



APLICAÇÕES, PREFERÊNCIAS E COMPARAÇÕES ENTRE MÉTODOS DE CLASSIFICAÇÃO SUPERVISIONADA: O CASO DE NATAL/RN

APPLICATIONS, PREFERENCES AND COMPARISONS BETWEEN SUPERVISED CLASSIFICATION METHODS: THE CASE OF NATAL / RN

Aldalfran Herbert de Melo Silveira¹, Fernando Moreira da Silva², Renato Moreira Hadad¹, Matheus Pereira Libório¹

RESUMO

Essa pesquisa teve como objetivo oferecer evidências empíricas para responder a quatro perguntas. Quais são as principais áreas de aplicação de Sensoriamento Remoto (SR) no Brasil? Qual é a participação relativa de cada área de aplicação nas pesquisas da área da geografia do Brasil? Qual é a proporção de utilização do Classificador Máxima Verossimilhança (MaxVer) nas pesquisas de classificação supervisionada? Quantos e quais classificadores comparar para assegurar bons resultados na classificação supervisionada? Para isso, toma-se como referência pesquisas publicadas nas principais revistas da área da geografia do Brasil e, como exemplo, a classificação supervisionada do município de Natal, Rio Grande do Norte. Nesse exemplo, valida-se internamente (comparação entre classificadores) e externamente (análise dos resultados em relação a outras pesquisas que realizam comparações entre classificadores) os resultados de quatro métodos de classificação supervisionada. Os resultados indicam que o SR é mais aplicado em pesquisas de análise urbana (38%), seguida de análises de atividades econômicas (27%), análises ambientais (23%) e análises metodológicas (12%). O MaxVer é o classificador mais utilizado em SR, sendo encontrado em 65% das pesquisas. Comparado a outros classificadores, o MaxVer apresenta melhores resultados de classificação em 64% dos casos. Conclui-se nessa pesquisa que a comparação entre três classificadores (desde que um deles seja o MaxVer) pode assegurar uma melhor classificação em 83% dos casos.

Palavras chave: Sensoriamento remoto; Áreas de aplicação; Análise de classificadores; Uso da terra; Análise da paisagem.

ABSTRACT

This research aims to provide empirical evidence to answer four questions. What are the main application areas of Remote Sensing (RS) in Brazil? What is the relative participation of each application area in researches in the area of geography in Brazil? What is the proportion of use of the Maximum Likelihood Classifier in supervised classification research? How many and which classifiers to compare to ensure good results in supervised classification? To do so, it is used as reference researches published in top Brazilian geographical journals and, as an example, the supervised classification of the city of Natal, Rio Grande do Norte. In this example, the results of four methods of supervised classification are validated internally (comparing classifiers) and externally (results analysis in relation to other researches that make comparisons between classifiers). The results show that RS is more applied in urban analysis (38%), followed by the analysis of economic activities (27%), environmental analysis (23%) and methodological analysis (12%). The Maximum Likelihood Classifier is the most used in RS, being found in 65% of the searches. Compared to other classifiers, Maximum Likelihood Classifier presents better classification results in 64% of cases. This research concludes that the comparison between three classifiers (since one of them is Maximum Likelihood) can assure a better classification in 83% of the cases.

Keywords: Remote sensing; Areas of application; Classification analysis; Land use; Landscape analysis.

Recebido em: 05/07/2019

Aceito em: 25/03/2020

¹ Pontifícia Universidade Católica de Minas Gerais (PUC-MG). Emails: adalfran@gmail.com, rhadad@pucminas.br, m4th32s@gmail.com.

² Universidade Federal do Rio Grande do Norte (UFRN). Email: fmoreyra@urfnet.br.

**APLICAÇÕES, PREFERÊNCIAS E COMPARAÇÕES ENTRE MÉTODOS DE CLASSIFICAÇÃO
SUPERVISIONADA: O CASO DE NATAL/RN**

1. INTRODUÇÃO

As paisagens urbanas são complexas e cada lugar tem suas peculiaridades e nuances (LAUDARES; LIBÓRIO, 2018). Embora uma informação do tipo urbano/não-urbano seja valiosa para determinar padrões e tendências do crescimento da cidade, tais informações podem não fornecer detalhes suficientes para se tomar decisões consistentes sobre o uso e a cobertura da terra (MELO JUNIOR et al., 2017; STANGANINI; LOLLO, 2018). O Processamento Digital de Imagens (PDI) de Sensoriamento Remoto (SR), normalmente realizado por meio de Sistemas de Informações Geográficas (SIG) possibilita extrair das imagens digitais informações com detalhes suficientes para realizar a diferenciação estatística entre os diversos objetos ou áreas da superfície (ROSA, 2018). Esse detalhamento torna o SR um recurso útil para mapear padrões e tendências de uso e ocupação dos espaços. Por sua vez, essa utilidade se reflete no número de pesquisas que fazem uso do SR para produzir esses mapeamentos.

Entre 2017 e 2018 diversas pesquisas sobre SR foram publicadas nas principais revistas da área da geografia no Brasil [1]. Em grande parte, essas pesquisas empregam a classificação supervisionada de imagens que tem uma característica fundamental: as classes são definidas “a priori” e cada pixel da imagem é associado a uma determinada classe conforme uma função discriminante preestabelecida (HASMADI; PAKHRIAZAD; SHAHRIN, 2017; PHIRI; MORGENROTH, 2017). Além de numerosas, pesquisas que usam SR para mapear padrões e tendências de uso e ocupação dos espaços se interessam por diversas subáreas da geografia, como, por exemplo, ambiental (ANDRADE; LOURENÇO, 2016; OLIVEIRA et al., 2019), urbana (PROFETA, 2015) e econômica e (FONSECA; SILVA; SENNA, 2018). Contudo, ainda que se reconheça a vasta literatura sobre SR, algumas questões permanecem em aberto, como, por exemplo: Quais são as principais áreas de aplicação da classificação supervisionada? Quais são os percentuais de

uso dos classificadores em pesquisas? Quais os riscos da não comparação entre classificadores nas pesquisas?

Essa pesquisa teve como objetivo oferecer evidências empíricas para responder a essas perguntas, e toma como exemplo a classificação supervisionada do município de Natal Rio Grande do Norte. Para tanto, esse estudo valida os resultados da classificação supervisionada internamente (comparação entre classificadores) e externamente (análise dos resultados em relação a outras pesquisas que realizam comparações entre classificadores). A dupla validação (interna e externa) da classificação supervisionada traz novas evidências que podem contribuir para reduzir deficiências inerentes ao SR, como, por exemplo, a quantidade de informações sobre cada pixel, a resolução espacial das imagens e as regras de decisão adotadas para designar os pixels às classes (NISHIDA, 1998; SILVA; DOURADO, 2016; ALMEIDA et al., 2018; ROSA, 2018). Essas validações podem contribuir para selecionar o classificador que melhor representa as interações existentes no espaço e auxiliar análises em áreas como: meio ambiente (p.ex. ANDRADE; LOURENÇO, 2016; OLIVEIRA ET AL., 2016); planejamento urbano (p.ex. PROFETA, 2015; TRINDADE; SALDANHA; PEREIRA FILHO, 2017); e desenvolvimento econômico e regional (p.ex. FONSECA; SILVA; SENNA, 2018).

2. EVIDÊNCIAS DAS APLICAÇÕES, PREFERÊNCIAS E COMPARAÇÕES DE MÉTODOS DE CLASSIFICAÇÃO SUPERVISIONADA

Pesquisadores vêm desenvolvendo procedimentos para coleta e análise de dados de SR por mais de 150 anos (JENSEN, 2007). Desde então, academia e setores privado e público realizam pesquisas sobre o uso de recursos da terra em diversas áreas (LONGLEY; et al., 2005). Para Forshaw et al. (1983), a análise de imagens de SR é especialmente importante em pesquisas voltadas para análise ambiental (p. ex. monitoramento) em suas diferentes

**APLICAÇÕES, PREFERÊNCIAS E COMPARAÇÕES ENTRE MÉTODOS DE CLASSIFICAÇÃO
SUPERVISIONADA: O CASO DE NATAL/RN**

escalas. Por outro lado, o crescente investimento em programas de lançamento e operação de satélites para geração de imagens (BELUCO; ENGEL; BELUCO, 2015) aumentou a produção de dados (imagens digitais) e estimulou o avanço de técnicas de SR (MOSER; et al., 2018). A maior disponibilidade de imagens digitais e o avanço das técnicas para a análise dos diversos objetos ou áreas da superfície contribuiu para ampliar as possibilidades de pesquisas de SR para além da análise ambiental (BEN-DOR; IRONS; EPEMA, 1999; ROMERO; et al., 2018).

Pelo menos entre as principais revistas da área da geografia analisadas [1], 38% das pesquisas de SR se concentram em análise urbana (p. ex. crescimento populacional e seus impactos), 27% em análises de atividades econômicas (p. ex. exploração agrícola e mineral), 23% em análise

ambiental (p. ex. monitoramento de bacia Hidrográfica e áreas de preservação) e 12% em análises metodológicas de SR (ex. métodos de classificação). Independentemente da área de pesquisa, o SR permite identificar e extrair informações contidas nas imagens para sua posterior interpretação (MOSER, et al., 2018). Essa interpretação é realizada por meio de métodos de classificação que particionam as imagens em classes (JENSEN, 2007). Pesquisadores afirmam que o método de classificação Máxima Verossimilhança (MaxVer) é o mais utilizado em pesquisas de SR (PRADO; HAYAKAWA; KAWAKUBO, 2016). Pelo menos entre as 26 pesquisas publicadas nas principais revistas da área da geografia [1] (Quadro 1) é possível confirmar tal afirmativa, pois 65% dessas pesquisas aplicam MaxVer.

<i>Classificador / Área de pesquisa</i>	<i>MaxVer</i>	<i>Vizinho Mais próximo ou Distância Mahalanobis</i>	<i>Proporção (%)</i>
<i>Análise ambiental</i>	Andrade e Lourenço (2016), Oliveira et al. (2016), Paula, Benedetti e Pereira Filho (2016), Leite, Marcos Esdras et al. (2012) e Sousa (2012).	Ribeiro, Silveira e Nucci (2013a)	23
<i>Análise urbana</i>	Ribeiro, Silveira e Nucci (2013), Dias, Trentin e Scoti (2015), Cardoso e Centeno (2015), Fernandes, Moreira e Nery (2015), Demarchi, Piroli e Zimback (2011), Passo, Souza Bias, Brites e Costa, (2013), Trindade, Saldanha e Pereira Filho (2017) e Profeta (2015).	Sakuno, Kawakubo, Spalevic e Mincato (2017) e Ribeiro, Silveira e Nucci (2013b)	38
<i>Atividades econômicas</i>	Arcoverde et al. (2010), Ferreira et al. (2012), Fonseca, Silva e Senna (2018) e Pfadenhauer e Butzke (1978).	Prado, Hayakawa e Kawakubo (2016), Franco, Scopel e Assunção (2015), Kawakubo, Morato e Luchiari (2004).	27
<i>Análise metodológica</i>		Justino, Martines e Kawakubo (2017), Ferreira e Ferreira (2013) e Reis et al. (2015).	12
<i>Proporção -%</i>	65%	35%	100%

Quadro 1 – Trabalhos publicados em revistas da geografia que utilizam SR por área. Fonte: Elaborado pelos autores.

Pelo menos nos trabalhos revisados, o MaxVer é o classificador mais utilizado em

pesquisas nas áreas ambiental, urbana e econômica. Apesar dessa preferência, o MaxVer é

**APLICAÇÕES, PREFERÊNCIAS E COMPARAÇÕES ENTRE MÉTODOS DE CLASSIFICAÇÃO
SUPERVISIONADA: O CASO DE NATAL/RN**

alvo de críticas por parte de pesquisadores. Primeiro porque o algoritmo considera que o padrão das classes presentes na imagem possui distribuição normal (JENSEN, 2005). Segundo porque não considera o comportamento espectral dos pixels vizinhos na tomada de decisão (PRADO; HAYAKAWA; KAWAKUBO, 2016). Por outro lado, pesquisadores afirmam que o MaxVer pode apresentar melhores resultados quando se tem um melhor conhecimento da área a ser interpretada (DIAS; TRENTIN; SCCOTI, 2015).

O fato é que qualquer processo de classificação envolve deficiências. Em primeiro lugar existem deficiências relacionadas à quantidade de informações sobre cada pixel (ROSA, 2018). Em segundo lugar existem deficiências relacionadas à resolução espacial das imagens (SILVA; DOURADO, 2016; ALMEIDA et al., 2018). Em terceiro lugar existem deficiências relacionadas à estrutura, premissas e hipóteses utilizadas no desenvolvimento do método de classificação, ou seja, às regras de decisão adotadas para designar os pixels às classes (NISHIDA, 1998).

Por isso, diversas pesquisas têm se dedicado a reduzir tais deficiências, especialmente aquelas que comparam classificadores, como: MaxVer, Distância Mínima (*Minimum Distance* - MinDist), Análise Linear Discriminante de Fischer (ALD-F), Distância Mahalanobis (*Mahalanobis Distance* - DM), Vizinho Mais Próximo (*K-Nearest Neighbor* - KNN), k-médias (KM), *Bhattacharya* (BHA) e Paralelepípedo (PAR). Normalmente a comparação entre os resultados desses classificadores é realizada por meio do coeficiente Kappa (K). O coeficiente Kappa é uma medida de associação usada para explicar e investigar o grau de concordância (confiança e exatidão) na classificação (KOTZ; HORMAN, 1983). O Kappa é uma medida da concordância real (indicado pelas células das diagonais da matriz de erro/confusão) menos a concordância por chance (indicado pelo produto total da linha e coluna, que não inclui entradas não reconhecidas) (VAN VLIET; BREGT; HAGEN-ZANKER, 2011). O Kappa mede o quanto a classificação está de acordo com os dados de

referência, assumindo os seguintes níveis de desempenho: péssimo ($k < 0$) ruim ($0 < K < 0,20$), razoável ($0,20 < K < 0,40$), bom ($0,40 < K < 0,60$), muito bom ($0,60 < K < 0,80$) e excelente ($0,80 < K < 1,00$) (LANDIS; KOSH, 1977).

O número de pesquisas que realizam comparações entre classificadores é significativo. Somente entre 2010 e 2018 foi possível relacionar onze pesquisas, sendo que dez delas utilizam o Kappa. A pesquisa de Moreira et al. (2016) é a exceção. Dentre os classificadores utilizados nessas comparações, o classificador MaxVer está presente em 90,9% dos casos. Essa é mais uma evidência que confirma que o MaxVer é o mais classificador mais utilizado em pesquisas de SR (PRADO; HAYAKAWA; KAWAKUBO, 2016). O Quadro 2 traz um resumo dos resultados das pesquisas que realizam comparações entre classificadores. A qualidade do classificador é indicada por números, sendo o melhor classificador representado pelo número 1.

SILVEIRA, A.H. M., et. al.
**APLICAÇÕES, PREFERÊNCIAS E COMPARAÇÕES ENTRE MÉTODOS DE CLASSIFICAÇÃO
 SUPERVISIONADA: O CASO DE NATAL/RN**

Referência	Classificador								Parâmetros		
	MaxVer	MinDist	DM	KNN	KM	BHA	PAR	Outro ^b	Sensor satélite ^a	Kappa	Resolução (metros)
Pertille et al. (2018)	1	2						2	II	0,976; 0,924	10
Fonseca et al. (2014)	1		3				2	4	VI	0,782; 0,777; 0,739	1 a 30
Cohenca e Carvalho (2015)	1	2						1	I	0,570; 0,390	30
Reis e Saavedra (2015)	2				1	3			I	0,888; 0,773; 0,944	30
Vale et al. (2018)	1	3	2						I	0,920; 0,840; 0,840	30
Campos et al. (2016)		2	1					2	I	0,660; 0,590	30
Gonçalves et al. (2015)	2						1		I	0,220; 0,330	
Ferreira et al. (2010)	2			1		3			VI	0,625; 0,620; 0,856	30
Moreira et al. (2016) ^c	1	3	4				2		V	0,920; 0,750; 0,670; 0,710	4 e 30
Silva et al. (2013)	1							1	IV	0,897; 0,907	4
Tangerino e Lourenço, (2013)	1				2				III	0,550; 0,130	
Melhor resultado em (%):	64%	0%	9%	9%	9%	0%	9%	10	-	-	-

Quadro 2 - Qualidade (ranking) do classificador em estudos que realizam comparação entre classificadores (1=melhor resultado). Legenda: (a) Satélite / sensor: (I. Operational Land Imager - LandSat 8; II. Sentinel-2/MSI; III. Hemispherical Resonator Gyroscope - Sattelite Pour l'Observation de la Terre; IV. Ikonos-II; V. KOMPSAT-2 e - Landsat 7; VI. Operational Land Imager - LandSat 5). (b): Outros métodos (Classificação Orientada por Objetos; Suppor Vector Machine Classification; Redes Neurais; Árvore de Decisões, Lógica Fuzzy; Spectral Angle Mapper; Isodata, Binary Encoding; e Maximum Likelihood). (C): os autores não utilizam Kappa. Fonte: Elaborado pelos autores.

Considerando que o número 1 é atribuído ao classificador que gera o maior coeficiente Kappa e que a chance do classificador gerar o maior coeficiente Kappa é dada pela frequência em que o número 1 é atribuído ao classificador, observa-se que o classificador MaxVer gera coeficientes Kappa maiores do que os demais classificadores em 65% das pesquisas

(TANGERINO; LOURENÇO, 2013; SILVA et al., 2013; MOREIRA et al., 2016; VALE et al., 2018; COHENCA; CARVALHO, 2015; PERTILLE et al., 2018; FONSECA et al., 2014). Nas pesquisas de Campos et al. (2016), Ferreira et al. (2010), Reis e Saavedra (2015) e Gonçalves et al. (2015), os classificadores DM, KNN, KM e PAR geraram os maiores coeficientes Kappa. Ou seja, esses

APLICAÇÕES, PREFERÊNCIAS E COMPARAÇÕES ENTRE MÉTODOS DE CLASSIFICAÇÃO SUPERVISIONADA: O CASO DE NATAL/RN

classificadores geram coeficientes Kappa maiores do que os demais classificadores em 9% das pesquisas listadas cada um. Isso significa que ao se combinar dois desses classificadores com o MaxVer tem-se 83% de chance de se obter o maior coeficiente Kappa, ou seja, a melhor classificação. Considerando que cada um dos classificadores DM, KNN, KM e PAR gera maior coeficiente Kappa em 9% das pesquisas e que o MaxVer gera maior coeficiente Kappa em 65% das pesquisas, tem-se da combinação de dois desses classificadores com o MaxVer uma chance de 83% de se obter o maior coeficiente Kappa.

Por outro lado, a utilização dos classificadores MinDist e BHA combinados a outros dois classificadores diferentes do MaxVer representa uma chance de apenas 18% de se obter a melhor classificação possível entre os sete classificadores analisados. Pelo menos em relação às onze pesquisas analisadas, não é possível afirmar quais dos sete classificadores analisados devem ser combinados ao MaxVer, mas é possível afirmar que essa combinação não deve ser feita com os classificadores MinDist ou BHA, pois tais classificadores não apresentam maior coeficiente Kappa em nenhuma das pesquisas analisadas.

Ainda que a chance do classificador gerar maiores coeficientes Kappa possa indicar quais classificadores combinar, os cálculos dos classificadores são diferentes, fazendo com que cada classificador tenha vantagens e desvantagens. Por exemplo, a MaxVer é calculada por meio da ponderação das distâncias entre as médias dos valores dos pixels das classes (FISHER, 1936). Esse classificador tende a ser mais eficaz porque cada pixel é destinado à classe que tem a mais alta probabilidade (semelhança) (MENESES; ALMEIDA, 2012). A MinDist é calculada por meio da informação contida em um conjunto de arquivos de assinatura, e utiliza a distância Euclidiana para incorporar cada pixel a um agrupamento (EASTMAN, 2012). A ALD-F é calculada por meio de uma função discriminante linear. Trata-se de uma função criada a partir de dados de treinamento pela qual é possível se calcular a probabilidade de um dado pertencer a uma determinada categoria (FISHER, 1936). A

definição da classe de cada pixel se dá após a avaliação de todas as funções (EASTMAN, 2012). A DM é calculada considerando o espalhamento dos dados, inclusive a orientação de amostras de uma determinada classe. Esse método assume que todas as covariâncias de classe são iguais (RIBEIRO; SILVEIRA; NUCCI, 2013). O KNN é calculado considerando comportamento espectral dos pixels vizinhos na tomada de decisão (PRADO; HAYAKAWA; KAWAKUBO, 2016). Esse método mantém os valores de níveis de cinza e de brilho dos pixels da imagem original (SAKUNO et al., 2017).

Baseado nessas diferenças de cálculo, busca-se em primeiro lugar comparar as classificações MaxVer, MinDist e KNN (KARANTZALOS, 2015) para o município de Natal/RN com os resultados consolidados na literatura do Quadro 2. Em segundo lugar, busca-se introduzir a classificação por ALD-F ao quadro de comparações. Em terceiro lugar, busca-se oferecer comparações com base nas imagens do satélite Landsat-8 uma vez que trabalhos anteriores utilizam imagens dos sensores SPOT (TANGERINO; LOURENÇO, 2013), ALOS (RIBEIRO; DORTZBACH; FLORES, 2012), Landsat-5 (ALBINO et al., 2013) ou Landsat-7 (GONÇALVES; SOUZA FILHO, 2005).

3. MATERIAIS E MÉTODOS

O espaço em análise é o município de Natal, estado do Rio Grande do Norte, Brasil, que tem as seguintes coordenadas geográficas: Latitude 05° 47'42" Sul, Longitude: 35° 12' 32" Oeste (COSTA JUNIOR; et al., 2012). Segundo o Censo de 2010, o município apresenta uma população de 862.044 habitantes, sendo 100% urbana (IBGE, 2010). A Figura 1 mostra o mapa de localização de Natal, destacando sua área urbana, objeto de análise dessa pesquisa.

SILVEIRA, A.H. M., et. al.
APLICAÇÕES, PREFERÊNCIAS E COMPARAÇÕES ENTRE MÉTODOS DE CLASSIFICAÇÃO SUPERVISIONADA: O CASO DE NATAL/RN

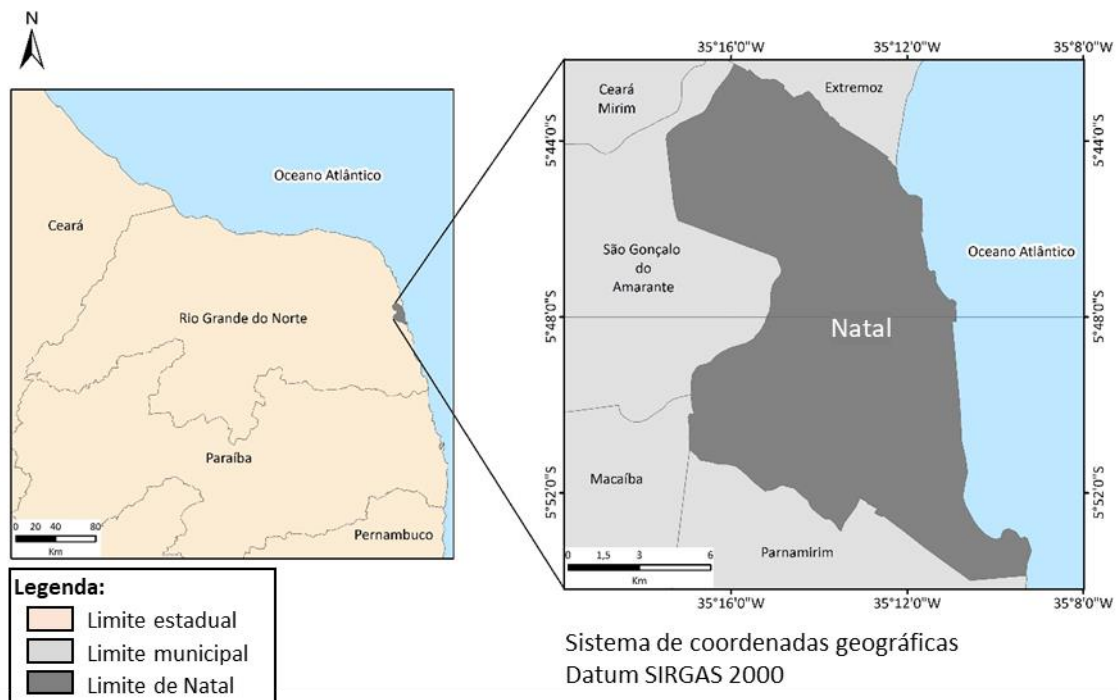


Figura 1 - Mapa de Localização. Fonte: Elaborado pelos autores.

O desenvolvimento da pesquisa foi realizado em 4 etapas: (1) Download e importação das imagens orbitais; (2) Pré-processamento das imagens orbitais; (3) Processamento das imagens orbitais; e (3.1) Classificação supervisionada.

Na primeira etapa, as imagens orbitais foram obtidas do instrumento imageador Operational Land Imager (OLI) da plataforma Landsat-8, correspondente a órbita 214, ponto 64, gratuitamente disponibilizados na página do Serviço de Levantamento Geológico Americano (USGS), acessível pelo link <https://www.usgs.gov/products/data-and-tools/data-and-tools-topics>. O processamento das imagens foi realizado nos SIGs IDRISI Selva Edition e ArcGIS 10.3. No IDRISI foi realizada a importação do arquivo GEOTIFF e a inclusão das coordenadas geográficas. Em seguida, as imagens foram recortadas de forma que o polígono abrangesse todo o município em epígrafe.

Na segunda etapa (pré-processamento), foram realizadas correções radiométricas das imagens. Essas correções foram necessárias devido a presença de desajustes na calibração dos detectores, erros esporádicos na transmissão dos dados e/ou influências atmosféricas. Os valores radiométricos das imagens Landsat-8 foram discretizados em 16 bits. Diferente das séries

anteriores, foi necessário realizar uma transformação (“Rescale”) para 8 bits. Como o histograma destas comportaram-se de forma unimodal, devido as características fisiográficas da área de estudo, aplicou-se a técnica de realce linear por saturação de contraste. Assim, foram executadas manipulações no histograma até se obter o contraste necessário para a visualização adequada dos alvos na imagem.

Para a conversão do Digital Number (DN) para radiância foram seguidos os parâmetros de coeficientes de calibração do sensor LANDSAT 8 OLI disponibilizados pelo Earth Resources Observation and Science Center (EROS). Para a correção atmosférica, seguiu-se o modelo de reflectância aparente (calculada a partir do Topo da Atmosfera) no IDRISI (SILVA; ANDRADE, 2013).

Na terceira etapa, para a execução das classificações, foram selecionadas as bandas Red – Green – Blue (RGB) 432, cor natural. Essa escolha foi baseada na resposta dessa composição em distinguir áreas ocupadas com vegetação (ex.: solo exposto, ocupação antrópica, solo de mangues) e em discernir e desanexar os três tipos de cobertura vegetal aqui abordados de forma precisa. Após a composição RGB, realizou-se o procedimento de fusão para otimizar a informação multiespectral e a resolução espacial

**APLICAÇÕES, PREFERÊNCIAS E COMPARAÇÕES ENTRE MÉTODOS DE CLASSIFICAÇÃO
SUPERVISIONADA: O CASO DE NATAL/RN**

da banda pancromática de 30m para 15m, viabilizando uma melhor identificação dos alvos urbanos. Em seguida, definiram-se as áreas de treinamento contendo dez classes de uso, a saber: Cl_1=(Dunas); Cl_2=(Mangue solo); Cl_3=(Mangue vegetação); Cl_4=(Nuvens)[2]; Cl_5=(Ocupação Antrópica); Cl_6=(Recursos hídricos); Cl_7=(Solo exposto); Cl_8=(Sombra de nuvens)[2]; Cl_9=(vegetação densa); Cl_10=(Vegetação rasteira). .

Na quarta etapa aplicaram-se as classificações supervisionadas apoiadas nos seguintes algoritmos: ALD-F, MaxVer, MinDist e KNN. Essas classificações foram realizadas no módulo de Processador de Imagens do SIG IDRISI, e, posteriormente na aba Hard Classifiers por meio dos algoritmos citados. No módulo SAMPLE, foram gerados 300 pontos aleatórios aos quais foram objeto da pesquisa de campo. Desses 300 pontos obteve-se êxito de acesso em 83 pontos (27,66%) [3], os quais foram fotografados no sentido Norte, Sul, Leste e Oeste. Os outros 217 pontos foram analisados por meio de fotointerpretação da imagem original apoiada por controle de campo. A defasagem temporal entre a tomada das imagens e a data de verificação de campo foi de 2 anos.

A partir da barra de ferramentas do menu principal do IDRISI, foi elaborada e analisada a cobertura do solo com os pontos amostrados obtidos: i.) do trabalho de campo; ii.) das imagens do Google Earth; iii.) das imagens obtidas do Google Street View. Em seguida, o arquivo raster da verdade terrestre e as classificações realizadas foram inseridas e analisadas no módulo ERRMAT

do IDRISI. O módulo ERRMAT tabula os erros e intervalos de confiança da classificação supervisionada por meio da confrontação da imagem uso da terra interpretado com a imagem da verdade terrestre (EASTMAN, 2012). Por fim, foi elaborada a matriz de erro/confusão que tabula as diferentes classes de uso da terra que as células verdadeiras foram atribuídas por meio do coeficiente Kappa (K).

4. RESULTADOS E DISCUSSÕES

Para o estudo de classificação supervisionado na área urbana de Natal/RN, utilizou-se quatro classificadores e 10 (dez) classes de uso da terra. Os resultados são apresentados em forma de matriz de erros. Essas matrizes apresentam a classificação digital em relação à imagem referência. Cada frequência observada na matriz corresponde a uma frequência esperada, na qual é calculada sob uma determinada hipótese de acordo com as regras da probabilidade (SPIEGEL, 1993). A frequência observada, em negrito, na diagonal apresenta a concordância entre o esperado e observado em cada categoria, ou seja, aqueles corretamente classificados.

A Tabela 1 traz a matriz de erro/confusão do classificador Fisher em relação ao mapa verdade. Este classificador teve desempenho de 0,65 (muito bom) no índice proposto por Landis e Kosh (1977). A matriz expõe a variabilidade das amostras no classificador em questão. Das 297 amostras aleatórias, 215 amostras apresentaram concordância com a realidade.

CLASSES	Cl_1	Cl_2	Cl_3	Cl_4	Cl_5	Cl_6	Cl_7	Cl_8	Cl_9	Cl_10
Cl_1	0	0	0	0	0	0	0	0	0	0
Cl_2	0	2	1	0	0	1	0	0	1	1
Cl_3	0	0	7	0	0	1	0	0	2	1
Cl_4	0	0	0	23	0	0	1	0	0	0
Cl_5	0	0	0	1	34	0	3	1	1	1
Cl_6	0	0	1	0	1	99	0	0	0	0
Cl_7	2	0	0	0	6	0	1	0	0	0
Cl_8	0	2	4	4	2	4	0	11	0	1
Cl_9	0	1	0	0	1	0	1	0	14	4
Cl_10	0	1	0	4	5	0	9	1	12	24

Tabela 1 - Matriz verdade terrestre (ALD-F). Legenda: Cl_1=(Dunas); Cl_2=(Mangue solo); Cl_3=(Mangue vegetação); Cl_4=(Nuvens); Cl_5=(Ocupação Antrópica); Cl_6=(Recursos hídricos); Cl_7=(Solo exposto); Cl_8=(Sombra de nuvens); Cl_9=(vegetação densa); Cl_10=(Vegetação rasteira). Fonte: Elaborado pelos autores.

**APLICAÇÕES, PREFERÊNCIAS E COMPARAÇÕES ENTRE MÉTODOS DE CLASSIFICAÇÃO
SUPERVISIONADA: O CASO DE NATAL/RN**

A Tabela 2 traz a matriz de erro/confusão do classificador MinDist em relação ao mapa verdade. Tal classificador obteve desempenho de 0,61 (muito bom) no índice proposto por Landis e

Kosh (1977). A matriz expõe a variabilidade das amostras no classificador em questão, de 300 amostras aleatórias, 203 apresentaram concordância com a realidade.

CLASSES	Cl_1	Cl_2	Cl_3	Cl_4	Cl_5	Cl_6	Cl_7	Cl_8	Cl_9	Cl_10
Cl_1	0	0	0	0	0	0	0	0	0	0
Cl_2	0	4	2	2	0	7	0	1	2	0
Cl_3	0	0	3	0	0	1	0	0	0	0
Cl_4	2	0	0	28	3	1	3	1	1	2
Cl_5	0	0	0	2	31	0	3	3	2	4
Cl_6	0	0	1	0	1	96	0	0	0	0
Cl_7	2	0	0	1	12	0	5	0	4	4
Cl_8	0	0	4	0	0	0	0	8	0	1
Cl_9	0	0	2	0	0	0	0	0	7	0
Cl_10	0	2	1	0	2	0	4	0	14	21

Tabela 2 - Matriz verdade terrestre (MinDist). Legenda: Cl_1=(Dunas); Cl_2=(Mangue solo); Cl_3=(Mangue vegetação); Cl_4=(Nuvens); Cl_5=(Ocupação Antrópica); Cl_6=(Recursos hídricos); Cl_7=(Solo exposto); Cl_8=(Sombra de nuvens); Cl_9=(vegetação densa); Cl_10=(Vegetação rasteira).
Fonte: Elaborado pelos autores.

A Tabela 3 traz a matriz de erro/confusão do classificador MaxVer em relação ao mapa verdade, ao qual, teve o desempenho de 0,66 (muito bom) no índice proposto por Landis e Kosh

(1977). A matriz expõe a variabilidade das amostras no classificador em questão, de 300 amostras aleatórias, 208 apresentaram concordância com a realidade.

CLASSES	Cl_1	Cl_2	Cl_3	Cl_4	Cl_5	Cl_6	Cl_7	Cl_8	Cl_9	Cl_10
Cl_1	2	0	0	0	0	0	0	0	0	0
Cl_2	0	1	2	0	0	2	0	0	1	0
Cl_3	0	0	6	0	0	1	0	0	0	0
Cl_4	0	0	0	29	0	2	3	3	2	1
Cl_5	1	1	2	3	38	1	5	1	4	4
Cl_6	0	0	0	0	1	97	0	0	0	0
Cl_7	1	2	0	0	9	2	2	0	1	2
Cl_8	0	0	2	0	0	0	0	0	0	1
Cl_9	0	0	1	1	0	0	0	9	10	1
Cl_10	0	2	0	0	1	0	5	0	12	23

Tabela 3 - Matriz verdade terrestre (MaxVer). Legenda: Cl_1=(Dunas); Cl_2=(Mangue solo); Cl_3=(Mangue vegetação); Cl_4=(Nuvens); Cl_5=(Ocupação Antrópica); Cl_6=(Recursos hídricos); Cl_7=(Solo exposto); Cl_8=(Sombra de nuvens); Cl_9=(vegetação densa); Cl_10=(Vegetação rasteira).
Fonte: Elaborado pelos autores.

A Tabela 4 traz a matriz de erro/confusão do classificador KNN em relação ao mapa verdade e o desempenho foi de 0,62 (muito bom) no índice proposto por Landis e Kosh (1977). A matriz expõe

a variabilidade das amostras no classificador em questão, de 300 amostras aleatórias, 207 apresentaram concordância com a realidade.

**APLICAÇÕES, PREFERÊNCIAS E COMPARAÇÕES ENTRE MÉTODOS DE CLASSIFICAÇÃO
SUPERVISIONADA: O CASO DE NATAL/RN**

CLASSES	Cl_1	Cl_2	Cl_3	Cl_4	Cl_5	Cl_6	Cl_7	Cl_8	Cl_9	Cl_10
Cl_1	2	0	0	5	0	0	3	0	0	0
Cl_2	0	4	1	3	2	3	0	2	1	0
Cl_3	0	1	6	0	0	0	0	0	3	2
Cl_4	0	0	0	19	0	0	0	0	0	0
Cl_5	0	0	0	0	33	0	3	1	1	4
Cl_6	0	0	1	0	1	101	0	1	0	0
Cl_7	2	0	0	5	10	0	5	2	3	4
Cl_8	0	1	4	0	0	0	0	7	0	1
Cl_9	0	0	1	0	1	1	0	0	15	6
Cl_10	0	0	0	1	2	0	4	0	7	15

Tabela 4 - Matriz verdade terrestre (KNN). Legenda: Cl_1=(Dunas); Cl_2=(Mangue solo); Cl_3=(Mangue vegetação); Cl_4=(Nuvens); Cl_5=(Ocupação Antrópica); Cl_6=(Recursos hídricos); Cl_7=(Solo exposto); Cl_8=(Sombra de nuvens); Cl_9=(vegetação densa); Cl_10=(Vegetação rasteira). Fonte: Elaborado pelos autores.

Os quatro classificadores apresentaram uma resposta muito boa ($0,60 < K < 0,80$) em relação ao coeficiente de concordância Kappa. Os coeficientes Kappa obtidos ficaram entre 0,61 a 0,66, sendo 0,66 para MaxVer; 0,65 para ALD-F; 0,62 para KNN; 0,61 para MinDist. Esses resultados se baseiam nas comparações das respectivas amostras desses classificadores, ou seja, 217; 215; 207; 203. Entre os classificadores, o MaxVer se sobressaiu perante os demais, mas em menor intensidade se comparado ao classificador ALD-F. Enquanto o MaxVer alcançou nas 217 amostras 72,33% de concordância com a realidade, ALD-F alcançou nas 215 amostras 71,66% de concordância com a realidade. Por sua vez, o classificador KNN alcançou nas 207 amostras 69,00% de concordância com a realidade. Por fim, o classificador MinDist alcançou nas 203 amostras 67,66% de concordância com a realidade. Esses resultados evidenciam que as diferenças entre os coeficientes Kappa dos classificadores utilizados na validação interna estão entre 0,67% e 4,67%. Em média, essas diferenças são de apenas 2,77%, dimensão que se reflete na semelhança visual entre os mapas das classificações apresentados na Figura 2.

Esses resultados (validação interna da classificação supervisionada) revelam que a comparação entre métodos de classificação supervisionada pode, ao indicar o classificador mais apropriado para a situação/problema,

melhorar os resultados das análises do estudo. Por exemplo, tomando como unidade de análise o município de Natal/RN, a adoção do MaxVer em detrimento do MinDist melhorou a classificação de forma absoluta em até 4,67% e/ou de forma relativa em até 6,45%.

Destaca-se ainda que a melhor representação da realidade do espaço urbano obtida por meio do classificador MaxVer também ocorre em 65% dos estudos que comparam métodos de classificação (ver Quadro 2). Esse resultado (validação externa das comparações realizadas) reforça a importância do classificador MaxVer, justificando em parte, o fato desse classificador ser o mais utilizado em SR. Além disso, os resultados sugerem que o classificador Fisher pode oferecer resultados mais consistentes do que o KNN e o MinDist em análises que comparam classificadores.

SILVEIRA, A.H. M., et. al.
**APLICAÇÕES, PREFERÊNCIAS E COMPARAÇÕES ENTRE MÉTODOS DE CLASSIFICAÇÃO
SUPERVISIONADA: O CASO DE NATAL/RN**

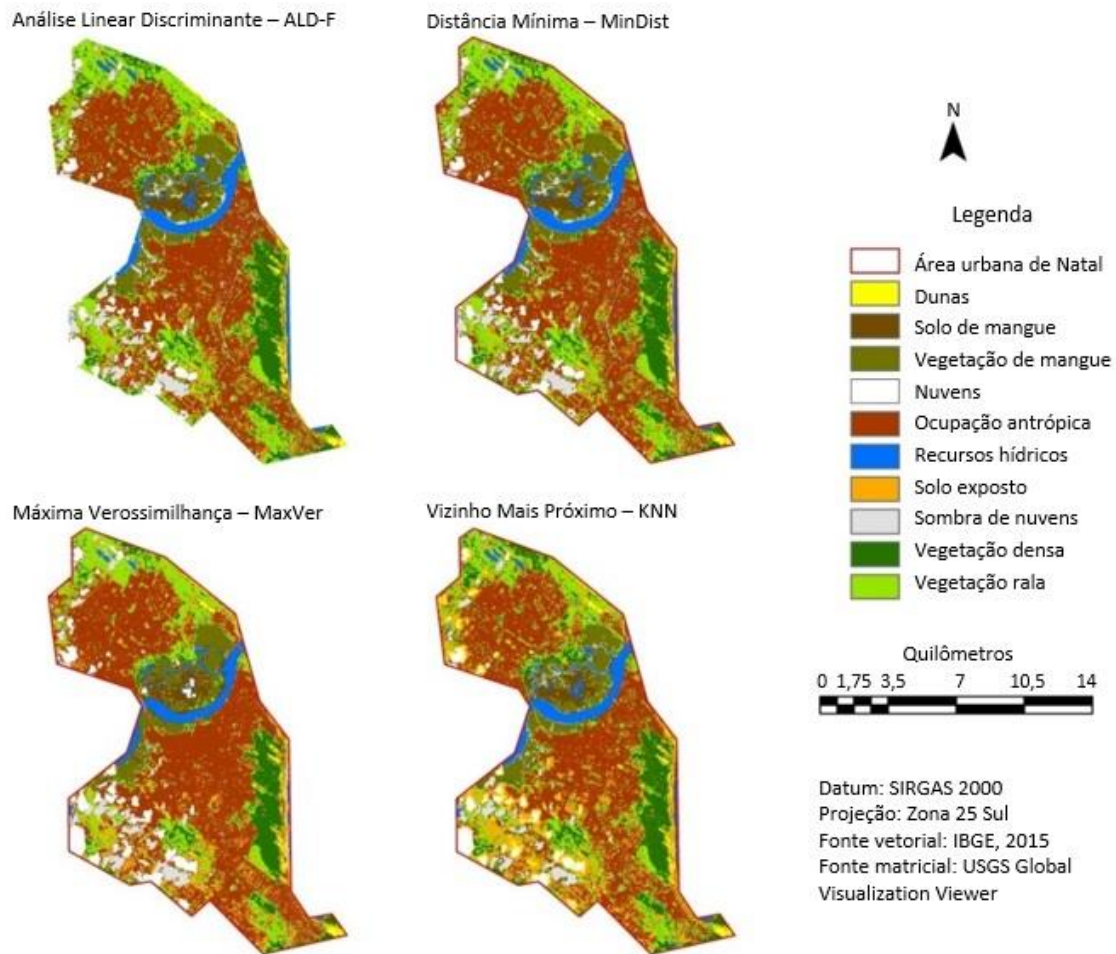


Figura 2 - Mapeamentos de Classificação Supervisionados. Fonte: Elaborado pelos autores.

5. CONCLUSÃO

Essa pesquisa valida interna e externamente a classificação supervisionada do município de Natal/RN, buscando uma representação consistente da realidade do espaço urbano. Para a validação interna foram aplicadas as classificações supervisionadas pixel a pixel baseadas nos algoritmos de classificação ALD-F, MaxVer, MinDist e classificação KNN. Para a validação externa foram analisados os resultados obtidos do município de Natal em relação a outras onze pesquisas que também comparam classificadores. Entre as contribuições dessa pesquisa incluem-se evidências empíricas que demonstram quais são as principais áreas de aplicação de SR e qual é a participação relativa de cada área de aplicação nas pesquisas publicadas nas principais revistas da área da geografia do Brasil [1]. Em síntese, as

evidências mostram que 38% dessas publicações estão relacionadas à análise urbana, 27% estão relacionadas à análises de atividades econômicas, 23% estão relacionadas à análise ambiental e 12% estão relacionadas à análises metodológicas de SR. Além disso, essa pesquisa traz evidências que permitem afirmar que o MaxVer: i.) é o classificador mais utilizado nas pesquisas de classificação supervisionada, sendo encontrado em 65% dos trabalhos publicados nas principais revistas da área de geografia; e ii.) quando comparado a outros classificadores, o MaxVer apresenta os melhores resultados, sendo o melhor classificador em 64% dos casos. Por fim, demonstra-se que a utilização de dois classificadores (excluídos o MinDist e o BHA) combinados ao MaxVer representa uma chance

**APLICAÇÕES, PREFERÊNCIAS E COMPARAÇÕES ENTRE MÉTODOS DE CLASSIFICAÇÃO
SUPERVISIONADA: O CASO DE NATAL/RN**

de 83% de se obter a melhor classificação possível entre os sete classificadores analisados.

Ainda que essas descobertas forneçam insights para discussões e aplicações em SR, essa pesquisa apresenta ao menos três limitações as quais se colocam como potenciais pesquisas futuras. A primeira limitação está associada à obtenção de dados (registro fotográfico) em campo. Barreiras físicas e outras dificuldades em acessar pontos da amostra implicou na redução do êxito de acesso (27,66%). Sugere-se estudar outras formas de extrair informações desses pontos (p. ex. drones) para se analisar possíveis alterações no uso da terra decorrentes da defasagem temporal entre as imagens de campo e as imagens usadas na fotointerpretação. A segunda limitação está associada à diversidade de padrões de cobertura do solo. Essa diversidade dificultou estabelecer classes com boa separabilidade espectral. Sugere-se realizar outros testes com maior quantidade de classes e subclasses. A terceira limitação está associada à significância estatística das evidências das áreas de aplicação de SR, principais classificadores e comparações entre classificadores. A quantidade de evidências (pesquisas) estudadas é insuficiente para realizar testes de hipótese que permitam generalizar os resultados. Sugere-se ampliar o número de evidências para representar a população com maior rigor estatístico.

6. NOTAS

[1] Considerou-se como uma das “principais revistas da área da geografia”, o periódico classificado como A1 e A2 (2013-16) no portal Qualis Capes. Entre tais periódicos estão: Caminhos de Geografia, Revista do Departamento de Geografia, GEOUSP: Espaço e Tempo, RA'E GA: O Espaço Geográfico em Análise; RBC. Revista Brasileira de Cartografia; Ateliê geográfico, Boletim goiano de geografia, Geographia, Mercator e Revista da ANPEGE.

[2] A existência de nuvens e sombras destas, detectadas pelos sensores ópticos devem ser consideradas no mapeamento do uso da

terra. Rudorff e Sugawara (2007), relatam que a frequente cobertura de nuvens nas imagens obtidas pelos satélites da série Landsat, principalmente no litoral Brasileiro, prejudica e até mesmo reprova que estas sejam utilizadas para fins de análise da paisagem.

[3] O tamanho da amostra é estatisticamente significativo para um nível de significância de 95% e margem de erro de 10%.

7. REFERÊNCIAS

ALBINO, T.; VICTORIA, D. D. C.; BATISTELLA, M.; SILVA, G. B. S.; LOEBMANN, D. D. S. Comparação entre a classificação supervisionada e a interpretação visual de agrossistemas nos municípios de Álvares Florence e Dracena, Estado de São Paulo. In: **Congresso Interinstitucional de Iniciação Científica**. Campinas, 2013.

ALMEIDA, R. T. S.; MOREIRA, A. N. H.; GRIEBELER, N. P.; DE SOUSA, S. B. INFLUÊNCIA DOS DADOS E MÉTODOS NO MAPEAMENTO DO USO E DA COBERTURA DA TERRA. **Raega-O Espaço Geográfico em Análise**, v. 43, p. 7-22, 2018.

ANDRADE, F. M.; LOURENÇO, R. W. Uso do solo e cobertura vegetal na Bacia Hidrográfica do Rio Una-Ibiúna/SP. **Revista do Departamento de Geografia**, v. 32, p. 48-60, 2016.

ARCOVERDE, G. F. B.; EPIPHANIO, J. C. N.; MARTINS, V. A.; MAEDA, E. E.; FONSECA, L. M. G. MAPEAMENTO DE CITROS: AVALIAÇÃO DE CLASSIFICAÇÕES POR ÁRVORE DE DECISÃO. **Revista Brasileira de Cartografia**, n. 62/1, 2010.

BELUCO, A.; ENGEL, P. M.; BELUCO, A. Classification of textures in satellite image with Gabor filters and a multi-layer perceptron with back propagation algorithm obtaining high accuracy. **International Journal of Energy and Environment**, v. 6, n. 5, p. 437, 2015.

BEN-DOR, E.; IRONS, J. R.; EPEMA, G. F. Soil reflectance. **Manual of Remote Sensing: Remote Sensing for Earth Science; Rencz, AN, Ryerson, RA, Eds**, p. 111-187, 1999.

SILVEIRA, A.H. M., et. al.
**APLICAÇÕES, PREFERÊNCIAS E COMPARAÇÕES ENTRE MÉTODOS DE CLASSIFICAÇÃO
SUPERVISIONADA: O CASO DE NATAL/RN**

- CARDOSO, F. B.; CENTENO, J. A. S. Análise da dinâmica do uso e cobertura do solo em Blumenau (SC), utilizando ferramentas de geoprocessamento. **Caminhos de Geografia**, v. 16, n. 56, 2015.
- 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. **Anais do XVII Simpósio Brasileiro de Sensoriamento Remoto. João Pessoa, Instituto Nacional de Pesquisas Espaciais**, João Pessoa-PB, Brasil, 25 a 29 de abril de 2015. p.1035-1042
- COSTA JUNIOR, N. P.; SILVEIRA, A. H. M.; SILVA, B. C. O.; SILVA, F. M.; Modelo Analítico para Estimativa da Umidade do Ar Através do Canal Termal do Sensoriamento Remoto. **Revista Geonorte**, Edição Especial, v.2, n.4, p.1594 – 1601, 2012.
- DEMARCHI, J. C.; PIROLI, E. L.; ZIMBACK, C. R. L. Análise temporal do uso do solo e comparação entre os índices de vegetação NDVI e SAVI no município de Santa Cruz do Rio Pardo–SP usando imagens LANDSAT-5. **Raega-O Espaço Geográfico em Análise**, v. 21, 2011.
- DIAS, D. F.; TRENTIN, R.; SCCOTI, A. A. V. Zoneamento Geoambiental para o município de Mata/RS: síntese das potencialidades e fragilidades. **Revista do Departamento de Geografia**, v. 30, p. 132-148, 2015.
- EASTMAN, J. R. IDRISI Selva manual. **Worcester: Clark Labs**, 2012.
- FERNANDES, F. H. S.; MOREIRA, A. A.; NERY, C. V. M. Dinâmica do uso e ocupação do solo da área desapropriada do lago artificial do bico da pedra no Norte do Estado de Minas Gerais. **Caminhos de Geografia**, v. 15, n. 50, 2015.
- FERREIRA, J. H. D.; OLIVEIRA, M. A.; VIERO, G. P.; FERREIRA, R. J. D.; PEREIRA, P. S.; SOUZA FILHO, E. E. DIFERENCIAÇÃO DA SILVICULTURA DE EUCALIPTO e PINUS, NA REGIÃO DA BACIA HIDROGRÁFICA DO TIBAGI. **Revista Brasileira de Cartografia**, 2012.
- FERREIRA, M. C.; FERREIRA, M. M. INFORMAÇÕES ESPACIAIS DE CARTAS ANTIGAS VISUALIZADAS EM IMAGENS DIGITAIS ATUAIS: UMA CONTRIBUIÇÃO DO SIG À ARQUEOLOGIA DA PAISAGEM. **Revista do Departamento de Geografia**, v. 26, p. 1-14, 2013.
- FISHER, R. A. The use of multiple measurements in taxonomic problems. **Annals of eugenics**, v. 7, n. 2, p. 179-188, 1936.
- FONSECA, S. F.; SILVA, A. C.; SENNA, J. A. TÉCNICAS DE GEOPROCESSAMENTO APLICADAS NA IDENTIFICAÇÃO DE USOS DA TERRA NO ENTORNO DAS TURFEIRAS DA SERRA DO ESPINHAÇO MERIDIONAL. **Raega-O Espaço Geográfico em Análise**, v. 43, p. 124-139, 2018.
- FORSHAW, M. R. B.; HASKELL, A.; MILLER, P. F.; STANLEY, D. J.; TOWNSHEND, J. R. G. Spatial resolution of remotely sensed imagery A review paper. **International Journal of Remote Sensing**, v. 4, n. 3, p. 497-520, 1983.
- FRANCO, I. O.; SCOPEL, I.; ASSUNÇÃO, H. F. UNIDADES DE MAPEAMENTO DE SOLOS SOB CULTIVO DE CANA-DE-AÇÚCAR EM 2011: análise da expansão da cultura no Sudoeste de Goiás (Brasil). **Revista do Departamento de Geografia**, v. 30, p. 1-18, 2015.
- GONÇALVES, A. K.; DA SILVEIRA, G. R. P.; DE BARROS, Z. X.; CAMPOS, S. Métodos de Classificação Supervisionada de Imagens De Satélite Aplicadas no Mapeamento do Uso do Solo na Bacia Hidrográfica do Ribeirão Santo Antônio, São Manuel/SP. **GEOSABERES: Revista de Estudos Geoeeducacionais**, v. 6, n. 1, p. 52-62, 2015.
- GONÇALVES, F. D.; SOUZA FILHO, P. W. M. Integração digital de imagens Radarsat-1 e Landsat-7 para o mapeamento dos índices de sensibilidade ambiental a derramamentos de óleo na Baía de Guajará (Belém-PA). **Simpósio Brasileiro de Sensoriamento Remoto**, v. 12, n. 1, p. 2005, 2005.
- HASMADI, M.; PAKHRIAZAD, H. Z.; SHAHRIN, M. F. Evaluating supervised and unsupervised techniques for land cover mapping using remote

SILVEIRA, A.H. M., et. al.
**APLICAÇÕES, PREFERÊNCIAS E COMPARAÇÕES ENTRE MÉTODOS DE CLASSIFICAÇÃO
SUPERVISIONADA: O CASO DE NATAL/RN**

- sensing data. **Geografia-Malaysian Journal of Society and Space**, v. 5, n. 1, 2017.
- JENSEN, J. R. **Remote Sensing of the Environment: An Earth Resource Perspective**. 2nd Edition. Upper Saddle River, N.J.: Pearson Prentice Hall, 2007.
- JUSTINO, R. C.; MARTINES, M. R.; KAWAKUBO, F. S. Classificação do Uso da Terra e Cobertura Vegetal Utilizando Técnicas de Mineração de Dados. **Revista do Departamento de Geografia**, v. 33, p. 36-46, 2017.
- KARANTZALOS, K. Recent advances on 2D and 3D change detection in urban environments from remote sensing data. In: **Computational Approaches for Urban Environments**. Springer, Cham, 2015. p. 237-272.
- KAWAKUBO, F. S.; MORATO, R. G.; LUCHIARI, A. Processamento das imagens HRG-SPOT 5 na determinação de classes de uso da terra e manchas de cobertura vegetal na região de Teodoro Sampaio–pontal do Paranapanema. **Espaço e Tempo**, v. 15, p. 127-136, 2004.
- KOTZ, S.; HORMAN, N. L. **Encyclopedia of statistical sciences**. New York: John Wiley & Sons; 1983. v.4, p.352-4.
- LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**, v.33, p.159-174, 1977.
- LAUDARES, S.; LIBÓRIO, M. P. Análise discriminante em estudos de sistemas integrados: um transecto urbano em Itaúna-MG. In: **Anais do XI Encontro nacional da ANPEGE: a diversidade da geografia brasileira: escalas e dimensões da análise e da ação**, Presidente Prudente/SP, Brasil, 9 a 12 de outubro de 2018, ANPEGE.
- LEITE, M. E.; ALMEIDA SOARES, M. I. S.; VELOSO, G. A.; FERREIRA, M. F. F. Sensoriamento remoto aplicado ao mapeamento da dinâmica do uso do solo na bacia do rio Pacuí, no norte de Minas Gerais, nos anos de 1989, 1999 e 2009. **Revista do Departamento de Geografia**, v. 23, p. 217-231, 2012.
- LONGLEY, P. A.; GOODCHILD, M. F.; MAGUIRE, D. J.; RHIND, D. W. **Geographic information systems and science**. John Wiley & Sons, 2005.
- MELO JUNIOR, D. R.; BELÉM, F. L.; LIMA, E. Q.; ROCHA. mapeamento e análise multitemporal do uso e cobertura da terra da região da cidade de Macapá/AP. **Ciência Geográfica**, V. 21, n. 2, p. 442-455, 2017.
- MENESES, P. R.; ALMEIDA, T. D I. Introdução ao processamento de imagens de sensoriamento remoto. **Brasília: UnB**, p. 01-33, 2012.
- MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. São José dos Campos: Instituto Nacional de Pesquisas Espaciais, 2001. 250 p.
- MOSER, G.; ZERUBIA, J.; SERPICO, S. B.; BENEDIKTSSON, J. A. Mathematical Models and Methods for Remote Sensing Image Analysis: An Introduction. In: **Mathematical Models for Remote Sensing Image Processing**. Springer, Cham, 2018. p. 1-36.
- NISHIDA, W. Classificação de Imagens de Sensoriamento Remoto Utilizando uma Rede Neural Artificial com Função de Base Radial. In: **Anais IX Simpósio Brasileiro de Sensoriamento Remoto**, Santos, Brasil, 11 – 18 setembro de 1998, INPE, p. 991-1001.
- OLIVEIRA, R. A.; CUNHA, D. C.; SIMONETTI, V. C.; STROKA, E. A. B.; SABONARO, D. Z. Proposição de Corredor Ecológico entre duas Unidades de Conservação na Região Metropolitana de Sorocaba. **Revista do Departamento de Geografia**, v. 32, p. 61-71, 2016.
- OLIVEIRA, T. R. OLIVEIRA, V. S.; PONTES, M.; LIBÓRIO, M. P.; HADAD, R. M.; LAUDARES, S. Metodologia para análise de danos ambientais do rompimento da barragem de fundão em Bento Rodrigues (MG). **HOLOS**, v. 7, p. 1-17, 2019.
- PASSO, D. P.; SOUZA BIAS, E.; BRITES, R. S.; COSTA, G. A. Uso do sistema InterIMAGE para a identificação de alvos urbanos em imagens do

SILVEIRA, A.H. M., et. al.
**APLICAÇÕES, PREFERÊNCIAS E COMPARAÇÕES ENTRE MÉTODOS DE CLASSIFICAÇÃO
SUPERVISIONADA: O CASO DE NATAL/RN**

- satélite Worldview II. **Revista Brasileira de Cartografia**, v. 6, n. 65/6, 2013.
- PAULA, M. R.; BENEDETTI, A. C. P.; PEREIRA FILHO, W. Influência do Uso e Cobertura da Terra Aliado à Precipitação Pluviométrica na Qualidade da Água da Bacia Hidrográfica do Rio Ingaí-RS/Brasil. **Revista do Departamento de Geografia**, v. 32, p. 143-152, 2016.
- PERTILLE, C. T.; SILVA, G. O.; SOUZA, C. F.; NICOLETTI, M. F. Estudo da Eficiência de Classificações Supervisionadas Aplicadas em Imagem de Média Resolução Espacial. **BIOFIX Scientific Journal**, v. 3, n. 2, p. 289-296, 2018.
- PFADENHAUER, J. S.; BUTZKE, A. Clima da região carbonífera do estado de Santa Catarina. In: Estudos sobre o impacto ecológico da mineração e do beneficiamento do carvão na região sul do estado de Santa Catarina. **GRAFISA**, 1978. p. 41-54.
- PHIRI, D.; MORGENROTH, J. Developments in Landsat land cover classification methods: A review. **Remote Sensing**, v. 9, n. 9, p. 967, 2017.
- PRADO, D. F. C.; HAYAKAWA, E. H.; KAWAKUBO, F. S. Mapeamento do cultivo de café no sul de Minas Gerais utilizando imagens Landsat-5 TM e variáveis topográficas. **Revista do Departamento de Geografia**, v. 31, p. 43-57, 2016.
- PROFETA, A. L. DINÂMICA MULTITEMPORAL DA COBERTURA DO SOLO NO MUNICÍPIO DE PIRANGA-MG, NO PERÍODO DE 1984 A 2009. **Revista Brasileira de Cartografia**, v. 67, n. 1, 2015.
- REIS, J. B. C.; SAAVEDRA, O. F. C. Comparação de métodos de classificação para reconhecimento de corpos d'água em imagens do sensor OLI do Landsat8. Em anais **XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, João Pessoa-PB, Brasil, 25 a 29 de abril de 2015, INPE p. 59-66
- REIS, M. S.; PANTALEÃO, E.; SIQUEIRA SANT'ANNA, S. J.; DUTRA, L. V. Análise de índice ponderado para avaliação de segmentação. **Revista Brasileira de Cartografia**, v. 67, n. 7, 2015.
- RIBEIRO, L.; SILVEIRA, R. M. P.; NUCCI, J. C. O crescimento populacional como fator de risco à perda florestal no município de pontal do paraná, litoral paranaense, Brasil. **Revista do Departamento de Geografia**, v. 25, p. 120-139, 2013.
- RIBEIRO, L.; SILVEIRA, R. M. P.; NUCCI, J. C. RESERVAS PARTICULARES DO PATRIMÔNIO NATURAL (RPPN'S) COMO SUBSÍDIO AO PLANEJAMENTO DA PAISAGEM NO MUNICÍPIO DE MANDIRITUBA, PR. **Revista do Departamento de Geografia**, v. 26, p. 69-94, 2013.
- RIBEIRO, R. S.; DORTZBACH, D.; FLORES, J. A. A. Classificação Supervisionada em Imagem ALOS para o mapeamento de arroz irrigado no município de Massaranduba SC. In: **IV Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação**. Recife - PE, 06- 09 de Maio de 2012. p. 001 – 007.
- ROMERO, D. J.; BEN-DOR, E.; DEMATTÊ, J. A.; SOUZA, A. B.; VICENTE, L. E.; TAVARES, T. R.; GALLO, B. C. Internal soil standard method for the Brazilian soil spectral library: Performance and proximate analysis. **Geoderma**, v. 312, p. 95-103, 2018.
- ROSA, M. R. Classificação do Padrão de Ocupação Urbana de São Paulo Utilizando Aprendizagem de Máquina e Sentinel 2. **Revista do Departamento de Geografia**, p. 15-21, 2018.
- SAKUNO, N. R. R.; KAWAKUBO, F. S.; SPALEVIC, V.; MINCATO, R. L. Mapeamento de Superfícies Impermeáveis em Áreas Urbanas Utilizando Imagens Índices Geradas Pelo Sistema Landsat-5 Thematic Mapper. **Revista do Departamento de Geografia**, n. spe, p. 190-198, 2017.
- SILVA, M. A. O.; ANDRADE, A. C. Geração de Imagens de Reflectância no Topo da Atmosfera e na Superfície de um Ponto de Vista Geométrico. Anais **XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, Foz do Iguaçu, PR, Brasil, 2013, INPE
- SILVA, O.; DOURADO, F. Comparação dos Resultados da Classificação Supervisionada da

SILVEIRA, A.H. M., et. al.
**APLICAÇÕES, PREFERÊNCIAS E COMPARAÇÕES ENTRE MÉTODOS DE CLASSIFICAÇÃO
SUPERVISIONADA: O CASO DE NATAL/RN**

Cobertura do Solo por Máxima Verossimilhança de Imagens LANDSAT-5 TM e ALOS AVNIR-2. **Geo UERJ**, n. 29, p. 220-233, 2016.

SOUSA JUNIOR, J. G. D. A.; DEMATTÊ, J. A. M.; GENÚ, A. M. Comportamento espectral dos solos na paisagem a partir de dados coletados por sensores terrestre e orbital. **Revista Brasileira de Ciência do Solo**, v. 32, n. 2, p. 727-738, 2008.

SOUSA, M. S. CARACTERIZAÇÃO DOS AREAIS DA BACIA DO RIBEIRÃO SUJO, MUNICÍPIO DE SERRANÓPOLIS/GO. **GEOUSP: Espaço e Tempo (Online)**, n. 26, p. 93-112, 2009.

SPIEGEL, M. R. **Estatística**. McGrawhill, 3ª edição, 1993

STANGANINI, F. N., LOLLO, J. A. O crescimento da área urbana da cidade de São Carlos/SP entre os anos de 2010 e 2015: o avanço da degradação ambiental. **urbe. Revista Brasileira de Gestão Urbana**, v. 10, p. 118-128, 2018.

STONER, E. R.; BAUMGARDNER, M. F. Characteristic variations in reflectance of surface soils. **Soil Science Society of America Journal**, v. 45, n. 6, p. 1161-1165, 1981.

SUGAWARA, L. M.; RUDORFF, B. F. T.; ADAMI, M. Viabilidade de uso de imagens do Landsat em mapeamento de área cultivada com soja no Estado do Paraná. **Pesquisa Agropecuária Brasileira**, v. 43, n. 12, p. 1777-1783, 2009.

TANGERINO, D. F.; LOURENÇO, R. Comparação da exatidão de métodos de classificação supervisionada e não supervisionada a partir do índice kappa na microbacia do Ribeirão Duas Águas em Botucatu/SP. In: **Anais XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, Foz do Iguaçu, PR, Brasil, 13 a 18 de abril de 2013, INPE.

TRINDADE, P. M. P.; SALDANHA, D. L.; PEREIRA FILHO, W. UTILIZAÇÃO DO INFRAVERMELHO TERMAL NA ANÁLISE ESPAÇO TEMPORAL DA TEMPERATURA DE SUPERFÍCIE e ILHAS DE CALOR URBANAS. **Revista Brasileira de Cartografia**, v. 69, n. 4, 2017.

VALE, J. R. B.; DA COSTA, J. A.; DOS SANTOS, J. F.; DA SILVA, E. L. S.; FAVACHO, A. T. Análise Comparativa de Métodos de Classificação Supervisionada Aplicada ao Mapeamento da Cobertura do Solo no Município de Medicilândia, Pará. **InterEspaço: Revista de Geografia e Interdisciplinaridade**, v. 4, n. 13, p. 26-44, 2018.

VAN VLIET, J.; BREGT, A. K.; HAGEN-ZANKER, A. Revisiting Kappa to account for change in the accuracy assessment of land-use change models. **Ecological Modelling**, v. 222, n. 8, p. 1367-1375, 2011.