



Uso do sensoriamento remoto como estratégia para a análise e gestão do uso dos solos

Use of remote sensing as a strategy for the analysis and management of land uses

Efraim Martins Araújo¹, George Leite Mamede², João Paulo Madeiro do Vale³, Eliakim Martins Araújo⁴

¹ Instituto Federal de Educação, Ciência e Tecnologia do Ceará, Campus Iguatu, Ceará, Brasil.

² Universidade da Integração Internacional da Lusofonia Afro-Brasileira (Unilab), Ceará, Brasil.

³ Universidade Federal do Ceará, Ceará, Brasil.

⁴ Instituto Federal de Educação, Ciência e Tecnologia do Maranhão, Campus Viana, Maranhão, Brasil.

Contato: eliakim.araujo@ifma.edu.br

Palavras-Chave

hiperespectral
Hyperion
índice de kappa
classificação de imagens

RESUMO

Este artigo tem por objetivo analisar a eficiência da classificação supervisionada na detecção de usos das terras no entorno de dois reservatórios rurais, situados no Assentamento 25 de Maio, no Município de Madalena – CE. Analisou-se o desempenho de diferentes classificadores supervisionada (Máxima Verossimilhança, KNN, Mínima Distância, SVM e Random Forest) em imagens multiespectrais (Landsat 8) e hiperespectrais (Hyperion) para detecção e diferenciação das classes de uso do solo. A classificação supervisionada, apresentou-se como uma ferramenta robusta na espacialização dos usos das terras, 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 multiespectral e hiperespectral. 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. Os resultados mostraram um excelente desempenho dos classificadores quando aplicado à imagem do sensor Hyperion, com Kappa de 0,81 (SVM) e 0,78 (Máxima verossimilhança) e o Landsat 8 um Kappa de 0,53 (Máxima verossimilhança).

Key-word

hyperspectral
Hyperion
kappa index
image classification

ABSTRACT

This article aims to analyze the efficiency of the supervised classification in the detection of land uses around two rural reservoirs, located in the 25 de Maio Settlement, in the Municipality of Madalena - CE. The performance of different supervised classifiers (Maximum Likelihood, KNN, Minimum Distance, SVM and Random Forest) was analyzed in multispectral (Landsat 8) and hyperspectral (Hyperion) images for the detection and differentiation of land use classes. The supervised classification presented itself as a robust tool in the spatialization of land uses, as it was able to separate both different targets (water, soil and vegetation) and similar targets (macrophytes, ebb, native vegetation, agriculture and thin vegetation) when applied. images from multispectral and hyperspectral sensors. It should be noted, however, that the performance of the classifiers applied to the image of the Hyperion sensor was, in general, superior to those obtained in Landsat 8 image, which can be explained by the high spectral resolution of the first. The results showed an excellent performance of the classifiers when applied to the Hyperion sensor image, with Kappa of 0.81 (SVM) and 0.78 (Maximum likelihood) and Landsat 8 a Kappa of 0.53 (Maximum likelihood).

Informações do artigo

Recebido: 05 de maio, 2020

Aceito: 01 de março, 2021

Publicado: 30 de abril, 2021

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 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.

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).

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 uso das terras 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.

Avanços mais recentes na tecnologia de sistemas de sensores espectrais permitiram o surgimento de uma nova geração de sistemas de sensores, denominados de hiperespectrais, capazes de coletar simultaneamente dados de uma cena em uma área em um número 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

especial) medidas espectrais em bandas estreitas e contínuas, disponibilizando grande quantidade de informação espectral (XIE et al., 2011).

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 e Marengo, localizados no Assentamento 25 de Maio, através de dados multiespectrais e hiperespectrais coletados pelos sensores *Landsat 8* (22/09/2014) e *Hyperion* (19/10/2014) respectivamente. Portanto, o estudo envolve a análise de espectros de referência e métodos de quantificação destas áreas, através de classificadores supervisionados de imagens de satélites. 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.

Material e Métodos

A pesquisa foi realizada no Assentamento 25 de Maio (25M) apresentado na Figura 1, 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, localizados na bacia hidrográfica do rio Banabuiú.

O assentamento 25 de Maio possui uma área total de 22.992 ha e se encontra inserido nos limites entre três municípios, Madalena, Boa Viagem e Quixeramobim, localizando-se a 187 km da capital, Fortaleza-CE. 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).

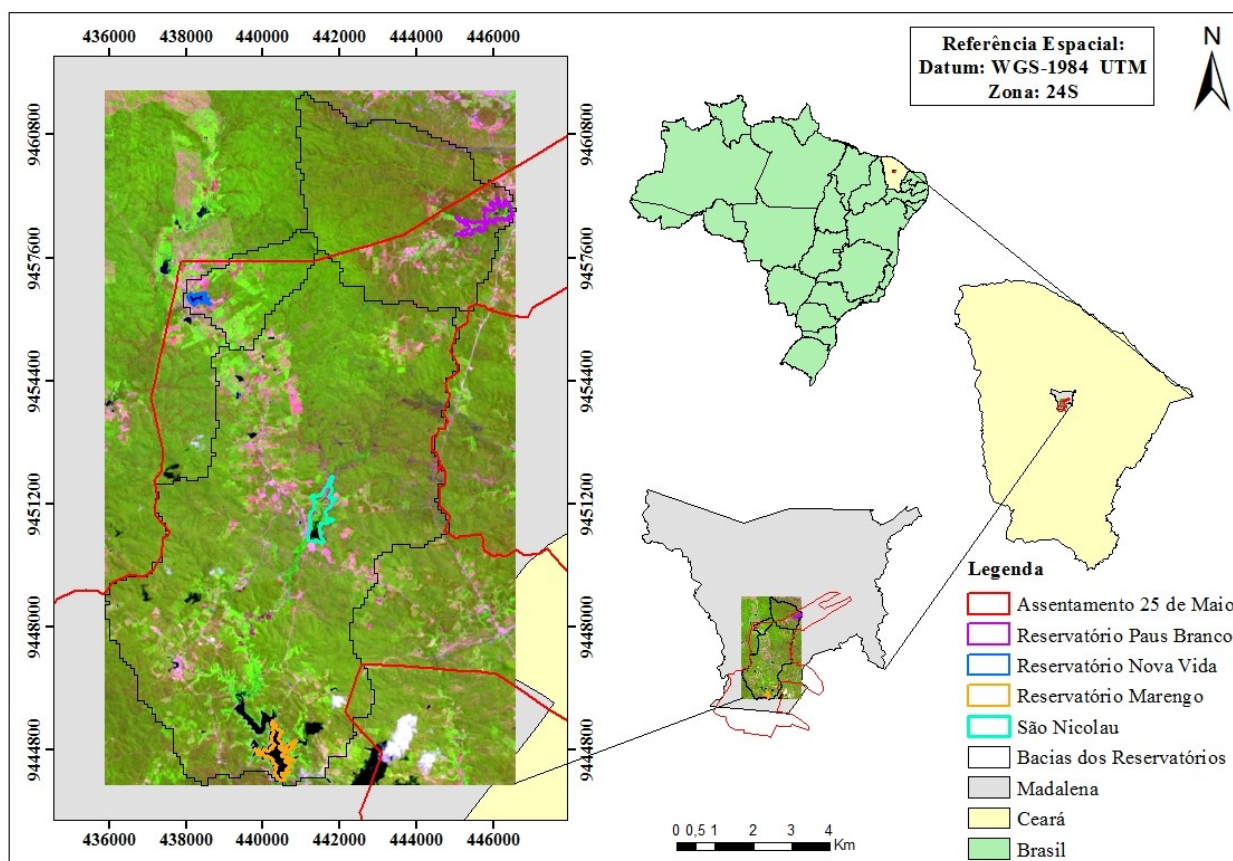
Foram selecionados para investigação no contexto desta pesquisa, os reservatórios, Paus Brancos e Marengo, pois foram os únicos a apresentar armazenamento de água durante todo o desenvolvimento da pesquisa. Estes açudes apresentam características físicas diferentes (Tabela 1) como área da bacia hidráulica e volume de armazenamento, e uso do solo no entorno (agricultura, pecuária, vazante e habitação).

Tabela 1. Características físicas dos reservatórios no Assentamento 25 de Maio em Madalena-CE

Reservatório	Capacidade (hm ³)	Área da bacia (km ²)	Área do espelho d'água (km ²)	Classificação
Paus Brancos	5,5	21	0,57	Pequeno
Marengo	18	75	3,1	Médio

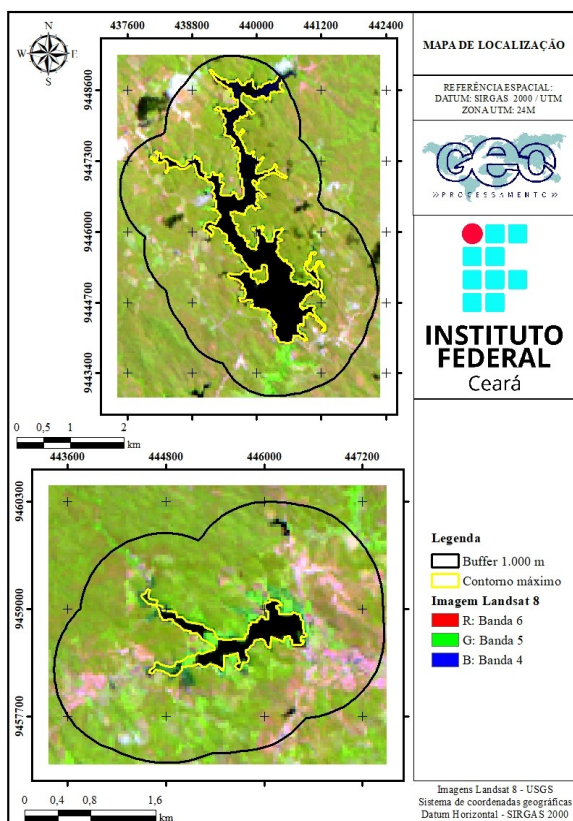
Fonte: Autor (2017)

Figura 1. Localização do Assentamento 25 de Maio no Estado do Ceará, destacando as bacias hidrográficas dos três reservatórios considerados.



Fonte: Autor (2017)

Figura 2. Área de influência considerada no entorno dos reservatórios



Fonte: Autor (2017)

A fim de compreender melhor o uso e ocupação das terras no entorno dos reservatórios Paus Branco e Marengo, decidiu-se considerar uma área com distanciamento mínimo de 1 km através da ferramenta *buffer* no programa Arc Gis® 10.2, em torno do contorno máximo (Figura 2) da bacia hidráulica de cada reservatório, para garantir a existência de diferentes classes.

A obtenção do contorno máximo (Tabela 1) dos reservatórios (Figura 2), se deu através da imagem Landsat 5 do dia 24 de julho de 2004, por ser um ano com precipitações pluviométrica acima da média em que os reservatórios superficiais supostamente estavam cheios, em análise comparativa com outros períodos.

Aquisição e seleção de imagens

As imagens orbitais digitais dos satélites *Landsat 8* (multiespectral) obtida do dia 22 de setembro de 2014 e *Hyperion* (hiperespectral) de 19 de outubro de 2014, 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.

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*).

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 termais (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 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. O critério para a seleção das imagens levou em consideração a cobertura de nuvens.

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. A cena do Hyperion apresenta órbita 217 e ponto 63 e possuem resolução espacial de 30 metros.

A imagem Hyperion foi pré-processada pelo software ENVI® 5.1 Neste processamento, foi realizada a conversão dos dados de LIR para o formato padrão do ENVI® 5.1. Para isso, foi utilizado um plugin disponibilizado no site da ITT *Visual Information Solutions*, denominado de Hyperion Tools. A 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 apresentaram valores errôneos, onde foi feita por meio da interpolação dos valores dos vizinhos horizontais. Também foi gerado um arquivo com os fatores de escala para utilização na correção atmosférica.

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.

Correção atmosférica

Foi realizado o processamento de correção atmosférica, das imagens dos dois satélites (*Landsat 8* e *Hyperion*). A correção atmosférica é o procedimento que tira o efeito de dispersão da energia eletromagnética, onde consiste em corrigir o espalhamento atmosférico e estimar a interferência atmosférica a partir dos números digitais (ND) das imagens.

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 algoritmo de análise atmosférica (FLAASH) é baseado no processamento pixel a pixel, proporcionando a vantagem de fornecer uma única assinatura espectral para cada pixel, quando possível.

Com o intuito de melhorar o desempenho da correção atmosférica, a imagem hiperespectral foi recortada para definir-se uma área de estudo menor, visando obter estimativas mais precisas dos parâmetros das características atmosféricas da área de interesse. Em seguida, foi criado um arquivo ASCII com valores específicos de fator de escala para cada banda, para compatibilizar as unidades, pois as bandas do SWIR tiveram como fator de escala o valor 800, enquanto que nas bandas do VNIR, o fator de escala foi de 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 (Tabela 2).

Tabela 2. Parâmetros utilizados para efetuar a correção atmosférica do satélite *Hyperion*

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 Aerossol	Rural
Recuperação de Aerossol	Nenhum
Visibilidade inicial	40
Polimento espectral	Não
Calibração do comprimento de onda	Sim
Órbita	217
Ponto	63

Fonte: Autor (2017)

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. 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 nm (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.

Correção geométrica

O georreferenciamento da imagem foi 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, foi avaliado o resíduo em unidades de pixel, seguido pela reamostragem dos pixels da cena *Hyperion* pelo método de vizinho mais próximo.

Classificação de imagens

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

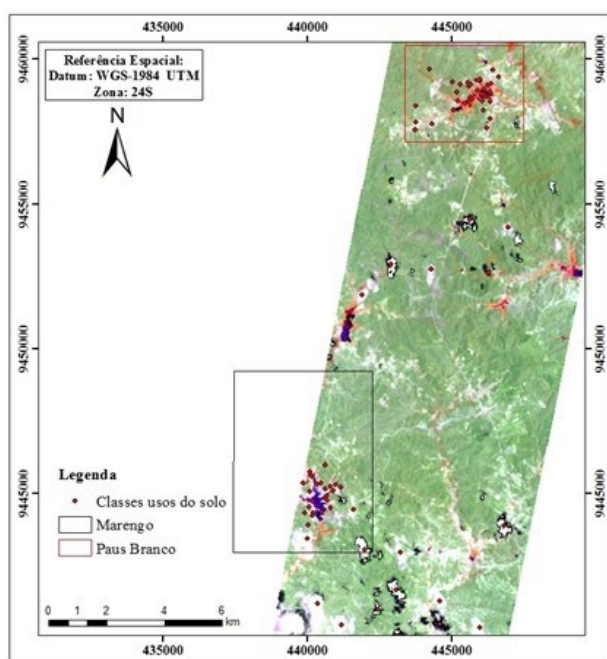
Na classificação supervisionada, foram utilizados algoritmos para nomear os pixels em uma imagem de forma a representar tipos específicos de cobertura terrestre, ou classes que são conhecidas a priori.

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 para a realização da classificação.

A coleta das amostras representativas das classes dos usos das terras, foram obtidas através de levantamento de pontos em torno dos reservatórios Paus Branco e Marengo. Os pontos foram obtidos com o auxílio de um GPS de navegação Garmin® modelo *etrex*, que apresentou 3 metros de precisão absoluta por ponto, coletados em campanhas realizadas em diferentes períodos do anos e em diferentes anos.

Durante a campanha, realizada no Assentamento 25 de Maio nos dias 17, 18 e 19 de outubro de 2014, foram levantados mais de seiscentos pontos (Tabela 3) de diferentes classes no entorno dos reservatórios Paus Branco e Marengo (Figura 3), o que permitiu uma representação significativa e um elevado conhecimento numa escala adequada às características existente na área de estudo.

Figura 3. Espacialização dos pontos utilizados para a classificação supervisionada das imagens *Landsat 8* e *Hyperion*



Fonte: Autor (2017)

As classes de uso de solo foram adotadas e divididas em sete categorias: 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 está descrito na Tabela 3. Em seguida, aplicaram-se técnicas de classificação supervisionada para toda a cena imageada pelos sensores *Landsat 8* e *Hyperion*, o que implicou na interação do analista com o sistema de análise, visando avanços significativos nos resultados produzidos. A classificação depende de informações provenientes do analista e permite analisar e identificar as diferenças de reflectância nas imagens, e consequentemente 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 (DUBE; MUTANGA, 2015).

Tabela 3. 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: Autor (2017)

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, *K-Nearest Neighbors* (KNN), *Random Forest*, para as imagens *Landsat 8* e *Hyperion*. Ainda foi utilizado o classificador *Support Vector Machine* (SVM) para a imagem do satélite *Hyperion*. Diversos autores como WHITE et al. (2010); XIE et al. (2011); JAFARI e LEWIS (2012), desenvolveram pesquisas relacionadas com a quantificação de classes utilizando imagens hiperespectrais do sensor *Hyperion*. Contudo, alguns citam apenas as faixas dos comprimentos de ondas adotados para classificar uma imagem, sem a preocupação de averiguar quais as bandas específicas e/ou exatas para a realização duma composição RGB

As bandas utilizadas para a composição RGB do satélite *Hyperion* para a determinação das classes, foram determinadas através do classificador SVM, que analisou todas as 155 bandas disponíveis do sensor, identificou quais bandas proporcionou separação das classes de interesse.

O processamento foi 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).

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 1) (MOREIRA, 2011).

$$P(w_j/x_o) = \frac{P(w_j) \cdot P(x_o/w_j)}{P(x_o)} \quad (\text{Eq. 1})$$

$P(x/w_j)$ 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 2 (MOREIRA, 2011).

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

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 .

Classificador de mínima distância

O classificador de mínima distância à média 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, e definidas por pontos previamente conhecidos. Segundo MOREIRA (2011), considerando um espaço n-dimensional, o cálculo é feito da através da Equação 3.

$$d(x, m/w) = \sqrt{\sum_{i=1}^n (x_i - m_i)^2} \quad (\text{Eq. 3})$$

$d(x, m/w)$ 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).

O treinamento busca caracterizar cada pixel de forma que as distâncias entre os atributos dos pixels de um agrupamento sejam mínimas, 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 obtidos pelo classificador (MOREIRA, 2011).

Classificador KNN

O KNN é diferente de outros métodos, as amostras são classificadas de acordo com características dos K-vizinhos mais próximos, obtidos por um ponto conhecido.

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. 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 pela Equação 4.

$$d(x, y) = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_n - y_n)^2} \quad (\text{Eq. 4})$$

O KNN é um classificador que possui apenas um parâmetro livre, que é o número de K-vizinhos, de busca controlado pelo analista 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, como classes semelhantes o processo é bem aceitável, com resultados condizentes com a realidade e com elevado grau de acurácia na representação de alvos terrestres (SOUZA 2013).

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 como foi apresentado por JAMES et al. (2013).

SVM – Suport Vector Machine

Para a classificação das imagens *Hyperion*, 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. O algoritmo *Suport Vector Machine*, determina limites de decisão para a separação das classes bem como a minimização dos erros (MOUNTRAKIS; JUNGHOIM, 2010). 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). O classificador apresenta o gama que é o ajuste da classe, calibrado para cada alvo e o parametro de penalidade que é consequencia da acuracia da classificador em função dos usos definidos. Os valores sugeridos pelo programa para a variável gama e para o parâmetro de penalidade foram 0,03 e 100, respetivamente. Estes valores advêm de uma calibração, após a informação dos pontos levantados em campo das diferentes classes de usos do solo.

Avaliação de desempenho dos classificadores de imagens

A avaliação da exatidão do mapeamento em relação à verdade terrestre foi realizada por meio da comparação de pontos aleatórios no mapa que foram obtidos através de levantamento realizado em campo (Equação 5). Após a confirmação das classes para cada ponto amostrado, foi criado um arquivo de valores que relacionou os pontos amostrais com a verdade terrestre. Por seguinte, foi gerada uma imagem raster dos pontos amostrais, para então, efetuar-se a análise estatística da classificação supervisionada.

Para a classificação supervisionada, é fornecida uma matriz de erros, onde o índice de Kappa geral é apresentando pelo modelo estatístico subdividido por categoria. Ainda segundo PIROLI (2010), nesta matriz de confusão, o erro de omissão expressa a imperfeição da classificação, e o erro de inclusão informa a delimitação excessiva de categoria em campo.

$$k = \frac{P_o - P_c}{1 - P_c} \quad (\text{Eq. 5})$$

k é o Coeficiente de concordância de Kappa;
 P_o é a concordância observada;
 P_c é a proporção de concordância ao acaso.

Foram definidas diferentes classes associadas ao índice Kappa para qualificar os mapas obtidos pelos vários métodos de classificação (Tabela 4).

Tabela 4. Qualidade da classificação associadas 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 6, 7 e 8.

$$k_{\text{individual}} = \frac{P_{oi} - P_{ci}}{1 - P_{ci}} \quad (\text{Eq. 6})$$

k_{individual} é o Coeficiente de concordância de Kappa individual;
 P_{oi} é a concordância observada;
 P_{ci} é a proporção de concordância ao acaso.

$$P_{oi} = \frac{N}{P} \quad (\text{Eq. 7})$$

N é o número de acertos do uso na diagonal principal;
 P é o total de pontos do uso obtido em campo.

$$P_{ci} = \frac{\sum C}{100} \quad (\text{Eq. 8})$$

∑C é o somatório da coluna do uso na matriz confusão.

Resultados e Discussão

Classificação imagem Landsat 8

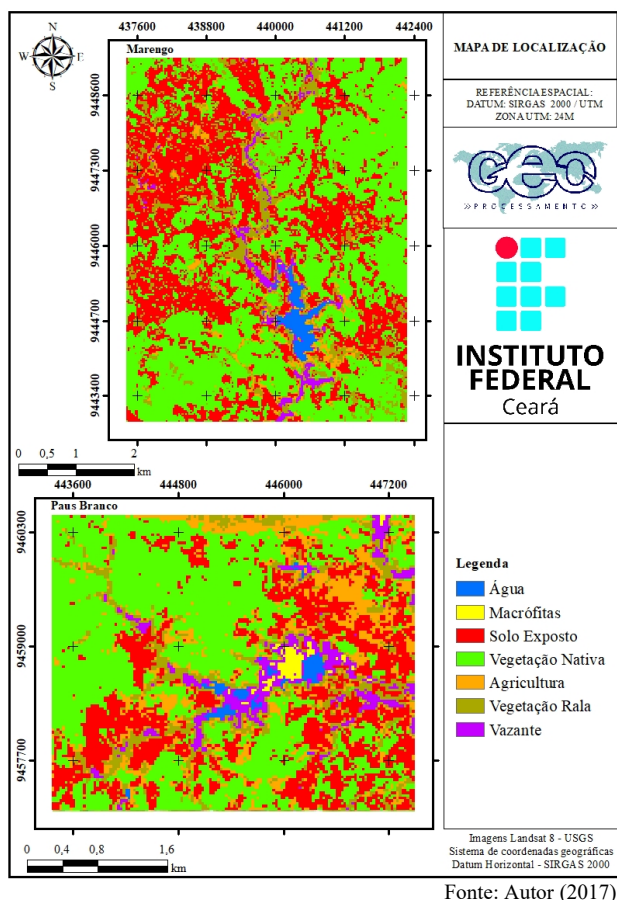
A separação das classes foi melhor representada pelas bandas 4, 5 e 6, do satélite *Landsat 8*, pois foi capaz de diferenciar alvos como água, solo exposto e vegetação nativa adequadamente

A aplicação do método de classificação supervisionada pelo método Máxima Verossimilhança nas imagens *Landsat 8*, permitiu a separação de classes como agricultura e vegetação rala (Figura 4).

Possibilitando a geração de um mapa de uso e ocupação das terras preciso e bastante condizente com a realidade, de acordo com os índices de Kappa obtidos.

A utilização de imagens multiespectrais como é caso do satélite *Landsat 8* apresenta elevada dificuldade na separação de usos do solo semelhante, 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.

Figura 4. Espacialização das classes obtido através da classificação supervisionada da imagem obtida pelo do satélite *Landsat 8* de 22/09/2014 pelo método de Máximo Verossimilhança



Fonte: Autor (2017)

Classificação imagem *Hyperion*

Buscando a obtenção de uma maior eficiência na separação das classes: água, macrófitas, solo exposto, vegetação nativa, vegetação rala, vazante, nuvem e sombra, foi necessário 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.

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 5).

Essa composição foi utilizada para todos os classificadores.

A classificação de imagem do sensor *Hyperion* através do algoritmo SVM apresenta eficiência extraordinária na separação de alvos com reflectância semelhante, podendo citar GEORGE et al. (2014).

Estes autores, em pesquisa realizada na região ocidental do Himalaia, buscando diferenciar espécies arbóreas através de imagens hiperespectrais através do satélite *Hyperion*, utilizaram o classificador SVM, que é um classificador de uso exclusivo para imagens

hiperespectrais na determinação dos alvos, onde o mesmo obteve um Kappa de 0,79, mostrando a eficiência desse classificador na espacialização de cobertura vegetal.

Tabela 5. Desempenho das bandas do satélite *Hyperion* para determinação das classes dos usos do solo

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

Kappa = 0,81 – Excelente

Legenda: As cores indicam os números das bandas utilizadas nos canais: R – vermelho; G – verde; B – azul. Fonte: Autor (2017)

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 6 e na Figuras 5.

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 6.

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.

A utilização de uma imagem de um satélite hiperespectral, onde o sensor *Hyperion*, promoveu um ganho significativo na separação das classes existentes na área de estudo, seja usando o método SVM como também utilizando o classificador 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. A utilização do classificador Máxima Verossimilhança permitiu comparar o desempenho na utilização das imagens *Landsat 8* com as das imagens *Hyperion*.

Tabela 6. Valores do índice de Kappa individual, obtidos através da classificação supervisionada por diferentes métodos, da imagem Hyperion

Classes	Máxima Verossimilhança Landsat 8	Máxima Verossimilhança Hyperion	SVM Hyperion	KNN	Mínima Distância	Random Forest
Água	1,00 -Excelente	0,97 - Excelente	<u>0,98</u> - Excelente	0,67 – Muito Boa	0,67 – Muito Boa	0,62 – Muito Boa
Macrófitas	0,83 - Excelente	0,88 - Excelente	<u>0,91</u> - Excelente	0,77 – Muito Boa	0,76 – Muito Boa	0,72 – Muito Boa
Solo exposto	<u>0,57</u> - Boa	0,69 - Muito Boa	0,70 – Muito Boa	0,83 - Excelente	0,72 – Muito Boa	0,57 - Boa
Vegetação nativa	0,61 – Muito Boa	0,74 - Muito Boa	0,77 - Muito Boa	0,61 – Muito Boa	0,66 – Muito Boa	0,56 - Boa
Agricultura	0,33 - Razoável	0,63 – Muito Boa	0,76 - Muito Boa	<u>0,94</u> - Excelente	0,56 - Boa	0,51 - Boa
Vegetação rala	0,06 - Ruim	0,59 - Boa	0,66 - Muito Boa	0,46 - Boa	0,42 - Boa	<u>0,65</u> – Muito Boa
Vazante	0,35 - Razoável	<u>0,73</u> – Muito Boa	0,61 - Muito Boa	0,50 - Boa	0,45 - Boa	<u>0,76</u> – Muito Boa
Nuvem	0,52 - Boa	0,89 - Excelente	0,90 - Excelente	0,83 - Excelente	0,94 - Excelente	0,94 - Excelente
Sombra	0,62 – Muito Boa	0,91 - Excelente	0,91 - Excelente	1,00 - Excelente	1,00 - Excelente	1,00 - Excelente
Kappa Médio	0,53 Boa	0,78 Muito Boa	0,81 Excelente	0,73 Muito Boa	0,69 Muito Boa	0,70 Muito Boa

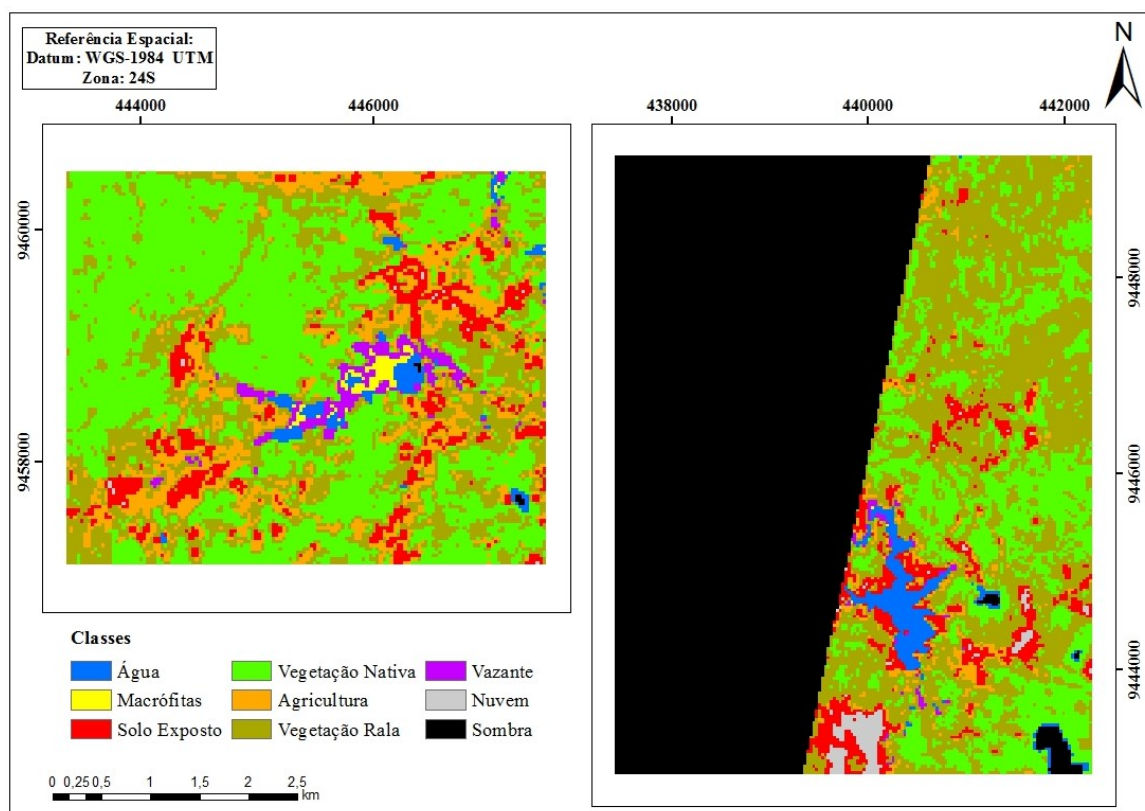
Legenda: Valores sublinhados informar os maiores valores encontrados por uso.

Fonte: Autor (2017)

Vale destacar a importância dos resultados obtidos através da classificação utilizando o classificador Máximo Verossimilhança pela facilidade de uso do mesmo, tanto pela simplicidade dos métodos, pela forma de processamento, pela separação de amostras utilizadas para a classificação e por último e não menos importante, pela vasta disponibilidade em programas de geoprocessamento. O método conseguiu separar adequadamente as classes macrófitas, vazante, agricultura

e vegetação rala, apesar destas classes possuírem respostas espectrais próximas. GEORGE et al. (2014) salientaram que as informações relacionadas a reflectância obtidas nas bandas estreitas de dados do satélite *Hyperion* tiveram potencial para capturar variabilidade espectral das espécies de plantas, melhorando assim o mapeamento de diferentes espécies vegetais.

Figura 5. Espacialização das classes no entorno dos reservatórios Paus Brancos e Marengo obtido através da classificação supervisionada Máximo Verossimilhança (R – 51; G – 161; B – 19) da imagem do satélite *Hyperion* de 19/10/2014



Fonte: Autor (2017)

Um resultado valioso encontrado na classificação supervisionada através do método Máximo Verossimilhança 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 na Figura 5.

Resultados semelhantes foram obtidos por COULTER et al. (2016) em pesquisa realizada em Gana, localizado no continente africano, 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 de outras classes como vazante, com características de reflectância bem similares, como pode ser observado na Figura 5. Essa classe apareceu com predominância no reservatório Paus Brancos. 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, que contribui significativamente na presença de matéria orgânica depositada na água.

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. Não foi utilizado o classificador SVN nessa análise comparativa, por se tratar de um classificador que utiliza todas as bandas do satélite e o intuito foi realizar a comparação entre classificadores que utilizam imagens RGB.

Na classificação supervisionada usando o método de Máxima Verossimilhança, 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 6.

O Kappa geral encontrado na classificação supervisionada Máxima Verossimilhança usando a imagem do satélite *Hyperion* foi 0,78 sendo classificado com muito boa. Resultado semelhante foram obtidos por BLANCO et al. (2014) em pesquisa realizada 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*. Outros resultados similares 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.

A análise do Kappa geral da imagem *Hyperion* mostrou que o classificador supervisionado Máxima Verossimilhança (Kappa geral = 0,78) apresentou melhores resultados do que o classificador KNN (Kappa geral = 0,73), *Random Forest* (Kappa geral de 0,70) e Mínima Distância (Kappa geral de 0,69) (Tabela 6).

Os valores do Kappa individual obtidos através da classificação supervisionada da imagem do satélite *Hyperion* pelo método Máxima Verossimilhança, foram superiores aos resultados obtidos pelos demais classificadores utilizados (KNN, Mínima Distância e *Random Forest*) em três classes: água, macrófitas e vegetação nativa. 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.

GALVÃO et al. (2005), em pesquisa realizada para diferenciar tipos de espécies vegetais, observaram que a imagem hiperespectral 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.

Conclusão

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 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.

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.

Os dados hiperespectrais demonstraram ser uma boa alternativa para análise de uso e ocupação das terras 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.

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*). 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.

Contribuição dos autores

Os autores desse artigo declaram que contribuíram de forma igualitária na sua elaboração.

Agradecimentos

A Universidade Federal do Ceará pela oportunidade de qualificação de doutorado e a CAPES pelo financiamento da bolsa de estudos

Referências

- 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**, v. 38, n., p. 150-163, 2015.
- 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**, v. 29, n., p. 11-21, 2014.
- BREIMAN, L. Random forests. *Machine Learning*, Boston, v.45, n.1, p. 5-32, 2001.
- 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**, v. 184, p. 396-409, 2016.
- 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**, v. 101, n. 1, p. 36-46, 2015.
- 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**, v. 1, n. 57, p. 7-14, 2005.
- 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**, v. 28, n.2, p. 140-149, 2014.
- GOLDSCHMIDT, R. R.; PASSOS, E. *Data Mining: Um Guia Prático*. Rio de Janeiro: Elsevier, 2005.
- JAMES, G.; HASTIE, T.; TIBSHIRANI, R. *An introduction to statistical learning: with applications in R*. London: Ed. Springer, 2013. 429 p.
- JAFARI, R.; LEWIS, M. M. Arid land characterization with EO-1 Hyperion hyperspectral data. **International Journal of Applied Earth Observation and Geoinformation**, v. 19, p. 298-307, 2012.
- LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. *Biometrics*, 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**, v. 56, n. 2, p. 319-333, 2011.
- 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**, v. 646, p. 123-131, 2010.
- 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.
- 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.
- 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.
- 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.
- 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.
- UNITED STATES GEOLOGICAL SURVEY USA. USGS. EarthExplorer. Disponível em: <http://landsat.usgs.gov/Landsat8_Using_Product.php>. Acesso em: setembro de 2013.
- 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: image SVM version 3.0*. Humboldt-Universität zu Berlin, Germany, 2014.
- XIE, Y.-S.; WANG, J.-N.; SHANG, K. An improved approach based on Moment Matching to Destriping for Hyperion data. **Procedia Environmental Sciences**, v. 10, n., p. 319-324, 2011.
- 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**, v. 114, p. 1576-1589, 2010.