



COMPARAÇÃO ENTRE DIFERENTES ALGORITMOS DE CLASSIFICAÇÃO SUPERVISIONADA NO MAPEAMENTO TEMÁTICO DE UMA BACIA HIDROGRÁFICA

Leovigildo Aparecido Costa Santos¹ Paulo Eliardo Morais de Lima²

¹ Engenheiro Florestal, mestrando no Programa de Pós-graduação em Recursos Naturais do Cerrado (RENAC) na Universidade Estadual de Goiás – UEG, Anápolis, GO, Brasil. E-mail: (eng.leovigildo@gmail.com)

² Biólogo, mestrando no Programa de Pós-graduação em Recursos Naturais do Cerrado (RENAC) na Universidade Estadual de Goiás – UEG, Anápolis, GO, Brasil.

Recebido em: 15/04/2018 – Aprovado em: 07/05/2018 – Publicado em: 09/06/2018
DOI 10.18677/TreeDimensional2018A3

RESUMO

Diferentes métodos são empregados para a classificação digital de imagens, porém, podem apresentar desempenhos diferentes, sendo importante testá-los para verificar suas eficácias no mapeamento de uso e cobertura da terra com intuito de se selecionar o classificador que apresente os melhores resultados e maior veracidade em relação à verdade de campo. O objetivo deste estudo foi avaliar e comparar os desempenhos de quatro algoritmos de classificação supervisionada para o mapeamento do uso e cobertura da terra da bacia hidrográfica do Rio Caldas – GO, utilizando imagens Landsat-8. Para tanto, foram utilizadas as cenas de órbita/ponto 222/71 e 222/72, com datas de passagem em 24/10/2017 e 22/10/2017, mosaicadas para formar uma única imagem de dimensões que abrangesse toda a área de interesse. A composição RGB utilizada foi das bandas 6, 5 e 4 (R=6, G=5, B=4). Para a realização do processamento digital da imagem foi empregado o *software* ENVI versão 5.0 e à elaboração de mapas temáticos o QGIS 2.18. Os algoritmos testados foram: Paralelepípedo, Distância de Mahalanobis, Distância Mínima e Máxima-verossimilhança. Como parâmetros de comparação foram utilizados os coeficientes de Kappa, acurácias global e matrizes de confusão. Os melhores resultados para a classificação de uso e cobertura foram obtidos pelo método da Máxima-verossimilhança (MaxVer), os piores pelo método do Paralelepípedo, os outros classificadores apresentaram resultados intermediários entre o melhor e o pior. Com os resultados obtidos pela classificação por MaxVer, constatou-se que atualmente a maior parte do solo da bacia é ocupada pelas classes Pastagem (63,14%) e Vegetação nativa (22,07%).

PALAVRAS-CHAVE: geoprocessamento; Kappa; landsat; sensoriamento remoto; uso e cobertura.

COMPARISON BETWEEN DIFFERENT SUPERVISED CLASSIFICATION ALGORITHMS IN THEMATIC MAPPING OF A RIVER BASIN

ABSTRACT

Different methods are used for a digital classification of images, however, they can present different performances, being important to test them to verify their efficiencies in the mapping of land use and coverage in order to select the classifier that presents the best results and greater truthfulness in relation to the truth of the field. The objective of this study was to evaluate and compare the performance of four supervised classification algorithms for the mapping of the land use and land cover of the Caldas river basin - GO, using Landsat-8 images. To do so, they were like the orbit / dot scenes 222/71 and 222/72, with passing date on 10/24/2017 and 10/22/2017, mosaicked to form a single image of dimensions covering an entire area of interest. An RGB composition used for bands 6, 5 and 4 (R = 6, G = 5, B = 4). For the realization of digital image processing and the use of ENVI version 5.0 software and the development of thematic maps, QGIS 2.18. The algorithms tested were: Parallelepiped, Mahalanobis Distance, Minimum Distance and Maximum Likelihood. As the comparison parameter is used by Kappa coefficients, global accuracy and matrices of confusion. The best results for a classification of use and coverage are obtained by the Maximum-likelihood method (MaxVer), the most common methods, the other classifiers presented the intermediates between the best and the worst. With the results obtained by classification by MaxVer, it was verified that at the moment it is part of the soil of the basin is occupied by classes Pasture (63.14%) and native vegetation (22.07%).

KEYWORDS: geoprocessing; Kappa; landsat; remote sensing; use and coverage

INTRODUÇÃO

O uso do sensoriamento remoto de imagens orbitais associado a técnicas de geoprocessamento por meio dos Sistemas de Informações Geográficas (SIGs) mostram-se eficientes para detectar mudanças no uso e cobertura do solo e as alterações provocadas nas paisagens em um determinado local. Segundo Meneses e Almeida (2012), o sensoriamento remoto é uma ciência que visa a obtenção de imagens da superfície da Terra por meio da detecção e medição quantitativa das respostas das interações da radiação eletromagnética com os materiais terrestres.

Os sensores remotos captam as diferentes refletâncias dos objetos e feições terrestres e transformam em imagens, cada objeto tem sua assinatura espectral o que o diferencia de outros, dessa forma torna-se possível a utilização de imagens provindas dos sensores para diversos tipos de mapeamentos e análises dos usos e cobertura da terra. A cobertura da terra se refere aos tipos de componentes que a cobrem, que podem ser relacionados ao meio ambiente (vegetação, água, gelo, rocha nua, solo) ou às construções antrópicas, enquanto que o uso se relaciona com o tipo de atividade que existe em um determinado local de estudo (SHERBININ, 2002).

As técnicas voltadas para a análise de imagens multiespectrais, adquiridas por sensores remotos a bordo de satélites recebem o nome de processamento digital de imagens (PDI), de acordo com Novo e Ponzoni (2001), as técnicas de PDI são divididas em três grupos: pré-processamento, realce e classificação. Os autores ainda explicam que as técnicas do primeiro grupo têm por objetivo a correção de imperfeições e erros introduzidos nos dados originais pelos sistemas sensores, as

técnicas de realce visam melhorar a qualidade visual da imagem através do controle do contraste entre os tons de cinza dos *pixels*, por último, a classificação visa a identificação de classes ou temas que vão compor um dos principais produtos gerados pela extração de informações das imagens do sensoriamento remoto: os mapas temáticos. Dainese (2001) acrescenta que a classificação digital de imagens orbitais consiste no estabelecimento de um processo de decisão no qual um grupo de pixels é definido como pertencente a uma determinada classe ou um tema que descreve um objeto no mundo real.

Atualmente existem diversos softwares utilizados para o PDI, dentre eles, o *Environment for Visualizing Images* (ENVI) é um dos mais populares, nele são disponibilizados diferentes algoritmos de classificação de imagens que proporcionam uma maior automatização e agilidade no mapeamento de uso e cobertura da terra, a eficácia de seu uso para este fim já foi confirmada nos trabalhos de Araújo et al. (2009), Li et al. (2014), Garofalo et al. (2015), Arantes et al. (2016), Lenzi e Nunes (2016) e Santos et al. (2017).

Para a classificação supervisionada os algoritmos mais empregados são os métodos do Paralelepípedo, da Distância Mínima Euclidiana, da Distância de Mahalanobis e o da Máxima-verossimilhança (Maxver). Sendo que, alguns estudos já foram realizados em diferentes locais com o intuito de compará-los quanto a eficiência para a classificação de uso e cobertura do solo, dentre eles pode-se citar os trabalhos de Aykut et al. (2004), Madhura e Venkatachalam (2013), Nery et al. (2013), Pandya et al. (2013), Niknejad et al. (2014), Sarmiento et al. (2014), Abburu e Golla (2015), Cohenca e Carvalho (2015), Garofalo et al. (2015) e Moura (2016).

Garofalo et al. (2015), Cohenca e Carvalho (2015), Souza et al. (2016) e Santos et al. (2017) obtiveram resultados satisfatórios em seus estudos com a utilização do ENVI para o processamento de imagens provenientes do sensor *Operational Land Imager* (OLI) a bordo do satélite Landsat-8, nos trabalhos dos referidos autores as classificações foram validadas através dos valores dos coeficientes de Kappa e acurácias global, obtidos pela matriz de confusão.

Diante do exposto, o objetivo deste trabalho foi avaliar e comparar os desempenhos de quatro algoritmos de classificação supervisionada para o mapeamento do uso e cobertura da terra da bacia hidrográfica do Rio Caldas – GO, utilizando imagens Landsat-8.

MATERIAL E MÉTODOS

A área de estudo compreende a Bacia Hidrográfica do Rio Caldas, inserida na região central do estado de Goiás e na Região Hidrográfica do Rio Paraná. O Rio principal tem suas nascentes localizadas nas proximidades do Distrito Agroindustrial de Anápolis (DAIA) a 1.110 metros de altitude e percorre 103,8 quilômetros até desaguar aos 653 metros de altitude na margem direita do Rio Meia-Ponte, o principal curso d'água que abastece a capital do estado.

A área de drenagem da Bacia é de 1.288,003 km² e está compreendida entre as latitudes 16°26' e 16°55'S e longitudes 48°45' e 49°10'O. Onze municípios compartilham o domínio físico da Bacia: Anápolis, Bela Vista de Goiás, Bonfinópolis, Caldazinha, Goiânia, Goianópolis, Hidrolândia, Leopoldo de Bulhões, Senador Canedo, Silvânia e Terezópolis de Goiás (Figura 1).

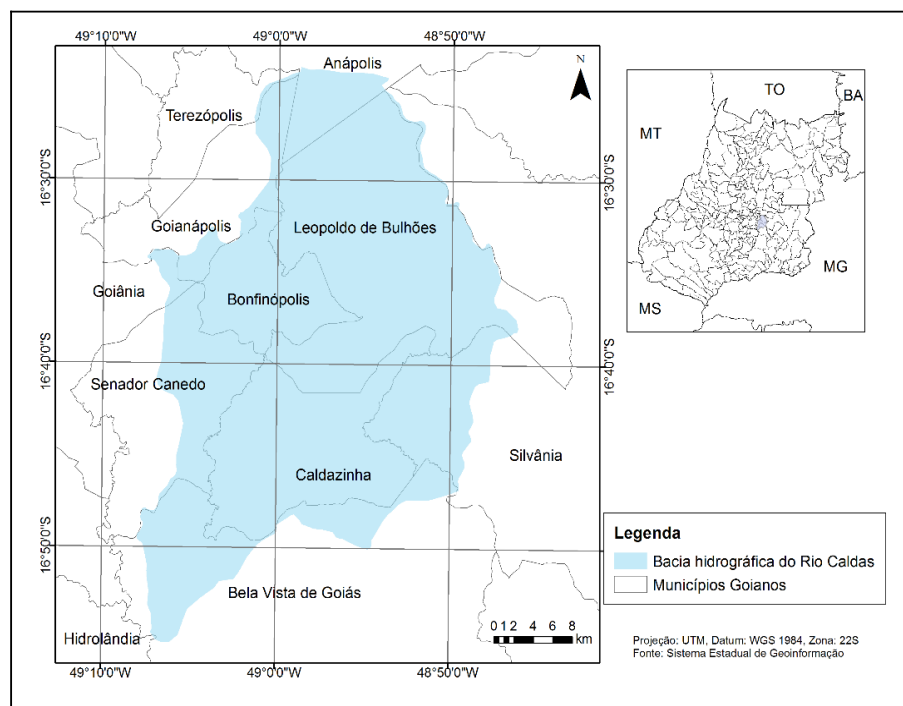


FIGURA 1 Localização da Bacia Hidrográfica do Rio Caldas, no estado de Goiás.

Dados de uma série histórica de produção agropecuária disponibilizada pelo Instituto Mauro Borges de Estatística e Estudos Socioambientais (IMB, 2016) mostram que a principal atividade econômica desenvolvida pelos municípios que compartilham a Bacia do Rio Caldas é a pecuária, sendo a maior parte do solo ocupada por pastagens.

Para o desenvolvimento da pesquisa, foram utilizadas duas imagens provenientes do sensor OLI (Landsat-8), correspondentes às cenas de órbita/ponto 222/71 e 222/72, com datas de passagem em 24/10/2017 e 22/10/2017, respectivamente e, disponibilizadas gratuitamente pelo Serviço Geológico dos Estados Unidos (United States Geological Survey – USGS). O critério para seleção das imagens foi uma presença de nuvens inferior a 10%.

O sensor OLI tem resolução temporal de 16 dias, as imagens são fornecidas já georreferenciadas, dispensando a etapa de correção geométrica. Apresentam uma resolução radiométrica de 16 bits, resolução espectral com nove diferentes bandas que juntas abrangem uma faixa espectral de 0,435 μm a 1,384 μm (Barsi et al. 2014) (Tabela 1).

TABELA 1 Características do sensor OLI do satélite Landsat-8.

Bandas espectrais	Comprimento de onda (μm)	Resolução espacial (m)
Banda 1 (aerossol costeiro)	0,43-0,45	30
Banda 2 (azul)	0,45-0,51	30
Banda 3 (verde)	0,53-0,59	30
Banda 4 (vermelho)	0,64-0,67	30
Banda 5 (infravermelho próximo)	0,85-0,88	30
Banda 6 (infravermelho de onda curta)	1,57-1,65	30
Banda 7 (infravermelho de ondas curtas)	2.11-2.29	30
Banda 8 (pancromática)	0.50-0.68	15
Banda 9 (nuvens cirrus)	1.36-1.38	30
Resolução radiométrica		16 bits
Resolução espacial		16 dias
Dimensões da cena		170x185 km
Projeção		UTM, Datum WGS 1984

Fonte: United States Geological Survey (USGS, 2013).

As imagens foram reprojctadas para o hemisfério sul, visto que, apesar de já serem fornecidas corrigidas geometricamente, elas são posicionadas ao hemisfério norte. Assim, a projeção utilizada no presente trabalho foi a Universal Transversa de Mercator (UTM), fuso 22S, datum planimétrico WGS 1984 (*World Geodetic System* 1984). De acordo com Santos (2014) o sistema UTM é o mais indicado quando se quer trabalhar com áreas de extensões que não ultrapassam mais de dois fusos, ainda apresenta menores distorções e melhor exatidão com as medidas reais, pois, os dados são gerados em metros. Esta etapa foi realizada no *software* QGIS versão 2.18.

Após reprojctadas as imagens foram convertidas do formato *TIF para *HDR para serem trabalhadas no *software* ENVI versão 5.0, tendo em vista que este formato é mais adequado para processamento no aplicativo, onde foram realizadas as etapas seguintes.

Em seguida, para uma melhor visualização e análise dos alvos, as bandas de interesse para a realização do trabalho foram empilhadas para a obtenção da composição colorida ou de falsa cor RGB (*red, green, blue*), para tanto, utilizou-se as bandas 6, 5 e 4 (sequência: B6, G5, B4), esta junção de acordo com Facco et al. (2017) possibilita a distinção mais clara dos limites entre solo e água, com vegetação mais discriminada, aparecendo em tonalidades de verde (Figura 2).

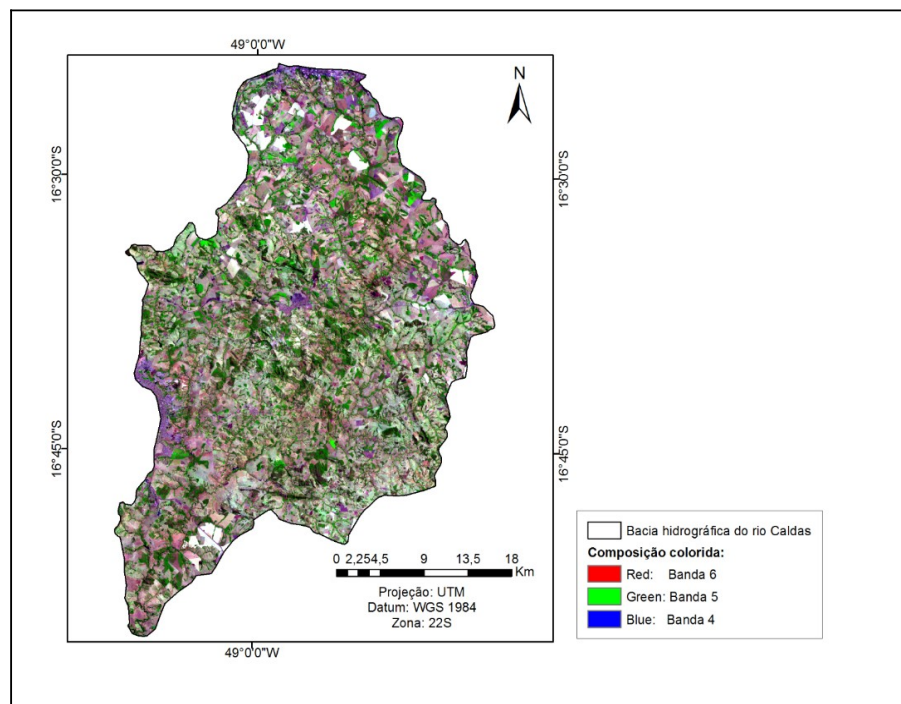


FIGURA 2 Imagem recortada nos limites da bacia hidrográfica do rio Caldas em composição RGB na sequência: banda 6 (R), banda 5 (G), banda 4 (B).

Como foram utilizadas duas cenas, se fez necessária a criação de um mosaico, que consistiu em uni-las para formar uma imagem de dimensões maiores, de modo que, toda a área da bacia fosse abrangida, isso foi feito utilizando a ferramenta Mosaicking. No QGIS, foi realizado o recorte do mosaico, de modo que a imagem final representasse somente a área de interesse, para tanto, foi empregado também o arquivo em formato *shapefile* referente às bacias hidrográficas do estado de Goiás disponibilizados pelo Sistema Estadual de Geoinformação (SIEG).

Para a classificação optou-se pelo método supervisionado, que é empregado quando se pretende classificar a imagem em classes de interesse pré-fixadas, neste processo o analista escolhe pequenas áreas de amostras na imagem, contendo poucas centenas de pixels que sejam bem representativos, espectralmente, de padrões ou feições dos alvos por ele reconhecidos, ou que podem ser identificados com a ajuda de outras fontes, tais como dados coletados no campo ou de mapas (MENESES; SANO, 2012).

As classes do mapeamento foram definidas tendo como base uma visualização prévia e detalhada das imagens, com apoio do software Google Earth, que conta com imagens atualizadas do ano 2017. No ENVI foi realizada a etapa de treinamento que consistiu na definição de regiões de interesse (ROIs), para tanto, foram observadas algumas características que facilitassem a distinção entre as classes, como a cor, textura e forma dos alvos. Foram amostrados em média 30 polígonos por classe e o mínimo de 1.000 pixels para cada uma, de modo que os algoritmos classificadores fossem “treinados” para alocar cada pixel em sua respectiva classe. As mesmas regiões de interesse foram utilizadas para todos os algoritmos classificadores, sendo que, as seguintes classes foram definidas para a etapa de treinamento e posterior classificação:

- **Agricultura:** alvos apresentam coloração verde mais claro que a vegetação nativa, formas geométricas e textura uniforme.
- **Água:** tonalidade que vai do azul claro ao escuro, dependendo da profundidade do corpo hídrico. Apresenta formato linear (rios e córregos), ou circulares (lagos, lagoas, etc.), a textura apresenta pouca variação.
- **Pastagem:** as pastagens cultivadas apresentam coloração em tons de vermelho e formato regular, apresenta pouca variação de textura.
- **Queimadas:** formato irregular e coloração do cinza ao preto, a textura varia como uma escala entre as duas cores. Os algoritmos podem confundir as cicatrizes de queimada com a água, quando os corpos d'água são profundos, ou com aglomerados urbanos mais adensados. Porém, normalmente as cicatrizes de queimadas estão associadas com áreas de cultivo ou pastagem, sendo de fácil correção na pós-classificação.
- **Solo exposto:** a coloração segue normalmente padrões de tonalidades brancas, cinzas e rosas, porém, também foi identificado solo nu com coloração amarelada, visto que a cor visível na imagem depende também dos constituintes químicos do solo. As formas podem ser geométricas (em áreas de plantio abandonadas ou entre safras), de textura uniforme ou desuniforme quando a coloração em uma mesma mancha varia do branco até tons de rosa.
- **Urbanização:** coloração em tons de azul e roxo ocorre em núcleos ou aglomerados, é perceptível a regularidade de ruas e quarteirões, facilmente identificados em imagens de média a alta resolução.
- **Vegetação nativa:** coloração verde de tons claros a escuros, mais claros quando associada aos cursos d'água e elevações do relevo, mais escuros quando em locais menos acidentados e entre os cursos d'água, textura variada no que parecem ser formações savânicas.

Foram testados quatro algoritmos de classificação supervisionada, disponíveis no ENVI. O método do Paralelepípedo que define áreas quadradas ou em paralelepípedo limitadas pelo maior e pelo menor valor de pixels contidos em agrupamentos pré-escolhidos, determinados pelas amostras de treinamento. Quando o algoritmo identifica pixels candidatos a mais de uma classe ou que não se encaixam em nenhuma, eles são realocados à classe mais próxima ou não são classificados, sendo normal a ocorrência de espaços vazios na imagem classificada (MENESES; SANO, 2012).

O método da Máxima-verossimilhança considera a ponderação das distâncias entre as médias dos valores dos pixels das classes, utilizando parâmetros estatísticos. É um classificador muito eficiente porque as classes de treinamento são utilizadas para estimar a forma da distribuição dos pixels contidos em cada classe no espaço de n bandas, como também a localização do centro de cada classe (MENESES ; SANO, 2012), sendo que, todos os pixels são classificados.

O método da Distância Mínima compara a distância euclidiana do pixel à média de cada classe e o atribui à classe cuja média seja mais próxima a ele (BORGES et al., 2007). Por último, o método da Distância de Mahalanobis é um classificador mais rápido, em que, todos os pixels são classificados na classe de treinamento mais próxima, a menos que seja especificado um limite de distância, caso em que alguns pixels podem não estar classificados se não cumprirem o limite (ENVI, 2010).

Para verificação da eficiência de cada um dos classificadores testados foi utilizada a metodologia de interpretação e validação da classificação proposta por Meneses e Sano (2012), Cattani et al. (2013) e Nery et al. (2013), onde, as análises

dos resultados dos coeficientes de Kappa, acurácia geral, matriz de confusão, erros de inclusão e omissão, ajudaram a decidir quais métodos apresentaram os melhores resultados.

A acurácia é calculada em função da matriz de erros, um resultado com 100% indica que todos os pixels foram classificados corretamente, quanto mais próximo deste valor mais correta foi a classificação dos pixels (ARANTES et al., 2016). A matriz de erros compara classe por classe e apresenta a relação entre a verdade de campo e o resultado da classificação, mostrando o quanto o mapeamento está correto.

O coeficiente de Kappa considera todos os elementos da matriz de confusão e mede o grau de concordância em escalas nominais, assumindo que as unidades são independentes, as classes da escala nominal são independentes e mutualmente exclusivas, o classificador e os pontos de referência operam de forma independente (COHEN, 1960). Os valores do coeficiente de Kappa variam de 0 a 1, sendo que, quanto mais próximo de 1 representa uma maior concordância entre os pontos de referência e as categorias classificadas.

Como parâmetro de decisão, no que se refere ao Coeficiente de Kappa, foram utilizados os valores propostos por Landis e Koch (1977) citados por Moreira (2001) (Tabela 2).

TABELA 2 Qualidade da classificação com base no Coeficiente de Kappa.

Coeficiente de Kappa	Qualidade do mapa temático
< 0	Péssima
0 – 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 ; KOCH (1977). Adaptado por MOREIRA (2001).

Os mapas resultantes das classificações foram vetorizados e convertidos para o formato *shapefile*, para posterior manipulação, correções e elaboração dos mapas temáticos no software QGIS 2.18. As tabelas de atributos foram exportadas em formato compatível com o software Excel, onde, os dados foram organizados de forma que facilitasse as análises finais.

RESULTADOS E DISCUSSÃO

Como resultados das imagens classificadas foram obtidos os mapas, de onde se extraiu os dados que serviram de base para as demais análises. Com base somente na visualização já é perceptível a diferença entre os resultados. (Figura 3).

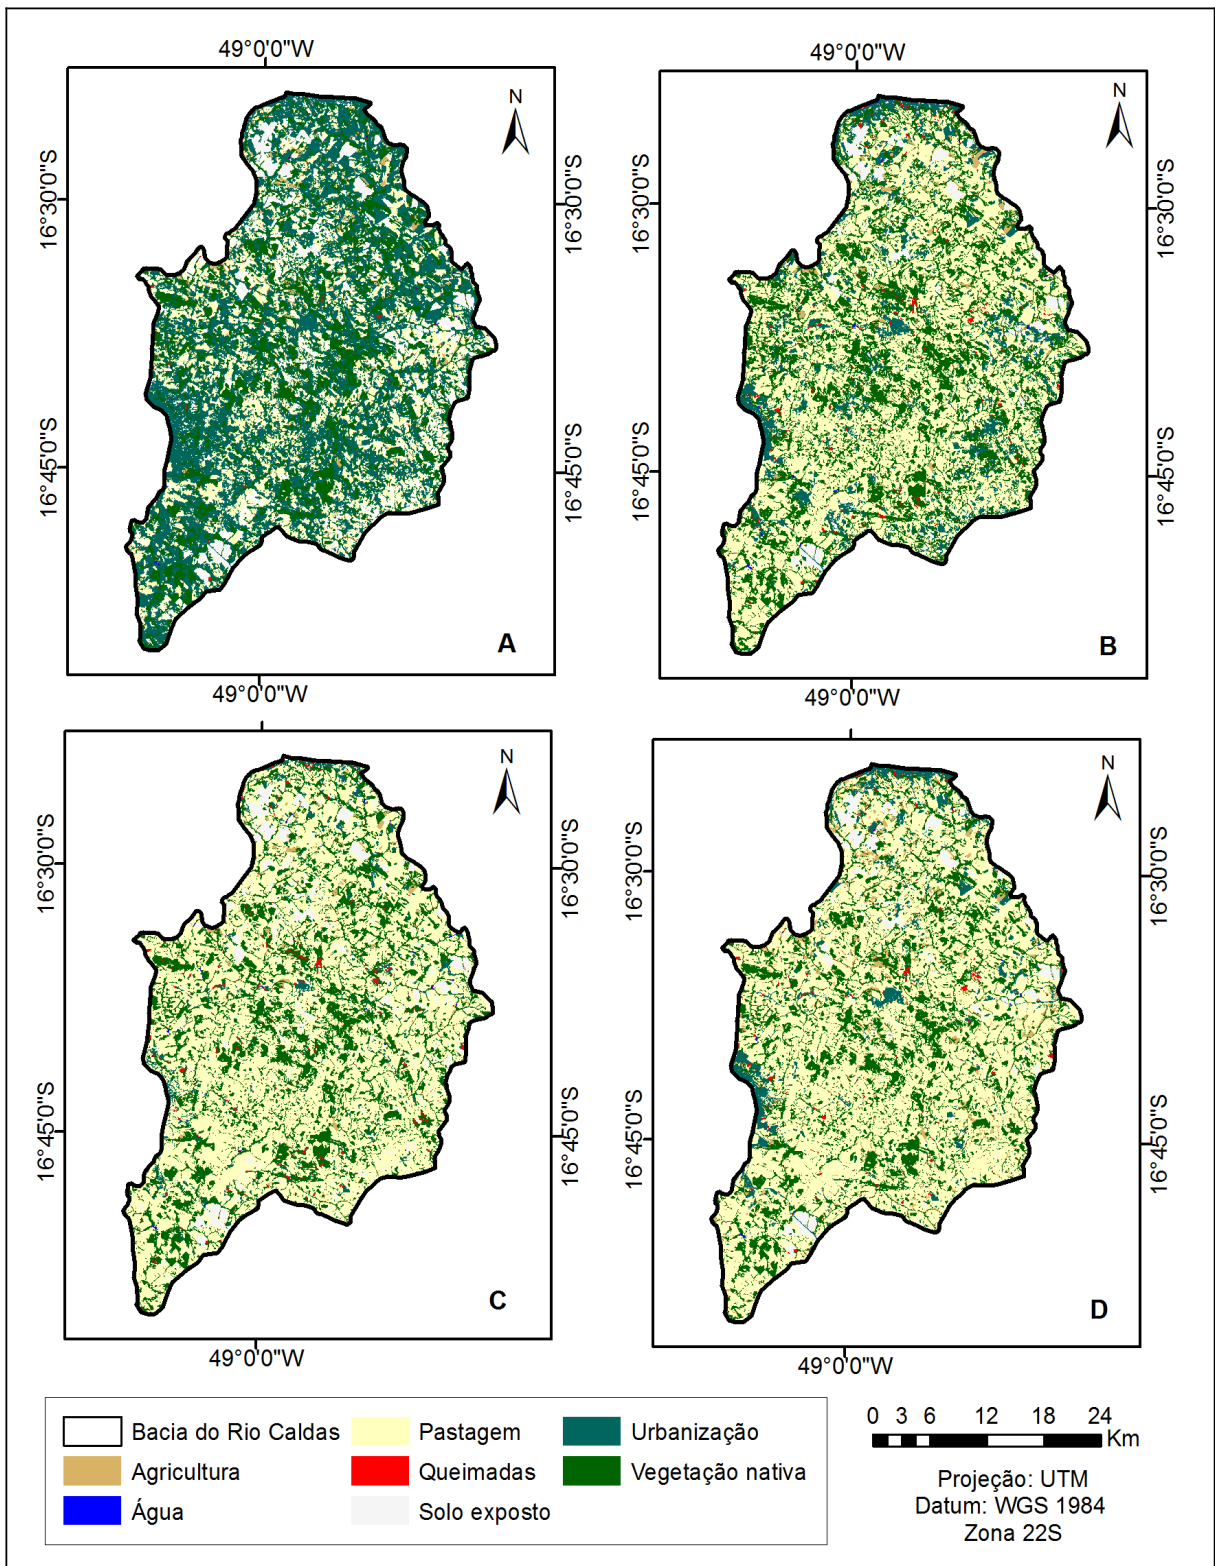


FIGURA 3 Mapas temáticos de uso e cobertura do solo para a bacia hidrográfica do rio Caldas, obtidos pela classificação pelo método do Paralelepípedo (A), Distância de Mahalanobis (B), Distância Mínima (C) e Máxima-verossimilhança (D)

Na comparação das áreas ocupadas por cada classe do mapeamento para a bacia hidrográfica do rio Caldas observou-se que houve diferenças nos resultados obtidos pelos diferentes classificadores, sendo que, nenhuma classe apresentou o mesmo percentual de área ocupada em mais de uma classificação. O método do paralelepípedo deixou de classificar mais de 8% do total de pixels da imagem, ou seja, este percentual não foi inserido em nenhuma das classes pré-estabelecidas na etapa de treinamento. De acordo com os resultados obtidos pela Distância de Mahalanobis, Distância Mínima e Máxima-Verossimilhança (MaxVer) a classe Pastagem é a que ocupa maiores áreas, seguida por Vegetação nativa, na classificação pelo Paralelepípedo a classe Urbanização é que ocupa a maior parte da bacia (Tabela 2).

TABELA 2 Percentuais de áreas ocupadas por cada classe de uso e cobertura da terra na bacia hidrográfica do rio Caldas obtidos pelos diferentes classificadores.

Classes	Resultados obtidos por classificador em km ²			
	Paralelepípedo	Dist. Mahalanobis	Dist. Mínima	MaxVer
Não classificado	8,76	0,00	0,00	0,00
Agricultura	2,21	1,86	1,36	4,56
Água	0,03	0,18	0,11	0,04
Pastagem	22,84	54,46	63,23	63,14
Queimadas	0,14	0,76	0,74	0,56
Solo exposto	2,64	3,01	5,99	3,69
Urbanização	41,43	10,74	4,61	5,94
Vegetação nativa	21,95	28,98	23,96	22,07
Total	100,00	100,00	100,00	100,00

A classificação pelo método do Paralelepípedo também apresentou os piores valores de acurácia global e coeficiente de Kappa, já o método de Máxima-verossimilhança apresentou os melhores resultados, seguido pelos da Distância de Mahalanobis e Distância Mínima. Estas constatações corroboram com o trabalho desenvolvido por Araújo et al. (2009) e indicam que o método do Paralelepípedo não seria recomendado para este tipo de mapeamento, ainda, de acordo com Meneses e Almeida (2012) tal algoritmo é indicado para classificações preliminares de reconhecimento da imagem e para efeitos de visualização (Tabela 3).

TABELA 3 Qualidade das classificações para os diferentes classificadores.

Classificadores	Acurácia	Coef. de	Qualidade da classificação
	(%)	Kappa	
Paralelepípedo	78,5	0,75	Muito boa
Distância Mahalanobis	89,6	0,88	Excelente
Distância Mínima	88,5	0,86	Excelente
MaxVer	96,6	0,96	Excelente

As análises das matrizes de confusão confirmam o fato exposto anteriormente, de que, os melhores resultados do mapeamento de uso e cobertura da terra foram fornecidos pelo método de classificação supervisionada por Máxima-verossimilhança, onde apenas a classe: Queimadas apresentou menos de 90% dos

pixels classificados corretamente, todas as demais ficaram acima deste valor. O maior percentual de confusão (8,49%) foi observado para locais em que a verdade de campo é pertencente a classe Queimadas e os pixels foram classificados como Urbanização.

Para o método da Distância de Mahalanobis, com exceção das classes Queimadas e Urbanização, todas as demais apresentaram um percentual acima de 90% de pixels classificados corretamente. Os maiores percentuais de confusão foram para verdade de campo Urbanização com 9,77% dos pixels classificados como Pastagem, a verdade de campo Queimadas teve 8,09% dos pixels classificados erroneamente como Urbanização.

A classificação pela Distância Mínima apresentou menos de 70% de pixels classificados corretamente para a classe Urbanização, menos de 90% para Agricultura, Queimadas e Pastagem. Foram observados percentuais de confusão de 13,31% para pixels de Queimadas que foram classificados erroneamente como Urbanização e 16,31% de Pastagem sendo classificados também como Urbanização.

Pelo método do Paralelepípedo a classe Queimadas teve somente 43,1% dos pixels classificados corretamente, enquanto que, Pastagem teve o pior resultado entre todas as classes e classificadores, somente 14,1% dos pixels foram classificados de forma correta, as demais classes apresentaram acertos superiores a 80%. As maiores confusões foram observadas para a verdade de campo Pastagem com 85,14% de seus pixels classificados como Urbanização e, para Queimadas com 45,46% de pixels inseridos também em Urbanização.

Os maiores erros de inclusão e omissão foram observados para o método do Paralelepípedo e menores para o da Máxima-verossimilhança, os outros apresentaram valores intermediários. Tais erros demonstram ao percentual de pixels que foram incluídos incorretamente em uma determinada classe (inclusão) ou que foram omitidos da classe correta (omissão) (Tabela 4).

TABELA 4 Erros de inclusão e omissão observados para os resultados dos diferentes classificadores.

Classes	Erros de inclusão (I) e omissão (O) em %							
	Paralelepípedo		Dist. Mahalanobis		Dist. Mínima		MaxVer	
	I	O	I	O	I	O	I	O
Agricultura	0,84	8,19	4,59	20,36	3,16	11,35	3,36	0,78
Água	0,07	2,02	8,50	0	8,18	0,01	0,07	2,11
Pastagem	9,10	85,90	17,39	3,39	23,71	16,79	2,88	2,49
Queimadas	2,43	56,90	3,27	15,65	8,64	19,22	3,71	10,26
Solo exposto	0,02	0,55	0,52	2,43	0,17	0,04	0,14	0,02
Urbanização	63,77	2,39	15,12	19,13	36,05	31,58	12,89	5,65
Vegetação nativa	11,04	1,69	21,02	5,66	9,15	4,55	1,71	3,87
Total	87,27	157,64	70,41	66,62	89,06	83,54	24,76	25,18

Os bons resultados obtidos através do método da Máxima-verossimilhança indicam que, dentre os algoritmos testados pelo presente estudo, ele é o melhor a ser utilizado para o mapeamento de uso e cobertura da terra de bacias hidrográficas inseridas no Cerrado goiano. Baseado nisso, para o presente artigo assume-se que a classe predominante na área em estudo é a Pastagem ocupando 813,22 km²,

seguida por Vegetação nativa que ocupa 284,24 km², Urbanização com 76,48 km², Agricultura 58,78 km², Solo exposto 47,46 km², Queimadas 7,27 km² e Água com 0,55 km².

A escolha do algoritmo da Máxima-verossimilhança como o que apresentou melhor classificação corrobora com os resultados obtidos em estudos realizados para diferentes regiões do território brasileiro, como os de Araújo et al. (2009) e Cattani et al. (2013) em regiões distintas no estado do Paraná, Nery et al. (2013) e Sarmiento et al. (2014) em Minas Gerais, Cohenca e Carvalho (2015) em Santa Catarina e, Rosa et al. (2017) no Rio Grande do Sul, ambos comparando diferentes classificadores supervisionados.

Alguns estudos realizados em outros países, comparando classificadores para mapeamentos temáticos, também obtiveram os melhores resultados com o método MaxVer, como exemplo temos os de Aykut et al. (2004) na Turquia, Madhura e Venkatachalam (2013) na Índia.

Resultados diferentes foram obtidos por Niknejad et al. (2014) em pesquisa realizada no Iran e Moura (2016) em Goiás, em ambos o melhor classificador foi o *Support Vector Machine* (SVM), não testado no presente estudo.

O método MaxVer é o mais utilizado para classificação supervisionada (RICHARDS;JIA, 2006), os resultados obtidos no presente estudo estão em concordância com a afirmação de Niknejad et al. (2014) de que esse algoritmo é considerado um dos que costumam apresentar acurácia mais alta entre os classificadores existentes.

CONCLUSÃO

- 1.A utilização de imagens Landsat-8 para o mapeamento do uso e cobertura da terra da bacia hidrográfica do rio Caldas - GO, possibilitando a obtenção de resultados satisfatórios na diferenciação das sete classes pré-definidas na etapa de treinamento, viabilizando uma precisa caracterização da área.
- 2.O algoritmo classificador da Máxima-verossimilhança se mostrou superior aos demais através da comparação entre os coeficientes de Kappa, acurácias global e matrizes de confusão, indicando a eficácia de sua utilização para estudos desta natureza.
- 3.O presente estudo demonstra a importância de se realizar uma análise comparando diferentes algoritmos classificadores para auxiliar na decisão de qual o melhor método a ser empregado para o mapeamento de uso e cobertura do solo, visto que, uma escolha precipitada pode gerar resultados que omitem grande parte da verdade observada em campo.

REFERÊNCIAS

- ABBURU, S.; GOLLA, B. S. Satellite image classification methods and techniques: a review. **International Journal of Computer Applications**, v. 119, p. 20–25, 2015.
- ARANTES, L. T.; ARANTES, B. H. T.; TONDATO, C. Análise multitemporal para o monitoramento de desmatamento através da imagem Landsat-5. **Revista Eletrônica de Agronegócio [online]**, v. 5, 2016.
- ARAÚJO, G. K. D.; JOHANN, J. A.; ROCHA, J. V. Criação de mapa temático de uso da terra com diferentes classificadores. In: **Anais XIV Simpósio Brasileiro de Sensoriamento Remoto – SBSR**, Natal, RN, Brasil, INPE, 2009.

AYKUT, A.; ERONAT, A. H.; NECDET, T. Comparing Different Satellite Image Classification Methods: An Application in Ayvalik District, Western Turkey. In: **Proc. XXth ISPRS Congress Technical Commission**, Istanbul, Turkey, 2014.

BARSI, J. A.; KVARAN, G.; MARKHAM, B. L.; PEDELTY, J. A. A. 2014. Resposta Espectral do Landsat-8 Operational Land Imager. **Remote Sens.** [online], v. 6, 2014.

BORGES, R. O.; SILVA, R. A. A.; CASTRO, S. S. Utilização da classificação por distância euclidiana no mapeamento dos focos de Arenização no setor sul da alta bacia do Rio Araguaia. **Anais XIII Simpósio Brasileiro de Sensoriamento Remoto**, Florianópolis, Brasil, INPE, 2007.

CATTANI, C. E. V.; MERCANTE, E.; SOUZA, C. H.; WRUBLACK, S. C. 2013. Desempenho de algoritmos de classificação supervisionada para imagens dos satélites RapidEye. In: **Anais XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, Foz do Iguaçu, PR, Brasil, INPE, 2013.

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

COHENCA, D.; CARVALHO, R. Comparação de métodos de classificação OBIA, Máxima Verossimilhança e Distância Mínima em imagem OLI/Landsat-8 em área de alta diversidade de uso do solo. In: **Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, João Pessoa-PB, Brasil, INPE, 2015.

ENVI - Environment for Visualizing Images. **Guia do usuário em português**. Sulsoft, 2010.

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

FACCO, D.S.; BENEDETTI, A. C.; KAISER, E. A.; FILHO, W. P. Avaliação da dinâmica do uso e cobertura da terra no município de Faxinal do Soturno no estado do Rio Grande do Sul. **Os Desafios da Geografia Física na Fronteira do Conhecimento [online]**, v. 1, 2017.

GAROFALO, D. F. T.; MESSIAS, C. G.; LIESENBERG, V.; BOLFE, E. L.; FERREIRA, M. C. Análise comparativa de classificadores digitais em imagens do Landsat-8 aplicados ao mapeamento temático. **Pesquisa Agropecuária Brasileira**, v. 7, p. 593-604, 2015.

IMB - Instituto Mauro Borges de Estatística e Estudos Ambientais. **Pesquisas Anuais**, 2016. Disponível: <http://www.imb.go.gov.br/pesqview.asp?caderno=PESQUANUAIS>. Acesso: 15 dez. 2017.

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

LENZI, I. L. C.; NUNES, G. M. Comparação entre os classificadores support vector machine e spectral angle mapper aplicado à diferenciação das fitofisionomias do Parque Estadual do Araguaia (MT). **Revista Geoaraguaia [online]** v. 6, 2016.

LI, P.; JIANG, L.; FENG, Z. Cross-Comparison of Vegetation Indices Derived from Landsat-7 Enhanced Thematic Mapper Plus (ETM+) and Landsat-8 Operational Land Imager (OLI) Sensors. **Remote Sens. [online]**, v. 6, 2014.

MADHURA, M.; VENKATACHALAM, S. Comparison of Supervised Classification Methods On Remote Sensed Satellite Data: An Application In Chennai, South India. **International Journal of Science and Research (IJSR)** v. 4, p. 1407-1411, 2013 .

MENESES, P. R.; ALMEIDA, T. **Introdução ao processamento de imagens de sensoriamento remoto**. Universidade de Brasília, Brasília, 2012.

MENESES, P. R.; SANO E. E. Classificação pixel a pixel de imagens. In: **Meneses, P. R., Almeida, T. (Org.), Introdução ao Processamento de Imagens de Sensoriamento Remoto**. 1 ed. Universidade de Brasília, Brasília, p.191-208, 2012.

MOREIRA, M. A. 2001. Fundamentos de Sensoriamento Remoto e Metodologias de Aplicação. 1 ed. INPE, São José dos Campos.

MOURA, N. V. A. **Comparação entre classificadores supervisionados para fins de análise multitemporal do uso e cobertura da terra no entorno do reservatório da Usina hidrelétrica de Corumbá IV/GO**. Dissertação (Mestrado). Brasília, Universidade de Brasília, 2016.

NERY, C. V. M.; FERNANDES, F. H. S.; Moreira, A. A.; Braga, F. Avaliação das Técnicas de Classificação MAXVER, MAXVER – ICM e Distância Mínima Euclidiana de acordo com Índice Kappa. **Revista Brasileira de Geografia Física**, v. 02, p. 211-219, 2013.

NIKNEJAD, M.; MIRZAEI, Z. V.; HEYDARI, M. 2014. Comparing different classifications of satellite imagery in forest mapping (Case study: Zagros forests in Iran). **International Research Journal of Applied and Basic Sciences**, . v.8, p. 1407–1415, 2014.

NOVO, E.M.L.M.; PONZONI, F. J. **Introdução ao Sensoriamento Remoto**. Instituto Nacional de pesquisas Espaciais, Divisão de Sensoriamento Remoto. 2001.

RICHARDS, J.; JIA, X. 2006. Remote sensing of tropical forests: an overview of research and applications using non-photographic sensors. **Engineering & Remote Sensing**. [online] v. 56, 2006.

ROSA, E. P.; TRENTIN, R.; DIAS, D. F.; SANTOS, V. S. 2017. Mapeamento do uso e ocupação da terra no município de Jaguari - RS. **Os Desafios da Geografia Física na Fronteira do Conhecimento [online]** v. 1, 2017.

SANTOS J. **QGIS 2.4, Sistema de Referência de Coordenadas (SRC)**. 2014. Disponível:
http://www.processamentodigital.com.br/wpcontent/uploads/2014/10/20141011_QGIS24_Sistema_de_Referencia_de_Coordenadas.pdf.

SANTOS L. A. C.; BATISTA, A. C.; NEVES, C. O. M.; CARVALHO, E. V.; SANTOS, M. M.; GIONGO, M. Análise multitemporal do uso e cobertura da terra em nove municípios do Sul do Tocantins, utilizando imagens Landsat. **Revista Agro@ambiente [online]** v. 11, n. 2, p. 111-118, 2017.

SARMIENTO, C. M.; RAMIREZ, G. M.; COLTRI, P. P.; SILVA, L. F. L.; NASSUR, O. A. C.; SOARES, J. F. Comparação de classificadores supervisionados na discriminação de áreas cafeeiras em Campos Gerais - Minas Gerais. **Coffee Science**, v. 9, n. 4, p. 546 – 557.2014.

SHERBININ, A. A. **Thematic Guide to Land-Use and Land-Cover Change (LUCC)**. CIESIN, Palisades, 2002.

SIEG - Sistema de Informações Geográficas do Estado de Goiás. **Compartimentação do Estado de Goiás em Bacias Hidrográficas segundo metodologia do Dr. Otto Pfafstetter**, 2016. Disponível: <http://www.sieg.go.gov.br/produtosIMB.asp?cod=1949>. Acesso: 15 nov. 2017.

SOUZA, C. D.; SILVA, R. M. N.; RODRIGUES, L. I. C.; MORORO, E. A. A.; DUARTE, C. R.; SOUTO, M. V. S. Emprego de imagens Landsat na análise temporal da linha de costa da porção oeste do estado do Ceará. **Revista de Geologia** v. 29, p. 181-194, 2015.

USGS - United States Geological Survey. **Landsat 8**, 2013. Disponível: <https://landsat.usgs.gov/landsat-8>. Acesso: 20 nov. 2017.