



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE CIÊNCIAS AGRÁRIAS
DEPARTAMENTO DE ENGENHARIA AGRÍCOLA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA

EFRAIM MARTINS ARAÚJO

**DETECÇÃO DE DIFERENTES ALVOS NO ENTORNO DE RESERVATÓRIOS NO
SEMIÁRIDO ATRAVÉS DO USO DE SENSORIAMENTO REMOTO**

FORTALEZA
2017

EFRAIM MARTINS ARAÚJO

DETECÇÃO DE DIFERENTES ALVOS NO ENTORNO DE RESERVATÓRIOS NO
SEMIÁRIDO ATRAVÉS DO USO DE SENSORIAMENTO REMOTO

Tese apresentada ao Curso de Doutorado em Engenharia Agrícola do Departamento de Engenharia Agrícola da Universidade Federal do Ceará, como parte dos requisitos para obtenção do título de Doutor em Engenharia Agrícola. Área de concentração: Manejo e Conservação de Bacias Hidrográficas no Semiárido.

Orientador: Prof. Dr. George Leite Mamede – Unilab.

Co-orientador: Prof. Dr. João Paulo do Vale Madeiro – Unilab.

FORTALEZA

2017

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária

Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

A688d Araújo, Efraim Martins.
Detecção de diferentes alvos no entorno de reservatórios no semiárido através do uso de sensoriamento remoto / Efraim Martins Araújo. – 2017.
161 f. : il. color.

Tese (doutorado) – Universidade Federal do Ceará, Centro de Ciências Agrárias, Programa de Pós-Graduação em Engenharia Agrícola, Fortaleza, 2017.

Orientação: Prof. Dr. George Leite Mamede.

Coorientação: Prof. Dr. João Paulo do Vale Madeiro.

1. Landsat 8. 2. Hyperion. 3. Classificação de imagens. 4. Comportamento espectral. 5. Índice de Kappa.
I. Título.

CDD 630

EFRAIM MARTINS ARAÚJO

DETECÇÃO DE DIFERENTES ALVOS NO ENTORNO DE RESERVATÓRIOS NO
SEMIÁRIDO ATRAVÉS DO USO DE SENSORIAMENTO REMOTO

Tese apresentada ao Curso de Doutorado em Engenharia Agrícola do Departamento de Engenharia Agrícola da Universidade Federal do Ceará, como parte dos requisitos para obtenção do título de Doutor em Engenharia Agrícola. Área de concentração: Manejo e Conservação de Bacias Hidrográficas no Semiárido.

Aprovada em: 20 / 04 / 2017

BANCA EXAMINADORA

Prof. George Leite Mamede, Dr. (Orientador)
Universidade Integração Internacional da Lusofonia Afro-Brasileira (Unilab)

Prof. João Paulo do Vale Madeiro, Dr. (Co-orientador)
Universidade Integração Internacional da Lusofonia Afro-Brasileira (Unilab)

Prof. Pedro Henrique Augusto Medeiros, Dr. (Conselheiro)
Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)

Profª. Cynthia Romariz Duarte, Dra. (Conselheira)
Universidade Federal do Ceará (UFC)

Prof. Paulo Cesar Moura da Silva, Dr. (Conselheiro)
Universidade Federal Rural do Semiárido (UFERSA)

A Deus.

A minha família, meus pais Lucimi e Luiza, meus irmãos Eliakim e Erika, minhas tias Luciene, Vera, Ana e Claudia e meus avós Hermínia, Luiza Maria e Francisco. E a minha namorada Islandia.

AGRADECIMENTOS

Primeiro a Deus pela força de vontade de alcançar os meus objetivos sonhados e que mesmo nos momentos difíceis me deu garra e coragem para superar os obstáculos e suportar as adversidades.

À Coordenação de Aperfeiçoamento de Pessoa de Nível Superior pela concessão da bolsa de estudos durante todo o curso de doutorado, de suma importância para o desenvolvimento da tese.

À Universidade Federal do Ceará pela possibilidade de cursar uma pós-graduação, pois foram seis anos estudando nessa instituição.

Aos professores do departamento de Engenharia Agrícola que tive a oportunidade de estudar e que muito contribuíram com o meu crescimento profissional, meus sinceros agradecimentos por todo conhecimento transmitido.

Aos colegas do departamento de Engenharia Agrícola pelo convívio e troca de informações.

Ao PPGEA, programa de pós-graduação que faço parte desde 2011 quando ingressei no mestrado.

Ao meu grande amigo e orientador George Leite Mamede pela orientação desse trabalho, sempre estando à disposição para tirar dúvidas, ensinar e dar sugestões para melhorar a qualidade do trabalho durante os quatro anos dessa longa caminhada.

Ao amado irmão, amigo Eliakim Martins Araújo, que sempre me apoiou e esteve ao meu lado, tirando as dúvidas, estudando e ajudando no que fosse preciso para o desenvolvimento do doutorado. E tudo o que fizemos juntos desde a graduação e todas as dificuldades e alegrias que compartilhamos juntos.

À minha família que esteve sempre ao meu lado me encorajando e pelo amor dedicado: Ao meu pai, meu grande exemplo e herói José Lucimi Araújo da Silva, minha mãe Maria Luiza Martins, minha amada irmã Erika Martins Araújo, minhas tias Maria Luciene Araújo da Silva, Vera Lúcia Araújo da Silva, Ana Lúcia Araújo da Silva e Maria Cláudia Araújo da Silva, meus avós Francisco da Silva, Hermínia Josina Araújo da Silva e Luiza Maria de Souza.

À minha namorada Islandia Portela Rodrigues pelo companheirismo e compreensão durante todo o doutorado.

Aos amigos residentes no assentamento 25 de maio em Madalena, pela receptividade, atenção, carinho, dedicação e ajuda na execução do trabalho de campo, durante

todas as campanhas realizadas: Dona Gorete, Seu Mauro, Gledson, Charles e todos os outros, queiro deixar o meu muito obrigado, pois sem eles não seria possível a realização da pesquisa de campo.

Aos colegas Thiago Xavier de Souza Rocha e Christine Farias Coelho por toda a ajuda e companheirismo durante e desenvolvimento da pesquisa, tanto nas viagens de campo quanto nas trocas de conhecimento.

Ao professor João Paulo Madeiro, pela essencial contribuição como Co-orientador, de forma dedicada, engrandecendo de forma imensurável essa pesquisa.

Aos demais membros da banca examinadora os professores Pedro Henrique Augusto Medeiros, Cynthia Romariz Duarte e Paulo Cesar Moura da Silva, por aceitarem em colaborar no aperfeiçoamento do trabalho.

“Os grandes homens não são aqueles que resolvem os problemas, mas aqueles que os descobrem.”

(Albert Schweitzer)

RESUMO

O objetivo deste trabalho é avaliar o potencial de discriminação dos uso e ocupação do solo no entorno de reservatórios localizados na região semiárida, mediante informações espectrais obtidas por sensor remoto com imagens de satélites multiespectrais e hiperespectrais. As imagens de satélites selecionadas para a realização da pesquisa foram imagens Landsat 8 e Hyperion. A pesquisa analisou o desempenho de diferentes técnicas de classificação de imagens aplicadas a sensores multiespectrais (Landsat 8) e hiperespectrais (Hyperion) para detecção e diferenciação das classes do solo no entorno dos reservatórios Paus Brancos, Nova Vida e Marengo, situados no Assentamento 25 de Maio, localizados no município de Madalena – CE, pertencentes a bacia hidrográfica do reservatório Banabuiú. As classes identificadas com base em levantamentos em campanhas realizadas em 2014 e 2015 no entorno dos reservatórios são: água (corpos hídricos), macrófitas, solo exposto, vegetação nativa, agricultura, vegetação rala e vazante, além dos alvos nuvem e sombra de nuvem. Testaram-se na pesquisa diferentes técnicas de processamento de imagens, tais como NDVI (Índice de Vegetação por Diferença Normalizada), classificador não supervisionado (ISODATA) e supervisionados (Máxima Verossimilhança, K-Nearest Neighbours - KNN, Mínima Distância e Random Forest). Para processamento de imagens hiperespectrais utilizou-se, adicionalmente, o classificador SVM (*Support Vector Machine*), por permitir o processamento de todas as 155 bandas radiometricamente calibradas do sensor Hyperion, atribuindo-lhes pesos no processo de classificação. Testaram-se, então, composições RGB das 10 melhores bandas de acordo com o ranking resultante do classificador SVM, para identificação daquela com melhor desempenho na diferenciação das classes no entorno dos três reservatórios estudados (bandas R – 51, G – 161, B – 19). A análise de imagens multiespectrais do NDVI apresentou limitações na diferenciação de classes, sobretudo em alvos com resposta espectral similar como tipos de vegetação. Já a classificação não-supervisionada mostrou-se deficiente por não conseguir separar corpos hídricos de sombra de nuvem, mesmo após a aplicação de técnicas de realces implementados dentro do ambiente Matlab. A análise espectral e temporal da reflectância de classes permitiu identificar o comportamento espectral das nove classes analisadas neste estudo, indicando as faixas espectrais com maior potencial de diferenciação, embora se perceba que, mesmo nestas faixas, alguns alvos apresentam comportamento espectral similar, não sendo facilmente separados. A classificação supervisionada, por sua vez, destacou-se por conseguir separar tanto alvos distintos (água, solo e vegetação) como alvos semelhantes (macrófitas, vazante, vegetação nativa, agricultura e vegetação rala) quando aplicadas as imagens dos sensores Landsat 8 e Hyperion. Cabe destacar, entretanto, que o desempenho dos classificadores aplicados à imagem do sensor Hyperion foi, em geral, superior aos obtidos em imagem Landsat 8, o que pode ser explicado pela alta resolução espectral do primeiro, que facilita a diferenciação de alvos com resposta espectral similar. Na etapa de teste de desempenho dos classificadores supervisionados, observou-se que o método KNN foi superior aos demais no processamento de imagem Landsat 8, com coeficiente Kappa de 0,68. Já no caso do Hyperion, o método de Máxima Verossimilhança teve melhor desempenho com Kappa de 0,78. Adicionalmente, realizou-se uma análise de sensibilidade da classificação supervisionada aplicada a imagens Landsat 8 e Hyperion quanto ao número de amostras por classe usadas no

treinamento, indicando que, em geral, o caráter aleatório de escolha das amostras potencializa o desempenho dos classificadores. Para validação do método de classificação supervisionada de Máxima Verossimilhança, utilizaram-se imagens Landsat 8 (24/08/2015) e Hyperion (28/08/2015). Os dados de treinamento do classificador foram coletados na campanha de novembro de 2015, no entorno do reservatório São Nicolau, também localizado no Assentamento 25 de Maio, enquanto que os dados de verificação do desempenho do método foram extraídos da imagem gerada no sobrevoo realizado, no mesmo período, no reservatório Paus Branco, usando um VANT (veículo aéreo não tripulado). Os resultados mostraram um excelente desempenho do classificador quando aplicado à imagem do sensor Hyperion, com Kappa de 0,83. Já a aplicação para a imagem do sensor Landsat 8 resultou em um Kappa de 0,49, o que pode ser explicado por sua baixa resolução espectral. Realizaram-se, ainda, duas aplicações do classificador supervisionado de Máxima Verossimilhança em imagens Landsat 8 e Hyperion para testar a eficiência do método. Na primeira, verificou-se a habilidade do classificador na detecção de contornos de reservatórios, em alguns dificultada pela presença de macrófitas na bacia hidráulica. Para isso, utilizou-se a área de interseção entre as cenas dos sensores Landsat 8 e Hyperion, que cobrem a área do Assentamento 25 de Maio, identificando 48 reservatórios. Os resultados mostraram que, em geral, o classificador subestima as áreas dos reservatórios, atingindo 73% e 51% do valor referência nas imagens Landsat 8 e Hyperion, respectivamente. Por fim, realizou-se uma aplicação do classificador supervisionado de Máxima Verossimilhança em imagens Hyperion para detecção de classes no entorno de reservatórios de outras regiões do Estado do Ceará. Na análise dos dados disponíveis, identificou-se um reservatório no município de Lavras da Mangabeira-CE, presente na imagem Hyperion (26/09/2010), com baixa cobertura de nuvens, em período próximo à imagem do google Earth (08/07/2009), usada para validação dos resultados. Os resultados da aplicação indicaram um bom desempenho do classificador associado à composição RGB da imagem Hyperion escolhida (bandas R – 51, G – 161, B – 19) na detecção das classes no entorno deste reservatório, produzindo um coeficiente Kappa de 0,90. Por outro lado, a disponibilidade de dados do sensor Hyperion em aplicações para o Estado do Ceará é bem restrita, o que dificulta o desenvolvimento de pesquisas continuadas usando imagens hiperespectrais.

Palavras Chave: Landsat 8. Hyperion. Classificação de imagens. Comportamento espectral. Índice de Kappa.

ABSTRACT

The main goal of this work is to evaluate the potential of discrimination for soil use and occupation in the surroundings of reservoirs located in the semi-arid region, using spectral information obtained by remote sensor considering multispectral and hyperspectral satellites images. The satellite images selected for the survey are Landsat 8 and Hyperion images. The research evaluated and compared the performance of different techniques for image classification applied to multispectral (Landsat 8) and hyperspectral (Hyperion) sensors aiming the detection and delineation of the land uses around the reservoirs Paus Brancos, Nova Vida and Marengo, located in the 25 de Maio settlement, Madalena – CE, belonging to the hydrographic basin of the Banabuiú reservoir. The classes identified based on surveys conducted in 2014 and 2015 campaigns around the reservoirs were: water (water bodies), macrophytes, exposed soil, native vegetation, agriculture, sparse vegetation and flood plain crop, in addition to cloud and shadow targets. Different techniques for image processing are tested and compared, such as NDVI (Vegetation Index by Normative Difference), non-supervised classifier (ISODATA) and supervised classifiers (Maximum Likelihood, K-Nearest Neighbours - KNN, Minimal Distance and Random Forest). For processing hyperspectral images, we use SVM (Support Vector Machine) classifier, which provides to analyze all the 155 radiometrically calibrated bands of the Hyperion sensor, assigning them weights in the classification process. According to the results provided by SVM classifier, RGB compositions of the 10 best ranked bands are evaluated aiming the identification of the best successful combination for delineating classes in the surroundings of the three studied reservoirs (bands R – 51, G – 161, B – 19). The analysis of NDVI multispectral images behaved inaccurate for delineating classes, mainly considering targets with similar spectral response, such as some kinds of vegetation. Meanwhile, the unsupervised classification proved to be deficient, not being able to discriminate water bodies from cloud shadow, even after applying contrast enhancing techniques within the Matlab computing program environment. The spectral and temporal analysis of soil use reflectance allowed to identify the spectral behavior of the nine classes considered in this study and also the spectral bands with the highest potential for discriminating the referred classes. Indeed, even within these optimal bands, some targets present similar spectral behaviors, difficulting their discrimination. On the other hand, the supervised classification applied to Landsat 8 and Hyperion images achieved to be successful in the delineation of either distinct (water, soil and vegetation) and similar (macrophytes, flood plain crop, native vegetation, agriculture and sparse vegetation) targets. It should be emphasized that the performance results of the classifiers applied to the Hyperion images are generally superior to those obtained respectively by the same classifiers over the Landsat 8 images. This can be explained by the higher spectral resolution of the first sensor, which increases the potential for delineating targets with similar spectral response. Concerning the supervised classifiers, in the stage of performance test, it was observed that KNN method is more accurate than the others for Landsat 8 images, with a maximum Kappa coefficient equal to 0.68. Meanwhile, for Hyperion images, the Maximum Likelihood method achieves the highest performance result, with a maximum Kappa coefficient equal to 0.78. Additionally, a sensitivity analysis of the supervised classification applied to Landsat 8 and Hyperion images is performed regarding the number of samples per class

randomly collected for training. It is clearly observed that the randomness concerning training stage allows finding subsets of samples which increase the performance results. For the evaluation of the supervised maximum likelihood classification method, Landsat 8 (24/08/2015) and Hyperion (285/08/2015) images are considered for the computing tests. The training data were collected through a research technical visit in November, 2015, around São Nicolau reservoir, also located in the 25 de Maio settlement, while the data for performance evaluation (validation) were extracted from the image generated through the overflight performed by an Unmanned Aerial Vehicle (UAV), in the same period in the Paus Brancos reservoir. The obtained results demonstrate the robustness for that classifier when applied to Hyperion image, with a Kappa of 0.83. Concerning Landsat 8 image, the computed Kappa is 0.49, which can be explained by the corresponding lower spectral resolution. Two other applications of the Maximum Likelihood classifier for Landsat 8 and Hyperion images were performed. In the first one, the accuracy of each classifier for detecting reservoirs contours was tested. In some of these reservoirs, that task is made difficult by the presence of macrophytes in the hydraulic basin. For this analysis, the intersection area between the scenes of the Landsat 8 and Hyperion sensors, which cover the area of 25 de Maio Settlement, was used, totalizing 48 reservoirs. The results showed that the classifier generally underestimates the reservoir areas, reaching 73% and 51% of the reference value in the Landsat 8 and Hyperion images, respectively. Finally, an application of the supervised Maximum Likelihood classifier was performed using Hyperion images for the detection of land uses in the surroundings of reservoirs of other regions of the State of Ceará. In the analysis of the available data, it is possible to identify a reservoir located in the municipality of Lavras da Mangabeira, displayed in the Hyperion image (26/09/2010), with low cloud cover, near the image of Google Earth (08/07/2009), also used for validation purposes. The results of the application indicate accurate performance for the classifier associated with the RGB composition selected for the Hyperion image (bands R - 51, G - 161, B - 19) concerning the detection of the uses around this reservoir, the resultant Kappa coefficient is 0.90. On the other hand, the availability of Hyperion sensor data in applications for the State of Ceará is very restricted, which makes difficult to develop continuous researches using hyperspectral images.

Keywords: Landsat 8. Hyperion. Image classification. Spectral behavior. Kappa index.

LISTA DE FIGURAS

Figura 1 -	Espectro eletromagnético	30
Figura 2 -	Formas de representação de dados multiespectrais (λ é o comprimento de onda)	31
Figura 3 -	Vizinhança de 3 x 3 pixels em torno de um ponto (x,y) de uma imagem ...	41
Figura 4 -	Traçados da equação 5 para vários valores de γ	43
Figura 5 -	Gráficos obtidos para a transformada de contraste para a função limiar	44
Figura 6 -	Localização do Assentamento 25 de Maio no Estado do Ceará, destacando as bacias hidrográficas dos três reservatórios considerados	49
Figura 7 -	Média da precipitação mensal no posto pluviométrico de Madalena – Série histórica de 1961 a 2015	51
Figura 8 -	Declividade percentual da área de estudo obtida a partir do modelo digital de elevação (MDE).....	52
Figura 9 -	Solos das bacias dos reservatórios	53
Figura 10 -	Fluxograma das etapas desenvolvidas na pesquisa.....	54
Figura 11 -	Área de influência considerada no entorno dos reservatórios Marengo, Nova Vida e Paus Brancos.....	55
Figura 12 -	Ilustração das cenas do satélite Landsat 8.....	56
Figura 13 -	Imagens Landsat 8 com alta cobertura de nuvens.....	58
Figura 14 -	Imagens Hyperion disponíveis no sitio da USGS	60
Figura 15 -	Imagem Hyperion (19/10/2014), composições RGB bandas 51, 161, 19, com a localização da área de estudo.....	61
Figura 16 -	Espacialização dos pontos para a obtenção das faixas de reflectância. Imagem Landsat 8 de 30/05/2013, composição RGB 6/5/4	64
Figura 17 -	Espacialização dos pontos das classes para análise dos valores de reflectância (Composição R – 51; G – 161; B – 19).....	65
Figura 18 -	Levantamento de pontos com auxílio de GPS de navegação	66
Figura 19 -	Pontos das classes levantados no entorno dos reservatórios estudados	67
Figura 20 -	Espacialização dos pontos utilizados para a classificação supervisionada (Composição RGB imagem Hyperion).....	67
Figura 21 -	Classificador de mínima distância	73
Figura 22 -	Algoritmo básico da técnica Random Forest	75
Figura 23 -	Tratamento M1 ($m = - 0,5$ e $E = 0,9$).....	77

Figura 24 –	Tratamento M2 ($m_2 - 0,5$ e $E - 2$).....	78
Figura 25 –	Espacialização de pontos levantados em novembro de 2015, no entorno do reservatório São Nicolau para validação da classificação das imagens Landsat 8 e Hyperion	81
Figura 26 –	Modelo do VANT FC-40 utilizado na obtenção de imagens.....	82
Figura 27 –	Imagem do reservatório Paus Brancos obtido através do VANT para validação da classificação das imagens Landsat 8 e Hyperion	82
Figura 28 -	Área definida pela cena do satélite Hyperion, órbita 217, ponto 63 selecionada para validação do método de classificação supervisionada.....	83
Figura 29 –	Cenas do satélite Hyperion no estado do Ceará, disponíveis no site da USGS	85
Figura 30 –	Imagem do Google Earth do dia 08/07/2009, do reservatório localizado em Lavras da Mangabeira – CE.....	87
Figura 31 –	Classes encontrados na área de estudo, no entorno dos reservatórios	89
Figura 32 -	Faixas de reflectância dos diferentes alvos estudados obtidos pelo sensor Landsat 8	91
Figura 33 -	Faixas de reflectância das diferentes classes, incluído nuvem e sombra, obtidos pelo sensor Hyperion.....	93
Figura 34 –	Espacialização das classes no entorno dos reservatórios Paus Brancos, Marengo e Nova Vida, obtidos através da classificação não-supervisionada (ISODATA) com 5 classes	97
Figura 35 –	Espacialização das classes no entorno dos reservatórios estudados, obtidos através da classificação não-supervisionada (ISODATA) com 7 classes....	98
Figura 36 –	Espacialização das classes no entorno dos reservatórios estudados, obtidos através da classificação não-supervisionada (ISODATA) com 9 classes....	99
Figura 37 –	Espacialização das classes do solo obtidos através da classificação não-supervisionada com 5 classes com o tratamento M1	102
Figura 38 –	Espacialização das classes obtidos através da classificação não-supervisionada com 7 classes após o tratamento M1.....	103
Figura 39 –	Espacialização das classes obtidos através da classificação não-supervisionada com 9 classes após o tratamento M1.....	103
Figura 40 –	Espacialização das classes, obtidos através da classificação não-supervisionada com 5 classes após o tratamento M2.....	106

Figura 41 –	Espacialização das classes obtidos através da classificação não-supervisionada com 7 classes após o tratamento M2.....	106
Figura 42 –	Espacialização das classes obtidos através da classificação não-supervisionada com 9 classes após o tratamento M2.....	107
Figura 43 –	Classes no entorno do reservatório Marengo, na classificação supervisionada.....	108
Figura 44 –	Classes no entorno do reservatórios Paus Brancos, na classificação supervisionada.....	108
Figura 45 –	Reservatório Paus Brancos, em fevereiro e agosto de 2014, respectivamente.....	109
Figura 46 –	Classes no entorno do reservatório Nova Vida, na classificação supervisionada.....	110
Figura 47 -	Bacia hidráulica do reservatório Nova Vida, no mês de fevereiro 2014	111
Figura 48 –	Comparativo do Kappa condicional, obtidos com diferentes métodos classificatórios e número de classes do solo, para imagem de setembro de 2014.....	112
Figura 49 –	Espacialização das classes através da classificação supervisionada pelo método KNN, utilizando 60 K-vizinhos e 7 amostras por classe, no entorno dos reservatórios Marengo, Paus Brancos e Nova Vida	120
Figura 50 –	Comparação dos valores do índice de Kappa, entre diferentes métodos classificadores supervisionados em imagens Landsat 8	121
Figura 51 -	NDVI no entorno do reservatório Paus Brancos.....	122
Figura 52 -	Espacialização das classes no entorno do reservatórios Paus Brancos, obtido através da classificação não-supervisionada com 5, 7 e 9 classes (R–51; B–161; G–19), imagem Hyperion	125
Figura 53 -	Espacialização das classes no entorno do reservatório Marengo, obtido através da classificação não-supervisionada com 5, 7 e 9 classes de uso (R – 51; B – 151; G – 19)	126
Figura 54 -	Espacialização das classes no entorno dos reservatórios Marengo obtido através da classificação supervisionada (R – 51; G – 161; B – 19) da imagem do satélite Hyperion de 19/10/2014	130
Figura 55 -	Espacialização das classes no entorno do reservatório Paus Brancos, obtido através da classificação supervisionada (R – 51; B – 161; G – 19), da imagem Hyperion de 19/10/2014.....	131

Figura 56 -	Desempenho do método de Máxima Verossimilhança na classificação supervisionada e não-supervisionada (5, 7 e 9 classes) de imagens Hyperion	133
Figura 57 –	Análise de sensibilidade dos classificadores Máxima Verossimilhança, KNN, Random Forest e Mínima Distância para imagem Landsat 8 de 22 setembro de 2014	135
Figura 58 –	Análise de sensibilidade dos classificadores Máxima Verossimilhança, KNN, Mínima Distância para imagem Hyperion de 19 outubro de 2014 ...	137
Figura 59 –	Classificação supervisionada gerada a partir da imagem Landsat 8 (24/08/2015) no entorno do reservatório Paus Brancos.....	140
Figura 60 –	Classificação supervisionada gerada a partir da imagem Hyperion (24/08/2015) no entorno do reservatório Paus Brancos.....	141
Figura 61 –	Ilustração da área de estudo utilizada para validação	143
Figura 62 –	Desempenho da estimativa dos espelhos d’água de reservatórios através de imagens Landsat 8 e Hyperion, em ha (A) e % (B)	146
Figura 63 –	Estimadas através de classificação de imagens dos satélites Landsat 8 e Hyperion, áreas de macrófitas em reservatórios	147
Figura 64 –	Validação dos satélites Landsat 8 e Hyperion, na determinação da área dos espelhos d’água de reservatórios localizados na área imagiada pelo satélite Hyperion	147
Figura 65 –	Ilustração da área do entorno do reservatório localizado no município de Lavras da Mangabeira – CE.....	148
Figura 66 –	Classificação supervisionada da imagem Hyperion de 26/09/2010 no entorno do reservatório localizado no município de Lavras da Mangabeira – CE	149

LISTA DE TABELAS

Tabela 1 -	Relação de cores e faixas espectrais na região do visível	32
Tabela 2 -	Características dos sensores embarcados no satélite Landsat 8.....	33
Tabela 3 -	Características do sensor Hyperion/EO-1	35
Tabela 4 -	Características físicas dos reservatórios no Assentamento 25 de Maio em Madalena-CE	50
Tabela 5 -	Banco de imagens Landsat 8 adquiridas no sítio da USGS 2015	57
Tabela 6 -	Banco de imagens Hyperion adquiridas no sitio da USGS, 2015.....	59
Tabela 7 -	Bandas do sensor Hyperion, e destaque, as bandas ruidosas que foram excluídas para a realização da pesquisa	62
Tabela 8 -	Parâmetros utilizados para efetuar a correção atmosférica.....	63
Tabela 9 -	Número de pontos por classe levantados em campo	68
Tabela 10 -	Banco de dados com as datas e imagens utilizadas para o desenvolvimento de todas as etapas da pesquisa.....	69
Tabela 11 -	Classificadores e processamentos cos respectivos programas utilizados durante as diversas etapas da pesquisa.....	71
Tabela 12 -	Qualidade da classificação associada aos valores da estatística Kappa.....	79
Tabela 13 -	Imagens do satélite Hyperion, disponível no site da USGS	86
Tabela 14 -	Valores da reflectância das bandas do Landsat 8, nas respectivas classes ..	92
Tabela 15 -	Valores de reflectância média das bandas R-51, G-161, B-19 do Hyperion, nas respectivas classes	94
Tabela 16 -	Síntese das classes possíveis de serem determinados para diferentes classificações de imagens Landsat 8.....	95
Tabela 17 -	Síntese dos valores do coeficiente de Kappa condicional, obtidos através da classificação não-supervisionada da imagem de setembro de 2014, do sensor Landsat 8.....	96
Tabela 18 -	Valores do coeficiente de Kappa de imagens de diferentes períodos, obtidos através da classificação não-supervisionada	100
Tabela 19 -	Síntese dos valores do coeficiente de Kappa condicional, obtidos através da classificação não-supervisionada (ISODATA) com 5, 7 e 9 classes após o tratamento M1	105

Tabela 20 –	Valores do coeficiente de Kappa individual, obtidos através da classificação supervisionada (Máxima Verossimilhança) de imagens Landsat 8.....	111
Tabela 21 -	Valores do coeficiente de Kappa individual, obtidos através das classificações não-supervisionadas e supervisionada de imagens Landsat 8	114
Tabela 22 –	Matriz confusão obtida através da classificação supervisionada pelo método Máximo Verossimilhança, na imagem Landsat 8 de setembro de 2014.....	116
Tabela 23 –	Matriz confusão obtidas através da classificação supervisionada pelo método da Mínima distância, na imagem Landsat 8 de setembro de 2014 .	117
Tabela 24 –	Matriz confusão obtidas através da classificação supervisionada pelo método do KNN, na imagem Landsat 8 de setembro de 2014	118
Tabela 25 –	Matriz confusão obtidas através da classificação supervisionada pelo método do Random Forest na imagem Landsat 8 de setembro de 2014.....	118
Tabela 26 –	Comparação dos valores do coeficiente de Kappa condicional e geral obtidos através de diferentes métodos de classificação supervisionados para a imagem de setembro de 2014 obtida do sensor Landsat 8	119
Tabela 27 -	Valores do Kappa condicional, obtidos através da classificação não-supervisionada (ISODATA) com 5, 7 e 9 classes das imagens Hyperion e Landsat 8.....	127
Tabela 28 -	Desempenho das bandas do satélite Hyperion para determinação das classes	128
Tabela 29 –	Valores do índice de Kappa individual, obtidos através da classificação supervisionada por diferentes métodos da imagem Hyperion de outubro de 2014.....	129
Tabela 30 –	Valores do índice de Kappa condicional, obtidos através da classificação supervisionada da imagem Hyperion de outubro de 2014 e Landsat 8 de setembro 2014.....	132
Tabela 31 –	Valores de Kappa encontrados através da classificação supervisionada, no entorno do reservatório Paus Brancos.....	139
Tabela 32 –	Matriz de confusão resultante da classificação supervisionada, Máxima Verossimilhança, da imagem Hyperion de 28/08/2015 no entorno do reservatório Paus Brancos, considerando 5 e 3 classes do solo	142

Tabela 33 –	Valores de Kappa encontrados através da classificação supervisionada de imagens Landsat 8 e Hyperion, no entorno do reservatório Paus Brancos no mês de agosto de 2015	142
Tabela 34 –	Estimativa das áreas aparente e efetiva de espelho d'água usando o método de classificação supervisionada de imagens Hyperion (19/10/14) e Landsat 8 (22/09/14).....	145
Tabela 35 –	Valores de Kappa encontrados através da classificação supervisionada, no entorno do reservatório localizado no município de Lavras da Mangabeira – CE	150

LISTA DE ABREVIATURAS E SIGLAS

ALI	Advanced Land Imager
ANA	Agência Nacional de águas
b	Bandas
B	Blue
CBERS	Satélite Sino-brasileiro de Recursos Terrestres
DNOCS	Departamento Nacional de Obras Contrás Secas
Embrapa	Empresa Brasileira de Pesquisa Agropecuária
ENVI	Environment for Visualizing Images
EO-1	Earth Observing Mission 1
EROS	Earth Resources Observation Science
ETM+	Enhanced Thematic Mapper Plus
FLAASH	Fast Line-of-Sight Atmospheric Analysis of Spectral
FUNCEME	Fundação cearense de meteorologia
GPS	Global Positioning System
G	Green
INPE	Instituto de Pesquisas Espaciais
NASA	National Aeronautics and Space Administration
ND	Nº digital
NDVI	Normalized Difference Vegetation Index
NIR	Infravermelho Próximo
nm	Nanômetros
OLI	Operational Land Imager
R	Red
SR	Sensoriamento Remoto
SRTM	Shuttle Radar Topography Mission
SVM	Support Vector Machine
SWIR	Infravermelho Médio
SWSI 1	Salinity And Water Stress Index 1
TM	Thematic map
UFC	Universidade Federal do Ceará
USGS	United States Geological Survey
25M	Assentamento 25 de maio
VANT	Veículo Aéreo Não Tripulado

LISTA DE SÍMBOLOS

ρ	Reflectância
λ	Comprimento de Onda
$^{\circ}$	Graus
n	n ^o de bandas

SUMÁRIO

1	INTRODUÇÃO	26
1.1	Hipótese.....	28
1.2	Objetivos	28
1.2.1	<i>Geral</i>	28
1.2.2	<i>Objetivos Específicos</i>	28
2	REVISÃO DE LITERATURA	29
2.1	Sensoriamento Remoto	29
2.2	Sensores Remotos Ópticos.....	32
2.2.1	<i>Landsat 8</i>	33
2.2.2	<i>EO-1 Hyperion</i>	34
2.3	Métodos Classificatórios.....	35
2.4	Classificação não-supervisionada	35
2.4.1	<i>ISODATA</i>	36
2.5	Classificação supervisionada.....	37
2.5.1	<i>Máxima Verossimilhança</i>	37
2.5.2	<i>Support Vector Machine (SVM)</i>	38
2.5.3	<i>Mínima distância</i>	39
2.5.4	<i>KNN</i>	39
2.5.5	<i>Random Forest</i>	40
2.6	Aplicações de técnicas de realce em imagens de satélite Landsat 8.....	40
2.6.1	<i>Transformações de Intensidade</i>	41
2.7	Índices estatísticos utilizados na avaliação da qualidade de classificação de imagens de satélite.....	45
2.7.1	<i>Índice de Kappa</i>	45
2.8	Validação das classificações de imagens de satélites.....	47
2.9	Identificação de Macrófitas em Reservatórios	48
3	CARACTERIZAÇÃO DA ÁREA DE ESTUDO	49
3.1	Caracterização Hidroclimatológica.....	50
3.2	Caracterização fisiográfica.....	51
3.2.1	<i>Relevo</i>	51
3.2.2	<i>Solos</i>	52

4	MATERIAL E MÉTODOS	54
4.1	Delimitação da área investigada no entorno dos reservatórios	55
4.2	Pré-processamento de imagens de satélite	55
4.2.1	<i>Sensor Landsat 8</i>	55
4.2.1.1	<i>Aquisição e seleção de imagens</i>	56
4.2.1.2	<i>Correção atmosférica</i>	58
4.2.2	<i>Sensor Hyperion</i>	59
4.2.2.1	<i>Aquisição e seleção de imagens</i>	59
4.2.2.2	<i>Conversão de dados do sensor</i>	61
4.2.2.3	<i>Correção atmosférica</i>	61
4.2.2.4	<i>Correção geométrica</i>	63
4.3.	Análise do comportamento espectral dos diferentes alvos	63
4.3.1	<i>Sensor Landsat 8</i>	64
4.3.2	<i>Sensor Hyperion</i>	64
4.4	Classificação de imagens	65
4.4.1	<i>Coleta de pontos em campo</i>	65
4.4.2	<i>Seleção de imagens e composição RGB</i>	68
4.4.3	<i>Sensor Landsat 8</i>	70
4.4.4	<i>Sensor Hyperion</i>	70
4.4.5	<i>Classificação não-supervisionada</i>	70
4.4.6	<i>Classificação supervisionada</i>	71
4.4.6.1	<i>Classificador de Máximo Verossimilhança</i>	72
4.4.6.2	<i>Classificador de Mínima distância</i>	73
4.4.6.3	<i>Classificador de KNN</i>	74
4.4.6.4	<i>Random Forest</i>	75
4.4.6.5	<i>SVM – Suport Vector Machine</i>	75
4.5	Determinação do NDVI	76
4.6	Aplicações de transformação de contraste (<i>contrast-stretching</i>)	76
4.7	Avaliação do desempenho dos classificadores de imagens	78
4.8	Análise de desempenho das classificações de imagens Landsat 8 e Hyperion	80
4.8.1	<i>Aplicação para reservatórios do Assentamento 25 de Maio usando dados de VANT</i>	80

4.8.2	<i>Aplicação para os reservatórios da cena do sensor Hyperion que cobre o Assentamento 25 de Maio</i>	83
4.8.3	<i>Aplicação para reservatórios do Estado do Ceará</i>	84
5	RESULTADOS E DISCUSSÃO	89
5.1	Classes existentes no entorno dos reservatórios do Assentamento 25 de Maio.....	89
5.2	Identificação das faixas de reflectância de diferentes classes	90
5.3	Classificação de imagens Landsat 8	95
5.3.1	<i>Espacialização das classes através da classificação não-supervisionada.</i>	95
5.3.2	<i>Utilização de técnicas de realces computacionais para tratamentos de imagens Landsat 8</i>	101
5.3.3	<i>Espacialização das classes através da classificação supervisionada</i>	107
5.3.4	<i>Classificação Supervisionada através de diferentes métodos, de imagens Landsat 8</i>	115
5.3.4.1	<i>Método de Máxima Verossimilhança</i>	115
5.3.4.2	<i>Método de Mínima Distância</i>	116
5.3.4.3	<i>Método de KNN</i>	117
5.3.4.4	<i>Método de Random Forest</i>	118
5.3.4.5	<i>Análise comparativa dos métodos de classificação supervisionada – Landsat 8</i>	119
5.4	Determinação das classes através do NDVI.....	121
5.5	Classificação de imagens Hyperion	124
5.5.1	<i>Espacialização das classes através da classificação não-supervisionada.</i>	124
5.5.2	<i>Classificação supervisionada da imagem Hyperion método SVM.....</i>	128
5.5.3	<i>Classificação supervisionada da imagem Hyperion</i>	129
5.5.3.1	<i>Método de Máxima Verossimilhança - Hyperion e Landsat 8.....</i>	129
5.5.3.2	<i>Análise comparativa dos métodos de classificação supervisionada testados – Hyperion</i>	131
5.6	Análise de sensibilidade quanto ao número de amostras por classe	134
5.6.1	<i>Sensor Landsat 8</i>	134
5.6.2	<i>Sensor Hyperion</i>	136
5.7	Análise de desempenho das classificações de imagens Landsat 8 e Hyperion	138

5.7.1	<i>Aplicação para reservatórios do Assentamento 25 de Maio usando dados de VANT</i>	138
5.7.2	<i>Aplicação para os reservatórios da cena do sensor Hyperion que cobre o Assentamento 25 de Maio</i>	143
5.7.3	<i>Aplicação para outros reservatórios do Estado do Ceará</i>	148
6	CONCLUSÕES	151
7	REFERÊNCIAS	153

1 INTRODUÇÃO

O semiárido brasileiro situado na região Nordeste, apresenta um regime pluviométrico marcado por extrema irregularidade de chuvas no tempo e no espaço, onde a escassez de água é tida como um limitador no desenvolvimento, já que a ocorrência cíclica das secas e seus efeitos catastróficos são bem conhecidos, fazendo-se necessário a busca por técnicas de convívio.

Os reservatórios são considerados como solução para o armazenamento de água, principalmente nas regiões áridas e semiáridas onde a pluviometria é escassa e irregular ao longo do ano. A presença da pequena açudagem no semiárido nordestino é uma consequência da política adotada nessa região, que objetiva armazenar água durante os períodos chuvosos para mantê-la disponível durante os severos períodos de seca.

Para a espacialização e quantificação dos reservatórios e das classes no seu entorno, estudos utilizando dados de sensores remotos em pesquisas relacionadas ao comportamento espectral de alvos da superfície terrestre, como a água, a vegetação (diferentes tipos de vegetação), os solos e as atividades agrícolas, são de extrema importância, pois fornecem subsídios à interpretação dos dados gerados. O sensoriamento remoto é uma tecnologia que permite obter imagens e outros tipos de dados, da superfície terrestre, através da captação e do registro de energia refletida ou emitida pela superfície (BHARDWAJ *et al.*, 2015). Possibilitando dessa maneira estudos aplicados e refinados em regiões semiáridas

A aplicação de técnicas de sensoriamento remoto tem apresentado um grande potencial na superação da limitação espaço-temporal na gestão dos recursos hídricos (VALÉRIO, 2009), pois permite a aquisição de informações em diferentes escalas espaciais e temporais, favorecendo a análise de diversos períodos do ano, no entorno de reservatórios. Além disso, cumpre um importante papel da avaliação e quantificação de macrófitas em corpos hídricos.

A quantificação da área de usos do solo pode ser obtida através de imagens de satélites, onde existem dois tipos principais de imagens: imagens multiespectrais e as imagens hiperespectrais (STEELE *et al.*, 2012).

Os sensores multiespectrais não permitem a diferenciação das diversas formações vegetais arbóreas com base em critérios espectrais, já que as pequenas diferenças ao longo do espectro são imperceptíveis em função das poucas bandas espectrais disponíveis. Estas bandas abrangem intervalos amplos ao longo do espectro eletromagnético, não sendo possível identificar feições espectrais mais estreitas, que diferenciam os alvos semelhantes

(DUBE; MUTANGA, 2015). Além disso, as diferenciações dos alvos são dificultadas, já que na grande maioria dos sensores multiespectrais, as resoluções espaciais são pouco refinadas, tornando difícil a caracterização das pequenas variações existentes.

Avanços mais recentes na tecnologia de sistemas sensores espectrais permitiram o surgimento de uma nova geração de sistemas sensores, denominados de hiperespectrais, capazes de coletar simultaneamente dados de uma cena em um considerável de faixas espectrais (GEORGE *et al.*, 2014). As imagens hiperespectrais trouxeram novas perspectivas para as análises ambientais, pois são capazes de fornecer para cada pixel (elemento de resolução espacial) medidas espectrais em bandas estreitas e contínuas, disponibilizando grande quantidade de informação espectral em seu domínio (XIE *et al.*, 2011).

A pesquisa é parte do projeto SERAS (Sensoriamento remoto como estratégia para a gestão das águas no Semiárido: Uso de análise hiperespectral para obtenção de dados hidroambientais) do Programa Probal.

Desta maneira, a presente pesquisa tem como objetivo o desenvolvimento e avaliação de técnicas de análise das áreas de uso e ocupação do solo no entorno dos reservatórios Paus Brancos, Marengo e Nova Vida, localizados no Assentamento 25 de Maio, através de dados multiespectrais e hiperespectrais coletados pelos sensores Landsat 8 e Hyperion respectivamente. Portanto, o estudo envolve a análise de espectros de referência e métodos de quantificação destas áreas, através de classificadores supervisionados e não-supervisionados de imagens de satélites, assim como a verificação das faixas de reflectância dos alvos estudados: água, macrófitas, solo exposto, agricultura, vegetação nativa, vegetação rala, vazante, nuvem e sombra. A metodologia utilizada neste trabalho contribui como uma ferramenta compatível com os atuais programas de monitoramento, a fim de alcançar uma expressiva melhoria na previsão do mapeamento do uso e ocupação do solo, tal como compreender melhor o seu comportamento.

1.1 Hipótese

É possível estabelecer um padrão de classificação e segmentação de imagens multiespectrais e hiperespectrais que permita detectar com precisão satisfatória as áreas inundadas de espelho d'água, com diferenciação de vegetação aquática e outras classes no entorno do reservatório.

1.2 Objetivos

1.2.1 Geral

Propor uma metodologia de identificação e quantificação de áreas inundadas de reservatórios utilizando análise de imagens orbitais (multiespectral e hiperespectral) que permita a diferenciação de vegetação aquática e classes no entorno de reservatórios.

1.2.2 *Objetivos Específicos*

- Diferenciar as macrófitas emergentes de vazantes, área agrícolas e vegetação nativa, no entorno dos reservatórios;
- Determinar as bandas dos sensores multiespectral (Landsat 8) e hiperespectral (Hyperion), que melhor diferenciam as classes: água, macrófitas, vegetação nativa, solo exposto, agricultura, vegetação rala, vazante nuvem e sombra de nuvem;
- Analisar e comparar o desempenho de diferentes classificadores supervisionados e não-supervisionados na detecção de classes (água, macrófitas, solo exposto, vegetação nativa, agricultura, vegetação rala e vazante);
- Aplicar a metodologia de separação de diferentes alvos no entorno de reservatórios não monitorados através de classificação de imagens de satélite, permitindo uma regionalização das classes a partir de sensoriamento remoto. E diferenciar nuvem e sombra de espelho d'água dos reservatórios;
- Estimar a área efetivamente inundada (água mais macrófitas) de reservatórios no semiárido.

2 REVISÃO DE LITERATURA

2.1 Sensoriamento Remoto

O sensoriamento remoto é a utilização de sensores para a aquisição de informações sobre objetos e fenômenos sem que haja contato direto entre sensor e alvo. Os sensores são os equipamentos capazes de coletar energia proveniente do objeto, convertê-la em sinal passível de ser registrado e apresentá-lo em forma adequada para a extração de informações (ESTOQUE; MURAYAMA, 2015).

As informações espaciais das imagens orbitais vêm modificando a forma de se observar e compreender a dinâmica na terra, pois os satélites fornecem dados sobre as interações dos sistemas existentes no planeta com o ecossistema terrestre circundante, permitindo a avaliação do grau de desenvolvimento de desmatamento, compartimentalização do sistema, estado de conservação dos solos e da cobertura vegetal, entre outras informações relevantes (NOVO, 2012).

O Sol é a principal fonte de energia (radiação) eletromagnética para o sistema solar, bem como para o sensoriamento remoto da superfície terrestre. A energia irradiada pela superfície aparente do Sol em direção a Terra é denominada de Fluxo Radiante e o máximo de energia solar disponível na superfície terrestre para fins de sensoriamento remoto encontra-se na faixa de 0,4 μm a 0,7 μm , que é conhecida como a região visível. Além disso também é possível na faixa do infravermelho próximo.


O sensoriamento remoto vai muito além da simples visualização de uma imagem de satélite ou de uma curva espectral obtida em laboratório. É preciso entender, acima de tudo, como a radiação interage com os elementos que compõem a superfície terrestre. A água, grande “solvente universal”, é certamente uma das substâncias mais complexas de serem compreendidas, visto a grande variedade de materiais que podem se encontrar associados e à própria dinâmica interna dos corpos da água.

De acordo com Novo (2012), a coexistência de características ondulatórias e quânticas faz parte da natureza dual de toda a matéria e energia. Assim, um fóton não é nem uma partícula, nem uma onda, mas possui propriedades de partícula e de onda. A energia radiante se comporta como onda eletromagnética e como partícula. A propagação da energia, a dispersão, a reflexão e a refração, são melhor explicadas quando se considera a energia radiante como onda. Já a absorção e emissão são melhores compreendidas quando se reconhece a natureza quântica da energia radiante (PETROPOULOS *et al.*, 2012).

O Sol produz mais emitância radiante do que a Terra porque sua temperatura é maior. A quantidade de energia emitida por um objeto é determinada pela soma (integração) da área sob sua curva (Figura 1). À medida que a temperatura do corpo aumenta, seu comprimento de onda dominante (λ_{\max}) desloca-se em direção aos menores comprimentos de onda do espectro, de acordo com a lei do deslocamento de Wien.

A região do espectro eletromagnética mais utilizada no sensoriamento remoto óptico é a faixa espectral que se estende de 0,3 a 15 μm , embora a faixa de micro-ondas também seja utilizada, em imagens de radar por exemplo. Já a faixa mais utilizada em sensoriamento remoto para estudos dos sistemas aquáticos continentais estende-se de 0,4 a 0,9 μm (Figura 1).

Figura 1 - Espectro eletromagnético




Fonte: Steffen (1995).

Cada comprimento de onda possui energia e frequência diferentes. O espectro eletromagnético é dividido em bandas ou regiões: radiação gama, raios X, radiação ultravioleta, visível, infravermelha, micro-ondas e ondas de rádio. Essas denominações estão relacionadas com a forma com que as radiações podem ser produzidas ou detectadas. A região do visível é definida como a radiação capaz de produzir a sensação de visão para o olho humano normal. Isaac Newton em 1672 constatou que um raio luminoso (luz branca), ao atravessar um prisma, disperso num feixe colorido um espectro de cores (DUBE; MUTANGA, 2015).

Desde, então os cientistas foram ampliando os seus estudos e verificaram que a luz branca é uma síntese de diferentes tipos de luz, uma espécie de vibração composta, basicamente, de muitas vibrações diferentes. Não existe um limite rígido entre duas cores do espectro visível.

Os limites tabulados apresentados na literatura são apenas teóricos, para fins didáticos. Este fato é bem ilustrado na Figura 2, onde se percebe claramente que a transição entre duas cores é difusa. O espectro visível pode ser subdividido de acordo com a cor. Para os comprimentos de onda mais curtos, cor violeta e para os comprimentos de onda longos, cor vermelha conforme ilustrado, esquematicamente, na Figura 1. A região do visível é importante para o sensoriamento remoto, pois imagens obtidas nesta faixa, geralmente, apresentam excelente correlação com a experiência visual do intérprete.

Figura 2 - Formas de representação de dados multiespectrais (λ é o comprimento de onda)



Fonte: Landgrebe (2003).

Na Tabela 1, estão contidas as cores que compõem a luz branca e as respectivas faixas do espectro eletromagnético expressas em nanômetro (nm) e micrômetro (μm). A radiação infravermelha (IV) constitui-se do conjunto de radiações eletromagnéticas cujos comprimentos de onda variam de 0,7 a 1.000 μm . Situam-se no espectro eletromagnético entre a luz vermelha e as micro-ondas e também podem receber a denominação de radiação térmica. Esta radiação é dividida em três faixas espectrais: IV próximo (0,7 a 1,1 μm), IV médio (1,1 a 3,0 μm) e IV distante (3,0 a 1.000 μm).

A aplicação do Sensoriamento Remoto (SR) ao estudo do ambiente aquático é uma constante dentro das ciências ambientais em todo o mundo. No Brasil, há uma larga aplicação do SR para analisar a qualidade dos corpos d'água em diversos ambientes, sejam eles rios, lagos, lagoas ou reservatórios artificiais. Um exemplo consolidado, dentro da temática em questão, é o projeto realizado pelo Ministério da Integração Nacional, Agência Nacional de Águas (ANA) e a Fundação Cearense de Meteorologia e Recursos Hídricos (FUNCEME) que fez o levantamento dos espelhos d'água acima de 20 hectares de todo o País utilizando o SR. A

metodologia empregada por esse projeto teve como princípio a aplicação temporal de imagens CBERS dos anos de 2000 a 2007, realizando o processamento digital dessas imagens e utilizando as melhores bandas para uma melhor resposta espectral dos corpos d'água, desta forma conseguiram extrair informações quantitativas das áreas, que culminou em um banco de dados e o mapeamento final dos espelhos d'água de todo o País (FUNCEME, 2008).

Tabela 1 - Relação de cores e faixas espectrais na região do visível

Cor	Comprimento de onda	
	Nanômetro (nm)	Micrômetro (µm)
Violeta	400 a 446	0,400 a 0,446
Azul	446 a 500	0,446 a 0,500
Verde	500 a 578	0,500 a 0,578
Amarela	578 a 592	0,578 a 0,592
Laranja	592 a 620	0,592 a 0,620
Vermelha	620 a 700	0,620 a 0,700

Fonte: Moreira (2011).

2.2 Sensores Remotos Ópticos

Os sensores ópticos emulam basicamente a visão, são fabricados segundo a tecnologia da emissão e recepção de irradiação infravermelha. O princípio de funcionamento geral de um sensor óptico consiste na colocação de emissores e receptores de luz (MOREIRA, 2011).

Os satélites e têm por finalidade captar a REM proveniente da superfície terrestre, e transformar a energia conduzida pela onda em pulso eletrônico ou valor digital proporcional à intensidade desta energia segundo a fonte da onda eletromagnética. Os sensores ópticos podem ser divididos em dois tipos, ativos e os passivos (NOVO, 2012).

- **Passivos:** Utilizam apenas a REM natural refletida ou emitida a partir da superfície terrestre. A luz solar é a principal fonte de REM dos sensores passivos.

- **Ativos:** Estes sistemas utilizam REM artificial, produzida por radares instalados nos próprios satélites. Estas ondas atingem a superfície terrestre onde interagem com os alvos, sendo refletidas de volta ao satélite. Uma vantagem dos sensores ativos é que as ondas produzidas pelos radares atravessam as nuvens, podendo ser operados sob qualquer condição atmosférica. Uma desvantagem é que o processo de interação com os alvos não capta, tão detalhadamente quanto os sensores passivos.

Os recursos naturais e o meio ambiente da Terra estão em mudanças contínuas em resposta à evolução natural e às atividades humanas. Para compreender o complexo inter-

relacionamento dos fenômenos que causam estas mudanças, é necessário fazerem-se observações com uma grande gama de escalas temporais e espaciais (MOREIRA, 2011) (DUBE; MUTANGA, 2015). A observação da Terra por meio de satélites é a maneira mais efetiva e econômica de coletar os dados necessários para monitoramento e modelagem destes fenômenos, especialmente em países de grande extensão territorial, como o Brasil (VALÉRIO, 2009).

2.2.1 Landsat 8

A série Landsat surgiu no final dos anos 60 como parte do Programa de Levantamento de Recursos Terrestres da NASA. Por se tratar do programa de satélites de recursos terrestre mais antigo, operando ininterruptamente desde 1972 e disponibilizando imagens gratuitas desde 1973, o programa apresenta um importantíssimo acervo histórico de imagens orbitais. No Brasil, o INPE é a instituição responsável pela manutenção e disponibilização deste acervo.

Em 11 de fevereiro de 2013, foi lançada ao espaço a Missão de Continuidade dos Dados Landsat (LDCM) – chamada de Landsat 8. Com dois novos sensores: o sensor espectral OLI e o sensor termal TIRS, o acréscimo de resolução espectral é muito positivo. Foram adicionadas duas bandas espectrais: a *new coastal* (banda 1), projetada especificamente para os recursos hídricos e investigação da zona costeira, e um novo canal de infravermelho (banda 9), para a detecção de nuvens. Tais adições provocaram mudanças nos intervalos dentro do espectro dos canais de todas as bandas (Tabela 2).

Tabela 2 - Características dos sensores embarcados no satélite Landsat 8

Bandas do satélite Landsat 8	(Micrômetros)	Resolução (Metros)
Band 1 – Aerossol costeira	0.43 – 0.45	30
Band 2 – Azul	0.45 – 0.51	30
Band 3 – Verde	0.53 – 0.59	30
Band 4 – Vermelho	0.64 – 0.67	30
Band 5 – Infravermelho próximo (NIR)	0.85 – 0.88	30
Band 6 – Infravermelho médio (SWIR 1)	1.57 – 1.65	30
Band 7 – Infravermelho médio (SWIR 2)	2.11 – 2.29	30
Band 8 – Pancromática	0.50 – 0.68	15
Band 9 – Cirrus	1.36 – 1.38	30
Band 10 – Infravermelho termal (TIRS) 1	10.60 – 11.19	100
Band 11 – Infravermelho termal (TIRS) 2	11.50 – 12.51	100

Fonte: USGS (2013).

Há também uma nova banda de garantia de qualidade (Banda QA), que fornece informações sobre a presença de nuvens, água e neve. A partir do sensor termal TIRS, foram criadas duas bandas espectrais para o comprimento de onda antes coberto por uma única banda nos sensores TM e ETM (USGS, 2013). Algumas bandas apresentam largura menor no espectro, principalmente na região do infravermelho do espectro eletromagnético.

2.2.2 *EO-1 Hyperion*

O satélite EO-1 da NASA (*National Aeronautics and Space Administration*), foi lançado em 21 de novembro de 2000 como parte de uma missão tecnológica de validação e demonstração para uma duração inicial de um ano. O instrumento ALI (*Advanced Land Imager*) foi usado para validar e demonstrar a tecnologia para a Missão de continuidade de dados Landsat.

A extensão do EO-1 foi planejada para coletar e distribuir os produtos multiespectrais ALI e hiperespectrais Hyperion, através de pedidos de aquisição de dados, sendo estas imagens adquiridas pelo satélite EO-1 arquivadas e distribuídas pela USGS, no EROS (*Center for Earth Resources Observation and Science*) e colocadas assim à disposição do público usuário, com características sintetizadas na Tabela 3. São 2 instrumentos distintos a bordo do satélite EO-1:

- a) O Hyperion adquire dados de imagem em 220 bandas espectrais entre 0,357 e 2,576 micrômetros com uma largura de banda espectral de 10-nm. Este instrumento opera igualmente no modo de escaneamento linear ao longo da órbita.
- b) Com resolução espacial de 30 m para todas as bandas, a cena padrão tem 7.7 km de largura e 42 km de extensão com a opção de extensão do comprimento da cena em até 185 km. O *Linear Etalon Imaging Spectrometer Array (LEISA) Atmospheric Corrector (LAC)* fornecia o primeiro teste baseado no espaço para um Corretor Atmosférico de bordo (*on-board Atmospheric Corrector - AC*) para aumentar a precisão na estimativa da refletância de superfície.

O volume de dados coletado pelo Hyperion é aproximadamente 75 vezes maior quando comparado às seis bandas óticas do sensor ETM+ Landsat (THENKABAIL *et al.*, 2004). Das 242 bandas produzidas pelo sensor Hyperion, apenas 155 são radiometricamente calibradas. Por meio deste elevado número de bandas espectrais, ecossistemas terrestres complexos podem ser imageados e identificados com melhor precisão quando comparado com sensores multiespectrais (GALVÃO *et al.*, 2005).

Tabela 3 – Características do sensor Hyperion/EO-1

Características	Hyperion
Abrangência espectral	356 - 2577 nm
Resolução espacial	30 m
Comprimento da faixa	42 X 7.7km a 185 X 7.7km
Cobertura espectral	Contínua
Número de bandas	242
Resolução espectral	10 nm
Bandas VNIR	1-70 (356-1058 nm)
Bandas SWIR	71-242 (852-2577 nm)
Ordem dos pixels	BIL
Resolução da Imagem	256x6460

Fonte: Earth Resources Observation & Science (EROS) Data Center, 2015.

2.3 Métodos Classificatórios

A classificação de imagens de satélites é uma das técnicas mais utilizadas para a extração de informações com diferentes objetos, permitindo ainda a incorporação destas informações em programas de geoprocessamento. A classificação pode ser entendida como uma partição do espaço de atributos segundo alguns critérios. Os métodos de classificação (ou classificadores) podem ser divididos em classificadores por pixel ou por região e podem levar em conta uma ou mais bandas da imagem (no caso de imagens multiespectrais e hiperespectrais).

Os classificadores por pixel utilizam a informação espectral de cada pixel isolado para rotular individualmente cada um, de acordo com as variáveis discriminantes (bandas espectrais), às classes informadas. Já os classificadores por regiões baseiam-se na informação de um conjunto de pixels vizinhos (região), técnica estar conhecida por classificação por objeto.

Existem diversos algoritmos de classificação utilizados em sensoriamento remoto. Os mais utilizados são os de Máxima Verossimilhança, Mínima Distância, KNN, SVM, Random Forest e ISODATA, empregados no procedimento de classificação supervisionada e não-supervisionada, respectivamente, como atestado por Figueiredo (2005) e Toneli (2008). Atualmente tem-se adotado classificadores mais robustos do tipo árvore, de decisão como o caso do método Random Forest (BREIMAN, 2001), e classificadores que avaliam as melhores bandas para representar os usos do solo, além dos pesos das bandas na representação dos alvos (SMOLA *et. al.*, 2000).

2.4 Classificação não-supervisionada

O método é dito não supervisionado quando o classificador não utiliza, a priori, nenhum conhecimento sobre as classes existentes na imagem e define, sem a interferência do analista, a estratificação da cena, atribuindo a cada pixel uma determinada classe. Tal abordagem corresponde à técnica de segmentação de imagens, em que as mesmas são divididas em certas classes sem conhecimento prévio.

Neste tipo de classificação, o algoritmo baseia-se na análise de agrupamentos onde são identificados no espaço de atributos as "manchas" (*clusters*) formadas por pixels com características espectrais similares. Define-se então, através de limiares estabelecidos pelo analista, quais as concentrações de pixels que devem ser tratadas como grupos distintos. O algoritmo define estas classes com base em regras estatísticas pré-selecionadas (RIPLEY, 2000).

Os algoritmos de agrupamento mais conhecidos são o K-MÉDIA e o ISODATA. Ambos têm por finalidade agruparem os pixels, dividindo os dados da imagem no espaço multiespectral em um determinado número de classes estipulado pelo usuário (JENSEN, 1996). O K-MÉDIA é um algoritmo para partição de um conjunto de elementos em determinado número de agrupamentos (*clustering*) K, utilizando o método dos mínimos quadrados e o ajustamento das médias (média móvel) no decorrer dos processos de iterações. O uso de um *software* para realizar esta operação se estrutura apenas na simples implementação de um algoritmo que se baseia nos mínimos quadrados. Este algoritmo, de forma geral, possui obrigatoriamente apenas duas etapas simples (THEILER E GISLER, 1997).

2.4.1 ISODATA

Neste tipo de classificação, o algoritmo baseia-se na análise de agrupamentos em que são identificadas, no espaço de atributos, as nuvens (*clusters*) formadas por "pixels" com características similares. Neste tipo de classificador, é comum especificar o número destas nuvens, isto é, o número de classes possíveis de serem encontradas na área de estudo. Define-se então, através de limiares estabelecidos pelo analista, quais as concentrações de "pixels" que devem ser tratadas como grupos distintos (VENTURIERI; SANTOS, 1998).

O ISODATA é uma modificação do algoritmo K-MÉDIA, em que é implementada a função de fusão ou divisão de classes espectrais (*clusters*). Apesar de ser um algoritmo similar ao K-MÉDIA, o ISODATA incorpora algumas compilações heurísticas. Existem muitas variações em torno do desenho básico deste algoritmo. As considerações aqui apresentadas são

formuladas a partir de um modelo básico, comum a todos, o qual pode ser observado em Ripley (2000).

Os agrupamentos iniciais são pré-definidos pelo usuário e distribuídos ao longo do eixo diagonal do espaço de atributos, que é representado por uma linha que se origina no ponto correspondente ao número máximo do nível de cinza de cada componente espectral. Se duas classes estão muito próximas e a distância entre centróides, ocorrerá uma fusão das classes. Se a distância que a amostra apresenta, a média das classes (centróide) for maior que a das classes existentes, esta será dividida em duas classes (RIPLEY, 2000). A cada iteração será recalculada a média das classes espectrais e os pixels serão reagrupados seguindo os seguintes critérios:

- a) As classes com desvio padrão acima de um linear serão subdivididas para formar classes menores;
- b) Classes que estão estatisticamente muito próximas serão fundidas; e
- c) Classes com número pequeno de pixels são eliminadas.

2.5 Classificação supervisionada

Dentre as diversas técnicas de classificação, uma das mais utilizadas é a classificação supervisionada (LIU, 2007; JENSEN, 2009). O classificador realiza o processo por meio de reconhecimento dos padrões espectrais na imagem, se faz com base nas amostras de áreas de treinamento que são fornecidas ao sistema de classificação pelo analista. Este classificador baseia-se nos valores radiométricos dos pixels e nos parâmetros da distribuição Gaussiana de cada uma das classes de treinamento (JENSEN, 2009).

2.5.1 Máxima Verossimilhança

O método da Máxima Verossimilhança é mais comumente utilizado quando é necessária a obtenção de classes, determinadas a partir de imagens de sensores remotos. A distribuição espectral das classes de uso do solo é considerada gaussiana ou normal (RIBEIRO *et al.*, 2007), isto é, objetos pertencentes à mesma classe apresentam respostas espectrais próximas à média de valores para aquela classe.

A Máxima Verossimilhança considera a ponderação das distâncias, utilizando parâmetros estatísticos de distribuição de pixels dentro de uma determinada classe. Para a obtenção de resultados adequados com esta classificação, é necessária a escolha de um número razoavelmente elevado de pixels para cada amostra de treinamento da classe, e que estes tenham uma distribuição estatística próxima da distribuição normal de acordo com Crósta (1993).

Este método de classificação parte do pressuposto de que o usuário conhece previamente a área estudada, bem como a distribuição das classes, para que desta forma, quando da aplicação da classificação, a seleção de amostra de treinamento (calibração) possa ser a mais eficiente possível (CRÓSTA, 1993). Este método classificatório é o mais utilizado em sensoriamento remoto dentro da abordagem estatística, já que envolve parâmetros (vetor média e matriz de covariância) da distribuição gaussiana multivariada, e ainda é supervisionado, pois estima estes parâmetros através das amostras de treinamento (QUEIROZ *et al.*, 2004).

A função de probabilidade a posteriori $P(\omega_i|x)$ pode ser expressa utilizando-se o teorema:

$$g_i(\mathbf{x}) = -\ln |\Sigma_i| - (\mathbf{x} - \boldsymbol{\mu}_i)^T \Sigma_i^{-1} (\mathbf{x} - \boldsymbol{\mu}_i) \quad \text{para } i=1, 2, \dots, k. \quad (1)$$

Onde:

$\boldsymbol{\mu}_i$ representa o vetor média;

Σ_i representa a matriz de covariância da classe ω_i ,

2.5.2 *Support Vector Machine (SVM)*

SVM é uma técnica de aprendizado de máquina, fundamentada nos princípios da Minimização do Risco Estrutural (VAPNIK, 1999). Esta técnica busca minimizar o erro com relação ao conjunto de treinamento (risco empírico), assim como o erro com relação ao conjunto de teste, isto é, conjunto de amostras não empregadas no treinamento do classificador (risco na generalização) (VAN DER LINDEN, *et al.*, 2014). O objetivo do classificador SVM consiste em obter um equilíbrio entre esses erros, minimizando o excesso de ajustes com respeito às amostras de treinamento e aumentando conseqüentemente a capacidade de generalização (VAPNIK, 1999).

O problema denominado de *overfitting* (sobreposição) consiste em o classificador memorizar os padrões de treinamento, especializando-se em suas peculiaridades e ruídos, ao invés de extrair as características gerais que permitiram a generalização ou reconhecimento de padrões não utilizados no treinamento do classificador (SMOLA *et al.*, 2000).

A questão da generalização pode ser melhor avaliada para o caso de duas classes. Assumindo que as amostras de treinamento de duas classes são linearmente separáveis, a função de decisão mais adequada é aquela para a qual a distância entre os centróides dos conjuntos das amostras de treinamento é maximizada (RABE *et al.*, 2014; VAN DER LINDEN, *et al.*, 2014).

Neste contexto, a função de decisão que maximiza esta separação é denominada de ótima (VAPNIK, 1999).

O método é determinado através da equação:

$$R(\alpha) = \int \frac{1}{2} L(f(d_i, \alpha), c_j) dPr(d_i, c_j) \quad (2)$$

2.5.3 *Mínima distância*

Este método é um caso particular do método de Máxima Verossimilhança descrito anteriormente, pois considera as matrizes de covariância de todas as classes iguais (RICHARDS, 1999).

A classificação de um novo pixel pelo método de Distância Mínima é obtida a partir da determinação da menor distância entre o pixel a ser classificado e os centróides das classes compostas por suas respectivas amostras de treinamento.

O método é calculado pela equação:

$$SD_{xyc} = \sqrt{\sum_{i=1}^n (\mu_{ci} - X_{xyi})^2} \quad (3)$$

Onde:

n = numero de bandas;

i = uma banda em particular;

c = uma classe em particular;

X_{xyi} = valor do pixel para uma banda i ;

μ_{ci} = média do valor na banda i para a classe;

SD_{xyc} = distância espectral do pixel x,y para a média da classes c .

3.5.4 *KNN*

O classificador *K-Nearest Neighbors*, K-vizinhos mais próximos, ou simplesmente KNN, assume que as amostras se encontram em um espaço n -dimensional em que n são as quantidades de amostras e K , o número de vizinhos de uma amostra. Diferente de outros métodos, as amostras são classificadas de acordo com características dos K-vizinhos mais próximos (DUDA *et al.*, 2001). Para obter a relação de uma amostra com seus vizinhos é

utilizada a distância euclidiana (SOUZA, 2013).

O valor de K determina a quantidade de vizinhos que serão avaliados para classificar um indivíduo. Segundo Souza (2013), deve-se evitar: valores pares de K; K = 1, para que a classificação não caia em mínimos e máximos locais; K = 9, para não analisar muitas classes diferentes

Em relação à segunda questão, uma das formas mais comuns de agrupar as categorias dos k vizinhos mais próximos é atribuir para o documento d_i a categoria com maior pontuação de acordo com a Equação:

$$pnt(d_i, c_j) = \sum_{d_t \in N_k(d_i)} sim(d_i, d_t) \times ver(c_j, d_t) \quad (4)$$

Onde: $N_k(d_i)$ são os k documentos de treino mais próximos de d_i , $sim(d_i, d_t)$ é o valor da similaridade entre d_i e d_t e $ver(c_j, d_t)$ é uma função que retorna 1, caso o documento de treino d_t pertença a categoria c_j e 0, caso contrário.

2.5.5 *Random Forest*

O classificador Random Forest é um método que consiste em um conjunto de árvores de decisão, classificação baseada em hiperplanos construídas no momento de treinamento do método (JAMES *et al.*, 2013). Para construí-las, são selecionados aleatoriamente alguns dos atributos contidos dentro do vetor de características, como apresentado por Breiman (2001). Uma vez feito isso, calcula-se a entropia apresentada por cada atributo e aquele que possuir a maior é escolhido para separar as classes naquela posição da árvore. A saída do classificador é dada pela classe que foi retornada como resposta pela maioria das árvores pertencentes à floresta (JAMES *et al.*, 2013).

O método apresenta aprendizado não supervisionado, ou seja, dadas as instâncias de treinamento e as etiquetas que indicam a classe de cada uma, o algoritmo aprende a classificá-las sem que haja a intervenção de um usuário no processo (BREIMAN, 2001). O método vem sendo largamente utilizado nas mais diversas áreas do aprendizado de máquina e vem apresentando ótimos resultados (HAN *et al.*, 2011).

2.6 Aplicações de técnicas de realce em imagens de satélite Landsat 8

As técnicas de processamento digital de imagens no domínio espacial são baseadas na manipulação direta dos pixels em uma imagem. Neste contexto, destacam-se duas

importantes metodologias: transformações de intensidade e filtragem espacial. A segunda abordagem é eventualmente referida como processamento de vizinhança espacial. Podemos interpretar a manipulação matemática correspondente a estas técnicas na forma da expressão:

$$g(x, y) = T[f(x, y)], \quad (5)$$

Em que:

$f(x, y)$ é a imagem original (imagem de entrada);

$g(x, y)$ é a imagem processada (imagem de saída);

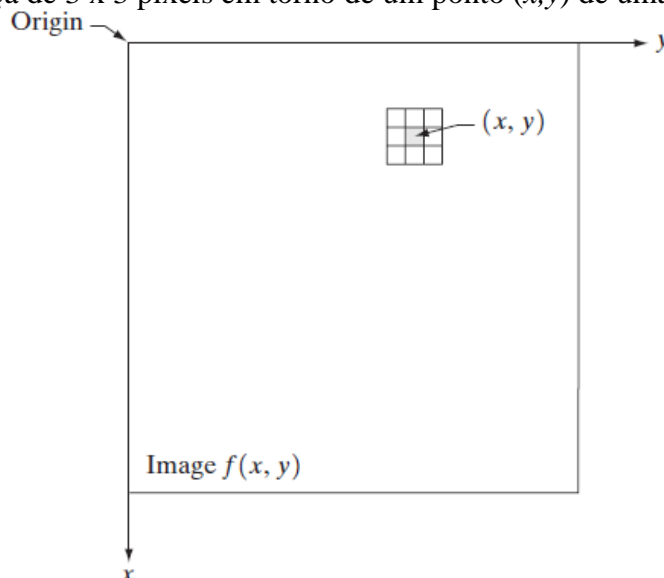
T é um operador em f, definido sobre uma determinada vizinhança em torno do ponto (x, y) .

Adicionalmente, o operador T pode realizar o processamento de um conjunto de imagens, como, por exemplo, realizar a soma de K imagens para redução de ruído.

A principal metodologia de definição de vizinhança espacial em torno de um ponto (x, y) é o uso de uma região retangular ou quadrada centrada em (x, y) , (Figura 3).

O centro da região de vizinhança é movido de pixel a pixel, iniciando, por exemplo, no canto superior esquerdo, abrange, assim, em cada posição, diferentes regiões da imagem. Apenas os pixels abrangidos pela vizinhança são considerados no cálculo da função $g(x, y)$.

Figura 3 - Vizinhança de 3 x 3 pixels em torno de um ponto (x, y) de uma imagem



Fonte: Gonzalez e Woods, 2000.

2.6.1 Transformações de Intensidade

A mais simples forma assumida pelo operador T ocorre quando é definida a vizinhança em torno de cada posição (x,y) de tamanho 1×1 pixel, isto é, com um único pixel. Neste caso, o valor da função g em (x,y) depende apenas da intensidade de f naquele ponto, isto é, do nível de cinza do pixel, e T torna-se um operador de transformação de intensidade ou de nível de cinza, considerando-se cada componente monocromática de uma imagem no formato RGB.

As funções de transformação de intensidade, por dependerem exclusivamente dos níveis de cinza de cada pixel independentemente um do outro, e não explicitamente de sua localização, são geralmente expressas na forma simplificada:

$$s = T(r), \quad (6)$$

em que:

r denota a intensidade (nível de cinza) de um dado pixel ou qualquer ponto (x, y) ;

f (imagem de entrada);

s denota a intensidade da imagem g , ambos em qualquer ponto (x,y) nas imagens.

As transformações de potência possuem a forma básica:

$$s = c \cdot r^\gamma, \quad (7)$$

em que:

c e γ = são constantes positivas.


Pode também ser expressa considerando a existência de um *offset*, isto é, um valor mínimo de saída para quando o valor da entrada é nulo:

$$s = c(r + \varepsilon)^\gamma \quad (8)$$

Traçados da função s para vários valores do parâmetro γ , são apresentados na Figura 4 abaixo.

Para valores de γ menores que 1, a função mapeia uma banda estreita de níveis de entrada próximos ao preto em uma ampla faixa de valores na saída, comprimindo uma banda larga de níveis de cinza em uma faixa menor de valores na saída. Analogamente, as curvas geradas com valores de $\gamma > 1$ produzem o efeito oposto daquele obtido para $\gamma < 1$.

Figura 4 - Traçados da equação 5 para vários valores de γ



Fonte: Gonzalez e Woods, 2000.

Nos testes experimentais, foram utilizados valores de $\gamma = 0,5$ (primeiro conjunto de imagens) e $\gamma = 0,75$ (segundo conjunto de imagens).

A transformada de contraste (*contrast-stretching*) é definida pela expressão:

$$\mathbf{s} = \mathbf{T}(\mathbf{r}) = \frac{1}{1+(m/r)^E} \quad (9)$$

Resultando na compressão dos valores de intensidade acima do valor de m em uma banda estreita de níveis claros (próximos ao branco) na imagem de saída, conforme ilustrado na Figura 5 ilustrada abaixo:


Quanto maior o valor do parâmetro E , mais íngreme é a inclinação da curva, e mais a função transformada de contraste de alongamento se aproxima, no limite de E tendendo a valores muito altos, da função limiar, a qual possui apenas dois valores de saída: 0, se $r < m$, e 255, se $r > m$.

Nos testes experimentais, o parâmetro m é calculado como a intensidade média dos pixels da amostra de imagem a ser classificada, e o parâmetro E é selecionado em uma lista de valores: 4, 9, 10, 12, 14, 16, 18.

A técnica de realce de contraste tem por objetivo melhorar a qualidade das imagens sob os critérios subjetivos do olho humano. É normalmente utilizada como uma etapa de pré-processamento para sistemas de reconhecimento de padrões (PEDRINI; SCHWARTZ, 2007). O contraste entre dois objetos pode ser definido como a razão entre os seus níveis de cinza

médios. A manipulação do contraste consiste numa transferência radiométrica em cada pixel, com o objetivo de aumentar a discriminação visual entre os objetos presentes na imagem. Realiza-se a operação ponto a ponto, independentemente da vizinhança. A escolha do mapeamento direto adequado é, em geral, essencialmente empírica. Entretanto, um exame prévio do histograma da imagem pode ser útil.

Figura 5 - Gráficos obtidos para a transformada em contraste para a função limiar



Fonte: Gonzalez e Woods, 2000.

O histograma de uma imagem descreve a distribuição estatística dos níveis de cinza em termos do número de amostras (pixels) em diferentes faixas de nível. A distribuição pode também ser dada em termos da percentagem do número total de "pixels" na imagem. Pode ser estabelecida uma analogia entre o histograma de uma imagem e a função densidade de probabilidade, que é um modelo matemático da distribuição de tons de cinza de uma classe de imagens (GONZALEZ; WOODS, 2000).

Pode-se fazer um realce de contraste utilizando-se uma função matemática denominada transformação radiométrica. Esta função consiste em mapear as variações dentro do intervalo original de tons de cinza para um outro intervalo desejado este método é utilizado para aumentar o contraste de uma imagem expandindo-se o intervalo original de níveis de cinza.

O aumento de contraste por uma transformação linear é a forma mais simples das opções. A função de transferência é uma reta e apenas dois parâmetros são controlados: a inclinação da reta e o ponto de interseção com o eixo X. A inclinação controla a quantidade de aumento de contraste e o ponto de interseção com o eixo X controla a intensidade média da imagem final (PEDRINI; SCHWARTZ, 2007).

2.7 Índices estatísticos utilizados na avaliação da qualidade de classificação de imagens de satélite

A utilização de imagens de satélite para fins de mapeamento, planejamento e monitoramento ambiental tem sido realizada há várias décadas. Atualmente, novas tecnologias têm possibilitado o uso de imagens de satélite para variados fins.

Em pesquisas de Sensoriamento Remoto, a utilização de imagens de satélite para a produção de mapas é uma das grandes inovações no segmento do geoprocessamento, pois possibilita uma gama de análises espaciais e temporais. Como o ambiente sofre alterações constantes pela ação antrópica, a interpretação de imagens de satélite é uma fonte direta de se determinar a dinâmica dos processos envolvidos em tais alterações. Neste sentido, a fotointerpretação e o processamento digital de imagens assumem papel de grande importância, pois permitem fornecer subsídios para a compreensão dos fenômenos ambientais, além da possibilidade de planejamento estratégico em situações distintas, como por exemplo, no planejamento urbano (JENSEN, 2009).

Técnicas de sensoriamento remoto vêm se mostrando promissoras, sobretudo no mapeamento de grandes extensões geográficas onde o uso dessas técnicas é requerido, realizado a partir de imagens orbitais, onde a resolução espacial é um dos principais fatores na definição das legendas dos mapas temáticos (PONZONI e REZENDE, 2002). O desenvolvimento de sensores com alta resolução espectral tem permitido aos usuários o mapeamento detalhado da superfície terrestre, abrindo um novo campo para os usuários de imagens orbitais.

Todavia, os dados de sensores remotos necessitam ser analisados para que sejam extraídas informações necessárias ao planejamento, manejo e monitoramento dos recursos. Nesse sentido, muitas técnicas de classificação foram desenvolvidas, visando, sobretudo, o mapeamento do uso e ocupação do solo de forma semiautomática, através de algoritmos especializados.

2.7.1 Índice de Kappa

Grande parte do mapeamento digital de cobertura vegetal, em nível regional, vem sendo realizado através de imagens de sensoriamento remoto. Técnicas de classificação supervisionada associadas ao processamento digital de imagens têm dado bons resultados na extração de informações que compõem determinada região. No entanto, todo o processo de classificação está sujeito a erros dos mais diversos tipos e fontes.

Entretanto, para o seu uso ser recomendado é necessário que se conheça a grau

de exatidão e de precisão da classificação. De acordo Moreira (2011), a exatidão significa o nível elevado de reconhecimento dos pixels classificados; enquanto que a precisão se refere aos resultados das áreas classificadas com as áreas mapeadas.

A avaliação da acurácia dos dados extraídos das imagens está diretamente relacionada com a qualidade do mapeamento. Todas as classes que compõem a imagem ou o mapa temático devem ser associadas a um controle de qualidade para que possam ser validadas. Entende-se que um mapeamento temático só deva ser utilizado como fonte fidedigna de informações quando associado a processos de avaliação da acurácia dos dados que o compõem. Observa-se que raramente mapas temáticos provenientes de classificação digital ou mesmo da fotointerpretação apresentam um relatório de acurácia das informações.

A avaliação da exatidão das classificações obtidas pelos algoritmos de classificação de imagens é gerada através de matrizes de confusão, tomando como referência o uso e cobertura da terra retratada, onde essa metodologia de análise tem sido empregue por diversos autores, em pesquisas realizadas. Em diversas parte do mundo (CONGALTON, 1991; BISSO, 2010; PETROPOULOS *et al.*, 2012; BLANCO *et al.*, 2014; ESTOQUE; MURAYAMA, 2015; COULTER *et al.*, 2016; GILBERTSO, *et al.*, 2017).

Segundo Congalton e Green (1999), o coeficiente de Kappa é baseado na diferença entre concordância observada (diagonal principal da matriz de confusão com a concordância entre a classificação e os dados de referência) e a chance de concordância entre os dados de referência e uma classificação aleatória (produto entre os totais marginais da matriz). A equação que fornece o valor de Kappa é dada por:

$$\hat{K} = \frac{N \sum_{i=1}^k x_{ii} - \sum_{i=1}^k (x_{i+} \cdot x_{+i})}{N^2 - \sum_{i=1}^k (x_{i+} \cdot x_{+i})} \quad (10)$$

Onde:

r = Número de classes

x_{ii} = Número de elementos classificados corretamente por classe

x_{i+} = Total de elementos classificados para uma categoria i

x_{+i} = Total de elementos de referência amostrados para uma categoria i

N = Número total de amostras

São utilizadas as métricas de exatidão global e índice Kappa (CONGALTON; GREEN, 1999), conforme os níveis de aceitação. Uma das vantagens apontadas para o uso do Kappa é que ele incorpora a informação dos pixels erroneamente classificados, e não apenas dos corretamente classificados, como a exatidão global. De forma simplificada, a exatidão global é um índice que superestima a confiabilidade da classificação, e o Kappa é uma avaliação mais adequada.

De acordo com Moreira (2001), o Índice Kappa apresenta a vantagem de que para o seu cálculo não se incluem somente os elementos da diagonal principal, e sim todos os elementos da matriz de erros, ou seja, estima a probabilidade de um pixel ser corretamente classificado em relação à probabilidade da classificação incorreta. Portanto, tal índice demonstra oscilações de erros de omissão e inclusão. A acurácia da classificação determinada por meio do coeficiente Kappa, desenvolvida por Landis e Koch (1977), associa a um determinado intervalo de valores Kappa um grau de qualidade do mapa temático.

O procedimento mais adotado na medição da exatidão das classificações por meio de matrizes de erro é o índice Kappa (CONGALTON, 2001; MACHADO, 2002). Esta medida de acurácia ou, mais apropriadamente, exatidão está baseada na diferença entre a concordância real na matriz (concordância entre os dados simulados e os dados de referência, indicada na diagonal principal) e a concordância por chance, indicada pelo total das linhas e das colunas (marginais).

Kappa (k) é uma estatística amplamente utilizada para estimar a acurácia da previsão de uma variável categórica. A estatística k é uma técnica multivariada discreta para determinar estatisticamente se uma matriz de erro é significativamente diferente do outro (ZHAN *et al.*, 2002).

A análise Kappa foi originalmente adotada em ciências sociais e, após sua inserção em estudos de sensoriamento remoto, vários trabalhos têm sido publicados com a sua utilização, tornando-se componente padrão em avaliações de acurácia (CONGALTON, 2001; SANCHES, *et al.*, 2008; DAINESE, 2001), em seus trabalhos utilizaram o índice Kappa para realizar a validação dos classificadores, tendo como referência a verdade terrestre.

O meio mais comum de expressar a precisão de mapas ou classificações automáticas, conforme (MOREIRA, 2011) é obter a porcentagem da área corretamente classificada, quando comparada com dados de referência.

2.8 Validação das classificações de imagens de satélites

Após a aplicação de um dado algoritmo de classificação, torna-se necessária a avaliação da precisão e da exatidão dos resultados, ou seja, é necessário determinar o quão próximo é o conjunto de atribuições realizadas em relação à realidade. O método de avaliação da exatidão e da precisão de classificação depende da disponibilidade de dados de campo (NOVO, 2012).

A confiabilidade de qualquer mapa (uso da terra, por exemplo) está diretamente vinculada a sua exatidão e também a sua precisão, as quais respectivamente indicam a proximidade de uma observação ou medida de seu valor real. Nesse sentido, realizada a classificação de imagens digitais, necessita-se de algum procedimento estatístico que defina a acurácia desta classificação, seja ela automatizada ou visual (BERNARDES, 2006).

Atualmente, as técnicas usadas na exatidão do mapeamento têm como ponto de partida a construção de matrizes de erro ou de contingência. Uma matriz de contingência constitui uma maneira eficaz de representar a acurácia de um conjunto de dados simulados ou estimada em relação a um conjunto de dados de referência, proporcionando um índice global de acerto (BERNARDES, 2006).

2.9 Identificação de Macrófitas em Reservatórios

A vegetação aquática passa a ser encarada como daninha quando seu crescimento acentuado causa problemas para a utilização dos ecossistemas, surgindo a partir desse momento a necessidade de aplicação de métodos de controle ou manejo.

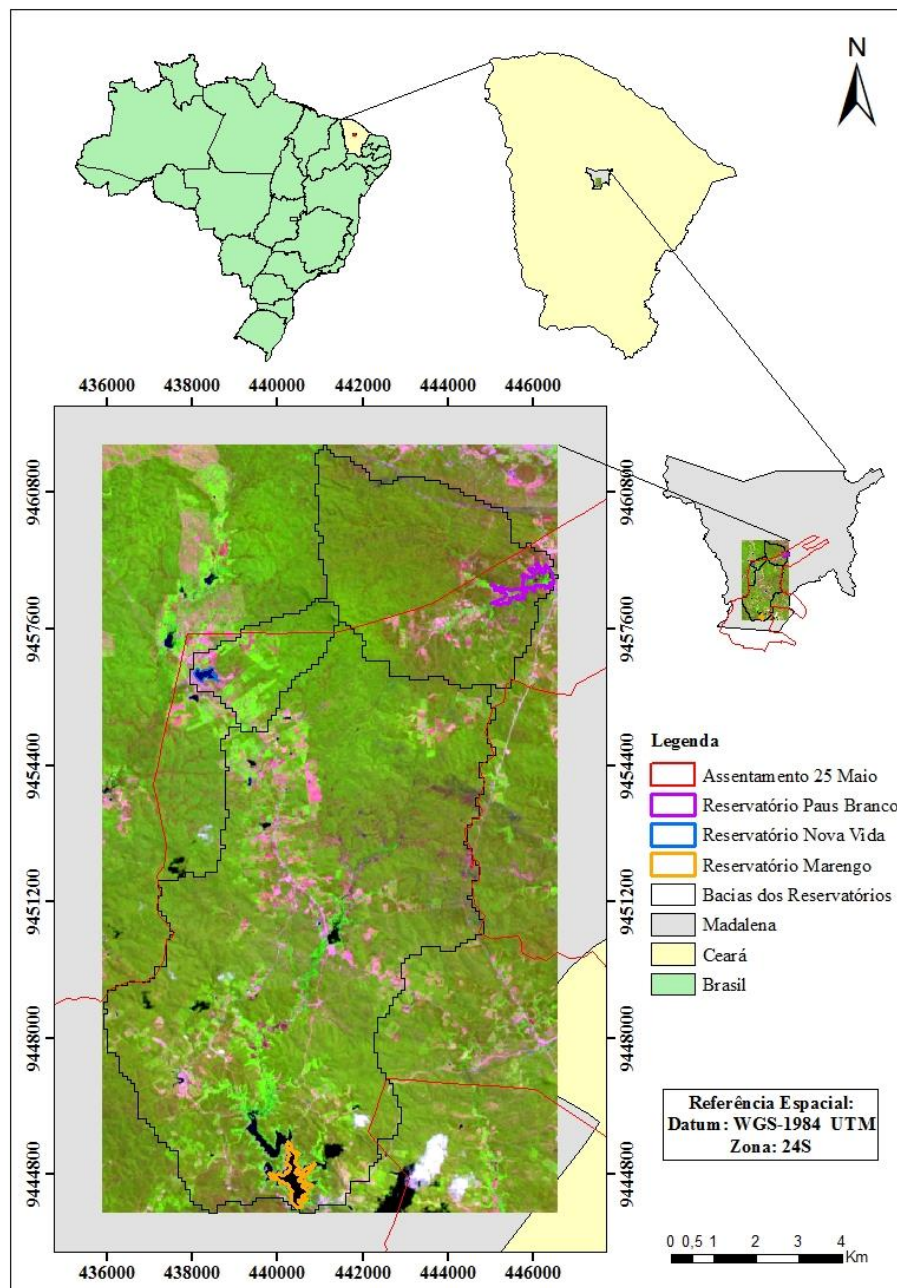
Com a disponibilidade das imagens do sensor TM (*Thematic Mapper*), foram realizados experimentos para verificar se o aumento na resolução espacial dessas imagens permitiria estimativas da concentração dos componentes individuais da água.

Conforme salienta Novo (2012), a maior limitação desses dados é sua resolução espectral inadequada para estudos da água, a qual não permite discriminar componentes opticamente ativos, principalmente quando ocorrem simultaneamente altas concentrações de clorofila e material inorgânico. Por outro lado, Galo *et al.* (2002) destacam que muito embora o sensor TM não tenha sido projetado para estudos de material orgânico, os dados obtidos permitem detectar apropriadamente áreas infestadas por plantas aquáticas em grandes reservatórios, principalmente macrófitas marginais e flutuantes.

3 CARACTERIZAÇÃO DA ÁREA DE ESTUDO

A pesquisa foi realizada no Assentamento 25 de Maio (25M) ilustrado na Figura 6, onde atualmente vivem 425 famílias com cerca de 2.000 habitantes, organizadas em 13 comunidades com 18 associações comunitárias e uma cooperativa. No Assentamento, há açudes de pequeno e médio porte, que são afluentes da bacia hidrográfica do rio Banabuiú.

Figura 6 – Localização do Assentamento 25 de Maio no Estado do Ceará, destacando as bacias hidrográficas dos três reservatórios considerados



Fonte: Elaborada pelo autor.

O assentamento 25 de Maio possui uma área total de 22.992 ha e se encontra inserido nos limites entre três municípios, Madalena (maior parte do território do assentamento), Boa Viagem e Quixeramobim, localizando-se a 187 km da capital, Fortaleza. Possui doze açudes que abastecem a população, dos quais onze açudes são de pequeno porte e um é de médio porte, segundo a classificação de Lima Neto *et al.* (2011); Malveira *et al.* (2012).

Dentre estes açudes, três foram selecionados para investigação no contexto desta pesquisa, sendo estes: Nova Vida, Paus Brancos e Marengo, pois foram os únicos a apresentar armazenamento de água durante todo o desenvolvimento da pesquisa. Estes açudes apresentam características físicas diferentes como área da bacia hidráulica e volume de armazenamento, e uso do solo no entorno (agricultura, pecuária, vazante e habitação). Na Tabela 4 pode ser visualizado as características físicas dos três reservatórios estudados no Assentamento 25 de Maio.

Tabela 4 - Características físicas dos reservatórios no Assentamento 25 de Maio em Madalena-CE

Reservatório	Capacidade (hm³)	Área da bacia (km²)	Área do espelho d'água (km²)	Classificação
Nova Vida	1,3	6	0,23	Pequeno
Paus Brancos	5,5	21	0,57	Pequeno
Marengo	18	75	3,1	Médio

Fonte: Relatório Técnico do INCRA (ACACE, 2005), adaptado pelo autor.

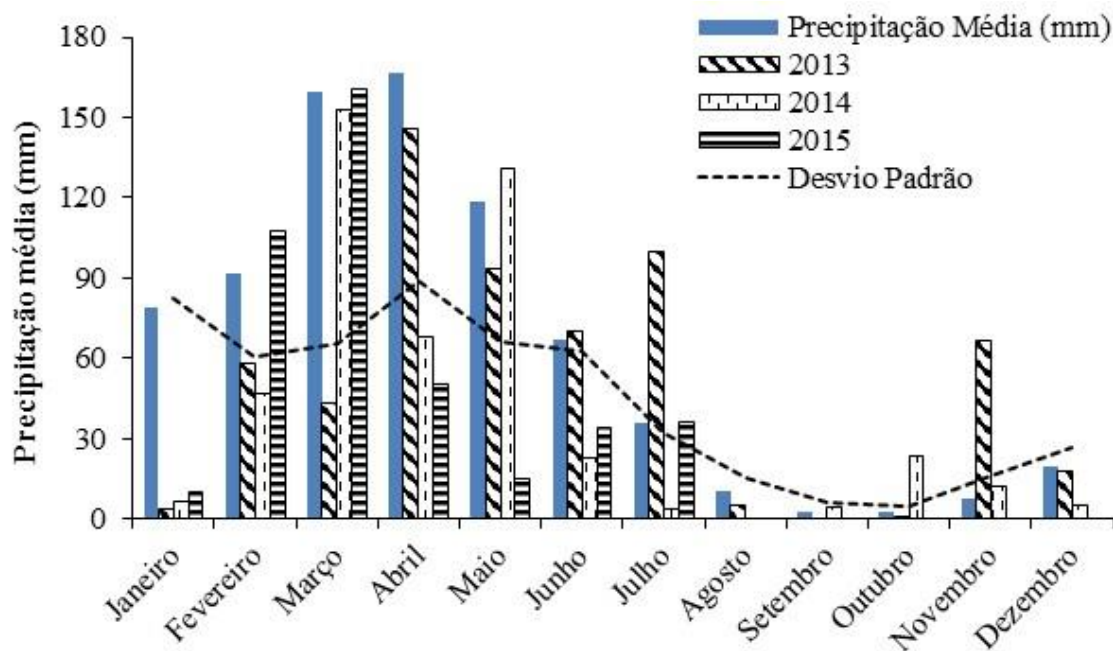
3.1 Caracterização Hidroclimatológica

A área de estudo encontra-se localizada no Polígono das Secas, com predominância de clima quente semiárido, segundo classificação de Köppen. Este clima é caracterizado por um período seco e quente.

As temperaturas médias estão entre 26 a 28 °C, com período chuvoso, concentrado entre os meses de janeiro a maio.

A pluviosidade média é de 692 mm (Figura 7) anuais e a taxa potencial de evapotranspiração é superior a 2000 mm anuais, devido à elevada temperatura ambiente e à intensa radiação solar, características da região onde se localiza o Assentamento 25 de Maio (IPECE, 2009).

Figura 7 – Média da precipitação mensal no posto pluviométrico de Madalena – Série histórica de 1961 a 2015



Fonte: FUNCEME, (2015).

3.2 Caracterização fisiográfica

3.2.1 Relevo

Situada entre as cotas altimétricas de 250 a 360m com declividade máxima de 16% (Figura 8). A obtenção do modelo digital de elevação (MDE) foram obtidas através do SRTM (*Shuttle Radar Topography Mission*) com resolução espacial de 90 x 90 metros (tamanho do pixel).

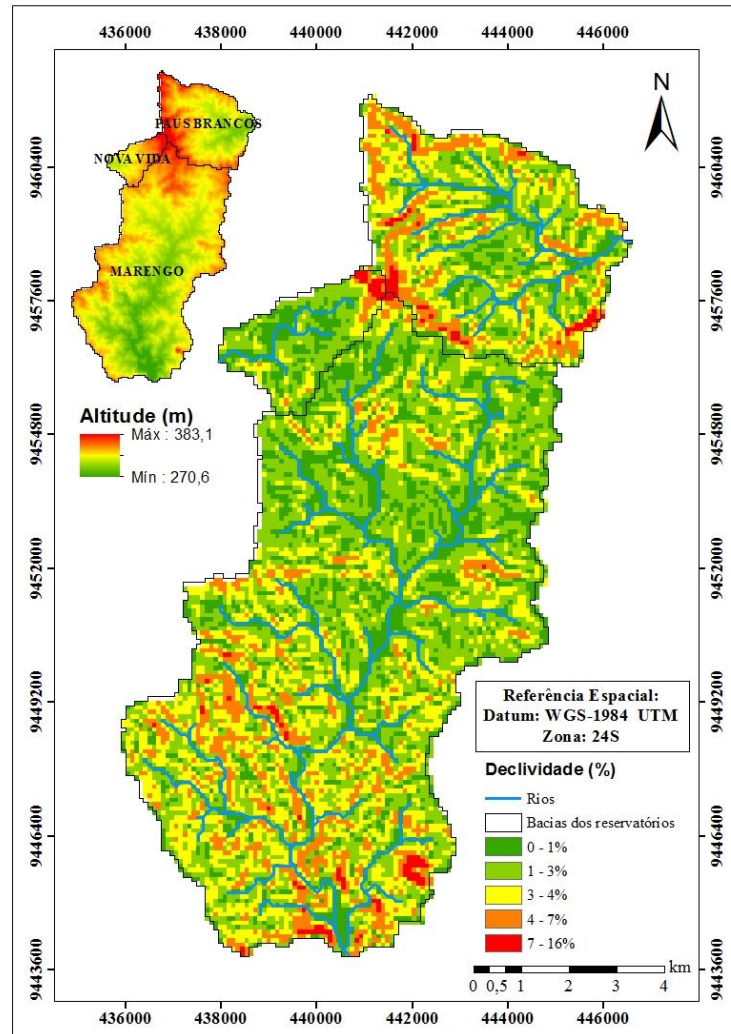
As bacias hidrográficas dos 3 reservatórios estudados foram geradas com base no modelo digital de elevação (SRTM). O modelo digital de terreno (SRTM/NASA) foi processado utilizando ferramentas do Sistema de Informações Geográficas (SIG) Arc Gis 10.2 para delimitação automática das bacias dos reservatórios considerados (Paus Brancos, Marengo e Nova Vida), como apresentado na Figura 8.

A área de estudo está sob formação geológica do período Pré-cambriano, composta por rochas do embasamento cristalino, representadas por gnaisses e rochas magmáticos diversos, associados a rochas plutônicas e metaplutônicas de composição predominantemente granítica (CEARÁ, 2011).

A rede de drenagem faz parte da bacia do rio Banabuiú, que drena 13% do território cearense (CEARÁ, 2008). Os rios e riachos são intermitentes, com escoamento superficial

restrito aos períodos chuvosos.

Figura 8 - Declividade percentual da área de estudo obtida a partir do modelo digital de elevação (MDE)

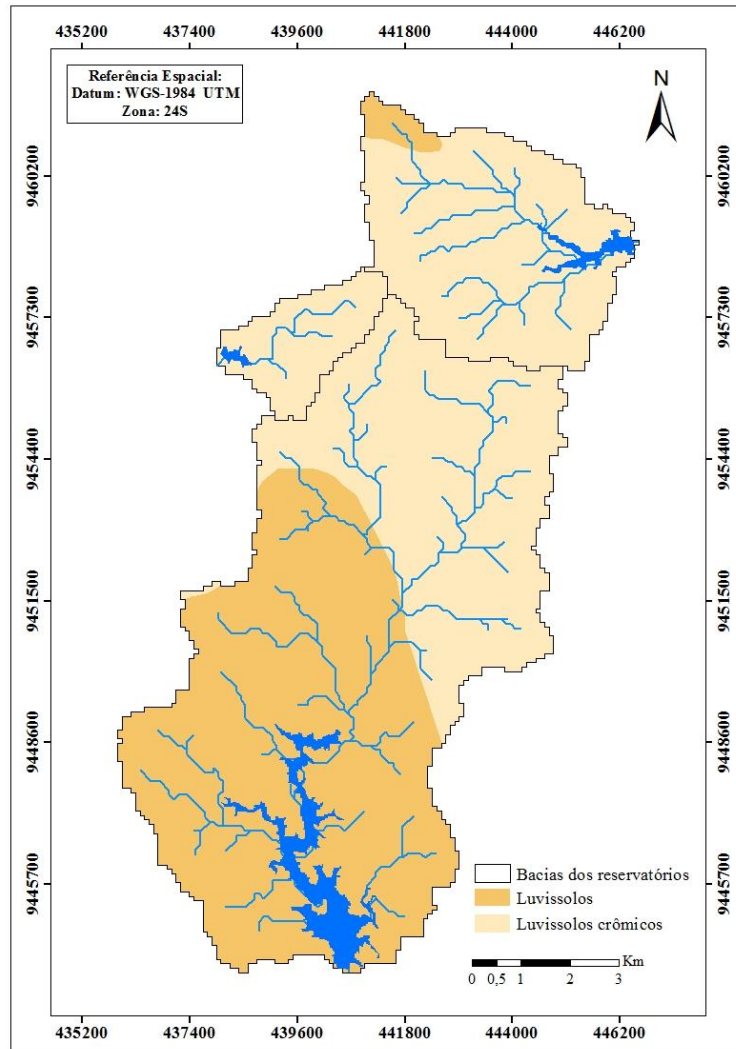


Fonte: SRTM (NASA).

3.2.2 Solos

A bacia situa-se sobre embasamento cristalino, região de solos rasos com predomínio do Luvisolos (Bruno não Cálcico), como pode ser observada na Figura 9, obtida através dos mapas dos temas pedologia e geologia de Jacomine *et al.* (1973), disponibilizados na forma digital pelo Serviço Geológico do Brasil (CPRM) em escala 1:1.000.000. A cobertura vegetal é de Caatinga arbustiva densa e floresta caducifólia espinhosa, vegetação típica da região, que perdem as folhas sazonalmente, (IPECE, 2009). Ao longo da rede hidrográfica, estabelece-se a mata ciliar, cuja espécie predominante é o marmeleiro.

Figura 9 – Solos das bacias dos reservatórios

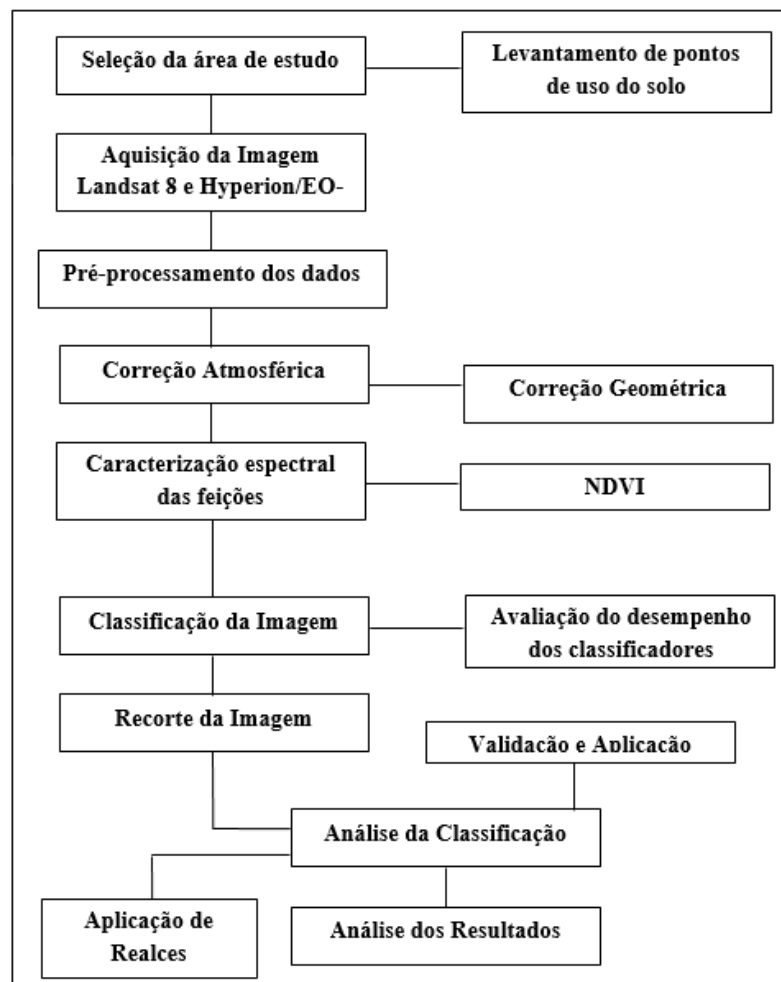


Fonte: Jacomine *et al.* (1973).

4 MATERIAL E MÉTODOS

O desenvolvimento da metodologia é composto de dez fases (Figura 10), onde o primeiro momento se deu pela escolha da área para a realização da pesquisa, no caso o Assentamento 25 de Maio, onde é desenvolvido diversas pesquisas pelo grupo Hidrosed. No segundo momento, foram selecionadas as imagens a serem processadas, tendo como critério a qualidade baseado, na cobertura de nuvens e sombra. Em seguida as imagens adotadas foram submetidas à correção atmosférica que visou converter o número digital em valores reais de reflectância. Em seguida, possibilitou a determinação do NDVI das imagens e das classificações não-supervisionadas e supervisionada. Então as imagens são submetidas ao processamento computacional através de algoritmo desenvolvidos no ambiente Matlab. Também são determinadas as faixas de reflectância das classes. Por fim, é realizado a avaliação quantitativa da qualidade da classificação através do índice de Kappa.

Figura 10 - Fluxograma das etapas desenvolvidas na pesquisa

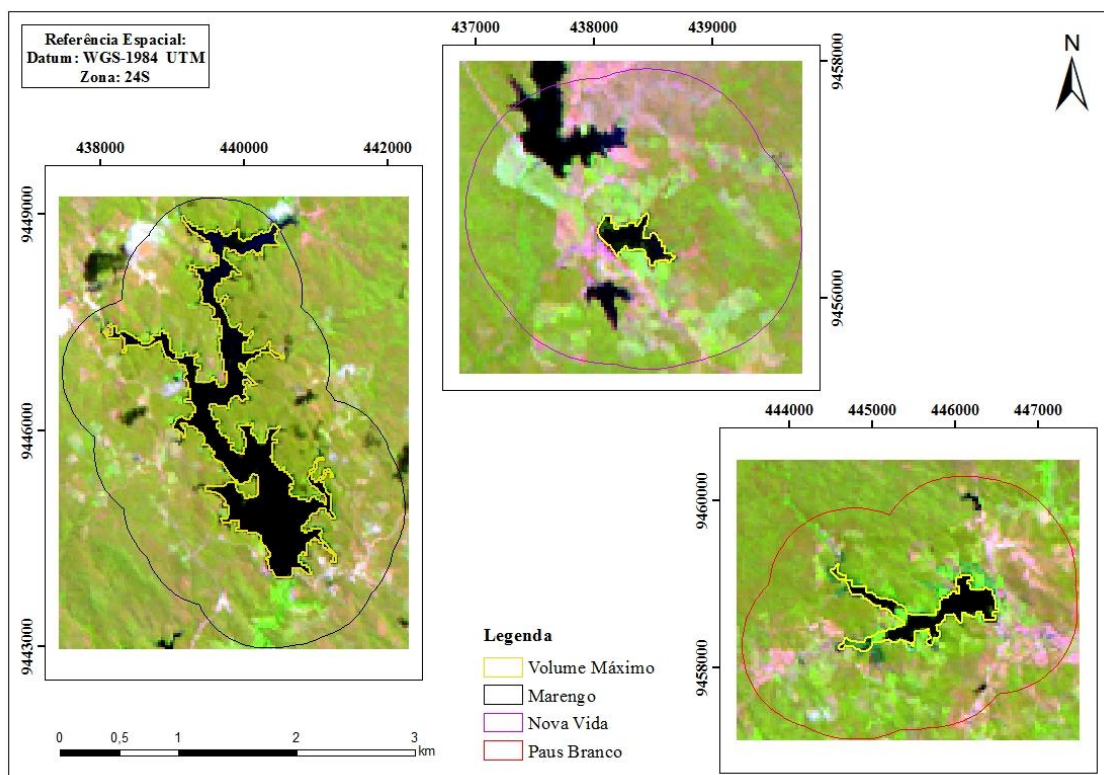


Fonte: Elaborada pelo autor.

4.1 Delimitação da área investigada no entorno dos reservatórios

A fim de compreender melhor o uso e ocupação do solo no entorno dos reservatórios estudados (Paus Branco, Marengo e Nova Vida), decidiu-se considerar uma área com distanciamento mínimo de 1km através da ferramenta *buffer* no programa Arc Gis 10.2, em torno do contorno máximo (Figura 11) da bacia hidráulica de cada reservatório estudado, para garantir a existência de diferentes classes. A obtenção dessa informação se deu através da imagem Landsat 5 do dia 24 de julho de 2004, por ser um ano com precipitações acima da média em que os reservatórios superficiais supostamente estavam cheios, em análise comparativa com outros períodos.

Figura 11 – Área de influência considerada no entorno dos reservatórios Marengo, Nova Vida e Paus Brancos



Fonte: Elaborada pelo autor.

4.2 Pré-processamento de imagens de satélite

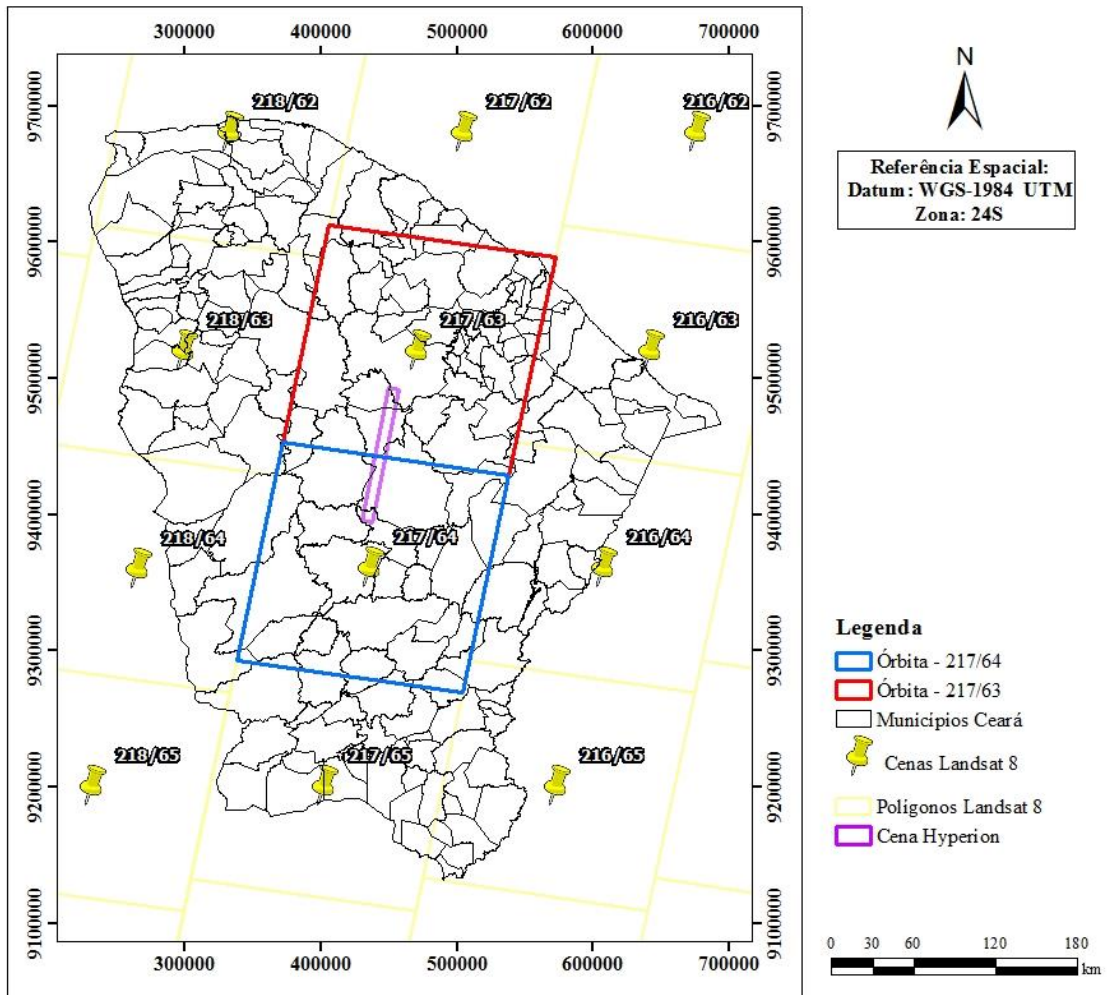
4.2.1 Sensor Landsat 8

4.2.1.1 Aquisição e seleção de imagens

As imagens orbitais digitais do satélite Landsat 8 foram adquiridas de forma gratuita no sítio do *United States Geological Survey* (USGS, 2013), a região de desenvolvimento da pesquisa está localizada sobre a órbita 217, ponto 63 (Figura 12).

Lançado em fevereiro de 2013, o satélite Landsat 8 apresenta órbita praticamente polar, posicionando-se de maneira heliossíncrona a uma altitude de aproximadamente 705 km. Existem dois sensores embarcados no satélite Landsat 8: o OLI (*Operacional Land Imager*) e o TIRS (*Thermal Infrared Sensor*).

Figura 12 - Ilustração das cenas do satélite Landsat 8



Fonte: INPE 2008.

Conforme apresentado na Tabela 4, os sensores a bordo do satélite Landsat 8 possuem faixa de imageamento de 170 km norte-sul por 185 km Leste-Oeste, resolução temporal de aproximadamente 16 dias, resolução espacial de 30 metros para as bandas do

visível, 15 metros para banda pancromática e 100 metros para as bandas termiais (*TIRS*), resolução radiométrica de 16 bits.

Foi necessária a realização da mudança de zona já que as imagens Landsat 8 são referenciadas em WGS 1984 na zona 24 Norte. A conversão foi feita no Arc Gis 10.2, sendo necessário realizar a conversão de zona, para 24 Sul.

As imagens foram captadas nas datas apresentadas na Tabela 5, tendo como critério de seleção a definição das mais atuais possíveis, sem a presença de nuvens sobre a região de estudo.

As bandas R-6, G-5 e B-4 foram consideradas para compor a visualização falsa cor que proporciona separação entre alvos de características semelhantes como tipos de vegetação. As imagens selecionadas para pesquisa são apresentadas na Tabela 5 e estão destacadas em negrito e sobescrito. O critério para a seleção das imagens levou em consideração a cobertura de nuvens.

Tabela 5 - Banco de imagens Landsat 8 adquiridas no sítio da USGS 2015

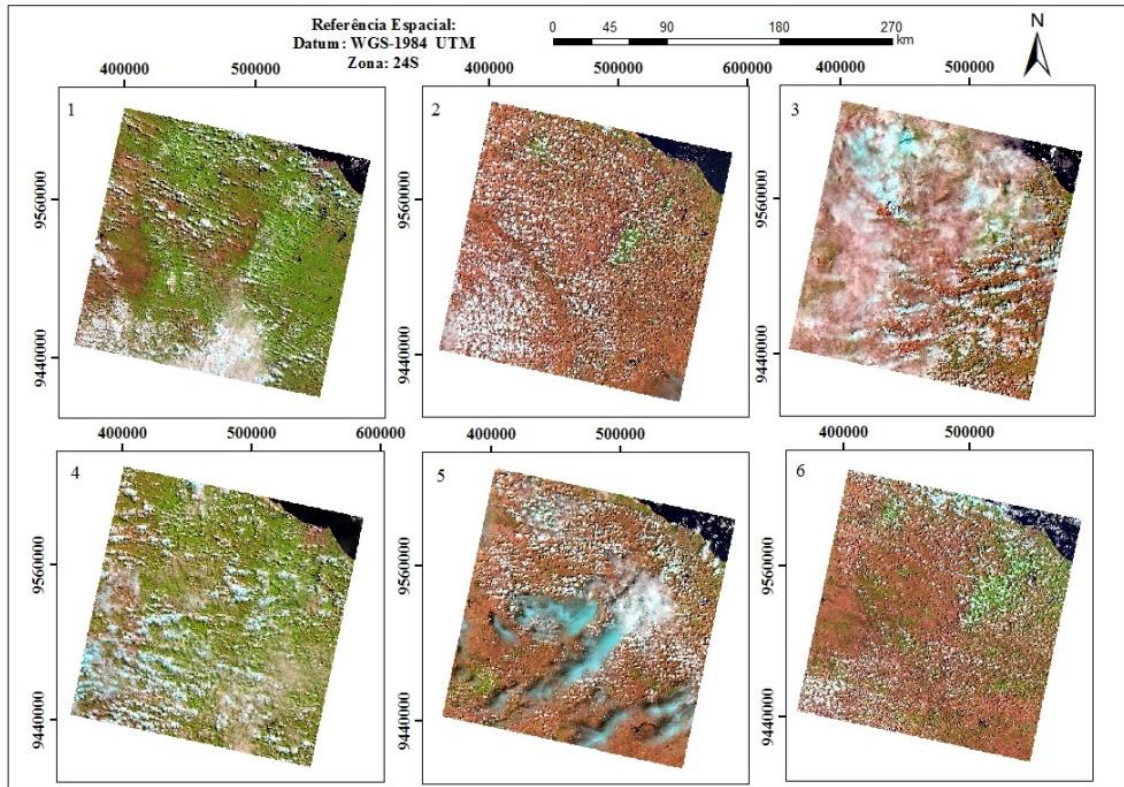
MÊS	2013	2014	2015
Janeiro	-	09 - 25	12 - <u>28</u>
Fevereiro	-	10 - 26	13
Março	-	14 - 30	17
Abril	12 - 28	15	02 - 18
Mai	14 - <u>30</u>	01 - 17	04 - 20
Junho	15	02 - 18	05 - 21
Julho	01 - 17	04 - 20	07 - 23
Agosto	02 - 18	<u>05</u> - 21	08 - <u>24</u>
Setembro	<u>03</u> - 19	06 - <u>22</u>	09 - 25
Outubro	05 - <u>21</u>	08 - 24	11 - <u>27</u>
Novembro	06	09 - 25	12 - 28
Dezembro	08 - 24	11 - 27	
	16	23	20
Total - 59 imagens → 8 cena boas – 13,5%			

Fonte: Elaborada pelo autor.

Uma das dificuldades de análise imagens de satélites em regiões equatoriais e subequatoriais se dá devido à alta cobertura de nuvens (Figura 13), causando a perda de informações dos alvos que se encontram abaixo da mesma ou até a confusão de informações (como é o caso de espelho d'água com a sombra das nuvens). Após a aquisição das 26 imagens, optou-se por trabalhar com seis imagens (o que corresponde a 103% do total do banco), de

baixa cobertura de nuvem para não ocasionar a perda de informações da superfície.

Figura 13 - Imagens Landsat 8 com alta cobertura de nuvens



Fonte: Elaborada pelo autor.

4.2.1.2 Correção atmosférica

A correção atmosférica é o procedimento que tira o efeito de dispersão da energia eletromagnética nas partículas de água suspensas na atmosfera, possibilitando que os alvos invariáveis, temporalmente, sejam interpretados. Consiste em corrigir o espalhamento atmosférico e estimar a interferência atmosférica a partir dos números digitais (ND) das imagens. O efeito da atmosfera é um dos agentes que altera a resolução radiométrica das imagens e o efeito dessa alteração é a redução do contraste dos alvos presentes na imagem.

A correção atmosférica das imagens Landsat 8 foi realizada por meio da análise dos histogramas e posterior subtração dos números digitais (ND) por meio da função *Dark Subtract* do *software* ENVI 5.1. Tal função possibilita o ajuste dos valores dos pixels para uma condição padrão de iluminação teórica, necessária em estudos que irão lidar com bandas coletadas em diferentes datas e/ou por diferentes sistemas sensores.

Para obter a reflectância de superfície, foi usado o aplicativo FLAASH (*Fast Line-of-Sight Atmospheric Analysis of Spectral Hypercubes*) para o cálculo do vapor d'água

e correção atmosférica subsequente de outros gases usando o *software* ENVI 5.1. O FLAASH opera baseado no processamento pixel a pixel, ou seja, proporciona a vantagem de fornecer uma única assinatura espectral para cada pixel, quando possível. A imagem de entrada deve fornecer os dados em ponto-flutuante, inteiro estendido ou inteiro e o formato de gravação da imagem deve ser BIL ou BIP.

Foram informados parâmetros da cena e as informações do sensor como: a coordenada central da cena (latitude/longitude), a elevação média da superfície, o tipo de sensor, a altitude do sensor e a data e hora de imageamento, modelo atmosférico tropical, modelo avançado de *ISAACS* e modelo de aerossol rural. Estes dados possibilitaram que o *FLAASH* determinasse a posição solar e a sua incidência sobre a superfície terrestre melhorando as informações.

4.2.2 *Sensor Hyperion*

4.2.2.1 *Aquisição e seleção de imagens*

Após a aquisição das 12 imagens (Tabela 6) optou-se por trabalhar com uma de baixa cobertura de nuvem, por não ocasionar a perda de informações da superfície, o que corresponde a 8% do total do banco de imagens.

Tabela 6 - Banco de imagens Hyperion adquiridas no sitio da USGS, 2015

MÊS	2014	2015
Janeiro	-	-
Fevereiro	-	09
Março	-	13
Abril	-	-
Maio	-	22 - 30
Junho	-	26
Julho	-	-
Agosto	-	<u>28</u>
Setembro	-	-
Outubro	11 - <u>19</u>	-
Novembro	25	09
Dezembro	01 - 03	-
		12 Imagens - 8%

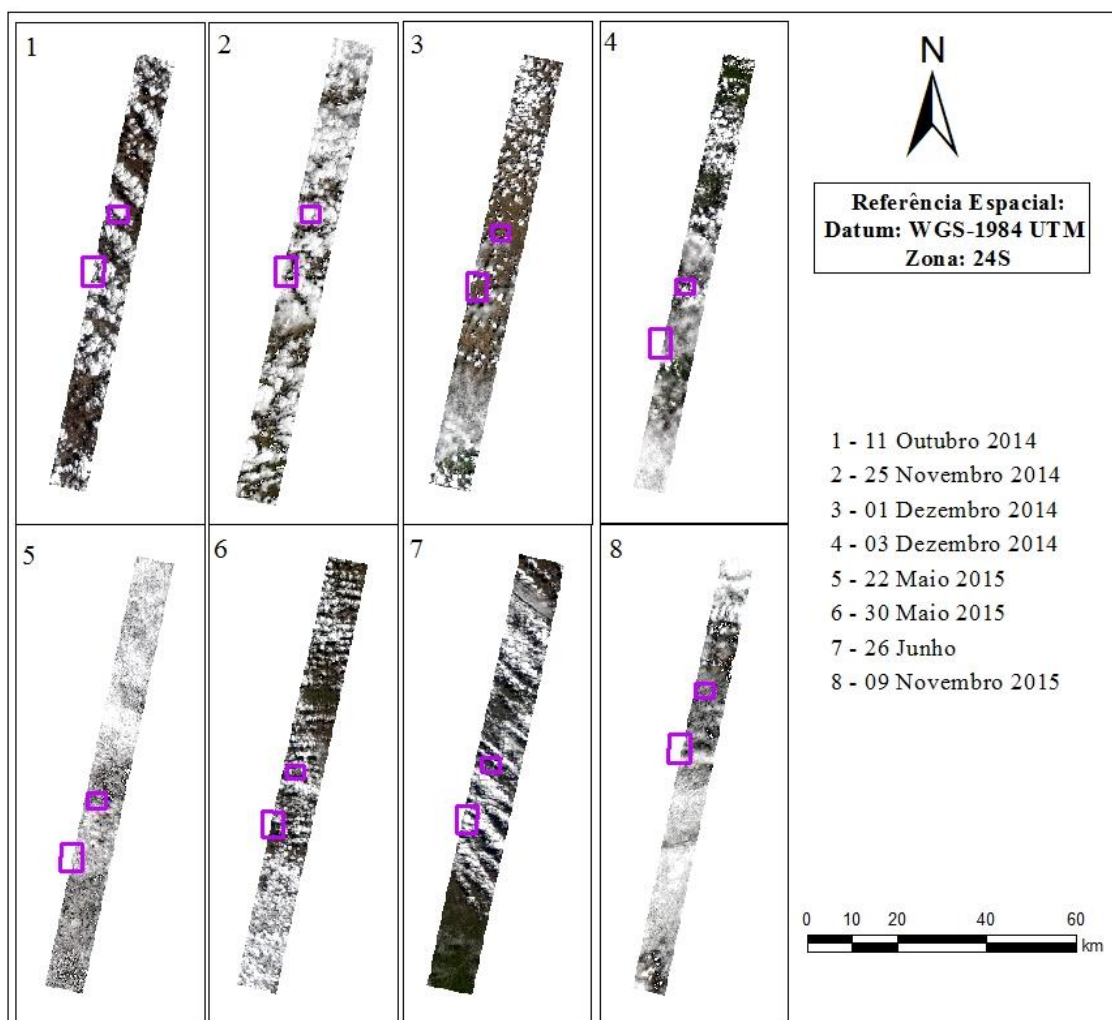
Fonte: Elaborada pelo autor.

A aquisição da imagem foi feita através da USGS (*United States Geological Survey*), que encaminhou o pedido à empresa EROS (*Earth Resources Observation and Science*). A imagem hiperespectral utilizada no trabalho foi adquirida na data do dia 19 de

outubro de 2014 (EO1H2170632014292110KF_1R).

O Hyperion é o primeiro sensor orbital a produzir imagens hiperespectrais da superfície da Terra, instalado no satélite *Earth Observing One* (EO-1) e lançado em 21 de novembro de 2000 pela NASA (*National Aeronautics and Space Administration*) a uma órbita de 705 km da superfície terrestre. Na Figura 14, pode ser visualizada a cena obtida pelo sensor Hyperion, observando-se a espacialização dos reservatórios Paus Brancos e Marengo, estudados na pesquisa.

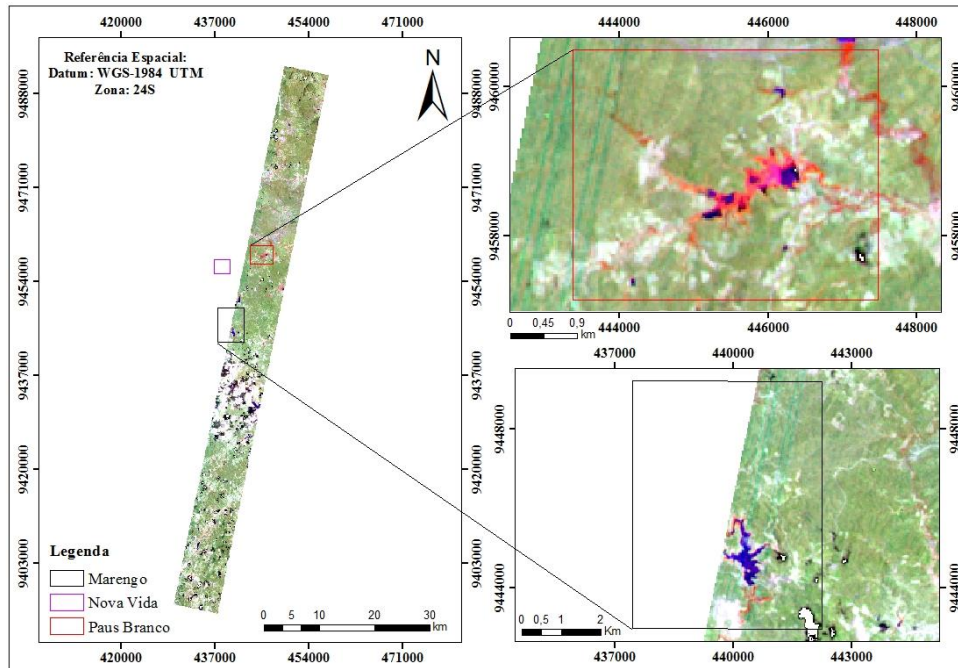
Figura 14 - Imagens Hyperion disponíveis no sitio da USGS



Fonte: Elaborada pelo autor.

Diferente da cena do Landsat 8, a cena do Hyperion, que apresenta órbita 217 e ponto 63, não contemplou a área do reservatório Nova Vida, como pode ser observado na Figura 15. Desta forma, o reservatório Nova Vida foi excluído da análise de dados hiperespectrais da área.

Figura 15 - Imagem Hyperion (19/10/2014), composições RGB bandas 51, 161, 19, com a localização da área de estudo



Fonte: Elaborada pelo autor

4.2.2.2 Conversão de dados do sensor

A imagem Hyperion é pré-processada pelo *software* ENVI 5.1. Neste processamento, é realizada a conversão dos dados de L1R para o formato padrão do ENVI 5.1. Para isso, é utilizado um *plugin* disponibilizado no site da ITT *Visual Information Solutions*, denominado de Hyperion Tools. Essa ferramenta tem uma opção para o georreferenciamento da imagem a partir de um arquivo do tipo “met”. A correção dos *stripes*, que são linhas verticais onde os pixels apresentam valores errôneos, é feita por meio da interpolação dos valores dos vizinhos horizontais. Também é gerado um arquivo com os fatores de escala para utilização na correção atmosférica.

4.2.2.3 Correção atmosférica

Imagens obtidas por sensores orbitais contêm informações sobre a atmosfera e sobre o alvo de interesse. Para corrigir os efeitos atmosféricos sobre a imagem Landsat 8 Hyperion, optou-se por utilizar o módulo *FLAASH (Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes)* que tem como base o código MODTRAN4, disponível comercialmente no *software* ENVI 5.1.

Das 242 bandas espectrais disponíveis, selecionaram-se apenas aquelas

radiometricamente calibradas (155 bandas), nos canais de 8 a 56 para o VNIR - Visível-Infravermelho-Próximo, e 77 a 220 para o SWIR-Infravermelho de Ondas Curtas, como mostra a Tabela 7.

Tabela 7 – Bandas do sensor Hyperion, e destaque, as bandas ruidosas que foram excluídas para a realização da pesquisa

1	2	3	4	5	6	7	8	9	10	11	12	13	14
15	16	17	18	19	20	21	22	23	24	25	26	27	28
29	30	31	32	33	34	35	36	37	38	39	40	41	42
43	44	45	46	47	48	49	50	51	52	53	54	55	56
57	58	59	60	61	62	63	64	65	66	67	68	69	70
71	72	73	74	75	76	77	78	79	80	81	82	83	84
85	86	87	88	89	90	91	92	93	94	95	96	97	98
99	100	101	102	103	104	105	106	107	108	109	110	111	112
113	114	115	116	117	118	119	120	121	122	123	124	125	126
127	128	129	130	131	132	133	134	135	136	137	138	139	140
141	142	143	144	145	146	147	148	149	150	151	152	153	154
155	156	157	158	159	160	161	162	163	164	165	166	167	168
169	170	171	172	173	174	175	176	177	178	179	180	181	182
183	184	185	186	187	188	189	190	191	192	193	194	195	196
197	198	199	200	201	202	203	204	205	206	207	208	209	210
211	212	213	214	215	216	217	218	219	220	221	222	223	224
225	226	227	228	229	230	231	232	233	234	235	236	237	238
239	240	241	242										

Fonte: USGS 2015.

Com o intuito de melhorar o desempenho da correção atmosférica, a imagem hiperespectral é recortada para definir-se uma área de estudo menor, visando obterem-se estimativas mais precisas dos parâmetros que consideram as características atmosféricas da área de interesse. Em seguida, cria-se um arquivo *ASCII* com valores específicos de fator de escala para cada banda, a fim de compatibilizar as unidades, pois as bandas do SWIR têm como fator de escala o valor 800, enquanto que nas bandas do VNIR, o fator de escala é 400.

O conjunto de parâmetros e especificações do instrumento sensor e de condições de aquisição da imagem que são solicitados pelo modelo *FLAASH* para correções são: latitude e longitude central, elevação média da cena, tipo e altitude do sensor, tamanho do pixel da imagem, data e hora da aquisição da cena, além de alguns parâmetros atmosféricos como modelo atmosférico, modelo de Aerossol, feição de absorção d'água e visibilidade da atmosfera, conforme sumarizado na Tabela 8.

Os modelos atmosféricos e aerossóis são selecionados a partir de modelos padrões

que melhor representariam a região de interesse. O *FLAASH* também inclui um método para obter a quantidade de aerossol e estimar a visibilidade média, usando a reflectância de pixels escuros, baseado em Kaufman *et al.* (1997).

O conteúdo de vapor d'água é estimado pelo modelo que considera os efeitos de absorção da radiação eletromagnética nas bandas posicionadas em 1050-1240 (feição de absorção centrada em 1135 nm). Além dessa feição de absorção, o ENVI 5.1 também estima vapor d'água da atmosfera nas bandas localizadas em 940 e 820 nm.

Tabela 8 - Parâmetros utilizados para efetuar a correção atmosférica

Informações	Característica da cena
Latitude	5 2 6.97
Longitude	-39 30 38.64
Sensor	Hyperion
Altitude do Sensor (km)	705
Grau de elevação (km)	0.210
Pixel (m)	30
Data	19 de outubro 2014
Horário GTM	11:49:09
Modelo Atmosférico	Mid-Latitude Summer
Recuperação de água	Sim
Recurso de absorção de água	1135
Modelo Aerosol	Rural
Recuperação de Aerosol	Nenhum
Visibilidade inicial	40
Polimento espectral	Não
Calibração do comp. de onda	Sim
Órbita	217
Ponto	63

Fonte: USGS (2013).

4.2.2.4 Correção geométrica

O georreferenciamento da imagem é realizado no software ENVI 5.1 utilizando-se doze pontos de controle sobre feições correspondentes entre a imagem Hyperion e uma imagem Landsat 8, que serviu como referência. Para a transformação, é usado o sistema de projeção UTM, datum WGS-84 e zona UTM 24 sul. Após o georreferenciamento, é avaliado o resíduo em unidades de pixel, seguido pela reamostragem dos pixels da cena Hyperion pelo método de vizinho mais próximo.

4.3. Análise do comportamento espectral dos diferentes alvos

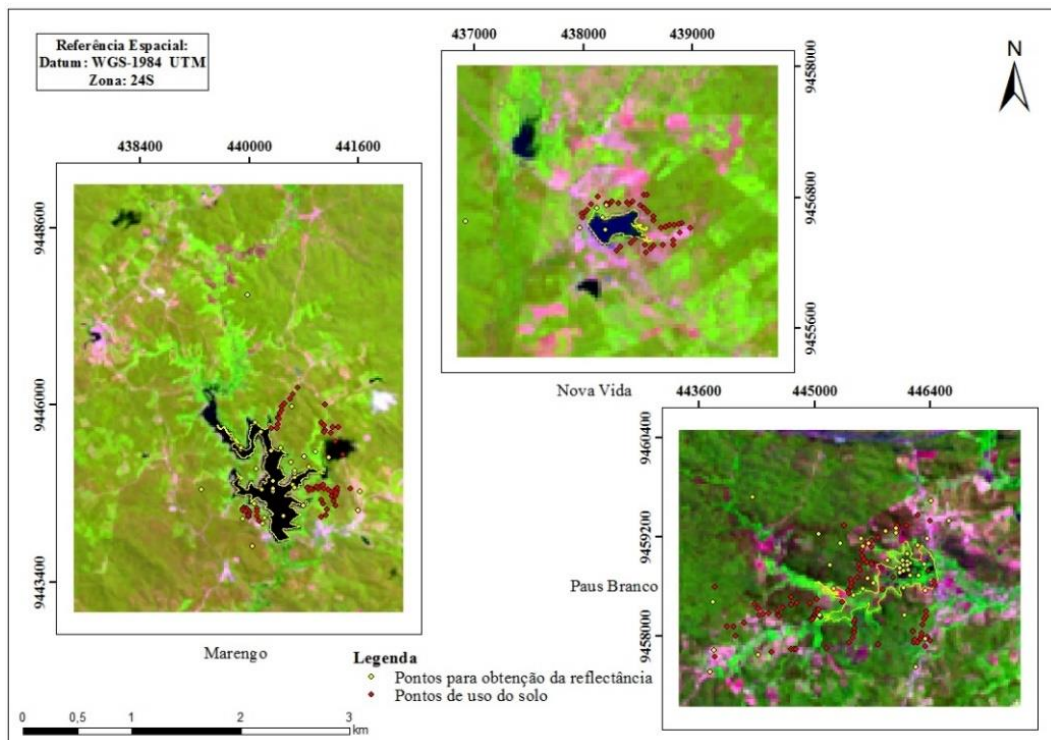
4.3.1 Sensor Landsat 8

De posse dos pontos das classes levantados em campo, foram selecionados 10 pontos (Figura 16) de cada classe (água, macrófitas, solo exposto, vegetação nativa, agricultura, vegetação rala, vazante), totalizando 70 pontos dentre os seiscentos pontos levantados para obtenção das faixas de reflectância de cada uso. Além das classes, buscou-se determinar as faixas de reflectância dos alvos nuvem e sombra, obtidos através da análise da própria imagem Landsat 8.

A escolha dos pontos obedeceu às seguintes condições:

- Serem distribuídos no entorno dos reservatórios avaliados;
- No mínimo um ponto de cada alvo no entorno do reservatório;
- Não estar sob nuvem ou sombra;
- Apresenta-se nas seis imagens consideradas na pesquisa. Como por exemplo o caso das macrófitas que mudou a sua espacialização na maior parte das imagens utilizadas na mesma localidade.

Figura 16 – Espacialização dos pontos para a obtenção das faixas de reflectância. Imagem Landsat 8 de 30/05/2013, composição RGB 6/5/4



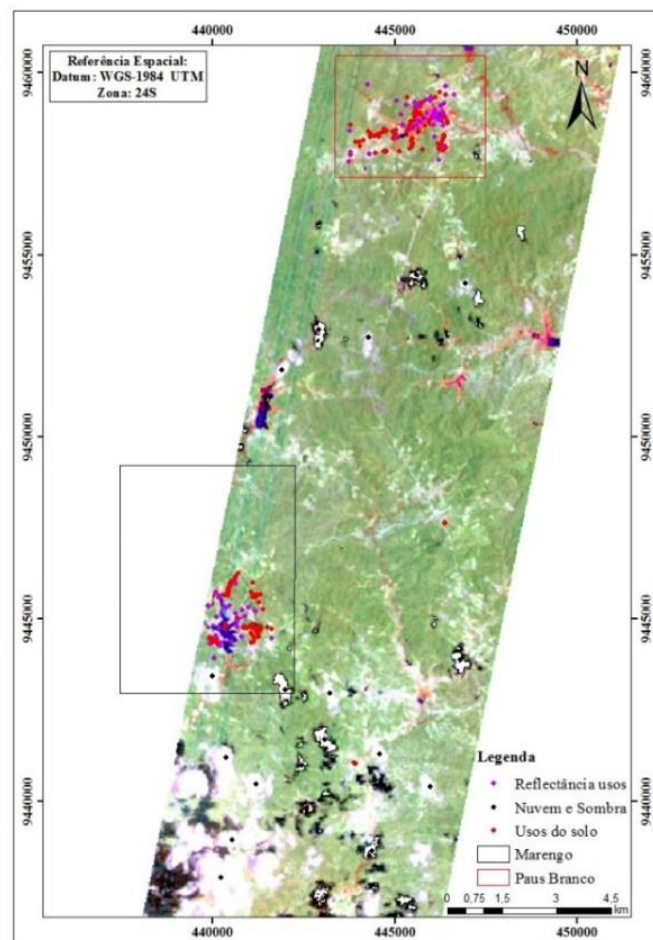
Fonte: Elaborada pelo autor.

4.3.2 Sensor Hyperion

Para o conhecimento das faixas de reflectância das classes existentes no entorno dos reservatórios Paus Brancos e Marengo, foram escolhidos 15 pontos de cada alvo (água, macrófitas, solo exposto, vegetação nativa, agricultura, vegetação rala, vazante, nuvem e sombra) distribuídos por toda área (Figura 17), a fim de se quantificar o intervalo máximo e mínimo da reflectância que cada classe expressa na imagem e ao longo do ano.

Na Figura 17, são ilustrados os pontos utilizados para a análise da reflectância dos alvos, espacializados usando a título de ilustração a composição colorida R – 51; G – 161; B – 19. São utilizados 15 pontos de cada alvo, em que o critério para a seleção dos mesmos é não estar no conjunto de pontos utilizados para a classificação supervisionada.

Figura 17 – Espacialização dos pontos das classes para análise dos valores de reflectância (Composição R – 51; G – 161; B – 19)



Fonte: Elaborada pelo autor.

4.4 Classificação de imagens

4.4.1 Coleta de pontos em campo

A coleta das amostras representativas das classes dos usos do solo, foram obtidas através de levantamento de pontos em torno dos reservatórios Paus Branco, Marengo e Nova Vida. Os pontos foram obtidos com o auxílio de um GPS de navegação Garmin modelo *etrex*, que apresentou 3 metros de precisão absoluta por ponto (Figura 18), coletados em campanha realizada no Assentamento 25 de Maio nos dias 17, 18 e 19 de outubro de 2014.

Figura 18 – Levantamento de pontos com auxílio de GPS de navegação

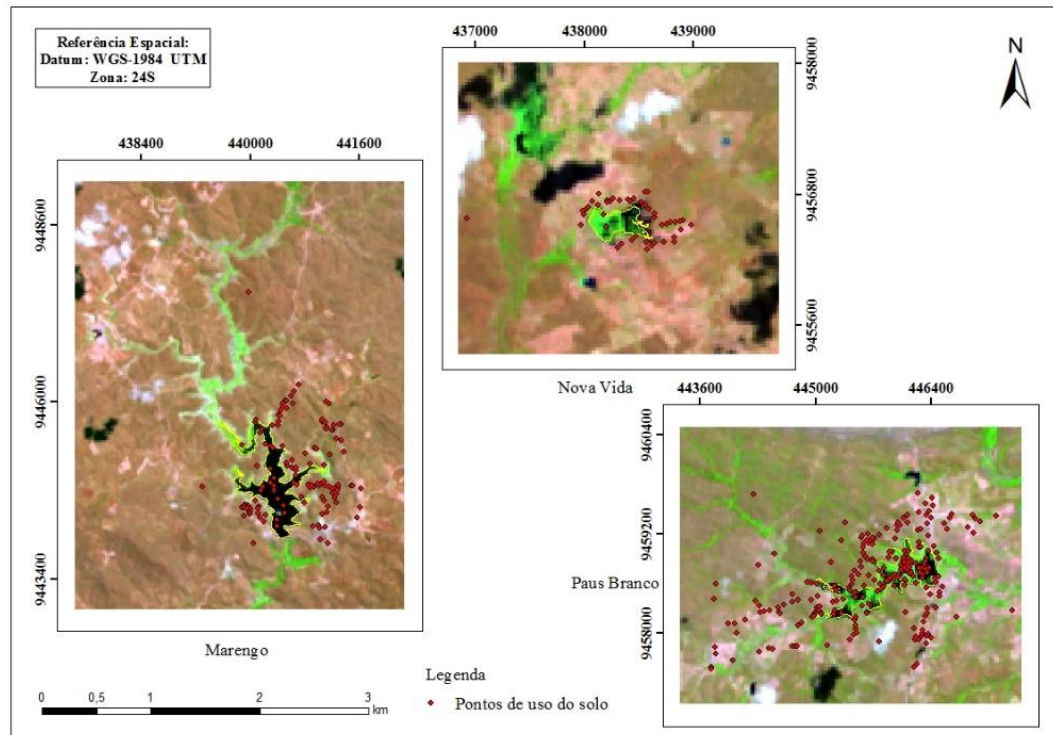


Fonte: Autor.

Na classificação supervisionada, são utilizados algoritmos para nomear os pixels em uma imagem de forma a representar tipos específicos de cobertura terrestre, ou classes que são conhecidas a priori. Na Figura 19 estão ilustrados os pontos das classes levantados em campo, no entorno dos reservatórios Marengo, Paus Brancos e Nova Vida, selecionados através de critérios pré-estabelecidos no processamento para geração do método supervisionado. Os pontos das classes são indispensáveis para o treinamento do classificador supervisionado a ser utilizado na pesquisa, necessitando-se assim o refino e escolha adequada das amostras a serem inseridos no programa de classificação.

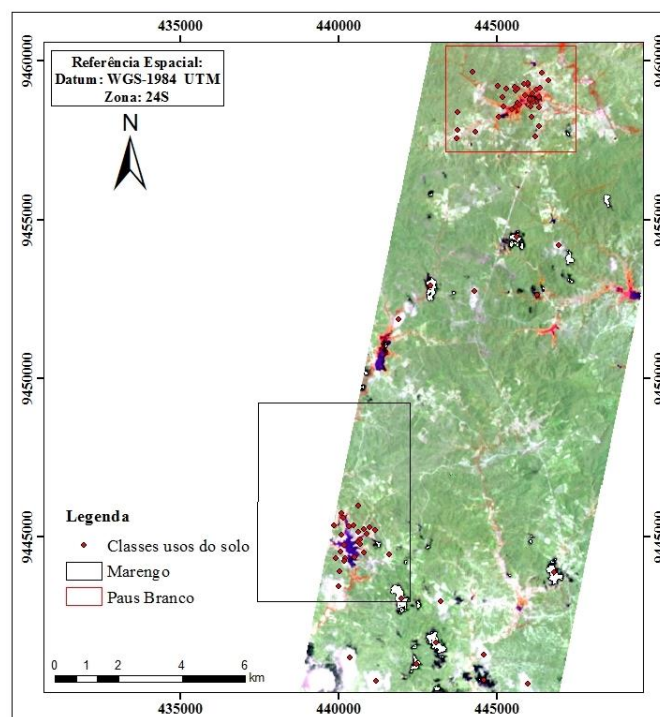
Durante a campanha, são levantados mais de seiscentos pontos (Tabela 9) de diferentes classes no entorno dos reservatórios Paus Branco, Marengo e Nova Vida (Figura 19), o que permitiu uma representação e conhecimento em escala precisa das características existente na área de estudo.

Figura 19 – Pontos das classes levantados no entorno dos reservatórios estudados



Fonte: Elaborada pelo autor.

Figura 20 - Espacialização dos pontos utilizados para a classificação supervisionada (Composição RGB imagem Hyperion)



Fonte: Elaborada pelo autor.

As classes adotados são divididos em sete classes: água (corpos hídricos), macrófitas (vegetação flutuante encontrada dentro dos reservatórios), solo exposto (ausência de vegetação e estradas), vegetação nativa (Caatinga preservada), agricultura, vegetação rala (Vegetação em regeneração ou de pequeno porte) e vazante (agricultura desenvolvida dentro da bacia hidráulica e na margem dos reservatórios e rios do assentamento 25 de Maio), além dos alvos nuvem e sombra de nuvem que comumente apareceram nas imagens.

O quantitativo das classes levantados em campos estar descrito na Tabela 9.

Tabela 9 – Número de pontos por classe levantados em campo

Classe	Quantidade de Pontos
Água	90
Macrófitas	105
Solo exposto	90
Vegetação Nativa	90
Agricultura	90
Vegetação Rala	90
Vazante	90
Total	660

Fonte: Elaborada pelo autor

4.4.2 Seleção de imagens e composição RGB

Para a realização das diversas etapas da pesquisa, foi necessário a organização de um banco de imagens, conforme exposto na Tabela 10. São utilizados diferentes satélites, tanto multiespectral (Landsat 8) como hiperespectral (Hyperion), imagens do Google Earth, além de imagem obtida através de um VANT (Veículo aéreo não tripulado).

De posse das imagens mencionadas, procede-se com sua análise, confrontamento e validação, através de pontos das classes levantados em campo em diferentes períodos do ano e em diferentes anos, como informado na Tabela 9.

Tabela 10 – Banco de dados com as datas e imagens utilizadas para o desenvolvimento de todas as etapas da pesquisa

MÊS	Levantamento pontos de classes	Classificação				Validação			São Nicolau		Paus Brancos	Aplicação
		Landsat 8		Hyperion	Imagem Lavras Da Mangabeira			Pontos das classes	Classificação		Kappa	Água e Macrófitas
		2013	2014	2015	2014	Google	Landsat8		Hyperion	Hyperion	Landsat8	VANT
Jan				28/01								
Fev												
Mar												
Abr												
Mai		30/05										
Jun												
Jul						08/07/09						
Ago	1-03/08/2014		05/08							28/08/15	24/08/15	
Set		03/09	22/09									
Out	17-20/10/2014	21/10			19/10	08/09/13	26/09/10	19/09/15				19/10/14
Nov									18/11/15		11/11/15	
Dez												

Fonte: Elaborada pelo autor

4.4.3 Sensor Landsat 8

Utilizaram-se seis imagens Landsat 8 dos anos 2013, 2014 e 2015. São selecionadas as imagens dos dias 30/05, 3/09, 21/10 de 2013, 05/08 e 22/09 de 2014 e 12/01 de 2015, por terem apresentado baixa cobertura de nuvem, e classificação boa qualidade. É notável uma melhor qualidade e nitidez para imagens do período seco quando comparadas a imagens em estação chuvosa.

As bandas utilizadas para a composição RGB do satélite Landsat 8 para a determinação das classes são as bandas 6, 5 e 4 nessa ordem. Essa composição é conhecida como falsa cor e torna possível a separação tanto de alvos distintos como água e solo exposto e vegetação nativa, como de alvos com índice de reflectâncias semelhantes, como é o caso de macrófitas, vazante e vegetação rala, conforme reportados em pesquisas realizadas por Bhardwaj *et al.*, (2015); Dube e Mutanga (2015).

4.4.4 Sensor Hyperion

Foi utilizada uma imagem do satélite Hyperion, datada essa do dia 19 de outubro de 2014, por ser a única imagem que apresenta qualidade aceitável, já que as demais disponíveis da região do Assentamento 25 de Maio, apresentam elevada cobertura de nuvens.

As bandas utilizadas para a composição RGB do satélite Hyperion para a determinação das classes, são determinadas através do classificador SVM (*Support Vector Machine*), que analisa todas as 155 bandas disponíveis do sensor, identifica quais bandas proporcionam separação das classes de interesse. O processamento é realizado no programa *EndMAP-Box 2.1*, disponível no sítio da Universidade Humboldt, Berlin Alemanha (RABE, *et al.*, 2014; VAN DER LINDEN, *et al.*, 2014).

4.4.5 Classificação não-supervisionada

A primeira técnica adotada é baseada no método de classificação não-supervisionada, aplicada tanto para as imagens Landsat 8 e Hyperion, na qual os elementos de uma cena estão associados a classes espectrais, sem qualquer conhecimento prévio da existência das classes. Neste caso, as classes espectrais são definidas com base no agrupamento de pixels que apresentam similaridade espectral, através da aplicação de métodos de agregamento, utilizando-se medidas de similaridade.

O algoritmo de agrupamento não supervisionado utilizado é o ISODATA (Tabela 11), o que é um classificador que permite um ajuste do número de classes

automaticamente durante as interações por fusão de agrupamentos semelhantes e divisão de classes com elevado desvio padrão (JENSEN, 2009).

Os classificadores e processamentos utilizados na pesquisa e seus respectivos programas está descrito na Tabela 11, apresentada abaixo.

Tabela 11 – Classificadores e processamentos cos respectivos programas utilizados durante as diversas etapas da pesquisa

Classificador	Programa
ISO DATA	Arc Gis 10.2
Máxima Verossimilhança	Arc Gis 10.2
Mínima Distância	Matlab
KNN	Matlab
Random Forest	Matlab
SVM	EndMAP – Box 2.1
Processamento	Programa
NDVI	ENVI 5.1
Delimitação bacias	Arc Gis 10.2
Correção Atmosférica	ENVI 5.1
Correção geométrica	ENVI 5.1
Realce de imagens	Matlab

Fonte: Elaborada pelo autor.

4.4.6 Classificação supervisionada

Em seguida, aplicam-se técnicas de classificação supervisionada para toda a cena imageada pelos sensores Landsat 8 e Hyperion, o que implica na interação do analista com o sistema de análise. Neste procedimento, o analista deve ter um conhecimento prévio da área de estudo, para posteriormente, informar as amostras representativas das classes necessárias para o treinamento de um algoritmo.

A Classificação supervisionada consiste numa família de métodos de imagens que depende de informações provenientes do analista e permite analisar e identificar as diferenças de reflectância nas imagens, e conseqüentemente as feições (classes) presentes na cena. Na classificação supervisionada, são utilizados algoritmos para rotular os pixels em uma imagem de forma a representar tipos específicos de cobertura terrestre, ou classes que são conhecidas a priori.

Desta forma, um conjunto amostral de dados de treinamento contendo exemplos de padrões de todas as classes existentes *in loco* é informado ao classificador para tomar decisões e conceber o mapa com as classes temáticas. Os algoritmos de agrupamento (método classificatório) supervisionado utilizados são os seguintes: Máxima Verossimilhança; Mínima

Distância, KNN e Random Forest

Diversos autores desenvolveram pesquisas relacionadas à quantificação de classes utilizando imagens hiperespectrais com o sensor Hyperion. Alguns citam apenas as faixas dos comprimentos de ondas adotados para realizar a classificação da imagem na obtenção das classes, e não tem se preocupado com utilizar bandas específicas e/ou exatas para a realização da composição RGB, como nos trabalhos realizados por Galvão *et al.* (2005); Schramm e Vibrans (2007); Tisot *et al.* (2007); White *et al.* (2010); Xie *et al.* (2011); Jafari e Lewis (2012).

4.4.6.1 Classificador de Máximo Verossimilhança

Segundo Moreira (2011), na formulação estatística do problema, assume-se uma densidade de probabilidade condicional $P(x/w_j)$, em que x é o conjunto de valores dos dados, nas diversas características, e w_j representa uma dada classe. Esta densidade de probabilidade condicional define a característica da classe.

Dado um objeto x_o , pode-se utilizar como regra de decisão a atribuição de x_o a uma classe w_j , cuja probabilidade condicional $P(w_j/x_o)$ é máxima. Pela regra de Bayes tem-se então (Equação 7) (MOREIRA, 2011):

$$P(\omega_j / x) = \frac{P(\omega_j)P(x / \omega_j)}{P(x)} \quad (11)$$

Em que:

$P(x/w_j)$ é a função densidade de probabilidade condicional referida à classe w_j ;

$P(x)$ é a probabilidade de ocorrência de cada amostra;

$P(w_j/x)$ e $P(w_j)$ são as probabilidades da classe w_j , condicionada e incondicionada aos valores das características, respectivamente.

Para proceder ao cálculo de $P(w_j/x)$ de forma simplificada, é possível calcular somente $P(x/w_j)P(w_j)$, pois $P(x)$ é o denominador de todas as classes. A quantidade $P(x/w_j)$, que é uma densidade de probabilidade, é chamada verossimilhança de w_j em relação a x . Dessa maneira, uma regra de decisão simplificada é classificar o objeto x_o como pertencente à classe w_j de maior valor de $P(x_o/w_j)$, ou seja, de máxima verossimilhança.

Uma vez que o classificador Máxima Verossimilhança considera a distribuição espectral das classes como sendo uma distribuição normal, a probabilidade da distribuição normal multidimensional é dada pela equação abaixo (MOREIRA, 2011):

$$P(x) = \frac{1}{(2\pi)^{n/2} |C|^{1/2}} \exp\left[-\frac{1}{2}(x-m)C^{-1}(x-m)^T\right] \quad (12)$$

Sendo x um vetor n -dimensional; m o vetor de componentes médias (também n -dimensional); C uma matriz quadrada $n \times n$, chamada matriz de covariância; $|C|$ o determinante de C e C^{-1} sua inversa.

A distribuição normal multivariada estará completamente especificada se forem determinados o vetor de componentes médias m e a matriz de covariância C .

4.4.6.2 Classificador de Mínima distância

O classificador de mínima distância tem como regra de decisão a distância mínima entre o vetor de componentes RGB do pixel que se deseja classificar e os vetores com valores médios de componentes RGB das classes espectrais contidas na área de estudo. Segundo Moreira (2011), considerando um espaço n -dimensional, o cálculo é feito por:

$$d(x, m/w) = \sqrt{\sum_{i=1}^n (x_i - m_i)^2} \quad (13)$$


Em que:

$d(x, m/w)$ é a distância mínima (euclidiana) entre o pixel x e o centroide da classe w ;

x_i e m_i são, respectivamente, as componentes do vetor x , que fornecem a posição do ponto no espaço de atributos, e do centroide da classe w ;

n , a dimensão do espaço de atributos (número de bandas espectrais).

Figura 21 - Classificador de mínima distância



Fonte: Meneses e Sano (2012).

O treinamento busca caracterizar cada pixel de forma que as distâncias entre os atributos dos pixels de um agrupamento sejam mínimas, e entre agrupamentos. Assim, é equivalente afirmar que o critério para se realizar o agrupamento dos dados em torno das classes é o de minimizar a soma dos erros quadráticos (MOREIRA, 2011). A Figura 21 ilustra o classificador de mínima distância. As linhas cheias indicam as medidas da distância mínima para um pixel candidato às classes.

4.4.6.3 Classificador de KNN

KNN é um classificador cujo aprendizado é feito de forma supervisionada. É uma metodologia de classificação que consiste na identificação de grupos de indivíduos com características similares e seu posterior agrupamento.

O conjunto de treinamento é formado por vetores n-dimensionais e cada elemento deste conjunto representa um ponto no espaço n-dimensional. Para determinar a classe de um elemento que não pertença ao conjunto de treinamento, o classificador KNN procura K elementos do conjunto de treinamento que estejam mais próximos deste desconhecido elemento, ou seja, que tenham a menor distância. Estes K elementos são chamados de K-vizinhos mais próximos. Determinam-se as classes desses K vizinhos e a classe mais frequente será atribuída à classe do elemento desconhecido. O método KNN é muito utilizado em aplicações envolvendo a tarefa de classificação, como método de mineração de dados (GOLDSCHMIDT; PASSOS, 2005).

A métrica mais comum no cálculo de distância entre dois pontos é a distância Euclidiana cuja definição é:

Seja $X = (x_1, x_2, \dots, x_n)$ e $Y = (y_1, y_2, \dots, y_n)$ dois pontos do R^n .

A distância Euclidiana entre X e Y é dada por:

$$d(x, y) = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_n - y_n)^2} \quad (14)$$

O KNN é um classificador que possui apenas um parâmetro livre, que é o número de K-vizinhos, de busca controlado pelo analista (pesquisadores) com o objetivo avaliar os resultados da classificação. Este processo pode ser computacionalmente exaustivo se

considerado um conjunto com elevado quantitativo de dados. Para determinadas aplicações o processo é bem aceitável, com resultados condizentes com a realidade.

4.4.6.4 Random Forest

Random Forest (em português, Floresta Aleatória) é uma técnica de classificação e regressão desenvolvida por Breiman (2001), que consiste num conjunto de árvores de decisão combinadas para solucionar problemas de classificação. Cada árvore de decisão é construída utilizando-se uma amostra aleatória inicial dos dados e, a cada divisão desses dados, um subconjunto aleatório de m atributos é utilizado. No final, Random Forest gera uma lista dos atributos mais importantes no desenvolvimento da floresta, que são determinados pela importância acumulada do atributo nas divisões dos nós de cada árvore da floresta (JAMES *et al.*, 2013). Os principais passos do algoritmo Random Forest podem ser vistos na Figura 22.

Figura 22 - Algoritmo básico da técnica Random Forest

Dado um conjunto de dados $X = x_1, x_2, \dots, x_j$ e $Y = y_1, y_2, \dots, y_k$.

Para $b = 1, 2, 3, \dots, B$, repita:

- (a) Cria uma amostra *bootstrap* (X_b, Y_b) com n exemplos de (X, Y) .
- (b) Ajusta uma árvore de decisão f^b para o conjunto de treinamento (X_b, Y_b) , utilizando m atributos para a escolha de cada nó.

Fim de repetição.

Gera o modelo final: $\hat{f}(x) = \sum_{b=1}^B f^b(x)$, que calcula os votos obtidos por cada modelo f^b , resultando uma classificação final de acordo com a votação majoritária.

Fonte: Breiman (2001).

De forma geral, uma árvore de decisão é um modelo gráfico representado por nós e ramos, em que os nós intermediários, ou decisórios, representam os testes de atributos, enquanto os ramos representam os resultados desses testes. O nó localizado no topo da árvore representa seu início e é denominado nó-raiz. Já o nó externo, que não possui um nó descendente, localizado na extremidade inferior, é denominado folha ou terminal, e representa o valor de predição do atributo-meta ou classe (HAN *et al.*, 2011).

4.4.6.5 SVM – Support Vector Machine

Para a classificação, são coletadas amostras das classes, e em seguida são processadas as imagens no programa EndMAP-Box 2.1, disponível no sítio da Universidade

Humboldt, Berlin Alemanha (RABE, *et. al.*, 2014; VAN DER LINDEN, *et al.*, 2014), para ajuste e obtenção de todos os parâmetros e atributos. No algoritmo Suport Vector Machine, determina limites de decisão para a separação das classes bem como a minimização dos erros (MOUNTRAKIS; JUNGHOIM, 2010). Os valores *gama* e parâmetro de penalidade são 0,03 e 100,00, valores sugeridos pelo programa, após a calibração realizada baseado nos pontos informados.

4.5 Determinação do NDVI

O NDVI (*Normalized Difference Vegetation Index*) ou IVDN (Índice de Vegetação da Diferença Normalizada), proposto por Rouse *et al.*, (1973), é um índice utilizado principalmente em pesquisas de cunho ambiental, pois permite fazer análises sobre a cobertura vegetal de determinada região em diversas escalas. Tratando-se de pesquisas utilizando imagens de satélite, o NDVI é um índice muito utilizado, pois reduz o efeito topográfico e apresenta uma escala de medida linear variando entre -1 e 1.

O Índice de Vegetação da Diferença Normalizada (NDVI) é obtido pela razão entre a diferença da reflectância do infravermelho próximo (NIR) e a reflectância do vermelho (R), soma das mesmas, conforme a expressão:

$$NDVI = \frac{NIR - R}{NIR + R} \quad (15)$$

Através de uma relação logarítmica com o NDVI, pode ser determinada a emissividade de superfície. Através da correção dos efeitos da emissividade de superfície, a reflectância na banda termal pode ser transformada em valores instantâneos de temperatura da superfície. Isso reforça a necessidade de se obter valores de reflectância e o NDVI.

Para realizar o processamento digital das imagens e álgebra de mapas (NDVI e SAVI), é utilizado o *software* ENVI 5.1, específico para Processamento Digital de Imagens (PDI). Para procedimentos que necessitam de uma plataforma de Sistema de Informação Geográfica (PETROPOULOS *et al.*, 2012), é utilizado o *software* ArcGis 10.3, que possibilita a determinação dos valores de NDVI.

4.6 Aplicações de transformação de contraste (*contrast-stretching*)

Buscando-se a obtenção de melhores resultados na classificação não-supervisionada, é utilizada ferramentas computacionais para a aplicações de transformação de contraste (*contrast-stretching*) nas imagens do Landsat 8. A tentativa de melhorar esse método classificatório pode ser justificada pelo fato de que, em algumas situações, não estão disponíveis dados de classes impossibilitando assim o processamento de imagens de satélite através da classificação supervisionada. Nesta situação a classificação não-supervisionada permitia o conhecimento prévio das classes existentes na região estudada, servindo como mapa base para a obtenção de informações mais precisas da área.

Seja cada pixel de uma imagem original com intensidade r . A transformada *contrast-stretching* realiza o seguinte processamento:


$$s = T(r) = \frac{1}{1 + (m/r)^E}, \quad (16)$$

Em que s representa o valor da intensidade do pixel correspondente na imagem de saída, E controla a inclinação da função e m representa um dado valor de intensidade (parâmetro de entrada) localizado entre o valor mínimo e máximo Figura 23 e 24.

Assim, os parâmetros de entrada da transformada são m e E , assumindo-se as seguintes configurações: $m = 0,5$ e $E = 0,9$ (Figura 23) e $m = 0,5$ e $E = 2$ (Figura 24)


$$m = - 0,5 \text{ e } E = 0,9 \quad (17)$$

Figura 23 – Tratamento M1 ($m = - 0,5$ e $E = 0,9$)



Fonte: Elaborada pelo autor.

$$m2 - 0,5 \text{ e } E - 2 \quad (18)$$

Figura 24 – Tratamento M2 ($m_2 = 0,5$ e $E = 2$)

Fonte: Elaborada pelo autor.

4.7 Avaliação do desempenho dos classificadores de imagens

A avaliação da exatidão do mapeamento em relação à verdade terrestre foi realizada por meio da geração de pontos aleatórios no mapa para posterior confirmação em campo. Após a confirmação das classes para cada ponto amostrado, cria-se um arquivo de valores relacionando os pontos amostrais com a verdade terrestre. Por seguinte, é gerada uma imagem *raster* (mapa do tipo matriz) dos pontos amostrais, para então, efetuar-se a análise estatística da classificação não-supervisionada ou supervisionada.

O modelo chamado de Kappa é um método estatístico que permite analisar de forma comparativa os resultados das análises dos mapas obtidos por meio do sensoriamento remoto, dentro de certo limite (LANDIS; KOCH, 1977; MOREIRA, 2001).

A avaliação da exatidão do mapeamento é realizada através do coeficiente Kappa (LANDIS; KOCH, 1977; MOREIRA, 2001; PIROLI, 2010;), conforme detalhado na equação 15. Para a classificação não-supervisionada e supervisionada, é fornecida uma matriz de erros e o índice de Kappa geral e por categoria. Ainda segundo Piroli (2010), nesta matriz de erro, o erro de omissão definição imperfeita da classificada e o erro de inclusão delimitação excessiva de categoria no terreno.

$$k = \frac{P_0 - P_c}{1 - P_c} \quad (19)$$

Em que:

k é o Coeficiente de concordância de Kappa;

P_0 é a concordância observada;

P_c é a proporção de concordância ao acaso.

A estatística do índice Kappa é um método de validação de mapas que tem como objetivo mensurar a qualidade de um mapa temático produzido pela classificação de uma imagem de satélite, tendo como referência outro mapa temático. São seis as classes da estatística Kappa para determinar a qualidade dos mapas (Tabela 12).

Tabela 12 - Qualidade da classificação associada aos valores da estatística Kappa

Valor de Kappa	Qualidade do mapa temático
< 0,00	Péssima
0,00 – 0,20	Ruim
0,20 – 0,40	Razoável
0,40 – 0,60	Boa
0,60 – 0,80	Muito boa
0,80 – 1,00	Excelente

Fonte: Landis e Koch (1977).

O cálculo do Kappa individual desenvolvido na pesquisa permite a análise de cada uso, proporcionando o entendimento da influência da sazonalidade e das mudanças das classes no decorrer do ano, podendo assim gerar uma melhor compreensão da representação do uso do solo através de imagens de satélites. O cálculo dessa variável está descrito nas equações 16, 17 e 18.

$$k - individual = \frac{P_{oi} - P_{ci}}{1 - P_{ci}} \quad (20)$$

Em que:

k-condicional é o Coeficiente de concordância de Kappa individual;

P_{oi} é a concordância observada;

P_{ci} é a proporção de concordância ao acaso.

$$P_{oi} = \frac{N}{P} \quad (21)$$

Em que:

P_{oi} é a concordância observada;

N é o número de acertos do uso na diagonal principal;

P é o total de pontos do uso obtido em campo.

$$P_{ci} = \sum C / 100 \quad (22)$$

Em que:

P_{ci} é a proporção de concordância ao acaso;

$\sum C$ é o somatório da coluna do uso na matriz confusão.

4.8 Análise de desempenho das classificações de imagens Landsat 8 e Hyperion

4.8.1 Aplicação para reservatórios do Assentamento 25 de Maio usando dados de VANT

Para a validação das classes, foi adotado o procedimento de levantamento de pontos das diferentes classes no entorno do reservatório São Nicolau, também localizado no Assentamento 25 de Maio, localizado ao sul do reservatório Paus Brancos e ao norte do Marengo. Os pontos foram obtidos em campanha realizada nos dias 16, 17 e 19 de novembro de 2015.

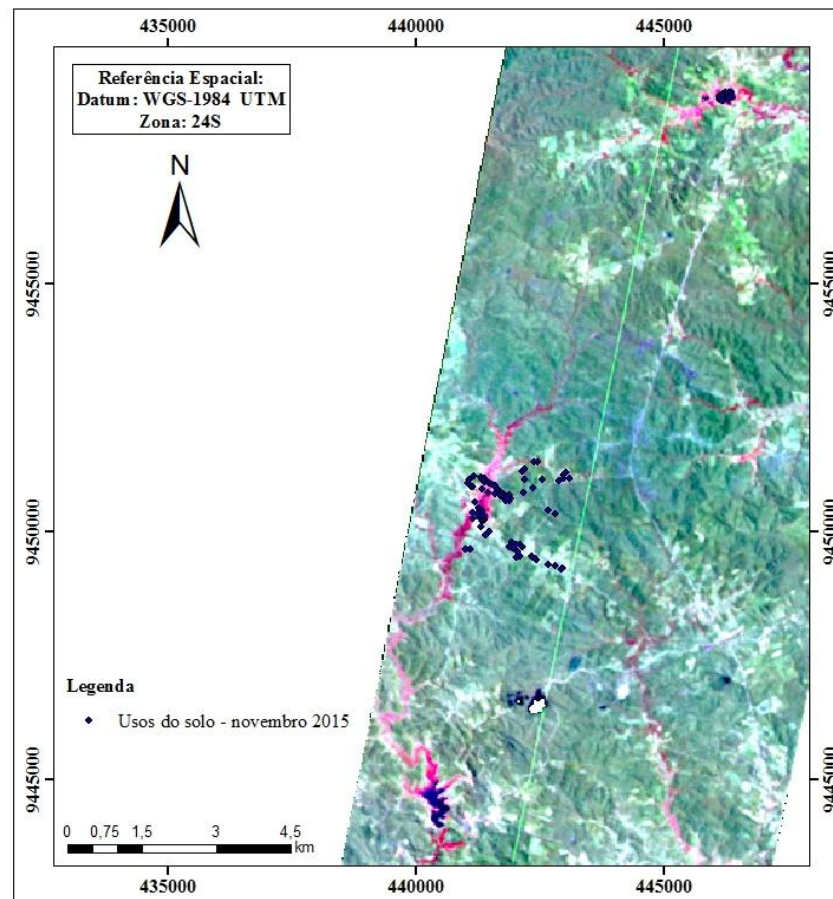
Durante a campanha, foram identificados no entorno do reservatório São Nicolau, seis classes (água, solo exposto, vegetação nativa, agricultura, vegetação rala e vazante) e foram levantados mais de duzentos pontos das classes comentados, durante o período de realização das coletas de dados. Como não foram detectadas macrófitas neste reservatório, os pontos usados na classificação foram obtidos em levantamento realizado no açude Paus Brancos na mesma campanha em novembro de 2015.

O processo de validação das classes, seguiu com a adoção de duas imagens, uma do satélite multiespectral Landsat 8 e outra do satélite hipespectral Hyperion. As duas imagens foram obtidas no mês de agosto de 2015, sendo a Landsat 8 obtida no dia 24 e a do satélite Hyperion no dia 28.

De posse dos pontos das classes, os mesmos foram espacializados sobre a imagem Landsat 8 e Hyperion, onde foram excluídos os pontos que estivessem sob nuvem ou sobra de nuvem em alguma das duas imagens.

A eficiência da classificação de imagens tanto Landsat 8 como Hyperion, para determinação das classes, foi avaliada através do índice de Kappa, sendo que, os pontos para a determinação desse índice, foram obtidos através de imagem produto de um voo realizado com um VANT (Veículo aéreo não tripulado) no dia 11 de novembro de 2015.

Figura 25 – Espacialização de pontos levantados em novembro de 2015, no entorno do reservatório São Nicolau para validação da classificação das imagens Landsat 8 e Hyperion



Fonte: Elaborada pelo autor.

A imagem aérea foi obtida por um VANT tipo quadricóptero, modelo *DJI Phantom FC-40* (Figura 26) controlado remotamente para espacialização das classes. O modelo utilizado possui uma câmera acoplada e realiza captura de imagens com resolução de 1280 x 720 pixels, com precisão espacial de 50 centímetros. A imagem capturada foi utilizada para a validação do mapeamento das classes obtidas através da classificação das imagens de satélite Landsat 8 e Hyperion. O voo foi conduzido pelo pesquisador alemão Till Francke, participante do projeto SERAS-PROBAL.

Para o cálculo do índice de Kappa foram utilizados 20 pontos de cada classe, sendo que a imagem obtida pelo VANT foi de pequena abrangência, devido o fator limitante bateria do equipamento, que não permitiu a obtenção de imagem de maior abrangência, o que não contemplou áreas de vegetação nativa e de agricultura, sendo levado em consideração apenas 5 classes, totalizando 100 pontos utilizados para a determinação do índice de Kappa. A imagem

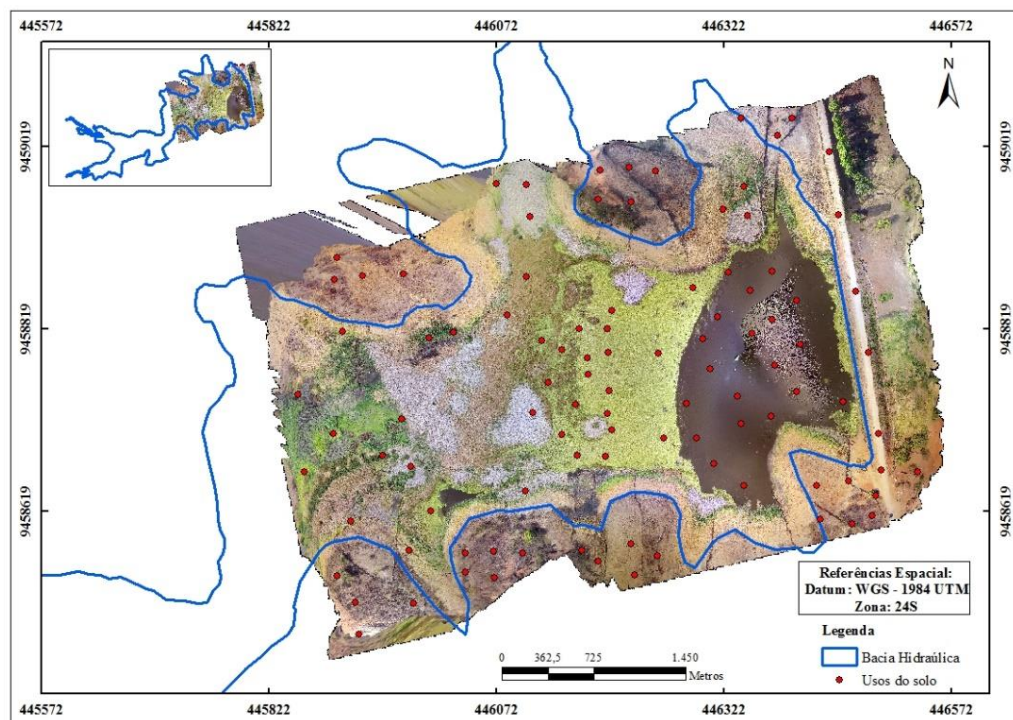
obtida através do voo sobre o reservatório Paus Brancos pode ser visualizada na Figura 27. As classes nuvem e sombra de nuvem, por sua vez, não foram caracterizados nesta aplicação, já que o imageamento usando o VANT voa em baixas altitudes e, assim, não detecta estes alvos.

Figura 26 – Modelo do VANT FC-40 utilizado na obtenção de imagens



Fonte: Autor.

Figura 27 – Imagem do reservatório Paus Brancos obtido através do VANT para validação da classificação das imagens Landsat 8 e Hyperion



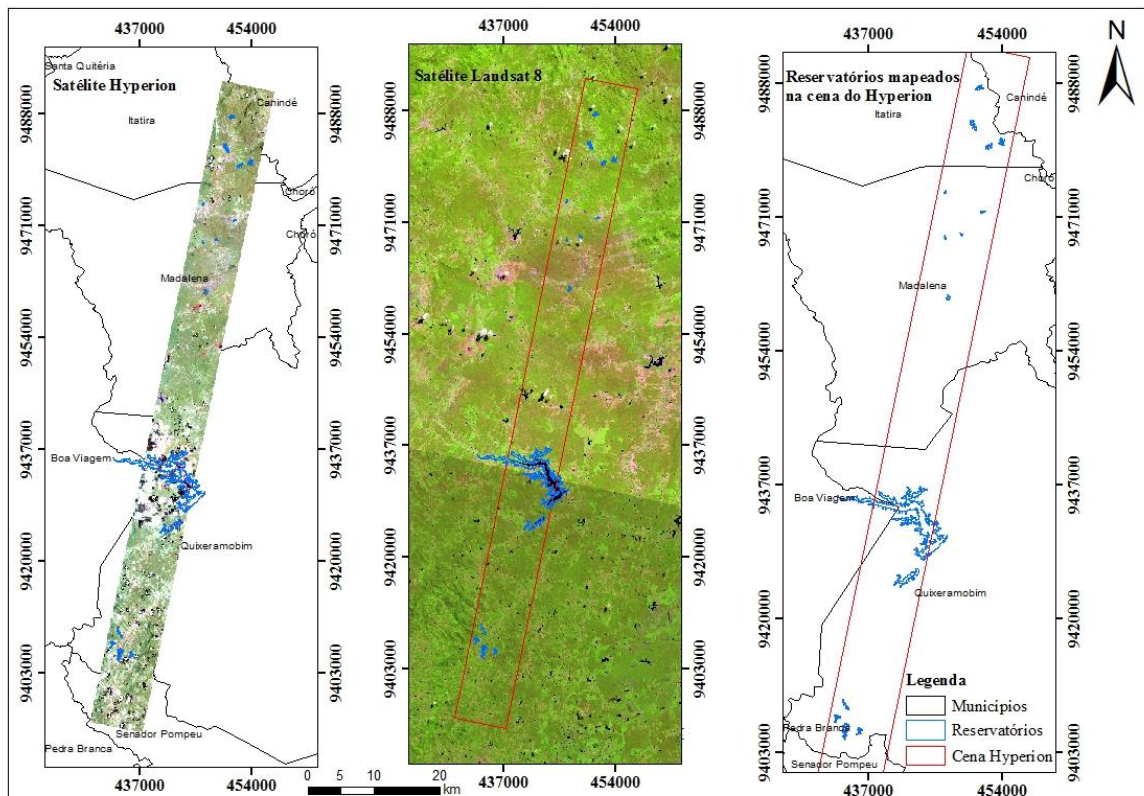
Fonte: Elaborada pelo autor.

4.8.2 Aplicação para os reservatórios da cena do sensor Hyperion que cobre o Assentamento 25 de Maio

Buscando mostrar a veracidade dos resultados obtidos através das classificações de imagens Landsat 8 e Hyperion utilizadas na pesquisa, pensou-se numa maneira de validar os dados, para apresentar de forma quantitativa a eficiência dos classificadores. A ideia foi estimar a área efetiva do espelho d'água (área de corpo hídrico aparente somada à área ocupada por macrófitas) de reservatórios através da classificação supervisionada tanto de imagem multiespectral (Landsat 8) como de imagem hiperespectral (Hyperion).

Na etapa de desenvolvimento da validação foram utilizadas as imagens: Landsat 8 de setembro de 2014 e Hyperion 19 de outubro de 2014, onde as mesmas foram classificadas pelo método supervisionado Máxima Verossimilhança. A área adotada para a validação dos dados foi toda a cena de abrangência do satélite Hyperion, de 7,7 km de largura e 185 km de comprimento e uma área real aproximada de 796 km² (desconsiderando a área de background da cena), como pode ser visualizado na Figura 28.

Figura 28 - Área definida pela cena do satélite Hyperion, órbita 217, ponto 63 selecionada para validação do método de classificação supervisionada



Fonte: Elaborada pelo autor.

Para obtenção do número exato de reservatórios e das respectivas áreas máximas do contorno, utilizou-se uma imagem Landsat 5 de 24 de julho de 2004, já que esse ano apresentou um regime pluviométrico bem superior à média histórica, gerando recarga suficiente para atingir a capacidade de armazenamento da maioria dos reservatórios do Estado. De posse da imagem Landsat 5, foram espacializados todos os reservatórios que apresentavam interseção com a cena do sensor Hyperion, sem cobertura de nuvem ou sombra de nuvem.

Para a análise do desempenho dos métodos de classificação de imagens na estimativa da área efetiva do espelho d'água, utilizaram-se contornos dos reservatórios medidos em campo ou baseados em imagens do Google Earth QuickBird (alta resolução espacial, que é de 1 metro) e composição RGB dos sensores Landsat 8 (bandas 6, 5 e 4) e Hyperion (bandas 51, 161 e 19).

Para a obtenção do nível de correlação entre a área do espelho d'água do reservatório medido e a área do espelho d'água do reservatório obtido na classificação supervisionada, utilizou-se o método de Nash-Sutcliffe (1970), descrito abaixo.

$$\text{Coeficiente Nash-Sutcliffe} = 1 - \frac{\sum(Y - X)^2}{\sum(Y - \bar{Y})^2} \quad (23)$$

Y – Área do espelho d'água do reservatório estimado com a imagem do google Earth;

X – Área do espelho d'água do reservatório obtido na classificação supervisionada;

\bar{Y} – Média do espelho d'água do reservatório obtido na classificação supervisionada.

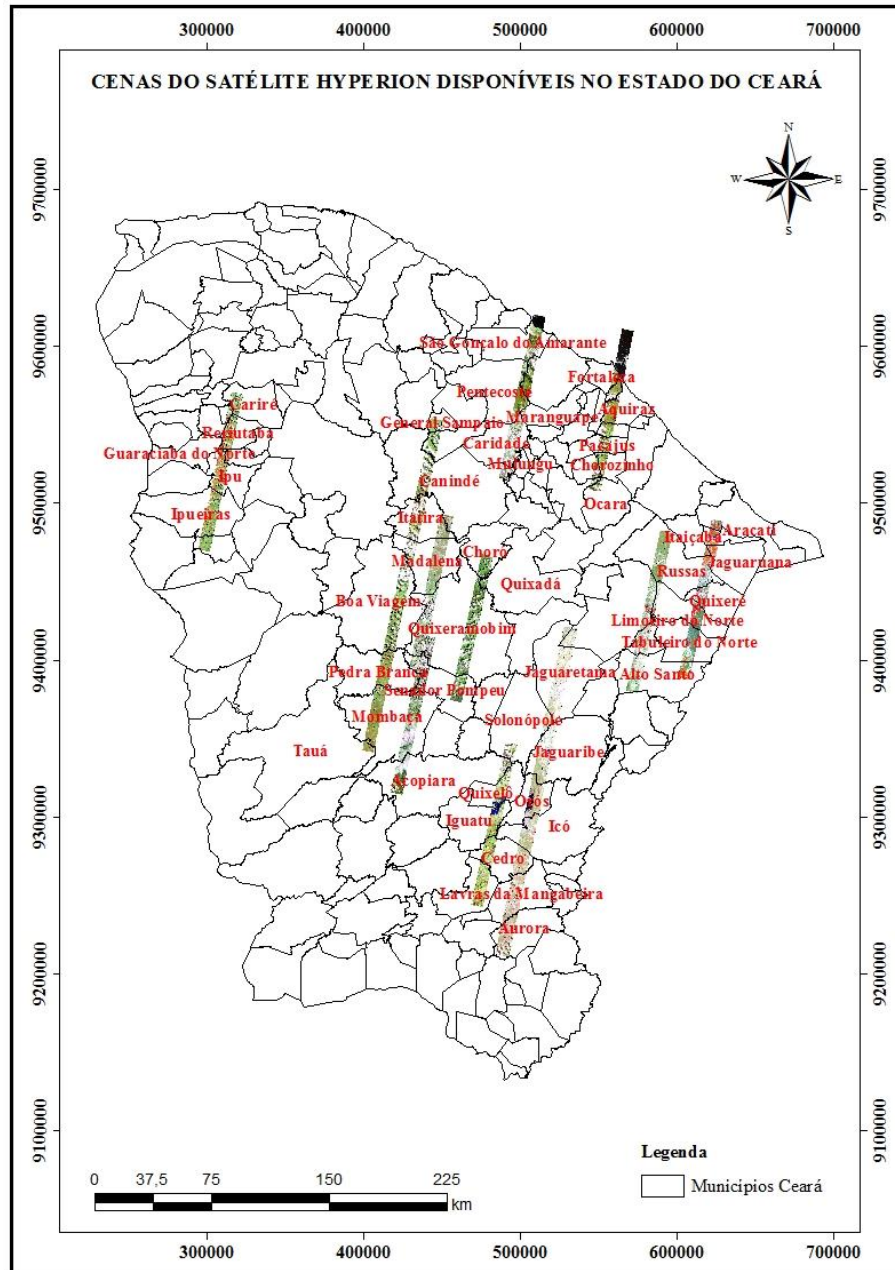
4.8.3 Aplicação para reservatórios do Estado do Ceará

Com o intuito de realizar uma análise comparativa do desempenho de classificações de imagens Landsat 8 e Hyperion na identificação de alvos no Estado do Ceará, investigou-se a disponibilidade de imagens destes sensores no sítio da USGS de boa qualidade e períodos equivalentes. A Figura 29 destaca um conjunto de cenas do sensor Hyperion distribuídas no Estado do Ceará.

O estado do Ceará tem uma área de 148.838 km², onde estão disponíveis apenas 11 cenas do satélite Hyperion, que cobrem uma área de 10.798 km², o que corresponde apenas 7,25% de cobertura do território cearense, tornando assim um fator limitante o uso das imagens desse satélite em determinadas pesquisas que exija uma certa periodicidade, visto que, além de existirem apenas onze cenas para todo o estado do Ceará, e boa parte das cenas apresentam apenas poucas imagens disponíveis, sendo esse um fator limitante para a adoção desse satélite

em algumas pesquisas que necessitem de cobertura de imagens ao longo de anos, para avaliar as mudanças no ambiente.

Figura 29 – Cenas do satélite Hyperion no estado do Ceará, disponíveis no site da USGS



Fonte: Elaborada pelo autor.

Já o satélite Landsat 8 (também disponível no site da USGS) tem-se cem por cento de cobertura do estado do Ceará, além disso fornece uma nova imagem a cada dezesseis dias, mostrando que esse satélite pode ser aplicado em pesquisas que necessitem de periodicidade de imagens na análise de ambientes ou na mudança da natureza provocadas por algum fator, seja

ele antrópico ou natural, permitindo o desenvolvimento de pesquisas continuadas.

Durante a etapa da seleção de imagens, observou-se a dificuldade de se trabalhar com imagens Hyperion, devido à escassez de dados dos mesmos. Nas onze cenas existentes no estado do Ceará, conseguiu-se obter 40 imagens (Tabela 13), sendo que, apenas 8 imagens foram classificadas como boas, ou seja, sem uma alta cobertura de nuvens, ou seja, aptas a serem utilizadas na aplicação.

Tabela 13 – Imagens do satélite Hyperion, disponível no site da USGS

CENA	CENA	DATA	QUALIDADE	RESERVATÓRIOS MACRÓFITAS	GOOGLE EARTH
1	Limoeiro do Norte	27/12/2002	Ruim	0	-
		28/01/2003	Ruim		-
		17/03/2003	Ruim		-
		06/05/2004	Ruim		-
		13/10/2004	<u>Boa</u>		-
2	Russas	15/06/2014	Ruim	0	-
		01/07/2014	<u>Boa</u>		-
		26/01/2015	Ruim		-
		22/02/2015	Ruim		-
<u>3</u>	<u>Lavras da Mangabeira</u>	08/08/2010	Ruim	2	-
		<u>26/09/2010</u>	<u>Boa</u>	<u>2</u>	<u>08/07/2009</u>
4	Orós	11/12/2009	<u>Boa</u>	0	-
		16/02/2010	Ruim		-
5	Aquiraz	17/05/2012	Ruim	1	-
6	Caucaia	26/07/2015	Ruim	0	-
7	Quixeramobim	18/12/2002	Ruim	2	-
		04/02/2003	Ruim		-
		23/02/2004	Ruim		-
8	Canindé	07/06/2012	<u>Boa</u>	1	-
9	Mombaça	30/07/2003	Ruim	1	-
		02/10/2003	Ruim		-
		01/08/2004	Ruim		-
		22/10/2006	Ruim		-
10	Guaraciaba	25/10/2003	Ruim	0	-
		18/04/2004	Ruim		-
		24/08/2004	<u>Boa</u>		-
		09/09/2004	Ruim		-
11	Madalena	11/10/2014	Ruim	5	09/06/2010
		19/10/2014	<u>Boa</u>		30/10/2010
		25/11/20014	Ruim		19/09/2011
		01/12/2014	Ruim		08/10/2011
		03/12/2014	Ruim		
		09/02/2015	Ruim		
		13/03/2015	Ruim		
		22/05/2015	Ruim		
		30/05/2015	Ruim		
		26/06/2015	Ruim		
		28/08/2015	<u>Boa</u>		
		09/11/2015	Ruim		15/10/2015
		13/11/2016	Ruim		

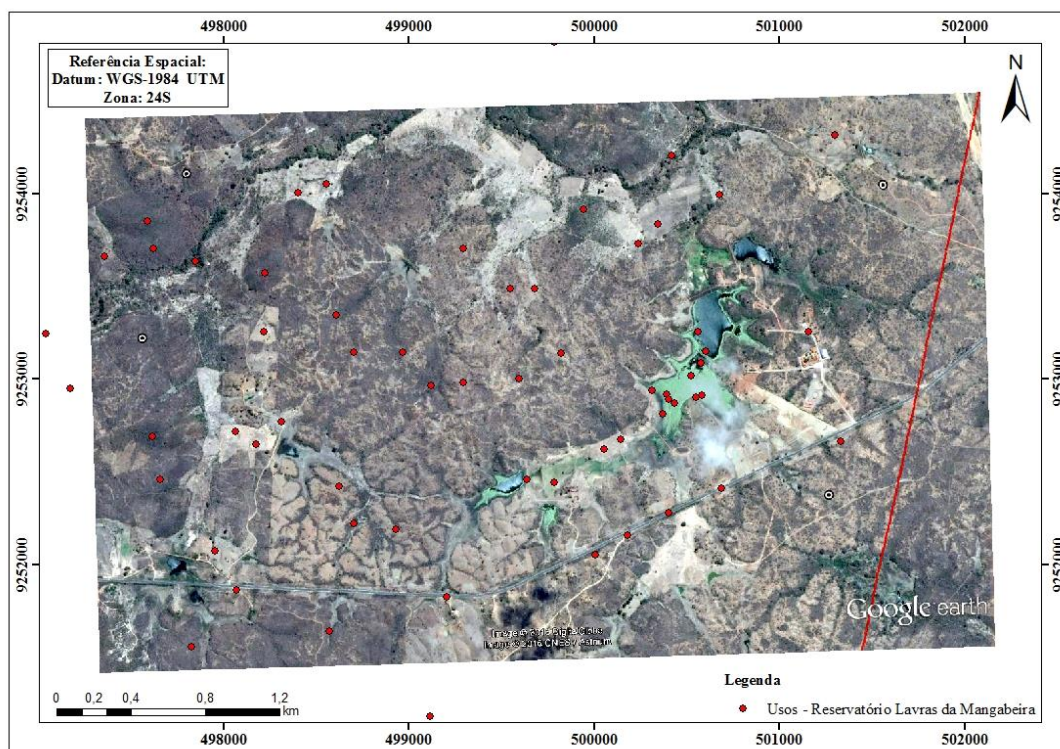
Fonte: Elaborada pelo autor.

O critério de escolha de qual imagem iria ser utilizada dentre as 8 imagens Hyperion consideradas boas, foi a existência de reservatórios com a presença de macrófitas. Dentre as onze cenas foram localizados 14 reservatórios com presença de macrófitas, sendo que, apenas três reservatórios estavam possibilitados, devido a presença de nuvens ou sombra de nuvem nos demais. Foram encontrados dois reservatórios na cena de Lavras da Mangabeiras, sendo um na cidade de Lavras e outro na cidade de Jaguaretama, já o terceiro reservatório mapeado foi na cena de Canindé como pode ser observado na Tabela 13.

O reservatório localizado na cidade de Jaguaretama foi descartado da análise, devido à presença de nuvem sobre o espelho d'água na imagem, sendo impossibilitado a obtenção das classes existentes abaixo da nuvem.

Para a obtenção de pontos das classes, que possibilitasse a obtenção da classificação supervisionada, foram utilizadas imagens Google Earth (próximo ao período da imagem Hyperion) que possuem resolução espacial variando de 0,50 a 1 m, dependendo da região. Imagens de resolução espacial altas como as QuickBird, disponíveis no Google Earth (Figura 30), podem ser usadas para fins de avaliação de precisão (ESTOQUE *et al.*, 2012; DU *et al.*, 2014).

Figura 30 – Imagem do Google Earth do dia 08/07/2009, do reservatório localizado em Lavras da Mangabeira – CE



Fonte: Elaborada pelo autor.

O reservatório localizado na cidade de Canindé também foi descartado por não apresentar imagem Google Earth próximo ao da imagem Hyperion de 07/06/2012, inviabilizando a obtenção de pontos das classes no entorno do reservatório, necessários para o treinamento do classificador supervisionado e também para obtenção da acurácia da classificação através do índice de Kappa.

O reservatório localizado na cidade de Lavras da Mangabeira, foi utilizado para a aplicação, pois apresentou todos os requisitos necessários: 1 – Classes avaliadas; 2 – Presença de Macrófitas; 3 – Ausência de nuvem e sombra; 4 – Imagem do Google Earth próximo ao próximo ao do período da imagem Hyperion. A imagem do Google Earth (QuickBird) de 08/07/2009, foi georreferenciada no Arc Gis 10.2 para obtenção das classes (Figura 30).

Foram levantados 10 pontos de cada classe (água, macrófitas, solo exposto, vegetação nativa, agricultura, vegetação rala e vazante) e dos alvos nuvem e sombra, totalizando 90 pontos, para a classificação. Já para a análise qualitativa da classificação, ou seja, obtenção do Kappa, foram obtidos 20 pontos de cada uso, totalizando 180 pontos.

5 RESULTADOS E DISCUSSÃO

5.1 Classes existentes no entorno dos reservatórios do Assentamento 25 de Maio

Com base em observações em campanhas realizadas no período de 2012 a 2015 no Assentamento 25 de Maio, não foram observadas alterações significativas na maior parte das classes (Figura 31) presentes naquela região, exceto em relação à presença de nuvem e sombra de nuvem, que apresentam aleatoriedade no tempo e espaço, e macrófitas nos reservatórios, caracterizadas por proliferação e extinção de espécies dependendo da variabilidade dos níveis de acumulação do açude e deslocamentos provocados pela ação do vento.

Figura 31 – Classes encontrados na área de estudo, no entorno dos reservatórios



Água (1); macrófitas (2); solo exposto (3); vegetação nativa (4); agricultura (5); vegetação rala (6); vazante (7). Fonte: Autor.

As classes ilustradas na Figura 31 e encontrados *in locu* no Assentamento 25 de Maio durante as campanhas são:

- 1 – Água: corresponde aos reservatórios existentes na área de estudo;
- 2 - Macrófitas: vegetação encontrada dentro da área inundada dos reservatórios;
- 3 – Solo exposto: área de solo nu com ausência de vegetação;
- 4 – Vegetação Nativa: área de vegetação com alta densidade de espécies arbóreas;
- 5 – Agricultura: regiões onde se pratica a produção agrícola de diversas culturas como milho e feijão;
- 6 – Vegetação Rala: regiões já exploradas pela ação antrópica, com predominância da vegetação rasteira;
- 7 – Vazante: áreas localizadas dentro da bacia hidráulica dos reservatórios, onde se pratica a produção de capim e hortaliças, muito característica da região, pelo fato do solo sempre apresentar umidade adequada para a prática agrícola, propiciando a produção durante todo o ano.

5.2 Identificação das faixas de reflectância de diferentes classes

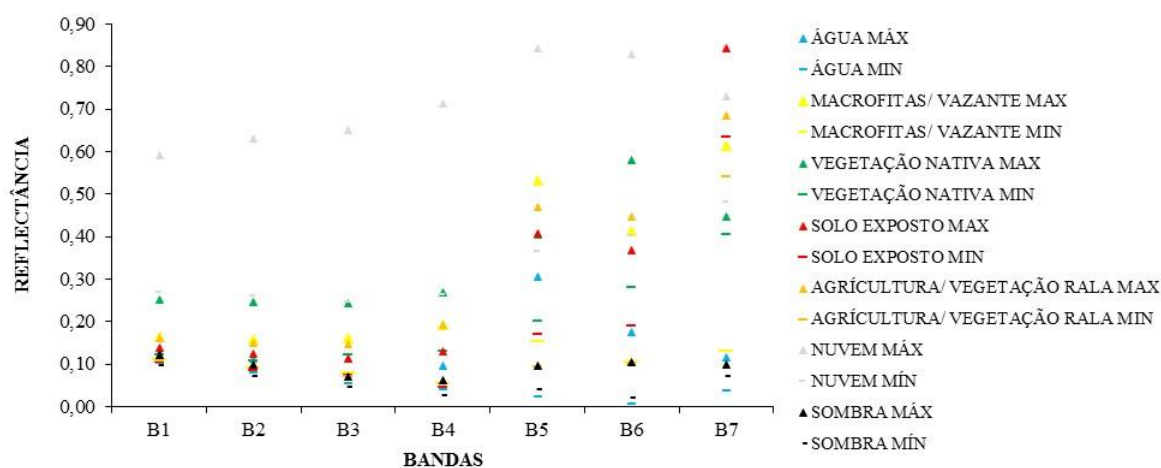
A separação das classes é melhor representada pelas bandas 4, 5 e 6, do satélite Landsat 8, pois apresentam melhor desempenho, com faixas de valores de reflectância de maior amplitude, o que facilita a diferenciação, conforme ilustrado na Figura 32. A classificação usando as bandas 4, 5 e 6 é capaz de diferenciar alvos como água, solo exposto e vegetação nativa adequadamente. Já as bandas 1, 2 e 3 apresentam baixo desempenho na separação de classes em virtude da similaridade do comportamento espectral dos alvos para todas as datas. Lopes (2013), em estudo realizado no reservatório Orós, utilizando imagens Landsat 8, afirma que as bandas do satélite em questão apresentam feições características do comportamento espectral de águas, em que se verificou dificuldade de determinação da reflectância nas bandas 1 e 2. Já na região do infravermelho próximo, ou seja, banda 5, os valores de reflectância são precisamente determinados, devido à forte absorção da água. Segundo Jensen (2009), a água pura seletivamente absorve/espalha a radiação incidente na coluna d'água. Encontram-se na literatura os valores dos coeficientes de absorção, espalhamento e atenuação das moléculas de água na faixa espectral de 0,250 a 0,800 μm .

O comportamento espectral é frequentemente utilizado para representar as características de reflectância da radiação eletromagnética sobre as classes individuais ou em

conjunto, embora a caracterização do comportamento espectral de um alvo esteja associada e diretamente ligada aos processos físicos de reflexão, que variam de classe para classe.

Dispondo-se dos valores médios de reflectância, obtidos nas bandas 1, 2, 3, 4, 5, 6 e 7 procedeu-se a análise em relação aos anos de 2013, 2014 e 2015. A análise da amplitude dos valores máximos e mínimos da reflectância indicou haver diferença significativa entre as bandas analisadas, sendo nítido a separação dos alvos principalmente nas bandas 6 e 5 do satélite Landsat 8, como pode ser visualizado na Figura 32. Resultados semelhantes são obtidos por Weiss *et al.* (2015), em estudo que visa analisar a curva espectral de diferentes alvos, no qual se observa que a banda 5 apresenta os maiores picos. Os autores ainda salientam que o método de calibração linear ponderada do *software* ENVI 5.1 demonstra-se mais apto à correção do sensor OLI, diferenciando melhor os alvos e representando um valor de reflectância mais próximo do real.

Figura 32 - Faixas de reflectância dos diferentes alvos estudados obtidos pelo sensor Landsat 8



Fonte: Elaborada pelo autor.

Dentre os alvos abordados na pesquisa, não é possível separar através da reflectância das classes agricultura e vegetação rala, como é apresentado na Tabela 14. Este resultado indica que a faixa de reflectância dessas duas classes são semelhantes, podendo ainda se sobrepor a outros alvos como macrófitas e vazante, tornando desafiante a determinação de uma faixa exata da reflectância, nessas bandas.

Um resultado que merece destaque é o comportamento dos valores de reflectância de alguns alvos que, mesmo apresentando resposta espectral similar, diferenciam-se pela amplitude das faixas de reflectância, sobretudo nas bandas 4, 5 e 6, como por exemplo agricultura (classe 5) e vegetação rala (classe 6).

Tabela 14 – Valores da reflectância das bandas do Landsat 8, nas respectivas classes

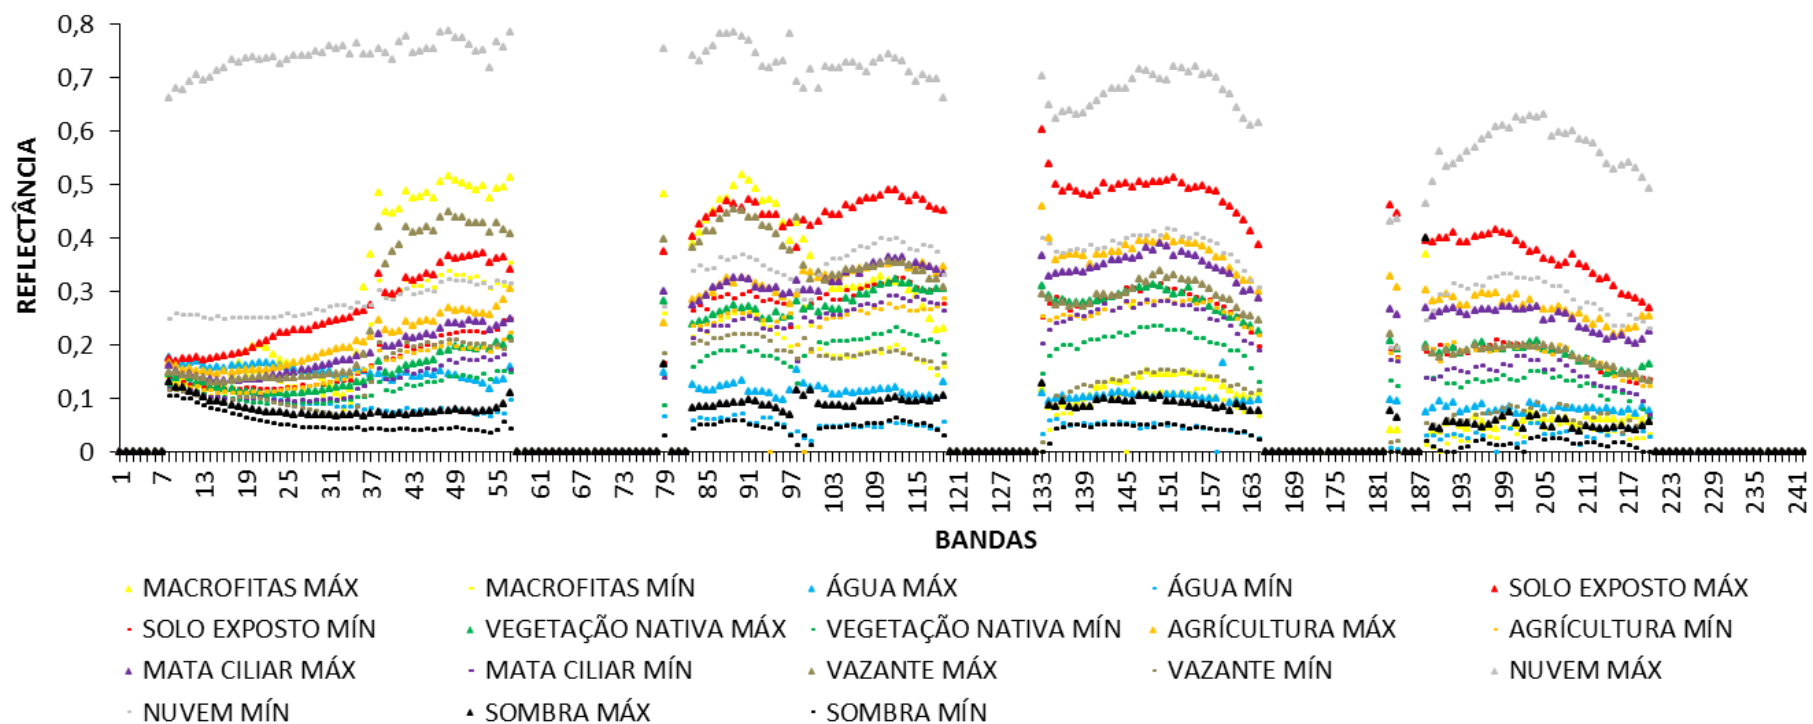
Classes		BANDAS						
		B1	B2	B3	B4	B5	B6	B7
Água	Máx.	0,12	0,10	0,09	0,07	0,07	0,05	0,12
	Mín.	0,10	0,08	0,05	0,03	0,02	0,01	0,04
Macrófitas Vazante	Máx.	0,13	0,12	0,13	0,14	0,44	0,31	0,61
	Mín.	0,11	0,09	0,08	0,05	0,15	0,10	0,13
Vegetação Nativa	Máx.	0,16	0,16	0,18	0,27	0,40	0,58	0,45
	Mín.	0,13	0,12	0,12	0,16	0,28	0,38	0,41
Solo exposto	Máx.	0,14	0,12	0,10	0,13	0,29	0,36	0,84
	Mín.	0,12	0,010	0,07	0,07	0,18	0,20	0,63
Agricultura Vegetação Rala	Máx.	0,14	0,15	0,15	0,19	0,35	0,45	0,69
	Mín.	0,11	0,10	0,10	0,09	0,21	0,22	0,54
Nuvem	Máx.	0,59	0,63	0,65	0,71	0,84	0,83	0,73
	Mín.	0,27	0,26	0,28	0,26	0,36	0,40	0,48
Sombra	Máx.	0,12	0,10	0,07	0,06	0,10	0,10	0,10
	Mín.	0,09	0,07	0,04	0,02	0,04	0,02	0,07

Fonte: Elaborada pelo autor.

Semelhantes dificuldades são encontradas por Rovedder (2017) em pesquisa realizada no município de Torres – RS, trabalhando com imagens de alta resolução espacial do satélite IKONOS II. O autor teve dificuldades em discriminar classes através da separação das faixas de reflectância de diferentes tipos de cobertura vegetal. Em seu trabalho sugere a utilização da classificação digital de imagens para a determinação com exatidão das classes, para garantir respostas condizentes com a realidade e uma representação espacial exata das classes na região de interesse.

Na Figura 33 pode ser observado que cada uso apresenta um comportamento espectral particular ao longo das diferentes bandas. Existem bandas que separam melhor alguns tipos de vegetação, outras já diferenciam melhor alvos de comportamento espectral diferentes como água, solo, exposto, vegetação nativa. Das observações concluiu-se que são necessárias separação de alvos distintos e semelhantes.

Figura 33 - Faixas de reflectância das diferentes classes, incluído nuvem e sombra, obtidos pelo sensor Hyperion



Fonte: Elaborada pelo autor.

O sensor Hyperion possibilita a aquisição de dados com resolução espectral suficiente para reconstruir bandas de absorção nos espectros dos pixels relacionadas com o conteúdo de clorofila, teor de água nas folhas, os quais podem ser parâmetros importantes na diferenciação de tipologias vegetais, o que é dificultado em algumas imagens multiespectrais como, por exemplo, do sensor Landsat 8.

Na Tabela 15, são apresentados os valores da reflectância média das bandas do sensor Hyperion utilizadas na composição RGB. As bandas abordadas foram R-51, G-161 e B-19, determinadas pelo classificador SVM. Pode-se observar que os alvos água e sombra apresentam valores de reflectância relativamente próximos, sendo um fator limitador em trabalhos realizados com imagens de satélite, já que é muito comum a presença de nuvens e sombra.

Dois outros grupos apresentam valores de reflectância semelhantes, que são eles: macrófitas e vazante (grupo 1) e vegetação nativa, agricultura e vegetação rala (grupo 2), sendo assim difícil a separação desses alvos através da faixa (valores máximos e mínimos) da reflectância.

Tabela 15 - Valores de reflectância média das bandas R-51, G-161, B-19 do Hyperion, nas respectivas classes

Classes	Amplitude	Banda 51	Banda 161	Banda 19
Água	Máximo	0,12	0,09	0,16
	Mínimo	0,09	0,06	0,13
Macrófitas	Máximo	0,50	0,11	0,19
	Mínimo	0,40	0,10	0,15
Solo Exposto	Máximo	0,32	0,42	0,19
	Mínimo	0,27	0,30	0,15
Vegetação Nativa	Máximo	0,19	0,25	0,11
	Mínimo	0,16	0,21	0,10
Agricultura	Máximo	0,25	0,32	0,14
	Mínimo	0,23	0,26	0,12
Vegetação Rala	Máximo	0,24	0,32	0,13
	Mínimo	0,20	0,25	0,10
Vazante	Máximo	0,40	0,21	0,12
	Mínimo	0,27	0,15	0,10
Nuvem	Máximo	0,64	0,58	0,61
	Mínimo	0,33	0,36	0,27
Sombra	Máximo	0,08	0,07	0,08
	Mínimo	0,05	0,04	0,07

Fonte: Elaborada pelo autor.

Pereira *et al.* (2012); Souza e Ferreira Junior (2012), em pesquisas realizada na bacia da barra dos coqueiros e no município de Goiânia, respectivamente, ambos no estado de Goiás, afirmam que a reflectância é influenciada diretamente por diversos fatores, como a latitude do local a altitude, nas diferentes classes.

5.3 Classificação de imagens Landsat 8

5.3.1 *Espacialização das classes através da classificação não-supervisionada*

Uma avaliação rigorosa da qualidade dos resultados gerados pelo classificador é realizada nesse trabalho. A primeira avaliação da espacialização das classes no Assentamento 25 de Maio seda com a classificação não-supervisionada adotando o método ISODATA como classificador, haja visto que esse classificador está disponível em vários programas de PDI (processamento digital de imagens) e também bastante utilizado por pesquisadores que trabalham com análise de uso e ocupação do solo através de imagens de satélite.

Optou-se por comparar os resultados gerados pelo método de classificação não supervisionado do algoritmo ISODATA, com os dados das diversas classes levantadas em campo (Tabela 16).

Tabela 16 – Síntese das classes possíveis de serem determinados para diferentes classificações de imagens Landsat 8

Não-supervisionada (5 classes)	Não-supervisionada (7 classes)	Não-supervisionada (9 classes)
Água	Água	Água
Macrófitas	Macrofitas	Macrofitas
Solo exposto	Solo exposto	Solo exposto
Vegetação Nativa	Vegetação Nativa	Vegetação Nativa
-	Agricultura	Agricultura
-	-	Vegetação Rala
-	Vazante	Vazante
Nuvem	Nuvem	Nuvem
-	-	Sombra

Fonte: Elaborada pelo autor.

Apesar de serem amplamente utilizados, esses métodos particionais de agrupamentos apresentam diversas limitações. As funções-objetivo usadas por eles partem do pressuposto de que o número de agrupamentos ou classes é conhecido a priori. Na hipótese de se ter escolhido um valor do número de classes inadequado, o método irá impor, pelo uso de técnicas de otimização, esse número de classes de agrupamentos aos dados. Segundo Gonçalves

et al. (2008), outra limitação não menos importante do algoritmo ISODATA é a existência de suposições sobre a forma dos agrupamentos, ou seja, a separação de classes semelhantes.

O método de classificação não supervisionado de setembro de 2014, permitiu determinar a quantidade de classes a serem geradas e espacializadas. Durante a determinação do número de classes, foram realizados diversos testes, nos quais se buscou determinar a quantidade de classes que mais se aproximasse da realidade visualizada em campo. Os testes são realizados com 5, 7 e 9 classes, sendo que a análise das imagens em confronto com pontos levantados em campo, indicou resultados mais próximos da realidade no entorno dos três reservatórios na classificação com 9 classes (Tabela 17).

Para verificar a eficiência do método de classificação, construiu-se uma matriz de confusão representando a distribuição de percentagens de pixel classificados de forma correta ou erroneamente conforme Landis e Koch (1977). A eficiência dos métodos de classificação não supervisionado com 5, 7 e 9 classes foi, então, analisada usando coeficiente de Kappa e seguindo os agrupamentos e separação das classes destacadas na Tabela 17.

Tabela 17 – Síntese dos valores do coeficiente de Kappa condicional, obtidos através da classificação não-supervisionada da imagem de setembro de 2014, do sensor Landsat 8

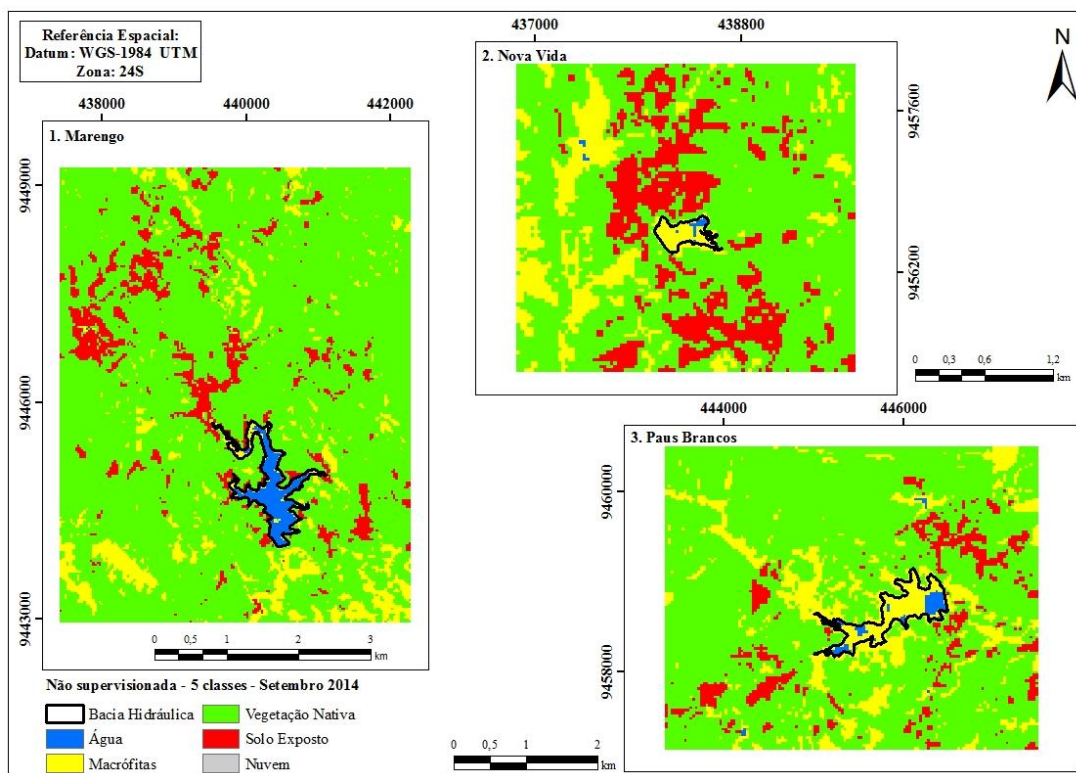
Classes	Não-supervisionada (5 classes)	Não-supervisionada (7 classes)	Não-supervisionada (9 classes)
Água	<u>0,70 - Muito Bom</u>	0,72 - Muito Bom	<u>0,72 – Muito Bom</u>
Macrófitas	0,69 - Muito Bom	<u>0,93 - Excelente</u>	0,02 - Ruim
Solo exposto	0,23 - Razoável	0,09 - Péssimo	0,61 – Muito Bom
Vegetação nativa	0,40 - Bom	0,81 - Excelente	0,71 – Muito Bom
Agricultura	-	0,13 - Ruim	0,01 - Ruim
Vegetação rala	-	-	0,35 - Razoável
Vazante	-	0,08 - Ruim	0,62 – Muito Bom
Nuvem	0,21 - Razoável	0,14 - Ruim	0,52 - Bom
Sombra	-	-	0,62 – Muito Bom
Kappa Geral	0,44 - Bom	0,39 - Razoável	0,46 - Bom

Fonte: Elaborada pelo autor.

Na classificação não-supervisionada com 5 classes, o uso água foi o que apresentou maior valor de Kappa de 0,70, sendo assim classificado com muito boa (Figura 34). É importante ressaltar que na classificação não-supervisionada com 5 classes, as classes macrófitas e vazante, foram considerados dentro de uma única classe, sendo uma desvantagem da adoção desse número de classes. As classes macrófitas e vazante ficaram em uma única classe pelo fato do método realizar uma divisão do número de classes pela faixa de valores de reflectância, como as duas classes apresentam valores muito próximos, não é possível a

separação dos mesmos. Pompêo *et al.* (2015), afirmam com veemência que as análises de imagens de satélite para determinação de regiões cobertas por macrófitas, apresentam dificuldades similares às encontradas na determinação de área coberta por vegetação terrestre, devido às características peculiares de cada espécie e às alterações que podem ocorrer na refletância, derivadas principalmente da mistura da resposta espectral.

Figura 34 – Espacialização das classes no entorno dos reservatórios Paus Brancos, Marengo e Nova Vida, obtidos através da classificação não-supervisionada (ISODATA) com 5 classes



Fonte: Elaborada pelo autor.

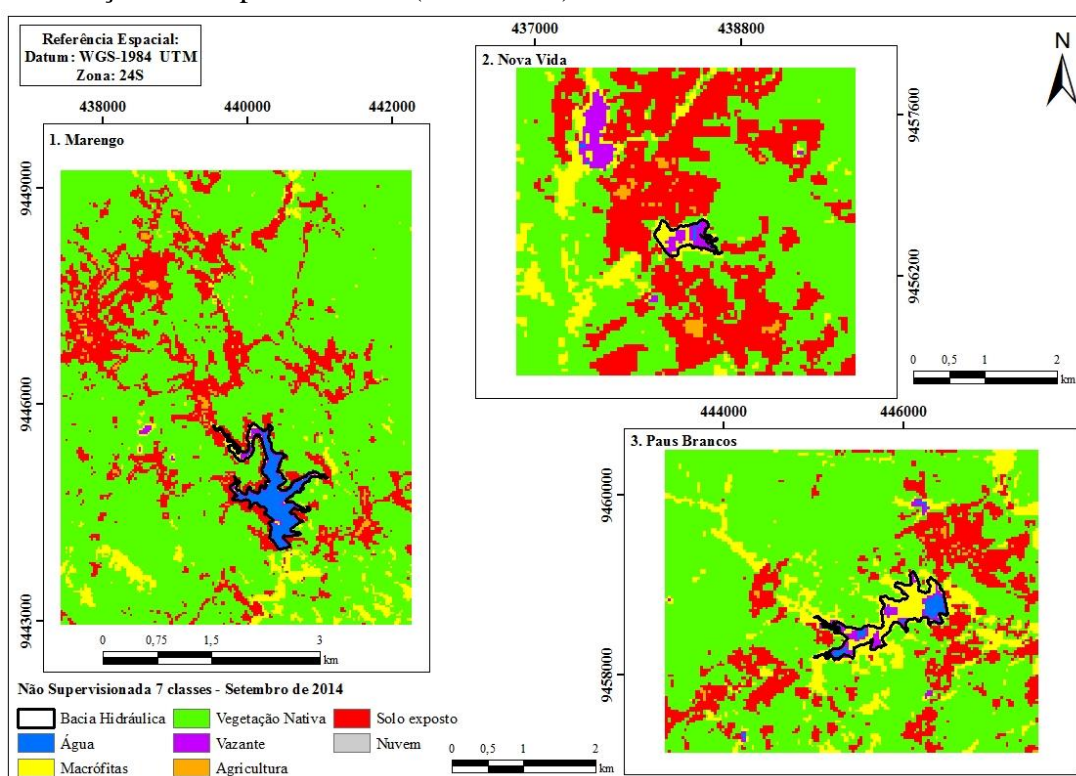
A classificação não supervisionada com 5 classes teve um desempenho baixo, o que pode ser explicado pelo fato do algoritmo se basear na análise de agrupamentos onde são identificadas, no espaço de atributos, as manchas formadas por pixels com características espectrais similares, não sendo possível separar água de sombra das nuvens, macrófitas de vazante, vegetação nativa de agricultura.

Nas 6 imagens analisadas do satélite Landsat 8 (Tabela 16), a classificação não-supervisionada com 5 classes apresentou na imagem de setembro de 2014 o melhor valor de índice de Kappa médio, correspondente a 0,44, ou seja, classificada como boa.

A classificação com 7 classes apresentou baixo desempenho devido ao procedimento de agrupar os pixels de características espectrais mais similares. Assim como na

classificação com 5 classes, não foi possível separar áreas cobertas por sombra de nuvem de corpos hídricos (Figura 35), sendo isso um ponto negativo, pois são raras imagens nessa região sem a presença de nuvens, como também foi afirmado por Rizzi e Rudorff (2005). Esses autores, trabalhando com imagens multitemporais adquiridas em períodos específicos ao longo do ano, reforçam a importância de se dispor de satélites de sensoriamento remoto com elevada frequência de revisita para viabilizar o uso do sensoriamento remoto em um sistema rotineiro de levantamento de classes.

Figura 35 – Espacialização das classes no entorno dos reservatórios estudados, obtidos através da classificação não-supervisionada (ISODATA) com 7 classes



Fonte: Elaborada pelo autor.

A classificação não-supervisionada com 7 classes apresentou Kappa de 0,39 para a imagem de setembro de 2014, sendo classificada como razoável, como pode ser visualizado na Tabela 16.

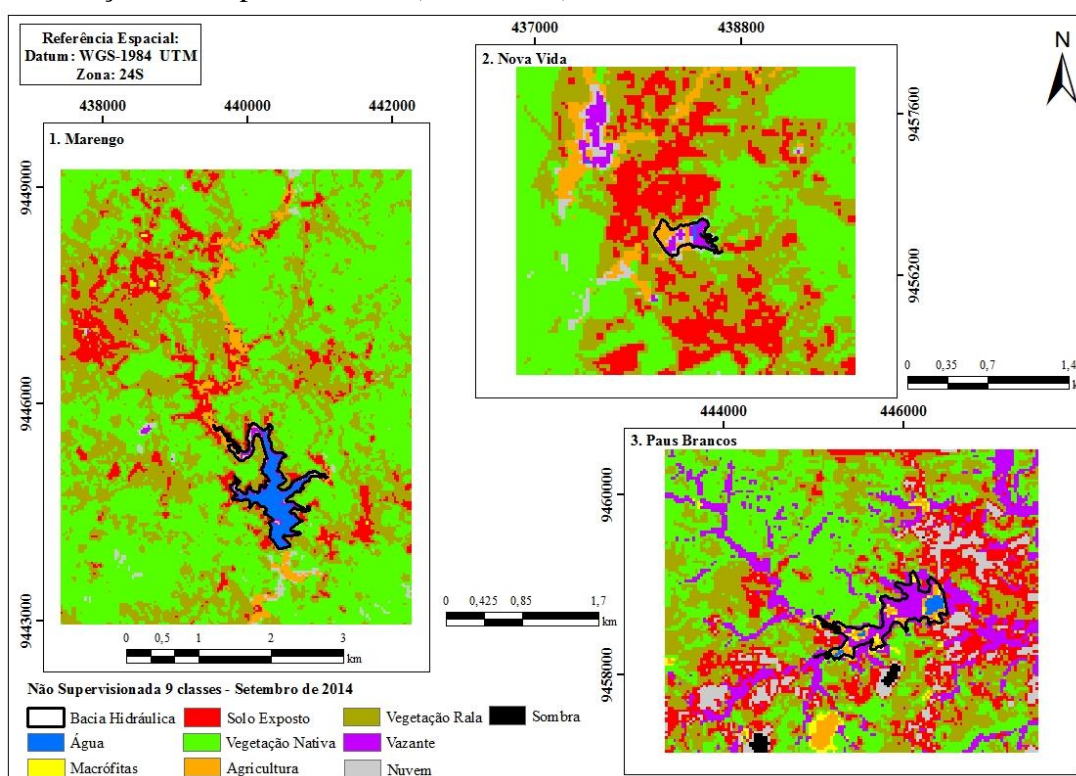
Na classificação não-supervisionada considerando 7 classes, a classes macrófita apresentou o melhor resultado na determinação, mostrando um Kappa de 0,93, sendo assim classificado como excelente a sua espacialização, como exposto na Tabela 16.

Na classificação não-supervisionada com 9 classes, por sua vez, observou-se o melhor desempenho na separação dos alvos, apresentando um índice de Kappa de 0,46 (Tabela

16) na imagem de setembro de 2014, indicando uma classificação boa segundo Landis e Koch (1977).

A utilização de nove classes na classificação não-supervisionada traz a vantagem de corresponder exatamente ao número de classes identificados no Assentamento 25 de Maio em campanha realizada em outubro de 2014. No caso de nuvem, observou-se o melhor desempenho na classificação com 9 classes quando comparado às de 5 e 7 classes, com um coeficiente Kappa de 0,50. Já no caso de sombra de nuvem, apenas esta classificação com 9 classes foi capaz de distingui-la das demais classes (Figura 36).

Figura 36 – Espacialização das classes no entorno dos reservatórios estudados, obtidos através da classificação não-supervisionada (ISODATA) com 9 classes



Fonte: Elaborada pelo autor.

Para testar a aplicabilidade de utilização de pontos de classes levantados em campo para validar resultados de classificação não-supervisionada de outros períodos, em um intervalo de até 18 meses, pode-se perceber, de acordo com a Tabela 18, que existe restrição nesta aplicação, sobretudo para classes que apresentam maior variabilidade no tempo como é o caso de agricultura, que apresenta estrutura vegetal distinta ao longo das etapas de produção desde plantio até colheita e nova limpeza do terreno.

Cabe destacar que, nesta análise, utilizaram-se pontos específicos de nuvem e

sombra de nuvem para cada imagem, dado o caráter aleatório de ocorrência no tempo e, nas demais classes, utilizaram-se apenas parte dos pontos coletados em campo como uma tentativa de assegurar que o ponto representava o mesmo uso em todas as imagens, o que foi verificado com base na composição colorida das imagens.

Analisando a qualidade da classificação não-supervisionada das seis imagens do satélite Landsat 8 utilizadas na pesquisa, e processadas com 5, 7 e 9 classes, pode-se constatar que, em geral, os melhores desempenhos da classificação não supervisionada ocorreram nas imagens com data mais próxima do período da coleta dos pontos das classes, com coeficiente Kappa variando de 0,36 a 0,54 (todas as classificações como “boa” ou “razoável”) dependendo do número de classes adotadas como pode ser visualizado na Tabela 18. Observou-se, ainda, que o melhor desempenho geral nas seis imagens ocorreu para a classificação não supervisionada com 7 classes, com destaque para imagem de agosto de 2014, que resultou em um Kappa de 0,54.

Tabela 18 – Valores do coeficiente de Kappa de imagens de diferentes períodos, obtidos através da classificação não-supervisionada

Imagem	Não-supervisionada (5 classes)	Não-supervisionada (7 classes)	Não-supervisionada (9 classes)
Maio 2013	0,31 - Razoável	0,30 - Razoável	0,40 - Boa
Setembro 2013	0,35 - Razoável	0,37 - Razoável	0,34 - Razoável
Outubro 2013	0,20 - Razoável	0,28 - Razoável	0,19 - Ruim
Agosto 2014	0,43 - Boa	<u>0,54 - Boa</u>	0,36 - Razoável
Setembro 2014	<u>0,44 - Boa</u>	0,39 - Razoável	<u>0,46 - Boa</u>
Janeiro 2015	0,23 - Razoável	0,35 - Razoável	0,28 - Razoável
Kappa Médio	0,32	0,37	0,33

Fonte: Elaborada pelo autor.

Segundo Rizzi e Rudorff (2005), o procedimento de classificação digital é ágil, porém pouco exato, já a interpretação visual é extremamente trabalhosa para uma grande região tal como a do presente estudo. Desta forma, pode-se concluir que os dois métodos, não-supervisionado e supervisionado são complementares e quando utilizados de forma conjunta permitem realizar o mapeamento de forma muito próxima a existente no campo.

A classificação não-supervisionada restringe a obtenção de um dos objetivos da pesquisa de conseguir separar macrófitas de vazante e agricultura de vegetação rala, sendo isso um limitador desse tipo de classificação. Dificuldades semelhantes foram encontradas por Gonçalves *et al.* (2008), em pesquisa realizada na cidade de Manaus na região do encontro dos Rios Negros e Solimões utilizando imagens Landsat 5 na obtenção de classes através da

classificação não-supervisionada pelo método ISODATA. Os mesmos encontraram que pequenas áreas de vegetação rala ou desmatada presentes na imagem foram classificadas como área urbana. O autor afirma que isso ocorreu pelo fato das classes serem espectralmente muito semelhantes aos padrões dessa classe e por se apresentarem com baixa densidade em comparação com os outros padrões de cobertura.

O aumento no número de classes pode melhorar a representação de alvos com valores de refletância mais concentrados, como é o caso de sombra de nuvem, e prejudicar aqueles com valores mais dispersos, como macrófitas e agricultura. Pompêo *et al.* (2015) destacam a dificuldade na separação de alvos com resposta espectral similar até mesmo com a adoção de técnicas mais complexas e eficientes, como é o caso da classificação orientada a objetos e utilização de métodos classificadores robustos como o K-NN e SVM.

Gonçalves *et al.* (2008), identificaram 4 classes através da classificação não-supervisionada através do método ISODATA. O uso água, um dos alvos determinados através da classificação, apresentou índice de Kappa 0,96, sendo esse o alvo com melhor desempenho entre todos os alvos analisados. Isso pode ser explicado pelo fato da área de ocupação do uso que é muito superior à área ocupada pelos reservatórios localizados no Assentamento 25 de Maio, analisados na presente pesquisa, onde é importante salientar que o classificador não-supervisionado leva em consideração a área (número de pixel existente) com uma dada faixa de reflectância para eleger uma classe.

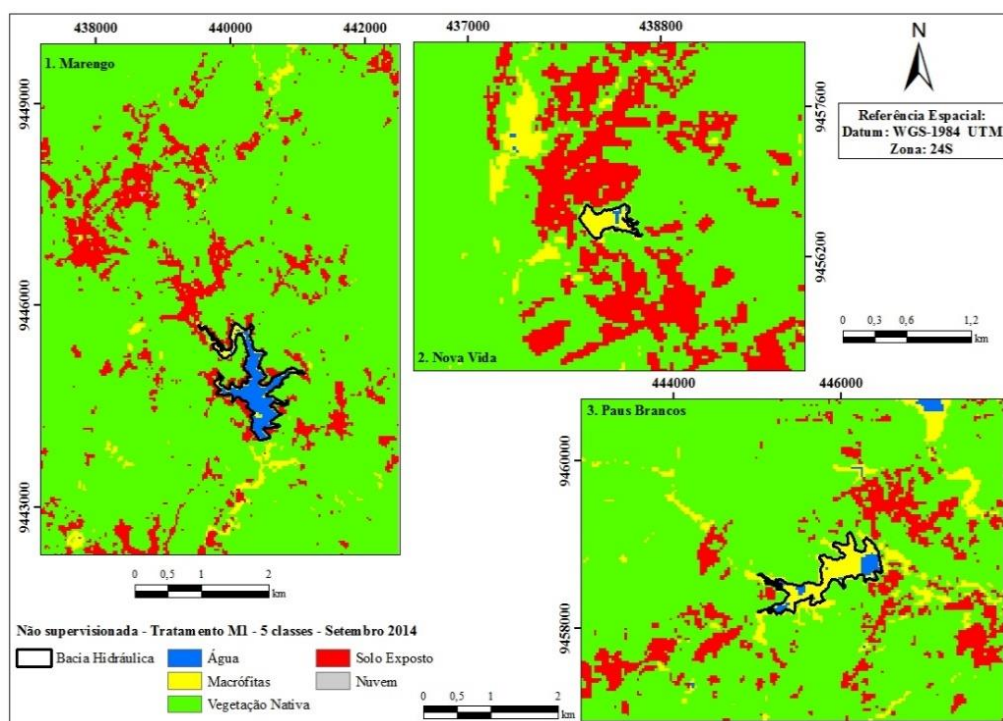
5.3.2 Utilização de técnicas de realces computacionais para tratamentos de imagens Landsat 8

A fim de melhorar os resultados da classificação das imagens Landsat 8, utilizou-se o realce de imagens implementado através de rotinas no ambiente Matlab. Os testes foram realizados para buscar separar melhor o classificador não-supervisionado através da implantação do método ISODATA, pois segundo Xu e Wunsch (2005), embora exista uma grande quantidade de diferentes métodos de agrupamentos na área de reconhecimento de padrões, a maioria dos softwares ou sistemas computacionais voltados para o processamento digital de imagens de sensoriamento remoto realiza a classificação não-supervisionada baseada em métodos de agrupamentos, como o K-médias e o ISODATA.

Os resultados obtidos pelo tratamento M1, que buscou melhorar a classificação não-supervisionada (Figuras 37, 38 e 39 e Tabela 19), não mostrou um avanço significativo na espacialização das classes do solo no entorno dos reservatórios estudados.

O realce de imagens foi aplicado às bandas 6, 5 e 4, mesmo sendo essas as bandas que melhor separam os alvos destacados na pesquisa, através da análise da reflectância, não foi possível diferenciar as classes abordados pela técnica do realce.

Figura 37 – Espacialização das classes do solo obtidos através da classificação não-supervisionada com 5 classes com o tratamento M1

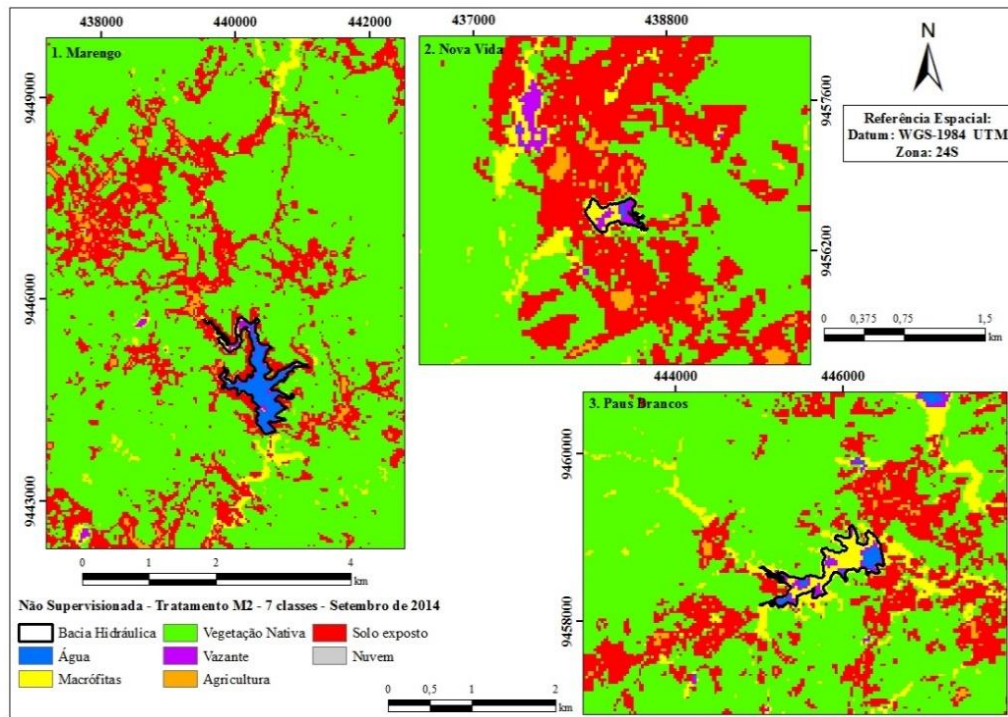


Fonte: Elaborada pelo autor.

A utilização da técnica de realce em um classificador não-supervisionado, teve como objetivo identificar a semelhança dos valores espectrais informados através do número de classes, não sendo eficiente na separação entre macrófitas e vazante, vegetação nativa e vegetação rala, agricultura e solo exposto, e entre sombra e água, mostrando que não é possível separar essas classes através da utilização de classificadores não-supervisionados, já que os mesmos não apresentam uma faixa fixa nos valores de reflectância.

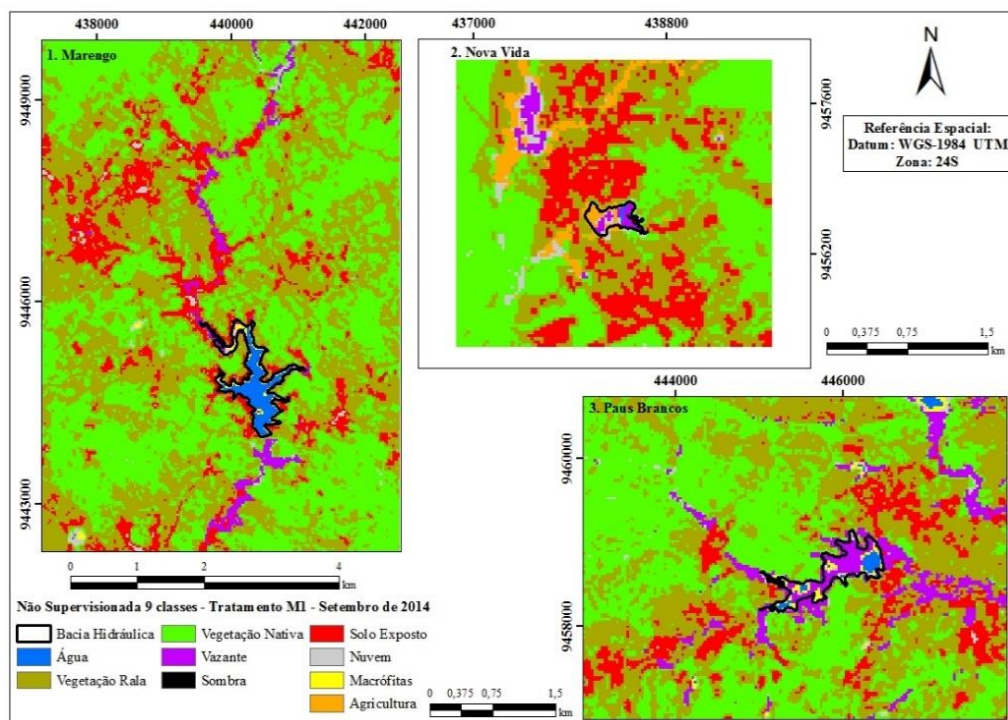
Gonçalves *et al.* (2008), em utilizando os classificadores ISODATA e K-médias, procederam com a técnica de realce SOM (*Serf Organizing Map*) de imagens, afim de melhorar os resultados iniciais. A imagem produzida pelo método de realce proposto se apresentou de forma mais homogênea em todas as áreas classificadas. Os autores afirmam que a diferença no aspecto visual certamente se dá em virtude das formas pelas quais o método trata a imagem, através de janelas de pixels, as quais incorporam informações de vizinhança e por isso permitem obter uma classificação resultante de melhor qualidade.

Figura 38 – Espacialização das classes obtidos através da classificação não-supervisionada com 7 classes após o tratamento M1



Fonte: Elaborada pelo autor.

Figura 39 – Espacialização das classes obtidos através da classificação não-supervisionada com 9 classes após o tratamento M1



Fonte: Elaborada pelo autor.

Na Tabela 19 estão apresentados os valores de Kappa geral e Kappa individual obtidos na classificação não-supervisionada da imagem do mês de setembro de 2014, para três cenários: simulação sem utilização de tratamentos de imagem; simulação com o tratamento M1; e simulação com tratamento M2. Os resultados indicam que o tratamento M1 não foi eficaz na otimização do desempenho do método de classificação não supervisionado. Já nas classificações com 7 e 9 classes, observa-se uma discreta melhora do desempenho do classificador após utilização da técnica de realce M1. O tratamento M2 (Figura 40, 41 e 42) por sua vez, apresentou resultados ligeiramente superiores às encontradas na simulação sem tratamento de imagem.

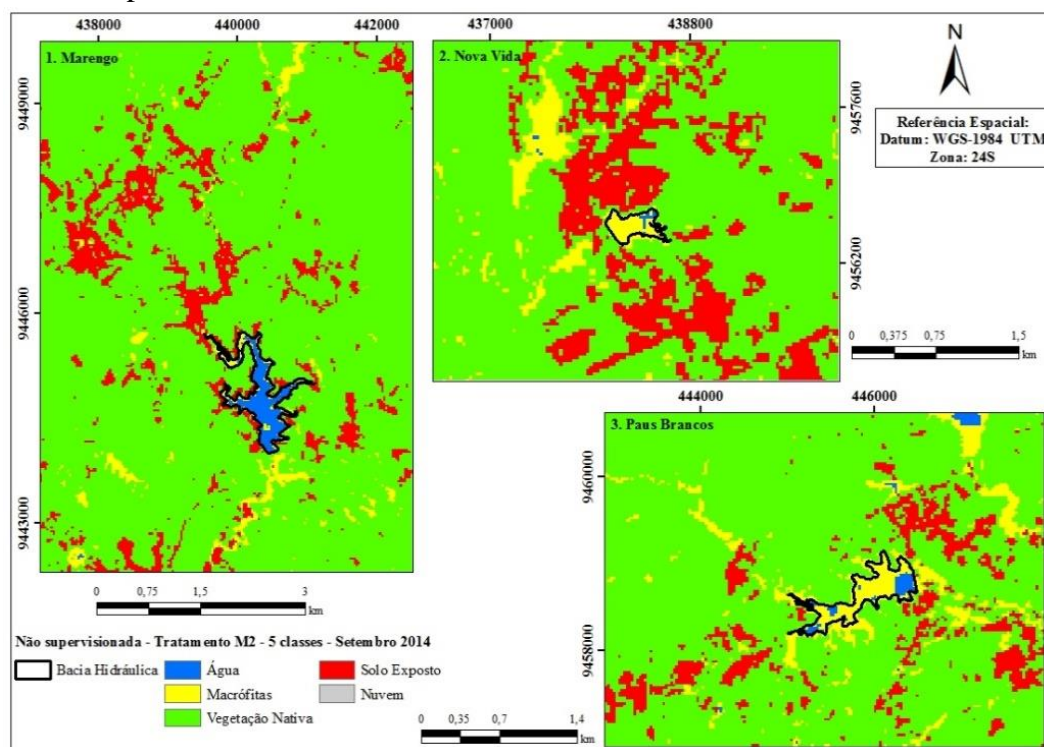
Tabela 19 – Síntese dos valores do coeficiente de Kappa condicional, obtidos através da classificação não-supervisionada (ISODATA) com 5, 7 e 9 classes após o tratamento M1

Classificação Não-supervisionada									
Classes	5 Classes			7 Classes			9 Classes		
	5 M1	5 M2	5 S.T.	7 M1	7 M2	7 S.T.	9 M1	9 M2	9 S.T.
Água	0,55	0,55	0,70	0,72	0,72	0,72	0,72	0,72	0,72
Macrófitas	1,00	1,00	0,69	0,93	0,93	0,93	0,02	0,02	0,02
Solo exposto	0,00	0,00	0,23	0,13	0,09	0,09	0,65	0,60	0,61
Vegetação nativa	0,00	0,00	0,40	0,86	0,78	0,81	0,61	0,65	0,71
Agricultura	-	-	-	0,47	0,35	0,13	0,00	0,02	0,01
Vegetação rala	-	-	-	-	-	-	0,55	0,30	0,35
Vazante	-	-	-	0,01	0,01	0,08	0,68	0,74	0,62
Nuvem	0,21	0,21	0,21	0,00	0,00	0,14	0,52	0,52	0,52
Sombra	-	-	-	-	-	-	0,62	0,62	0,62
Kappa Geral	0,25	0,25	0,44	0,40	0,37	0,39	0,47	0,46	0,46
	Razoável	Razoável	Boa	Boa	Razoável	Razoável	Boa	Boa	Boa

S.T.: Imagem Landsat 8 sem tratamento.

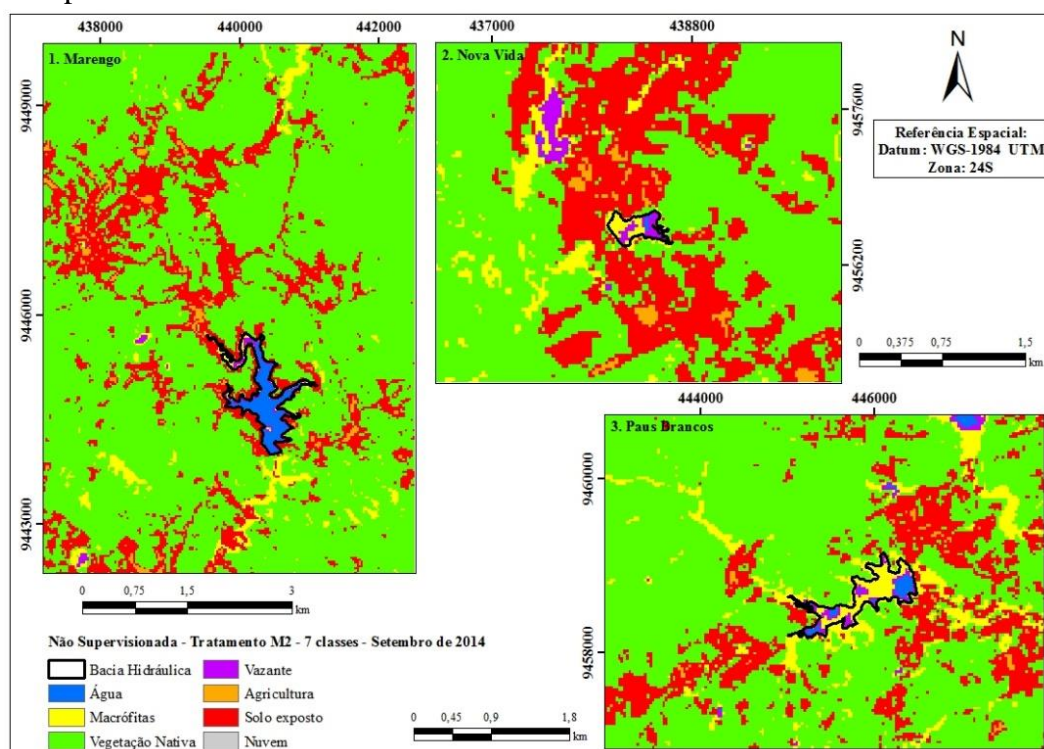
Fonte: Elaborada pelo autor.

Figura 40 – Espacialização das classes, obtidos através da classificação não-supervisionada com 5 classes após o tratamento M2



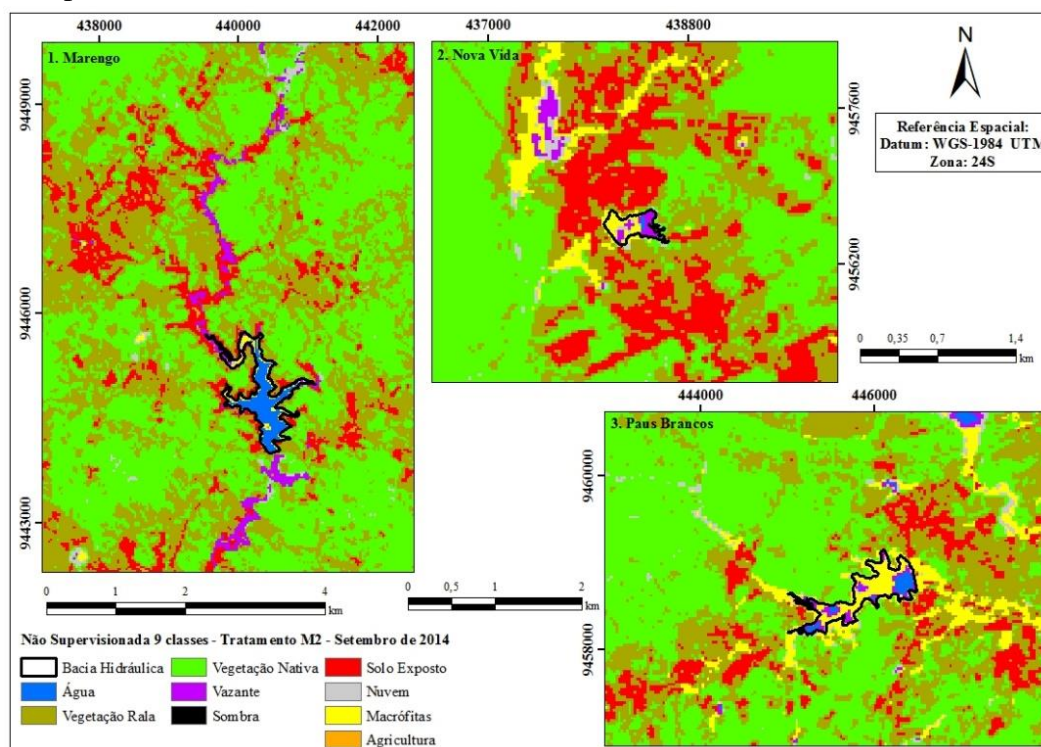
Fonte: Elaborada pelo autor.

Figura 41 – Espacialização das classes obtidos através da classificação não-supervisionada com 7 classes após o tratamento M2



Fonte: Elaborada pelo autor.

Figura 42 – Espacialização das classes obtidos através da classificação não-supervisionada com 9 classes após o tratamento M2



Fonte: Elaborada pelo autor.

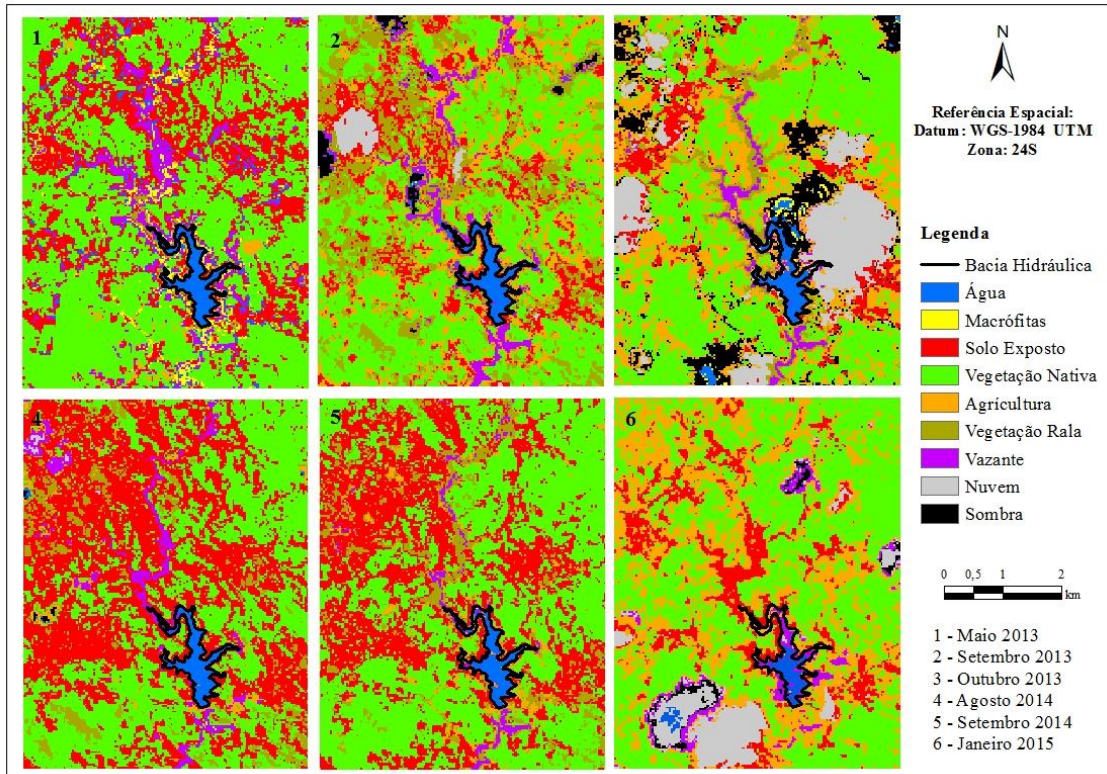
5.3.3 Espacialização das classes através da classificação supervisionada

O método de classificação supervisionado exigiu um conhecimento prévio da área do Assentamento 25 de Maio, permitindo a seleção de amostras de treinamento confiáveis.

Os resultados obtidos na classificação supervisionada no entorno dos três reservatórios foram bem melhores em comparação à classificação não-supervisionada, afirmação que pode ser confirmado através dos pontos das classes levantados na área de estudo. Isso que pode ser explicado pelo próprio princípio do método do classificador supervisionado, usando pontos medidos com identificação da classe de uso do solo, como pode ser visualizado nas Figuras 43, 44 e 46.

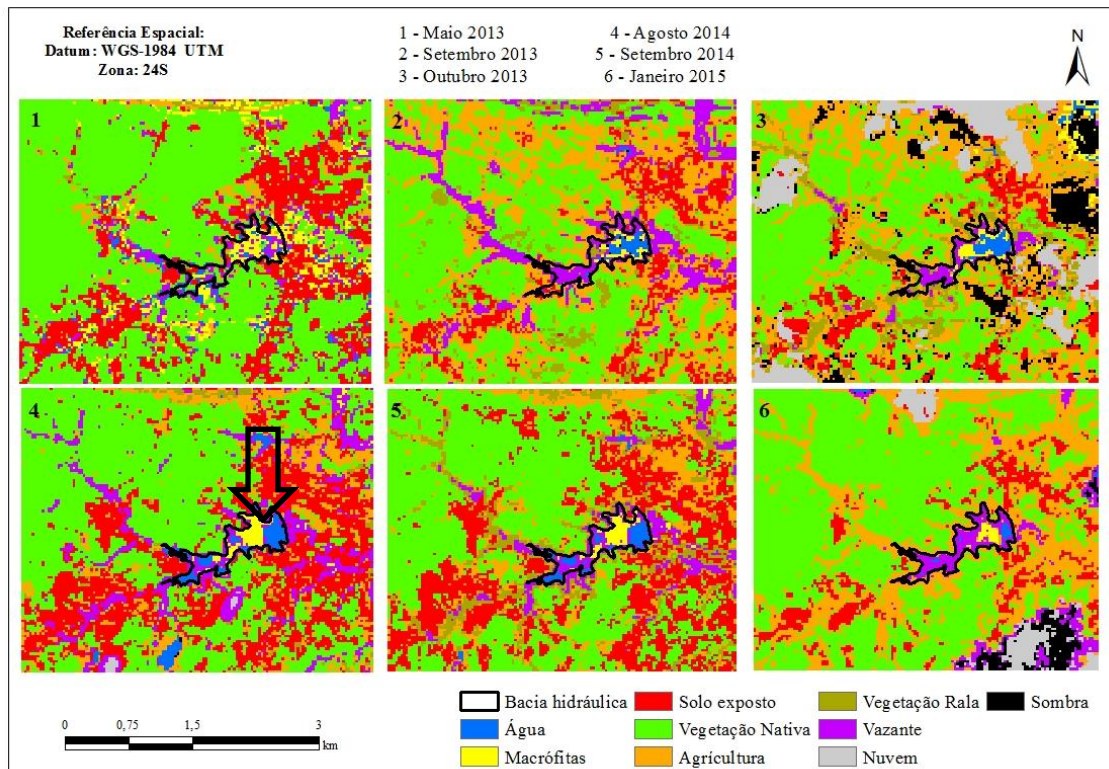
O classificador opera com base na distribuição de probabilidade de cada classe selecionada com base nas classes diagnosticados em campo e confrontados com as informações obtidas através dos satélites. A análise inicialmente treina o classificador, para depois associar os pixels a uma determinada classe (previamente definida), através de regras estatísticas preestabelecidas, para separação das classes, semelhantes e distintas existentes na imagem.

Figura 43 – Classes no entorno do reservatório Marengo, na classificação supervisionada



Fonte: Elaborada pelo autor.

Figura 44 – Classes no entorno dos reservatórios Paus Brancos, na classificação supervisionada



Fonte: Elaborada pelo autor.

Um resultado valioso encontrado na classificação supervisionada se deu pela eficiência na separação de corpos hídricos de sombra de nuvens em todas as imagens que apresentaram a existência dos dois alvos, como está ilustrado nas Figuras 43, 44 e 46, diferentemente da classificação não-supervisionada que não obteve êxito na separação destes alvos. Resultados semelhantes foram obtidos por Coulter *et al.* (2016) em pesquisa realizada em Gana, para obtenção dos usos existentes no país, devido a exploração dos recursos naturais desenfreado que o mesmo vem sofrendo ao longo dos anos.

Outro resultado importante obtido na aplicação da classificação supervisionada foi a diferenciação de macrófitas (Figura 45) de outras classes como vazante, com características de reflectância bem similares, como pode ser observado na Figura 38. Essa classe aparece com predominância no reservatório Paus Brancos e em algumas épocas no açude Nova Vida, conforme identificação em campo e nas imagens utilizadas. May e Carvalho (2010) afirmam que a presença de macrófitas é comum em lagos rasos em áreas de várzea, devido à área muitas vezes ter uma agricultura intensiva. Já Tundisi (2008), argumentam que a concentração de nutrientes (nitrogênio e fósforo) é o principal fator limitante para a proliferação da macrófitas.

Figura 45 – Reservatório Paus Brancos, em fevereiro e agosto de 2014, respectivamente

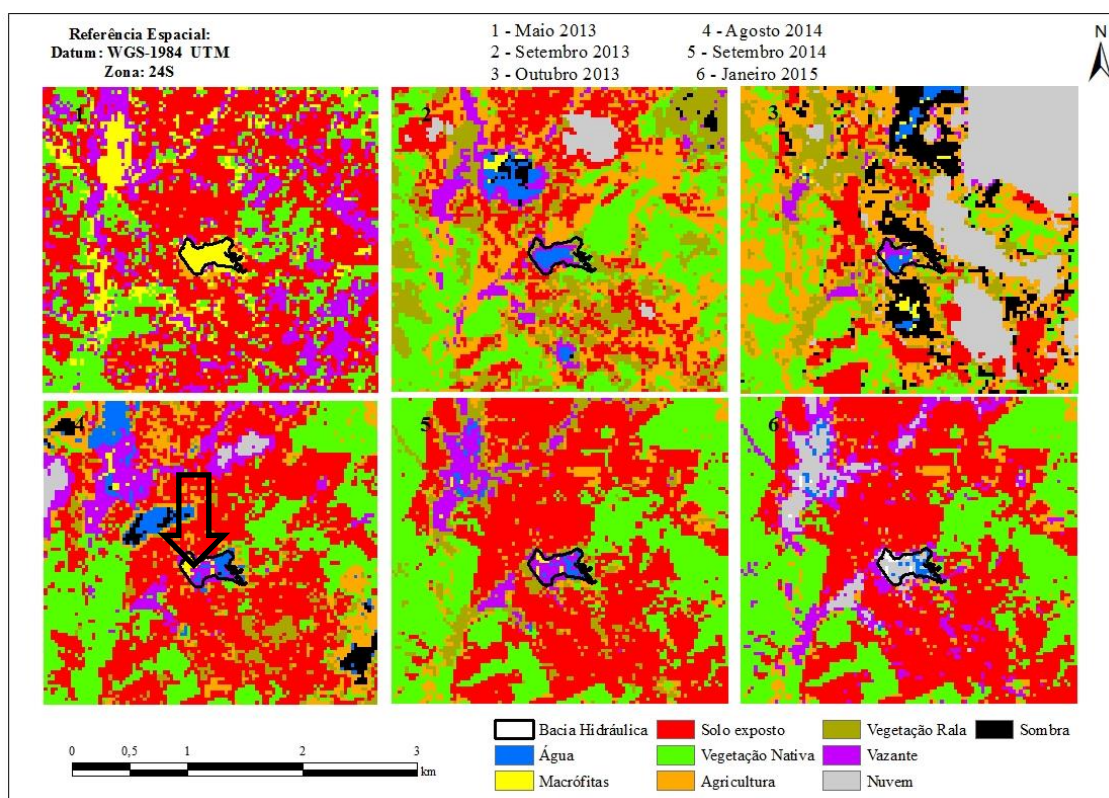


Fonte: Autor.

O reservatório Nova Vida (Figuras 46 e 47) apresentou uma variabilidade sazonal na existência de macrófitas. Nas campanhas realizadas, observou-se que em alguns momentos foi diagnosticada a presença da vegetação aquática, já em outros momentos não foi verificada a existência da vegetação aquática, mostrando que a presença de macrófitas nesse reservatório apresenta alta variabilidade, o que torna esse reservatório diferente tanto do Paus Brancos como do Marengo.

Antunes (2009) afirma que a capacidade reprodutiva de macrófitas aquáticas é resultado da alta capacidade de absorção de nutrientes e de radiação solar, infere-se que o aumento na quantidade de macrófitas pode ter influência da diferença do fotoperíodo e da intensidade da radiação, que são maiores no verão. Como efeito disso, as altas temperaturas também favorecem a propagação das macrófitas em reservatórios localizados em regiões semiáridas.

Figura 46 – Classes no entorno do reservatório Nova Vida, na classificação supervisionada



Fonte: Elaborada pelo autor.

A aplicação do método de classificação supervisionada permitiu a separação também de classes como agricultura e vegetação rala, diferente da resposta obtida através do algoritmo classificador não supervisionado apresentado anteriormente. Este avanço demonstrado possibilitou a geração de um mapa de uso e ocupação do solo preciso e bastante condizente com a realidade, de acordo com os índices de Kappa obtidos.

El-Askary *et al.* (2014); Pahlevan e Schott, (2013) afirmam que o infravermelho próximo (banda 5) do satélite Landsat 8 desempenha uma função fundamental na resposta espectral de florestas, permitindo a detecção precisa de vários tipos de vegetação em diferentes condições.

Figura 47 - Bacia hidráulica do reservatório Nova Vida, no mês de fevereiro 2014



Fonte: Autor.

Os resultados obtidos através da classificação supervisionada das seis cenas Landsat 8 utilizadas na pesquisa, mostram que em todas as imagens o Kappa geral foi superior a 0,46, mostrando que a qualidade do mapa temático gerado foi boa como está ilustrado na Tabela 20. Os resultados da classificação supervisionada são superiores aos encontrados na classificação não-supervisionada o que pode ser explicado pelo próprio princípio do método do classificador, que usa pontos levantados com identificação das classes. Resultados semelhantes foram encontrados por Machado *et al.* (2014) analisando diferentes métodos de classificação de imagens de satélite no estado da Paraíba.

Tabela 20 – Valores do coeficiente de Kappa individual, obtidos através da classificação supervisionada (Máxima Verossimilhança) de imagens Landsat 8


Classes	Maio 13	Set 13	Out 13	Ago 14	Set 14	Jan 15
Água	0,41	<u>1,00</u>	<u>1,00</u>	0,89	<u>1,00</u>	0,94
Macrófitas	0,70	0,57	0,83	<u>0,89</u>	0,83	0,28
Solo exposto	0,52	0,55	0,21	<u>0,74</u>	0,57	0,42
Vegetação nativa	0,40	0,48	0,12	<u>0,83</u>	0,61	0,59
Agricultura	0,17	<u>0,40</u>	0,26	0,10	0,33	<u>0,40</u>
Vegetação rala	<u>0,21</u>	0,04	0,15	0,15	0,06	0,02
Vazante	0,12	<u>0,54</u>	0,15	0,26	0,35	0,00
Nuvem	0,67	<u>1,00</u>	<u>1,00</u>	0,67	0,52	0,57
Sombra	<u>0,89</u>	0,73	0,72	0,52	0,62	0,57
Kappa Geral	0,46	0,51	0,47	0,55	0,53	0,41
	Boa	Boa	Boa	Boa	Boa	Boa

Fonte: Elaborada pelo autor.

As imagens de agosto e setembro de 2014 apresentaram os melhores valores de Kappa, sendo 0,55 e 0,53 respectivamente, assim classificado como boa a qualidade do mapa temático, o que pode estar relacionado à proximidade das datas das imagens com a data da campanha (outubro de 2014) e à boa qualidade destas imagens com baixa cobertura de nuvem e sombra. Já a imagem de janeiro de 2015 teve o menor valor de Kappa (0,41) entre as seis imagens, isso pode ser explicado pelo fato da mesma ter o maior percentual de nuvem e sombra de nuvem, o que prejudica a espacialização das classes, já que a informação existente abaixo da nuvem ou da sombra não pode ser extraída.

Os resultados referentes à qualidade do mapa temático, obtidos através do índice de Kappa, mostram que o uso água, apresentou valores máximos de Kappa, ou seja, Kappa = 1,00, em três imagens (setembro de 2013, outubro de 2013 e setembro de 2014), o que confirma que o mesmo foi o uso com maior exatidão na espacialização. Já a classe vegetação rala apresentou os menores valores de Kappa (0,02 a 0,21) nas seis imagens, sendo esse a classe com maior dificuldade de espacialização, isso pode ser explicado ao comportamento espectral do mesmo que é semelhante à reflectância da vegetação nativa e agricultura. Coulter *et al.* (2016) encontraram dificuldades semelhantes na separação de agricultura de floresta secundárias em pesquisa realizada no continente africano, onde os mesmos obtiveram valores de Kappa de 0,25.

Figura 48 – Comparativo do Kappa condicional, obtidos com diferentes métodos classificatórios e número de classes do solo, para imagem de setembro de 2014



Fonte: Elaborada pelo autor.

O desempenho da classificação supervisionada para a determinação das classes no Assentamento 25 de Maio, obtidos através do processamento de imagens Landsat 8, mostrou-se superior em relação aos resultados encontrados através da classificação não-supervisionada (Figura 48).

Rizzi e Rudorff (2005) afirmam que o uso de imagens multitemporais adquiridas em períodos específicos ao longo do ano, aliado ao problema relacionado à cobertura de nuvens, reforça a importância de se dispor de satélites de sensoriamento remoto com elevada frequência de revisita para viabilizar o uso dessa tecnologia em um sistema rotineiro de levantamento de áreas agrícolas.

Jafari e Lewis (2012) reforçam que a baixa resolução espectral de imagens de sensor multiespectral limita sua capacidade de extração de informações em ambientes com escassa variação da reflectância, principalmente nas regiões com presença de cobertura vegetal.

Analisando o desempenho da classificação das seis imagens Landsat 8, através dos classificadores supervisionados e não-supervisionado, pode-se observar que as classes água, macrófitas e nuvem foram os únicos que apresentaram Kappa = 1,00 em alguma imagem, como pode ser visualizado na Tabela 21.

Os resultados encontrados na análise da qualidade da classificação das imagens Landsat 8 mostram que a imagem de setembro de 2014 apresentou o maior número de Kappa máximos na classificação não-supervisionada com 5, 7 e 9 classes, e na classificação supervisionada.

A imagem de outubro de 2013 foi a imagem com menor quantidade de valores de Kappa máximo, tendo apenas dois acertos, o que pode estar diretamente relacionado à qualidade da imagem, pois a mesma apresentou a maior área coberta por nuvem e sombra em relação as outras cinco imagens estudadas, como pode ser visualizado na Tabela 21.

Tabela 21 - Valores do coeficiente de Kappa individual, obtidos através das classificações não-supervisionadas e supervisionada de imagens Landsat 8

Classes	N. S. - 5 classes	N. S. - 7 classes	N. S. 9 classes	Supervisionada
IMAGEM LANDSAT 8 – 30 DE MAIO DE 2013				
Água	0,38	0,06	0,42	0,41
Macrófitas	0,62	0,00	0,00	0,70
Solo exposto	0,40	0,58	0,53	0,52
Vegetação nativa	0,00	0,32	0,18	0,40
Agricultura	-	0,35	0,00	0,17
Vegetação rala	-	-	0,14	0,21
Vazante	-	0,04	0,39	0,12
Nuvem	0,24	1,00	1,00	0,67
Sombra	-	-	0,89	0,89
IMAGEM LANDSAT 8 – 3 DE SETEMBRO DE 2013				
Água	0,57	0,57	0,60	1,00
Macrófitas	0,28	0,00	0,51	0,57
Solo exposto	0,29	0,46	0,29	0,55
Vegetação nativa	0,36	0,75	0,24	0,48
Agricultura	-	0,53	0,09	0,40
Vegetação rala	-	-	0,14	0,04
Vazante	-	0,27	0,18	0,54
Nuvem	0,30	0,42	0,16	1,00
Sombra	-	-	0,89	0,73
IMAGEM LANDSAT 8 – 21 DE OUTUBRO DE 2013				
Água	0,29	0,46	0,35	1,00
Macrófitas	0,32	0,09	0,07	0,83
Solo exposto	0,00	0,46	0,07	0,21
Vegetação nativa	0,30	0,07	0,18	0,12
Agricultura	-	0,24	0,05	0,26
Vegetação rala	-	-	0,04	0,15
Vazante	-	0,15	0,05	0,15
Nuvem	0,16	0,60	0,66	1,00
Sombra	-	-	0,30	0,72
IMAGEM LANDSAT 8 – 5 DE AGOSTO DE 2014				
Água	0,55	0,66	0,41	0,89
Macrófitas	0,68	0,93	0,03	0,89
Solo exposto	0,02	0,65	0,15	0,74
Vegetação nativa	0,66	0,65	0,35	0,83
Agricultura	-	0,38	0,13	0,10
Vegetação rala	-	-	0,18	0,15
Vazante	-	0,04	0,32	0,26
Nuvem	0,33	0,59	0,94	0,67
Sombra	-	-	0,83	0,52
IMAGEM LANDSAT 8 – 22 DE SETEMBRO DE 2014				
Água	0,70	0,72	0,72	1,00
Macrófitas	0,69	0,93	0,02	0,83
Solo exposto	0,23	0,09	0,61	0,57
Vegetação nativa	0,40	0,81	0,71	0,61
Agricultura	-	0,13	0,01	0,33
Vegetação rala	-	-	0,35	0,06
Vazante	-	0,08	0,62	0,35
Nuvem	0,21	0,14	0,52	0,52
Sombra	-	-	0,62	0,62
IMAGEM LANDSAT 8 – 28 DE JANEIRO DE 2015				
Água	0,23	0,46	0,37	0,94
Macrófitas	0,41	1,00	0,82	0,28
Solo exposto	0,09	0,57	0,37	0,42
Vegetação nativa	0,49	0,54	0,69	0,59
Agricultura	-	0,00	0,04	0,40
Vegetação rala	-	-	0,02	0,02
Vazante	-	0,04	0,01	0,00

* - N. S. – Não-supervisionada.

* Os valores em negrito e sublinhados representam o maior valor de Kappa individual encontrado nas imagens Landsat 8.

Fonte: Elaborada pelo autor.

5.3.4 *Classificação Supervisionada através de diferentes métodos, de imagens Landsat 8*

A análise da qualidade e eficiência da classificação das imagens de satélite foi obtida através do índice de Kappa, além dos valores e da classificação da qualidade do mapa temático obtido, esse índice estatístico permite um estudo detalhado e aprofundado com relação às limitações e dificuldades do classificador em separar e identificar algumas classes. Os problemas relacionados à determinação de alguns alvos podem ser constatados minuciosamente por meio das informações pontuais e individualizadas, obtidas através da matriz de confusão. Esse tipo de organização dos dados permitiu identificar as principais limitações dos classificadores supervisionados na espacialização das classes estudadas, gerados através de imagens Landsat 8 e analisados pelo o índice de Kappa.

Foram testados vários métodos de classificação supervisionada para detecção e diferenciação das classes na bacia hidráulica e entorno dos reservatórios Paus Brancos, Marengo e Nova Vida, usando a imagem Landsat 8 de setembro de 2014: Máxima Verossimilhança; Mínima Distância; KNN; Random Forest. Os resultados dos métodos de classificação testados neste item referem-se aos de melhor desempenho dos classificadores, variando-se o número de amostras por classe. A análise de sensibilidade dos métodos de classificação quanto ao número de amostras por classe está detalhada no item 5.6.

5.3.4.1 *Método de Máxima Verossimilhança*

O método de classificação Máxima Verossimilhança apresentou fortes limitação na determinação das classes macrófitas e agricultura, conseguindo acertar apenas um ponto de 20 nas duas classes citados (Tabela 22). Dos 20 pontos de macrófitas, 19 pontos foram confundidos com o uso vazante, sendo isso um grande problema, já que a classe macrófitas e vazante situa-se no entorno dos reservatórios e são de suma importância para a quantificação da área efetiva do reservatório na data do levantamento. Resultados idênticos foram obtidos por Silva (2007) em pesquisa que utilizou o classificador supervisionado Máxima Verossimilhança para a determinação das classes, através de imagens Landsat 5. O autor observou uma tendência a se classificarem áreas de vegetação de várzea (vazante) como sendo área de macrófitas.

O uso agricultura apresentou confusão com as classes vegetação rala (13 pontos de 20), solo exposto (4 pontos de 20), vegetação nativa (1 ponto de 20) e vazante (1 ponto de 20), mostrando uma limitação do classificador Máxima Verossimilhança na determinação das classes macrófitas e agricultura. Dificuldades semelhantes foram encontradas por Coulter *et al.* (2016), que encontraram limitações na separação de agricultura de floresta secundária e savana.

As classes água e vegetação nativa foram determinadas com maior eficiência, acertando 15 de 20 pontos. O uso água apresentou maior semelhança espectral com macrófitas (3 de 20 pontos), já vegetação nativa com vegetação rala (3 de 20 pontos), como pode ser observado na Tabela 22.

Tabela 22 – Matriz confusão obtida através da classificação supervisionada pelo método Máximo Verossimilhança, na imagem Landsat 8 de setembro de 2014

		P _o - Concordância observada									
		MAPA TEMÁTICO									
		ÁGU.	MAC.	SOL.	V.NAT	AGR	V. RA	VAZ.	NUV	SOM.	Σ
VERDADE TERRESTRE	ÁGUA	15	3	0	0	2	0	0	0	0	20
	MACRÓFITAS	0	1	0	0	0	0	19	0	0	20
	SOLO	0	0	13	1	0	5	1	0	0	20
	VEG NATIVA	0	0	0	15	0	3	2	0	0	20
	AGRÍCULTURA	0	0	4	1	1	13	1	0	0	20
	VEG RALA	0	1	2	7	0	10	0	0	0	20
	VAZANTE	1	0	0	2	2	1	14	0	0	20
	NUVEM	0	0	0	0	0	9	0	11	0	20
	SOMBRA	5	0	0	0	2	0	0	0	13	20
	SOMA	21	5	19	26	7	41	37	11	13	180

Fonte: Elaborada pelo autor.

5.3.4.2 Método de Mínima Distância

O segundo classificador supervisionado testado na pesquisa foi o método de Mínima Distância, onde diferentemente dos resultados encontrados através do classificador Máxima Verossimilhança, que apresentou grande dificuldades na determinação do uso macrófitas, este conseguiu separar bem esse uso dos demais, acertando 19 dos 20 pontos analisados, sendo o uso com maior eficiência na sua espacialização, como está apresentado na Tabela 23. Resultados semelhantes foram obtidos por Silva (2007) em pesquisa que utilizou os classificadores supervisionado Máxima Verossimilhança e Mínima Distância em estudo para avaliar a dinâmica de macrófitas na região amazônica, através de imagens Landsat 5, onde o mesmo conseguiu excelente resultado na espacialização das áreas ocupadas por macrófitas com o classificador Mínima Distância em relação ao classificador Máxima Verossimilhança.

Vale destacar a eficiência do classificador na determinação da classe sombra (acertando 18 pontos de 20), mas apresentou incoerências na determinação do uso água, onde conseguiu acertar apenas 3 de 20 pontos, sendo esse um ponto negativo do classificador.

A maior limitação do classificador Mínima Distância foi em relação à determinação do uso vegetação rala, onde o mesmo não conseguiu acertar nenhum dos 20 pontos. As áreas de vegetação rala foram confundidas com os alvos solo exposto (9 de 20 pontos), agricultura (6

de 20 pontos), vegetação nativa (4 de 20 pontos) e água (1 de 20 pontos), o que prejudica bastante o levantamento em áreas do Bioma Caatinga que, historicamente, vem sofrendo um intenso processo de degradação com substituição da vegetação nativa por vegetação mais rala em estado de recuperação.

Tabela 23 – Matriz confusão obtidas através da classificação supervisionada pelo método da Mínima distância, na imagem Landsat 8 de setembro de 2014

		P _o - Concordância observada									
		MAPA TEMÁTICO									
		ÁGU.	MAC.	SOL.	V.NAT	AGR	V. RA	VAZ.	NUV	SOM.	Σ
VERDADE TERRESTRE	ÁGUA	3	0	0	0	0	1	1	0	15	20
	MACRÓFITAS	1	19	0	0	0	0	0	0	0	20
	SOLO	0	0	16	1	1	0	1	1	0	20
	VEG NATIVA	0	0	1	11	6	0	2	0	0	20
	AGRÍCULTURA	0	0	12	0	6	0	2	0	0	20
	VEG RALA	1	0	9	4	6	0	0	0	0	20
	VAZANTE	0	6	1	0	1	1	10	0	1	20
	NUVEM	0	0	4	0	0	0	0	16	0	20
	SOMBRA	2	0	0	0	0	0	0	0	18	20
	SOMA	7	25	43	16	20	2	16	17	34	180

Fonte: Elaborada pelo autor.

5.3.4.3 Método de KNN

O classificador KNN, método de classificação que consiste na identificação de grupos de indivíduos com características similares e seu posterior agrupamento, foi testado variando-se a quantidade de amostras por classe selecionadas aleatoriamente para treinamento: 3 a 10 amostras, no total de 9 classes: água, macrófitas, solo exposto, vegetação nativa, agricultura, vegetação rala, vazante, nuvem e sombra. Já o parâmetro K-vizinhos mais próximos, do algoritmo KNN, variou de 1 até o valor resultante do produto do número de amostras por classe pelo número de classes (neste caso o limite superior do intervalo é 90).

O classificador KNN, terceiro método abordado na pesquisa, apresentou alta eficiência na espacialização do alvo sombra, conseguindo acertar os 20 pontos, ou seja, cem por cento de acerto. Além do alvo citado anteriormente, vale a pena destacar a precisão do método na determinação das classes macrófitas (19 de 20 pontos), vegetação nativa e sombra (acertou 18 de 20 pontos), que apresentaram um elevado grau de acerto, como pode ser visualizado na Tabela 24. O classificador KNN foi o único método a conseguir acertar em quatro classes do solo 18 ou mais pontos.

Assim como ocorreu com os classificadores Mínima Distância e Random Forest, o uso vegetação rala apresentou uma baixa taxa de acerto na espacialização através do classificador KNN, conseguindo acertar apenas 4 pontos de um total de 20. O uso vegetação

rala foi confundido com as classes solo exposto (3 de 20 pontos), vegetação nativa (6 de 20 pontos) e agricultura (7 de 20 pontos), conforme apresenta a Tabela 24. Hansen *et al.* (2002); Toneli (2008) afirmam que é difícil espacializar e separar diferentes classes de cobertura vegetal, haja visto que os valores de reflectância são muito semelhantes, além disso a separação também se torna complexa com relação ao período da imagem (período seco ou chuvoso), já que as plantas perdem as folhas no período seco.

Tabela 24 – Matriz confusão obtidas através da classificação supervisionada pelo método do KNN, na imagem Landsat 8 de setembro de 2014

		P _o - Concordância observada									
		MAPA TEMÁTICO									
		ÁGU.	MAC.	SOL.	V.NAT	AGR	V. RA	VAZ.	NUV	SOM.	Σ
VERDADE TERRESTRE	ÁGUA	15	0	0	0	0	0	1	0	4	20
	MACROFITAS	1	19	0	0	0	0	0	0	0	20
	SOLO	0	0	17	1	0	1	1	0	0	20
	VEG NATIVA	0	0	0	18	2	0	0	0	0	20
	AGRÍCULTURA	0	0	6	2	9	1	2	0	0	20
	VEG RALA	0	0	3	6	7	4	0	0	0	20
	VAZANTE	1	6	1	3	0	0	9	0	0	20
	NUVEM	0	0	2	0	0	0	0	18	0	20
	SOMBRA	0	0	0	0	0	0	0	0	20	20
	SOMA	17	25	29	30	18	6	13	18	24	180

Fonte: Elaborada pelo autor.

5.3.4.4 Método de Random Forest

Os resultados da matriz de confusão obtida através do classificador Random Forest, permite constatar que quatro classes apresentaram 18 pontos de acertos de um total de 20: água, macrófitas, nuvem e sombra (Tabela 25).

Tabela 25 – Matriz confusão obtidas através da classificação supervisionada pelo método do Random Forest na imagem Landsat 8 de setembro de 2014

		P _o - Concordância observada									
		MAPA TEMÁTICO									
		ÁGU.	MAC.	SOL.	V.NAT	AGR	V. RA	VAZ.	NUV	SOM.	Σ
VERDADE TERRESTRE	ÁGUA	17	0	0	0	0	0	2	0	0	20
	MACROFITAS	1	17	0	0	0	0	0	0	0	20
	SOLO	0	0	18	1	0	0	0	1	0	20
	VEG NATIVA	0	0	0	12	4	2	2	0	0	20
	AGRÍCULTURA	0	0	7	1	10	0	2	0	0	20
	VEG RALA	1	0	4	3	9	3	0	0	0	20
	VAZANTE	1	6	1	0	0	1	7	0	0	20
	NUVEM	0	0	1	0	0	0	0	19	0	20
	SOMBRA	1	0	0	0	0	0	0	0	19	20
	SOMA	21	23	31	17	23	6	13	20	19	180

Fonte: Elaborada pelo autor.

5.3.4.5 Análise comparativa dos métodos de classificação supervisionada – Landsat 8

Dos quatro classificadores supervisionados adotados na pesquisa, o KNN foi o método que apresentou melhor desempenho, com índice de Kappa geral de 0,68, considerado muito bom, seguido pelo classificador Random Forest (0,67) segundo melhor classificador, utilizando 5 amostras por classe e 8 árvores para a separação das classes (Tabela 26).

Tabela 26 – Comparação dos valores do coeficiente de Kappa condicional e geral obtidos através de diferentes métodos de classificação supervisionados para a imagem de setembro de 2014 obtida do sensor Landsat 8

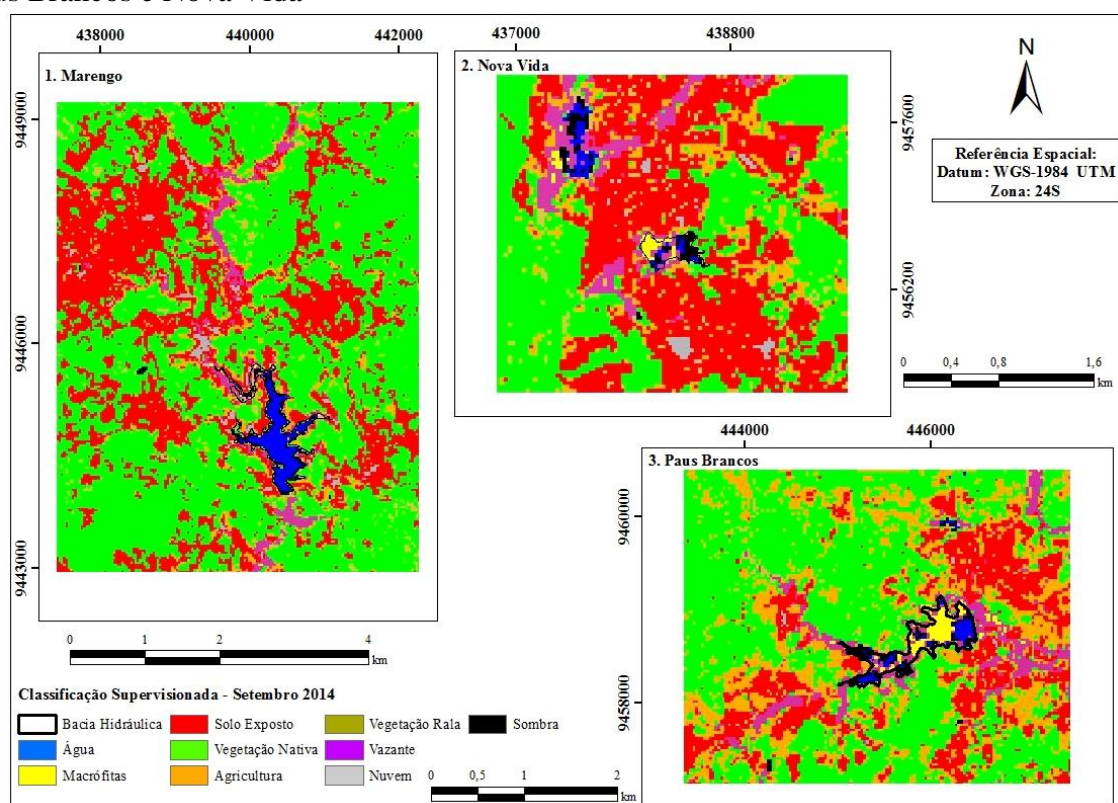
Classes	Máxima Veros.	Mínima Distância	KNN	Random Forest
Água	<u>1,00</u>	0,12	0,72	0,88
Macrófitas	0,83	<u>0,94</u>	<u>0,94</u>	<u>0,94</u>
Solo exposto	0,57	0,74	0,82	<u>0,88</u>
Vegetação nativa	0,61	0,51	<u>0,88</u>	0,56
Agricultura	0,33	0,21	0,39	<u>0,42</u>
Vegetação rala	0,06	0,00	<u>0,17</u>	0,12
Vazante	0,35	<u>0,45</u>	0,41	0,39
Nuvem	0,52	0,78	0,89	<u>0,94</u>
Sombra	0,62	0,88	<u>1,00</u>	0,94
Kappa Geral	0,53 (Boa)	0,49 (Boa)	0,68 (Muito boa)	0,67 (Muito boa)
Frequência de melhor desempenho	1	2	4	4

Fonte: Elaborada pelo autor.

Analisando o Kappa individual das classes apresentado na Tabela 24, pode-se constatar que o classificador KNN apresentou maior valor de Kappa individual em quatro classes (macrófitas = 0,94, vegetação nativa = 0,88, vegetação rala = 0,17 e sombra de nuvem = 1,00) em comparação aos outros classificadores avaliados. Os resultados encontrados pelo classificador KNN, foram obtidos utilizando 60 K-vizinhos e 7 amostras por classe (Figura 49).

É importante salientar a eficiência do classificador KNN na espacialização do alvo sombra de nuvem que apresentou um Kappa individual de 1,00, ou seja, o método conseguiu acertar todos os pontos utilizados na validação. É de suma importância a utilização de um classificador com alta eficiência na separação dos alvos nuvem e sombra dos demais classes, haja visto que são raras as imagens com ausência de nuvem e sombra de nuvem principalmente no estado do Ceará, como foi apresentado anteriormente como limitador para a escolha de imagens boas (sem a presença de nuvem e sombra de nuvem) no desenvolvimento de pesquisas que utilizem imagens de satélites.

Figura 49 – Espacialização das classes através da classificação supervisionada pelo método KNN, utilizando 60 K-vizinhos e 7 amostras por classe, no entorno dos reservatórios Marengo, Paus Brancos e Nova Vida




Fonte: Elaborada pelo autor

Toneli (2008), em sua pesquisa, utilizou imagens de satélite Landsat 5 para a obtenção de classes na bacia hidrográfica do rio Peruaçu, através do classificador KNN, e obteve um Kappa geral de 0,91, resultado muito superior ao encontrado na presente pesquisa, que foi 0,69. Os resultados superiores encontrados pelo autor podem ser explicados pelo fato que, na região, foram espacializados apenas classes semelhantes e considerou-se apenas uma imagem, diferentemente da presente pesquisa, que buscou representar as classes do solo através de imagens de satélite de diferentes anos em diferentes períodos (período seco e período chuvoso), e em um assentamento que apresenta classes do solo bastante heterogêneas.

Depois do classificador KNN, o método Random Forest, foi o segundo classificador com maior número de Kappa individual máximo. O classificador Random Forest apresentou Kappa máximo para as classes macrófitas (0,94) e solo exposto (0,88), como pode ser visualizado na Figura 50. O classificador selecionou o uso de 4 pontos de amostra e por classe e a determinação de 8 árvores para o melhor resultado, chegando assim a um valor de Kappa de 0,67. A determinação do número de pontos por classe e de árvores, faz parte de uma análise

de maximização dos resultados característica do próprio classificador Random Forest, na busca da melhor forma de separação das classes.

Figura 50 – Comparação dos valores do índice de Kappa, entre diferentes métodos classificadores supervisionados em imagens Landsat 8



Fonte: Elaborada pelo autor.

Como já mencionado anteriormente, os quatro métodos classificadores supervisionados analisados apresentaram dificuldades na espacialização do uso vegetação rala, o que pode ser explicado pela semelhança dos valores de resposta espectral que o alvo possui em relação a outros como agricultura. Além disso, o satélite Landsat 8 é um sensor imageador multiespectral, apresentando dificuldade na separação de alvos com reflectância próxima.

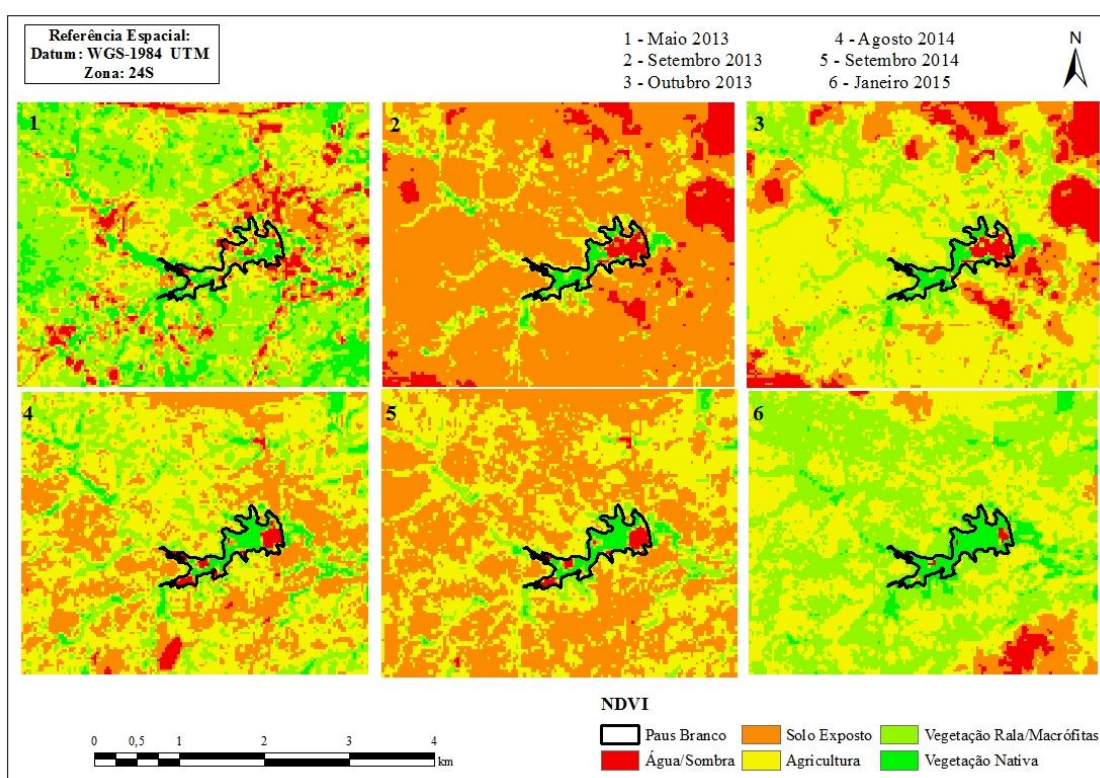
5.4 Determinação das classes através do NDVI

O Índice de Vegetação da Diferença Normalizada (NDVI) é um indicador da proporção e da condição da vegetação verde, onde geralmente para superfícies com presença de alguma vegetação o valor do NDVI é positivo, para superfícies sem vegetação o valor é nulo, já para a água e nuvens o valor geralmente é negativo. Determinar das classes usando NDVI apresentou limitação por não conseguir diferenciar espelho d'água de sombra de nuvem, como pode ser observado na Figura 51 para o reservatório Paus Brancos. Araújo (2010), em seu trabalho realizado na Baixada Santista, mostra as limitações na utilização do NDVI na separação de água e sombra de nuvem. Outra limitação do método está relacionada à identificação de corpos hídricos, pois a espacialização de espelhos d'água mostra uma grande variedade de turbidez, devido a esse fator os índices de água de diferença normalizada (NDWI),

como proposto por muitos pesquisadores, não dão resultados adequados no caso de lagos, conforme apresentam Bhardwaj *et al.* (2015).

Outro ponto negativo notável está relacionado com o período da imagem. A caatinga apresenta grande variabilidade interanual, justificada pela peculiaridade da estrutura vegetal com perda de folhagem no período de estiagem, resultando em valores de NDVI extremamente baixos confundindo-se com solo exposto, por exemplo, e recomposição no período chuvoso, elevando os valores de NDVI a taxas superiores a 0,3 na área de estudo (Figura 51).

Figura 51 - NDVI no entorno do reservatório Paus Brancos



Fonte: Elaborada pelo autor.

Quanto mais próximo do extremo positivo, maior a densidade da cobertura vegetal, ou seja, condiz com seu estágio denso e desenvolvido. Esse valor diminui gradativamente para cobertura vegetal menos densa, que apresenta valores positivos, porém não muito elevados. O NDVI é utilizado para identificar a presença de vegetação verde na superfície, permitindo caracterizar sua distribuição espacial e a evolução do seu estado ao longo do tempo, que é determinada a partir das variações das condições climáticas dominantes e analisada a partir de imagens temporais. Ke *et al.* (2015) tentaram diferenciar classes usando NDVI calculado através de imagens Landsat 8 e verificaram que as áreas cobertas por vegetação têm melhor

acordo com NDVI do que as áreas com ausência de vegetação.

Embora o Índice de Vegetação da Diferença Normalizada (NDVI) seja bastante utilizado no sensoriamento remoto, o mesmo apresenta algumas limitações. Segundo Jensen (2009), o índice sofre influência de radiância de trajetória atmosférica, apresenta saturação em relação a altos valores de Índice de Área Foliar (IAF) e tem sensibilidade às mudanças do substrato do dossel, como o solo. Elmore *et al.* (2000) afirmam que outra desvantagem do índice NDVI está no fato deste ser altamente influenciado pelo brilho e efeito espectral do solo, fato que prejudica as avaliações sobre a vegetação.

5.5 Classificação de imagens Hyperion

5.5.1 *Espacialização das classes através da classificação não-supervisionada*

Buscando a obtenção de uma maior eficiência na separação das classes: água, macrófitas, solo exposto, vegetação nativa, vegetação rala, vazante, nuvem e sombra, buscou-se o uso de uma imagem de melhor resolução espectral (hiperespectral), que pudesse apresentar melhores resultados do que os encontrados através da classificação de imagens Landsat 8 (multiespectral). Jafari e Lewis (2012) enfatizam que a maior resolução espectral de imagens hiperespectrais pode melhorar a discriminação de componentes, especialmente de vários tipos de vegetação.

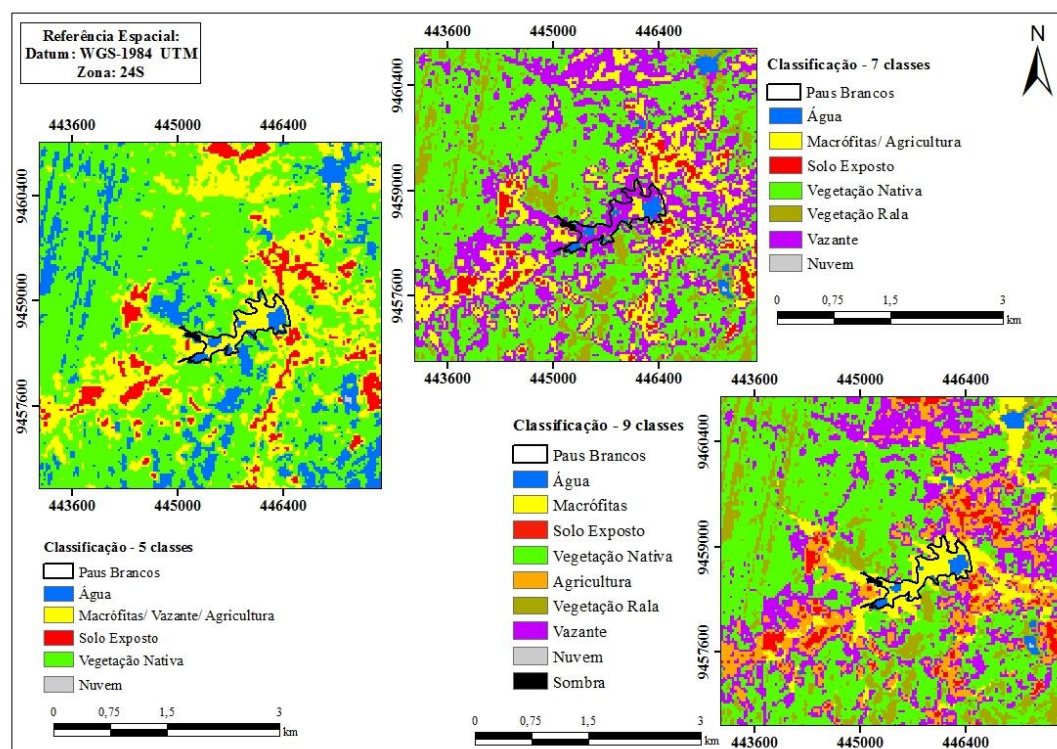
A classificação não-supervisionada da imagem do satélite Hyperion com data em 19 de outubro de 2014 baseou-se no método de classificação ISODATA, na qual os elementos de uma cena estão associados a classes espectrais, sem qualquer conhecimento prévio da existência das classes, com resultados apresentados nas Figuras 52 e 53 para os reservatórios Paus Brancos e Marengo, respectivamente. Nesta classificação, utilizou-se a composição R – 51, B – 161 e G – 19: As bandas foram obtidas através do classificador SVM (suport vector machine), que indicou essas três bandas como sendo as mais adequadas entre as 155 bandas corrigidas atmosféricamente do satélite Hyperion.

Segundo Pal e Mather (2005), existe uma grande variedade de propostas de algoritmos para a classificação de imagens hiperespectrais, onde diferentes técnicas provenientes de diversas áreas de pesquisa estão sendo utilizadas como base para o desenvolvimento desses algoritmos, entre elas, a máquina de vetores-suporte (SVM).

Neste método, não há interferência do analista na fase de treinamento do algoritmo de classificação as classes espectrais são definidas com base no agrupamento de pixels que apresentam similaridade espectral através da aplicação de métodos de agregamento, utilizando medidas de similaridade. Neste caso, levou-se em consideração apenas os valores numéricos da reflectância, como propuseram Richards e Jia (1999) em estudo sobre separação de classes através da classificação não-supervisionada pelo classificador ISODATA.

A classificação adotando 5 classes apresentou um baixo desempenho na classe água, apresentando inconsistências no entorno dos dois reservatórios estudados (Paus Brancos e Marengo) como pode ser visualizado nas Figuras 52 e 53. A qualidade do mapa temático obtido pela classificação não-supervisionada com 5 classes foi considerada como boa mesmo com as limitações decorrentes do número insuficiente de classes, com coeficiente Kappa de 0,43 (Tabela 25).

Figura 52 - Espacialização das classes no entorno dos reservatórios Paus Brancos, obtido através da classificação não-supervisionada com 5, 7 e 9 classes (R-51; B-161; G-19), imagem Hyperion



Fonte: Elaborada pelo autor.

Os resultados obtidos pela classificação ISODATA com 7 classes usando imagens do satélite Hyperion conseguiu espacializar melhor o uso água em relação a classificação com 5 classes, mas em contrapartida apresentou pobre desempenho em relação as classes vazante e macrófita como pode ser visualizado na Tabela 25.

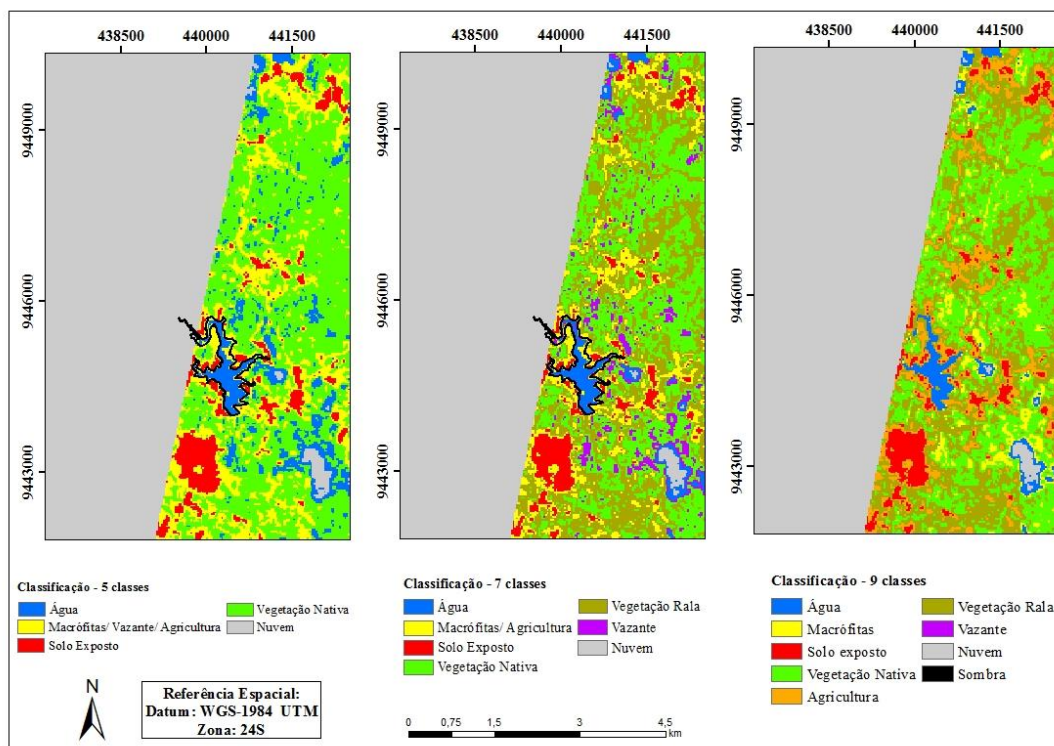
Uma deficiência percebida na análise realizada neste estudo se refere à limitação por agrupar as classes macrófitas e agricultura utilizando 5 e 7 classes. Entretanto, outros estudos indicaram que o algoritmo ISODATA apresenta grande potencial na discriminação de áreas agrícolas em imagens de alta resolução espacial como mostram Panda *et al.* (2009).

A classificação adotando nove classes através da classificação não-supervisionada pelo método ISODATA, apresentou bastante coerência na espacialização das diferentes classes abordados existentes no entorno dos reservatórios estudados, como está ilustrado na Figuras 52 e 53.

Analisando os resultados índice de Kappa obtido na classificação não-supervisionada adotando-se 5, 7 e 9 classes, pode-se constatar que a classificação com 9 classes

apresentou o melhor resultado, com um Kappa de 0,48, o que indica um melhor desempenho do método em comparação com aqueles obtidos para 5 e 7 classes, imagem Hyperion

Figura 53 - Espacialização das classes no entorno do reservatório Marengo, obtido através da classificação não-supervisionada com 5, 7 e 9 classes de uso (R – 51; B – 151; G – 19)



Fonte: Elaborada pelo autor.

Comparando os resultados do índice de Kappa encontrados na classificação não-supervisionada pelo método ISODATA das imagens dos satélites Landsat 8 (imagem do 22 setembro de 2014) e do Hyperion (imagem dia 19 de outubro de 2014), ou seja, de dias próximos, pode-se observar que o Landsat 8 foi melhor na classificação com 5 e com 7 classes em relação ao Hyperion. Já o Hyperion apresentou maior valor de Kappa na classificação com 9 classes em comparação ao Landsat 8 (Tabela 27), apesar de os resultados terem sido bem semelhantes

Tabela 27 - Valores do Kappa condicional, obtidos através da classificação não-supervisionada (ISODATA) com 5, 7 e 9 classes das imagens Hyperion e Landsat 8

Classificação não-supervisionada						
Classes	Imagem Landsat - 8 09/2014			Imagem Hyperion - 10/2014		
	5 classes	7 classes	9 classes	5 classes	7 classes	9 classes
Água	0,70	0,72	0,72	0,64	0,93	0,79
Macrófitas	0,69	0,93	0,02	0,22	0,36	1,00
Solo exposto	0,23	0,09	0,61	0,36	0,79	0,86
Vegetação nativa	0,40	0,81	0,71	0,47	0,61	0,21
Agricultura	-	0,13	0,01	-	0,00	0,85
Vegetação rala	-	-	0,35	-	0,00	0,00
Vazante	-	0,08	0,62	-	0,00	0,00
Nuvem	0,21	0,14	0,52	0,43	0,30	0,38
Sombra	-	-	0,62	-	-	0,33
Kappa Geral	0,44	0,39	0,46	0,43	0,30	0,47
	Boa	Razoável	Boa	Boa	Razoável	Boa

Fonte: Elaborada pelo autor.

5.5.2 Classificação supervisionada da imagem Hyperion método SVM

Devido a quantidade de bandas que o sensor Hyperion possui, fez-se necessário a determinação das bandas que apresentem melhores resultados na separação das classes avaliados no presente trabalho. Os pesos das bandas mais importantes, foram avaliadas através do classificador supervisionado SVM, utilizado em diversas pesquisas com o intuito de determinar as classes com precisão (BLANCO *et al.*, 2014; PETROPOULOS *et al.*, 2012). O algoritmo identificou um ranking com o desempenho de cada uma das 155 bandas no processo de classificação da imagem Hyperion, o que resultou em um coeficiente Kappa de 0,81, considerado como excelente.

Afim de se obter as bandas que pudessem expressar com alta exatidão as classes através de um classificador supervisionado mais simples e comum, como é o caso do método Máxima Verossimilhança, buscou-se determinar a melhor composição RGB, entre as dez bandas com melhor desempenho, encontrados através da classificação SVM. As bandas encontradas como sendo as de melhores para uma composição RGB foram: 51 no canal R (vermelho), 161 no canal G (verde) e 19 no canal B (azul) (Tabela 28).

Tabela 28 - Desempenho das bandas do satélite Hyperion para determinação das classes

Banda	Desempenho (%)	Rank
161 - G	92,7	1°
148	91,6	2°
145	91,6	3°
146	91,5	4°
206	91,5	5°
216	91,4	6°
197	91,3	7°
19 - B	91,2	8°
143	90,9	9°
51 - R	90,9	10°
Kappa = 0,81 – Excelente		

Fonte: Elaborada pelo autor.

George *et al.* (2014), em pesquisa realizada na região ocidental do Himalaia, buscando diferenciar espécies arbóreas através de imagens hiperespectrais através do satélite Hyperion, utilizou o classificador SVM para a determinação dos alvos, onde o mesmo obteve um Kappa de 0,79, mostrando a eficiência desse classificador na espacialização de cobertura vegetal.

5.5.3 Classificação supervisionada da imagem Hyperion

5.5.3.1 Método de Máxima Verossimilhança - Hyperion e Landsat 8

Os resultados produzidos na classificação supervisionada através do método Máxima Verossimilhança no entorno dos reservatórios Paus Brancos e Marengo, conseguiu expressar as classes visualizados e levantados em campo, como pode ser observado na Tabela 29 e nas Figuras 54 e 55.

Nesta pesquisa adotou-se a composição das bandas R-51, G-161 e B-19, por apresentar melhor desempenho na classificação da imagem Hyperion.

Comparando os métodos de classificação SVM e Máxima Verossimilhança aplicados na imagem Hyperion, pode-se constatar que o SVM apresentou melhor desempenho na separação das classes, apresentando um Kappa de 0,81, sendo classificado como excelente, contra um Kappa de 0,78 encontrado pelo classificador Máxima Verossimilhança, sendo classificado como Muito Bom, como está exposto na Tabela 29.

Tabela 29 – Valores do índice de Kappa individual, obtidos através da classificação supervisionada por diferentes métodos da imagem Hyperion de outubro de 2014

Classes	SVM Hyperion	Máxima Verossimilhança Hyperion	Máxima Verossimilhança Landsat 8
Água	<u>0,98</u> - Excelente	0,97 - Excelente	1,00 - Excelente
Macrófitas	<u>0,91</u> - Excelente	0,88 - Excelente	0,83 - Excelente
Solo exposto	<u>0,70</u> - Muito Boa	0,69 - Muito Boa	0,57 - Boa
Vegetação nativa	<u>0,77</u> - Muito Boa	0,74 - Muito Boa	0,61 - Muito Boa
Agricultura	<u>0,76</u> - Muito Boa	0,63 - Muito Boa	0,33 - Razoável
Vegetação rala	<u>0,66</u> - Muito Boa	0,59 - Boa	0,06 - Ruim
Vazante	0,61 - Muito Boa	<u>0,73</u> - Muito Boa	0,35 - Razoável
Nuvem	<u>0,90</u> - Excelente	0,89 - Excelente	0,52 - Boa
Sombra	<u>0,91</u> - Excelente	0,91 - Excelente	0,62 - Muito Boa
Kappa Médio	0,81 Excelente	0,78 Muito Boa	0,53 Boa
Nº Kappa máximos	8	1	0


Fonte: Elaborada pelo autor.

A utilização do classificador Máxima Verossimilhança na imagem Hyperion apresentou melhor desempenho (Kappa 0,78 classificado como muito boa) em comparação aos resultados encontrados no processamento da imagem Landsat 8 com Kappa de 0,53, sendo classificado como Boa.

Tisot *et al.* (2007), em pesquisa realizada na região agrícola de Franca no estado de São Paulo, buscou determinar as classes existentes na região através de imagens do satélite

Hyperion, utilizando o classificador supervisionado Máxima Verossimilhança. Usando a imagem hiperespectral, os autores conseguiram separar com eficiência classes com comportamento espectral semelhantes (café, cana-de-açúcar, mata e pastagem) utilizando as bandas do sensor Hyperion R-48, G-151 e B-31 (composição RGB), bandas essas próximas à faixa utilizada na presente pesquisa.

Figura 54 - Espacialização das classes no entorno dos reservatórios Marengo obtido através da classificação supervisionada (R – 51; G – 161; B – 19) da imagem do satélite Hyperion de 19/10/2014

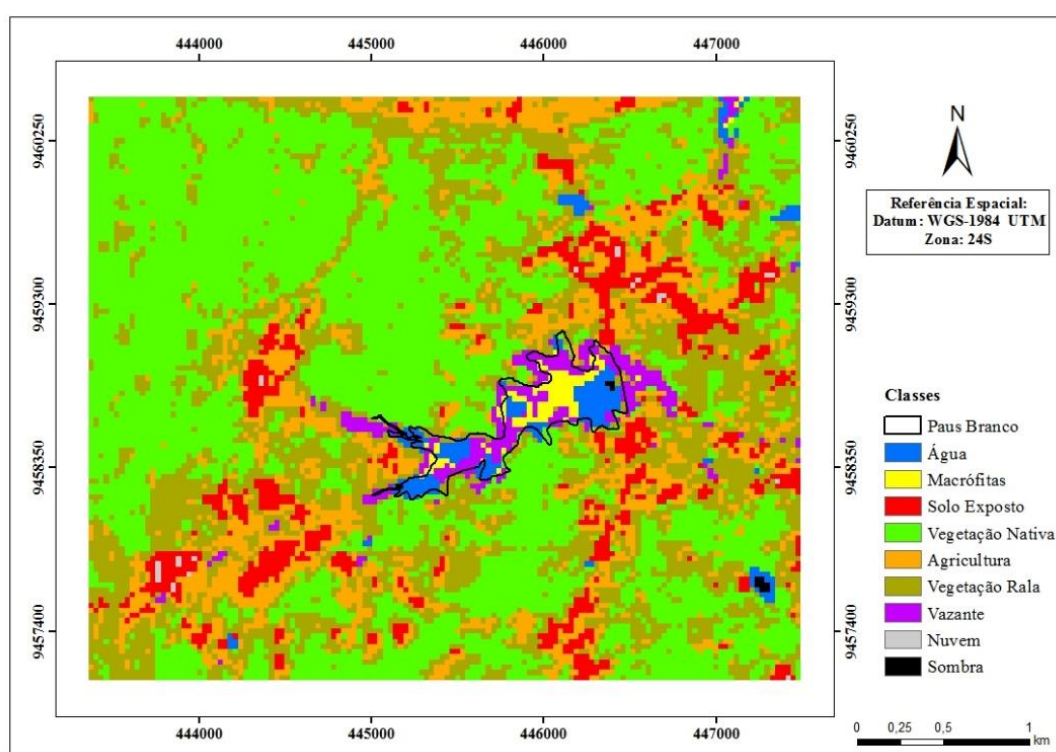


Fonte: Elaborada pelo autor.

A utilização de uma imagem de melhor qualidade espectral, ou seja, de um satélite hiperespectral, na quantificação das faixas de reflectância, como o caso daquelas obtidas pelo sensor Hyperion, promoveu um ganho significativo na separação das classes existentes na área de estudo, seja usando o método SVM ou de Máxima Verossimilhança como mostram os

resultados anteriores, com Kappa de 0,81 (usando 155 bandas) e 0,78 (usando as bandas R – 51, G – 161, e B – 19), respectivamente. O método conseguiu separar adequadamente as classes macrófitas, vazante, agricultura e vegetação rala, apesar destas classes possuírem respostas espectrais próximas. George *et al.* (2014) salientam que as informações relacionadas a reflectância obtidas nas bandas estreitas de dados do satélite Hyperion têm potencial para capturar variabilidade espectral das espécies de plantas, melhorando assim o mapeamento de diferentes espécies vegetais.

Figura 55 - Espacialização das classes no entorno do reservatório Paus Brancos, obtido através da classificação supervisionada (R – 51; B – 161; G – 19), da imagem Hyperion de 19/10/2014



Fonte: Elaborada pelo autor.

5.5.3.2 Análise comparativa dos métodos de classificação supervisionada testados – Hyperion

Realizou-se a análise comparativa dos quatro métodos de classificação aplicados à imagem Hyperion de 19 de outubro de 2014, quais sejam: Máxima Verossimilhança, KNN, Mínima Distância e Random Forest. Os resultados dos métodos de classificação testados neste item referem-se aos de melhor desempenho dos classificadores, variando-se o número de amostras por classe. A análise de sensibilidade dos métodos de classificação quanto ao número de amostras por classe está detalhada no item 5.6.

Na classificação supervisionada usando o método de Máxima Verossimilhança para a imagem Hyperion de outubro de 2014, as classes água, macrófitas, nuvem e sombra apresentaram valores de Kappa individual superiores a 0,8, sendo assim classificados com excelente, conforme sumariza a Tabela 30. O uso vegetação rala foi o que apresentou menor valor de Kappa individual (0,59, boa), sendo bem superior aos valores encontrados na análise das imagens Landsat 8, o que reforça a importância da utilização de imagens hiperespectrais para estudo com alta diversidade de classes. A eficiência na separação das classes com reflectâncias homogêneas está diretamente ligada à qualidade espectral da imagem Hyperion, ou seja, ao número de bandas que o satélite dispõe, possibilitando a identificação de alvos com reflectâncias sobreposta.

O Kappa geral encontrado na classificação supervisionada usando a imagem do satélite Hyperion foi 0,78 sendo classificado com muito bom. A análise de desempenho do classificador Máxima Verossimilhança pode ser visualizada na Tabela 30. Resultado semelhante foi obtido por Blanco *et al.* (2014) em pesquisa realizado para analisar as classes (arbustos, área de pastos, fragmentos de rocha, deserto) na região de pastos patagônicos, no sul da Argentina, onde os autores encontraram um Kappa de 0,77 na classificação utilizando imagens Hyperion. Resultados semelhantes foram obtidos também por George *et al.* (2014) em pesquisa realizada no Himalaia visando a separação de diferentes espécies vegetais, onde a classificação apresentou valores de Kappa geral de 0,79 (Hyperion) e 0,60 (Landsat 8), mostrando um melhor desempenho do satélite Hyperion do que o satélite Landsat 8 na espacialização dos alvos.

Tabela 30 – Valores do índice de Kappa condicional, obtidos através da classificação supervisionada da imagem Hyperion de outubro de 2014 e Landsat 8 de setembro 2014


Classes	Máxima Verossimilhança	KNN	Mínima Distância	Random Forest
Água	<u>0,97</u>	0,67	0,67	0,62
Macrófitas	<u>0,88</u>	0,77	0,76	0,72
Solo exposto	0,69	<u>0,83</u>	0,72	0,57
Vegetação nativa	<u>0,74</u>	0,61	0,66	0,56
Agricultura	0,63	<u>0,94</u>	0,56	0,51
Vegetação rala	0,59	0,46	0,42	<u>0,65</u>
Vazante	0,73	0,50	0,45	<u>0,76</u>
Nuvem	0,89	0,83	<u>0,94</u>	<u>0,94</u>
Sombra	0,91	<u>1,00</u>	<u>1,00</u>	<u>1,00</u>
Kappa Geral	0,78	0,73	0,69	0,70
	Muito Boa	Muito Boa	Muito Boa	Muito Boa
Nº Kappa máximos	3	3	2	3

Fonte: Elaborada pelo autor.

A análise do Kappa da imagem Hyperion mostrou que o classificador supervisionado Máxima Verossimilhança (Kappa geral = 0,78) apresentou melhores resultado do que o classificador KNN (Kappa geral = 0,73), Random Forest (Kappa geral de 0,70) e Mínima Distância (Kappa geral de 0,69) como está exposto na Tabela 28. O resultado pode ser explicado pelo fato de o classificador KNN trabalhar a exclusão de pontos, e na pesquisa está sendo demonstrado que o fator preponderante na determinação das classes do solo é faixa das bandas, quanto mais estreita a banda, melhor o resultado obtido na classificação, comprovando também que o processo de otimização para escolha das melhores bandas se mostrou eficiente.

Os valores do Kappa individual obtidos através classificação supervisionada da imagem do satélite Hyperion pelo método Máxima Verossimilhança, foram superiores em três classes (água, macrófitas e vegetação nativa) classificadores KNN, Mínima Distância e Random Forest, resultado diferente dos obtidos pela imagem Landsat 8, que apresentou os melhores resultados através da classificação pelo método KNN. A utilização das imagens hiperespectrais obtidas pelo sensor orbital Hyperion, que possui altíssima resolução espectral, aliado com o classificador eficiente, foi capaz de fornecer medidas espectrais em bandas estreitas e contínuas para cada pixel da imagem, definindo de forma precisa as curvas espectrais, potencializando a discriminação de diferentes componentes, particular de cada uso e/ou alvo, abordado na presente pesquisa.

Figura 56 - Desempenho do método de Máxima Verossimilhança na classificação supervisionada e não-supervisionada (5, 7 e 9 classes) de imagens Hyperion



Fonte: Elaborada pelo autor.

Galvão *et al.* (2005), em pesquisa realizada para diferenciar tipos de espécies vegetais, observaram que a imagem hipespectral derivada do satélite Hyperion apresentou importante capacidade de mostrar bandas (determinadas regiões do espectro eletromagnético) de absorção, como a presença de água na folha, que se mostram úteis para diferenciar tipos de espécies vegetais, como é o caso da vegetação nativa, agricultura, vazante, macrófita e vegetação rala, abordadas nesta pesquisa.

Na Figura 56, apresenta-se o desempenho do método de Máxima Verossimilhança na classificação não supervisionada (5, 7 e 9 classes) e supervisionado da imagem Hyperion. É nítida a superioridade do classificador supervisionado em relação ao não-supervisionado, na análise de imagens hiperespectrais, assim como foi observado nos resultados gerados pelo processamento das imagens multiespectrais (Landsat 8), recomendando-se o uso preferencial pela utilização dos classificadores supervisionados na determinação de classes no entorno de reservatórios em regiões semiáridas, independentemente da resolução espectral do satélite.

5.6 Análise de sensibilidade quanto ao número de amostras por classe

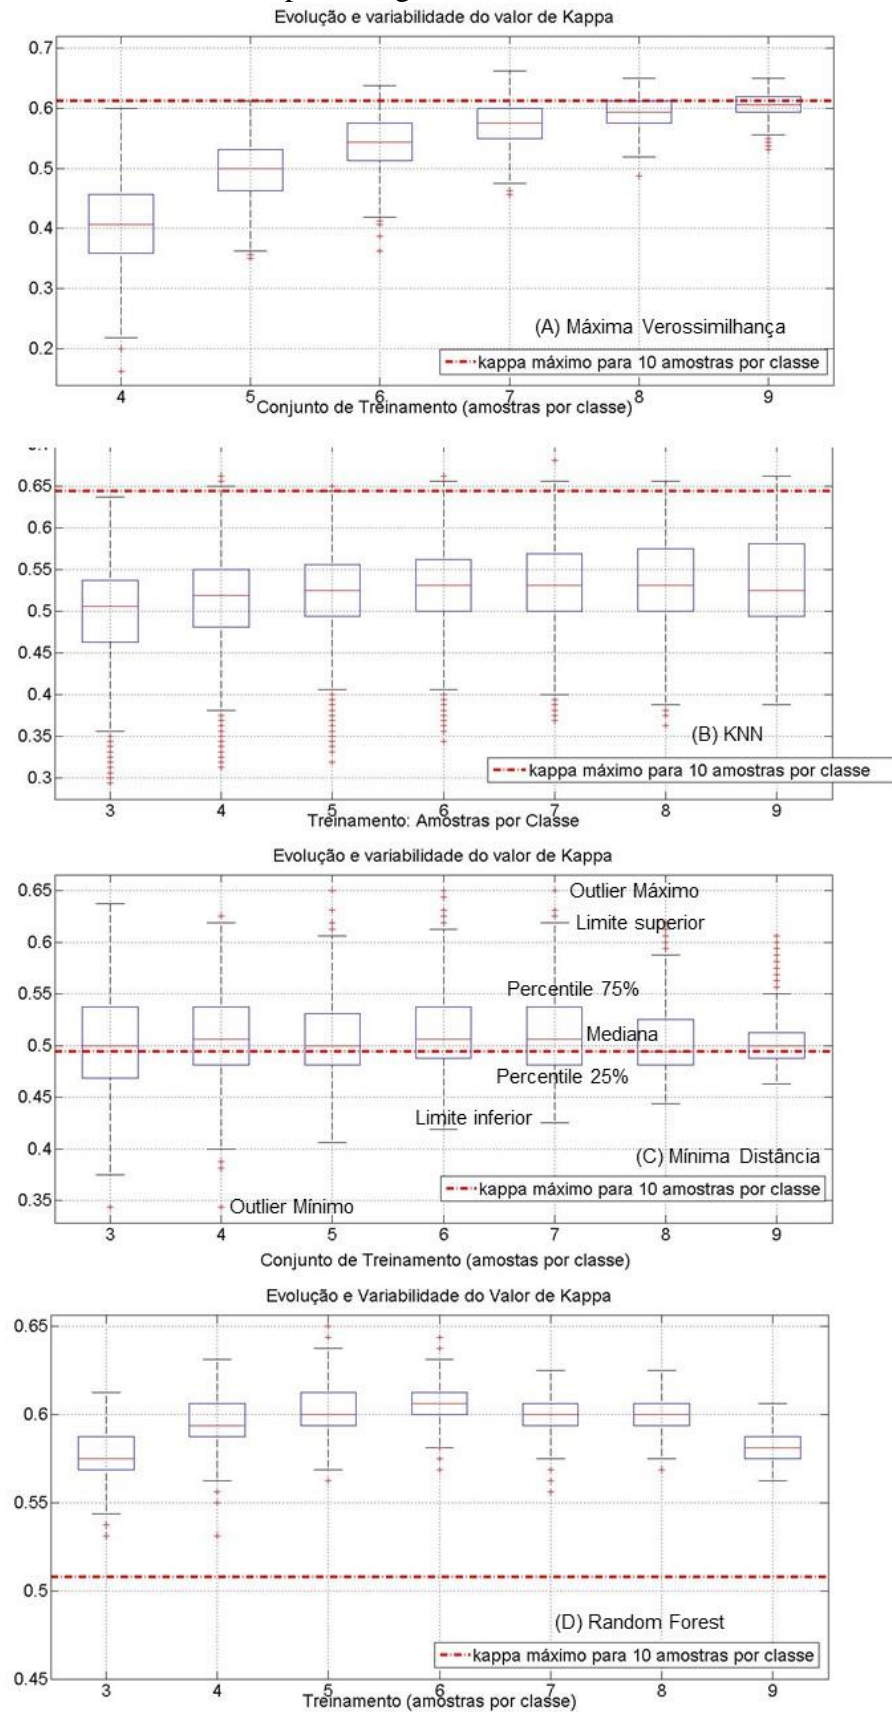
5.6.1 Sensor Landsat 8

Analisou-se a sensibilidade dos classificadores Máxima Verossimilhança, KNN, Mínima Distância e Random Forest a variações do número de amostras por classe na classificação da imagem Landsat 8 de 22 de setembro de 2014 (Figura 57).

Os gráficos do tipo *box plot* foram utilizados para avaliar e comparar as distribuições de amostragens, propiciando a visualização da amplitude dos resultados obtidos através dos parâmetros descritivos mediana, percentil 75%, percentil 25%, limite superior, limite inferior, *outlier* máximo e *outlier* mínimo. É importante observar o ponto de *outlier* máximo encontrado por cada classificador supervisionado, pois o mesmo representa o maior valor de Kappa obtido pelo classificador através de diferentes simulações, ou seja, representa o melhor resultado que o classificador pode gerar. O *outlier* só é obtido em uma única situação, ou seja, significa a potencialização dos resultados gerados pelo método classificatório. Já o limite superior pode ser obtido por um ou pelo conjunto de valores de Kappa que ocorre mais de uma vez, durante as diversas simulações ha que foram submetidas o classificador.

Os resultados do desempenho do método de classificação KNN para diferentes valores de K-amostras e K-vizinhos estão apresentados na Figura 57.

Figura 57 – Análise de sensibilidade dos classificadores Máxima Verossimilhança, KNN, Random Forest e Mínima Distância para imagem Landsat 8 de 22 setembro de 2014



Fonte: Elaborada pelo autor.

Pode-se observar que o valor máximo de Kappa é obtido na simulação com 7 K-amostras. Como se pode perceber, simulação com 60 K-vizinhos, apresenta o valor máximo do coeficiente Kappa obtido através da análise dos parâmetros descritivos do *outlier* (Figura 57).

Os resultados da análise de sensibilidade realizada para os diferentes classificadores supervisionados ilustrados na Figura 57, mostram que o número fixo de amostra de treinamento prejudica a obtenção de valores de Kappa máximos, recomendando-se a análise criteriosa e individualizada da variação do número de pontos por classe em cada classificador utilizado.

Os classificadores Máxima Verossimilhança e KNN apresentaram valor de Kappa máximo utilizando-se 7 amostras por classe. O classificador KNN apresentou o melhor desempenho entre os quatro métodos avaliados na espacialização de classes no entorno dos reservatórios no Assentamento 25 de Maio. Já o método Mínima Distância atingiu o melhor valor de Kappa usando 5 amostras por classe. E por último o classificador Random Forest conseguiu o maior valor de Kappa com 5 amostras por classe.

5.6.2 *Sensor Hyperion*

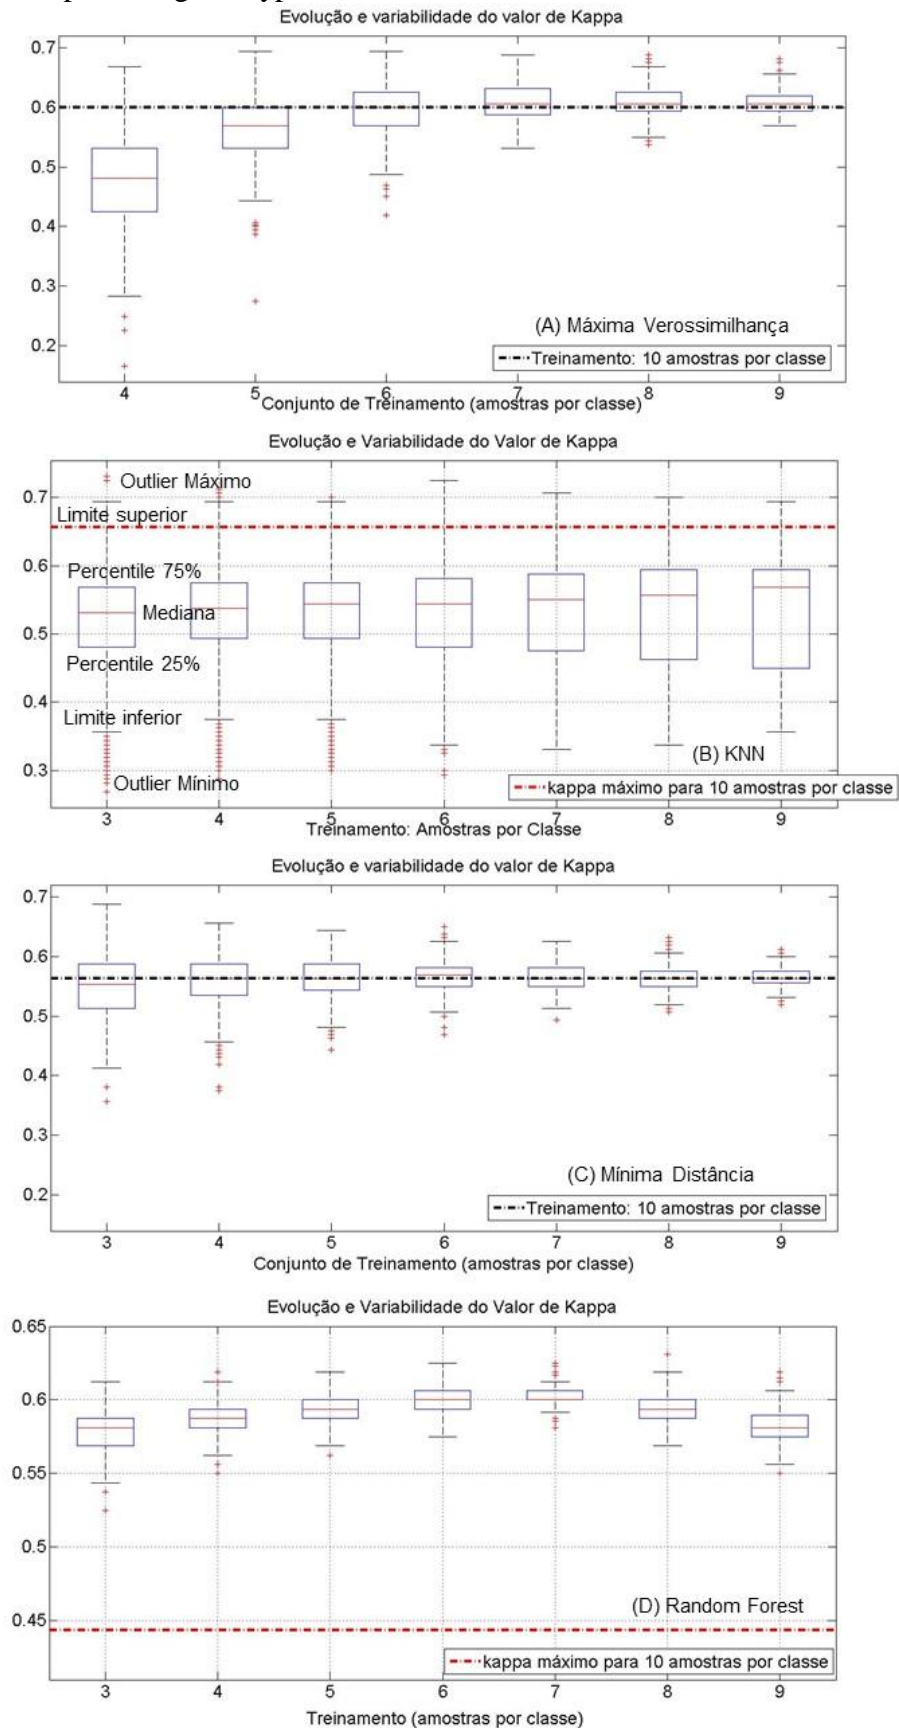
Analisou-se a sensibilidade dos classificadores Máxima Verossimilhança, KNN, Mínima Distância e Random Forest a variações do número de amostras por classe na classificação da imagem Hyperion de 19 de outubro de 2014 (Figura 58).

Os resultados do desempenho do método de classificação Máxima Verossimilhança para diferentes números de amostras são apresentados na Figura 58, propiciando a visualização da amplitude dos resultados obtidos através do classificador supervisionado Máxima Verossimilhança para a potencialização dos valores de Kappa. Pode-se observar que o valor máximo de Kappa é obtido na simulação com 6 amostras. Como se pode perceber, simulação com 6 amostras por classe, apresenta o valor máximo do coeficiente Kappa obtido através da análise dos parâmetros descritivos do *outlier*.

Os resultados da análise de sensibilidade realizada para os diferentes classificadores supervisionados (Figura 58) mostra que o número fixo de amostra de treinamento prejudica a obtenção de valores de Kappa máximos, recomendando-se a análise criteriosa e individualizada do número de pontos em cada classificador utilizado.

O classificador Máxima Verossimilhança apresentou valor de Kappa máximo utilizando-se 6, pontos por classe, sendo esse método de classificação de imagem a apresentar o melhor desempenho entre os quatro métodos avaliados na espacialização de classes.

Figura 58 – Análise de sensibilidade dos classificadores Máxima Verossimilhança, KNN, Mínima Distância para imagem Hyperion de 19 outubro de 2014



Já o classificador KNN obteve o Kappa máximo com 3 amostra por classe, o método Mínima Distância apresentou o melhor desempenho usando 3 amostras por classe, e por último, o classificador Random Forest conseguiu o maior valor de Kappa com 4 amostras por classe.

5.7 Análise de desempenho das classificações de imagens Landsat 8 e Hyperion

5.7.1 Aplicação para reservatórios do Assentamento 25 de Maio usando dados de VANT

Com o intuito de investigar o desempenho do modelo na classificação de imagens Landsat 8 e Hyperion da região estudada em período distinto do analisado inicialmente na pesquisa, realizou-se outro levantamento em campo no período de novembro de 2015. A campanha concentrou esforços na caracterização das classes na época, a partir de dados de um sobrevoo usando um VANT na porção do reservatório Paus Branco mais próxima do barramento, dada a restrita autonomia de bateria do equipamento. Este levantamento produziu um mapa com resolução espacial de 0,5 metros. Adicionalmente, foram levantados pontos de classes na bacia hidráulica do reservatório São Nicolau e entorno com um GPS de navegação.

Nesta aplicação, utilizaram-se as mesmas composições de bandas propostas na etapa inicial da pesquisa de classificação das classes do solo (Hyperion R-51, G-161, B-19 e Landsat 8 R-6, G-5, B-4). Novamente, os valores de Kappa geral encontrados através da utilização da imagem do Hyperion (0,73 e 0,83, com 5 e 3 classes, respectivamente) foram superiores aos valores obtidos através do Landsat 8 (0,39 e 0,49 com 5 e 3 classes, respectivamente), como pode ser visualizado na Tabela 31.

A validação das classes não contemplou as classes vegetação nativa e agricultura devido o não imageamento pelo VANT das áreas contendo essas classes. Os alvos nuvem e sombra também não foram validados já que o VANT voou em uma altitude abaixo das nuvens a alta resolução das imagens obtidas, os dados extraídos para descrição e identificação das classes de paisagem tornam-se mais confiáveis e fiéis à realidade de campo tanto em relação à espacialização, quanto em relação à fidelidade na descrição e identificação da cobertura da terra.

Silva *et al.* (2015), em pesquisa realizada utilizando um VANT para análise do uso da terra na Área de Preservação Ambiental (APA) do Rio Mamanguape, conseguiram resultados interessantes na determinação das classes, e afirmam que a utilização de VANTs tanto pode contribuir para otimização dos estudos agropecuários, quanto dos estudos ambientais naturais e culturais, reduzindo gastos e gerando dados mais fiéis à realidade de campo.

Tanto os resultados do Hyperion como do Landsat 8 foram melhores na análise considerando 3 classes do solo, onde as três classes considerados foram água, macrófitas e vazante, o que está diretamente ligado ao tamanho da área da imagem do VANT, que contemplou uma área pequena ocupada em grande parte por essas três classes. O Kappa geral obtido através da classificação supervisionada do Hyperion foi de 0,83, considerando 3 classes, sendo classificado como excelente, como pode ser visualizado na Tabela 31.

Tabela 31 – Valores de Kappa encontrados através da classificação supervisionada, no entorno do reservatório Paus Brancos

	HYPERION	LANDSAT 8
Considerando 5 classes		
Água	0,87	0,87
Macrófitas	0,76	0,80
Solo exposto	0,43	0,01
Vegetação rala	0,69	0,04
Vazante	0,93	0,24
Valor de Kappa	<u>0,73</u>	<u>0,38</u>
Qualidade do mapa temático	<u>Muito boa</u>	<u>Razoável</u>
Considerando 3 classes		
Água	0,85	0,82
Macrófitas	0,72	0,68
Vazante	0,92	0,27
Valor de Kappa	<u>0,83</u>	<u>0,55</u>
Qualidade do mapa temático	<u>Excelente</u>	<u>Boa</u>

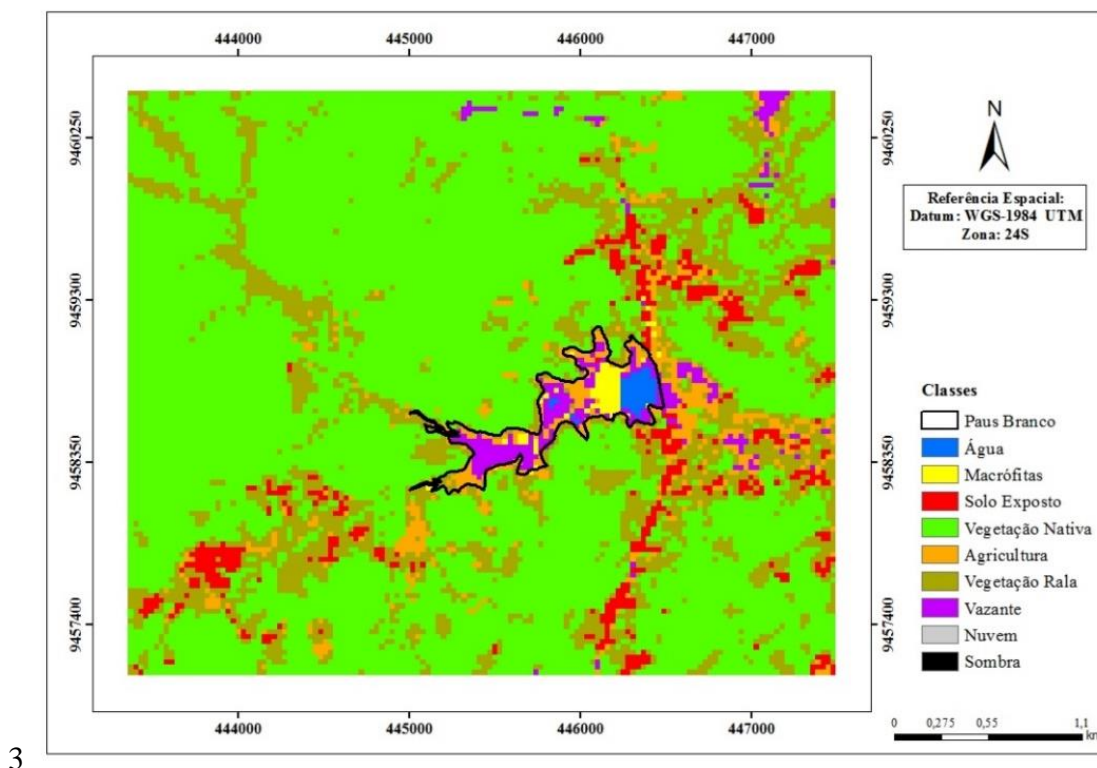
Fonte: Elaborada pelo autor.

O resultado pior encontrado na classificação da imagem Landsat 8 se deve à presença do uso agricultura dentro da bacia hidráulica do reservatório Paus Brancos, o que mostra a limitação do satélite na separação das classes agricultura, vazante e macrófitas (Figura 59). A similaridade dos valores de reflectância entres as classes macrófitas, vazante e agricultura mostra de forma clara o cuidado que se deve ter na análise dos resultados gerados nas classificações de imagens Landsat 8, pois em alguns casos é nítida a confusão ou inversão de informações reais existentes em campo. Dessa forma, algumas classes são quase impossíveis de ser separados e determinados através de imagem multiespectral, mesmo que a classificação seja obtida através de conjunto de pontos detalhado das classes levantados em campo.

Jafari e Lewis (2012), em pesquisa realizada para espacialização de alvos sobre a superfície do solo através de imagens Hyperion e Landsat 8, comprovam que a maior resolução espectral de imagens hiperespectrais pode melhorar a discriminação de componentes tanto

semelhantes como heterogêneos, com resultados muito superiores aos obtidos por satélites multiespectrais como o caso do Landsat 8.

Figura 59 – Classificação supervisionada gerada a partir da imagem Landsat 8 (24/08/2015) no entorno do reservatório Paus Brancos

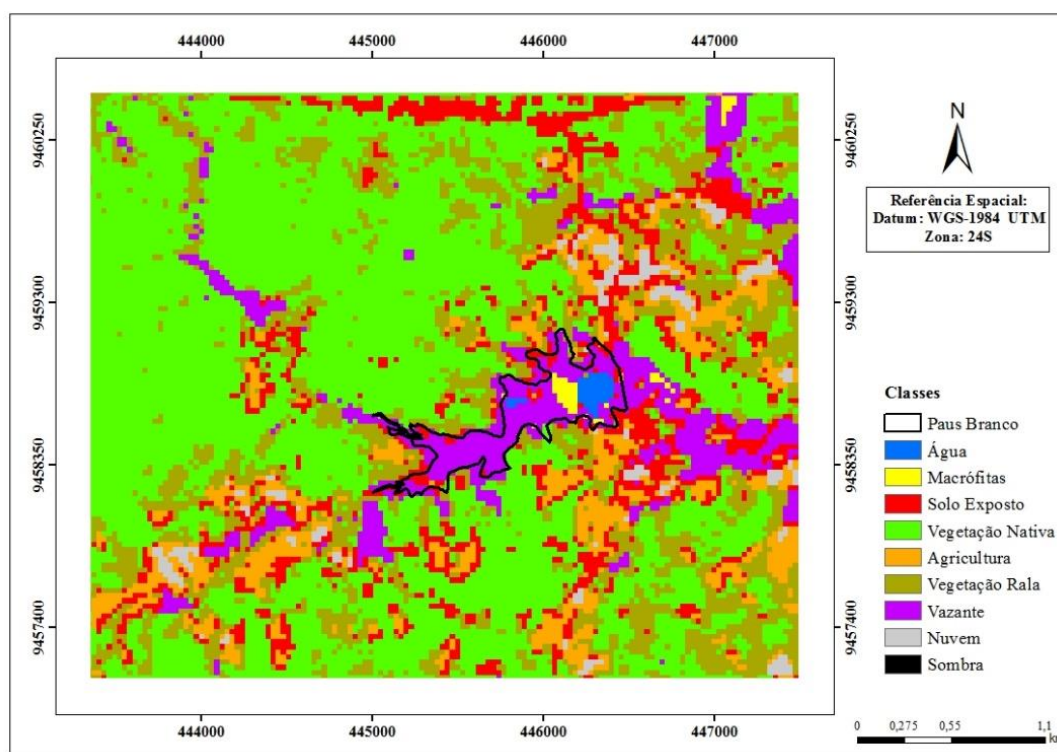


Fonte: Elaborado pelo autor.

Na Figura 60 é apresentada a espacialização das classes obtidas através da classificação supervisionada da imagem do satélite Hyperion pelo método da Máxima Verossimilhança, que apresentou resultados excelentes de acordo com os valores de Kappa produzidos. O produto gerado desta classificação é bastante condizente com a realidade, reforçando a tese de que as imagens hiperespectrais apresentam grande eficiência na espacialização de classes tanto homogêneas como de classes diferentes, o que reforça o ganho dos resultados obtidos através do sensor Hyperion.

Blanco *et al.* (2014) afirmam que a resolução da imagem espectral do Hyperion é suficientemente robusta para avaliar o uso da terra, fornecendo uma ferramenta eficaz e confiável para avaliar as atividades antropogênicas, podendo os resultados serem aplicadas como uma ferramenta de gestão, planejamento e monitoramento do uso do solo e também na recuperação de áreas degradadas, exercendo assim um papel preponderante como uma ferramenta de gestão ambiental.

Figura 60 – Classificação supervisionada gerada a partir da imagem Hyperion (24/08/2015) no entorno do reservatório Paus Brancos



Fonte: Elaborado pelo autor.

Os resultados obtidos através da matriz confusão para a imagem Hyperion, conforme detalhados na Tabela 32, mostram que as classes vegetação rala e solo exposto apresentam semelhanças com outras classes, o que pode estar diretamente ligado à área coberta pela imagem do VANT. Já as classes água (acerto 18 de 20 pontos) e vazante (acerto 19 de 20 pontos), tiveram quase que 100% de eficiência, mostrando a importância da utilização de imagens hiperespectrais na separação e determinação dessas classes.

A aplicação de sensores hiperespectrais, como o Hyperion, tem, entretanto, algumas limitações como disponibilidade, custo, continuidade, processamento e análise complexas, além da área de imageamento que é muito estreita sendo necessária, em muitos casos, a aquisição de um conjunto de cenas para cobertura de uma área, sobretudo quando apresentam distâncias mais expressivas no sentido Leste-Oeste (DUBE e MUTANGA, 2015; MUTANGA *et al.*, 2012).

Tabela 32 – Matriz de confusão resultante da classificação supervisionada, Máxima Verossimilhança, da imagem Hyperion de 28/08/2015 no entorno do reservatório Paus Brancos, considerando 5 e 3 classes do solo

MATRIZ OBTIDA COM 5 CLASSES							
P_o - Concordância observada							
MAPA TEMÁTICO							
		Água	Mac.	Solo	V. Rala	Vazante.	Σ
VERDADE TERRESTRE	Água	18	0	0	0	2	20
	Macrófitas	3	16	0	0	1	20
	Solo exposto	0	0	10	5	5	20
	Vegetação rala	0	0	2	15	3	20
	Vazante	0	1	0	0	19	20
SOMA		21	17	12	20	30	100
MATRIZ OBTIDA COM 3 CLASSES							
P_o - Concordância observada							
MAPA TEMÁTICO							
		Água	Macrófitas	Vazante	Σ		
VER. TER.	Água	18	0	2	20		
	Macrófitas	3	16	1	20		
	Vazante	0	1	19	20		
SOMA		21	17	22	60		

Fonte: Elaborado pelo autor.

Os resultados de Kappa individual mostram que na análise com 5 classes, o satélite Hyperion apresentou valores superiores em relação aos resultados encontrados pelo satélite Landsat 8 em 4 das 5 classes. Só o uso macrófitas apresentou Kappa individual melhor no Landsat 8 (Kappa = 0,80 – excelente) do que o Hyperion (Kappa = 0,76 – muito boa), como pode ser visualizado na Tabela 33.

Tabela 33 – Valores de Kappa encontrados através da classificação supervisionada de imagens Landsat 8 e Hyperion, no entorno do reservatório Paus Brancos no mês de agosto de 2015

USO	5 CLASSES		3 CLASSES	
	Hyperion	Landsat 8	Hyperion	Landsat 8
Água	0,87	0,87	0,85	0,82
Macrófitas	0,76	0,80	0,72	0,68
Solo Exposto	0,43	0,01	-	-
Vegetação rala	0,69	0,04	-	-
Vazante	0,93	0,24	0,92	0,27
Kappa Geral	0,73	0,39	0,83	0,49
Qualidade do mapa	Muito boa	Razoável	Excelente	Boa

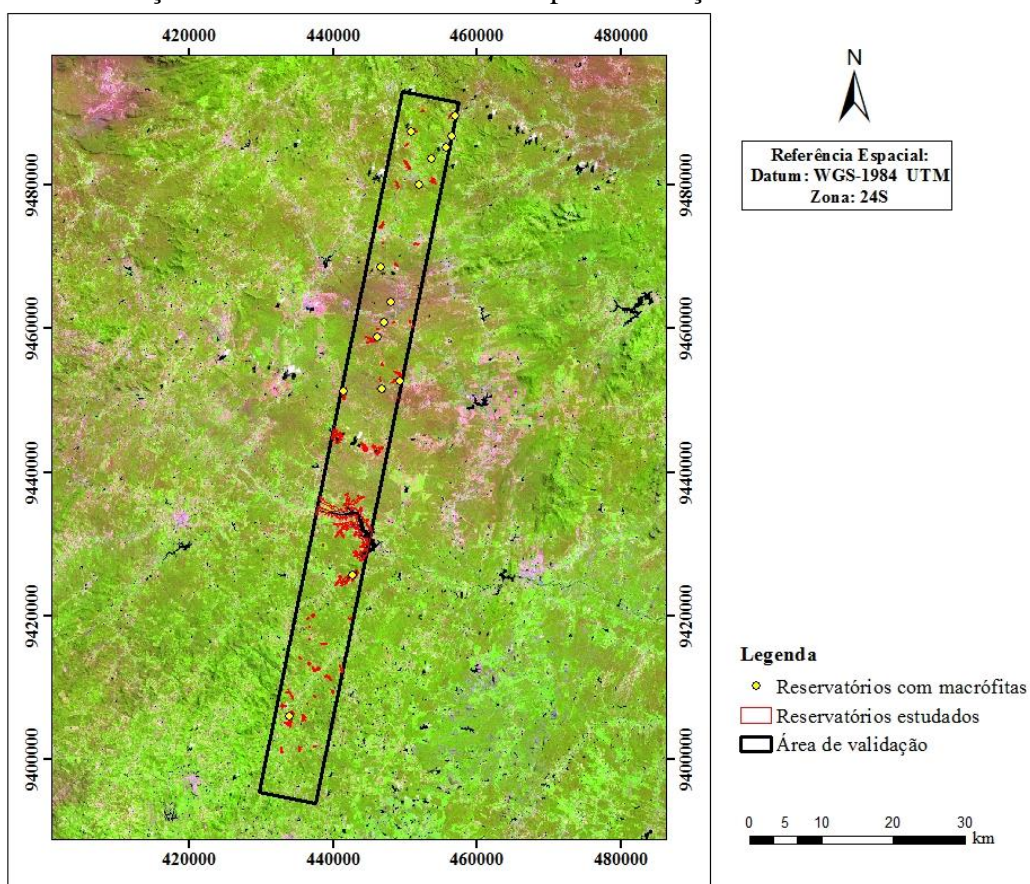
Fonte: Elaborado pelo autor.

Já na análise realizada considerando apenas 3 classes, os valores de Kappa individual do Hyperion foram superiores nas três classes do solo (água, macrófitas e vazante) (Tabela 33).

5.7.2 Aplicação para os reservatórios da cena do sensor Hyperion que cobre o Assentamento 25 de Maio

Através da classificação supervisionada das imagens dos satélites Hyperion (19 de outubro de 2014) e Landsat 8 (22 de setembro de 2014), foram identificados 48 reservatórios, na área com abrangência de 796 km², da cena do satélite Hyperion (Figura 61).

Figura 61 – Ilustração da área de estudo utilizada para validação



Fonte: Elaborado pelo autor.

Como a cena do satélite Landsat 8 conseguiu cobrir toda a cena do satélite Hyperion, os reservatórios foram identificados na imagem do Landsat 8 considerando a área de 796 km², afim de poder traçar uma comparação entre os dois satélites e avaliar a eficiência dos mesmos na espacialização de reservatórios, haja visto a quantidade de reservatórios existentes

no estado do Ceará, onde a grande maioria dos reservatórios não dispõe de dados de volume e área inundada.

A espacialização dos reservatórios através da imagem Landsat 5 de 22 de julho de 2004, diagnosticou-se a presença de 118 reservatórios, já que o ano de 2004 apresentou um regime pluviométrico bem acima da média e, com isso, admite-se que a maioria dos reservatórios atingiram a capacidade máxima de armazenamento. Segundo Novo (2001), um dos problemas na determinação de espelhos d'água está ligado à interferência na absorção da energia modificada pelo comportamento espectral da curva de reflectância, o que resulta em feições específicas relacionadas ao tipo de componente presente na água, que é bastante regional e heterogêneo.

Dos 118 reservatórios espacializados na imagem Landsat 5 de 2004, 70 encontraram-se totalmente secos ou com cobertura de nuvem e sombra nas imagens do Landsat 8 e Hyperion do ano de 2014, fato esse que se deve aos três (2012, 2013 e 2014) anos seguidos com precipitações abaixo da média, acarretando uma diminuição drástica dos volumes dos reservatórios do estado do Ceará. Neste contexto, foram identificados apenas 48 reservatórios através da classificação das imagens dos dois satélites estudados, sendo observado presença de macrófitas em 21 destes na classificação da imagem do sensor Hyperion e 8 do Landsat 8, como pode ser analisado na Tabela 34. Isso reforça a eficiência do sensor Hyperion na detecção de macrófitas em reservatórios do semiárido.

Dos 48 reservatórios espacializados, apenas o reservatório de identificação 21 não conseguiu ser diagnosticado através da classificação supervisionada da imagem do satélite Landsat 8, mas o mesmo foi espacializado através da imagem Hyperion, mostrando a eficiência dessa imagem no desenvolvimento de estudo relacionado à estimativa de área inundada de reservatórios.

No açude Paus Brancos, por exemplo, o satélite Landsat 8 subestimou a área de macrófita, o que acarretou numa diminuição de 16,7% em relação à área efetivamente inundada (área do espelho d'água somado à área ocupada por macrófita) como pode ser visualizado na Tabela 34. Segundo Pompêo *et al.* (2015), a identificação de macrófitas em reservatórios é importante, pois as mesmas infestam o corpo d'água e podem alterar a qualidade da água.

Tabela 34 – Estimativa das áreas aparente e efetiva de espelho d'água usando o método de classificação supervisionada de imagens Hyperion (19/10/14) e Landsat 8 (22/09/14)


Reservatório	Obtenção do contorno	Área contorno (ha)	Landsat 8			Hyperion		
			Área efetiva (ha)	Diferença Área de Macrófitas (%)	Área efetiva espelho d'água (%)	Área efetiva (ha)	Diferença Área de Macrófitas (%)	Área efetiva espelho d'água (%)
Marengo	Campo	45,0	40,7	-	90%	42,03	-	93%
2	Campo	<u>37,1</u>	<u>32,5</u>	<u>0%</u>	<u>88%</u>	<u>33,57</u>	<u>3%</u>	<u>90%</u>
3	Comp.	<u>36,7</u>	<u>29,1</u>	<u>0%</u>	<u>79%</u>	<u>34,47</u>	<u>5%</u>	<u>94%</u>
Paus Brancos	Campo	<u>39,9</u>	<u>24,6</u>	<u>28%</u>	<u>62%</u>	<u>30,69</u>	<u>44%</u>	<u>77%</u>
São Nicolau	Campo	<u>35,0</u>	<u>24,1</u>	<u>1%</u>	<u>69%</u>	<u>34,29</u>	<u>10%</u>	<u>98%</u>
Tigres	Goog. Earth	<u>23,3</u>	<u>13,8</u>	<u>38%</u>	<u>59%</u>	<u>18,99</u>	<u>49%</u>	<u>82%</u>
7	Comp.	15,2	10,6	-	70%	11,43	-	75%
8	Comp.	<u>10,9</u>	<u>8,0</u>	<u>0%</u>	<u>73%</u>	<u>8,73</u>	<u>1%</u>	<u>80%</u>
9	Comp.	<u>20,0</u>	<u>7,8</u>	<u>10%</u>	<u>39%</u>	<u>11,70</u>	<u>13%</u>	<u>59%</u>
10	Comp.	<u>14,2</u>	<u>6,8</u>	<u>0%</u>	<u>48%</u>	<u>11,34</u>	<u>2%</u>	<u>80%</u>
11	Comp.	<u>8,2</u>	<u>6,1</u>	<u>0%</u>	<u>74%</u>	<u>5,94</u>	<u>2%</u>	<u>72%</u>
Nova Vida	Comp.	<u>10,0</u>	<u>4,3</u>	<u>1%</u>	<u>43%</u>	<u>9,54</u>	<u>1%</u>	<u>95%</u>
13	Comp.	<u>5,8</u>	<u>3,8</u>	<u>0%</u>	<u>66%</u>	<u>5,76</u>	<u>8%</u>	<u>100%</u>
14	Comp.	<u>6,2</u>	<u>3,5</u>	<u>55%</u>	<u>57%</u>	<u>5,94</u>	<u>89%</u>	<u>96%</u>
15	Comp.	<u>4,5</u>	<u>2,6</u>	<u>0%</u>	<u>58%</u>	<u>3,06</u>	<u>2%</u>	<u>68%</u>
16	Comp.	2,8	2,2	-	76%	2,34	-	82%
17	Comp.	<u>2,6</u>	<u>2,0</u>	<u>0%</u>	<u>77%</u>	<u>1,62</u>	<u>4%</u>	<u>63%</u>
18	Comp.	3,2	2,0	-	62%	1,26	-	40%
19	Comp.	<u>5,3</u>	<u>1,8</u>	<u>0%</u>	<u>34%</u>	<u>1,71</u>	<u>2%</u>	<u>32%</u>
20	Comp.	3,2	1,6	-	51%	1,35	-	43%
21	Comp.	2,9	1,6	-	56%	2,43	-	84%
22	Comp.	2,5	1,6	-	66%	1,71	-	70%
23	Comp.	5,8	1,4	-	25%	4,23	-	72%
24	Comp.	2,6	1,4	-	51%	0,99	-	38%
25	Comp.	2,0	1,3	-	63%	1,08	-	54%
26	Comp.	1,8	1,0	-	56%	1,17	-	66%
27	Comp.	1,7	1,0	-	59%	1,44	-	85%
28	Comp.	1,8	0,9	-	50%	1,80	-	100%
29	Comp.	<u>3,5</u>	<u>0,8</u>	<u>0%</u>	<u>23%</u>	<u>1,80</u>	<u>13%</u>	<u>51%</u>
30	Comp.	2,9	0,8	-	28%	2,61	-	89%
31	Comp.	1,0	0,7	-	71%	0,81	-	80%
32	Comp.	1,9	0,7	-	39%	1,71	-	92%
33	Comp.	1,1	0,7	-	65%	0,63	-	57%
34	Comp.	1,4	0,6	-	45%	1,26	-	90%
35	Comp.	2,0	0,6	-	32%	1,08	-	55%
36	Comp.	1,0	0,6	-	61%	0,72	-	70%
37	Comp.	1,3	0,6	-	50%	0,72	-	58%
38	Comp.	<u>2,8</u>	<u>0,5</u>	<u>0%</u>	<u>19%</u>	<u>2,34</u>	<u>45%</u>	<u>83%</u>
39	Comp.	1,6	0,5	-	33%	0,90	-	55%
40	Comp.	0,8	0,5	-	54%	0,72	-	86%
41	Comp.	0,7	0,5	-	62%	0,72	-	98%
42	Comp.	<u>0,5</u>	<u>0,4</u>	<u>0%</u>	<u>78%</u>	<u>0,36</u>	<u>20%</u>	<u>78%</u>
Betúlia	Comp.	2,0	0,4	-	18%	1,71	-	86%
Marequetá	Comp.	1,0	0,3	-	26%	0,54	-	51%
45	Comp.	<u>1,8</u>	<u>0,2</u>	<u>0%</u>	<u>10%</u>	<u>1,62</u>	<u>5%</u>	<u>88%</u>
46	Comp.	0,5	0,2	-	33%	0,27	-	50%
47	Comp.	0,8	0,2	-	22%	0,54	-	65%
48	Comp.	<u>1,1</u>	<u>0,0</u>	<u>0%</u>	<u>0%</u>	<u>0,54</u>	<u>8%</u>	<u>50%</u>

*Valores sublinhados destacam reservatórios com presença de macrófitas nas classificações; *Em azul está o reservatório não identificados; *Comp. RGB: Composição RGB de imagens Landsat 8 e Hyperion do período da classificação.

Fonte: Elaborada pelo autor.

Os resultados obtidos através do processamento digital das imagens Landsat 8 e Hyperion, mostram o desempenho dos dois satélites na estimativa da área efetivamente inundada dos quarenta e oito reservatórios especializados (Figura 62 e Tabela 34). As áreas do contorno dos reservatórios, obtidas pela classificação supervisionada da imagem do satélite Hyperion foram bem próximas às medidas em campo ou estimados usando imagens do Google Earth e composições Landsat 8 (bandas 6, 5 e 4) e Hyperion (bandas 51, 161 e 19), tidos como áreas de referência no processo de validação dos resultados. Já as áreas obtidas pela classificação do satélite Landsat 8, na maioria das vezes, são subestimadas em relação às áreas de referência, como pode ser visualizado na Figura 62.

Figura 62 – Desempenho da estimativa dos espelhos d’água de reservatórios através de imagens Landsat 8 e Hyperion, em ha (A) e % (B)




Fonte: Elaborado pelo autor.

Na Figura 62 B pode-se observar que o satélite Hyperion conseguiu estimar o volume máximo em quatro reservatórios e em outros chegou a valores bem próximos de 100%, com percentuais de acerto, em geral, superiores aos obtidos na classificação com Landsat 8. George

et al. (2014) afirmam que o bom desempenho de classificações de imagens do sensor Hyperion, facilita a detecção e separação de alvos com resposta espectral similar. Já o satélite Landsat 8 apresenta restrições no levantamento de áreas inundadas, sobretudo naquelas com presença de macrófitas.


Figura 63 – Estimadas através de classificação de imagens dos satélites Landsat 8 e Hyperion, áreas de macrófitas em reservatórios



Fonte: Elaborado pelo autor.

A validação dos resultados das classificações das imagens dos satélites Landsat 8 e Hyperion usando o coeficiente de Nash-Sutcliffe foi aplicado para observar se existe correlação entre as áreas de referência e aquelas estimadas em classificações das imagens Landsat 8 e Hyperion.

Figura 64 – Validação dos satélites Landsat 8 e Hyperion, na determinação da área dos espelhos d'água de reservatórios localizados na área imagiada pelo satélite Hyperion



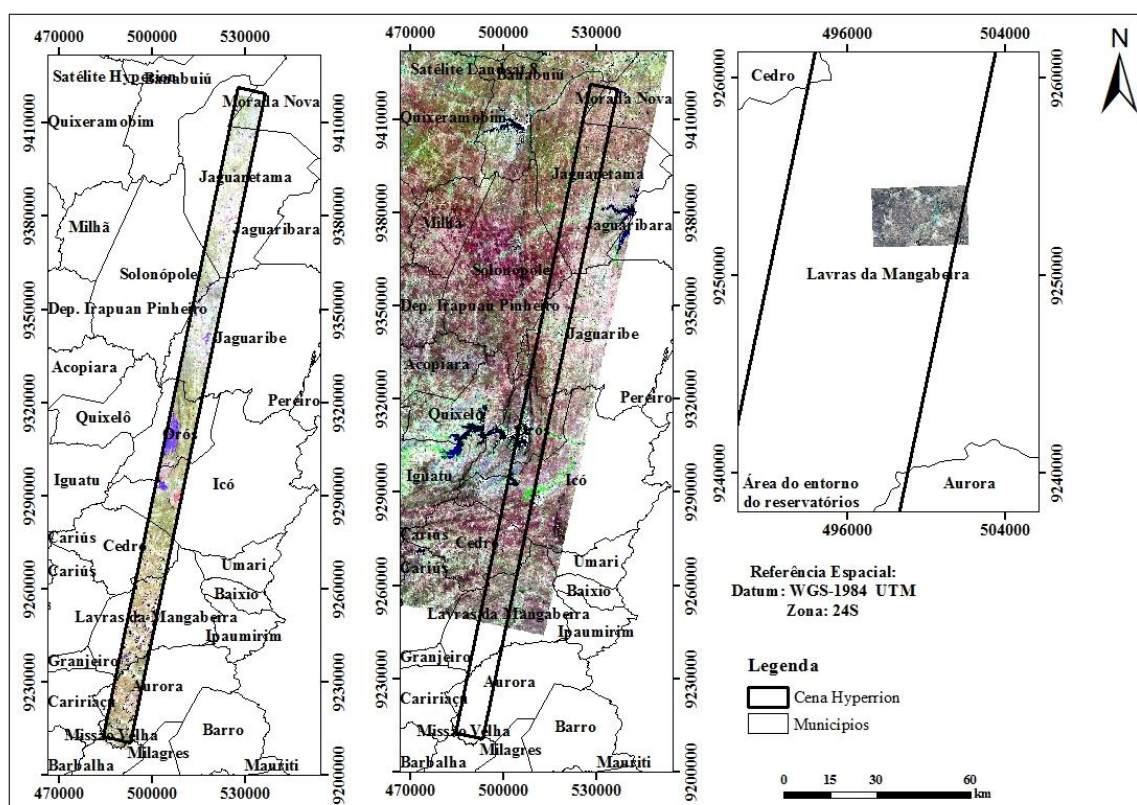
Fonte: Elaborado pelo autor.

O coeficiente de Nash-Sutcliffe encontrado na classificação da imagem Hyperion foi de 0,96, mostrando excelente eficiência do modelo, e que o mesmo está estimando de forma coerente a área do espelho d'água dos reservatórios. A classificação da imagem Landsat 8 apresentou um coeficiente de Nash-Sutcliffe de 0,86, resultado inferior ao encontrado na imagem Hyperion. Os resultados encontrados na validação das imagens Landsat 8 e Hyperion estão ilustrados na Figura 64.

5.7.3 Aplicação para outros reservatórios do Estado do Ceará

Após realização de busca em todo o Estado do Ceará com cobertura de imagens Hyperion que pudessem ser utilizadas na análise de desempenho das classificações de imagens, identificou-se uma única cena do Hyperion que poderia ser utilizada. Nesta cena, observou-se a existência de dois açudes com cobertura de vegetação aquática em suas bacias hidráulicas, localizados no Município de Lavras da Mangabeira (Figura 65).

Figura 65 – Ilustração da área do entorno do reservatório localizado no município de Lavras da Mangabeira - CE



Fonte: Elaborada pelo autor.

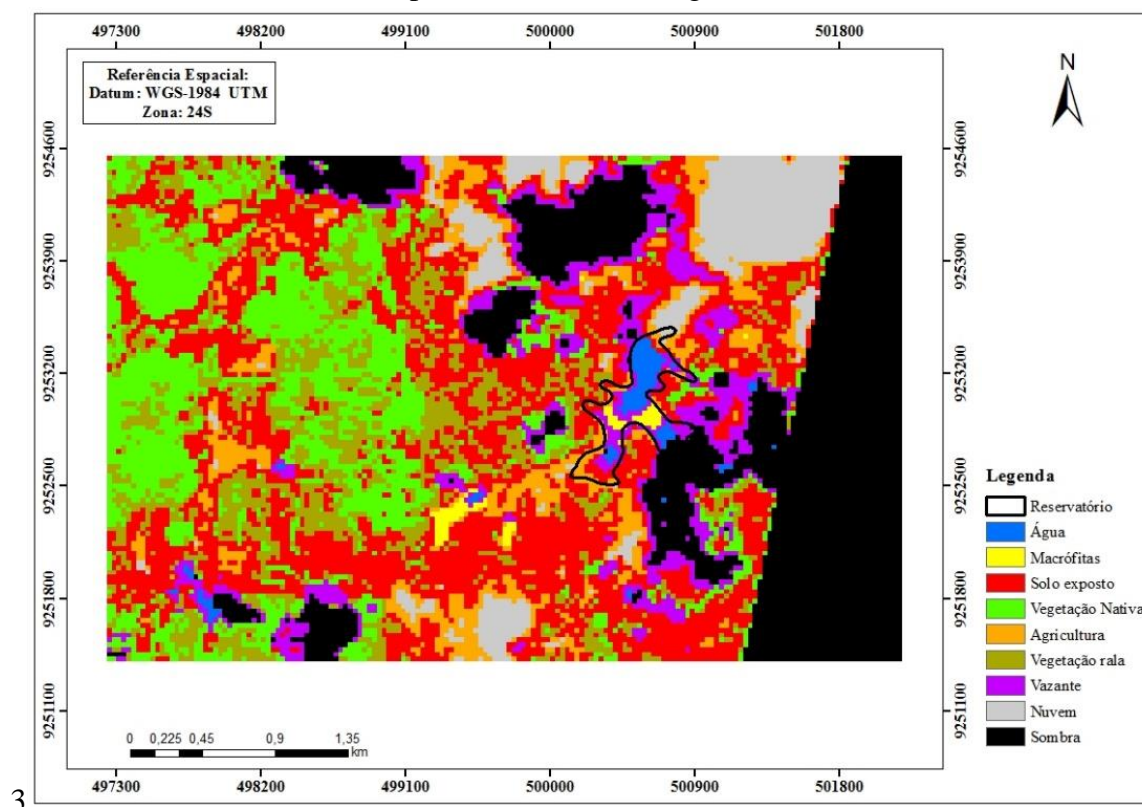
Reforça-se a escolha desses reservatórios por apresentarem as nove classes analisados nesta pesquisa (água, macrófitas, solo exposto, vegetação nativa, agricultura,

vegetação rala, vazante, sombra, nuvem). Além disso, adquiriu-se imagens Landsat 8, Hyperion e Google Earth com baixa cobertura de nuvem e sombra, que contemplasse a bacia hidráulica e o entorno do mesmo. Entretanto, como as imagens do satélite Landsat 8 estão disponíveis apenas a partir de 2013, e a imagem selecionada do Hyperion data de 2010 e do Google Earth de 2009, optou-se por utilizar apenas os dados destes últimos.

Utilizou-se para a classificação da imagem Hyperion que cobria a região, a mesma composição de bandas (R - 51, G - 161 e B - 19) obtida na análise para os reservatórios do Assentamento 25 de Maio em Madalena, para testar sua aplicabilidade para outras regiões.

A imagem processada do satélite Hyperion foi do dia 29 de setembro de 2010, tendo apresentado cobertura de nuvens e sombra, como pode ser visualizado na Figura 66, o que dificultou um detalhamento da bacia hidráulica do reservatório estudado, visto que as nuvens e sombra apareceram nas áreas circunvizinhas aos reservatórios, dificultando a determinação da bacia hidráulica dos mesmos (Figura 66).

Figura 66 – Classificação supervisionada da imagem Hyperion de 26/09/2010 no entorno do reservatório localizado no município de Lavras da Mangabeira - CE



Fonte: Elaborada pelo autor.

O Kappa geral encontrado na classificação da imagem do satélite Hyperion foi de 0,90, o que sugere que a composição de bandas proposta (R - 51, G - 161 e B - 19) pode ser aplicada para outras regiões na separação destas 9 classes. Nesta aplicação, obteve-se um mapa temático excelente, com valor de Kappa ainda superior ao encontrado no Assentamento 25 de Maio. A imagem hiperespectral possibilita a distinção dos alvos semelhantes, reforçando a importância da utilização desse tipo de imagem para a separação com precisão e eficiência das classes, como também afirmou Blanco *et al.* (2014) em sua pesquisa.

Analisando os resultados encontrados pela determinação do Kappa individual de cada classe, pode-se constatar que a classificação da imagem Hyperion apresentou desempenho muito bom, com destaque para as classes solo exposto, vegetação nativa e vegetação rala com acerto de 100% (Tabela 35), o que representa um resultado muito valioso já que as três classes sempre apresentaram grandes dificuldades de determinação, haja visto as semelhanças que essas classes possuem com outros, requerendo sensores com excelente resolução espectral, como é o caso dos satélites hiperespectral, e um conjunto de pontos de campo bem definido.

Tabela 35 – Valores de Kappa encontrados através da classificação supervisionada, no entorno do reservatório localizado no município de Lavras da Mangabeira – CE

Classes	Hyperion
Água	0,77 – Muito Boa
Macrófitas	0,90 - Excelente
Solo Exposto	1,00 - Excelente
Vegetação nativa	1,00 - Excelente
Agricultura	0,77 – Muito Boa
Vegetação rala	1,00 - Excelente
Vazante	0,77 – Muito boa
Nuvem	1,00– Excelente
Sombra	0,77– Muito Boa
Kappa Geral	0,90
Qualidade do mapa temático	Excelente

Fonte: Elaborada pelo autor.

6 CONCLUSÕES

Foi possível estabelecer um padrão de classificação de imagens multiespectrais que permitiu detectar precisamente as áreas inundadas de espelho d'água, com diferenciação de vegetação aquática e outras classes no entorno do reservatório através da classificação supervisionada.

A análise espectral e temporal da reflectância de classes não permitiu separar de maneira precisa através das faixas mínima e máxima dos alvos analisados na pesquisa, por ser influenciado diretamente pela sazonalidade da imagem, ou seja, a resposta espectral dos alvos está diretamente relacionada ao período (seco ou chuvoso) de obtenção da imagem.

A utilização da classificação não-supervisionada não atendeu aos objetivos proposto, pois apresentou-se deficiente por não conseguir separar corpos hídricos de sombra de nuvem. Além disso, este método não foi capaz de diferenciar macrófitas de vazante, nem agricultura de vegetação rala, mostrando que esse tipo de classificador possui limitações de separar alvos com respostas espectrais semelhantes. Já entre os diferentes métodos de classificação supervisionada utilizados na pesquisa, o classificador KNN apresentou o melhor desempenho na determinação das classes através da classificação de imagens Landsat 8 no entorno de reservatórios localizados no semiárido brasileiro.

Os resultados encontrados afirmam que um número elevado de amostras de treinamento não implica em bons resultados na classificação, pois a análise de sensibilidade mostrou que o número de amostras de treinamento deve ser flexibilizado e avaliado dependendo do classificador abordado.

O classificador SVM apresentou-se bastante eficiente na separação de classes na bacia hidráulica e entorno dos reservatórios do Assentamento 25 de Maio, apresentando a vantagem de utilizar todas as 155 bandas da imagem Hyperion. Este classificador apresenta, ainda, como produto o peso de cada uma das bandas usadas na classificação da imagem, o que permitiu a identificação das três bandas prioritárias para geração de composição R – 51, G – 161 e B – 19, e eventual uso por outros métodos de classificação de imagem considerados nesta pesquisa. Alguns testes realizados nesta pesquisa para a mesma região em outro período e para outra região do Estado do Ceará confirmam a eficiência do uso desta combinação de bandas do Hyperion na detecção e separação de alvos no entorno de reservatórios do Bioma Caatinga, incluindo macrófitas existentes em reservatórios.

Os dados hiperespectrais demonstraram ser uma boa alternativa para análise de uso e ocupação do solo mesmo em alvos com características espectrais similares. Mesmo

utilizando-se de métodos tradicionais de classificação, os dados trabalhados aqui atingiram um bom desempenho com a utilização do critério de seleção de feições das diferentes classes. Os resultados encontrados utilizando imagens hiperespectrais apresentam melhor desempenho que os encontrados na análise multiespectrais, o que mostra a importância da resolução espectral da imagem, para a espacialização e separação de classes com características diferentes ou semelhantes. A classificação da imagem Hyperion através do classificador Máxima Verossimilhança mostrou alto grau de eficiência na estimativa da área do espelho d'água dos reservatórios, validado através do coeficiente de Nash-Sutcliffe (0,96), o que está diretamente ligado a qualidade espectral da imagem do sensor hiperespectrais Hyperion.

A imagem Hyperion apresentou resultados precisos mostrando-se uma importante ferramenta de suporte para a gestão de recursos hídricos do estado na espacialização de reservatórios, além do diagnóstico de açudes com presença de macrófitas com elevado grau de precisão. A pesquisa recomenda a utilização das imagens hiperespectrais (Hyperion) devido ao ganho nos resultados na separação das classes na espacialização de corpos hídricos, muito superiores aos resultados das imagens multiespectrais (Landsat 8). Mas o satélite Hyperion apresentou limitação para sua utilização pelo fato da pequena quantidade de imagens disponíveis e pela baixa área de cobertura no estado do Ceará, limitando o desenvolvimento de pesquisas em áreas estratégicas.

7 REFERÊNCIAS

- ANTUNES, R. P. **Análise do potencial de uso das macrófitas aquáticas do sistema de áreas alagadas construídas da ETE da Comunidade de Serviços Emaús (Ubatuba, SP) como adubo orgânico.** 2009. Dissertação (Mestrado em Ciências da Engenharia Ambiental) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2009.
- ASSOCIAÇÃO DE COOPERAÇÃO AGRÍCOLA DO ESTADO DO CEARÁ. (ACACE). **Plano de recuperação do projeto de assentamento São Joaquim.** Madalena-CE, 2005.
- ARAÚJO, C. A. S. **Aplicação de técnicas de sensoriamento remoto na análise multitemporal do ecossistema manguezal na Baixada Santista, SP.** 2010. Dissertação (Mestrado em Ciências) – Instituto de Oceanografia, Universidade de São Paulo, São Paulo, 2010.
- BERNARDES, T. **Caracterização do ambiente agrícola do complexo serra negra por meio de sensoriamento remoto e sistemas de informação geográfica.** 2006. Dissertação (Mestrado em Agronomia) - Universidade Federal de Lavras, Lavras, 2006.
- BHARDWAJ, A.; SINGH, M. K.; JOSHI, P. K.; SNEHMANI; SINGH, S.; SAM, L.; GUPTA, R. D.; KUMAR, R. A lake detection algorithm (LDA) using Landsat 8 data: A comparative approach in glacial environment. **International Journal of Applied Earth Observation and Geoinformation**, [S.l.], v. 38, n., p. 150-163, 2015.
- BISSO, A. B. A. **Dados do sensor Hyperion / EO-1 para análise das áreas de mata atlântica e de bananais no nordeste do Rio Grande do Sul.** 2010. Dissertação. (Mestrado em Sensoriamento Remoto e Meteorologia) - Centro estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2010.
- BLANCO, P. D.; DEL VALLE, H. F.; BOUZA, P. J.; METTERNICHT, G. I.; Ecological site classification of semiarid rangelands: Synergistic use of Landsat and Hyperion imagery. **International Journal of Applied Earth Observation and Geoinformation**, [S.l.], v. 29, n., p. 11- 21, 2014.
- BREIMAN, L. **Random forests.** *Machine Learning*, Boston, v.45, n.1, p. 5-32, 2001.
- CEARÁ, Assembleia Legislativa. **Cenário Atual dos recursos hídricos do Ceará / Conselhos de Altos estudos e Assuntos Estratégicos, Assembleia Legislativa do Estado do Ceará;** Eudoro Walter de Santana (Coordenador). – Fortaleza: INESP, 2008. 174 p. : II. – (Coleção Pacto das Águas).
- CEARÁ, SECRETARIA DOS RECURSOS HÍDRICOS. (SRH). **Documentos – Projetos Especiais.** Fortaleza - CE, 2011. Disponível em: <<http://www.srh.ce.gov.br/index.php/projetos-especiais/documentos>>. Acesso em: 10 fev. 2014.
- CONGALTON, R. G. **A review of assessing the accuracy of classifications of remotely sensed data.** *Remote Sens. Environ.* 37, 35–46, 1991.
- CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data:**

principles and practices. New York: Lewis Publishers, 1999. 137 p.

CONGALTON, R.. Accuracy assessment and validation of remotely sensed and other spatial information. **International Journal of Wildland Fire**, [S. I.], v. 10, p. 321-328, 2011.

COULTER, L. L.; STOW, D. A.; TSAI, Y.; IBANEZ, N.; SHIH, H.; KERR, A.; BENZA, M.; WEEKS, J. R.; MENSAH, F. Classification and assessment of land cover and land use change in southern Ghana using dense stacks of Landsat 7 ETM+ imagery. **Remote Sensing of Environment**. [S. I.], v. 184, p. 396-409, 2016.

CRÓSTA, A. P. **Processamento Digital de Imagens de Sensoriamento Remoto.** Campinas: UNICAMP, 1993.

DAINESE, R. C. **Sensoriamento remoto e geoprocessamento aplicado ao estudo temporal do uso da terra e na comparação entre classificação não-supervisionada e análise visual.** 2001. Dissertação (Mestrado em Agronomia/Energia na Agricultura) - Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista, Botucatu, 2001.

DU, Z.; LI, W.; ZHOU, D.; TIAN, L.; LING, F.; WANG, H.; GUI, Y.; SUN, B. Analysis of Landsat-8 OLI imagery for land surface water mapping. **Remote Sens. Lett.** [S. I.], v. 5, p. 672–681, 2014.

DUDA, R. O.; HEART, P. E.; STORK, D. G. **Pattern Classification.** 2. ed. [S.l.: s.n.], 2001.

DUBE, T.; MUTANGA, O.; ELHADI, A.; ISMAIL, R. Intra-and-inter species biomass prediction in a plantation forest: testing the utility of high spatial resolution spaceborne multispectral rapid-eye sensor and advanced machine learning algorithms. **Sensors** [S. I.], v. 14, p. 15348–15370. 2014.

DUBE, T.; MUTANGA, O. Evaluating the utility of the medium-spatial resolution Landsat 8 multispectral sensor in quantifying aboveground biomass in uMgeni catchment, South Africa. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S. I.], v. 101, n. 1, p. 36-46, 2015.

EL-ASKARY, H.; ABD EL-MAWLA, S. H.; LI, J.; EL-HATTAB, M. M.; EL-RAEY, M. Change detection of coral reef habitat using Landsat-5 TM, Landsat 7 ETM+ and Landsat 8 OLI data in the Red Sea (Hurghada, Egypt). **Int. J. Rem. Sens.** [S. I.], v. 35, p. 2327–2346, 2014.

ELMORE, A. J.; MUSTARD, J. F.; MANNING, S. J.; LOBELL, D. B. Quantifying vegetation change in semiarid environments: precision and accuracy of Spectral Mixture Analysis and the Normalized Difference Vegetation Index. **Remote Sensing of Environment**, [S. I.], v. 73, n.1, p. 87- 102, Jan. 2000.

ESTOQUE, R. C.; MURAYAMA, Y. Examining the potential impact of land use/cover changes on the ecosystem services of Baguio city, the Philippines: a scenario-based analysis. **Appl. Geogr.** [S. I.], v. 35, p. 316–32, 2012.

ESTOQUE, R. C.; MURAYAMA, Y. Classification and change detection of built-up lands from Landsat-7 ETM+ and Landsat-8 OLI/TIRS imageries: A comparative assessment of various spectral indices. **Ecological Indicators**, [S. I.], v. 56, n. 1, p. 205-217, 2015.

FIGUEIREDO, S. M.. de M. **Comparação entre técnicas de classificação digital em imagens landsat no mapeamento do usos e ocupação do solo em capixaba, Acre.** 2005. Dissertação (Mestrado em Engenharia Florestal) – Universidade Federal de Lavras, Lavras, 2005.

FUNDAÇÃO CEARENSE DE METEOROLOGIA E RECURSOS HÍDRICOS. Ministério da Integração Nacional, Agência Nacional das Águas. **Mapeamento dos espelhos d'água do Brasil.** Fortaleza: FUNCEME, 2008. 108 p.

FUNDAÇÃO CEARENSE DE METEOROLOGIA E RECURSOS HIDRICOS. FUNCEME. **Rede de monitoramento.** Disponível em: <<http://www.funceme.br/index.php/areas/rede-de-monitoramento/plataforma-de-coleta-de-dados>>. Acesso: 20 dez. 2015.

GALO, M. L. B. T.; VELINI, E. D.; TRINDADE, M. L. B.; SANTOS, S. C. A. Uso de Sensoriamento Remoto orbital no monitoramento da dispersão de macrófitas nos reservatórios do Complexo Tietê. **Planta Daninha**, Edição Especial de Plantas Aquáticas, Viçosa, v. 20, p. 7-20, 2002.

GALVÃO, L. S; FORMAGGIO, A. R; TISOT, D. A; Discriminação de variedades de cana-de-açúcar com dados hiperespectrais do sensor Hyperion/EO-1, **Revista Brasileira de Cartografia.** Campinas, v. 1, n. 57, p. 7-14, 2005.

GALVÃO, L. S.; FORMAGGIO, A. R.; TISOT, D. A. Discrimination of sugarcane varieties in southeastern Brazil with EO-1 Hyperion data. **Remote Sensing of Environment**, [S. I.], New York, v. 94, n. 4, p. 523-34, 2009.

GAROFALO, C., EL KHOURY, M., LUCAS, P., BELY, M., RUSSO, P., SPANO, G. Autochthonous starter cultures and indigenous grape variety for regional wine production. **J Appl Microbiol.** [S. I.], 118, June (6), 1395–1408, 2015.

GEORGE, R.; PADALIA, H.; KUSHWAHA, S. P. S. Forest tree species discrimination in western Himalaya using EO-1 Hyperion. **International Journal of Applied Earth Observation and Geoinformation**, [S. I.], v. 28, n.2, p. 140-149, 2014.

GILBERTSON, J. K.; KEMP, J.; NIEKERK VAN A. Effect of pan-sharpening multi-temporal Landsat 8 imagery for crop type differentiation using different classification techniques. **Computers and Electronics in Agriculture.** [S. I.], v.134, p. 151–159, 2017.

GONÇALVES, M. L.; ANDREADE NETO, M. L.; ZULLO JÚNIOR, J. Classificação não-supervisionada de imagens de sensores remotos utilizando redes neurais auto-organizáveis e métodos de agrupamentos hierárquicos. **Revista Brasileira de Cartografia**, Campinas, n. p. 1-13, 2008.

GOLDSCHMIDT, R. R.; PASSOS, E. **Data Mining: Um Guia Prático.** Rio de Janeiro: Elsevier, 2005.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de Imagens Digitais.** Ed. Edgard Blücher, 2000.

HAN, T.; GOODENOUGH, D. G.; DYK, A.; LOVE, J. Detection and correction of abnormal

pixels in Hyperion images. In: Geoscience and Remote Sensing Symposium, 2002. Toronto, Canada. **Proceedings. IEEE International.**, p. 1327-1330, 2002.

HAN, J.; KAMBER, M.; PEI, J. **Data mining: concepts and techniques**. San Francisco: Morgan Kaufmann Publishers, 3 rd ed., 2011.

HANSEN, M. C.; DEFRIES, R. S.; TOWNSHEND, J. R. G.; SOHLBERG, R.; DIMICELI, C.; CARROLL, M. Towards on operational MODIS continuous fiel of percent tree cover algorithm: example using AVHRR and MODIS data. **Remote Sensing of Environment, New York**, v. 83, p. 303-319, 2002.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. INPE. **Processamento Digital de Imagens. 2008**. Disponível em:

<http://www.dpi.inpe.br/~carlos/Academicos/Cursos/Pdi/pdi_cores.html>. Acesso em: 19 julho. 2015.

INSTITUTO DE PESQUISA E ESTRATÉGIA ECONÔMICA DO CEARÁ. IPECE. **Perfil básico municipal de Madalena**. Fortaleza, 2009.

JACOMINE, P. K. T.; ALMEIDA, J. C.; MEDEIROS, L. A. R. **Levantamento Exploratório – Reconhecimento de Solos do Estado do Ceará**. Recife, Ministério da Agricultura/ Superintendência do Desenvolvimento do Nordeste, v. 1, 1973. 301p. (Boletim técnico, 28 ; Série Pedologia,16).

JAFARI, R.; LEWIS, M. M. Arid land characterisation with EO-1 Hyperion hyperspectral data. **International Journal of Applied Earth Observation and Geoinformation**, [S. I.], v. 19, p. 298–307, 2012.

JAMES, G.; HASTIE, T.; TIBSHIRANI, R. An introduction to statistical learning: with applications in R. London: Ed. Springer, 2013. 429 p.

JENSEN, J. R. **Introductory Digital Image Processing--A Remote Sensing Perspective**. Prentice Hall, Inc., New Jersey, p. 197-256, 1996.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: uma perspectiva em Recursos Terrestres**. Tradução de J. C. N. Epiphânio. São José dos Campos, SP: Parênteses, 2009. 598 p. (Prentice Hall Series in Geographic Information Science) Tradução de: Remote Sensing of the environment: an earth resource perspective.

KAUFMAN, Y. J.; WALD, A. E.; REMER, L. A.; GAO, B.; LI, R.; FLYNN, L. The MODIS 2.1- m Channel-Correlation with Visible Reflectance for Use in Remote Sensing of Aerosol. **IEEE Transactions on geoscience and remote sensing**, Greenbelt, v. 35, n. 2, set. 1997.

KE. Y.; IM, J.; LEE, J.; GONG, H.; RYU, Y. Characteristics of Landsat 8 OLI-derived NDVI by comparison with multiple satellite sensors and in-situ observations. **Remote Sensing of Environment**. [S. I.], v. 164, p. 298–313, 2015.

LANDGREBE, D. A. **Signal Theory Methods in Multispectral Remote Sensing**. Wiley Interscience, 2003.

LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**, [S. I.], v. 33, n. 1, p. 159-174, 1977.

LIMA NETO, I. E.; WIEGAND, M. C.; ARAÚJO, J. C. Sediment redistribution due to a dense reservoir network in a large semiarid Brazilian basin. **Hydrological Sciences Journal**. [S. I.], v. 56, n. 2, p. 319-333, 2011.

LOPES, F. B. **Uso de sensoriamento remoto como suporte ao monitoramento da qualidade das águas superficiais da região semiárida do Brasil**. 2013. 202 f. Tese (Doutorado em Engenharia Agrícola) – Centro de Ciências Agrárias, Universidade Federal do Ceará, Fortaleza, 2013.

LIU, W. T. **Aplicações de sensoriamento remoto**. Ed UNIDERP, Campo Grande, RJ, 2007. 865 p.

MACHADO, M. L. **Caracterização de agroecossistemas cafeeiros da Zona da Mata de Minas Gerais, usando sensoriamento remoto e sistemas de informações geográficas**. 2002. Dissertação (Mestrado em Solos e Nutrição de Plantas) - Universidade Federal de Lavras, Lavras, 2002.

MACHADO, C. A. S.; BELTRAME, A. M. K.; SHINOHARA, E. J.; GIANNOTTI, M. A.; DURIEUX, L.; NÓBREGA, T. M. Q.; QUINTANILHA, J. A. Identifying concentrated areas of trip generators from high spatial resolution satellite images using object-based classification techniques. **Applied Geography**, [S. I.], v. 53, p. 271-283, 2014.

MALVEIRA, V. T. C.; ARAÚJO, J. C.; GÜNTNER, A. Hydrological Impact of a High-Density Reservoir Network in the Semiarid North-Eastern Brazil. **Journal of Hydrologic Engineering**, [S. I.], v. 17, n. 1, p. 109-117, 2012.

MAY, L.; CARVALHO, L. Maximum growing depth of macrophytes in Loch Leven, Scotland, United Kingdom, in relation to historical changes in estimated phosphorus loading. **Hydrobiologia**. [S. I.], v. 646, p. 123-131, 2010.

MENESES, P. R.; SANO, E. E. Sensor Radar de Abertura Sintética. In: MENESES, P.R.; ALMEIDA, T. **Introdução ao Processamento de Imagens de Sensoriamento Remoto**. ed.1. Brasília: UnB/CNPQ, 2012. cap. 4.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. Viçosa, MG: UFV, 4ª edição, 2009, 320 p.

MOREIRA, M. A. **Fundamentos do Sensoriamento Remoto e Metodologias de Aplicações**. 4. ed. – Viçosa, MG: editora UFV, p. 422, 2011.

MOUNTRAKIS, G.; JUNGHOIM, C. O. Support vector machines in remote sensing: a review. **ISPRS Journal of Photogrammetry and Remote Sensing, New York**, v. 2011, n. 66, p. 247-259, Dec. 2010.

MUTANGA, O., ADAM, E., CHO, M. A. High density biomass estimation for

wetland vegetation using WorldView-2 imagery and random forest regression algorithm. **Int. J. Appl. Earth Observ. Geoinform.** [S. I.], v. 18, p. 399-406, 2012.

NASH, J. E.; SUTCLIFFE J. V., River flow forecasting through conceptual models part I - A discussion of principles, **Journal of Hydrology**, [S. I.], n. 10 (3), 282–290, 1970.

NOVO, E. M. L. de M. Comportamento Espectral da Água. In: MENESES, P. R., MADEIRA NETTO, J. da S. (Orgs.). **Sensoriamento remoto: reflectância de alvos naturais**. Brasília: Universidade de Brasília, 2001, p. 203-221.

NOVO, E. M. L. de M. **Sensoriamento remoto: princípios e aplicações**. 4. ed. rev. São Paulo: Blucher, 2012. 387 p.

PAHLEVAN, N.; SCHOTT, J. R. Leveraging EO-1 to evaluate capability of new generation of Landsat sensors for coastal/inland water studies. Selected TopicsAppl. **Earth Observ. Rem. Sens., IEEE J.** [S. I.], v. 6, p. 360–374, 2013.

PAL, M.; MATHER, P. M. Support Vector Machines for Classification in Remote Sensing. International. **Journal of Remote Sensing**. [S. I.], v. 26, n. 5, March 2005.

PANDA, S.; HOOGENBOOM, G.; PAZ, J. Distinguishing blueberry bushes from mixed vegetation land use using high resolution satellite imagery and geospatial techniques, **Computers and Electronics in Agriculture**. [S. I.], v. 67, p. 51–58, 2009.

PEDRINI, H.; SCHWARTZ, W. R. **Análise de Imagens Digitais: Princípios, Algoritmos e Aplicações**. Editora Thomson Learning, 2007.

PEREIRA, L. C.; MARIANO, Z. de F.; WACHHOLZ, F.; Cabral, J. B. P. Analise da temperatura de superfície e do uso da terra e cobertura vegetal na bacia barra dos Coqueiros (Goiás). **Revista Geonorte**. Manaus, v.2, n. 5, p.1243 – 1255, 2012.

PETROPOULOS, G. P.; ARVANITIS, K.; SIGRIMIS, N. Hyperion hyperspectral imagery analysis combined with machine learning classifiers for land use/cover mapping. **Expert Systems with Applications**, [S. I.], v. 39, n. 3, p. 3800-3809, 2012.

PIROLI, E. L.; DEMARCH, J. C. Imagens ALOS para análise do uso do solo nas Áreas de Proteção Permanente do Córrego das Furnas em Ourinhos, SP. In: IX SEMINÁRIO DE ATUALIZAÇÃO EM SENSORIAMENTO REMOTO E SISTEMAS DE INFORMAÇÕES GEOGRÁFICAS APLICADOS À ENGENHARIA FLORESTAL, 2010, Curitiba - PR. **Anais Curitiba: Fupef**, 2010. v. 1. p. 461-467.

PONPÊO, M.; MOSCHINI-CARLOS, V.; NISHIMURA, P. Y.; SILVA, S. C.; DOVAL, J. C. L. Ecologia de reservatórios e interfaces. **São Paulo**: Instituto de Biociências da Universidade de São Paulo, 2015.

PONZONI, F. J. Comportamento Espectral da Vegetação. In: MENESES, P.R.; MADEIRA NETO, J.S., (Eds). **Sensoriamento remoto: reflectância de alvos naturais**. Brasília: UNB/ EMBRAPA, 2001.

PONZONI, F. J.; REZENDE, A. C. P. Influência da resolução espacial de imagens orbitais na

identificação de elementos da paisagem em Altamira – PA. *Árvore*, Viçosa, v. 26, n. 4, p. 403-410, jul/ago 2002.

QUEIROZ, R. B.; SEVERINO; P. A. da R; RODRIGUES; A. G.; GÓMEZ; A. T. Redes Neurais: Um comparativo com Máxima Verossimilhança Gaussiana na Classificação de Imagens CBERS 1. II WORKSHOP DE TECNOLOGIA DA INFORMAÇÃO APLICADA AO MEIO AMBIENTE, *Anais*. 2004.

RABE, A., VAN DER LINDEN, S., HOSTERT, P. (2014). imageSVM, **Version 3.0, software de available**. Disponível em: <www.imagesvm.net>. Acesso em: 14 de janeiro de 2016.

RIBEIRO, R. J. da C.; BAPTISTA, G. M. de M.; BIAS, E. de S. Comparação dos métodos de classificação supervisionados de imagem Máxima Verossimilhança e Redes Neurais em ambiente urbano. XVIII SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 2007, Florianópolis. *Anais...* Florianópolis: INPE, 2007.

RICHARDS, J. A.; JIA, X. Remote sensing digital image analysis: an introduction. 3. ed. **New York: Springer-** Verlag, 1999.

RIPLEY, B. D. Pattern recognition an neurais networks 4 Ed. **Cambridge: University Press**. 2000. p. 287-322.

RIZZI, R.; RUDORFF, B. F. T.; Estimativa da área de solo no Rio Grande do Sul por meio de imagens de Satélite Landsat. *Revista brasileira de Cartografia*, CCampinas v. n. 57/03, p. 226-234, 2005.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the Great Plains with ERTS. In Earth Resources Tecnology Satellite-1 Symposium, 3,. Proceedings. Washington., [S. I.], v. 1, Sec. A, p. 309-317, 1973.

ROVEDDER, J. **Validação da classificação orientada a objeto em imagens de satélite IKONOS II e elaboração de indicadores ambientais georreferenciados no município de Torres, planície costeira do Rio Grande do Sul**. 2007. Dissertação (Mestrado em Sensoriamento Remoto) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2007.

RUDORFF, C. M. **Estudo da Composição das Águas da Planície Amazônica por Meio de Dados de Reflectância do Sensor Hyperion/EO-1 e de Espectrorradiômetro e Campo Visando a Compreensão da Variação Temporal dos seus Constituintes Opticamente Ativos**. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto de Pesquisas Espaciais, São José dos Campos, 2006.

SANCHES, I. D.; GÜRTLER, S.; FORMAGGIO, A. R. Discriminação de variedades de citros em imagens CCD CBERS-2. *Ciência Rural*., Santa Maria v. 38, n. 1, p. 103-108, jan-fev, 2008.

SCHRAMM, V. F.; VIBRANS, A. C. Uso de imagens hiperespectrais (EO-1 Hyperion) para detalhamento da detecção das formações florestais na bacia do Itajaí. *Dynamis revista tecno-científica*, [S. I.], v. 13, n.1, p. 59-69, 2007.

SILVA, T. S. F. **Imagens EOS-Modis e Landsat 5 TM no estudo da dinâmica das comunidades de macrófitas na Várzea amazônica**. 2007. Dissertação (Mestrado em

Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São Paulo, São José dos Campos 2007.

da SILVA, J. F.; de ASSIS, H. Y. E. G.; BRITO, A. V.; ALMEIDA, N. V. VANT como ferramenta auxiliar na análise da cobertura e uso da terra. X CONGRESSO BRASILEIRO DE AGROINFORMÁTICA, 2015, Ponta Grossa. **Anais...** 2015.

SMOLA, A. J.; BARTLETT P. L.; SCHOLKOPF B.; SCHUURMANS D.; Advances in large margin classifiers. **Massachusetts Institute of Technology**. London, England: Ed. MIT Press, 2000.

SOUZA, S. B. de; FERREIRA JUNIOR, L. G. Relação entre temperatura de superfície terrestre, índices espectrais e classes de cobertura da terra no município de Goiânia (GO). **Revista Espaço Geográfico em Análise**. Paraná, v. 26. p. 75–99, 2012.

SOUZA, R. T. **Avaliação de classificadores na classificação de radiografias de tórax para o diagnóstico de pneumonia infantil**. 2013. Dissertação (Mestrado em Ciência da Computação) - Instituto de Informática, Universidade Federal de Goiás, Goiânia, 2013.

STEELE, C. M.; BESTELMEYER, B.T.; SMITH, P.L.; YANOFF, S.; BURKETT, L.M.; Spatially explicit representation of state-and-transition models. **Rangeland Ecol. Manag.** v. 65, p. 213–222, 2012.

STEFFEN, C. A. Reflectância. São José dos Campos, **Instituto Nacional de Pesquisas Espaciais-INPE**, INPE 5638. PUD/070, 1995.

TISOT, D. A.; FORMAGGIO, A. R.; RENNÓ, C. Eficácia de dados Hyperion/EO-1 para identificação de alvos agrícolas: Comparação com dados ETM⁺/LANDSAT-7. **Engenharia Agrícola**. Jaboticabal, v. 27, n. 2, p. 511-519, 2007.

THEILER, J.; GISLER, G. A contiguity-enhanced k-means clustering algorithm for unsupervised multispectral image segmentation. **Proc SPIE** **3159**. pgs 108-118, 1997.

THENKABAIL, P. S.; ENCLONA, E. A.; ASHTON, M. S.; LEGG, C.; DE DIEUE, M. J. Hyperion, IKONOS, ALI and ETM plus sensors in the study of African rainforests. **Remote Sensing of Environment**, [S. I.], v. 90, p. 23-43, 2004.

TONELI, C. A. Z. **Estimativa da cobertura arbórea utilizando a combinação de imagens ikonos e Landsat**. 2008. Dissertação (Mestrado em Engenharia Florestal) – Universidade Federal de Lavras, Lavras, 2008.

TUNDISI, J. G. **Limnologia**. São Paulo: Oficina de Textos, 2008.

UNITED STATES GEOLOGICAL SURVEY USA. USGS. **EarthExplorer**. Disponível em: <http://landsat.usgs.gov/Landsat8_Using_Product.php>. Acesso em: setembro de 2013.

UNITED STATES GEOLOGICAL SURVEY USA. USGS. **EarthExplorer**. Disponível em: <https://lta.cr.usgs.gov/EO1.html#acquisition_date>. Acesso em: maio de 2015.

VALÉRIO, A. M. **O uso do sensoriamento remoto orbital e de superfície para o estudo do comportamento do corpo de água do reservatório de Manso, MT, Brasil.** 2009. Dissertação (Mestrado em Sensoriamento Remoto), Instituto Nacional de Pesquisas Espaciais, São Paulo, São José dos Campos, 2009.

VAN DER LINDEN, S.; RABE, A.; HELD, M.; WIRTH, F.; SUESS, S.; OKUJENI, A.; HOSTERT, P. Image SVM Classification, **Manual for Application: imageSVM version 3.0.** Humboldt-Universität zu Berlin, Germany, 2014.

VAPNIK, V.N. **The Nature of Statistical Learning Theory.** USA: Springer, 2nd ed., 1999.

VENTURIERI, A.; SANTOS, J. R. **Técnicas de classificação de imagens para análise de cobertura vegetal.** In: Assad, E. D.; Sano, E. E. Sistema de Informações Geográficas, Aplicações na Agricultura. Brasília, EMBRAPASPI/EMBRAPA-CPAC, Parte III, Capítulo 18, 434 p. 1998.

XIE, Y.-S.; WANG, J.-N.; SHANG, K. An improved approach based on Moment Matching to Destriping for Hyperion data. **Procedia Environmental Sciences**, [S. I.], v. 10, n., p. 319-324, 2011.

XU, R.; WUNSCH II, D. Survey of Clustering Algorithms. **IEEE Transactions on Neural Networks.** v. 16, n. 3, May 2005.

WHITE, J. C.; GÓMEZ, C.; WULDER, M. A.; COOPS, N. C. Characterizing temperate forest structural and spectral diversity with Hyperion EO-1 data. **Remote Sensing of Environment.** [S. I.], v. 114, p. 1576–1589, 2010.

WEISS, C. V. da C.; CAMARGO, D. C. S.; ROSCA, E. H.; ESPINOZA, J. Análise comparativa entre métodos de correção atmosférica em imagens do sensor Operational Land Imager (OLI), plataforma Landsat 8. **Scientia Plena.** Aracajú, v. 11, n. 2, p. 1-8, 2015.

ZHAN, Q.; MOLENAAR, M.; LUCIEER, A. Pixel unmixing at the subpixel scale based on land cover class probabilities: application to urban areas. In: FOODY, G.M.; ATKINSON, P.M. (Eds.). **Uncertainty in remote sensing and GIS.** Chichester: Wiley, p. 59-76, 2002.