

**AVALIAÇÃO DA QUALIDADE DE CLASSIFICADORES DE
IMAGENS LANDSAT 8 EM AMBIENTE COMPUTACIONAL SAGA
GIS PARA MAPEAMENTO DE COBERTURA DA TERRA NO
BIOMA CERRADO**

**QUALITY ASSESSMENT OF LANDSAT 8 IMAGE CLASSIFIERS IN A SAGA
GIS COMPUTER ENVIRONMENT FOR LAND COVERING MAPPING IN
THE CERRADO BIOME**

**EVALUACIÓN DE LA CALIDAD DE LOS CLASIFICADORES DE IMAGEN
LANDSAT 8 EN UN ENTORNO COMPUTACIONAL SAGA GIS PARA EL
MAPEO DE COBERTURA DE TIERRAS EN EL BIOMA DE CERRADO**

Antonia Sueli Silva Sousa

Mestre em Desenvolvimento Socioespacial e Regional pela Universidade Estadual do Maranhão – UEMA. Especialista em Geoprocessamento pelo Instituto Federal do Maranhão – IFMA. Graduada em Geografia pela Universidade Federal do Maranhão – UFMA.
antoniasuelisousa@gmail.com / <http://lattes.cnpq.br/6377922484215163>

Paulo Roberto Mendes Pereira

Doutorando em Geografia pela Universidade Estadual de Campinas – UNICAMP. Mestre em Geografia pela Universidade Estadual Júlio de Mesquita Filho – UNESP. Graduado em Geografia pela Universidade Federal do Maranhão – UFMA.
p.roberto18@hotmail.com / <http://orcid.org/0000-0002-8749-6699>

Audivan Ribeiro Garcês Júnior

Doutorando em Geografia pela Universidade Federal do Ceará – UFC. Mestre em Saúde e Ambiente e Graduado em Geografia pela Universidade Federal do Maranhão – UFMA.
audivanribeiro@gmail.com / <http://orcid.org/0000-0003-1047-6996>

Recebido: 26/07/2019; Aceito: 08/12/2020; Publicado: 12/10/2021.

RESUMO

Uma das principais aplicações das imagens de satélites é a caracterização da cobertura terrestre, que a partir do uso de técnicas de classificação permite monitorar as transformações espaciais da superfície terrestre. O Sistema Automatizado de Análise Geociêntífica – Saga Gis apresenta um conjunto de ferramentas voltado à análise geográfica, incluindo pacotes de classificação de imagens digitais, onde se destacam os classificadores: Maxver, Mahalanobis, distância mínima, paralelepípedo. O objetivo deste artigo é avaliar o potencial dos classificadores de imagens do Saga Gis no bioma Cerrado, sendo objeto de estudo, o município de Brejo-MA. Foi utilizada uma imagem Landsat 8 de 2017, com resolução espacial de 30 metros. A metodologia consistiu na aplicação de um conjunto de técnicas de tratamento digital de imagens, segmentação, extração de atributos e classificação. A análise dos dados pautou-se na comparação visual e análise da exatidão global e de índice Kappa. O classificador Maxver apresentou os melhores resultados para o Kappa e exatidão global, já os piores valores foram associados ao classificador paralelepípedo.

Palavras-chave: Geotecnologia; Processamento de Imagem; Acurácia, Mapeamento.

ABSTRACT

One of the main applications of satellite images is the characterization of terrestrial coverage, which from the use of classification techniques allows to monitor the spatial transformations of the terrestrial surface. The System for Automated Geoscientific Analyzes-Saga Gis presents a set of tools aimed at geographic analysis, including digital image classification packages, in which the classifiers stand out: Maxver, Mahalanobis, minimum distance, parallelepiped. The objective of this article is to evaluate the potential of the Saga Gis image classifiers in the Cerrado biome, being the object of study, the municipality of Brejo-MA. It was to use a Landsat 8 image (2017), with a spatial resolution of 30 meters. The methodology consisted of applying a set of techniques for digital image processing, segmentation, attribute extraction and classification. Data analysis was based on visual comparison and analysis of global accuracy and Kappa index. The Maxver classifier presented the best results for Kappa and overall accuracy, whereas the worst values were associated with the parallelepiped classifier.

Keywords: Geotechnology; Image Processing; Accuracy; Mapping.

RESUMEN

Una de las principales aplicaciones de las imágenes de satélite es la caracterización de la cobertura terrestre, que, a partir del uso de técnicas de clasificación, permite el seguimiento de las transformaciones espaciales de la superficie terrestre. El Sistema de Análisis Geocientífico Automatizado (Saga Gis) presenta un conjunto de herramientas orientadas al análisis geográfico, que incluyen paquetes de clasificación de imágenes digitales, en los que destacan los clasificadores: Maxver, Mahalanobis, distancia mínima, paralelepípedo. El objetivo de este artículo es evaluar el potencial de los clasificadores de imágenes Saga Gis en el bioma del Cerrado, siendo objeto de estudio, el municipio de Brejo-MA. Se utilizó una imagen Landsat 8 de 2017 con una resolución espacial de 30 metros. La metodología consistió en aplicar un conjunto de técnicas de procesamiento, segmentación, extracción de atributos y clasificación de imágenes digitales. El análisis de los datos se basó en la comparación visual y el análisis de la precisión global y el índice Kappa. El clasificador Maxver presentó los mejores resultados para Kappa y precisión general, mientras que los peores valores se asociaron con el clasificador paralelepípedo.

Palabras clave: Geotecnología; Procesamiento de imágenes; Precisión; Mapeo.

INTRODUÇÃO

O mapeamento das mudanças da cobertura da terra representa atualmente uma importante ferramenta para a geração de informações do espaço ocupado, e tem sua evolução associada diretamente ao surgimento do Sensoriamento Remoto, sendo esta a principal técnica de coleta automática de dados para o levantamento e monitoramento dos recursos terrestres, em escala global e/ou local (BIE et al., 1996; SRIVASTAVA et al., 2012; MENESES; ALMEIDA, 2012).

Os produtos oriundos do sensoriamento remoto – imagens de satélites, fotografias aéreas, etc. – representam um importante recurso para a análise das transformações do espaço geográfico em grande escala. As imagens de satélites são consideradas uma das principais fontes de informações da superfície terrestre, principalmente por conta de suas propriedades sinópticas e temporais (RODRIGUES, 2018; ARAUJO et al., 2019), que permitem analisar as mudanças espaciais em regiões de grandes extensões a um

custo relativamente baixo (MIRANDA; GOMES; GUIMARÃES, 2005; JENSEN, 2009).

Esse fator ampliou o uso de imagens de satélite nas mais diversificadas temáticas, as quais se pode destacar: mudanças no uso da terra (LAMBIN; GEIST, 2006; ISLAM et al., 2018; RODRIGUES, 2018), desmatamento e estimativa da vegetação (GRINAND et al., 2013; PARENTE et al., 2019), e expansão agrícola (SANO et al., 2009; FORMAGGIO; SANCHES, 2017; YAN et al., 2019; PEREIRA et al., 2020).

Ademais, o mapeamento temático, a partir do uso de imagens de satélites, está diretamente associado ao desenvolvimento de técnicas de classificação dessas imagens (LI et al., 2014). Rosa (2009) destaca que classificar uma imagem é reconhecer padrões homogêneos, seguida da definição de rótulos (classes), sendo seu sucesso diretamente ligado à capacidade do classificador em separar classes espectralmente distintas.

Esse processo se intensificou a partir da evolução das tecnologias computacionais, que promoveram o surgimento de diversas metodologias para o processo de extração das informações; fator que tornou a técnica mais confiável e mais próxima da realidade, e possibilitou mostrar e quantificar com maior precisão a distribuição geográfica de um tema e, posteriormente, apresentá-lo em formato de mapas, tabelas ou gráficos.

Fonseca et al. (1990) afirmam que o ato de classificar automaticamente uma imagem de sensoriamento remoto representa um desafio, quando abordados os padrões de exatidão resultantes das classificações automáticas, principalmente em ambientes de elevada homogeneidade espectral, o que dificulta a separabilidade das classes e reduz a taxa de acurácia das classificações, a exemplo do bioma Cerrado.

Dentre os muitos softwares livres, destaca-se o Sistema Automatizado de Análise Geociência-Saga Gis, software de licença aberta, projetado para a implementação de algoritmos voltados à análise geográfica. Foi criado nos anos 1990, pelo Departamento de Geografia Física da Universidade de Hamburgo, com objetivo principal de manipular dados matriciais, principalmente modelos digitais de elevação, porém, posteriormente, passou a servir de suporte para muitos outros modelos de análises, integrando também dados vetoriais e tabulares (CONRAD et al., 2015).

O Saga Gis apresenta um pacote de classificadores supervisionados de imagens digitais, que, em geral, utiliza informações das propriedades numéricas dos *pixels* presentes na imagem, a partir de um conjunto de amostras de treinamento elencadas pelo analista. É um elemento que serve de suporte para a diferenciação de classes de acordo com os atributos utilizados, nos quais se destacam os algoritmos Máxima Verossimelhança,

Distância Mínima, Paralelepípedo e Distância de Mahalanobis.

Considerando esse panorama, o objetivo deste trabalho foi avaliar o potencial de uso dos algoritmos de classificação supervisionada de imagens de Landsat 8, disponíveis no software Saga Gis para identificação de padrões de cobertura no Cerrado Maranhense, comparando os classificadores por Máxima Verossimilhança, Paralelepípedo, Distância de Mahalanobis e Mínima Distância.

Nesta perspectiva, os resultados deste estudo tendem a auxiliar em uma melhor compreensão das classes, no que tange à cobertura da terra na área. É importante ressaltar que a escolha de um classificador que melhor detalhe a região irá facilitar trabalhos futuros e auxiliará na identificação de fatores geográficos ligados ao processamento de imagem.

CLASSIFICAÇÃO DIGITAL DE IMAGEM DE SATÉLITES: uma abordagem teórica

O sensoriamento remoto tem como um de seus principais objetivos a extração das informações contidas nas imagens. É um processo que está diretamente associado ao desenvolvimento de técnicas de classificação de imagens, que possibilitam quantificar a distribuição geográfica de um determinado tema e apresentar seus resultados em diferentes formatos. Crósta (2002) afirma que a classificação de uma imagem tem como fundamento a atribuição de um significado qualitativo ao número digital, ou seja, atribuir ao pixel uma classe temática (solo, vegetação, água). A interpretação e a classificação de imagens podem ser feitas de forma visual e manual ou automatizadas, com auxílio de algoritmos de classificação acoplados ou não em sistemas de informações geográficas (NOVO, 2010).

Devido à demora e custo desses processos, a forma automatizada tornou-se mais viável para o mapeamento contínuo de grandes extensões, sendo seu sucesso diretamente ligado à capacidade do classificador em reconhecer padrões e separar classes espectralmente distintas (LANG; BLASCHKE, 2007; NOVO, 2010). Rosa (2009) afirma que o sucesso desse processo de classificação está diretamente associado à capacidade de os classificadores distinguirem as classes presentes nas imagens que lhe atribuem elevada acurácia.

Meneses e Sano (2012) destacam que os métodos de classificação podem ser divididos usualmente a partir: da necessidade ou não de amostras de treinamento (classificação supervisionada e não-supervisionada); pela forma de organização dos dados

(classificadores pixel e por regiões); do tipo de classificador (paramétrico e não-paramétrico); ou do tipo de análise do dado (classificação espectral e espacial).

Os classificadores não-supervisionados têm como princípio a classificação sem a interferência do analista, baseada em diferenças e semelhanças estatísticas das imagens, sendo todo o processo realizado pela máquina. Já os algoritmos supervisionados necessitam de dados amostrais prévios dos objetos presentes nas imagens, os quais são fornecidos pelo analista, com intuito de treinar o algoritmo para diferenciar as classes em questão (ROSA, 2009; NOVO, 2010; MENESES; SANO, 2012).

Outra categoria usualmente utilizada é a dos classificadores criados a partir da forma de organização dos dados, são eles: por pixel e por regiões. Na classificação pixel a pixel utiliza-se apenas as informações espectrais (número digital) dos pixels, fazendo uso de medidas de distâncias ou de probabilidades para encontrar padrões homogêneos e categorizá-los em classes. Já os classificadores por regiões (segmentos), utilizam agrupamentos de pixel internamente homogêneos e formam regiões distintas, que são usadas como unidades para se reconhecer padrões e formar classes (MENESES; SANO, 2012).

Os classificadores paramétricos modelam as fronteiras de decisão a partir de parâmetros fixos, utilizando modelos de distribuição probabilístico baseados na distribuição normal dos dados (ZANOTTA; FERREIRA; ZORTEA, 2019). Os classificadores não-paramétricos, por sua vez, têm natureza determinística e podem ser utilizados com dados que não se comportam de acordo com as características da curva normal (ADREOLA, 2009).

Vale destacar que, segundo a literatura, os classificadores supervisionados probabilísticos (paramétricos) são os mais usuais, principalmente por conta da sua fácil agregação a sistemas de informações geográficas, baixo custo e simplicidade, e possibilidade de acurácia relativamente alta. Dentre eles, destacam-se os algoritmos Máxima Verossimilhança, Mínima Distância, Distância de Mahalanobis e Paralelepípedo.

De acordo com Meneses e Sano (2012), esses classificadores diferem-se quanto a parâmetros estatísticos estimados e à sensibilidade à variabilidade dos dados de treinamento, podendo apresentar desempenho diferenciado, a depender das características da região.

O algoritmo de Máxima Verossimilhança-Maxver corresponde a um classificador estatístico supervisionado que considera a ponderação das distâncias, usando critérios de

verossimilhança, a partir das amostras de treinamento fornecidas pelo usuário (ROSA, 2009). O mecanismo utiliza informações associadas à média variância e/ou covariância dos dados amostrais, assumindo que todas as bandas têm distribuição normal, além de calcular a probabilidade de um *pixel* ou região pertencer a uma determinada classe (MENESES; SANO, 2012).

De acordo com Crósta (2002), esse classificador necessita de um número elevado de amostras de treinamento – preferencialmente acima de uma centena– para criar as possibilidades relativas ao *pixel* ou região “x” do espaço multiespectral pertencente à classe disponível $p(\frac{w}{wt})$. Essa ação tem como intuito classificar os *pixels* da imagem calculada que pertencerão a cada uma das classes criadas para o mapa. Ao final, os *pixels* serão incluídos nas classes que possuem os maiores valores de probabilidade (MOREIRA et al., 2016).

O classificador por Mínima Distância define a qual classe determinado *pixel* ou região pertencerá. É calculado a partir da diferença entre o valor do *pixel* e o valor médio de cada classe. Para tanto, utiliza a distância Euclidiana, que definirá a qual classe cada *pixel* será incorporado. Isso será possível a partir da análise de similaridade resultante da equação $D(x_i, m_i) = \sqrt{(x_i - m_i)^2}$, onde x_i é o *pixel* candidato, m_i é a média das classes, e n é o número de bandas, sendo o *pixel* candidato designado à classe com média mais próxima, isto é, à classe que apresenta a menor distância Euclidiana.

A Distância de Mahalanobis é ponderada a partir do desvio padrão dos dados amostrais utilizados, sensível à dispersão da distribuição dos valores de treinamento. É considerado um classificador rápido, principalmente por todos os *pixels* ou regiões classificadas na classe de treinamento mais próxima, a menos que seja especificado um limite de distância, condição na qual alguns *pixels* podem não estar classificados, caso não atinjam o limite estabelecido (MOREIRA et al., 2016).

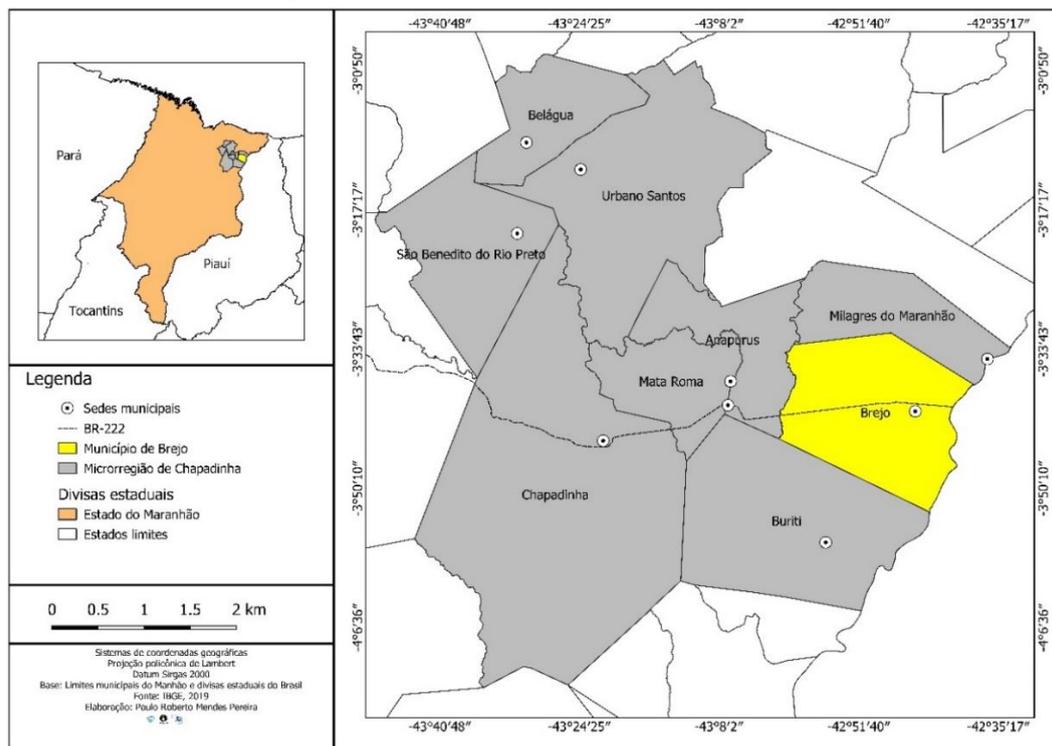
Já o classificador Paralelepípedo segue um padrão diferente dos demais, pois tem como ideia central determinar o intervalo de valores das amostras de treinamento, e, a partir da área de treinamento, define limiares superiores e inferiores de cada classe. Se um determinado *pixel* ou região estiver localizado dentro de um espaço multidimensional, isto é, dentro de determinada classe, ele é definido como pertencente a esta classe; no entanto, se estiver em duas áreas distintas, não é classificado, o que pode explicar a elevada taxa de erro associada a este classificador.

ÁREA DE ESTUDO

O município de Brejo (Figura 01) possui extensão territorial de 1.074 km²,

localizado na porção Leste do estado do Maranhão, nas coordenadas: 43°0'19.18"O; 42°40'7.96"O e 3°53'14.07"S, 03° 18' 22"S, limitando-se ao norte, com o município de Milagres do Maranhão, ao sul, com o município de Buriti de Inácia Vaz, ao leste com o município de Anapurus, e a oeste, com o município de Matias Olímpio – PI (IBGE, 2017).

Figura 01 – Localização do município de Brejo – MA



Fonte: adaptado de IBGE, 2015.

O município apresenta embasamento geológico de atributos sedimentares pertencentes à bacia do Parnaíba, formado por: depósitos detríticos-lateríticos, compostos por lateritos imaturos (petroplintitas) ferruginosos, areia e argila; arenitos de estratificação cruzada, texturas finas a grosseiros, argilosas e intercalações de argilitos e siltitos do Grupo Itapecuru; e arenitos esbranquiçados, de intercalações de silte, com folhelhos cruzados da Formação Longá. Já nos leitos dos canais intermitentes, se destaca a presença de depósitos aluvionares recentes, onde há arenitos e argilas friáveis (BATISTELA et al., 2013).

Sua geomorfologia caracteriza-se por apresentar variação altimétrica entre 15 e 128 metros, formada por feições tabuliformes planas, intercaladas por vales e terraços fluviais, além de colinas de topos côncavos de declividade ondulado. 80% do território é caracterizado por solos do tipo Plintossolos, formados por minerais hidromórficos de textura média e argilosa, de restrição à percolação d'água; já nos topos dos tabuleiros predominam os Latossolos Amarelos e manchas de Neossolos nas proximidades dos

cursos d'água.

O clima da área é o subsúmido seco, com temperaturas acima de 31°C e umidade relativa do ar em torno de 75%, apresentando chuvas sazonais de janeiro a junho, com média anual variando entre 1200 e 1500 mm. A hidrografia é marcada por um conjunto de córregos, rios e lagos, com mais de 65% da área drenada pela sub-bacia hidrográfica do rio Buriti, um importante corpo hídrico do Leste Maranhense que deságua na maior lagoa da porção nordeste brasileira, denominada de lagoa do Bacuri, que tem ligação direta com o rio Parnaíba; os outros 35% estão inseridos na sub-bacia hidrográfica do Rio Preto, um dos principais tributários do Rio Munim (BATISTELA et al., 2013).

A vegetação prevalecente é típica do Cerrado, com árvores espaçadas de média altura e com troncos retorcidos, predominando os chamados carrascos, campos cerrados, cerrados e capão. A vegetação, juntamente com a hidrografia, têm uma grande importância local, haja vista a relação de interdependência da população com esses recursos naturais.

Com economia associada à produção agrícola (IBGE, 2017), a ocupação desta região está associada a imigrantes oriundos da região nordeste do país (FEITOSA; TROVÃO, 2006), e apresentou processo de transformação de cobertura da terra recente (ALMEIDA, 2017), associado principalmente ao Programa de Cooperação Nipo-Brasileira para o Desenvolvimento dos Cerrados (PRODECER III).

A partir dos anos 2000, a região passou a fazer parte do setor de expansão de novas áreas de produção, transcurso motivado pelo deslocamento da fronteira agrícola da porção sul do estado em direção ao leste maranhense. Devido a isso, Brejo se tornou o segundo município do Maranhão que mais perdeu áreas de vegetação nativa de Cerrado nas últimas décadas, como evidenciado por Gaspar (2010).

Segundo dados do INPE (2013), entre os anos de 2005 e 2015, a área perdeu aproximadamente 20% de toda cobertura vegetal natural, em decorrência da abertura de novas áreas agrícolas, o que demonstra a necessidade de políticas de monitoramento das transformações de cobertura da terra para o local.

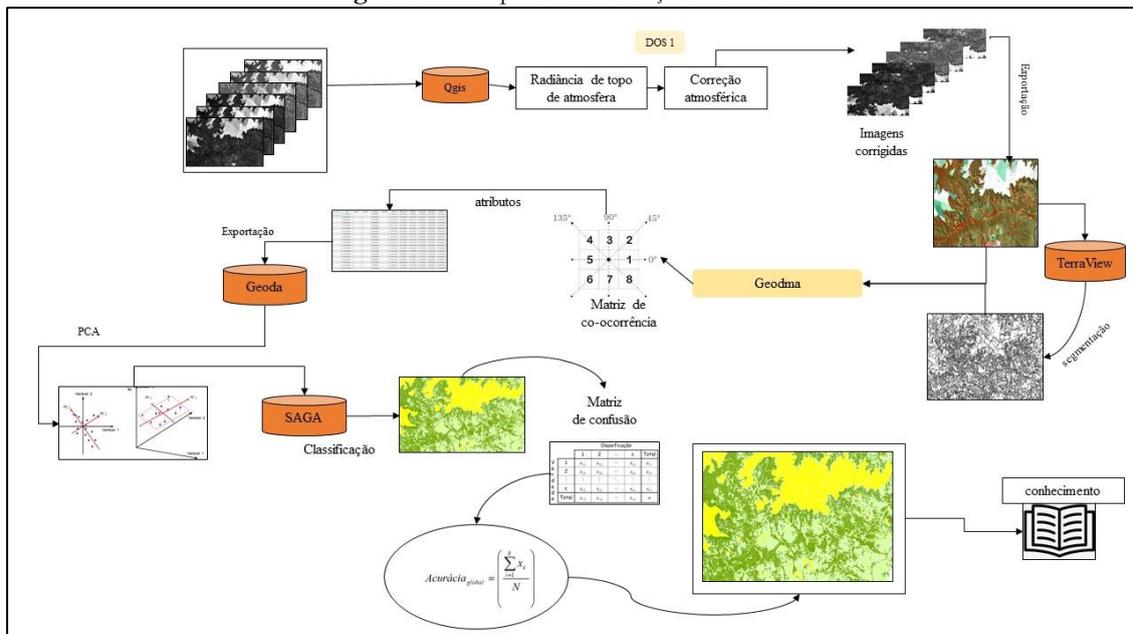
PROCEDIMENTOS METODOLÓGICOS

A metodologia desenvolvida baseou-se na aplicação de técnicas de tratamento e processamento digital de imagens, seguindo os procedimentos descritos por Florenzano (2011), Novo (2010), Araujo et al. (2019), Ge et al. (2020), que correspondem às etapas de correção atmosférica, mesclagem, segmentação, extração de atributos, coleta de amostras,

classificação e validação.

Para a análise dos dados, foram empregados os seguintes softwares: *QGIS 2.14*; *Terra View 5.1*, *Geodma 0.2*; *GeoDa*; *Saga Gis*; *Libre Office Calc*. A Figura 02, a seguir, apresenta o roteiro metodológico adotado no processo de elaboração do trabalho, no qual é possível observar as etapas de utilização de cada software.

Figura 02 – Etapas de Elaboração do trabalho



Fonte: INPE (2017), adaptado pelos autores.

Foi utilizada uma imagem do satélite Landsat 8, sensor OLI, órbita/ponto 219/063, resolução espacial de 30m, do dia 23 de maio de 2017, disponibilizada no catálogo de imagens do Serviço de Levantamento Geológico Americano (*United States Geological Survey-USGS*). Para a escolha da imagem, foi considerado o quantitativo de cobertura de nuvem, não ultrapassando os 5% para a área de estudo. Este é um fator importante para a geração dos dados, pois tende a influenciar nos resultados esperados, principalmente por conta da perda da informação.

A imagem transformou valores de níveis de cinza (número digital) em valores de radiância, utilizando os parâmetros descritos em USGS (2010).

$$\lambda = \left(\frac{L_{max} - L_{min}}{Q_{cal_{max}} - Q_{cal_{min}}} * Dn \right) + L_{min}$$

Na equação acima, L_{λ} é a radiância espectral registrada no sensor [W/m² srμm]; Q_{cal} é valor do *pixel* calibrado [DN]; L_{min} corresponde à radiância espectral registrada no sensor, que é escalonado em relação ao $Q_{cal_{min}}$ [W/m² srμm]; e L_{max} corresponde à radiância espectral registrada no sensor, que é escalonado em relação ao $Q_{cal_{max}}$ [W/m²

srum].

As imagens em radiância de topo de atmosfera passaram por um processo de correção atmosférica, visando à atenuação dos efeitos atmosféricos sobre as imagens digitais. Foi aplicado o modelo de subtração de *pixel* escuro-DOS (CHAVEZ JR., 1988), que objetiva reduzir o efeito do espalhamento atmosférico, utilizando apenas parâmetros relativos ao número digital da imagem.

No modelo DOS, assume-se a possibilidade de existência de *pixels* com valores nulos (escuros), como sombras ocasionadas pela topografia ou por nuvens, e que deveriam possuir valores consideravelmente baixos na imagem, equivalente a cerca de 1% de reflectância (CHAVEZ JR., 1988). De acordo com Maia et al. (2017), esses *pixels* apresentam valores superiores ao esperado, decorrentes do efeito do espalhamento atmosférico, e que servem de referência para a correção desse processo, que pode ser realizada por meio da subtração dos valores estimados para toda a imagem, resultando em um espalhamento uniforme em toda a cena.

Neste trabalho, foi aplicado um filtro de realce, com objetivo de melhorar a discriminação visual entre as feições observadas e reduzir os efeitos do agrupamento de *pixels* em determinadas regiões do histograma que dificultam discriminar visualmente diferentes objetos na superfície. Para isso, o filtro escolhido foi o *realce linear*, pois proporciona uma distribuição dos valores de níveis de cinza a partir do espalhamento linear, segundo uma função linear de 1º (grau).

Na prática, o processo de distribuição provoca a modificação das características originais dos alvos, alterando a escala de cinza. Assim, o novo valor está diretamente associado ao valor inicial do *pixel*, indicando ao histograma seus novos limites (MENESES; ALMEIDA 2012).

Na equação abaixo, o valor de Y representa o valor do *pixel* no novo histograma; x refere-se ao valor do nível de cinza original da imagem; n representa a resolução radiométrica do sensor; e *maior* e *menor* referem-se aos limites originais dos valores no histograma.

$$Y = (x - \text{menor}) * \left(\frac{2^n - 1}{\text{maior} - \text{menor}} \right)$$

A imagem foi submetida à etapa de segmentação, que corresponde a um processo de subdivisão de imagens em regiões discretas a partir do agrupamento de *pixels*, que possuem características semelhantes internamente (forma, textura, cor e nível digital), porém são diferentes externamente. Vale ressaltar que essa etapa constitui um importante passo para a extração de inferências significativas de dados visuais para posterior análise

(GONZALEZ; WOODS, 2010; MENESES; ALMEIDA, 2012).

Foi utilizado o algoritmo Crescimento de regiões (BAATZ; SHAPE, 2000), que consiste no agrupamento de *pixels*, selecionando inicialmente um como “semente” e, a partir de comparações estatísticas com *pixels* vizinhos, regiões são formadas, com limites definidos a partir de valores de área e similaridade, fixados pelo analista (MENESES; ALMEIDA, 2012). Dentro dessa perspectiva, o limiar da área corresponde aos valores de área máxima (quantidade de *pixels*) que cada segmento apresenta, e a similaridade está associada à distância média dos atributos dos *pixels* para compor cada segmento. Estes serão agrupados em cada região, sendo utilizados como parâmetro de similaridade 0.13 e de mesmo tamanho dos segmentos 10, que mostraram boa separabilidade das diferentes feições observadas na área.

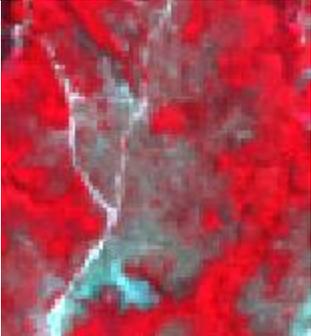
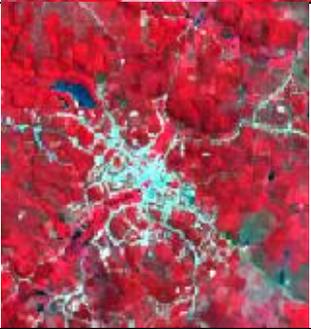
O uso de regiões a partir de segmentação de imagens possibilita a caracterização dos objetos, fator que vai além das características espectrais comumente associados a processos de classificação (KORTING et al., 2009), que evidenciam as diferenças e similaridades entre os objetos. Este é, portanto, um importante recurso no processo de diferenciação de objetos com elevada semelhança espectral, como o caso do Cerrado.

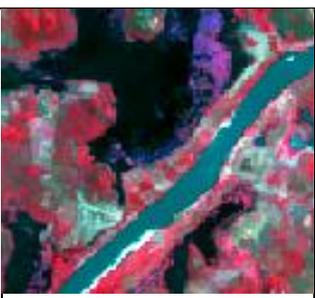
Para a etapa de classificação por objetos, foi necessária a coleta de um conjunto amostras, que serviram de treinamento para cada classificador, em que foi possível identificar as seguintes classes: Formações Florestais, Campos, Lavouras Temporárias, Corpos Hídricos, Solo Exposto e Área Construída.

Para essa etapa, foi necessária a criação de uma chave de interpretação (Quadro 01), com o objetivo de subsidiar a escolha das áreas amostrais, escolhidas a partir de características visualmente perceptíveis (cor, textura e forma).

Após a coleta de amostras de treinamento, foi iniciada a etapa de classificação supervisionada, utilizando as informações referentes às regiões resultantes da análise dos dados. Vale ressaltar que foram criadas as mesmas classes para todos os algoritmos testados, visando assim observar qual algoritmo apresentou melhor desempenho. Nesta fase, foram analisados os algoritmos Maxver, Mínima distância, Paralelepípedos e Distância de Mahalanobis, todos caracterizados como paramétricos.

Quadro 01 – Composição e caracterização da cobertura da terra

| Classe | Imagem | Características |
|----------------------|---|---|
| Formação florestal |  | Composta por vegetação de porte arbóreo e arborescente com nível de cobertura superior a 50%, em geral, cerradão, cerrado denso e mata seca. Apresentou coloração vermelha escura a média, com textura rugosa, que caracteriza a densidade do dossel da vegetação. |
| Campos |  | Caracterizados por uma vegetação espaçada, composta por gramíneas e arbustos de baixa densidade; mescla vegetação de baixo porte com coloração esverdeada a vermelho claro, de textura rugosa média e forma irregular. |
| Lavouras temporárias |  | Caracterizadas por apresentar forma bem definida, textura lisa e padrão de cor variando entre ciano, laranja, vermelho-claro, vermelho-escuro, amarelo-escuro, branco e azul-escuro. |
| Área construída |  | Apresenta textura lisa, padrão de forma definida ou não, de acordo com a forma de ocupação próximo a estradas. Apresenta coloração que varia entre o azul-claro e escuro, devido à presença de vários componentes minerais nos materiais urbanos. Não há um padrão definido para as séries. |
| Solo exposto |  | Apresenta coloração esbranquiçada ou azulada, de padrão geralmente irregular, textura lisa, e localiza-se próximo a áreas com presença marcante de ambientes degradados. |

| | | |
|-----------------|---|--|
| Corpos hídricos |  | Apresenta forma irregular, textura lisa, com padrões retilíneos ou curvilíneos, coloração azulada, quando possui elevada presença de material em suspensão, e preta, na ausência de material em suspensão. |
|-----------------|---|--|

Fonte: Dados da pesquisa, 2019.

Para a identificação do algoritmo com melhor desempenho de classificação, utilizou-se a matriz de confusão e seus respectivos índices de acurácia (FURTADO et al., 2012), e uma imagem de alta resolução, do ano de 2018, disponível na plataforma *Google Earth*. Da imagem, extraiu-se um conjunto de 247 pontos conhecidos, os quais foram comparados aos resultados das classificações e subsidiaram a elaboração da matriz de confusão, com posterior avaliação de desempenho a partir do índice Kappa e Exatidão Global (CONGALTON; GREEN, 1990). Os resultados dos desempenhos estabelecidos por Landis e Koch (1977) atribuem características qualitativas aos valores quantitativos dos resultados obtidos na validação geral (Quadro 02).

Quadro 02 – Valores do condicionante Kappa

| Kappa | Valor |
|-----------|-------------|
| Péssimo | <0.00 |
| Ruim | 0.00 - 0.20 |
| Regular | 0.21 – 0.40 |
| Bom | 0.41 – 0.60 |
| Muito bom | 0.61 – 0.80 |
| Excelente | 0.81 – 1.00 |

Fonte: ROSA, 2009.

A exatidão global indica a porcentagem de acertos a partir do número total de amostras classificadas corretamente e sua relação com o número total de amostras utilizadas. A partir dessa informação, torna-se possível avaliar o nível de precisão da classificação, que neste caso é diretamente interpretável, uma vez que a proporção de *pixels* classificados corresponde às probabilidades relacionadas à precisão de comissão e omissão relatada de um determinado mapa temático. Ademais, o coeficiente *Kappa* foi usado para avaliar a diferença estatística entre as classificações, indicando o grau de exatidão (CONGALTON, 1991).

$$E_g = \left(\frac{\sum_{i=1}^r x_{ii}}{n} \right)$$

Na fórmula supracitada, E_g representa a exatidão Global; $\sum_{i=1}^r x_{ii}$ corresponde

ao número total de amostras classificadas corretamente; e n corresponde ao número total de amostras. O índice $Kappa$, por sua vez, varia de -1 a 1, o que significa que, quanto mais próximo de 1 estiver, maior será a precisão da classificação, que é calculada a partir do produto da acurácia global pelos erros de comissão, como mostra a equação a seguir:

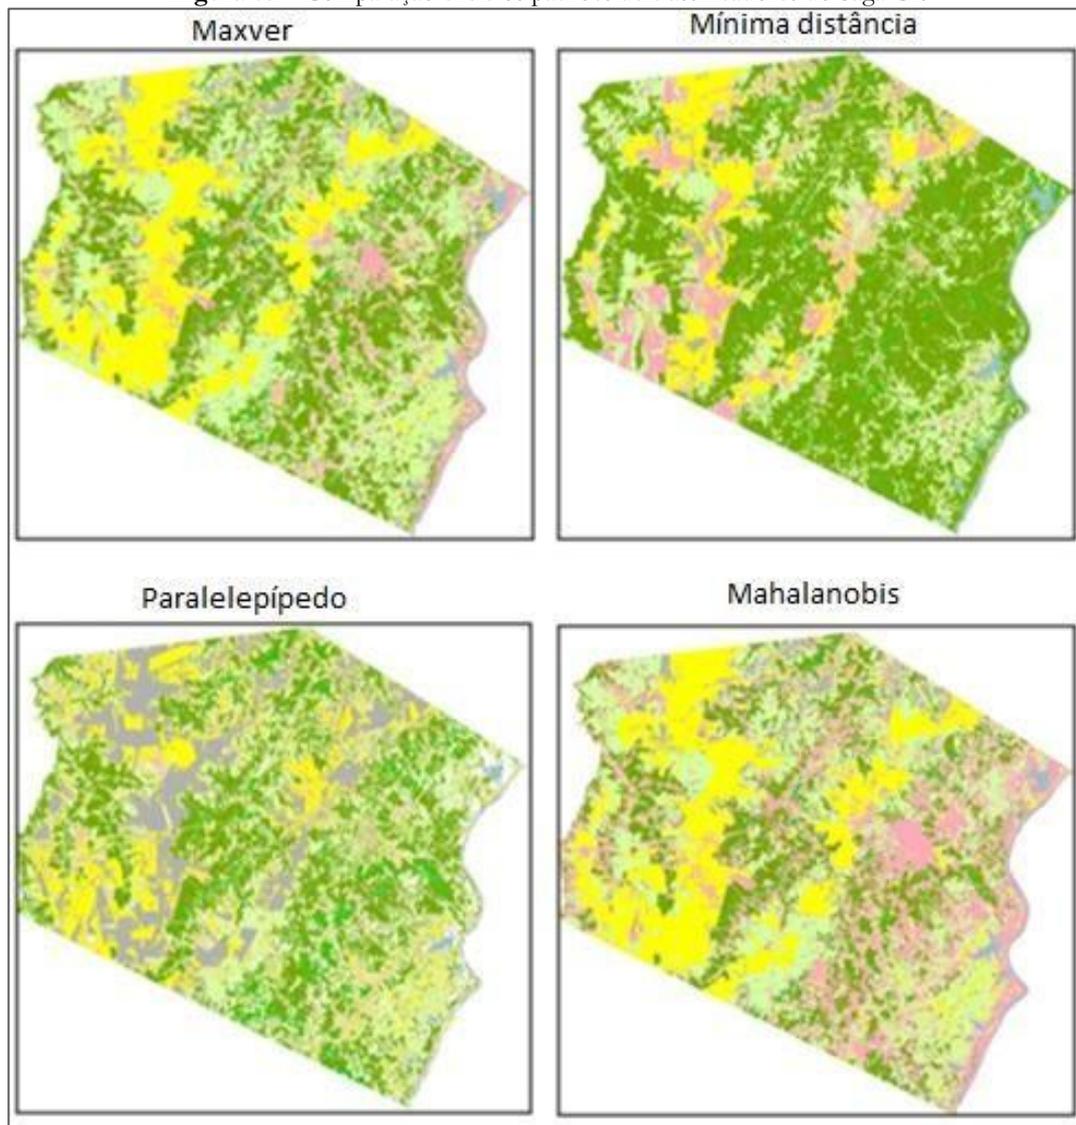
$$K = \frac{n \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_i x_{+i})}{N^2 - \sum_{i=1}^c (x_i x_{+i})}$$

Nesta equação, k é o valor do índice; n é número total de amostras; $\sum dp$ é a soma da diagonal principal; e $\sum(l*c)$ representa o produto da soma da linha pelas colunas de cada classe representativa.

RESULTADOS

O mapeamento da cobertura da terra do município de Brejo foi obtido a partir da classificação automática da imagem Landsat 8 e da utilização dos algoritmos presentes no software Saga Gis; apresentou significativas dissimilaridades quando observados os resultados dos algoritmos de classificação testados, conforme demonstra a Figura 03.

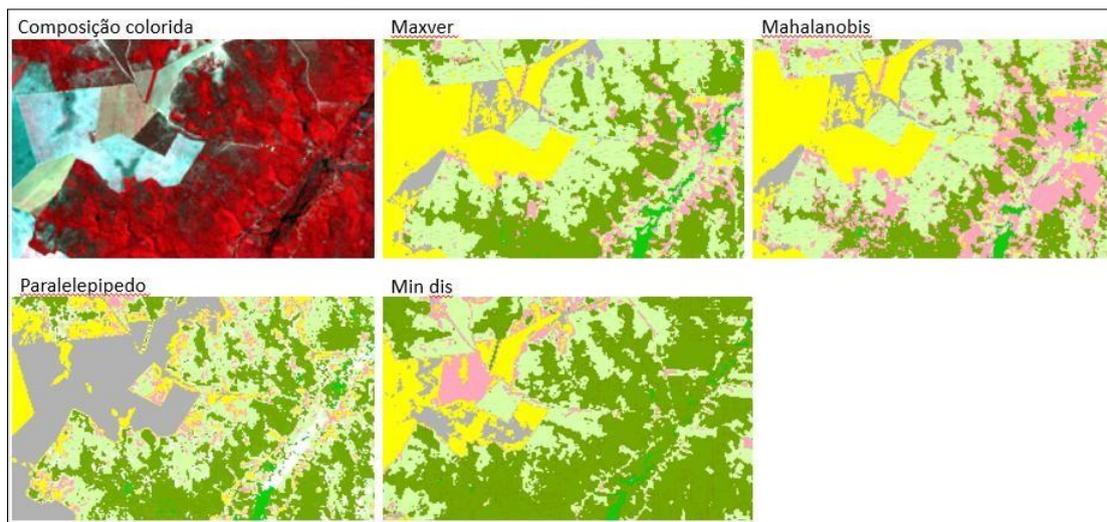
Figura 03 – Comparação entre os padrões de classificadores do Saga Gis



Fonte: Dados da pesquisa, 2019.

Por meio da comparação visual entre imagem original e os resultados das classificações (Figura 04), observou-se: significativas confusões geradas pelos quatro algoritmos testados, onde nenhuma classe apresentou o mesmo percentual de área ocupada; e superestimação, em maior ou menor proporção, das classes mapeadas, o que indica uma necessidade de correção das classificações geradas no processo de classificação automatizada.

Figura 04 – Padrão de algoritmos no Saga Gis



Fonte: Dados da Pesquisa, 2019.

O Quadro 03 apresenta a taxa de cobertura da terra por classes mapeadas de acordo com o algoritmo de classificação usada. As Formações Campestres foram as classes com maior área de cobertura em grande parte dos classificadores, representando entre 44 e 38% da cobertura da terra, com exceção do Paralelepípedo, que representou apenas 20% da cobertura total da área. A segunda classe com maior área foi a das Formações Florestais, que apresentaram diferentes taxas de cobertura quando comparadas aos classificadores Maxver, Paralelepípedo, Mínima Distância e Mahalanobis, com taxas de 29, 12, 32 e 16% respectivamente.

Quadro 03 – Resultado obtido por classificador em Km²

| | Maxver | Paralelepípedo | Mínima Distância | Mahalanobis |
|----------------------|--------|----------------|------------------|-------------|
| For. Florestais | 299.22 | 215.1 | 352.52 | 191.66 |
| For. Campestres | 437.62 | 361.6 | 477.89 | 449.41 |
| Culturas Temporárias | 205.77 | 148.05 | 105.33 | 222.64 |
| Corpos Hídricos | 11.32 | 8.27 | 15.84 | 11.17 |
| Áreas Construídas | 29.96 | 66.93 | 105.33 | 255.34 |
| Solo Exposto | 35.67 | 969.24 | 18.99 | 35.73 |

Fonte: Dados da Pesquisa, 2019.

A classe Culturas Temporárias apresentou predomínio de área nas classificações dos algoritmos Maxver e Distância de Mahalanobis, representando 20% e 19% da cobertura total; e nos classificadores Paralelepípedo e Mínima Distância, representando apenas 9% da cobertura da área. A classe apresentou também superestimação principalmente na Distância de Mahalanobis.

Assim como a anterior, a classe Áreas Construídas apontou superestimação em

todos os classificadores testados, mostrando predomínio no classificador Distância de Mahalanobis de 21% da cobertura total da área. Já nos classificadores Maxver, Paralelepípedo e Distância Mínima, apresentou respectivamente 2, 3 e 9% da cobertura da área, quando observados a acurácia global e o índice Kappa das classificações geradas a partir das imagens classificadas, de acordo com o padrão de exatidão por usuário e por produção.

O Quadro 04 mostra os valores do Kappa e exatidão global, e a Figura 04, acima, apresenta a comparação visual dos resultados obtidos a partir da aplicação dos classificadores para o município de Brejo.

Quadro 04 – Comparativo entre os classificadores de imagens pelo Saga Gis

| Classificador | Acurácia (%) | Coef. Kappa | Qualidade |
|----------------------|---------------------|--------------------|------------------|
| Maxver | 70.20 | 0.629 | Muito Bom |
| Dist. M.nima | 55.8 | 0.433 | Bom |
| Dist, Mahalanobis | 65.8 | 0.577 | Bom |
| Paralelepipedo | 26.2 | 0.134 | Ruim |

Fonte: Dados da pesquisa, 2019.

O mapeamento elaborado a partir do classificador de Mahalanobis apresentou um condicionante Kappa de 0.577 e exatidão global de 65%, valores considerados bons. Porém, quanto ao processo de classificação, este classificador apresentou potencial para identificação e diferenciação da classe Água, com concordância de 100% de acerto. Observou-se ainda elevada confusão entre as classes Vegetação Densa, Áreas Construídas e Campos, uma vez que a primeira apresentou apenas 48% de acertos, sendo este o menor percentual de acurácia de classificação quando comparado à imagem de referência, que mostra a baixa qualidade desse classificador para diferenciar esta classe.

O Quadro 05 apresenta a matriz de confusão elaborada para a classificação de Mahalanobis, o qual representou o segundo melhor classificador presente no Saga Gis, e manifestou os melhores valores para condicionante Kappa e exatidão global.

Quadro 05 – Matriz de Classificação por Mahalanobis

| Classificação | Referências | | | | | | Acurácia |
|----------------------|------------------------|---------------|------------------------|-----------------------------|---------------------|-------------|-----------------|
| | Vegetação densa | Campos | Área construída | Lavouras temporárias | Solo Exposto | Água | |
| Vegetação densa | 28 | 12 | 18 | 0 | 0 | 0 | 0.482 |
| Campos | 4 | 48 | 8 | 5 | 4 | 0 | 0.695 |
| Área construída | 0 | 0 | 21 | 0 | 0 | 0 | 1.000 |
| Lavouras temporárias | 0 | 1 | 1 | 39 | 2 | 0 | 0.906 |
| Solo Exposto | 0 | 1 | 0 | 1 | 18 | 0 | 0.947 |
| Água | 0 | 1 | 0 | 0 | 0 | 7 | 1 |

Fonte: Dados da pesquisa, 2019.

Mesmo apresentando valores aceitáveis de Kappa, o classificador Mahalanobis mostrou superestimação das classes – com destaque para as Áreas Construídas – e área de aproximadamente 222 km². De acordo com o IBGE, a sede municipal de Brejo apresenta território de aproximadamente 9 km², o que evidencia o quanto o classificador excedeu essa classe para o município. Diante do exposto, é possível afirmar que Áreas Construídas apresentou confusão com a classe Vegetação Densa.

Quanto aos resultados do classificador Maxver (Quadro 06), observou-se Kappa de 0.629 e exatidão global de 70%, caracterizado por Rosa (2009) como muito bom. Esse classificador apresentou os melhores resultados de baixa confusão entre as classes, sendo as classes Água e Áreas Construídas com padrões de identificação mais satisfatórios – a primeira com 100% de acerto, e a segunda, com 95%. A classe com pior índice de acertos para este classificador foi a Vegetação Densa, com padrão de 67%, sendo maior confusão com a classe Campos.

Quadro 06 – Matriz de confusão da classificação Maxver

| Classificação | Referências | | | | | | |
|----------------------|-----------------|--------|-----------------|----------------------|--------------|------|---------|
| | Vegetação densa | Campos | Área construída | Lavouras temporárias | Solo Exposto | Água | Usuário |
| Vegetação densa | 39 | 18 | 1 | 0 | 0 | 0 | 0.672 |
| Campos | 9 | 51 | 2 | 3 | 4 | | 0.739 |
| Área construída | 0 | 1 | 20 | 0 | 0 | 0 | 0.952 |
| Lavouras temporárias | 0 | 4 | 0 | 37 | 2 | 0 | 0.860 |
| Solo Exposto | 0 | 0 | 0 | 1 | 18 | | 0.947 |
| Água | 0 | 0 | 0 | 0 | 0 | 7 | 1 |

Fonte: Dados da Pesquisa, 2019.

O classificador Maxver apresentou também grande potencial para a identificação de feições com elevado brilho, destacando, assim, as classes Áreas Construídas e Lavouras Temporárias. Apesar de apresentarem valores de objetos aproximados, estas foram bem definidas e mostraram baixa confusão quando comparadas entre si. Porém, destacou-se elevada confusão entre as classes Áreas Construídas e Feições Campestres.

O classificador Mínima distância (Quadro 07), considerado um modelo de classificação de imagens mais simplista, apresentou a segunda melhor exatidão global, com 60% de acerto, e melhor Kappa, com 0,513. Demonstrou também parâmetros semelhantes ao Maxver, destacando-se por conta da superestimação das classes de área urbana, principalmente por se observar elevada confusão com as áreas de lavouras temporárias e com solo exposto. Foi o classificador que melhor classificou áreas de vegetação densa (cerrado florestado) e formações campestres, indicando elevada aplicabilidade para a

diferenciação de padrões florestais.

Quadro 07 – Matriz de confusão por Mínima Distância

| Classificação | Referências | | | | | | |
|----------------------|-----------------|--------|-----------------|----------------------|--------------|------|---------|
| | Vegetação densa | Campos | Área construída | Lavouras temporárias | Solo Exposto | Água | Usuário |
| Vegetação densa | 34 | 24 | 1 | 0 | 0 | 0 | 0.586 |
| Campos | 10 | 51 | 8 | 0 | 0 | | 0.739 |
| Área construída | 1 | 1 | 7 | 12 | 0 | 0 | 0.333 |
| Lavouras temporárias | 0 | 3 | 16 | 25 | 6 | 0 | 0.500 |
| Solo Exposto | 0 | 0 | 0 | 5 | 11 | 0 | 0.647 |
| Água | 0 | 0 | 0 | 0 | 0 | 7 | 1 |

Fonte: Dados da pesquisa, 2019.

O classificador Paralelepípedo (Quadro 08) apresentou condicionante Kappa de 0.134 e percentual de acerto de apenas 26%. A classe com melhor desempenho de identificação foi Água, com padrão de 71%, enquanto as Áreas Construídas apresentaram acurácia nula. Esse classificador mostrou elevado percentual de áreas não classificadas – aproximadamente 30% –, sendo estes os piores resultados para todas as classes identificadas na imagem. Vale ressaltar que esse fator pode estar diretamente associado ao aspecto da funcionalidade do algoritmo.

Quadro 08 – Matriz de confusão Paralelepípedo

| Classificação | Referências | | | | | | |
|----------------------|-----------------|--------|-----------------|----------------------|--------------|------|---------|
| | Vegetação densa | Campos | Área construída | Lavouras temporárias | Solo Exposto | Água | Usuário |
| Vegetação densa | 24 | 32 | 1 | 0 | 0 | 0 | 0.413 |
| Campos | 7 | 19 | 14 | 19 | 6 | | 0.275 |
| Área construída | 0 | 1 | 0 | 1 | 18 | 0 | 0.00 |
| Lavouras temporárias | 0 | 0 | 0 | 9 | 34 | 0 | 0.209 |
| Solo Exposto | 0 | 0 | 0 | 0 | 19 | 0 | 1.00 |
| Água | 0 | 0 | 0 | 0 | 0 | 5 | 0.714 |

Fonte: Dados da pesquisa, 2019.

Visualmente, esse classificador apresentou excessivas áreas sem dados, fator que resultou em perda de informação; o seu valor de Kappa é considerado ruim, o que inviabiliza seu uso para a classificação de imagens de áreas que apresentam características radiométricas de classes semelhantes. É importante destacar que a classe com menor área por classe foi Áreas Construídas; já as classes Solo Exposto e Lavouras Temporárias apresentaram os maiores percentuais de acertos, por meios dos quais se observou elevada confusão entre elas, com uma superestimação das áreas de solo exposto.

Apesar de apresentar boa aceitação, o classificador Paralelepípedo apontou visualmente elevada confusão, principalmente entre as Áreas Construídas e Água. Dentro deste cenário, a classe com melhor limiar de acertos foi a de Culturas Temporárias, que apresentou acurácia do produtor de 85% e usuário de 77%, considerados bons resultados no que tange a identificação de áreas utilizadas para cultivos; já a pior classe deu-se com a identificação de Áreas Construídas, principalmente por se configurar em um pequeno núcleo urbano de 9 km².

Dentre os classificadores, o Paralelepípedo foi o que teve pior desempenho, pois apresentou qualidade questionável nas classes correspondentes, com elevada taxa de confusão entre diversas classes, e ausência de área construída. Os mapas temáticos gerados, por sua vez, podem ser considerados satisfatórios, no entanto, destacou-se a necessidade de correção em todos os mapas.

Em geral, considerando os mapas temáticos gerados pela Classificação Supervisionada, quando aplicado o método da Distância Mínima, Maxver, Mahalanobis e Paralelepípedo nas imagens OLI do satélite Landsat 8, considerando os índices Kappa, Exatidão global, chegou-se a conclusão que, para a área de estudo, a classificação pelo método Maxver obteve os melhores resultados, com exatidão global da classificação de 72% de acertos e um Kappa de 0.629.

CONSIDERAÇÕES FINAIS

Analisando os resultados deste estudo, é possível concluir que os mapas temáticos gerados pela classificação Supervisionada para a área do município de Brejo apresentaram elevadas taxas de confusão, sobre as quais a classificação pelo método Maxver obteve os resultados mais satisfatórios, com os melhores valores tanto para a exatidão global, quanto para os índices Kappa.

O segundo melhor classificador foi a Distância de Mahalanobis, apesar de ter apresentado baixa capacidade para classificar classes formações florestais, com taxa de acerto de apenas 48%. Os piores valores foram observados para o classificador Paralelepípedo, único classificado como bom, com taxa de acerto de 26% e 13%, respectivamente, para a exatidão global e índice Kappa, o que mostra a baixa eficiência para o mapeamento de uso e cobertura da terra.

No geral, o software Saga Gis demonstrou elevado potencial para o processo de classificação de imagens que apresentam elevada potencialidade de confusão. A tentativa de distinção destas classes pelos algoritmos Maxver e Distância Mínima mostrou os resultados

mais satisfatórios, porém, com uma baixa qualidade da classificação, principalmente pelas características das imagens, o que dificulta discriminar as áreas com algumas classes de solos.

Por fim, cabe inferir que os métodos de classificação estudados que utilizam apenas as características espectrais são incapazes de diferenciar de forma precisa classes que possuem semelhança espectral, tais como Solo, Edificações e Lavouras Temporárias, o que ocasionou elevada taxa de confusão entre essas classes. Desse modo, é necessária a análise de classificadores mais robustos, como os classificadores por aprendizado de máquina, que podem viabilizar outras formas de separabilidade de classes e, assim, apresentar uma melhor acurácia dos dados.

REFERÊNCIAS

ADREOLA, R. **Support Vector Machines na Classificação de Imagens Hiperespectrais**. 2009. Dissertação (Mestrado em Sensoriamento Remoto) – Centro Estadual de Pesquisa em Sensoriamento Remoto e Meteorologia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2009.

ALMEIDA, J. G. **A luta na/pela terra frente à expansão da soja no município de Brejo – MA**. 2017. Dissertação (Mestrado em Geografia) – Programa de Pós-Graduação em Geografia, Natureza e Dinâmica do Espaço, Universidade Estadual do Maranhão, São Luís, 2017.

ARAUJO, H. B.; PEREIRA, P. R. M.; RODRIGUES, T. C. S.; COSTA JUNIOR, E. P. B da. Mudança de cobertura da terra nos municípios de Chapadinha e Buriti – MA, entre os anos de 1990 a 2017. **Revista Geonorte**, v. 10, n. 36, p. 194-214, 2019. Disponível em: <<https://www.periodicos.ufam.edu.br/index.php/revista-geonorte/article/view/5556>>. Acesso em: 02 fev. 2020.

BAATZ, M.; SCHAPE, A. Multiresolution Segmentation: an optimization approach for high quality multi-scale image segmentation. **Journal of Photogrammetry and Remote Sensing**, Heidelberg, v. 58, n. 3-4, p. 12-23, 2000.

BATISTELLA, M.; BOLFE, E. L.; VICENTE, L. E.; VICTORIA, D. C.; ARAÚJO, L. S. **Relatório do Diagnóstico do Macrozoneamento Ecológico-Econômico do Estado do Maranhão**. Campinas, SP: Embrapa, 2013. 445 p. (Embrapa Monitoramento por Satélite / Relatório Técnico, v. 1 - CDD 333.70981).

BIE, C. A. J. M. de; LEEUWEN, J. A. van; ZUIDEMA, P. A. **The land use database: a knowledge based software program for structured storage and retrieval of userdefined land use data sets: user's reference manual**. Version 1.04 for MS-DOS. [Enschede, The Netherlands]: International Institute for Geo-Information Science and Earth Observation: Food and Agriculture Organization: United Nations Environment Programme: Wageningen University, 1996. 41 p. Disponível em: <<http://wgbis.ces.iisc.ernet.in/energy/HC270799/LM/SUSLUP/Luse/Manual/chap2.pdf>>. Acesso em: 06 mar. 2019.

CHAVEZ JR., P. S. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. **Remote Sensing of Environment**, v. 24, p. 459-479, 1988.

CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, v. 49 n. 12, p. 1671-1678, 1991.

CONRAD, O.; BECHTEL, B.; BOCK, M.; DIETRICH, H.; FISCHER, E.; GERLITZ, L.; WEHBERG, J.; WICHMANN, V.; BÖHNER, J. System for Automated Geoscientific Analyses (SAGA). v. 2.1.4. **Geoscientific Model Development**, v. 8, n. 7, 1991-2007, 2015.

CRÓSTA, A. P. **Processamento digital de imagens de sensoriamento remoto**. Campinas: Instituto de Geociências: UNICAMP. 2002, 170 p.

FONSECA, L. M. G.; BINS, L. S.; VELASCO, F. R. D.; MONTEIRO, A. M. V. Um sistema de segmentação baseado em conhecimento para imagens de satélite. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 6., 1990, Manaus. **Anais eletrônicos...** Manaus: INPE, 1990. Disponível em: <<http://marte.sid.inpe.br/col/dpi.inpe.br/marte@80/2008/08.15.14.00/doc/197-200.pdf>>. Acesso em: 06 jan. 2020.

FEITOSA, A. C.; TROVÃO, J. R. **Atlas Escolar do Maranhão: espaço geohistórico e cultural**. João Pessoa: Grafset, 2006. 207 p.

FLORENZANO, T. G. **Iniciação em Sensoriamento Remoto**. 3. ed. São Paulo: Oficina de Textos, 2011.

FORMAGGIO, A. R.; SANCHES, I. D. **Sensoriamento remoto em agricultura**. São Paulo: Oficina de Textos, 2017. 285 p.

GASPAR, R. B. **O eldorado dos gaúchos: deslocamento de agricultores do Sul do país e seu estabelecimento no Leste Maranhense**. 2010. Dissertação (Mestrado em Ciências Sociais) – Universidade Federal do Maranhão, São Luís, 2010.

GE, G.; SHI, Z.; ZHU, Y.; YANG, X.; HAO, Y. Land use/cover classification in an arid desert-oasis mosaic landscape of China using remote sensed imagery: performance assessment of four machine learning algorithms. **Global Ecology and Conservation**, v. 22, e00971, June 2020. Disponível em: <<https://doi.org/10.1016/j.gecco.2020.e00971>>. Acesso em: 06 jun. 2020.

GONZALEZ, R. C.; WOODS, R. C. **Processamento digital de imagens**. 3. ed. rev. São Paulo: Editora Edgard Blucher, 2010.

GRINAND, C.; RAKOTOMALALA, F.; GOND, V.; VAUDRY, R.; BERNOUX, M.; VIEILLEDENT, G. Estimating deforestation in tropical humid and dry forests in Madagascar from 2000 to 2010 using multi-date Landsat satellite images and the random forests classifier. **Remote Sensing of Environment**, v. 139, p. 68-80, 2013.

IBGE. **Mapa de Vegetação 2012**. IBGE: Rio de Janeiro, 2012. Disponível em: <ftp://geofp.ibge.gov.br/mapas_tematicos/mapas_murais/vegetacao.pdf>. Acesso em: 12 jun. 2019.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE) - **Manuais: tutorial de geoprocessamento**, SAGAGIS. 2017.

_____. **Projeto Terra Class Cerrado Mapeamento do Uso e Cobertura Vegetal do Cerrado**, 2013. Disponível em: <<http://www.dpi.inpe.br/tccerrado/>>. Acesso em: 13 jun. 2019.

ISLAM, K.; JASHIMUDDIN, M.; NATH, B.; NATH, T. K. Land use classification and change detection by using multi-temporalremotely sensed imagery: The case of Chunati wildlife sanctuary, Bangladesh. **The Egyptian Journal of Remote Sensing and Space Science**, v. 21, n. 1, p. 37-47, abr. 2018.

KORTING, T.; FONSECA, L.; ESCADA, M.; CÂMARA, G. GeoDMA: um sistema para mineração de dados de sensoriamento remoto. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14., 2009, Natal. **Anais...** Natal-RN: INPE, 2009, p. 7813-7820.

LAMBIN, E. F.; GEIST, H. **Land-use and land-cover change: local processes and global impacts**. Springer, IGBP Series, 2006.

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

LI, C.; WANG, J.; WANG, L.; HU, L.; GONG, P. Comparison of classification algorithms and training sample sizes in urban land classification with landsat thematic mapper imagery. **Remote Sensing**, v. 6, p. 964-983, 2014.

LIU, W. T. H. **Aplicações do Sensoriamento Remoto**. Campo Grande: Ed. UNIDERP, 2009.

MAIA, M. A.; RODRIGUES, N. B.; RITCHER, M.; RUBIM, I. Modelos de correção atmosférica aplicados em imagens do sensor OLI/Landsat 8 a partir do uso de programas gratuitos: uma análise comparativa. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 18., 2017, Santos. **Anais...** Santos-SP: INPE, 2017.

MENESES, P. R.; SANO, E. E. Classificação pixel a pixel de imagens. In: MENESES, P. R.; ALMEIDA T. de. (Org.). **Introdução ao processamento de imagens de Sensoriamento Remoto**. Brasília: UnB/CNPq, 2012.

MIRANDA, E. E.; GOMES, E. G.; GUIMARÃES, M. **Mapeamento e estimativa da área urbanizada do Brasil com base em imagens orbitais e modelos estatísticos**. Campinas: Embrapa Monitoramento por Satélite, 2005.

MOREIRA, E. F.; SANTOS, R. L. Da S.; FARNCA-ROCHA, W. J. S da.; BOSCOLO, D.; PIGOZZO, C. M. Comparação e desempenho de algoritmos parametricos na classificação supervisionada de área naturalmente heterogêneas e dinâmicas. **Revista Brasileira de Cartografia**, v. 68, n. 3, p. 581-594, 2016.

NOVO, E. M. L. M. **Sensoriamento Remoto Princípios e Aplicações**. 2. ed. São Paulo: Edgard Blücher, 2010.

PARENTE, L.; MESQUITA, V.; MIZIARA, F.; BAUMANN, L.; FERREIRA, L.

Assessing the pasturelands and livestock dynamics in Brazil, from 1985 to 2017: a novel approach based on high spatial resolution imagery and Google Earth Engine cloud computing. **Remote Sensing of Environment**, v. 232, p. 111301-11, 2019.

ROSA, R. **Introdução ao sensoriamento remoto**. 7. ed., Uberlândia: Ed. EDUFU, 2009. 264 p.

RODRIGUES, T. C. S. **Estudo da cobertura e uso da terra na microrregião do Gurupi, Amazônia maranhense, entre os anos de 1976 – 2016 por meio da aplicação do sensoriamento remoto e SIG's**. 2018. Tese (Doutorado em Geografia) – Faculdade de Ciência e Tecnologia, Universidade Estadual Paulista Júlio de Mesquita Filho, Presidente Prudente, 2018.

SANO, E. E. [et al.]. Mapeamento da cobertura vegetal natural e antropópico do bioma cerrado por meio de imagens LANDESAT ETM. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14., 2009, Natal. **Anais...** Natal: INPE, abr. 2009. p. 1199-1206.

SRIVASTAVA, P.K.; GUPTA, M.; MUKHERJEE, S.; Mapping spatial distribution of pollutants in groundwater of a tropical area of India using remote sensing and GIS. **Appl Geomatics**, v. 4, n. 1, p. 21-32., 2012.

UNITED STATES GEOLOGICAL SURVEY – USGS. **EROS Archive - Landsat Archives - Landsat 4-5 Thematic Mapper (TM) Level-1 Data Products, 2010**. Disponível em: <<https://earthexplorer.usgs.gov/>>. Acesso em: 23 maio 2018.

ZANOTTA, D.; FERREIRA, M.; ZORTEA, M. **Processamento de imagens de Satélites**. São Paulo: Oficina de Textos, 2019. 320 p.

Como citar:

ABNT

SOUSA, A. S. S.; PEREIRA, P. R. M.; GARCÊS JÚNIOR, A. R. Avaliação da qualidade de classificadores de imagens Landsat 8 em ambiente computacional SAGA GIS para mapeamento de cobertura da terra no bioma Cerrado. **InterEspaço: Revista de Geografia e Interdisciplinaridade**, v. 7, e202128, 2021. Disponível em: <<http://dx.doi.org/10.18764/2446-6549.e202128>>. Acesso em: 12 out. 2021.

APA

Sousa, A. S. S., Pereira, P. R. M., & Garcês Júnior, A. R. Avaliação da qualidade de classificadores de imagens Landsat 8 em ambiente computacional SAGA GIS para mapeamento de cobertura da terra no bioma Cerrado. *InterEspaço: Revista de Geografia e Interdisciplinaridade*, v. 7, e202128. Recuperado em 12 outubro, 2021, de <http://dx.doi.org/10.18764/2446-6549.e202128>



This is an open access article under the CC BY Creative Commons 4.0 license.

Copyright © 2021, Universidade Federal do Maranhão.

