

AVALIAÇÃO DA EFICIÊNCIA DOS CLASSIFICADORES DE IMAGEM DE SENSORIAMENTO REMOTO COM VARIAÇÃO NA RESOLUÇÃO ESPACIAL

EVALUATION OF EFFICIENCY FOR REMOTE SENSING IMAGE CLASSIFIERS WITH VARIATION IN THE SPATIAL RESOLUTION

EVALUACIÓN DE LA EFICIENCIA DE CLASIFICADORES DE IMÁGNES DE DETECCIÓN REMOTA COM VARIACIÓN DE RESOLUCIÓN ESPACIAL

Warlen Librelon de Oliveira

Mestre em Engenharia Mecânica pela Universidade Federal de Minas Gerais – UFMG. Graduado em Engenharia Ambiental pelo Centro Universitário Newton Paiva.
pesquisa@librelon.com.br / <http://orcid.org/0000-0002-3815-0173>

Bárbara Roberta Morais

Mestra em Análise e Modelagem de Sistemas Ambientais – UFMG. Graduada em Agronomia pelo Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais – IFMG/Campus Bambuí.
barbararobertamorais@gmail.com / <http://orcid.org/0000-0001-9797-4116>

Marcelo Antônio Nero

Pós-Doutor pela Escola Politécnica da Universidade de São Paulo – USP. Doutor em Engenharia de Transportes pela Universidade de São Paulo – USP. Mestre em Engenharia de Transporte pela Universidade de São Paulo – USP. Graduado em Cartografia pela Universidade Estadual Paulista Júlio de Mesquita Filho – UNESP. Professor do Departamento de Cartografia do Instituto de Geociências – UFMG.

marcelo-nero@ufmg.br / <http://orcid.org/0000-0003-2124-5018>

Recebido: 30/03/2021; Aceito: 31/08/2021; Publicado: 28/10/2022.

RESUMO

Compreender as características das feições terrestres no intuito de conduzir tomadas de decisão que causem o menor impacto negativo no ambiente é uma etapa inicial e fundamental. Esta pesquisa teve como objetivo avaliar o desempenho de cinco algoritmos de classificação de imagens para o mapeamento das classes de uso e cobertura da terra de duas regiões com características distintas de Belo Horizonte – MG. Para o processo de classificação foram utilizadas 2 imagens provenientes de ortofotos com resolução espacial original de 0,20 m e com base nestas, foram geradas 12 novas imagens através do processo de amostragem de pixels. Para testar a significância estatística das classificações, foram utilizados a Acurácia Global, Índice Kappa e o Coeficiente de Correlação de Pearson (r). Os resultados obtidos apontaram para a necessidade de se abordar a interpretação de vários autores, bem como de outros índices de qualidade temática, além da necessidade de no futuro criar-se uma metodologia que pondere qualidade posicional e a temática em conjunto na avaliação final dos mapas.

Palavras-chave: Índice Kappa; Classificação de Imagens; Qualidade Temática; Comparativo de Índices.

ABSTRACT

Understanding the characteristics of terrestrial features in order to conduct decision-making that causes the least negative impact on the environment is an initial and fundamental step. This research aimed to evaluate the performance of five image classification algorithms for the mapping of land use and land cover classes in two regions with different characteristics from Belo Horizonte - MG. For the classification process, 2 images from orthophoto images with an original spatial resolution of 0.20 m were used, and based on these, 12 new images were generated through the pixel resampling process. To test the statistical significance of the classifications, the Global Accuracy, Kappa Index, and Pearson's Correlation Coefficient (r) were used. The results obtained pointed to the need to approach the interpretation of several authors, as well as other thematic quality indexes, in addition to the need to create a methodology in the future that considers the positional quality and the theme together in the final evaluation of the maps.

Keywords: Kappa Index; Image Classification; Thematic Quality; Comparison of Indices.

RESUMEN

Comprender las características de los accidentes terrestres para poder llevar a cabo la toma de decisiones que provoquen el menor impacto negativo en el medio ambiente es un paso inicial y fundamental. Esta investigación tuvo como objetivo evaluar el desempeño de cinco algoritmos de clasificación de imágenes para el mapeo de clases de uso y cobertura del suelo en dos regiones con características diferentes a Belo Horizonte - MG. Para el proceso de clasificación se utilizaron 2 imágenes de ortofotografías con una resolución espacial original de 0,20 my en base a estas se generaron 12 nuevas imágenes mediante el proceso de remuestreo de píxeles. Para probar la significancia estadística de las clasificaciones, se utilizaron la Precisión Global, el Índice Kappa y el Coeficiente de Correlación de Pearson (r). Los resultados obtenidos apuntaron a la necesidad de abordar la interpretación de varios autores, así como otros índices de calidad temáticos, además de la necesidad de crear una metodología en el futuro que considere la calidad posicional y la temática en conjunto en la evaluación final de los mapas.

Palabras clave: Índice Kappa; Clasificación de Imágenes; Calidad Temática; Comparativo entre índices.

INTRODUÇÃO

Diante da crescente necessidade de compreender a dinâmica do uso do solo para que tomadas de decisões sejam o mais assertivas possível, o uso de imagens de satélite tem propiciado inúmeras aplicações nas diversas áreas do conhecimento. Assim, vale ressaltar trabalhos apresentados e que possuem relação com essa temática, tais como Silva e Nucci (2016) e Castillo, Leal e Almendra (2020), em que nestes trabalhos fica claro que o surgimento de recursos computacionais (classificadores de imagens), que conduzem os processos para interpretar a superfície terrestre, também tem evoluído de forma importante. Porém, as características de uma imagem são extremamente diferentes, o que pode influenciar a eficiência de cada algoritmo de classificação. Sendo assim, qual seria o melhor classificador para ser usado com uma determinada imagem? É possível que não exista uma resposta para tal pergunta. Mas se for possível identificar o comportamento dos algoritmos em função de algumas características da imagem, seria possível facilitar a escolha que melhor atenderia o objetivo. Com isso, o objetivo desse trabalho foi avaliar o

desempenho de cinco algoritmos de classificação de imagem com treze resoluções espaciais diferentes (sendo estas degradadas) para duas imagens com características distintas em relação às suas feições.

REFERENCIAL TEÓRICO E ANALÍTICO

A classificação de imagens pode ser entendida como uma atividade que visa agrupar pixels, mediante as suas características, em classes pré-definidas ou não pelo usuário. No contexto do processamento digital de imagens, os métodos de classificação, assim chamados genericamente, são atribuídos com o intuito de reconhecer as classes ou categorias em pixels na imagem (JENSEN, 2009). O mapeamento do uso e cobertura da terra, através da classificação de imagens, consiste em uma das aplicações do sensoriamento remoto mais importantes da atualidade (NASCIMENTO et al., 2013). A resultante das interações entre a energia eletromagnética refletida e a emitida pelos objetos terrestres determinam a qualidade da resposta nas imagens. Entre as propriedades físicas dos objetos obtidos pela reflectância, está o albedo. Este é um tipo de dado que pode ser usado para avaliar a variação da imagem no tempo sem a necessidade da classificação. No entanto, apresentará apenas indícios de mudança nas reflectâncias das imagens como apresentado por Melo e Souza (2016). Tais autores avaliaram as mudanças de temperaturas a partir dos dados de albedo em períodos distintos para a cidade de Guaranhuns no estado de Pernambuco – Brasil.

Como forma de avaliar a distribuição e variabilidade espacial de uma determinada variável, a geoestatística tem um papel fundamental, a qual se dispõe de diversos métodos, tal como a krigagem. Conforme Landim (2006) e Yamamoto e Landim (2013), corresponde este a um método de estimativa que avalia os valores das variáveis ordenadas no espaço e/ou tempo com base nos valores adjacentes. Além disso, a krigagem tem a característica de interpolar valores por blocos ou de forma pontual, o que é de grande importância para os estudos que necessitem de mensuração de dados para o desenvolvimento de produtos cartográficos (MELO, 2016)

Segundo Venturieri e Santos (1998), são várias as metodologias de classificação digital de imagens aplicadas para a realização de levantamentos, análises e monitoramentos das paisagens. Todas as técnicas de classificação buscam extrair a maior quantidade possível de informações temáticas das imagens, em um tempo de processamento computacional mínimo. Ainda de acordo com os autores, o usuário antes de começar todo e qualquer tipo de tratamento digital, deve antes analisar os objetivos do trabalho e estabelecer qual tipo de

produto é o mais apropriado, relacionando-o prioritariamente com o nível de estratificação temática e com o tipo de algoritmo de classificação.

Segundo Melo e Souza (2016), os mapas temáticos, resultado da modelagem matemática e das tecnologias do Sensoriamento Remoto e Sistemas de Informações Geográficas, são importantes instrumentos de subsídio à tomada de decisão e gestão da paisagem local. Ainda de acordo com os autores, uma questão crucial está relacionada à percepção do pesquisador no momento da coleta de informações e confecção da base de dados, uma vez que estes fatores são requisitos para a representação da realidade e qualidade do mapeamento temático.

O processo de classificação faz uso de modelos matemáticos que são conhecidos como algoritmos. Estes métodos são ordenados em função da presença ou ausência de uma fase de treinamento. No processo de treinamento, o usuário fornece informações acerca dos pixels que são representativos para cada classe (BARBOSA VALE et al., 2018). Portanto, havendo a etapa de treinamento no processamento de classificação da imagem, pode-se concluir que o procedimento consiste em uma abordagem de classificação supervisionada.

A classificação supervisionada consiste em um método para identificar áreas espectralmente semelhantes em uma imagem através de um processo de treinamento. Em tal abordagem, o usuário precisa de um conhecimento prévio do local de estudo (CASTILLEJO-GONZÁLEZ et al., 2009).

Todo o processo de classificação de imagens e confecção de mapas temáticos deve passar por avaliações a posteriori, com o intuito de verificar a acurácia dos mesmos. As matrizes de erro e os índices estatísticos derivados são utilizados para estimar e validar a acurácia dos produtos gerados (MASTELLA; VIEIRA, 2018).

De acordo com Li et al. (2014) e ainda na atualidade, apesar de uma gama de novos algoritmos de classificação de imagens terem sido desenvolvidos nos últimos anos, é escasso na literatura testes e comparações sistemáticas destes algoritmos com a mesma tarefa de classificação. Os autores ainda relatam que a comparação do desempenho dos classificadores encontra-se limitada à análise de um novo algoritmo com um classificador convencional, sendo este muitas das vezes o classificador de máxima verossimilhança.

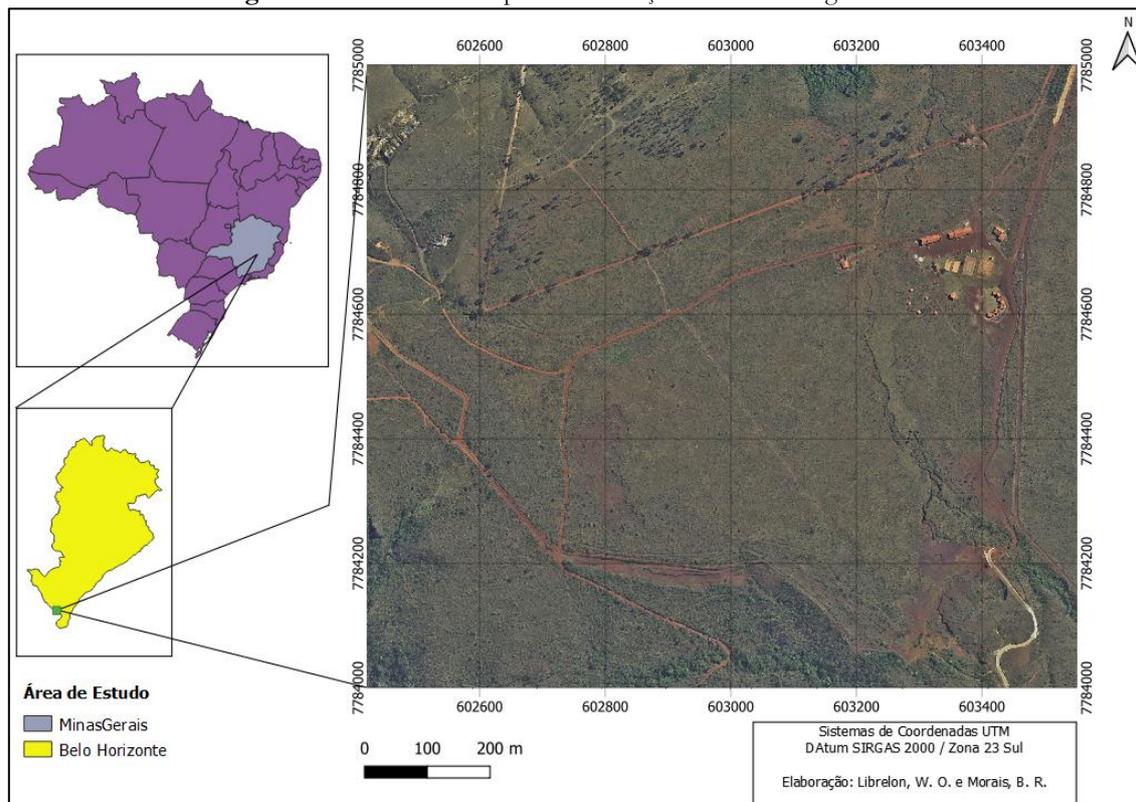
Como observado por Vale et al. (2018), os classificadores possuem, de uma forma geral, bons resultados quando a área de estudo é caracterizada como ambiente rural. Os três classificadores aplicados pelo autor tiveram valores para o índice Kappa acima de 0,84 e exatidão global acima de 90%.

Para as áreas urbanas, Anjos et al. (2017) relatam os desafios do sensoriamento remoto para trabalhar com o processo de classificação de imagens e a importância da resolução espacial na identificação e mapeamento de alvos urbanos. No entanto, os classificadores conseguiram alcançar bons resultados no estudo do presente artigo. Sendo que, todas as classificações apresentaram exatidão global e Kappa superiores a 70%.

MATERIAIS E MÉTODOS

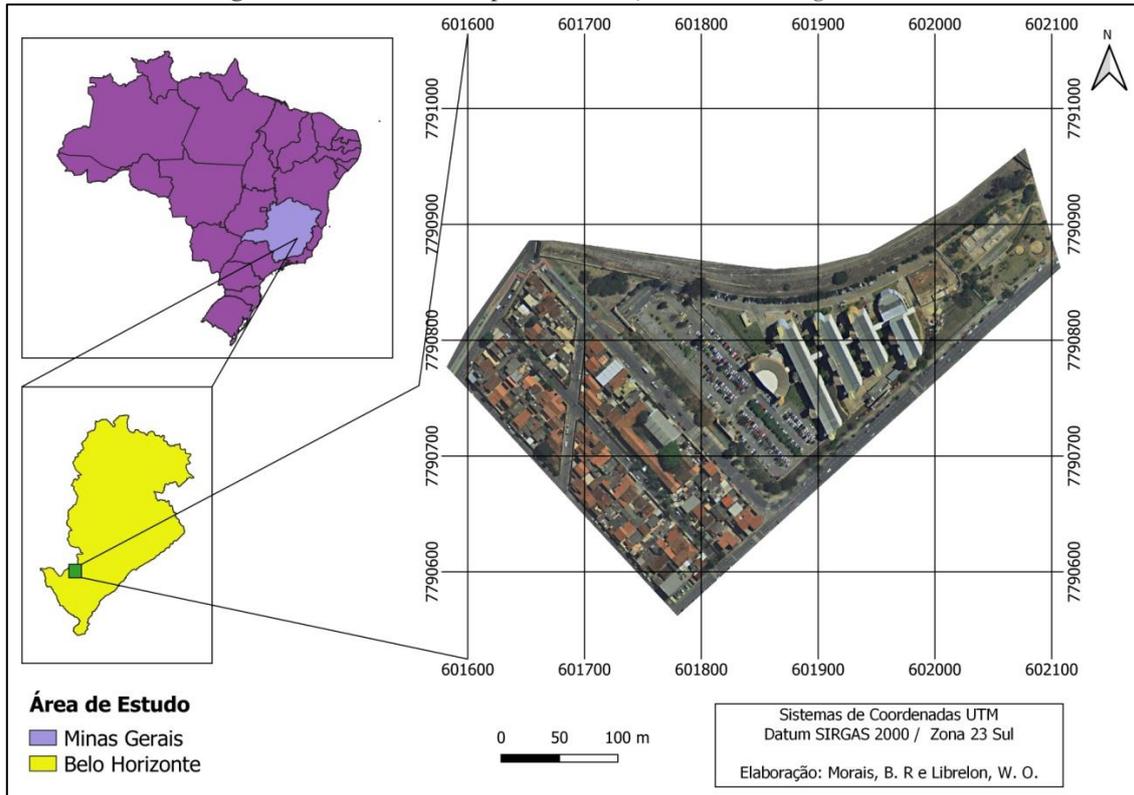
Os experimentos aqui empregados foram realizados sobre duas imagens provenientes de ortofotos com resolução espacial original de 0,20 m. A primeira imagem, com característica rural, foi recortada da Região do Parque Estadual Rola Moça (Figura 1). Já a segunda imagem, com característica urbana, corresponde a um recorte da Região do Bairro Barreiro (Figura 2), ambas dentro dos limites do município de Belo Horizonte – MG.

Figura 1 – Área de estudo para classificação referente à região rural.



Fonte: Autores (2021).

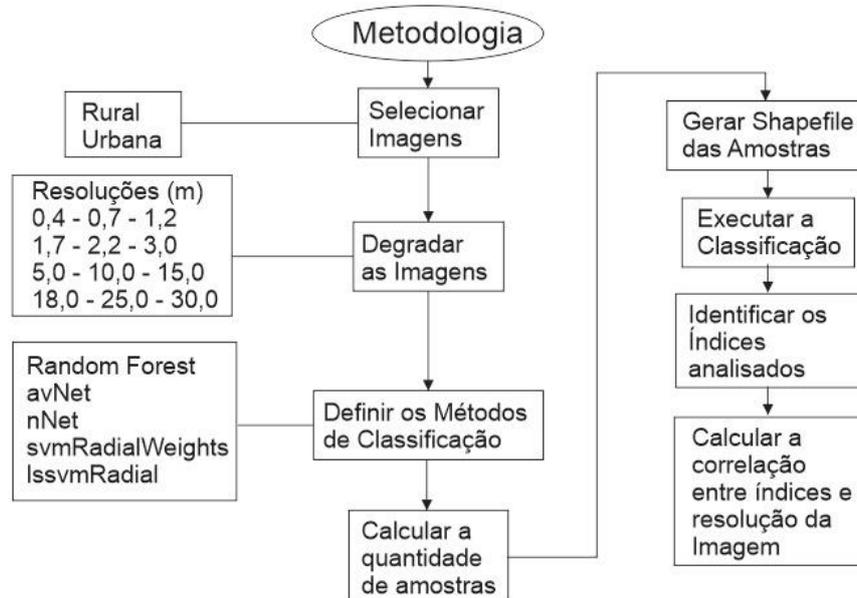
Figura 2 – Área de estudo para classificação referente à região urbana.



Fonte: Autores (2021).

Na figura 3 é apresentado o fluxograma geral da metodologia que foi aplicada.

Figura 3 – Fluxograma da metodologia aplicada.



Fonte: Autores (2021).

Com base nas duas imagens, foram geradas 12 novas imagens para cada região através da degradação das respectivas resoluções espaciais para os seguintes valores: 0,4 m, 0,7 m, 1,2 m, 1,7 m, 2,2 m, 3,0 m, 5,0 m, 10,0 m, 15,0 m, 18,0 m, 25,0 m e 30,0 m através

do programa QGis (programa de sistema de informação geográfica e livre de código aberto) (“QGIS Geographic Information System”, 2015). Com o mesmo programa, foi criado um arquivo no formato shapefile contendo os polígonos representativos da imagem referentes à classe vegetação arbórea, vegetação rasteira e solo exposto para o estudo da área rural e um arquivo no formato shapefile contendo os polígonos referente à classe vegetação arbórea, vegetação rasteira, telhado colonial, telhado de zinco/laje e rua asfaltada para a classe urbana.

A determinação do tamanho da amostra das classes (n), vide equação 1, foi realizada através da equação proposta por Cochran (1977), a qual também vem sendo utilizada recentemente por diversos autores, tais como por Olofsson et al. (2013).

$$n = \frac{(\sum W_i S_i)^2}{[s(\hat{O})]^2 + \left(\frac{1}{n}\right) \sum W_i S_i^2} \approx \left(\frac{\sum W_i S_i}{s(\hat{O})}\right)^2 \quad (1)$$

onde, N é número de unidades na área de interesse (número de pixels total se a unidade espacial for um pixel); $S(\hat{O})$ é o erro padrão da precisão geral estimada que o usuário pretende alcançar; W_i é a proporção mapeada da área da classe i ; S_i é o desvio padrão do estrato i . Sendo S_i obtido pela equação 2.

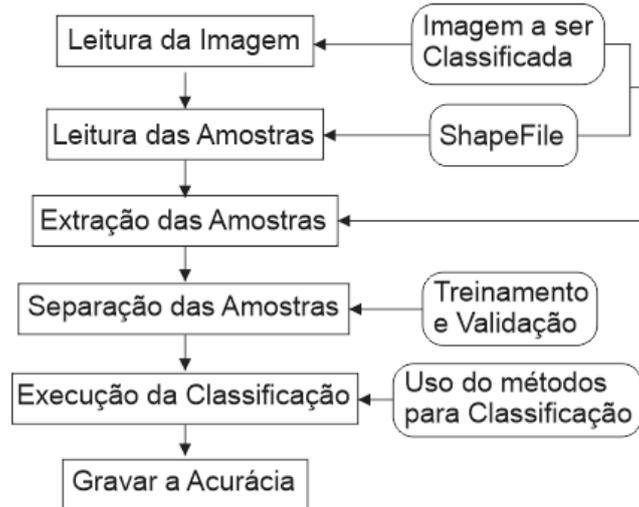
$$S_i = \sqrt{U_i(1 - U_i)} \quad (2)$$

em que, U_i consiste na acurácia do usuário.

A classificação foi desenvolvida através de um script de programação por meio do software R, com o uso das bibliotecas de funções específicas para a execução da classificação. Para atender aos objetivos da pesquisa, selecionaram-se cinco métodos de classificação a ser aplicado com o script de programação. O método *lssvmradial* (*Least Squares Support Vector Machine with Radial Basis Function Kernel*), o qual representa uma variante do tradicional método de Support Vector Machine com o uso dos mínimos quadrados e uma função de ajuste de base radial. O método *nnet* (*Neural Network*), que utiliza o algoritmo de redes neurais artificiais como base no processo de treinamento e validação. O método *avNet* utiliza a mesma base do algoritmo de rede neural artificial, porém com o uso da média dos valores. O método *svmRadialWeights*, que usa a base do Support Vector Machine e atribui pesos nas classes. E por fim o método Random Forest, que é tradicional no processamento de classificação.

A figura 4 apresenta a estrutura do script de programação em R para a execução do procedimento de classificação.

Figura 4 – Estrutura da programação em R



Fonte: Autores (2021).

Aplicação do coeficiente de concordância Kappa e do coeficiente de correlação de Pearson (r) para validação dos resultados e interpretação de acordo com Fleiss, Cohen e Everitt (1969), Landis e Koch (1977) e Monserud e Leemans (1992), demonstrado por Foody (2020) (Quadro 1).

Quadro 1 – Classificação para interpretação do índice Kappa

	Landis and Kock	Fleiss et al.	Monserud and Leemans
1.0	Quase perfeito	Excelente	Perfeito Excelente
0.8	Substancial		Muito Bom
0.6	Moderado	Suficiente para bom	Bom
0.4	Suficiente		Suficiente
0.2	Leve	Pobre	Pobre
0.0	Pobre		Muito Pobre
			Nenhuma

Fonte: Adaptado (FOODY, 2020).

Para avaliar a correlação entre conjunto de dados, foi aplicado o índice de Pearson, que pontua valores entre -1 e +1 que representa o grau de relação linear entre duas variáveis quantitativas. Ainda segundo o autor, os valores positivos representam a relação proporcional entre as duas variáveis, e os negativos, a relação inversamente proporcional. Sendo, quanto mais próximo de zero, menor é a correlação entre os dados (FIGUEIREDO FILHO; SILVA JÚNIOR, 2009). Para interpretar os resultados do coeficiente de Pearson, utilizou-se a escala proposta por Cochran (1977); Dancey e Reidy (2018), de acordo com a tabela 1.

Tabela 1 – Classificação para coeficiente de Pearson

Classificação Cochran / Dancey e Reidy	Cochran	Dancey e Reidy
Pequeno / Fraco	$0,10 < r \leq 0,29$	$0,10 < r \leq 0,30$
Médio / Moderado	$0,30 < r \leq 0,50$	$0,40 < r \leq 0,70$
Grande / Forte	$0,50 < r \leq 1,00$	$0,70 < r \leq 1,00$

Fonte: (COCHRAN, 1977; DANCEY e REIDY, 2018).

RESULTADOS E DISCUSSÕES

As amostras usadas para o processo de classificação foram criadas em função das classes definidas e distribuídas como apresentado nos quadros 2 e 3.

Quadro 2 – Definição da quantidade de amostras para cada classe da imagem rural

	Vegetação Arbórea	Vegetação Rasteira	Solo Exposto	Total	Nº Classes
Área em m ²	148.000	974.100	78.000	1.200.100	3
Wi (Proporção)	0,12	0,81	0,06		
Ui (Acurácia Usuário)	0,90	0,90	0,90		
Si (Desvio padrão da Ui)	0,30	0,30	0,30		
Wi*Si	0,04	0,24	0,02	0,29	
SE (Precisão geral)				0,001	
Número total de amostras				84.100	
Proporcional	10.372	68.262	5.466	84.100	

Quadro 3 – Definição da quantidade de amostras para cada classe da imagem urbana.

	Vegetação Arbórea	Vegetação Rasteira	Telhado Colonial	Telhado Zinco/laje	Rua Asfaltada	Total	Nº Classes
Área em m ²	20.239,08	12.283,44	10.445,80	23.015,24	31.271,36	97.254,920	5
Wi (Proporção)	0,21	0,13	0,11	0,24	0,32		
Ui (Acurácia)	0,90	0,90	0,90	0,90	0,90		

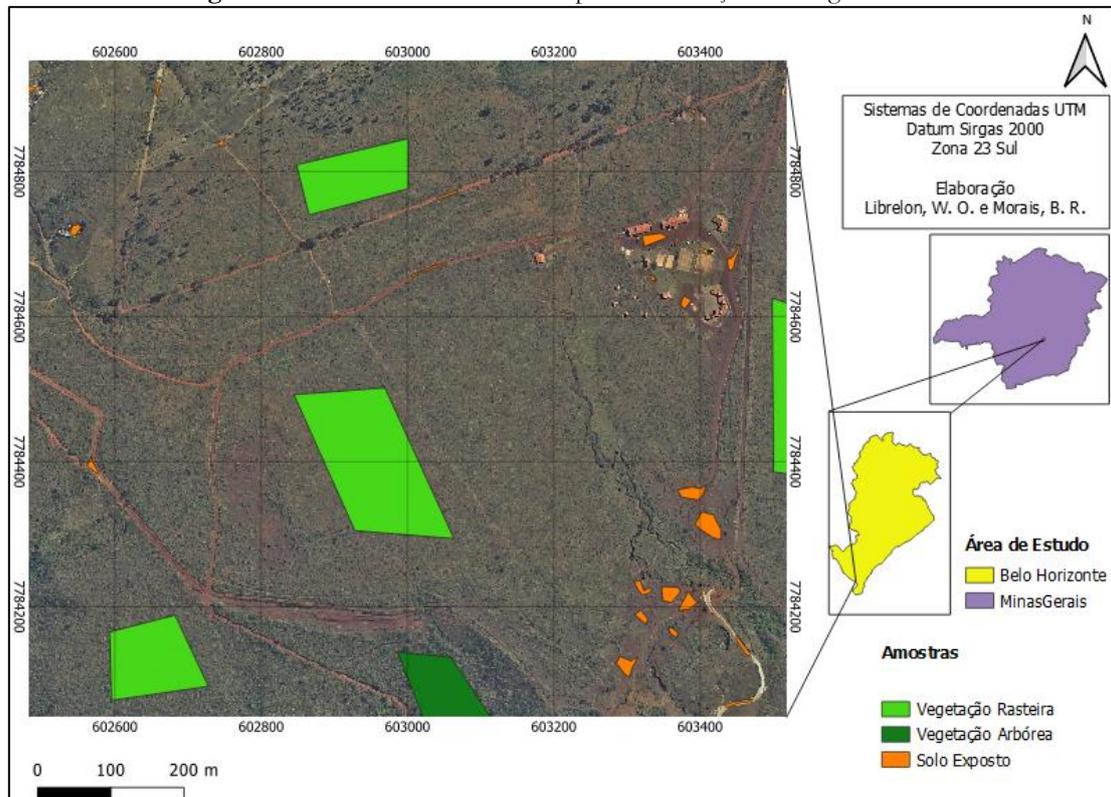
Usuário)							
Si (Desvio padrão da U _i)	0,30	0,30	0,30	0,30	0,30		
W _i *Si	0,06	0,04	0,03	0,07	0,10	0,29	
	SE (Precisão geral)					0,01	
	Número total de amostras					841,00	
Proporcional	175,01	106,22	90,33	199,02	270,42	841,00	

Fonte: Autores (2021).

As quantidades de amostras coletadas para todas as classes foram baseadas nos quadros 2 e 3 que foram gerados a partir das equações 1 e 2. Como resultados, foram obtidos os seguintes valores de amostras para as classes: 270,76 m² de vegetação arbórea, 267,80 m² de vegetação rasteira, 128,56 m² de telhado colonial, 304,48 m² de telhado zinco/laje, 452,12 m² de rua asfaltada, totalizando 1.423,72 m². Para a área rural, foram obtidos os valores das amostras para as classes vegetação arbórea, vegetação rasteira e solo exposto, de 16.101 m², 61.834 m² e 2.306 m² respectivamente, totalizando 80.241 m².

As figuras 4 e 6 representam as imagens com os polígonos de amostragem para a classificação da região rural e urbana respectivamente.

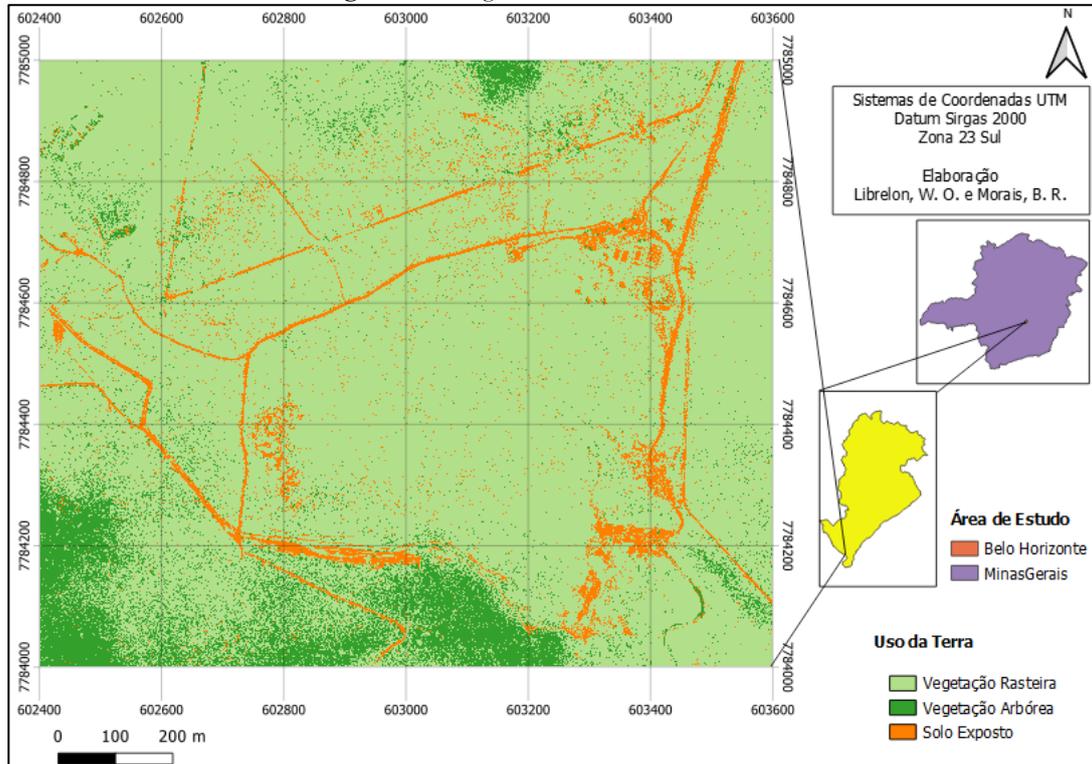
Figura 4 – Amostras de treinamento para classificação da imagem rural.



Fonte: Autores (2021).

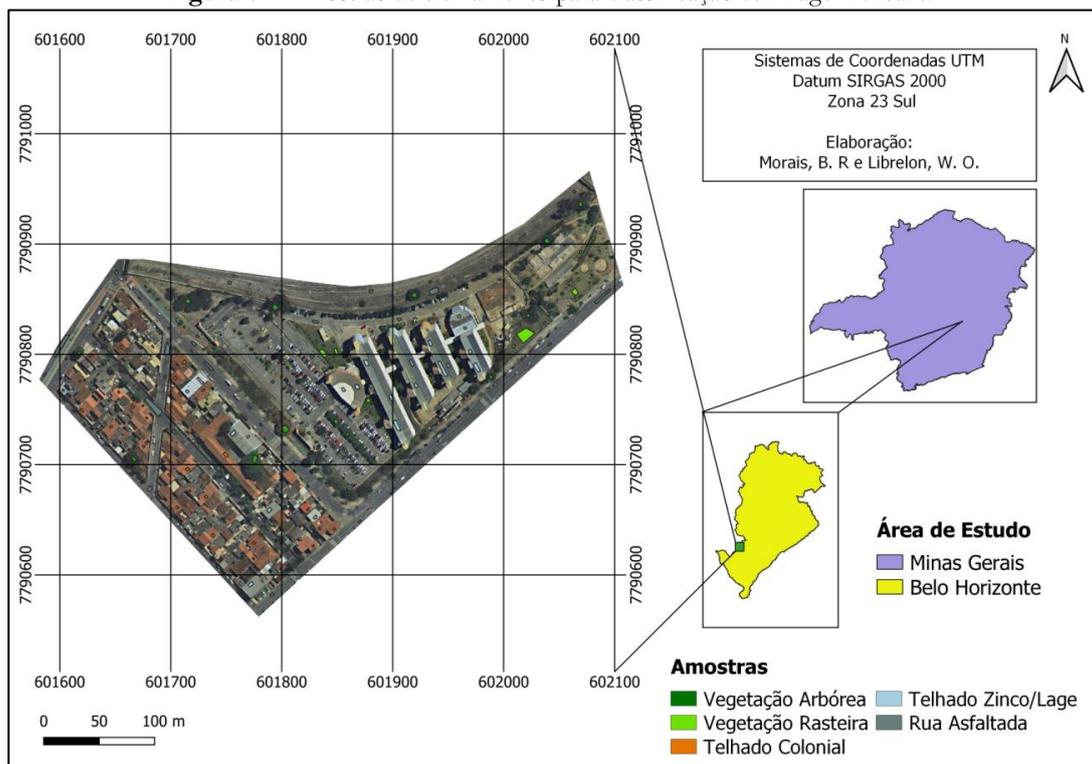
Após a execução da classificação, foi escolhida apenas uma imagem classificada de cada área para representar o resultado do modelo com base na imagem com 0,2m de resolução. As figuras 5 e 7 representam a área rural e urbana respectivamente.

Figura 5 – Imagem classificada da área rural.



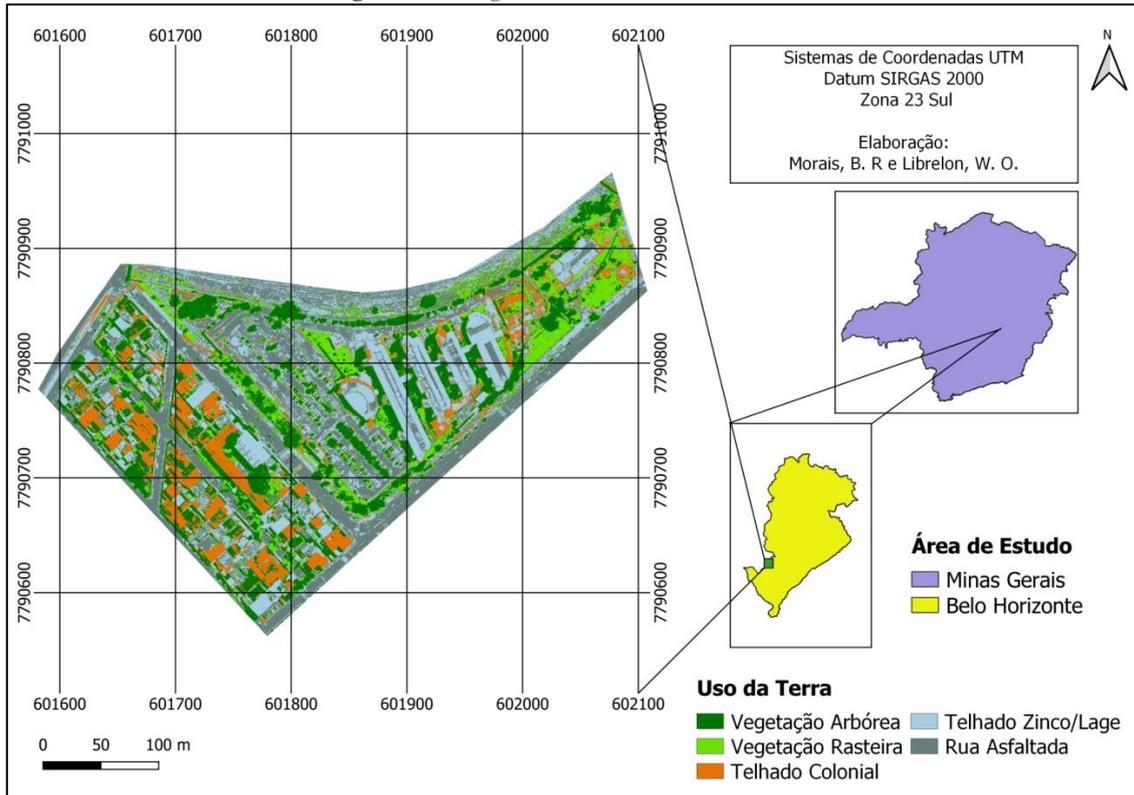
Fonte: Autores (2021).

Figura 6 – Amostras de treinamento para classificação da imagem urbana.



Fonte: Autores (2021).

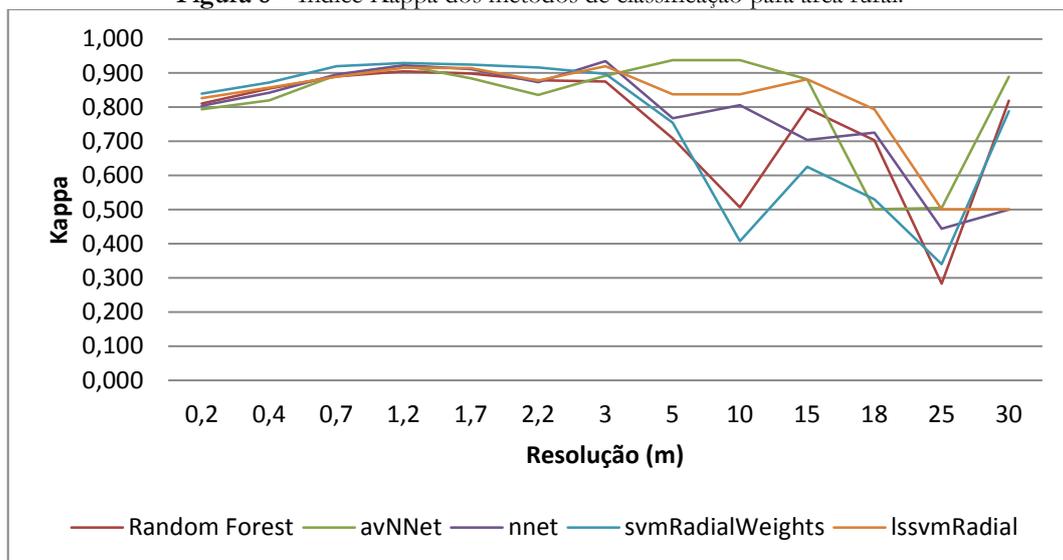
Figura 7 – Imagem classificada da área urbana.



Fonte: Autores (2021).

Com a execução do script de programação para classificação das imagens, foram obtidos os resultados do índice Kappa em função da resolução espacial. A figura 8 apresenta o gráfico identificando o índice Kappa e a figura 9 representa a acurácia global dos modelos para a área rural.

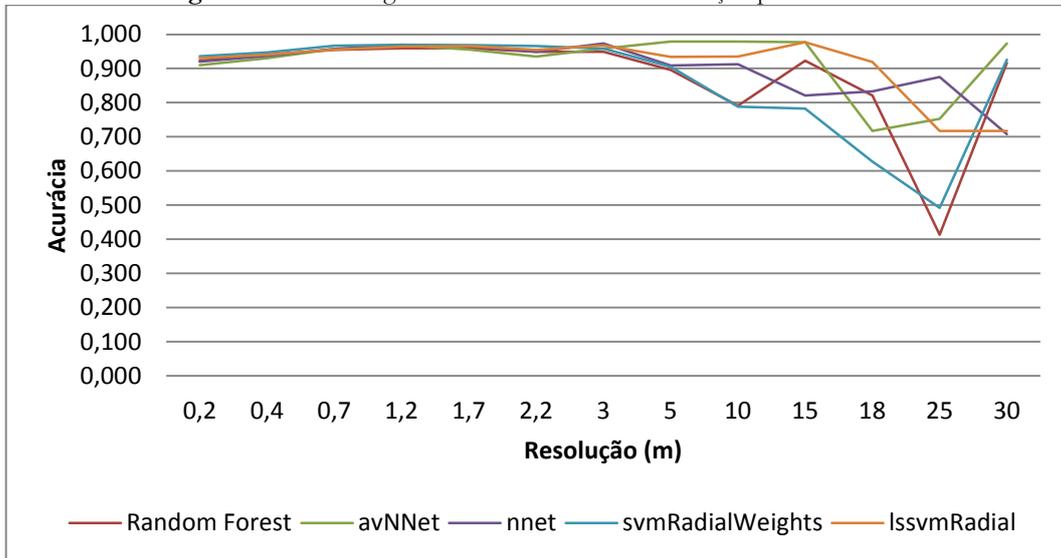
Figura 8 – Índice Kappa dos métodos de classificação para área rural.



Fonte: Autores (2021).

Com os índices Kappa apresentados no gráfico da figura 8, observa-se um melhor ajuste do modelo de classificação para todos os métodos até a resolução de 3 m. A partir de 5 m os métodos não se comportaram de forma segura o suficiente para inferir seu desempenho.

Figura 9 – Acurácia global dos métodos de classificação para área rural.



Fonte: Autores (2021).

Quando se avalia a acurácia dos métodos, observa-se uma coerência entre o índice Kappa e o índice global, o que faz sentido e era esperado, pois os melhores valores estão presentes ao considerar a resolução de 3 m.

Para observar a correlação entre as resoluções espaciais e os valores dos índices Kappa, foi calculado o coeficiente de Pearson e obtidos os valores descritos na tabela 2.

Tabela 2 – Valores de correlação de Pearson entre índice Kappa e resolução espacial da imagem para área rural.

Métodos	Todas as Resoluções	Entre 0,2 e 3m	Entre 5 e 30m
avNNet	-0,476	0,433	-0,432
lssvmRadial	-0,865	0,699	-0,867
Nnet	-0,920	0,709	-0,887
svmRadialWeights	-0,663	0,482	-0,291
Random Forest	-0,570	0,458	-0,070

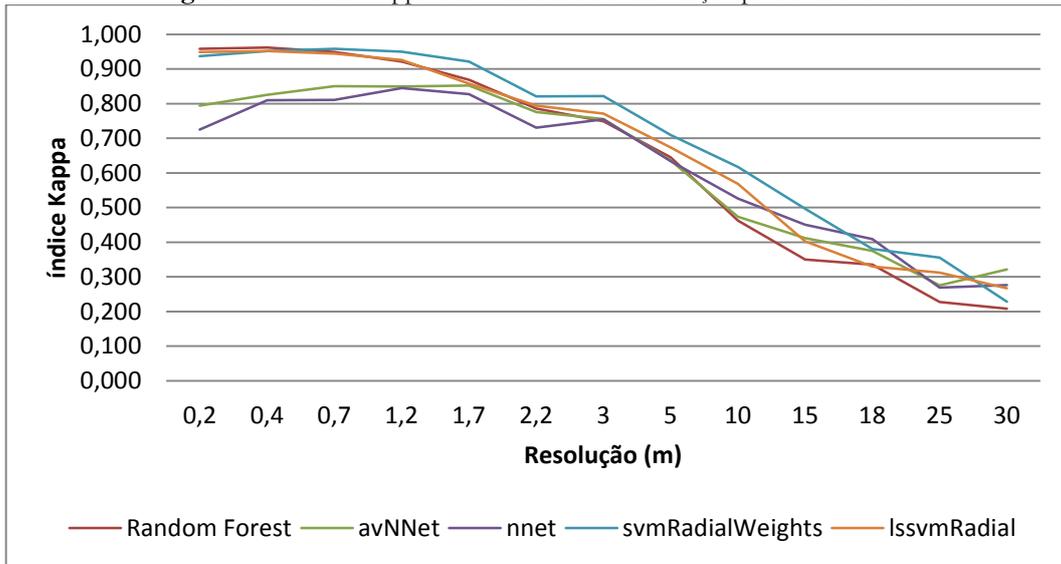
Fonte: Autores (2021).

Considerando-se as correlações entre os índices Kappa e as resoluções espaciais das imagens, tem-se que apenas os métodos correspondentes ao lssvmRadial e ao Nnet se destacaram como de melhores correlações ao atingirem valores próximos de 0,70. A alta

correlação se mantém quando observado as faixas de resolução que tiveram o melhor desempenho do Kappa. Porém, mesmos valores do Kappa com valores mais baixos para a faixa de resolução acima de 5 m, as melhores correlações se mantiveram nesses métodos (lssvmRadial e Nnet).

Para a área urbana, o coeficiente de Kappa e a acurácia global encontram-se representados pelas figuras 10 e 11 respectivamente.

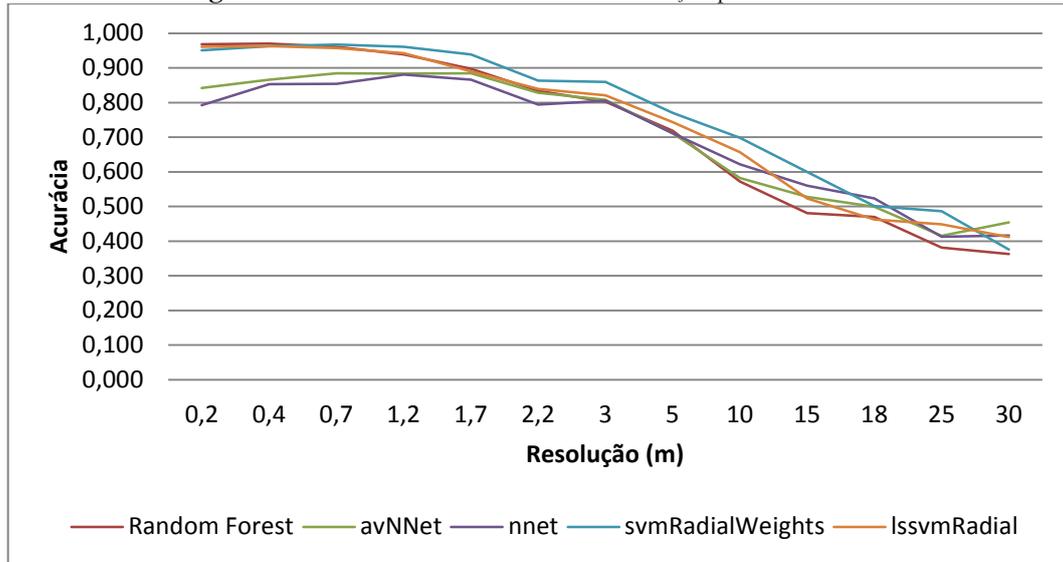
Figura 10 – Índice Kappa dos métodos de classificação para área urbana.



Fonte: Autores (2021).

Observa-se pela figura 10 os valores do índice Kappa que até a resolução espacial de 1,7 m houve um melhor ajuste do modelo de classificação para todos os métodos analisados. A partir da resolução espacial de 2,2 m, os métodos não se comportaram de forma segura o suficiente para inferir seu desempenho. Para a resolução espacial inicial nota-se que os métodos Random Forest, lssvmRadial e svmRadialWeights apresentaram uma excelente concordância no processo de classificação. Já os algoritmos avNNet e nnet alcançaram uma concordância muito boa para a resolução espacial inicial e, posteriormente, de 0,4 m até 1,7 m, atingindo-se uma concordância excelente, baseando-se nas interpretações de Landis e Koch (1977).

Figura 11 – Acurácia dos métodos de classificação para área urbana.



Fonte: Autores (2021).

O resultado para a acurácia global dos métodos é coerente com os valores obtidos para o índice Kappa, seguindo o mesmo padrão observado para a área rural. Os melhores valores para a área urbana foram alcançados até a resolução de 1,7 m.

O índice de Pearson também foi realizado para avaliar a correlação entre as resoluções espaciais e os valores do coeficiente de Kappa, como apresentados na tabela 3.

Tabela 3 – Valores de correlação Pearson entre índice Kappa e resolução da imagem para área urbana.

Métodos	Todas as Resoluções	Entre 0,2 e 1,7 m	Entre 2,2 e 30 m
avNNNet	-0,945	0,790	-0,926
lssvmRadial	-0,952	-0,910	-0,954
Nnet	-0,967	0,724	-0,974
svmRadialWeights	-0,975	-0,510	-0,981
Random Forest	-0,948	-0,960	-0,955

Fonte: Autores (2021).

Para as classificações da imagem urbana, nota-se que para todas as resoluções espaciais todos os algoritmos apresentaram valores próximos a -1, indicando forte correlação negativa entre a resolução espacial e o índice Kappa. Portanto, pode-se observar que as resoluções espaciais e o índice Kappa possuem uma correlação inversamente proporcional. Isto é, ao piorar a resolução espacial o coeficiente de concordância Kappa tende a diminuir, aumentando-se o risco da má avaliação da qualidade temática do mapa gerado. Para a segunda análise, observa-se que os métodos Random Forest e lssvmRadial apresentaram correlação também dita forte negativa. No entanto, os algoritmos avNNNet e

Nnet foram caracterizados com uma correlação moderada positiva com direção diretamente proporcional. Assim, neste caso, ao diminuir a resolução espacial aumenta-se o valor do índice Kappa, melhorando, conseqüentemente, a qualidade do mapa temático gerado. Por fim, a última análise demonstra, assim como na primeira, uma correlação espacial forte negativa para todos os métodos.

CONCLUSÃO

Entender a eficiência dos classificadores com base nas características das imagens e para melhor aplicá-los, é de fundamental importância. Dessa forma, o padrão de feições observadas e a resolução espacial, ambos abordados nessa pesquisa, são características que podem ser analisadas para a melhor escolha do método de classificação. Assim, essa pesquisa avaliou vários métodos de classificação em duas áreas de feições diferentes com diversas resoluções e concluiu que o desempenho dos algoritmos para ambas áreas tiveram um comportamento similar, onde os melhores resultados foram obtidos na faixa de resolução entre 0,2m e 1,7m. Porém, quando observado o conjunto completo das resoluções, os resultados da área urbana apresentaram um comportamento mais equilibrado, sem variações abruptas nos valores dos índices, diferentemente da área rural, onde a partir da resolução 2,2m, os índices apresentaram variações importantes, e que pode ser comprovado no coeficiente de correlação apresentado na tabela 2.

Em relação aos métodos, foi identificado comportamento diferente entre as áreas, onde o algoritmo nNet que tem sua base em algoritmos de Redes Neurais Artificiais obteve um dos melhores desempenhos para área rural e os algoritmos *lsvmRadial* e *Random Forest* para a área urbana. Ambos para faixa de 0,2 a 1,7 m de resolução espacial, sendo considerados excelentes na classificação proposta por Landis e Koch (1977).

Avaliado os índices de uma forma mais ampla, concluiu-se que a área urbana foi bastante sensível à resolução, onde o aumento da resolução foi diretamente proporcional ao aumento da eficiência do índice para todos os algoritmos. Enquanto para a área rural esse benefício ficou limitado na faixa de 0,2m a 1,7m de resolução espacial.

Observou-se no presente trabalho a inferência, ainda que indireta, da precisão posicional, a qual é traduzida aqui no tamanho do pixel, ou seja, na resolução espacial e, que influencia nos resultados da classificação de imagens, bem como na precisão temática desta.

Outro aspecto importante a ser considerado é que não existem ainda na literatura cotidiana inferências e a aplicação em conjunto das acurácias posicional e temática, o que

poderia considerar, por exemplo, amostras em bordas de classificações com critérios específicos e em função dos parâmetros de erro padrão posicional seria uma sugestão inicial.

Finalmente, esperou-se a partir dos testes aqui realizados gerar provocações nessa linha de pesquisa e considerar no futuro próximo testes que levem em conta as outras resoluções, a saber, tais como a temporal, espectral e radiométrica.

AGRADECIMENTOS

Os autores agradecem à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - CAPES e a Fundação de Amparo à Pesquisa de Minas Gerais - FAPEMIG, pelo apoio financeiro através da concessão de bolsas de estudos aos alunos que compõem a autoria deste trabalho. Agradecemos também a gentileza de Daniela Aparecida Rocha Librelon Hilbert e Paulo Sérgio Uliana Júnior pelas traduções para o espanhol e para o inglês respectivamente.

REFERÊNCIAS

ANJOS, C. S. dos [et al.]. Análise do nível de legenda de classificação de áreas urbanas empregando imagens multiespectrais e hiperespectrais com os métodos árvore de decisão c4.5 e floresta randômica. **Bol. Ciênc. Geod.**, v. 23, n. 2, p. 371–388, 2017. <<https://doi.org/10.1590/S1982-21702017000200024>>. Acesso em: 20 jan. 2022.

BARBOSA VALE, J. R. [et al.]. 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. Disponível em: <<https://doi.org/10.18764/2446-6549.v4n13p26-44>>. Acesso em: 20 jan. 2022.

CASTILLEJO-GONZÁLEZ, I. L. [et al.]. Object-and pixel-based analysis for mapping crops and their agro-environmental associated measures using QuickBird imagery. **Computers and Electronics in Agriculture**, v. 68, n. 2, p. 207–215, 2009.

CASTILLO, E. J.; LEAL, C. O.; ALMENDRA, D. Presiones por el uso de los comunes urbanos en áreas metropolitanas: caso del humedal Boca Maule en Chile. **Ateliê Geográfico**, v. 14, n. 3, p. 74–99, 2020.

COCHRAN, W. G. **Sampling Techniques**. 3rd Edition. New York: John Wiley and Sons, Inc. [s.l: s.n.].

DANCEY, C.; REIDY, J. **Estatística sem Matemática para Psicologia**. Porto Alegre: Artmed, 2018.

FELIX, M.; NUCCI, J. C. Hemerobia das paisagens e lei de zoneamento do bairro Capela Velha no município de Araucária – PR. **Ateliê Geográfico**, Goiânia-GO, v. 10, n. 2, p. 82-96, ago. 2016.

FIGUEIREDO FILHO, D. B.; SILVA JÚNIOR, J. A. D. Desvendando os mistérios do coeficiente de correlação de Pearson (r). **Revista Política Hoje**, v. 18, n. 1, p. 115–146, 2009.

FLEISS, J. L.; COHEN, J.; EVERITT, B. S. Large sample standard errors of kappa and weighted kappa. **Psychological Bulletin**, v. 72, n. 5, p. 323–327, 1969.

FOODY, G. M. Explaining the unsuitability of the kappa coefficient in the assessment and comparison of the accuracy of thematic maps obtained by image classification. **Remote Sensing of Environment**, v. 239, n. 111630, jan. 2020.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente**: uma perspectiva em recursos terrestres. São José dos Campos: Parêntese Editora, 2009.

LANDIS, J. R.; KOCH, G. G. Landis and Koch 1977 agreement of categorical data. **Biometrics**, v. 33, n. 1, p. 159–174, 1977.

LI, C. [et al.]. Comparison of classification algorithms and training sample sizes in urban land classification with landsat thematic mapper imagery. **Remote Sensing**, v. 6, n. 2, p. 964–983, 2014.

MASTELLA, A. F.; VIEIRA, C. A. Acurácia temática para classificação de imagens utilizando abordagens por pixel e por objetos. **Revista Brasileira de Cartografia**, v. 70, n. 5, p. 1618–1643, 2018.

MELO, F. P. de. **Risco ambiental e ordenamento do território em Garanhuns - PE**. 2016. Tese (Doutorado em Geografia) - Programa de Pós-Graduação em Geografia, Universidade Federal de Sergipe - UFS, São Cristóvão, 2016.

MELO, F. P. de; SOUZA, R. M. E. Energia eletromagnética na superfície terrestre: estimativa multitemporal do albedo em Garanhuns-Pe. **Ciência e Natura**, v. 38, n. 1, 2016.

MONSERUD, R. A.; LEEMANS, R. Comparing global vegetation maps with the Kappa statistic. **Ecological Modelling**, v. 62, n. 4, p. 275–293, 1992.

NASCIMENTO, R. [et al.]. An assessment of the support vector machine for a cbers-2 ccd image classification: a case study of a tropical reservoir in Brazil. **Revista Brasileira de Cartografia**, n. 65, p. 431–439, 2013.

OLOFSSON, P. [et al.]. Making better use of accuracy data in land change studies: Estimating accuracy and area and quantifying uncertainty using stratified estimation. **Remote Sensing of Environment**, v. 129, p. 122–131, 2013.

QGIS Geographic Information System, 2015. Disponível em: <www.qgis.org>.

VENTURIERI, A.; SANTOS, J. R. DOS. Técnicas de classificação de imagens para análise de cobertura vegetal. Sistemas. In: ASSAD, E. D.; SANO, E. E. (Ed.). **Sistema de informações geográficas**: aplicações na agricultura. Brasília: Embrapa Amazônia Oriental, 1998. p. 351–371.

YAMAMOTO, J. K.; LANDIM, P. M. B. **Geoestatística**: conceitos e aplicações. São Paulo: Oficina de Textos, 2013.

Como citar:

ABNT

OLIVEIRA, W. L. de; MORAIS, B. R.; NERO, M. A. Avaliação da eficiência dos classificadores de imagem de sensoriamento remoto com variação na resolução espacial. **InterEspaço: Revista de Geografia e Interdisciplinaridade**, v. 8, e202204, 2022. Disponível em: <<http://dx.doi.org/10.18764/2446-6549.e202204>>. Acesso em: 28 out. 2022.

APA

Oliveira, W. L. de, Morais, B. R., & Nero, M. A. Avaliação da eficiência dos classificadores de imagem de sensoriamento remoto com variação na resolução espacial. *InterEspaço: Revista de Geografia e Interdisciplinaridade*, v. 8, e202204, 2022. Recuperado em 28 outubro, 2022, de <http://dx.doi.org/10.18764/2446-6549.e202204>



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

Copyright © 2022, Universidade Federal do Maranhão.

