ± 0,90	
	Cerrado Típico	84,05 ± 0,61	15,95 ± 0,61	
	Cerrado Denso	40,18 ± 2,14	59,82 ± 2,14	
	Vereda	20,00 ± 0,00	80,00 ± 0,00	
	Mata de Galeria	95,48 ± 0,87	4,52 ± 0,87	
RGB +Amarelo	Campo Rupestre	72,51 ± 4,01	27,49 ± 4,01	62,73 ± 0,49
	CLU	1,77 ± 2,85	98,23 ± 2,85	
	CLU com Murundu	1,42 ± 2,99	98,58 ± 2,99	
	Campo Limpo	50,75 ± 2,06	49,25 ± 2,06	
	Campo Sujo	60,01 ± 1,29	39,99 ± 1,29	
	Cerrado Ralo	32,59 ± 0,81	67,41 ± 0,81	
	Cerrado Típico	83,32 ± 0,88	16,68 ± 0,88	
	Cerrado Denso	39,70 ± 1,31	60,30 ± 1,31	
	Vereda	10,00 ± 0,00	90,00 ± 0,00	
	Mata de Galeria	95,59 ± 0,35	4,41 ± 0,35	
RGB +RE	Campo Rupestre	65,02 ± 3,54	34,98 ± 3,54	65,78 ± 0,45
	CLU	17,61 ± 2,76	82,39 ± 2,76	
	CLU com Murundu	0,00 ± 0,00	100,00 ± 0,00	
	Campo Limpo	58,90 ± 1,65	41,10 ± 1,65	
	Campo Sujo	61,47 ± 1,17	38,53 ± 1,17	
	Cerrado Ralo	39,52 ± 1,06	60,48 ± 1,06	
	Cerrado Típico	84,86 ± 0,59	15,14 ± 0,59	
	Cerrado Denso	43,97 ± 1,65	56,03 ± 1,65	
	Vereda	0,00 ± 0,00	100,00 ± 0,00	
	Mata de Galeria	98,79 ± 0,35	1,21 ± 0,35	
RGB +NIR	Campo Rupestre	59,14 ± 2,66	40,86 ± 2,66	66,10 ± 0,49
	CLU	19,37 ± 2,85	80,63 ± 2,85	
	CLU com Murundu	0,00 ± 0,00	100,00 ± 0,00	
	Campo Limpo	63,20 ± 1,81	36,80 ± 1,81	
	Campo Sujo	60,23 ± 1,11	39,77 ± 1,11	
	Cerrado Ralo	40,55 ± 1,00	59,45 ± 1,00	
	Cerrado Típico	85,08 ± 0,79	14,92 ± 0,79	
	Cerrado Denso	42,57 ± 0,99	57,43 ± 0,99	
	Vereda	4,00 ± 5,16	96,00 ± 5,16	
	Mata de Galeria	99,56 ± 0,57	0,44 ± 0,57	

continua

Tabela 7.15: Continuação

Conjunto	Classes	TAC	EO	Taxa de acerto Global
Reflectância	Campo Rupestre	58,30 ± 0,00	41,70 ± 0,00	66,97 ± 0,48
	CLU	26,45 ± 3,11	73,55 ± 3,11	
	CLU com Murundu	0,00 ± 0,00	100,00 ± 0,00	
	Campo Limpo	66,92 ± 1,71	33,08 ± 1,71	
	Campo Sujo	63,99 ± 1,61	36,01 ± 1,61	
	Cerrado Ralo	38,08 ± 1,67	61,92 ± 1,67	
	Cerrado Típico	85,81 ± 0,72	14,19 ± 0,72	
	Cerrado Denso	39,70 ± 2,13	60,30 ± 2,13	
	Vereda	1,00 ± 3,16	99,00 ± 3,16	
	Mata de Galeria	99,67 ± 0,53	0,33 ± 0,53	
Reflectância +MLME	Campo Rupestre	50,00 ± 0,00	50,00 ± 0,00	67,48 ± 0,36
	CLU	27,63 ± 2,84	72,37 ± 2,84	
	CLU com Murundu	0,00 ± 0,00	100,00 ± 0,00	
	Campo Limpo	67,16 ± 1,31	32,84 ± 1,31	
	Campo Sujo	64,08 ± 1,20	35,92 ± 1,20	
	Cerrado Ralo	38,39 ± 1,21	61,61 ± 1,21	
	Cerrado Típico	87,34 ± 0,48	12,66 ± 0,48	
	Cerrado Denso	41,60 ± 1,93	58,40 ± 1,93	
	Vereda	3,00 ± 4,83	97,00 ± 4,83	
	Mata de Galeria	100,00 ± 0,00	0,00 ± 0,00	
Reflectância +TC	Campo Rupestre	55,81 ± 4,00	44,19 ± 4,00	66,74 ± 0,35
	CLU	27,63 ± 3,98	72,37 ± 3,98	
	CLU com Murundu	0,00 ± 0,00	100,00 ± 0,00	
	Campo Limpo	65,3 ± 1,58	34,7 ± 1,58	
	Campo Sujo	64,01 ± 1,35	35,99 ± 1,35	
	Cerrado Ralo	37,34 ± 1,25	62,66 ± 1,25	
	Cerrado Típico	86,37 ± 0,63	13,63 ± 0,63	
	Cerrado Denso	37,94 ± 2,43	62,06 ± 2,43	
	Vereda	2,00 ± 4,21	98,00 ± 4,21	
	Mata de Galeria	100,00 ± 0,00	0,00 ± 0,00	
Reflectância +IVs	Campo Rupestre	52,49 ± 4,01	47,51 ± 4,01	68,52 ± 0,53
	CLU	32,35 ± 4,17	67,65 ± 4,17	
	CLU com Murundu	0,00 ± 0,00	100,00 ± 0,00	
	Campo Limpo	70,60 ± 1,72	29,4 ± 1,72	
	Campo Sujo	64,80 ± 0,71	35,2 ± 0,71	
	Cerrado Ralo	39,47 ± 1,36	60,53 ± 1,36	
	Cerrado Típico	87,43 ± 0,61	12,57 ± 0,61	
	Cerrado Denso	47,29 ± 2,46	52,71 ± 2,46	
	Vereda	0,00 ± 0,00	100,00 ± 0,00	
	Mata de Galeria	98,79 ± 0,35	1,21 ± 0,35	

Tabela 7.15: Conclusão

Conjunto	Classes	TAC	EO	Taxa de acerto Global
TODOS	Campo Rupestre	50,00 ± 0,00	50,00 ± 0,00	68,60 ± 0,49
	CLU	35,30 ± 6,22	64,70 ± 6,22	
	CLU com Murundu	0,00 ± 0,00	100,00 ± 0,00	
	Campo Limpo	70,00 ± 0,86	30,00 ± 0,86	
	Campo Sujo	65,37 ± 1,65	34,63 ± 1,65	
	Cerrado Ralo	41,28 ± 1,63	58,72 ± 1,63	
	Cerrado Típico	86,41 ± 0,54	13,59 ± 0,54	
	Cerrado Denso	45,39 ± 2,37	54,61 ± 2,37	
	Vereda	0,00 ± 0,00	100,00 ± 0,00	
	Mata de Galeria	98,79 ± 0,35	1,21 ± 0,35	

*+MLME – adição do conjunto com dados do Modelo Linear de Mistura Espectral; +TC – adição do conjunto com dados da Transformada *Tasseled Cap*; +IVs adição do conjunto com dados dos Índices de Vegetação; +NIR – Adição das banda NIR1 e NIR2; +Amarelo – Adição da banda do Amarelo; +RE – Adição da banda *Red-Edge*.

Fonte: Produção do Autor.

Tabela 7.16: Matriz de confusão para a imagem WorldView-2 – Legenda N4.

		Classe Real									
		Campo Rupestre	CLU	CLU com Murundu	Campo Limpo	Campo Sujo	Cerrado Ralo	Cerrado Típico	Cerrado Denso	Vereda	Mata de Galeria
Predição	Campo Rupestre	7	0	0	1	0	0	0	0	0	0
	CLU	0	6	0	0	0	0	0	0	0	0
	CLU com Murundu	0	0	0	0	0	2	0	0	0	0
	Campo Limpo	2	2	0	58	17	1	0	0	0	0
	Campo Sujo	3	4	4	22	140	46	5	0	0	0
	Cerrado Ralo	0	1	7	0	41	79	29	0	0	0
	Cerrado Típico	0	4	3	0	13	60	325	29	3	0
	Cerrado Denso	0	0	0	0	0	0	14	27	4	0
	Vereda	0	0	0	0	0	0	0	1	0	0
	Mata de Galeria	0	0	0	0	0	0	0	1	3	92

Fonte: Produção do Autor.

Comparação Landsat-8 vs WorldView-2:

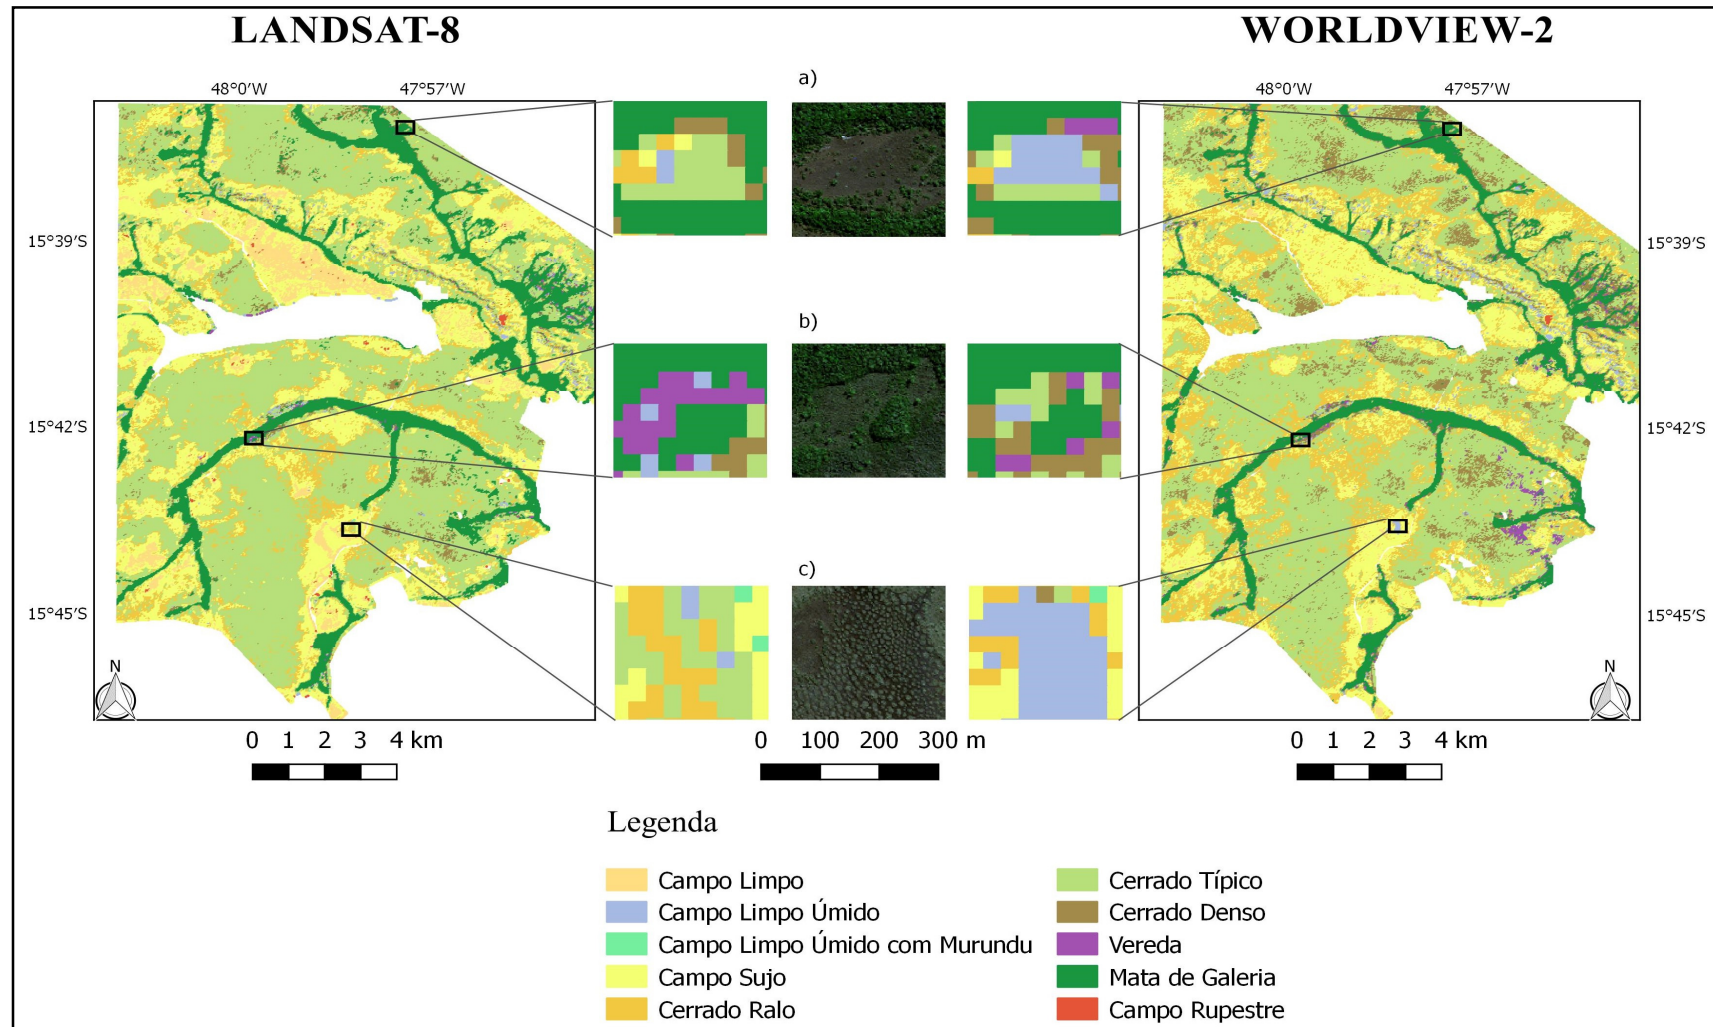
A Legenda N4 apresenta valores de TA muito similares a Legenda N3. A dificuldade em discriminação das classes de Campo Limpo Úmido e Campo Limpo Úmido com Murundu foi evidente. A melhor TAC para a classe de Campo Limpo

Úmido foi obtida com a imagem WorldView-2, já a classe de Campo Limpo Úmido com Murundu obteve valores altos de EO para ambas as imagens.

Todavia, a discriminação destas classes da classe Campo Limpo, aumentou consideravelmente sua TAC. Conforme mostrado na caracterização espectral, a Legenda N3 apresentava uma grande quantidade de *outliers* para os Índices de Vegetação para essa classe. Esses pontos estavam relacionados as classes de Campo Limpo Úmido e Campo Limpo Úmido com Murundu. Desta maneira, a separação destas classes da classe Campo Limpo permitiu uma melhor discriminação da mesma. A TAC para a classe de Campo Limpo passou de 41,44% para a imagem Landsat-8 na Legenda N3 para 70,00% para a imagem WorldView-2 na Legenda N4.

Essa melhora na taxa de acerto resultou em uma alteração dos mapas temáticos, principalmente para a imagem WorldView-2 (Figura 7.4). A presença de Campo Limpo diminuiu consideravelmente e mesmo com uma TAC de 35,30%, a classe de Campo Limpo Úmido passou a ser representada.

Figura 7.4: Mapas temáticos com detalhes para a Legenda N4.



a) região de Campo Limpo Úmido (não detectada para a imagem Landsat-8) circundada por Mata de Galeria; b) região de Vereda não detectada para a imagem WorldView-2; c) região de Campo Limpo Úmido com Murundu classificada de maneira incorreta em ambas as imagens.

Fonte: Produção do autor.

7.5 Classificação usando os atributos de textura

Nesta seção foi realizada a classificação com os atributos de textura. Estes atributos mostram potencial em melhorar os resultados da classificação nos trabalhos de Carvalho *et al.* (2010) e Girolamo Neto *et al.* (2017). Esta avaliação foi feita somente na imagem WorldView-2 e para a Legenda N4. Os atributos relacionados à Homogeneidade, Contraste, Dissimilaridade, Entropia, Segundo Momento Angular e Correlação da matriz GLCM foram calculados para individualmente para cada um dos 18 atributos utilizados na classificação da imagem WorldView-2 (7 atributos de Reflectância, 3 componentes do MLME, 3 componentes da Transformada TC e 5 Índices de Vegetação). Isso resultou em um conjunto de dados com um total de 126 atributos (108 de textura e 18 dos outros tipos).


A classificação com atributos de textura foi realizada com e sem métodos de seleção de atributos. Os métodos de seleção de atributos utilizados foram *Wrapper*, *Correlation Feature Selection (CFS)*, *InfoGain* e *GainRatio*. O método de seleção de atributos que apresentou melhor resultado foi o CFS. Os atributos selecionados por este método estão na Figura 7.5. A classificação com atributos de textura sem a seleção de atributos mostrou TA inferior ao mesmo procedimento realizado com seleção de atributos (Tabela 7.17).

Os atributos de Reflectância selecionados foram todas as bandas do visível e também a banda NIR2. A banda do amarelo foi responsável pela melhora na TAC da classe Campo Rupestre. Enquanto que a banda NIR2 melhorou a TAC das classes Campo Limpo Úmido, Campo Limpo, Cerrado Ralo, Cerrado Típico, Cerrado Denso e Mata de Galeria para a Legenda N4. Estas cinco bandas representam um conjunto similar ao conjunto de Reflectância, ou seja, está sendo representado os Valores de Reflectância espectral dos alvos tanto na faixa do visível quanto na faixa do NIR.

Apesar das componentes do MLME terem sido selecionadas, o uso destes atributos não apresentou melhora na TA da Legenda N4. Houve a melhora pontual de algumas classes como Cerrado Típico e Cerrado Denso. Em contrapartida, os Índices de Vegetação selecionados foram o NDVI, o EVI e o MSAVI2. A adição de Índices de Vegetação melhorou estatisticamente a TA para a Legenda N4 em relação ao conjunto de Reflectância, mostrando que seu uso é importante para discriminar as fitofisionomias do Cerrado (p valor do teste-t = $1,18 * 10^{-4}$).

Com relação aos atributos de textura selecionados, sua grande maioria esteve relacionada com a Entropia. A Entropia das mesmas bandas (Azul, Verde, Amarelo, Vermelho e NIR2) foram selecionadas, além da Entropia do NDVI. A Entropia da GLCM está ligada a desordem dos pixels em uma região, sendo que regiões heterogêneas têm um maior valor deste atributo, enquanto que regiões homogêneas têm menor valor (HALL BEYER, 2017). Girolamo Neto *et al.* (2017) mostraram que estes atributos foram são fundamentais para a discriminação das fitofisionomias do Cerrado pois formação de dossel intercalado com regiões de vegetação herbácea pode aumentar a Entropia em classes como Campo Sujo¹⁰, Cerrado Ralo e Cerrado Típico. O Segundo Momento Angular também está relacionado a estas características da vegetação, mas de maneira inversa a entropia.

Figura 7.5: Atributos selecionados pelo método *Correlation Feature Selection*.



Foram selecionados 5 atributos de Reflectância, 3 componentes do MLME, 3 índices de Vegetação e 9 atributos de textura da matriz GLCM.

Fonte: Produção do Autor.

¹⁰ Para a classe de Campo Sujo a Entropia capta a diferença entre arbustos e arvoretas em relação a regiões de solo exposto.

Já os atributos de correlação expressam que existe um comportamento previsível e linear entre dois pixels vizinhos dentro da região. Altos valores de correlação significam alta previsibilidade entre os relacionamentos dos pixels (HALL-BEYER, 2017). Para as fitofisionomias do Cerrado, estes atributos podem avaliar se a distribuição da vegetação é mais heterogênea, ou seja, se existe uma variação constante entre árvores e regiões com vegetação herbácea, por exemplo.

A Tabela 7.17 apresenta as medidas de avaliação da classificação na Legenda N4 e também com atributos de textura, com e sem seleção de atributos.

O uso de atributos de textura com seleção de atributos aumentou a PA de 68,60% para 74,17%. Este valor foi superior a TA obtida por Carvalho *et al.* (2010), que foi de 59,56% com o uso destes atributos. Mesmo com esta melhora, classes como Campo Limpo Úmido, Campo Limpo Úmido com Murundu e Veredas ainda apresentam dificuldades em serem classificadas com imagens de alta resolução. Em contrapartida, todas as outras classes da Legenda N4 apresentaram melhores valores de TAC em relação a classificação sem textura, exceto a classe de Campo Limpo, que manteve os mesmos valores.

A classe Campo Rupestre obteve TAC de 73,34%. A textura tem potencial em aumentar a separabilidade desta classe pois pode avaliar a alternância entre pixels de rocha e de vegetação herbácea. As classes de Campo Sujo aumentou sua TAC para 70,64%, obtendo valores superiores aos trabalhos de Schwieder *et al.* (2016) e Girolamo Neto *et al.* (2017). As Matas de Galeria mostraram uma TAC de 100%.

A Tabela 7.18 mostra a matriz de confusão para o classificador gerado com textura e seleção de atributos CSF, permitindo uma avaliação melhor de onde ocorreu a redução dos erros de classificação em comparação aos resultados obtidos para a classificação sem textura.

Tabela 7.17: Medidas de avaliação da classificação com e sem textura para a Legenda N4 – imagem WorldView-2.

Conjunto	Classes	TAC	EO	Taxa de acerto Global
Legenda N4	Campo Rupestre	50,00 ± 0,00	50,00 ± 0,00	68,60 ± 0,49
	CLU	35,30 ± 6,22	64,70 ± 6,22	
	CLU com Murundu	0,00 ± 0,00	100,00 ± 0,00	
	Campo Limpo	70,00 ± 0,86	30,00 ± 0,86	
	Campo Sujo	65,37 ± 1,65	34,63 ± 1,65	
	Cerrado Ralo	41,28 ± 1,63	58,72 ± 1,63	
	Cerrado Típico	86,41 ± 0,54	13,59 ± 0,54	
	Cerrado Denso	45,39 ± 2,37	54,61 ± 2,37	
	Vereda	0,00 ± 0,00	100,00 ± 0,00	
	Mata de Galeria	98,79 ± 0,35	1,21 ± 0,35	
Legenda N4 +Textura	Campo Rupestre	65,01 ± 5,29	34,99 ± 5,29	72,13 ± 0,48
	CLU	10,03 ± 2,85	89,97 ± 2,85	
	CLU com Murundu	0,00 ± 0,00	100,00 ± 0,00	
	Campo Limpo	62,72 ± 2,38	37,28 ± 2,38	
	Campo Sujo	72,80 ± 1,12	27,20 ± 1,12	
	Cerrado Ralo	46,28 ± 1,43	53,72 ± 1,43	
	Cerrado Típico	91,37 ± 1,08	8,63 ± 1,08	
	Cerrado Denso	44,91 ± 2,39	55,09 ± 2,39	
	Vereda	32,00 ± 9,19	68,00 ± 9,19	
	Mata de Galeria	99,78 ± 0,46	0,22 ± 0,49	
Legenda N4 +Textura +Seleção de atributos	Campo Rupestre	73,34± 3,50	26,66± 3,50	74,17 ± 0,18
	CLU	12,96± 2,45	87,04± 2,45	
	CLU com Murundu	0,00± 0,00	100,00± 0,00	
	Campo Limpo	70,64± 0,51	29,36± 0,51	
	Campo Sujo	72,51± 0,65	27,49± 0,65	
	Cerrado Ralo	52,71± 1,21	47,29± 1,21	
	Cerrado Típico	91,91± 0,40	8,09± 0,40	
	Cerrado Denso	49,68± 1,69	50,32± 1,69	
	Vereda	6,00± 5,16	94,00± 5,16	
	Mata de Galeria	100,00± 0,00	0,00± 0,00	

+Textura: adição de atributos de textura; +Seleção de atributos: Uso de métodos de seleção de atributos.

Fonte: Produção do Autor.

Tabela 7.18: Matriz de confusão para a imagem WorldView-2 e atributos de textura –
Legenda N4.

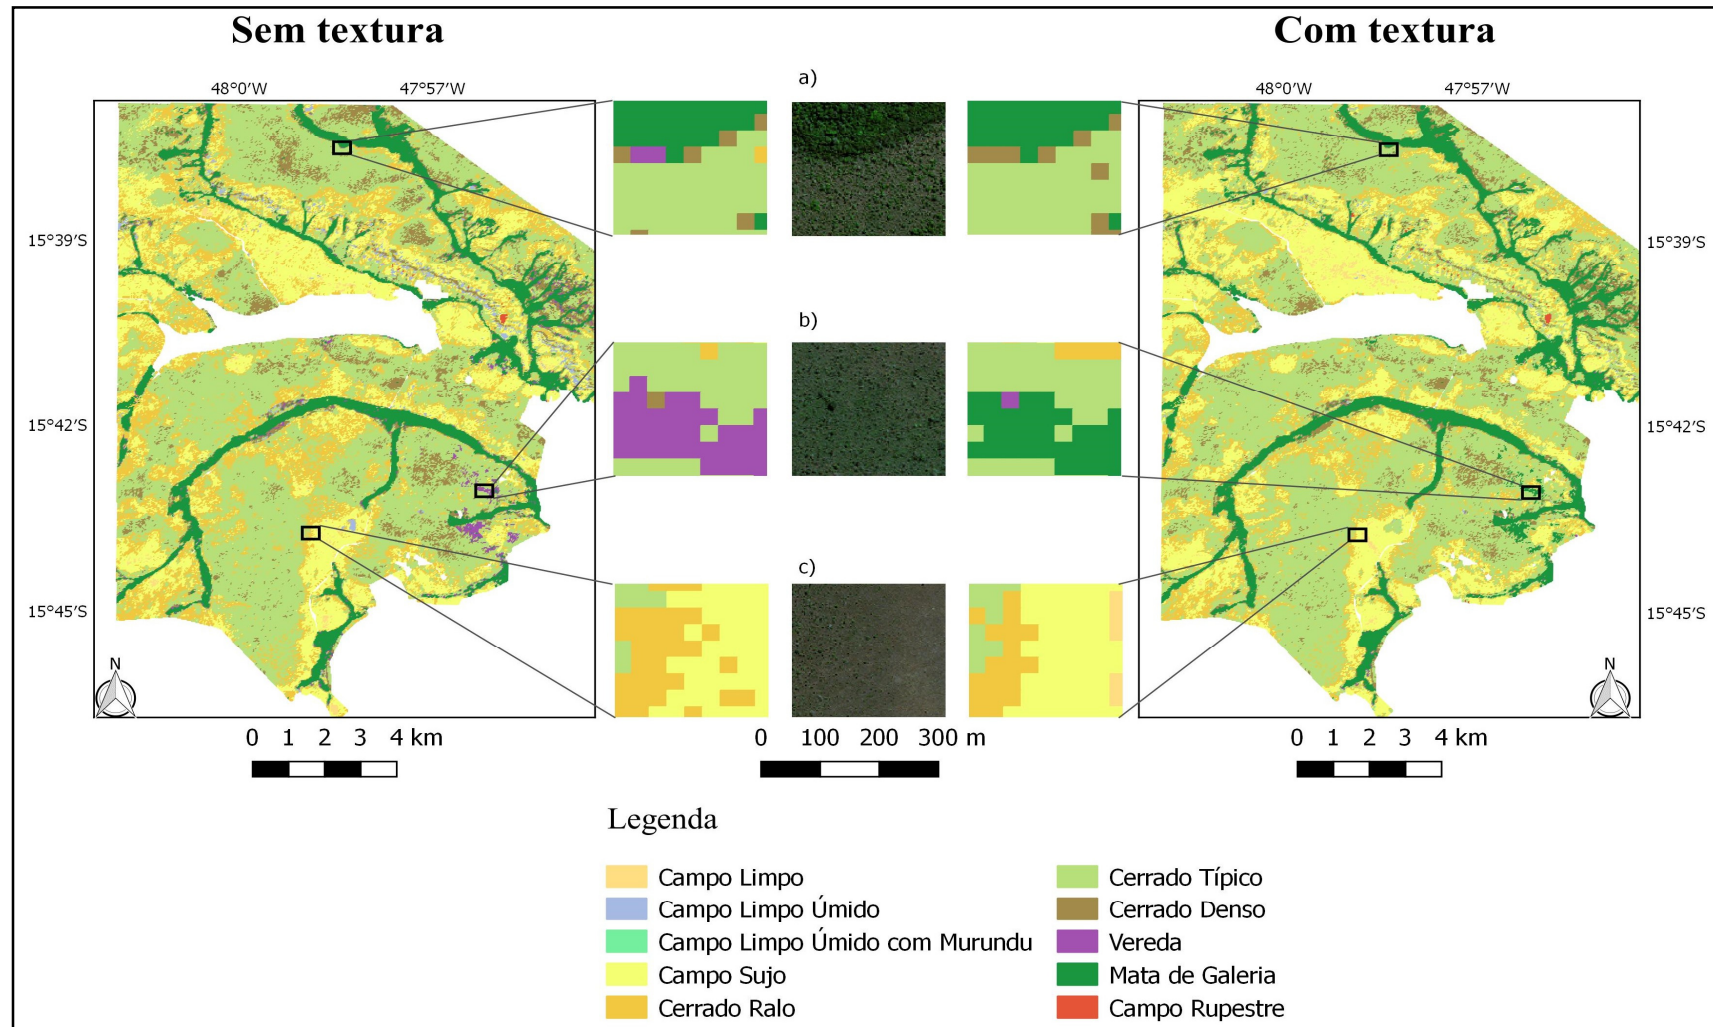
		Classe Real									
		Campo Rupestre	CLU	CLU com Murundu	Campo Limpo	Campo Sujo	Cerrado Ralo	Cerrado Típico	Cerrado Denso	Vereda	Mata de Galeria
Predição	Campo Rupestre	9	0	0	0	0	0	0	0	0	0
	CLU	0	2	0	0	0	0	0	0	0	0
	CLU com Murundu	0	0	0	0	0	1	0	0	0	0
	Campo Limpo	1	3	0	57	11	0	0	0	0	0
	Campo Sujo	1	5	3	24	154	30	0	0	0	0
	Cerrado Ralo	1	1	6	0	42	101	19	0	1	0
	Cerrado Típico	0	6	5	0	4	56	343	30	2	0
	Cerrado Denso	0	0	0	0	0	0	11	32	4	0
	Vereda	0	0	0	0	0	0	0	0	0	0
	Mata de Galeria	0	0	0	0	0	0	0	1	3	93

CLU – Campo Limpo Úmido

Fonte: Produção do Autor.

A redução dos erros com o uso de textura aconteceu, prioritariamente, pela redução dos erros entre fitofisionomias adjacentes. Houve uma redução de erros entre classes de Campo Sujo com Campo Limpo, Cerrado Ralo com Campo Sujo, Cerrado Típico com Cerrado Ralo e Cerrado Denso com Cerrado Típico. Essas classes apresentam alternância de regiões com vegetação arbórea e herbáceo-arbustiva, mostrando maior discriminação com o uso dos atributos de Entropia, de maneira análoga ao obtido por Girolamo Neto *et al.* (2017). A textura também foi responsável pela redução de erros de transição entre regiões campestres e savânicas, apontadas por Oliveira *et al.* (2007a), Ferreira *et al.* (2007), Carvalho *et al.* (2010), Schwieder *et al.* (2016) e Girolamo Neto *et al.* (2017b) como principal erro na classificação de fitofisionomias do Cerrado. A Figura 7.6 mostra que ocorre uma diminuição das regiões classificadas como Campo Limpo Úmido quando atributos de textura são utilizados. As regiões de transição entre classes também passaram a ser identificadas de uma maneira mais homogênea quando a textura foi utilizada.

Figura 7.6: Mapas temáticos com e sem o uso de atributos de textura.



a) região de transição entre Cerrado Típico e Mata de Galeria com pontos de Cerrado Denso; b) região de Cerrado Típico e Cerrado Ralo com a presença de capim gordura, ocasionando erros de classificação; c) melhor transição entre classes de Campo Sujo e Cerrado Ralo com textura.

Fonte: Produção do autor.

8 CONCLUSÃO

Atributos espectrais e texturas extraídos a partir de imagens Landsat-8 e WorldView-2, combinadas com técnicas de mineração de dados, foram utilizadas para classificar as fitofisionomias do Cerrado usando a legenda proposta por Ribeiro e Walter (2008). O potencial das bandas espectrais Amarelo, *Red-Edge*, Infravermelho próximo e do SWIR das imagens Landsat-8 e WorldView-2 para a discriminação das fitofisionomias do Cerrado foi analisado neste trabalho.

Além disso, a classificação baseada no algoritmo *Random Forest* foi avaliada para quatro diferentes níveis de legenda, levando em conta as diferentes resoluções espaciais e espectrais das imagens Landsat-8 e WorldView-2. Para viabilizar este estudo comparativo, a imagem WorldView-2 foi particionada em janelas de 15x15 pixels, considerada como uma unidade mínima de mapeamento denominada SuperPixel, compatível com o tamanho de pixel da imagem Landsat-8. Atributos como as componentes do Modelo Linear de Mistura Espectral e da Transformada *Tasseled Cap*, Índices de Vegetação, Reflectâncias das bandas complementares entre as duas imagens da área de estudo (Amarelo e *Red-Edge* para o WorldView-2 e SWIR1 e SWIR2 para o Landsat-8) e textura foram usados no processo de classificação. A escolha destes atributos baseou-se em estudos recentes sobre mapeamento das fitofisionomias do Cerrado, nos quais mostraram potencial para melhor discriminação entre algumas das classes propostas por Ribeiro e Walter (2008).

As análises de caracterização espectral das fitofisionomias do Cerrado mostraram que as mesmas são similares e que podem ser diferenciáveis, com boa taxa de acerto na classificação, apenas para as classes Florestal, Savânica e Campestre, definidas na legenda N1, para as duas imagens. As classes Campestre, Savânica e Florestal apresentaram taxas de acerto de classificação em torno de 80,96%, 91,63% e 98,90%, respectivamente. Estes valores foram superiores aos trabalhos que usaram legendas de classificação semelhantes a este trabalho, como Sano *et al.* (2008), Greechi *et al.* (2013), Borges e Sano (2014) e MMA (2015). Para as classes da legenda N1, as bandas *Red-Edge* e NIR melhoraram a discriminação entre as classes Campestre e Florestal, enquanto as bandas SWIR contribuíram para aumentar a taxa de acerto da classe Campestre.

Foi observado também que a separabilidade entre classes com maior nível de detalhamento como Campo Limpo, Campo Sujo e Campo Rupestre e as subdivisões do Cerrado *Stricto Sensu* (Cerrado Ralo, Cerrado Típico e Cerrado Denso) foi muito difícil usando apenas o atributo Reflectância. Para a legenda N4, com 10 classes, a taxa de acerto global da classificação foi de 65,21% e 68,60% para as imagens Landsat-8 e WorldView-2, respectivamente. Além disso, foi observada confusão entre as classes Campo Limpo, Campo Sujo, Cerrado Ralo e Cerrado Denso. As classes Campo Limpo Úmido, Campo Limpo Úmido com Murundu e Vereda não foram discriminadas com boa taxa de acerto (valores inferiores a 35%). Entretanto, observou-se que o uso da banda Amarelo combinada com as demais bandas do visível aumentou a taxa de acerto para a classe Campo Rupestre (71,51%).

O uso das componentes do Modelo Linear de Mistura Espectral e da Transformada *Tasseled Cap* no processo de classificação aumentou sutilmente a taxa de acerto de algumas classes, mas não contribuiu efetivamente para identificar as classes nas legendas mais detalhadas, principalmente na imagem WorldView-2. Entretanto, o uso de Índices de Vegetação foi essencial para melhorar a identificação das fitofisionomias de Cerrado com melhor taxa de acerto para as duas imagens, semelhante aos resultados obtidos por Liesenberg *et al.* (2007a), Carvalho *et al.* (2010) e Costa *et al.* (2014).

Devido às dificuldades observadas no processo de classificação das fitofisionomias usando os atributos citados anteriormente, os atributos de textura, definidos a partir da matriz GLCM, foram utilizados na classificação baseada no algoritmo *Random Forest* e mineração de dados da imagem WorldView-2. Os atributos mais relevantes para a classificação foram selecionados pelo método CFS (*Correlation Feature Selection*). Os atributos de textura foram calculados para os SuperPixels da imagem WorldView-2. O uso desses atributos aumentou a taxa de acerto global para 74,17%, maior valor obtido neste estudo para a legenda N4. É importante enfatizar que os resultados obtidos com o uso dos atributos de textura foram superiores aos obtidos por Oliveira *et al.* (2007), Carvalho *et al.* (2010), França e Sano (2010) e Schwieder *et al.* (2016).

Dentre os atributos selecionados pelo método CFS, destacam-se os atributos de Entropia. Estes atributos representam as variações entre regiões com vegetação arbórea intercaladas por regiões com vegetação herbáceo-arbustiva. Desta maneira, as classes

Cerrado Ralo, Cerrado Típico e Cerrado Denso, apresentaram melhorias consideráveis em suas taxas de acerto com a inclusão dos atributos de textura. As classes de Cerrado Ralo e Cerrado Denso apresentaram taxas de acerto (52,71% e 49,68%, respectivamente) similares aos obtidos por Schwieder *et al.* (2016) e Girolamo Neto *et al.* (2017b). Porém, a classe Cerrado Típico apresentou melhores resultados (taxa de acerto de 91,91%) do que os obtidos por Ferreira *et al.* (2007), Schwieder *et al.* (2016) e Girolamo Neto *et al.* (2017b), que foram de 91%, 66% e 79%, respectivamente.

As classes Campo Rupestre e Campo Sujo também apresentaram melhorias na taxa de acerto com o uso de atributos de textura, atingindo valores em torno de 73,34% e 72,51%, respectivamente. De acordo com Oliveira *et al.* (2007) e Costa *et al.* (2014), a discriminação da classe Campo Rupestre, usando imagens de média resolução espacial, é difícil e a taxa de acerto obtida foi baixa, em torno de 60%. A discriminação da classe Campo Sujo, com taxa de acerto de 72,51%, contribuiu para reduzir o erro de classificação em áreas de transição com Cerrado Ralo, observado como principal fonte de erro em outros estudos como os de Oliveira *et al.* (2007a), Ferreira *et al.* (2007), Schwieder *et al.* (2016) e Girolamo Neto *et al.* (2017b).

É importante dizer que a principal contribuição deste trabalho foi a análise detalhada realizada para a caracterização e discriminação das fitofisionomias do Cerrado, considerando diferentes níveis de legenda do sistema de classificação proposto por Ribeiro e Walter (2008), em um estudo comparativo de classificação de duas imagens com resoluções espacial e espectral diferentes. Devido à complexidade da cobertura vegetal do Cerrado, estas análises contribuíram para entender as características espectrais das fitofisionomias do Cerrado sob o ponto de vista da separabilidade entre as classes, que por sua vez subsidiaram o entendimento dos resultados da classificação dos tipos de cobertura vegetal do Cerrado. A exploração do potencial das bandas espectrais complementares nas imagens do WorldView-2 (Amarelo, *Red-Edge*) e Landsat-8 (SWIR1, SWIR2) mostraram que estas bandas são importantes para melhorar os resultados da classificação, em particular para algumas classes. Portanto, a hipótese de que o uso de imagens do WorldView -2 na classificação das fitofisionomias do Cerrado poderiam melhorar a identificação das classes foi confirmada pelos resultados deste trabalho.

Como desdobramento futuro desse trabalho, recomenda-se repetir as análises realizadas neste trabalho para outras áreas do Cerrado que têm classes de

fitofisionomias não presentes na área do Parque Nacional de Brasília, ou que possuem baixa ocorrência, como a classe Campo Limpo Úmido com Murundu. Outro desdobramento é o uso da segmentação de imagens no processo de classificação usando as técnicas de GEOBIA combinadas com as técnicas de mineração de dados. Neste caso, os problemas de transição entre os segmentos (bordas) na classificação devem ser levados em conta. Outra possibilidade é usar outros atributos combinados com as técnicas de seleção de atributos no processo de classificação, assim como foi feito com a adição do atributo textura no conjunto de atributos espectrais.

REFERÊNCIAS BIBLIOGRÁFICAS

- AGAPIOU, A. ; HADJIMITSIS, D.G.; ALEXAKIS, D.D. PAPADAVID, G.
Examining the phenological cycle of barley (*Hordeum vulgare*) using satellite and in situ spectroradiometer measurements for the detection of buried archaeological remains. **GIScience & Remote Sensing**, v. 49, n. 6, p. 854-872, 2012.
- ALLEN, T. F. H. Community ecology. In: DODSON, S. I.; LANGSTON, N. E.; TURNER, M. G.; CARPENTER, S. R.; KITCHELL, J. F.; JEANNE, R. L.; IVES, A. R.; ALLEN, T. F. H. (Eds.). **Ecology**. Oxford: Oxford University Press, 1998. p.315-383.
- ANJOS, C. S.; ALMEIDA, C. M.; RUIZ, P. R. S.; LACERDA, M.G. Feature selection and its impact on orbital imagery classification accuracy. In: GEOBIA, 2018, Montpellier, França. **Proceedings...** 2018. 12p.
- APTE, C.; WEISS, S. Data mining with decision trees and decision rules. **Future Generation Computer Systems**, v. 13, n. 2-3, p. 197-210, 1997.
- BAIG, M. H. A.; ZHANG, L.; SHUAI, T.; TONG, Q. Derivation of a tasseled cap transformation based on Landsat 8 at satellite reflectance. **Remote Sensing Letters**, v.5, n.5, p. 423-431, 2014.
- BELLE, V. **Detection and recognition of human faces using random forest for a mobile root.**2008.104p. Dissertação (Mestrado em Ciência da Computação) – Rwthachen University, Alemanha, 2008.
- BERK, A.; BERNSTEIN, L. S.; ROBERTSON, D. C. **MODTRAN**: a moderate resolution model for LOWTRAN. Burlington: Geophysics Laboratory, United States Air Force, 1987.
- BERK, A.; HAWES, F. Validation of MODTRAN® 6 and its line-by-line algorithm. **Journal of Quantitative Spectroscopy and Radiative Transfer**, v. 203, p. 542-556, 2017.
- BORGES, E. F.; SANO, E. E. Séries temporais de EVI do MODIS para o mapeamento de uso e cobertura vegetal do oeste da Bahia. **Boletim de Ciências Geodésicas**, v. 20, n. 3, p.526-547, 2014.

- BREIMAN, L. Random forests. **Machine Learning Journal**, v. 45, p. 5-32, 2001.
- BUSSAB, W.O; MORETTIN, P. A. **Estatística básica**. São Paulo: Saraiva, 2010.
- CARVALHO, L.; RAHMAN, M.; HAY, G.; YACKEL, J. Optical and SAR imagery for mapping vegetation gradients in Brazilian savannas: synergy between pixel-based and object-based approaches. In: INTERNATIONAL CONFERENCE OF GEOGRAPHIC OBJECT-BASED IMAGE, 38., 2010, Ghent, Belgica. **Proceedings...** 2010. p.1 – 7.
- CHAVEZ JUNIOR, P. S. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. **Remote Sensing of Environment**, v. 24, n. 3, p. 459-479, 1988.
- CIANCIARUSO, M. V.; SILVA, I. A.; BATALHA, M. A. Diversidades filogenética e funcional: novas abordagens para a ecologia de comunidades. **Biota Neotropica**, v. 9, n. 3, p. 93-103, 2009.
- Cochran, W.G. **Sampling techniques**. 3ed. New York: John Wiley & Sons, 1977. 428p.
- COSTA, W. S. **Mapeamento de formações campestres nativas e de pastagens cultivadas no cerrado Brasileiro utilizando mineração de dados**. 2014. 85p. (sid.inpe.br/mtc-m21b/2014/02.25.03.03-TDI). Dissertação (Mestrado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2014.
- COSTA, W. S.; FONSECA, L. M. G.; KORTING, T. S. Classificação de pastagens cultivadas e formações campestres nativas no Cerrado Brasileiro a partir da análise de séries temporais extraídas de índices EVI do sensor MODIS. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 17., 2015, João Pessoa, PB. **Anais...** São José dos Campos: INPE, 2015. p.1516-1523.
- COSTA, W. S.; FONSECA, L. M. G.; KORTING, T. S. Mapping grasslands formations and cultivated pastures in the brazilian Cerrado using data mining. In: INTERNATIONAL CONFERENCE ON ADVANCED GEOGRAPHIC INFORMATION SYSTEMS, APPLICATIONS AND SERVICES (GEOPROCESSING), 6., 2014, Barcelona, ES. **Proceedings...** 2014. p.138-141.

- COUTINHO, L. M. O bioma cerrado. In: KLEIN, A. L. (Org.). **Eugen Warming e o cerrado brasileiro: um século depois**. São Paulo: Editora UNESP, 2002. p.77-91.
- CRIST, E. P.; CICONE, R. C. A physically-based transformation of Thematic Mapper data-The TM Tasseled Cap. **IEEE Transactions on Geoscience and Remote Sensing**, v. GE-22, n. 3, p. 256-263. 1984.
- DASH, M.; LIU, H. Feature selection for classification. **Intelligent Data Analysis**, v. 1, n. 3, p. 131-156, 1997.
- DEMATTE, J. A. M.; SILVA, M. L. S.; ROCHA, G. C.; CARVALHO, L. A., FORMAGGIO, A. R.; FIRME, L. P. Variações espectrais em solos submetidos à aplicação de torta de filtro. **Revista Brasileira de Ciência do Solo**, v. 29, n. 3, p.317-326, 2005.
- EHLERS, M.; JANOWSKY, R.; GAEHLER, M. New remote sensing concepts for environmental monitoring. In: REMOTE SENSINGFOR ENVIRONMENTAL MONITORING, GIS APPLICATIONSAND GEOLOGY, 2002. **Proceedings...** 2002. p. 1-13.
- EMPRESA BRASILEIRADE PESQUISA AGROPECUÁRIA – EMBRAPA: **Correção do solo e adubação no sistema de plantio direto nos cerrados**. Rio de Janeiro: Embrapa Solos, 2003. 22 p.
- EXELIS VISUTAL INFORMATION SOLUTION. **ENVI classic tutorial: atmospherically correcting multispectral data using FLAASH**. Exelis, 2013.14p.
Disponível em:
http://www.harrisgeospatial.com/portals/0/pdfs/envi/FLAASH_Multispectral.pdf.
- FARIAS, M. F. R.; CARVALHO, A. P. F.; MARTINS, E. S.; CARVALHO JUNIOR, O. A.; REATTO, A; GOMES, R. A. T. Levantamento de solos do Parque Nacional de Brasília: Escala 1:50.000. Planaltina: Embrapa, 2019. 66 p.
- FAYYAD, U.; PIATETSKY-SHAPIRO, G.; SMYTH, P. From data mining to knowledge discovery in databases. **AI Magazine**, v. 17, n. 3, p. 37-54, 1996.

FERREIRA, L. G.; YOSHIOKA, H.; HUETE, A.; SANO, E. E. Seasonal landscape and spectral vegetation index dynamics in the Brazilian Cerrado: an analysis within the Large-Scale Biosphere–Atmosphere Experiment in Amazônia (LBA). **Remote Sensing of Environment**, v. 87, n. 4, p. 534-550, 2003.

FERREIRA, M. E.; FERREIRA, L. G.; SANO, E. E.; SHIMABUKURO, Y. E. Spectral linear mixture modeling approaches for land cover mapping of tropical savanna areas in Brazil. **International Journal of Remote Sensing**, v. 2, n.28, p. 413-429, 2007.

FERREIRA, M. E.; PECCININI, A. A.; FERREIRA, L. G.; HUETE, A. R. Análise da sazonalidade de paisagens antrópicas e nativas do bioma Cerrado através dos produtos MODIS índices de vegetação, área foliar e atividade fotossintética. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12., 2005, Goiânia, GO. **Anais...**São José dos Campos: INPE, 2005. p.505-512.

FOREST INVESTMENT PROGRAM - CERRADO. **Projeto de desenvolvimento de sistemas de prevenção de incêndios florestais e monitoramento da cobertura vegetal no Cerrado brasileiro**. Disponível em: <http://www.dpi.inpe.br/fipCerrado/dashboard.html>. Acesso em: 10 jul 2018.

FORMAGGIO, A. R.; EPIPHANIO, J. C. N., VALERIANO, M. M.; OLIVEIRA, J. B. Comportamento espectral (450-2.450 nm) de solos tropicais de São Paulo. **Revista Brasileira de Ciência do Solo**, v. 20, n. 3, p. 467-474, 1996.

FRANÇA, A. M. F.; SANO, E. E. Mapeamento de áreas de campo limpo úmido no Distrito Federal a partir de fusão de imagens multiespectrais. **Sociedade & Natureza**, v. 23, n. 2, p.197-209, 2011.

GIROLAMO NETO, C. D.; FONSECA, L. M. G. ; VALERIANO, D. M. ; NEVES, A. K. ; KORTING, T. S. Desafios na classificação automática de fitofisionomias do Cerrado brasileiro com base em mapas de referência na escala 1:250.000. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 18., 2017, Santos, SP. **Anais...** São José dos Campos: INPE, 2017. p. 6647-6654.

GIROLAMO NETO, C. D.; FONSECA, L. M. G.; KÖRTING, T. S. Assessment of texture features for Brazilian savanna classification: a case study in Brasília National Park. **Revista Brasileira de Cartografia**, v. 69, n. 5, p. 891-901. 2017.

GRABHERR, G.; KOJIMA, S. Vegetation diversity and classification systems. In: SOLOMON, A. M.; SHUGART, H. H. (Eds). **Vegetation dynamics & global change**. New York: Chapman & Hall, 1993. p.218-232.

GRECCHI, R. C.; GWYN, H. J. Q.; BÉNIÉ, G. B.; FORMAGGIO, A. R. Assessing the spatio-temporal rates and patterns of land-use and landcover changes in the Cerrados of southeastern Mato Grosso, Brazil. **International Journal of Remote Sensing**, v. 34, n. 15, p. 5369-5392, 2013.

GUSMÃO, R. P.; MAIO, C. R.; CARREIRA, M. E. P. C. S.; ESTEVES, M. G.; CASTELLO BRANCO, M. L. G.; AMÊNDOLA, P. L. **Diagnóstico Brasil: a ocupação do território e o meio ambiente**. Rio de Janeiro: IBGE, 1990. 170 p.

GUYON, I.; ELISSEEFF, A. An introduction to variable and feature selection. **Journal of Machine Learning Research**, v.3, p.1157-1182, 2003.

HADJIMITSIS, D.G.; PAPADAVID, G; AGAPIOU, A; THEMISTOCLEOUS, K; HADJIMITS, M.G.; RETAILS, A; CLAYTON, C.R.I. Atmospheric correction for satellite remotely sensed data intended for agricultural applications: impact on vegetation indices. **Natural Hazards and Earth System Sciences**, v. 10, n. 1, p. 89-95, 2010.

HADJIMITSIS, D. G.; CLAYTON, C. R. I.; HOPE, V. S. An assessment of the effectiveness of atmospheric correction algorithms through the remote sensing of some reservoirs. **International Journal of Remote Sensing**, v. 25, n. 18, p. 3651-3674, 2004.

HALL, M. A. **Correlation-based feature selection for machine learning**. 178p. Thesis (PhD on Computer Science) – University of Waikato, Nova Zelândia. 1999.

HALL-BEYER, M. **GLCM texture: atutorial v.3.0**. 2017. 75p. Disponível em: <https://prism.ucalgary.ca/handle/1880/51900>.

HAN, J.; KAMBER, M.; PEI, J. **Data mining: concepts and techniques**. San Francisco: Morgan Kaufmann Publishers, 2011. 743p.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. **IEEE Transactions on Systems, Man and Cybernetics**, v.SMC-3, n. 6, p. 610-621, 1973.

- HARRIS GEOSPATIAL SOLUTIONS. **EXELIS – ENVI**: Environment for visualizing imagens. Disponível em:
https://www.harrisgeospatial.com/docs/using_envi_Home.html. Acesso em: 24 jan. 2018.
- HOFFMANN, W. A.; ADASME, R.; HARIDASAN, M.; CARVALHO, M. T.; GEIGER, E. L.; PEREIRA, M. A. B.; GOTSCH, S. G.; FRANCO, A. C. Tree topkill, not mortality, governs the dynamics of savanna–forest boundaries under frequent fire in central Brazil. **Ecology**, v. 90, n. 5, p. 1326-1337, 2009.
- HONKAVAARA, E; ARBIOL, R.; MARKELIN, L.; MARTINEZ, L; CRAMER, M; BOVET, S; SCHLAPFER, D. Digital airborne photogrammetry: a new tool for quantitative remote sensing? a state-of-the-art review on radiometric aspects of digital photogrammetric images. **Remote Sensing**, v. 1, n. 3, p. 577-605, 2009.
- HUETE, A. R. A soil adjusted vegetation index SAVI. **Remote Sensing of Environment**, v. 25, p. 295–309, 1988.
- HUETE, A. R.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E.P.; GAO, X.; FERREIRA, L.G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v.83, n.1-2, p.195-213, 2002.
- HUETE, A. R.; LIU, Q.Q.; BATCHILY, K.; VAN LEEUWEN, W. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. **Remote Sensing of Environment**, v.59, n.3, p.440-451, 1997.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE) – **Mapas de biomas e vegetação**. Disponível em:
<https://ww2.ibge.gov.br/home/presidencia/noticias/21052004biomashtml.shtm>. Acesso em: 06 dez. 2015.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Manual técnico da vegetação brasileira**. 2. ed. Rio de Janeiro: IBGE, 2012. 271p.
- INSTITUTO CHICO MENDES DE CONSERVAÇÃO DA (ICMBio). **Parque Nacional de Brasília**. Disponível em:
<http://www.icmbio.gov.br/portal/visitacao1/unidades-abertas-a-visitacao/213-parque-nacional-de-brasilia.html>, Brasília: MMA, 2014a. Acesso em: 14 jul 2014.

- INSTITUTO CHICO MENDES DE CONSERVAÇÃO DA (ICMBio). **Plano de manejo do Parque Nacional de Brasília**. Brasília: MMA, 2014. 305p.
- INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE) FIP CERRADO. **PRODES**: monitoramento da Floresta Amazônica Brasileira por satélite. Disponível em: <http://www.obt.inpe.br/OBT/assuntos/programas/amazonia/prodes>. Acesso em: 11 jul. 2018.
- INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **Academic cooperation agreement**. Disponível em: http://www.inpe.br/institucional/sobre_inpe/relacoes_internacionais/arquivos/theDigitalGlobeFoundation.pdf. Acesso em: 29 nov. 2016.
- INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE – IPCC. **Good practice guidance for land use, land use change and forestry**. 2003. Disponível em: http://www.ipcc-nggip.iges.or.jp/public/gpplulucf/gpplulucf_contents.html. Acesso em: 24 mar. 2016.
- JANECEK, A; GANSTERER, W; DEMEL, M; ECKER On the relationship between feature selection and classification accuracy. In: SAEYS, Y.; LIU, H.; INZA, I.; WEHENKEL, L.; PEE, Y. V. (Eds.). **New challenges for feature selection in data mining and knowledge discovery**. [S.l.: s.n.], 2008. p. 90-105.
- JENSEN, J. R. **Remote sensing of the environment: an earth resource perspective 2/e**. [S.l.]: Pearson Education India, 2009.
- JIANG, Z.; HUETE, A.R.; DIDAN, K.; MIURA, T. Development of a two-band enhanced vegetation index without a blue band. **Remote Sensing of Environment**, v.112, n.10, p.3833-3845, 2008.
- JOHN, G. H.; KOHAVI, R. Wrappers for feature subset selection. **Artificial Intelligence**, v.97, n.1-2, p.273-324, 1997.
- KAUFMAN, Y. J.; SENDRA, C. Algorithm for automatic atmospheric corrections to visible and near-IR satellite imagery. **International Journal of Remote Sensing**, v. 9, n. 8, p. 1357-1381, 1988.

KAUTH, R. J.; THOMAS, G. S. The tasseled cap – a graphic description of the spectral-temporal development of agricultural crops as seen in Landsat. In: SYMPOSIUM ON MACHINE PROCESSING OF REMOTELY SENSED DATA, 1976, West Lafayette, Indiana. **Proceedings...** West Lafayette, Indiana:IEEE, 1976. p.41-51.

KLINK, C.; MACHADO, R. Conservation of the brazilian Cerrado. **Conservation Biology**, v. 19, n. 3, p. 707-713, 2005.

KÖRTING, T. S. **Geodma**: atoolbox integrating data mining with object-based and multi-temporal analysis of satellite remotely sensed imagery. 2012. 97p. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2012.

LIESENBERG, V.; PONZONI, F. J. ; GALVÃO, L. S. Discriminação espectral de algumas fitofisionomias do Cerrado Brasileiro através de dados multitemporais do sensor MODIS/TERRA. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis, SC. **Anais...** São José dos Campos: INPE, 2007b.

LIESENBERG, V.; PONZONI, F. J.; GALVÃO, L. S. Análise da dinâmica sazonal e separabilidade espectral de algumas fitofisionomias do Cerrado com índices de vegetação dos sensores Modis Terra e Aqua. **Revista Árvore**, v. 31, n. 2, p. 295-305, 2007a.

LYAPUSTIN, A.; WANG, Y.; LAZLO, I.; KAHN, R.; KORKIN; REID, J. SMultiangle implementation of atmospheric correction (MAIAC): 2. aerosol algorithm. **Journal of Geophysical Research: Atmospheres**, v. 116, n. D3, 2011.

MA, L.; FU, T.; BLASCHKE, T.; LI, M.; TIEDE, D.; ZHOU, Z.; CHEN, DE. Evaluation of feature selection methods for object-based land cover mapping of unmanned aerial vehicle imagery using random forest and support vector machine classifiers. **ISPRS International Journal of Geo-Information**, v. 6, n. 2, p. 51, 2017.

MACHADO, A. B. M.; FONSECA, G. A. B.; MACHADO, R. B.; AGUIAR, L. M. S., LINS, L. V. **Livro vermelho das espécies ameaçadas de extinção da fauna de Minas Gerais**. Belo Horizonte: Fundação Biodiversitas, 1998. 608p.

MAESSCHALCK, R.E.; JOUAN-RIMBAUD, D.; MASSART, D. L. The mahalanobis distance. **Chemometrics and Intelligent Systems**, v. 50, n. 1, p. 1-18, 2000.

MEDEIROS, M. B.; MIRANDA, H.S. Mortalidade pós-fogo em espécies lenhosas de campo sujo submetido a três queimadas prescritas anuais. **Acta Botânica Brasílica**, v. 19, n. 3, p. 493-500, 2005.

MENDONÇA, M. P.; LINS, L. V. **Lista vermelha das espécies ameaçadas de extinção da flora de Minas Gerais**. Belo Horizonte: Fundação Biodiversitas, 2000. 160 p.

MINISTÉRIO DO MEIO AMBIENTE (MMA) – **Mapeamento do uso e cobertura da terra do cerrado**: Projeto TerraClass Cerrado 2013. 2015. Disponível em: <http://www.mma.gov.br/publicacoes/biomas/category/62-cerrado>, 2015. Acesso em: 25 nov. 2015.

MINISTÉRIO DO MEIO AMBIENTE (MMA). **Desenvolvimento de sistema de prevenção de incêndios florestais e monitoramento da cobertura vegetal do Cerrado Brasileiro**. Brasília: MMA, 2016. 51p.

MINISTÉRIO DO MEIO AMBIENTE (MMA). **Programa de monitoramento ambiental dos biomas brasileiros**. Disponível em: <http://www.mma.gov.br/informma/item/618-ppcerrado>, Brasília: MMA, 2018c. Acesso em: 14 jul. 2018.

MINISTÉRIO DO MEIO AMBIENTE (MMA). **Proteção e combate ao desmatamento da Amazônia**. Disponível em: <http://www.mma.gov.br/informma/item/616-preven%C3%A7%C3%A3o-e-controle-do-desmatamento-na-amaz%C3%B4nia>, Brasília: MMA, 2018a. Acesso em: 12 jul. 2018.

MINISTÉRIO DO MEIO AMBIENTE (MMA). **Proteção e combate ao desmatamento do cerrado**. Brasília: MMA, 2018ba. Disponível em: <http://www.mma.gov.br/informma/item/618-ppcerrado>. Acesso em: 13 jul. 2018.

MIRANDA, H. S.; SATO, M. N.; NETO, W. N.; AIRES, F. S. Fires in the cerrado, the Brazilian savanna. In: MARK, C. (Ed.). **Tropical fire ecology**. Berlin: Springer, 2009. p.427-250.

MITCHELL, T. M. **Machine learning**. New York: Mcgraw-Hill, 1997. 421 p.

- MITTERMEIER, R. A.; TURNER, W. R.; LARSEN, F. W.; BROOKS, T. M.; GASCON, C. Global biodiversity conservation: the critical role of hotspots. In: ZACHOS, F. E.; HABEL, J. C. (Eds). **Biodiversity hotspots**. Berlin: Springer, Berlin, 2011. p.3-22.
- MOREIRA, A. G. Effects of fire protection on savanna structure in Central Brazil. **Journal of Biogeography**, v. 27, n. 4, p.1021-1029, 2000.
- MOREIRA, B.; PAUSAS, J.G. Tanned or burned: the role of fire in shaping physical seed dormancy. **Caderno de Geografia**, v. 7, n. 12, p. 1-8, 2012.
- MÜLLER, H; RUFIN, P.; GRIFFITHS, P.; SIQUEIRA, A. J. B.; HOSTERT, P. Mining dense Landsat time series for separating cropland and pasture in a heterogeneous Brazilian savanna landscape. In: SIMPÓSIOBRASILEIRODE SENSORIAMENTO REMOTO, 17., 2015, João Pessoa, PB. **Anais...**São José dos Campos, 2015. p.1133-1120.
- NEVES, A. K. **Mineração de dados de sensoriamento remoto para detecção e classificação de áreas de pastagem na Amazônia legal**. 2017. 77p.(id.inpe.br/mtc-m21b/2017/02.02.15.58-TDI). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2017.
- NEVES, A. K.; BENDINI, H. N. ; KORTING, T. S. ; FONSECA, L. M. G. . Combining time series features and data mining to detect land cover patterns: a case study in northern Mato Grosso State, Brazil. **Revista Brasileira de Cartografia**, v. 68, p. 1133-1142, 2016.
- OLIVEIRA, L. T.; CARVALHO, L. M. T.; ACERBI-JUNIOR, F. W. Fusão de imagens landsat e mineração de dados geográficos para mapear o cerrado dos municípios de Paraopeba e Caetanópolis - MG. In: SIMPÓSIOBRASILEIRODE SENSORIAMENTO REMOTO, 12., 2005, Goiânia, GO. **Anais...**São José dos Campos: INPE, 2005a. p.4171-4176.
- OLIVEIRA, L. T.; CARVALHO, L. M. T.; ACERBI-JUNIOR, F. W. Mineração de dados geográficos para mapear as fitofisionomias do bioma cerrado. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12., 2005, Goiânia, GO. **Anais...** São José dos Campos: INPE, 2005b. p.4177-4184.

OLIVEIRA, L. T.; OLIVEIRA, T. C. A.; CARVALHO, L. M. T.; LACERDA, W. S.; CAMPOS, S. R. S; MARTINHAGO, A. Z. Comparison of machine learning algorithms for mapping phytophysionomies of the brazilian Cerrado. In: BRAZILIAN SYMPOSIUM ON GEOINFORMATICS, 9., 2007, Campos do Jordão, SP. **Anais...** 2007b. p.195-205.

OLIVEIRA, M. E. A.; MARTINS, F. R.; CASTRO, A. A. J. F.; SANTOS, J. R. Classes de cobertura vegetal do Parque Nacional de Sete Cidades (transição campo-floresta) utilizando imagens TM/Landsat, NE do Brasil. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis, SC. **Anais...**São José dos Campos: INPE, 2007a. p.1775-1783.

OROZCO FILHO, J. C. **Avaliação do uso da abordagem orientada-objeto com imagens de alta resolução RapidEye na classificação de fitofisionomias do Cerrado.** 2017. 44p. Dissertação (Mestrado em Geografia) -Universidade de Brasília (UnB), Brasília, 2017.

OSHIRO, T. M. **Uma abordagem para a construção de uma única árvore a partir de uma Random Forest para classificação de bases de expressão gênica.** 2013. 90p.Dissertação (Mestrado em Bioinformática) – Universidade de São Paulo (USP), Riberão Preto, 2013.

PATHAK, B.; BAROOAH, D. Texture analysis based on the gray-level cooccurrence matrix considering possible orientations. **International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering**, v.2, n.9, p.4206-4212, 2013.

PEÑA, M.A.; BRENNING, A. Assessing fruit tree crop classification from Landsat-8 time-series for the Maipo Valley, Chile. **Remote Sensing of Environment**, v. 171, p. 234 – 244, 2015.

PERKINS, T.; ADLER-GOLDEN, S.; MATTEEW, M.; BERK, A.; AANDERSON, G.; GGARDNER, J.; FELDE, G. Retrieval of atmospheric properties from hyper and multispectral imagery with the FLAASH atmospheric correction algorithm. In: SCHAFFER, K. P. (Ed.). **Remote sensing of clouds and the atmosphere X.** [S.l.]: International Society for Optics and Photonics, 2005. p. 59790E.

- PINHEIRO, E. D. S.; DURIGAN, G. I. S. E. L. D. A. Dinâmica espaço-temporal (1962-2006) das fitofisionomias em unidade de conservação do Cerrado no sudeste do Brasil. **Revista Brasileira de Botânica**, v. 32, n. 3, p. 441-454, 2009.
- PIROMAL, R. A. S.; RIVERA-LOMBARDI, R. J.; SHIMABUKURO, Y. E.; FORMAGGIO, A. R.; KURG, T. Utilização de dados MODIS para a detecção de queimadas na Amazônia. **Acta Amazonica**, v. 38, n. 1, p. 77–84, 2008.
- PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento remoto no estudo da vegetação**. São José dos Campos: Parênteses, 2009. 127p.
- QI, A. C.; HUETE, A. R.; KERR, Y. H.; SOROOSHIAN, S. A modified soil adjusted vegetation index. **Remote Sensing of Environment**, v.48, n.2, pp.119–126, 1994.
- R CORE TEAM. **R: A language and environment for statistical computing**. Vienna, Austria: R Foundation for Statistical Computing, 2013.
- REZENDE, S. O. **Sistemas inteligentes: fundamentos e aplicações**. Barueri: Manole, 2002. 527p.
- RIBEIRO, J. F.; WALTER, B. M. T. As principais fitofisionomias do bioma Cerrado. In: SANO, S. M.; ALMEIDA, S. P.; RIBEIRO, J. F.(Orgs).**Cerrado: ecologia e flora**. Brasília: EMBRAPA, 2008. p.152-212.
- ROBERTS, D. A.; BATISTA, G. T.; PEREIRA, J. L. G.; WALLER, E. K.; NELSON, B.W. Change identification using multitemporal spectral mixture analysis: applications in eastern Amazonia. In: LUNETTA, R. S. ; ELVIDGE, C. D.(Eds.). **Remote sensing change detection: environmental monitoring methods and applications**. Michigan: Ann Arbor Press, 1998. v.1, cap. 9, p. 137 - 161.
- ROUSE JUNIOR, W.; HAAS, R.H.; SCHELL, J.A.; DEERING, D.W. Monitoring vegetation systems in the Great Plains with ERTS. In: ERTS SYMPOSIUM, 3., 1973, Greenbelt. **Proceedings...** Greenbelt: NASA, 1973. p. 309–317.
- SAEYS, Y.; INZA, I.; LARRAÑAGA, P. A review of feature selection techniques in bioinformatics. **Bioinformatics**, v. 23, n. 19, p. 2507-2517, 2007.
- SANO, E. E.; BARCELLOS, A. O.; BEZERRA, H. S. Assessing the spatial distribution of cultivated pastures in the Brazilian savanna. **Pasturas Tropicales**, v. 22, n. 3, p. 2-15, 2001.

- SANO, E. E.; ROSA, R.; BRITO, J. L. S.; FERREIRA, L. G. Land cover mapping of the tropical savanna region in Brazil. **Environmental Monitoring and Assessment**, v. 166, n. 1-4, p. 113-124, 2010.
- SANO, E. E.; ROSA, R.; BRITO, J. L. S.; FERREIRA, L. G. **Mapeamento de cobertura vegetal do bioma Cerrado**. Planaltina, DF: Embrapa Cerrados, 2008. 60p.
- SANTOS, P. R.; PEREIRA, G.; ROCHA, L. C. Análise da distribuição espacial dos focos de queimadas para o bioma Cerrado (2002-2012). **Caderno de Geografia**, v. 24, n. 1, p. 133-142, 2014.
- SCHWIEDER, M.; LEITÃO, P. J.; BUSTAMANTE, M. M. C.; FERREIRA, L. G.; RABE, A.; HOSTERT, P. Mapping brazilian savanna vegetation gradients with Landsat time series. **International Journal of Applied Earth Observation and Geoinformation**, v.52, p.361-370, 2016.
- SESNIE, S. E.; FINEGAN, B.; GESSLER, P. E.; THESSLER, S.; BENDANA, Z. R.; SMITH, A. M. S. The multispectral separability of Costa Rican rainforest types with support vector machines and random forest decision trees. **International Journal of Remote Sensing**, v. 31, n. 11, p. 2885-2909, 2010.
- SHIVAKUMAR, B. R.; RAJASHEKARARADHYA, S. V. Spectral similarity for evaluating classification performance of traditional classifiers. In: INTERNATIONAL CONFERENCE ON WIRELESS COMMUNICATIONS, SIGNAL PROCESSING AND NETWORKING (WiSPNET), 2017 **Proceedings...** IEEE, 2017. p. 1999-2004.
- SILVA, F. A. M.; ASSAD, E. D.; EVANGELISTA, B. A. Caracterização climática do bioma Cerrado. In: SANO, S. M.; ALMEIDA, S. P.; RIBEIRO, J. F. (Orgs.). **Cerrado: ecologia e flora**. Brasília: Embrapa Informação Tecnológica, 2008. p.69-88.
- SILVA, L. R.; SANO, E. E. Análise das imagens do satélite RapidEye para discriminação da cobertura vegetal do bioma Cerrado. **Revista Brasileira de Cartografia**, v. 68, n. 7, p1267-1283, 2016.
- SILVA, L. R.; SANO, E. E. Análise das imagens do satélite RapidEye para discriminação da cobertura vegetal do bioma Cerrado. **Revista Brasileira de Cartografia**, v. 68, n. 7, p1267-1283, 2016.

SIMON, M. F.; GREYER, R.; QUEIROZ, L. P.; SKEMA, C.; PENNINGTON, R. T.; HUGHES, C. E. Recent assembly of the Cerrado, a Neotropical plant diversity hotspot, by in situ evolution of adaptations to fire. **Proceedings of the National Academy of Science USA**, v. 106, n. 48, p. 20359-20364, 2009.

SKOLE, D. L.; SALAS, W. A.; NOBRE, C. A. Physical and human dimensions of deforestation in Amazonia. **Biosciences**, v. 44, n. 5, p. 314-322, 2012.

TEIXEIRA, L. R.; NUNES, G. M., FINGER, Z.; SIQUEIRA, A. J. B. Potencialidades da classificação orientada a objetos em imagens SPOT5 no mapeamento de fitofisionomias do Cerrado. **Revista ESPACIOS**, v.36, n.20, 2015.

THOMPSON, S.K. On sampling and experiments. **Environmetrics**, v. 13, p.429–436, 2002.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, n. 2, p. 127-150, 1979.

VALERIANO, D. M. **FREL Cerrado**: nível de referência de emissões provenientes do desmatamento do Cerrado. Disponível em: redd.mma.gov.br/images/conaredd/conaredd_frelcerrado_daltonvaleriano.pdf. Acesso em: 14 dez. 2017.

VARMUZA, K.; FILZMOSER, P. **Introduction to multivariate statistical analysis in chemometrics**. [S.l.]: CRC press, 2016.

WITTEN, I. H.; FRANK, E.; HALL, M. A. **Data mining**: practical machine learning tools and techniques. San Francisco: Morgan Kaufmann, 2011. 630p.

WORLD WIDE FUND FOR NATURE (WWF) – **Cobertura vegetal dos biomas do Brasil** – Cerrado. 2015. Disponível em: http://www.wwf.org.br/natureza_brasileira/areas_prioritarias/cerrado/bioma/cobertura_vegetal/, 2015. Acesso em: 9 out. 2015.

YARBROUGH, L. D.; NAVULUR, K.; RAVI, R. Presentation of the Kauth–Thomas transform for WorldView-2 reflectance data. **Remote Sensing Letters**, v.5, n.2, p131-138, 2014.

ZANTER, K. Landsat 8 (L8) data users handbook. **Landsat Science Official Website**. Disponível em: <https://landsat.usgs.gov/landsat-8-l8-data-users-handbook>. Acesso em: 20 jan. 2018.

ZHANG, X. Y., C. B. SCHAAF, M. A. FRIEDL, A. H. STRAHLER, F. GAO, J. C. F. HODGES. MODIS Tasseled cap transformation and its utility. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM 2002. **Proceedings...** IEEE, 2002. p. 1063–1065.

APÊNDICE A: DADOS COMPLEMENTARES DE DISTÂNCIA EUCLIDIANA

Tabela A.1: Distância Euclidiana para a combinação de bandas *Blue* x *Green* e entre as classes da Legenda N1.

	Distância Euclidiana entre as classes ($\times 10^{-2}$)		
	Campestre e Savânica	Campestre e Florestal	Savânica e Florestal
WorldView-2	0,9551	2,3666	1,4155
Landsat-8	0,8578	2,0312	1,1770

Fonte: Produção do Autor.

Tabela A.2: Distância Euclidiana para a combinação de bandas *Blue* x *Red* e entre as classes da Legenda N1.

	Distância Euclidiana entre as classes ($\times 10^{-2}$)		
	Campestre e Savânica	Campestre e Florestal	Savânica e Florestal
WorldView-2	1,7662	5,0861	3,3213
Landsat-8	1,5398	4,0289	2,4893

Fonte: Produção do Autor.

Tabela A.3: Distância Euclidiana para a combinação de bandas *Blue* x *NIR* e entre as classes da Legenda N1.

	Distância Euclidiana entre as classes ($\times 10^{-2}$)		
	Campestre e Savânica	Campestre e Florestal	Savânica e Florestal
WorldView-2	1,6075	8,2494	6,6873
Landsat-8	1,0761	6,0166	5,0083

Fonte: Produção do Autor.

Tabela A.4: Distância Euclidiana para a combinação de bandas *Green* x *Red* e entre as classes da Legenda N1.

	Distância Euclidiana entre as classes ($\times 10^{-2}$)		
	Campestre e Savânica	Campestre e Florestal	Savânica e Florestal
WorldView-2	1,7679	5,0106	3,2509
Landsat-8	1,5573	3,9946	2,4420

Fonte: Produção do Autor.

Tabela A.5: Distância Euclidiana para a combinação de bandas *Green* x *NIR* e entre as classes da Legenda N1.

	Distância Euclidiana entre as classes ($\times 10^{-2}$)		
	Campestre e Savânica	Campestre e Florestal	Savânica e Florestal
WorldView-2	2,1903	9,3573	7,2997
Landsat-8	1,1010	5,9937	4,9850

Fonte: Produção do Autor.

Tabela A.6: Distância Euclidiana para a combinação de bandas *Blue* x *Green* e entre as classes da Legenda N2.

Imagem	Classes	Distância Euclidiana entre as classes ($\times 10^{-2}$)				
		CRup	CL	CS	CSS	VE
WV2	CL	1,4889				
L8		0,6678				
WV2	CS	1,7870	0,2999			
L8		0,9229	0,2565			
WV2	CSS	2,5665	1,0805	0,7806		
L8		1,6531	0,9870	0,7306		
WV2	VE	3,2241	1,7421	1,4421	0,6633	
L8		2,1879	1,5233	1,2667	0,5372	
WV2	MG	3,9797	2,5027	2,2030	1,4259	0,7628
L8		2,8308	2,0169	1,9127	1,1855	0,6491

Fonte: Produção do Autor.

Tabela A.7: Distância Euclidiana para a combinação de bandas *Blue* x *Red* e entre as classes da Legenda N2.

Imagem	Classes	Distância Euclidiana entre as classes ($\times 10^{-2}$)				
		CRup	CL	CS	CSS	VE
WV2	CL	1,4949				
L8		0,5678				
WV2	CS	1,9047	0,4126			
L8		0,9084	0,3480			
WV2	CSS	3,4029	1,9418	1,5350		
L8		2,2504	1,7176	1,3739		
WV2	VE	5,2679	3,8390	3,3437	1,9059	
L8		3,5288	3,0082	2,6667	1,2938	
WV2	MG	6,7235	5,2904	4,8860	3,3513	1,4556
L8		4,7492	4,2266	3,8836	2,5096	1,2203

Fonte: Produção do Autor.

Tabela A.8: Distância Euclidiana para a combinação de bandas *Blue* x *NIR* e entre as classes da Legenda N2.

Imagem	Classes	Distância Euclidiana entre as classes ($\times 10^{-2}$)				
		CRup	CL	CS	CSS	VE
WV2	CL	1,7382				
L8		0,6120				
WV2	CS	1,6778	0,3325			
L8		0,7302	0,1833			
WV2	CSS	1,7295	1,7946	1,4771		
L8		1,1831	1,1385	1,0117		
WV2	VE	3,9179	4,8451	4,5477	3,0937	
L8		2,3725	2,5413	2,4451	1,4438	
WV2	MG	7,3786	8,4771	8,1854	6,7361	3,6424
L8		5,7673	6,0740	6,0031	5,0310	3,5967

Fonte: Produção do Autor.

Tabela A.9: Distância Euclidiana para a combinação de bandas *Green* x *Red* e entre as classes da Legenda N2.

Imagem	Classes	Distância Euclidiana entre as classes ($\times 10^{-2}$)				
		CRup	CL	CS	CSS	VE
WV2	CL	1,6234				
L8		0,6551				
WV2	CS	2,0195	0,4062			
L8		0,9865	0,3480			
WV2	CSS	3,4984	1,9383	1,5363		
L8		2,3293	1,7342	1,3893		
WV2	VE	3,4984	3,8070	3,4113	1,8836	
L8		3,5821	3,0113	2,6696	1,2843	
WV2	MG	6,7018	5,2087	4,8122	3,2806	1,4019
L8		4,7550	4,1902	3,8487	2,4622	1,1790

Fonte: Produção do Autor.

Tabela A.10: Distância Euclidiana para a combinação de bandas *Green* x *NIR* e entre as classes da Legenda N2.

Imagem	Classes	Distância Euclidiana entre as classes ($\times 10^{-2}$)				
		CRup	CL	CS	CSS	VE
WV2	CL	1,8500				
L8		0,6937				
WV2	CS	1,8080	0,3244			
L8		0,8254	0,1833			
WV2	CSS	1,9110	1,7908	1,4785		
L8		1,3271	1,1634	1,0379		
WV2	VE	3,9709	4,8198	4,5282	3,0800	
L8		2,4513	2,5449	2,4483	1,4351	
WV2	MG	7,3592	8,4264	8,1416	6,7012	3,6213
L8		5,7721	6,0487	5,9805	5,0075	3,5829

Fonte: Produção do Autor.

Tabela A.11: Distância Euclidiana para a combinação de bandas *Blue* x *Green* e entre as classes da Legenda N3.

Imagem	Classes	Distância Euclidiana entre as classes ($\times 10^{-2}$)						
		CRup	CL	CS	CR	CT	CD	VE
WV2	CL	1,4889						
L8		0,6678						
WV2	CS	1,7871	0,3000					
L8		0,9230	0,2565					
WV2	CR	2,2161	0,7306	0,4306				
L8		1,3416	0,6755	0,4190				
WV2	CT	2,6426	1,1568	0,8570	0,4266			
L8		1,7372	1,0712	0,8148	0,3958			
WV2	CD	3,1618	1,6744	1,3751	0,9458	0,5200		
L8		2,0858	1,4190	1,1629	0,7442	0,3494		
WV2	VE	3,2242	1,7421	1,4422	1,0117	0,5872	0,1355	
L8		2,1880	1,5233	1,2668	0,8480	0,4531	0,1274	
WV2	MG	3,9798	2,5027	2,2030	1,7731	1,3499	0,8518	0,7629
L8		2,8309	2,1691	1,9127	1,4950	1,1016	0,7653	0,6492

Fonte: Produção do Autor.

Tabela A.12: Distância Euclidiana para a combinação de bandas *Blue* x *Red* e entre as classes da Legenda N3.

Imagem	Classes	Distância Euclidiana entre as classes ($\times 10^{-2}$)						
		CRup	CL	CS	CR	CT	CD	VE
WV2	CL	1,4949						
L8		0,5678						
WV2	CS	1,9047	0,4127					
L8		0,9085	0,3481					
WV2	CR	2,6869	1,2109	0,8016				
L8		1,6415	1,0995	0,7545				
WV2	CT	3,5752	2,1174	1,7110	0,9105			
L8		2,4252	1,8942	1,5508	0,7967			
WV2	CD	4,5356	3,0888	2,6835	1,8830	0,9726		
L8		3,0453	2,5191	2,1763	1,4223	0,6256		
WV2	VE	5,2680	3,8391	3,4372	2,6394	1,7301	0,7636	
L8		3,5288	3,0082	2,6667	1,9135	1,1171	0,4926	
WV2	MG	6,7235	5,2904	4,8860	4,0857	3,1752	2,2027	1,4556
L8		4,7492	4,2267	3,8837	3,1294	2,3329	1,7076	1,2204

Fonte: Produção do Autor.

Tabela A.13: Distância Euclidiana para a combinação de bandas *Blue* x *NIR* e entre as classes da Legenda N3.

Imagem	Classes	Distância Euclidiana entre as classes ($\times 10^{-2}$)						
		CRup	CL	CS	CR	CT	CD	VE
WV2	CL	1,85						
L8		0,6121						
WV2	CS	1,8081	0,3245					
L8		0,7303	0,1834					
WV2	CR	1,739	1,0267	0,7095				
L8		0,8811	0,6136	0,4681				
WV2	CT	1,9861	1,9736	1,6625	0,9551			
L8		1,2996	1,2914	1,1734	1,2996			
WV2	CD	2,6894	2,9992	2,6878	1,9794	1,0257		
L8		1,78	1,861	1,7512	1,2964	0,5806		
WV2	VE	2,6894	2,9992	2,6878	1,9794	1,0257	1,932	
L8		2,3729	2,5413	2,4451	2,0002	1,2878	0,7134	
WV2	MG	7,3593	8,4264	8,1416	7,4571	6,5189	5,5398	3,6213
L8		5,7673	6,074	6,0031	5,5794	4,8775	4,3097	3,5967

Fonte: Produção do Autor.

Tabela A.14: Distância Euclidiana para a combinação de bandas *Green x Red* e entre as classes da Legenda N3.

Imagem	Classes	Distância Euclidiana entre as classes ($\times 10^{-2}$)						
		CRup	CL	CS	CR	CT	CD	VE
WV2	CL	1,6235						
L8		0,6551						
WV2	CS	2,0195	0,4063					
L8		0,9866	0,3481					
WV2	CR	2,7807	1,1992	0,7959				
L8		1,7169	1,1082	0,7623				
WV2	CT	3,6674	2,1126	1,7111	0,9154			
L8		2,502	1,9103	1,5658	0,8039			
WV2	CD	4,6611	3,1145	2,7122	1,9163	1,0021		
L8		3,1506	2,5616	2,2166	1,4544	0,6515		
WV2	VE	5,3075	3,8071	3,4114	2,6199	1,7092	0,7532	
L8		3,5821	3,0113	2,6696	1,9099	1,108	0,4772	
WV2	MG	6,7019	5,2088	4,8122	4,0193	3,1057	2,1191	1,4019
L8		4,755	4,1902	3,8487	3,0886	2,2857	1,6416	1,1791

Fonte: Produção do Autor.

Tabela A.15: Distância Euclidiana para a combinação de bandas *Green* x NIR e entre as classes da Legenda N3.

Imagem	Classes	Distância Euclidiana entre as classes ($\times 10^{-2}$)						
		CRup	CL	CS	CR	CT	CD	VE
WV2	CL	1,85						
L8		0,6938						
WV2	CS	1,8081	0,3245					
L8		0,8254	0,1834					
WV2	CR	1,739	1,0267	0,7095				
L8		1,0147	0,6289	0,4806				
WV2	CT	1,9861	1,9736	1,6625	0,9551			
L8		1,4379	1,315	1,1931	0,7238			
WV2	CD	2,6894	2,9992	2,6878	1,9794	1,0257		
L8		1,9547	1,9182	1,801	1,3315	0,6084		
WV2	VE	3,971	4,8198	4,5282	3,8381	2,8975	1,932	
L8		2,4514	2,545	2,4483	1,9968	1,2799	0,7028	
WV2	MG	7,3593	8,4264	8,1416	7,4571	6,5189	5,5398	3,6213
L8		5,7721	6,0487	5,9805	5,5567	4,8551	4,284	3,5829

Fonte: Produção do Autor.

Tabela A.16: Distância Euclidiana para a combinação de bandas *Blue* x *Green* e entre as classes da Legenda N4.

Imagem	Classes	Distância Euclidiana entre as classes ($\times 10^{-2}$)								
		CLU	CLUCM	CRup	CL	CS	CR	CT	CD	VE
WV2	CLUCM	0,4078								
L8		0,3961								
WV2	CRup	2,2315	1,8849							
L8		1,473	1,0951							
WV2	CL	0,9662	0,6329	1,2658						
L8		1,0473	0,6747	0,426						
WV2	CS	0,455	0,142	1,7871	0,5231					
L8		0,5517	0,1813	0,923	0,4989					
WV2	CR	0,1502	0,34	2,2161	0,9536	0,4306				
L8		0,1516	0,2512	1,3416	0,918	0,419				
WV2	CT	0,4464	0,7613	2,6426	1,38	0,857	0,4266			
L8		0,2819	0,6436	1,7372	1,3137	0,8148	0,3958			
WV2	CD	0,9446	1,2813	3,1618	1,8979	1,3751	0,9458	0,52		
L8		0,6188	0,993	2,0858	1,6616	1,1629	0,7442	0,3494		
WV2	VE	1,0278	1,3393	3,2242	1,9649	1,4422	1,0117	0,5872	0,1355	
L8		0,731	1,093	2,188	1,7657	1,2668	0,848	0,4531	0,1274	
WV2	MG	1,7898	2,0959	3,9798	2,725	2,203	1,7731	1,3499	0,8518	0,7629
L8		1,3802	1,7365	2,8309	2,4109	1,9127	1,495	1,1016	0,7653	0,6492

Fonte: Produção do Autor.

Tabela A.17: Distância Euclidiana para a combinação de bandas *Blue* x *Red* e entre as classes da Legenda N4.

Imagem	Classes	Distância Euclidiana entre as classes ($\times 10^{-2}$)								
		CRup	CLU	CLUCM	CL	CS	CR	CT	CD	VE
WV2	CLU	0,327								
L8		0,4086								
WV2	CLUCM	2,938	2,626							
L8		2,0045	1,5976							
WV2	CL	2,0235	1,698	1,035						
L8		1,9789	1,571	0,2621						
WV2	CS	1,1119	0,785	1,9047	0,9242					
L8		1,144	0,7393	0,9085	0,84					
WV2	CR	0,369	0,1732	2,6869	1,7258	0,8016				
L8		0,4036	0,1314	1,6415	1,5943	0,7545				
WV2	CT	0,6455	0,9492	3,5752	2,6345	1,711	0,9105			
L8		0,4244	0,8277	2,4252	2,39	1,5508	0,7967			
WV2	CD	1,5978	1,9149	4,5356	3,6066	2,6835	1,883	0,9726		
L8		1,0409	1,4489	3,0453	3,0152	2,1763	1,4223	0,6256		
WV2	VE	2,3384	2,6611	5,268	4,358	3,4372	2,6394	1,7301	0,7636	
L8		1,527	1,9356	3,5288	3,5047	2,6667	1,9135	1,1171	0,4926	
WV2	MG	3,7927	4,114	6,7235	5,8087	4,886	4,0857	3,1752	2,2027	1,4556
L8		2,7468	3,1553	4,7492	4,7228	3,8837	3,1294	2,3329	1,7076	1,2204

Fonte: Produção do Autor.

Tabela A.18: Distância Euclidiana para a combinação de bandas *Blue* x *NIR* e entre as classes da Legenda N4.

Imagem	Classes	Distância Euclidiana entre as classes ($\times 10^{-2}$)								
		CRup	CLU	CLUCM	CL	CS	CR	CT	CD	VE
WV2	CLU	2,8665								
L8		2,0709								
WV2	CLUCM	2,7657	1,394							
L8		1,4586	1,1877							
WV2	CL	0,9944	2,1188	1,7787						
L8		0,8874	1,5487	0,5996						
WV2	CS	1,2126	1,6771	1,6789	0,5338					
L8		0,783	1,3557	0,7303	0,3633					
WV2	CR	1,842	1,0407	1,5847	1,2345	0,7158				
L8		1,0893	0,9846	0,8811	0,7974	0,4681				
WV2	CT	2,7716	0,48	1,8102	2,1653	1,6624	0,9504			
L8		1,7691	0,5067	1,2996	1,4617	1,1734	0,7158			
WV2	CD	3,7554	1,1379	2,4655	3,1561	2,6588	1,9472	0,9969		
L8		2,3379	0,6508	1,78	2,0249	1,7512	1,2964	0,5806		
WV2	VE	5,6813	2,9008	3,9179	5,0157	4,5478	3,8515	2,9099	1,9361	
L8		3,0511	1,1852	2,3729	2,6954	2,4451	2,0002	1,2878	0,7134	
WV2	MG	9,3235	6,5237	7,379	8,6424	8,1855	7,4931	6,5523	5,5723	3,6425
L8		6,6458	4,6599	5,7673	6,2066	6,0031	5,5794	4,8775	4,3097	3,5967

Fonte: Produção do Autor.

Tabela A.19: Distância Euclidiana para a combinação de bandas *Green x Red* e entre as classes da Legenda N4.

Imagem	Classes	Distância Euclidiana entre as classes ($\times 10^{-2}$)								
		CRup	CLU	CLUCM	CL	CS	CR	CT	CD	VE
WV2	CLU	0,5144								
L8		0,5258								
WV2	CLUCM	3,1322	2,6459							
L8		2,1336	1,6204							
WV2	CL	2,0885	1,6613	1,1787						
L8		2,0388	1,5565	0,3538						
WV2	CS	1,165	0,772	2,0195	0,9243					
L8		1,1915	0,7281	0,9866	0,8479					
WV2	CR	0,37	0,2965	2,7807	1,72	0,7959				
L8		0,4297	0,2168	1,7169	1,61	0,7623				
WV2	CT	0,5461	1,0247	3,6674	2,6346	1,7111	0,9154			
L8		0,3743	0,8841	2,502	2,413	1,5658	0,8039			
WV2	CD	1,5479	2,0153	4,6611	3,6362	2,7122	1,9163	1,0021		
L8		1,0254	1,5303	3,1506	3,0641	2,2166	1,4544	0,6515		
WV2	VE	2,2501	2,6798	5,3075	4,3303	3,4114	2,6199	1,7092	0,7532	
L8		1,4807	1,9653	3,5821	3,5145	2,6696	1,9099	1,108	0,4772	
WV2	MG	3,6492	4,0811	6,7019	5,732	4,8122	4,0193	3,1057	2,1191	1,4019
L8		2,6592	3,1422	4,755	4,6934	3,8487	3,0886	2,2857	1,6416	1,1791

Fonte: Produção do Autor.

Tabela A.20: Distância Euclidiana para a combinação de bandas *Green* x *NIR* e entre as classes da Legenda N4.

Imagem	Classes	Distância Euclidiana entre as classes ($\times 10^{-2}$)								
		CRup	CLU	CLUCM	CL	CS	CR	CT	CD	VE
WV2	CLU	2,8939								
L8		2,0971								
WV2	CLUCM	2,9712	1,431							
L8		1,6314	1,2182							
WV2	CL	1,1208	2,0895	1,8659						
L8		1,0139	1,5341	0,645						
WV2	CS	1,2615	1,671	1,8081	0,5339					
L8		0,8508	1,3496	0,8254	0,3812					
WV2	CR	1,8422	1,0681	1,739	1,2265	0,7095				
L8		1,0992	0,9996	1,0147	0,8284	0,4806				
WV2	CT	2,7501	0,616	1,9861	2,1655	1,6625	0,9551			
L8		1,7578	0,5944	1,4379	1,499	1,1931	0,7238			
WV2	CD	3,7345	1,2997	2,6894	3,1899	2,6878	1,9794	1,0257		
L8		2,331	0,8163	1,9547	2,097	1,801	1,3315	0,6084		
WV2	VE	5,6455	2,9179	3,971	4,9917	4,5282	3,8381	2,8975	1,932	
L8		3,0282	1,2331	2,4514	2,7081	2,4483	1,9968	1,2799	0,7028	
WV2	MG	9,2661	6,503	7,3593	8,591	8,1416	7,4571	6,5189	5,5398	3,6213
L8		6,6101	4,651	5,7721	6,1843	5,9805	5,5567	4,8551	4,284	3,5829

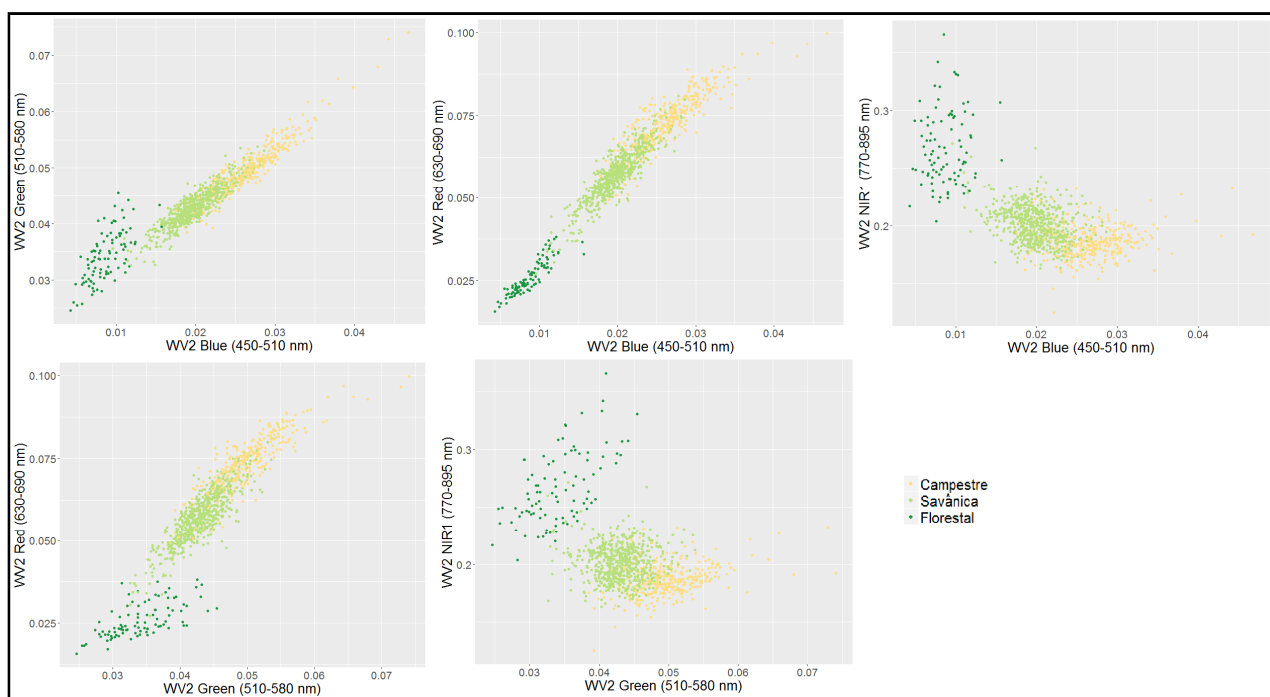
Fonte: Produção do Autor.

APÊNDICE B: GRÁFICOS DE CARACTERIZAÇÃO ESPECTRAL

Gráficos de caracterização espectral:

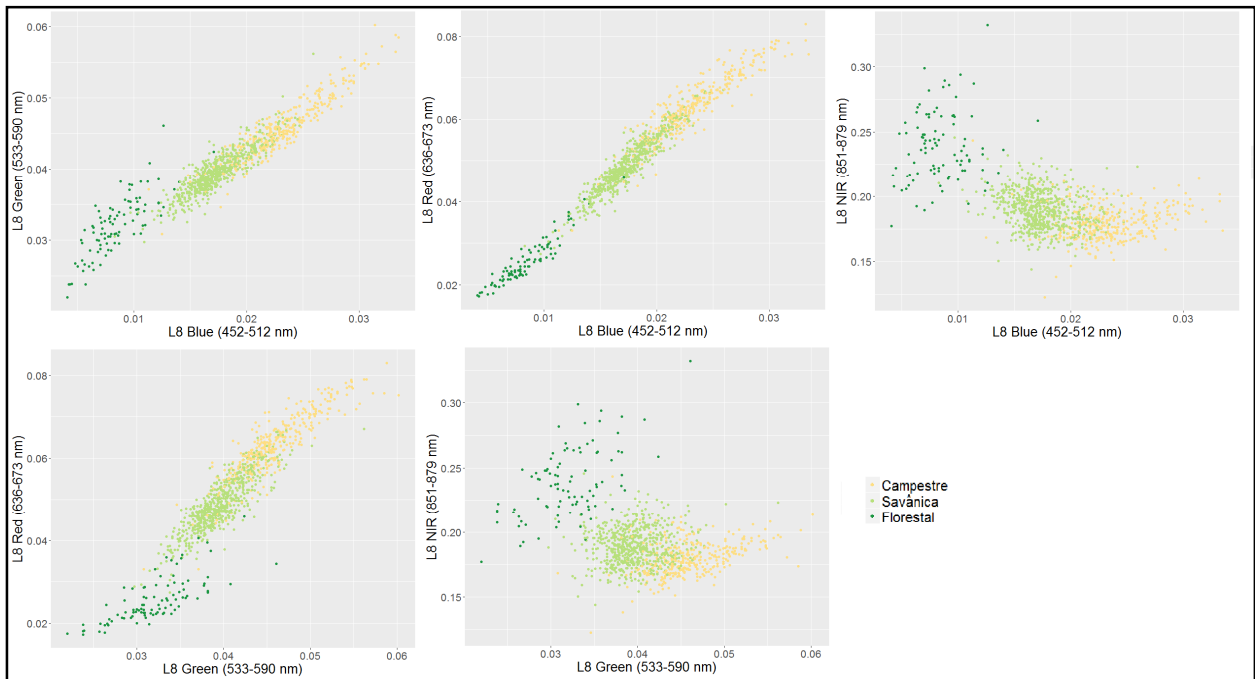
Este Apêndice apresenta todos os demais gráficos que não foram utilizados nos capítulos 6 e 7. As Figuras B.1 e B.2 mostram a dispersão dos dados espectrais de ambas as imagens para a Legenda N1. Já as Figuras B.3 e B.4 para a Legenda N2, as Figuras B.5 e B.6 para a Legenda N3 e as Figuras B.7 e B.8 para a Legenda N4. Os dados do Modelo Linear de Mistura Espectral estão nas imagens B.9, B.10, B.11 e B.12. Por sua vez os dados da Transformada *Tasseled Cap* estão nas Figuras B.13, B.14, B.15 e B.16.

Figura B.1: Gráficos de dispersão das classes para as combinações de banda para a imagem WorldView-2 para a Legenda N1.



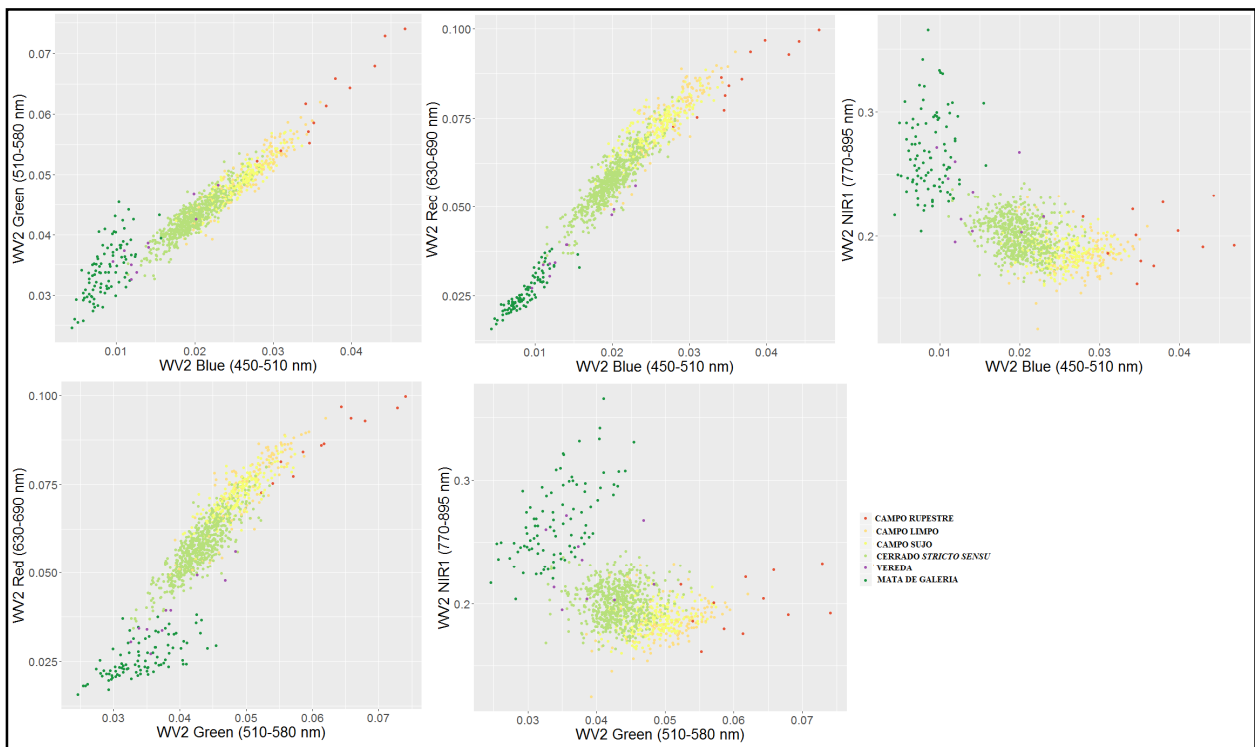
Fonte: Produção do Autor.

Figura B.2: Gráficos de dispersão das classes para as combinações de banda para a imagem Landsat-8 para a Legenda N1.



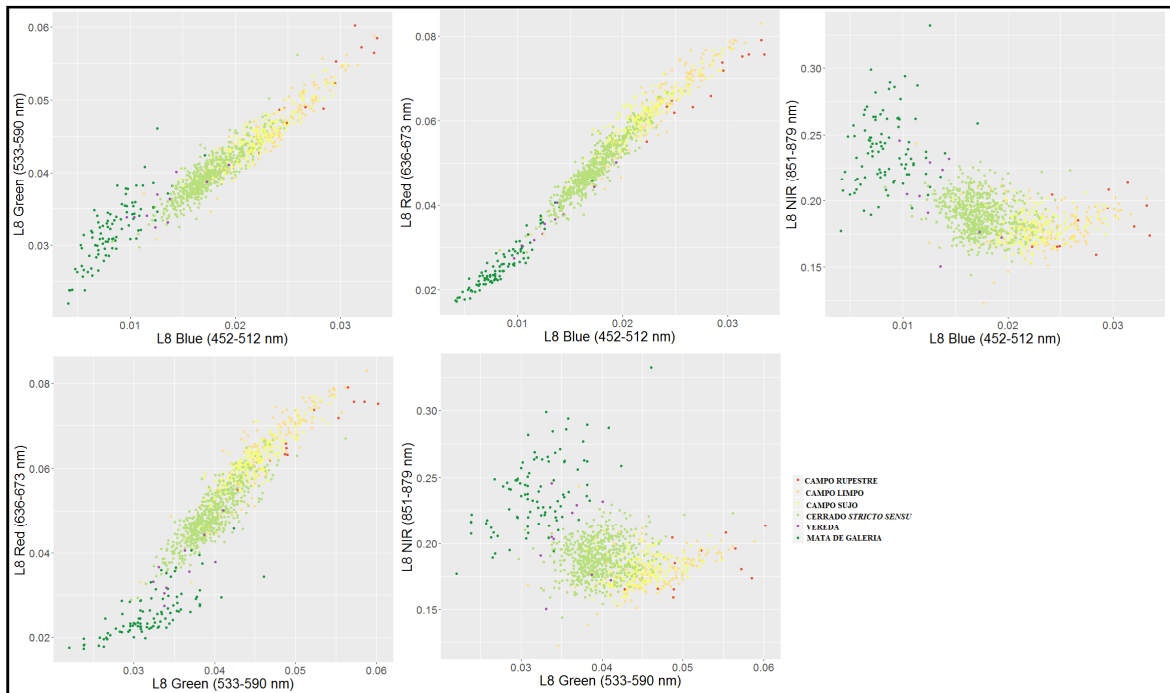
Fonte: Produção do Autor.

Figura B.3: Gráficos de dispersão das classes para as combinações de banda para a imagem WorldView-2 para a Legenda N2.



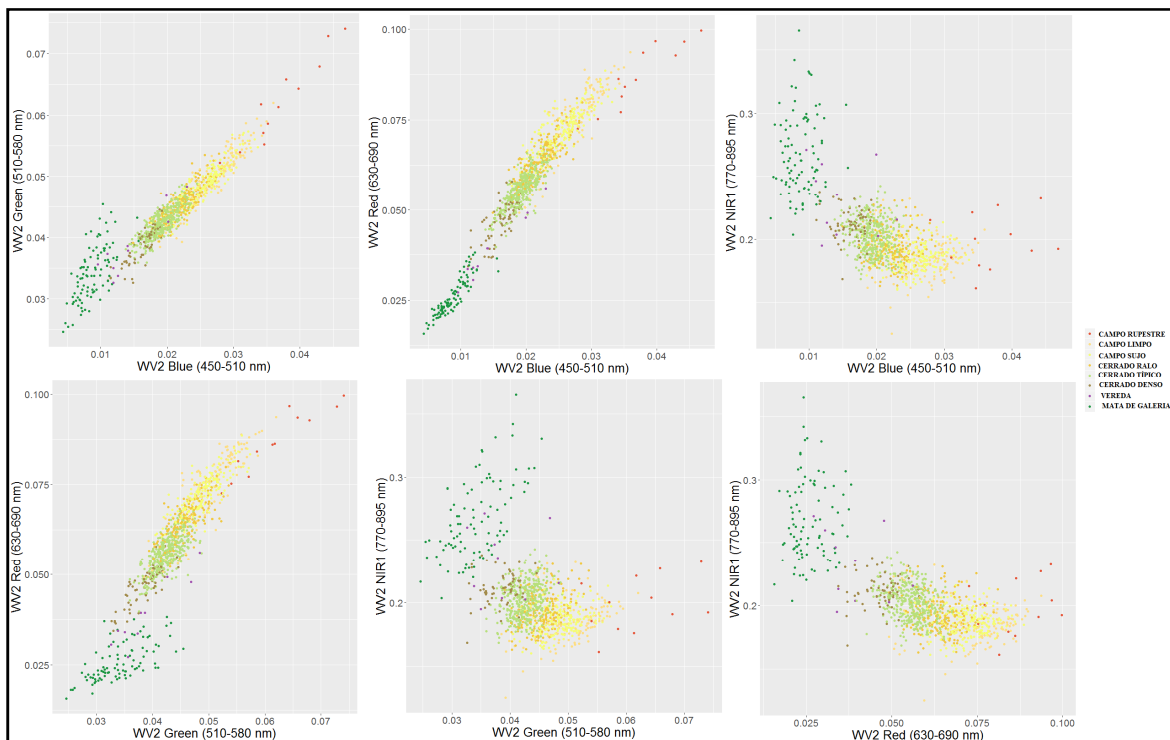
Fonte: Produção do Autor.

Figura B.4: Gráficos de dispersão das classes para as combinações de banda para a imagem Landsat-8 para a Legenda N2.



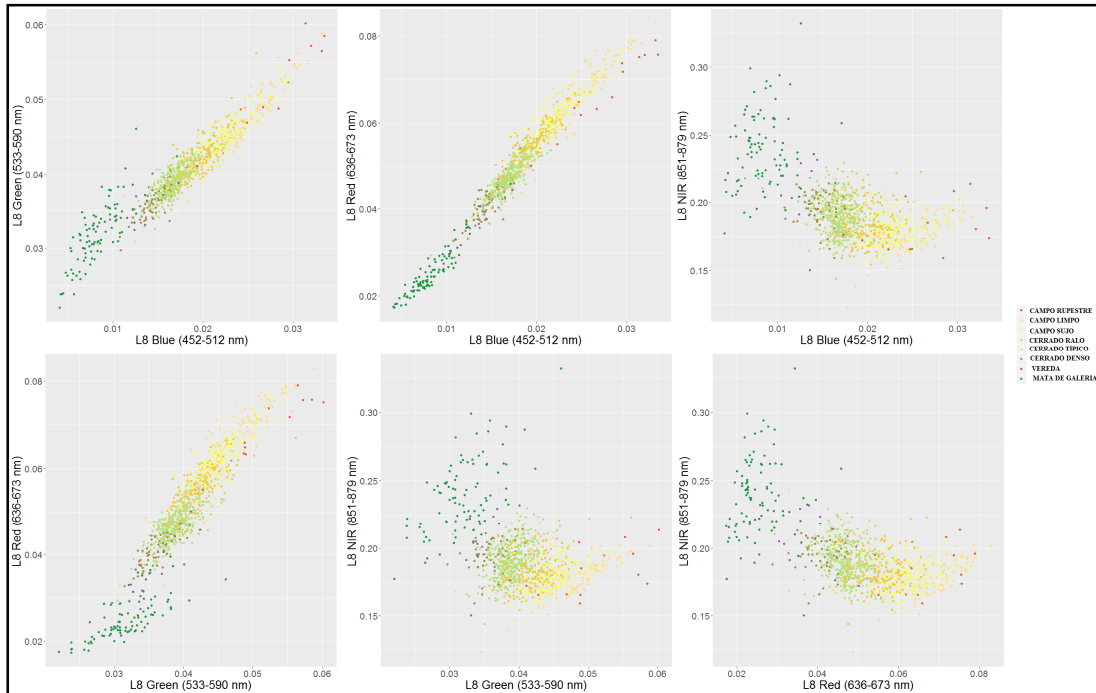
Fonte: Produção do Autor.

Figura B.5: Gráficos de dispersão das classes para as combinações de banda para a imagem WorldView-2 para a Legenda N3.



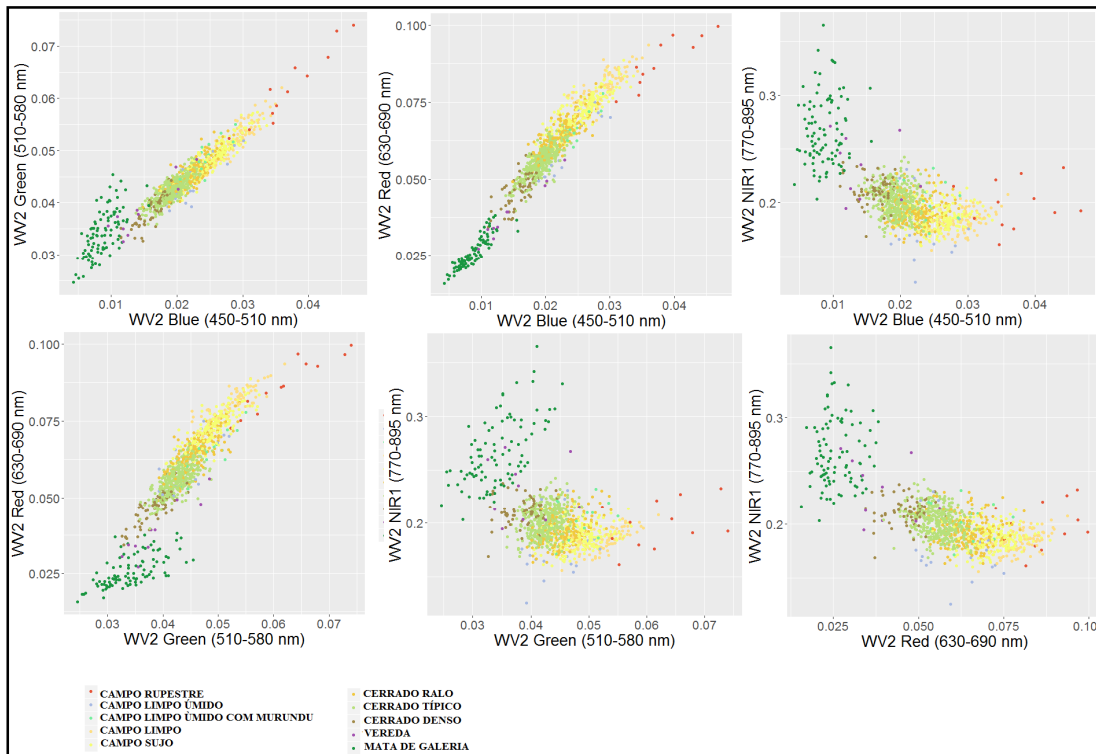
Fonte: Produção do Autor.

Figura B.6: Gráficos de dispersão das classes para as combinações de banda para a imagem Landsat-8 para a Legenda N3.



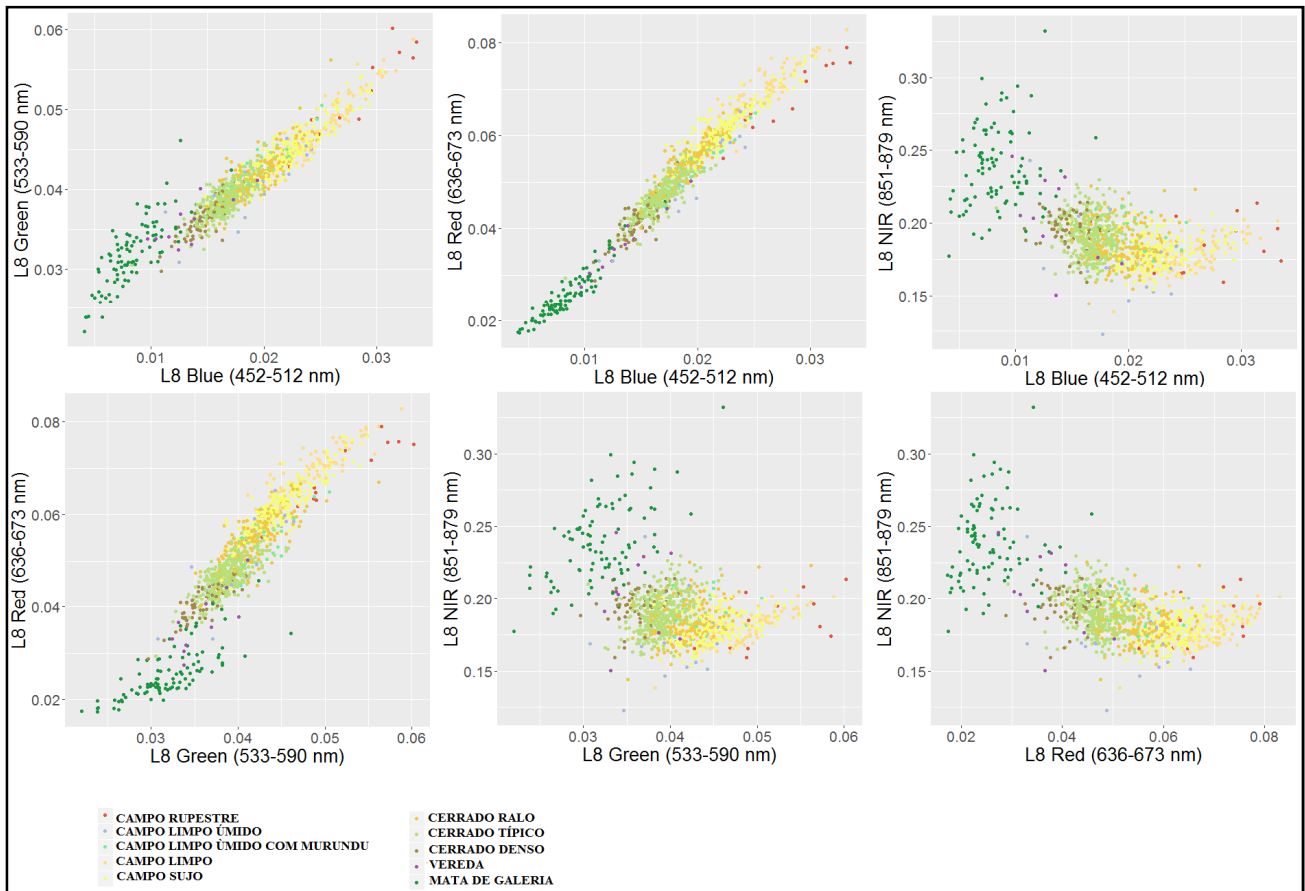
Fonte: Produção do Autor.

Figura B.7: Gráficos de dispersão das classes para as combinações de banda para a imagem WorldView-2 para a Legenda N4.




Fonte: Produção do Autor.

Figura B.8: Gráficos de dispersão das classes para as combinações de banda para a imagem Landsat-8 para a Legenda N4.



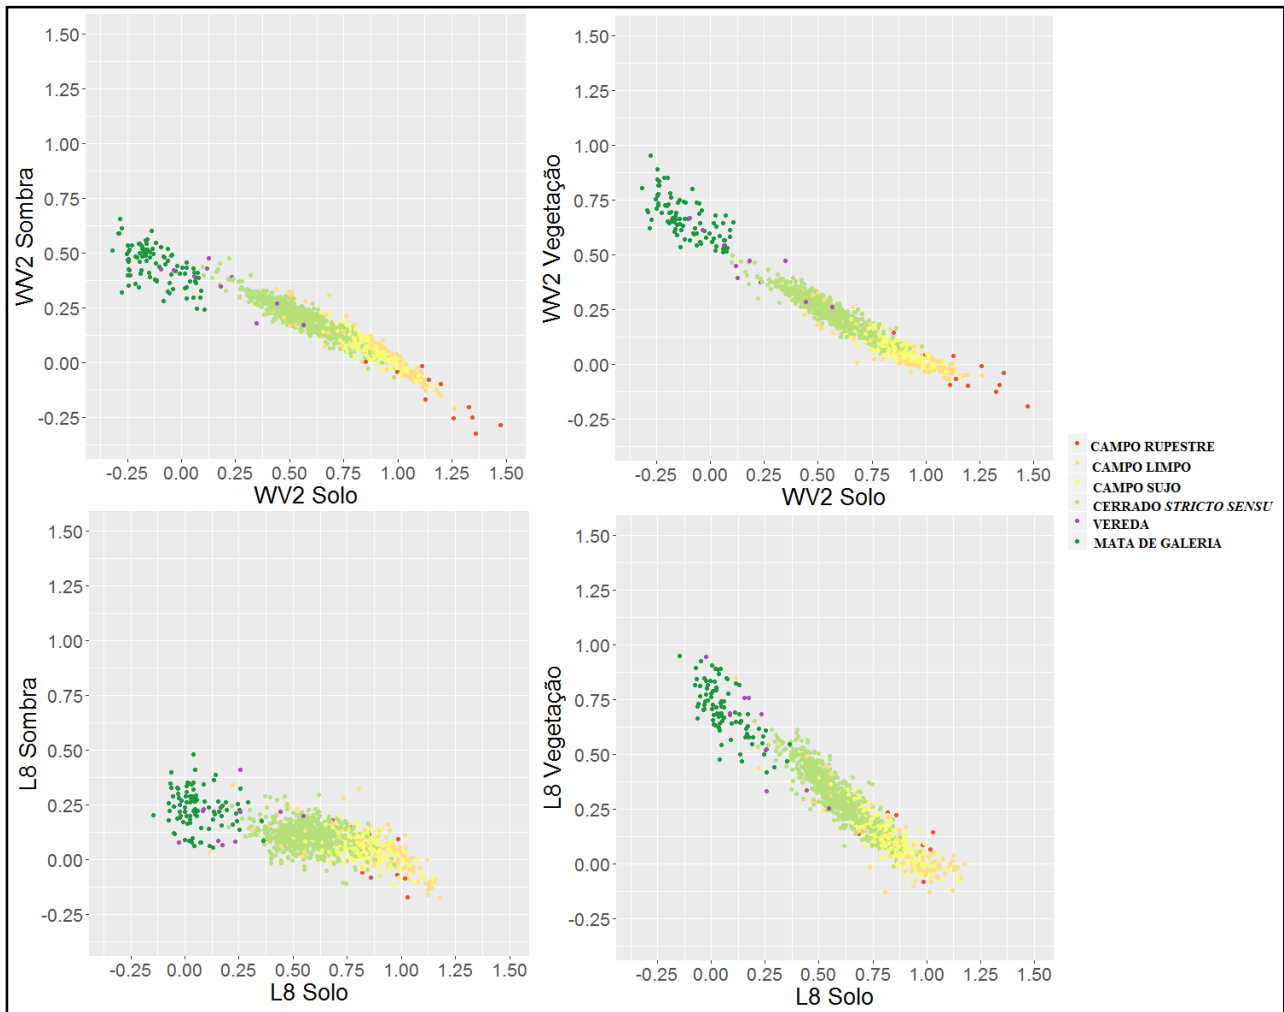
Fonte: Produção do Autor.

Figura B.9.: Gráficos de dispersão das classes para as componentes do Modelo Linear de Mistura Espectral para a Legenda N1.



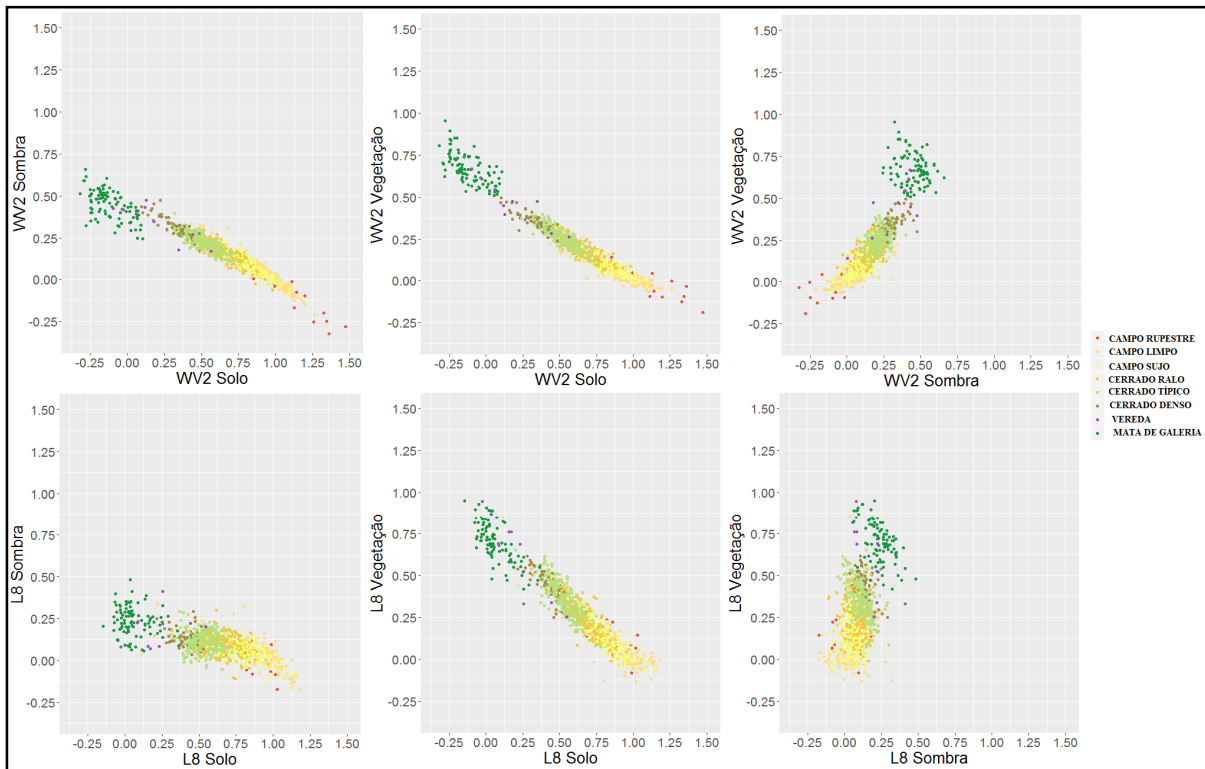
Fonte: Produção do Autor.

Figura B.10: Gráficos de dispersão das classes para as componentes do Modelo Linear de Mistura Espectral para a Legenda N2.



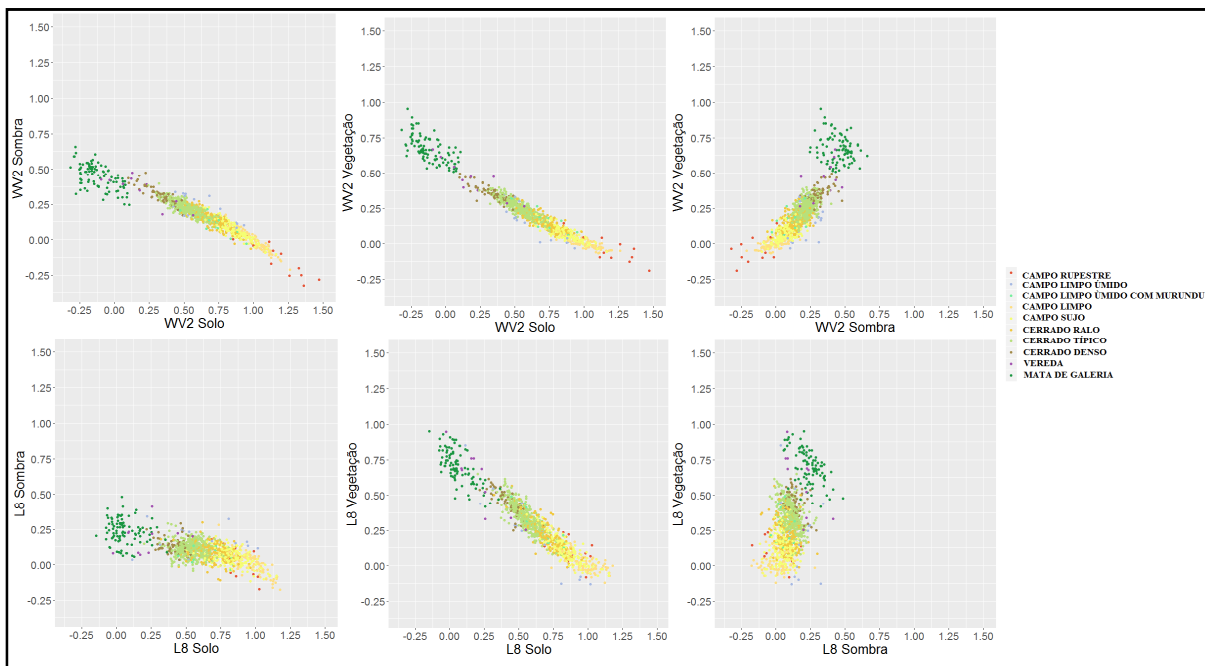
Fonte: Produção do Autor.

Figura B.11.: Gráficos de dispersão das classes para as componentes do Modelo Linear de Mistura Espectral para a Legenda N3.



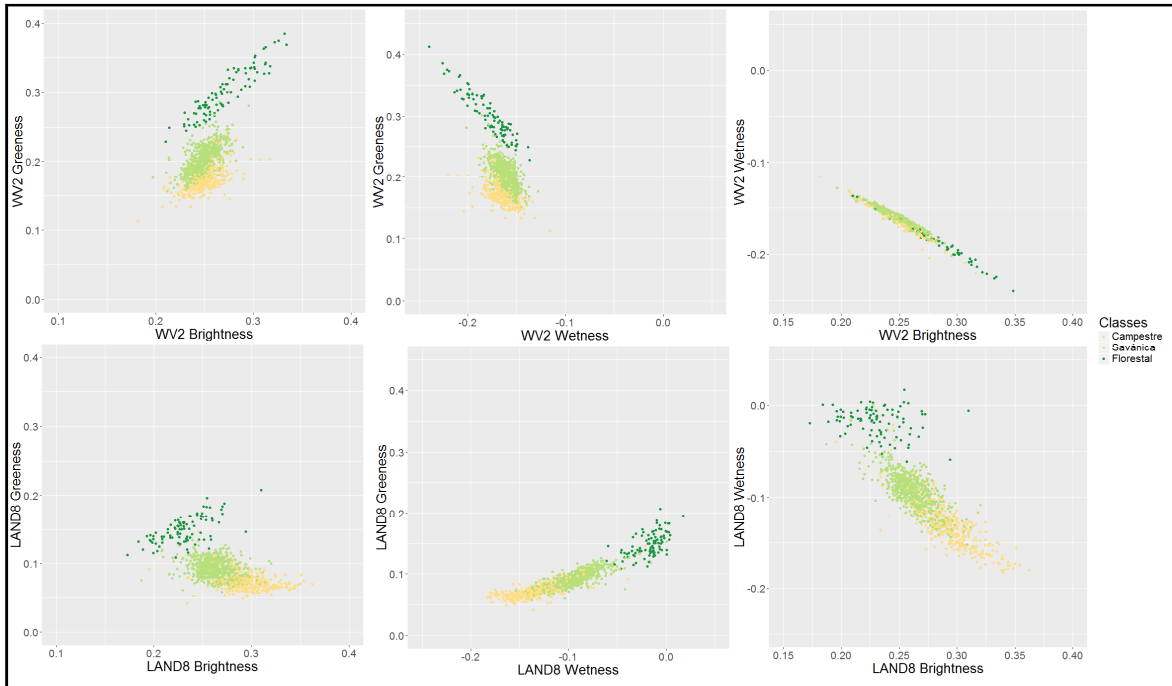
Fonte: Produção do Autor.

Figura B.12.: Gráficos de dispersão das classes para as componentes do Modelo Linear de Mistura Espectral para a Legenda N4.



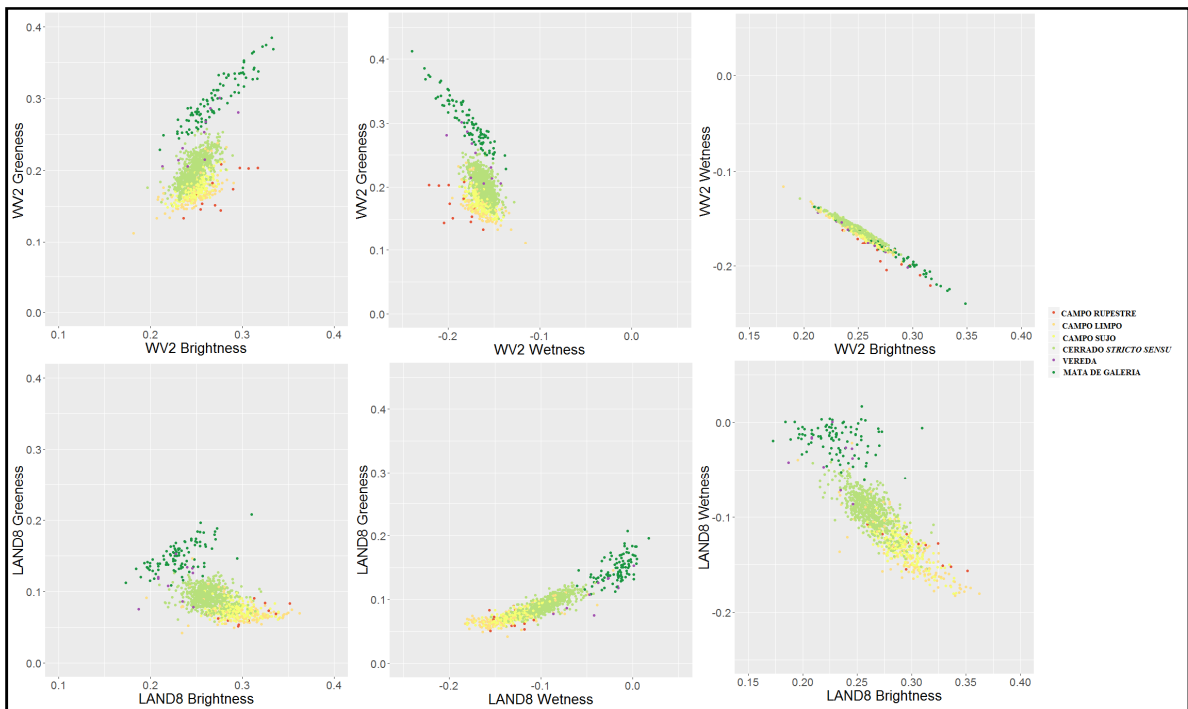
Fonte: Produção do Autor.

Figura B.13: Gráficos de dispersão das classes para as componentes da Transformada *Tasseled Cap* para a Legenda N1.



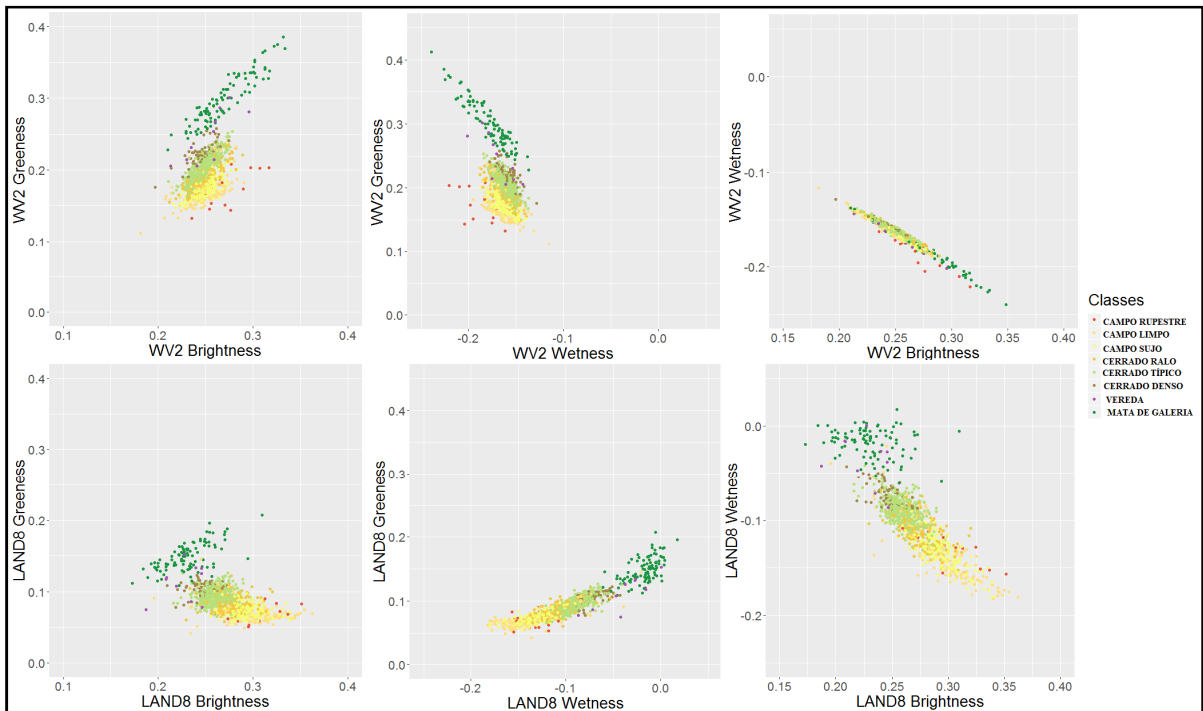
Fonte: Produção do Autor.

Figura B.14: Gráficos de dispersão das classes para as componentes da Transformada *Tasseled Cap* para a Legenda N2.



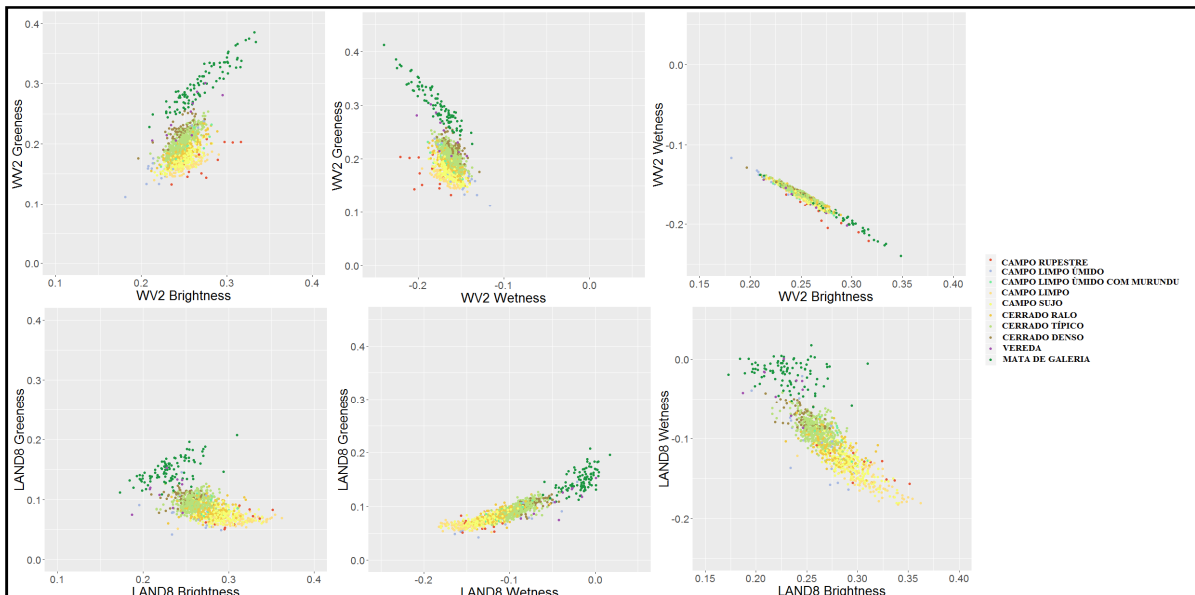
Fonte: Produção do Autor.

Figura B.15: Gráficos de dispersão das classes para as componentes da Transformada *Tasseled Cap* para a Legenda N3.



Fonte: Produção do Autor.

Figura B.16: Gráficos de dispersão das classes para as componentes da Transformada *Tasseled Cap* para a Legenda N4.



Fonte: Produção do Autor.