



AVALIAÇÃO DE DESEMPENHO DE CLASSIFICADORES EM IMAGENS CBERS-04A E SENTINEL-2 DO MUNICÍPIO DE PIRACICABA - SP

Fernanda Cristina Carvalho Milani ¹
Danilo Carneiro Valente ²

RESUMO

Este trabalho tem como objetivo avaliar o desempenho dos classificadores *Support Vector Machine* (SVM) e *k-Nearest Neighbor* (KNN) em imagens CBERS-04A e Sentinel-2 no mapeamento de uso de ocupação da terra no município de Piracicaba-SP. A partir da segmentação das imagens e aplicação de técnicas de classificação orientada a objetos, foram definidas as classes de uso e ocupação da terra e colhidas amostras de treinamento. O processo de classificação foi feito para as imagens CBERS-04A e Sentinel-2 utilizando em ambas as mesmas amostras de treinamento e aplicando em cada uma delas tanto o algoritmo KNN, quanto o SVM, gerando 4 diferentes mapas de uso e ocupação da terra. A avaliação dos resultados se deu pelos métodos Índice Kappa e Exatidão Global e foi possível verificar a similaridade entre os resultados da aplicação do algoritmo SVM nas duas imagens, assim como a similaridade entre os resultados da aplicação do KNN nas duas imagens. Foi possível definir que as maiores confusões ocorreram entre as classes de formação campestre e agricultura, e solo exposto e agricultura, podendo estar relacionadas ao estágio fenológico e às características espectrais e de textura em que a maior parte dos cultivos agrícolas se encontravam na data do imageamento da área.

Palavras-chave: Avaliação de Desempenho, Classificadores, SVM, KNN, Uso e Ocupação da Terra.

ABSTRACT

This work aims to evaluate the performance of the Support Vector Machine (SVM) and k-Nearest Neighbor (KNN) classifiers in CBERS-04A and Sentinel-2 images in the mapping of land use and occupation in the city of Piracicaba-SP. From image segmentation and application of object-oriented classification techniques, we defined land use and occupation classes and collected training samples. Using both the same training samples and applying both the KNN and the SVM algorithms to each of them, the classification process generated four different land use and occupation maps. We used the Kappa Index and Global Accuracy methods to evaluate the results. It was possible to verify the similarity between the results of applying the SVM algorithm in the two images, as well as the similarity between the results of applying the KNN in the two images. It was also noted that the highest confusion occurred between the classes of rural formation and agriculture and exposed soil and agriculture, which may be related to the phenological stage and the spectral and texture characteristics in which most crops were at the time of imaging of the area.

Keywords: Performance Assessment, Classifiers, SVM, KNN, Land Use and Occupation.

¹ Mestranda do Curso de Geografia da Universidade Estadual de Campinas - Unicamp, fernandacmilani@gmail.com;

² Mestrando do Curso de Geografia da Universidade Estadual de Campinas - Unicamp, daniloc.valente@gmail.com.



INTRODUÇÃO

Com o contínuo desenvolvimento de novas técnicas e tecnologias, o sensoriamento remoto e suas aplicações ganham cada vez mais espaço em diversos campos do conhecimento. A popularização de plataformas e ferramentas de geoprocessamento e sensoriamento remoto, que permitem ao usuário acesso a baixo ou nenhum custo às informações espaciais, garantem a realização de diversos estudos de modo rápido, econômico, não invasivo e confiável, auxiliando na tomada de decisão (AMIRI et al., 2014). A necessidade de identificar informações sobre determinada região, suas alterações na paisagem e planejar o ordenamento do território é cada vez mais notável, com grande impacto nos âmbitos econômico, social e/ou ambiental (OLIVEIRA et al., 2019).

O uso de imagens orbitais junto às técnicas de classificação por meio de sensoriamento remoto e geoprocessamento se apresentam como importantes ferramentas para o levantamento e monitoramento de informações espaciais, em que um mapeamento preciso e atualizado de uso e ocupação da terra torna-se indispensável para tomada de decisões (PERTILLE et al., 2018).

A classificação digital de imagens é um processo sobre o qual atribui-se um significado ao pixel ou a um *cluster* através do reconhecimento de padrões homogêneos identificados junto a suas características espectrais e espaciais (QUEIROZ et al., 2017). Este reconhecimento é feito a partir de classificadores, entre os quais destacamos os classificadores não paramétricos SVM e KNN (NOI, KAPPAS, 2018).

O SVM se baseia no princípio da separação ótima entre as classes, procurando encontrar um hiperplano (limites de decisão) para separar as classes da imagem de acordo com a seleção das amostras de treinamento (MOUNTRAKIS, OGOLE, 2011). Já a classificação pelo algoritmo KNN leva em conta as características dos vizinhos mais próximos em relação às informações das amostras de treinamentos para atribuir uma classe ao objeto (NOI, KAPPAS, 2018).

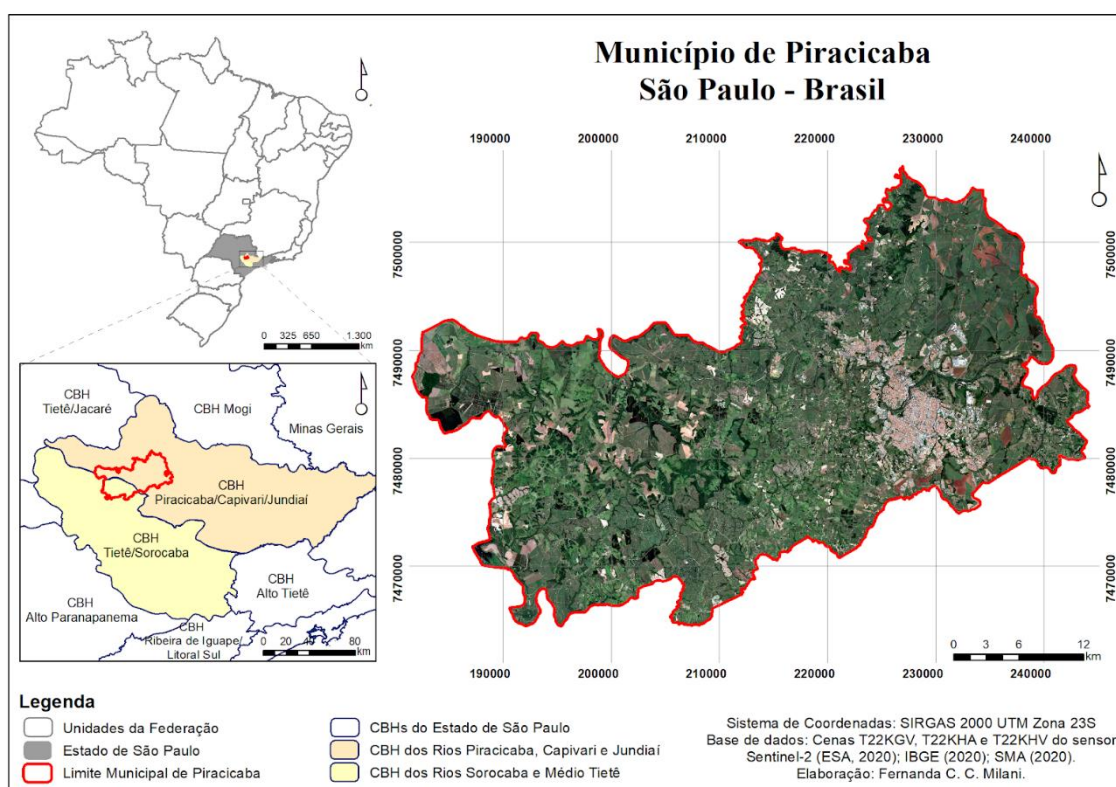
Portanto, considerando a importância do desenvolvimento e aplicação de ferramentas geoespaciais para conhecimento do território, este trabalho tem como objetivo avaliar o desempenho do mapeamento de uso e ocupação da terra no município de Piracicaba-SP, utilizando imagens orbitais Sentinel-2 e CBERS-04A, através do processo de segmentação de imagens e aplicação das técnicas de classificação orientada a objetos por meio dos classificadores *Support Vector Machine* (SVM) e *k-Nearest Neighbor* (KNN).

METODOLOGIA

Área de Estudo

O município de Piracicaba localiza-se no interior do Estado de São Paulo, na média depressão periférica paulista, a 152 km da capital. A topografia do município é pouco acidentada e, de acordo com a classificação de Köppen (1936), o clima é tropical de altitude (Cwa) (IPPLAP, 2019). Com área total de 1.376 km², Piracicaba é majoritariamente rural, com seu centro urbano correspondendo a aproximadamente 16% da área total do município (IPPLAP, 2019). De acordo com dados do Censo Demográfico do Instituto Brasileiro de Geografia e Estatística (IBGE, 2010), a população é de 364.571 habitantes e a densidade demográfica é de 264,47 habitantes/km².

Figura 1. Localização da área de estudo



Materiais e métodos

Para o desenvolvimento deste trabalho, foram utilizadas imagens dos satélites CBERS-04A e Sentinel-2, obtidas no dia 25 de novembro de 2020, o que garante o mesmo cenário de análise. Através do Catálogo de Imagens do Instituto Nacional de Pesquisas Espaciais (INPE), foi feita a aquisição das imagens pancromática e multiespectrais CBERS-04A obtidas pela Câmera Multiespectral e Pancromática de Ampla Varredura (WPM), com resolução espacial



de 2 e 8 metros respectivamente, e corrigidas radiometricamente. O *download* das imagens já corrigidas atmosféricamente e com 10 metros de resolução espacial, obtidas pelo sensor *MultiSpectral Instrument* (MSI) a bordo dos dois satélites da constelação Sentinel-2, foi feito através da plataforma *Copernicus Open Access Hub*, da Agência Espacial Européia (ESA). As características das imagens adquiridas para o estudo são apresentadas no quadro 1.

Quadro 1. Características das imagens utilizadas no estudo.

Sensor	Cenas	Resolução Espacial (m)	Bandas Espectrais	Comprimento de Onda Central (nm)
WPM	204/141	2	Pan	675
		8	B1	485
	B2		555	
	B3		660	
	204/142	B4	832	
MSI	T22KGV	10	B02	492.1
	T22KHA		B03	559
	T22KHV		B04	664.9
			B08	832.9

Após o *download* das imagens, através da ferramenta *Mosaic To New Raster* no *software* ArcGIS 10.8, foi feito o mosaico das cenas. Em seguida, a partir da ferramenta *Extract by Mask*, extraímos a área de estudo nas quatro bandas multiespectrais das duas imagens utilizando o *shapefile* do limite do município disponibilizado pelo IBGE.

Com a delimitação da área de estudo em ambas as imagens, as bandas foram empilhadas em um único *raster* a fim de criarmos a composição colorida das imagens por meio da ferramenta *Composite Bands*. Com as imagens compostas, o processo de classificação de uso e ocupação da terra foi realizado utilizando o *software* ENVI 5.3. Através da ferramenta *Example Based Feature Extraction* foram realizadas as etapas de segmentação, seleção das amostras de treinamento e escolha dos algoritmos para a classificação.

Na etapa de segmentação e agrupamento, foram definidos os parâmetros para o *Segment Setting* e para o *Merge Setting*. Para o primeiro, que determina a densidade da segmentação, foi utilizado o algoritmo Edge com o valor de 30, ao passo que para o segundo, que determina o nível de agregação fundindo segmentos com base na combinação de informações espaciais e espectrais, foi utilizado o algoritmo *Full Lambda Schedule* com valor de 80. Os valores foram definidos a partir de análises de tentativa e erro, identificando o que melhor se adequa à área estudada em tal data.

A partir da segmentação, realizamos a análise visual nas duas imagens e criamos uma chave de interpretação considerando as características espectrais com diferentes composições,



além da forma e textura, o que resultou em 18 classes usadas para a classificação: Água, Mata 1, Mata 2, Silvicultura 1, Silvicultura 2, Formação Campestre 1, Formação Campestre 2, Formação Campestre 3, Cultura 1, Cultura 2, Cultura 3, Cultura 4, Solo Exposto 1, Solo Exposto 2, Solo Exposto 3, Infraestrutura Urbana 1, Infraestrutura Urbana 2, e Infraestrutura Urbana 3. Foram selecionadas entre 40 e 100 amostras de treinamento para cada uma das classes, de acordo com sua representatividade na área de estudo.

Após a definição das amostras de treinamento, a classificação se deu através da seleção dos atributos espectrais, espaciais e de textura, utilizando os algoritmos KNN e SVM. O processo de classificação foi feito para as imagens CBERS-04A e Sentinel-2 utilizando em ambas as mesmas amostras de treinamento e rodando para cada uma delas tanto o algoritmo KNN, quanto o SVM, o que resultou em 4 diferentes mapas de uso e ocupação da terra (Figuras 1 e 2). Ressaltamos que na seleção do algoritmo KNN não permitimos a criação da classe *Unclassified*, mas os demais atributos seguiram a configuração *Default*. Já na seleção do algoritmo SVM, todos os parâmetros seguiram a configuração *Default*.

Com os resultados exportados, foi possível organizar as classes de uso e ocupação no *software* ArcGIS 10.8. Para tanto, foi feita a junção das classes Mata (1 e 2), Silvicultura (1 e 2), Formação Campestre (1, 2 e 3), Cultura (1, 2, 3, 4) Solo Exposto (1, 2 e 3) e Infraestrutura Urbana (1, 2 e 3), que, em conjunto com a classe Água, resultou em 7 classes finais, apresentadas nas figuras 1 e 2.

A avaliação do desempenho dos classificadores nas duas imagens foi feita através dos métodos da Exatidão Global e Índice Kappa. Assim, utilizando a ferramenta *Create Pan-sharpened Raster Dataset*, foi feita a fusão das bandas multiespectrais da imagem CBERS-04A com sua banda pancromática de 2 metros de resolução espacial, onde obtivemos como resultado uma imagem multiespectral com resolução espacial de 2 metros, considerada como verdade de campo para validação dos mapas resultantes.

Desta forma, a partir da ferramenta *Create Random Points*, foram gerados 350 pontos aleatórios em toda a superfície da área de estudo, classificados visualmente a partir da imagem CBERS 04-A de dois metros de resolução. Para a extração de valores de cada uma das classificações geradas, foi utilizada a ferramenta *Extract Multi Values To Point*, com a exportação da tabela de atributos do *shapefile* dos pontos para o formato *xlsx*, permitindo a organização e análise dos dados, resultando na criação da matriz de confusão para cada uma das classificações no *software* Excel.

RESULTADOS E DISCUSSÃO

Analisando os resultados, identifica-se que Piracicaba apresenta grande aptidão para atividades agrícolas, marcada principalmente pelo cultivo de cana-de-açúcar, que no ano de 2019 correspondeu a aproximadamente 89% de toda a área plantada municipal (IBGE, 2020).

O resultado das classificações de uso e ocupação da terra pelos algoritmos KNN e SVM no sensor WPM – CBERS-04A são observados nas Figuras 2 e 3.

Figura 2. Classificação de Uso e Ocupação da Terra utilizando o classificador KNN nas imagens CBERS-04A

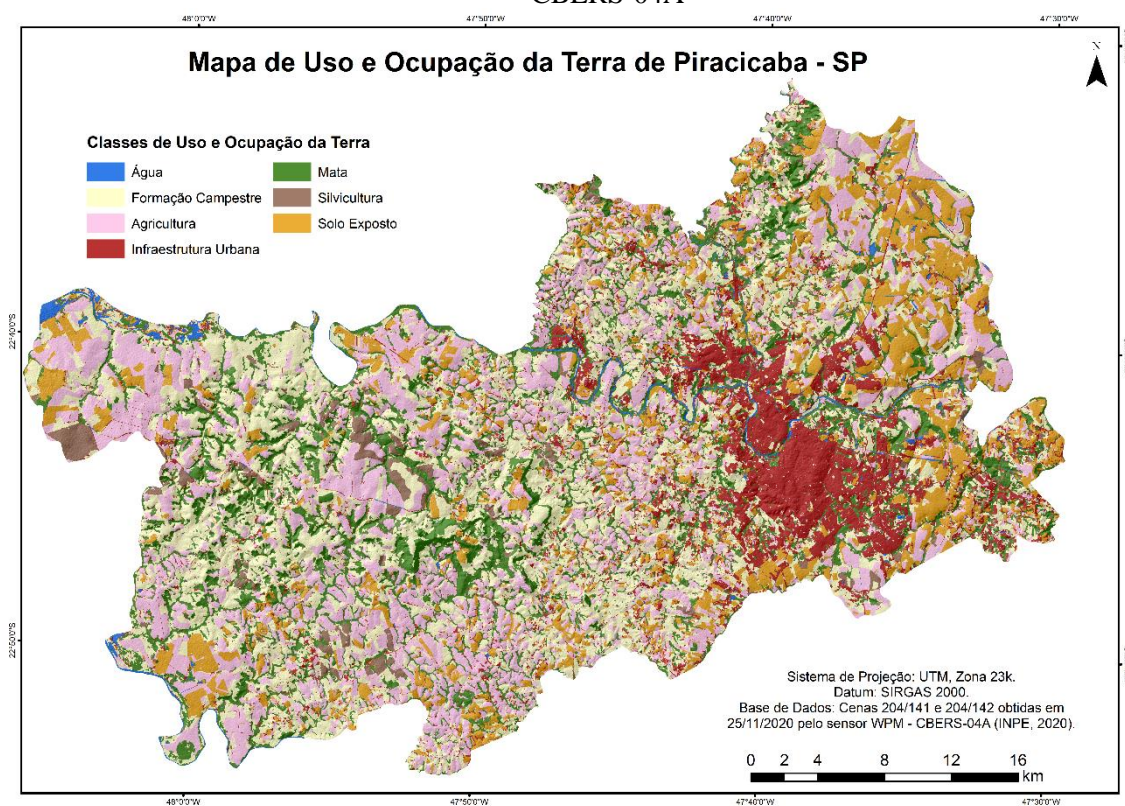


Figura 3. Classificação de Uso e Ocupação da Terra utilizando o classificador SVM nas imagens CBERS-04A

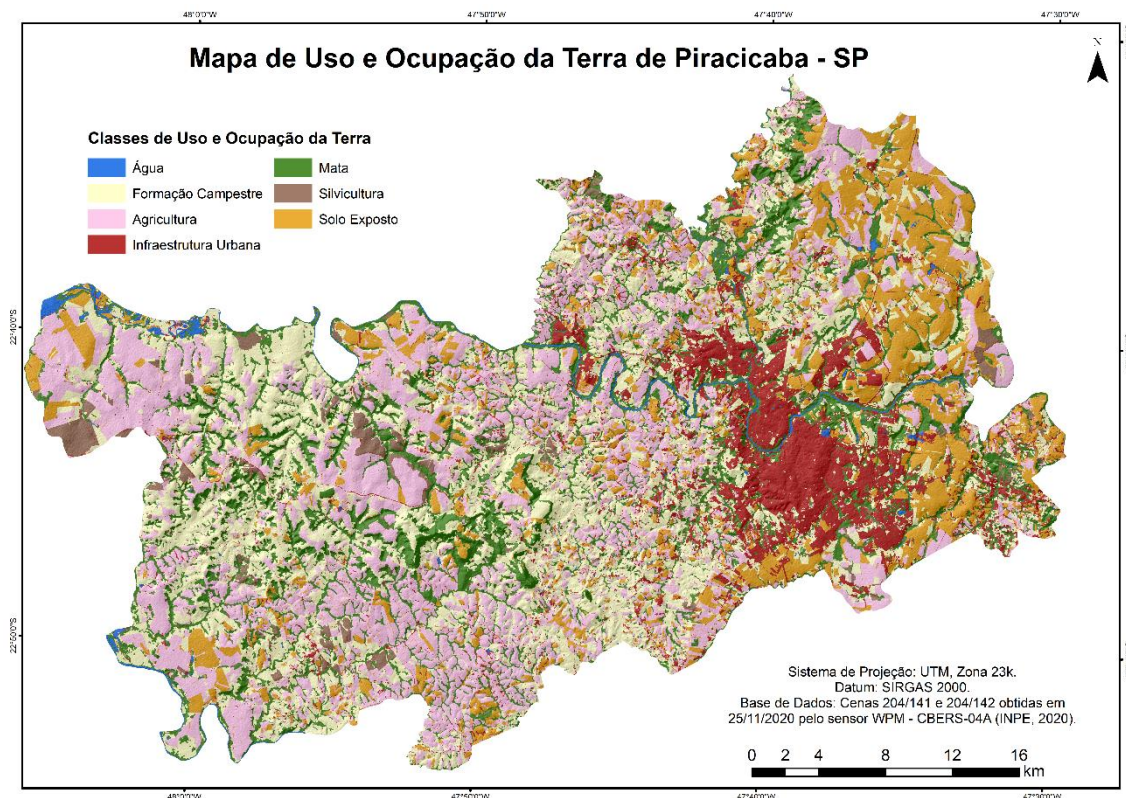


Tabela 1. Percentual da área ocupada nos diferentes usos classificados nos métodos KNN e SVM em imagens CBERS-04A

Classes	Área Identificada (%)	
	WPM	
	CBRES_KNN	CBRES_SVM
Água (AG)	1,11	1,049
Agricultura (AC)	24,72	26,74
Formação campestre (FC)	29,51	27,62
Infraestrutura urbana (IU)	10,93	9,95
Mata (MT)	16,69	17,25
Silvicultura (SI)	3,23	2,80
Solo exposto (SE)	13,82	14,60
Total	100,00	100,00

Observa-se que a classe de formação campestre foi a de maior representatividade nas classificações com imagens CBERS-04A, recobrando 29,51% da área do município na classificação com o KNN e 27,62% com o classificador SVM (Tabela 1).



A classe de agricultura ocupou 24,72% da área para o classificador KNN e 26,74% no SVM, esta área destaca-se em grande parte ao cultivo da cana-de-açúcar, predominante no município.

Na porção a leste do município é possível identificar áreas de solo exposto, que em sua grande maioria são terrenos em fase de preparação para a agricultura. Já as áreas de matas encontram-se em grande parte associado a fragmentos de mata ciliar correspondendo a 13,82% e 14,6% da área identificado nos classificadores KNN e SVM respectivamente.

O resultado da classificação utilizando imagens do sensor MSI-Sentinel 2 é observado nas Figuras 4 e 5.

Figura 4. Classificação de Uso e Ocupação da Terra utilizando o classificador KNN nas imagens Sentinel -2

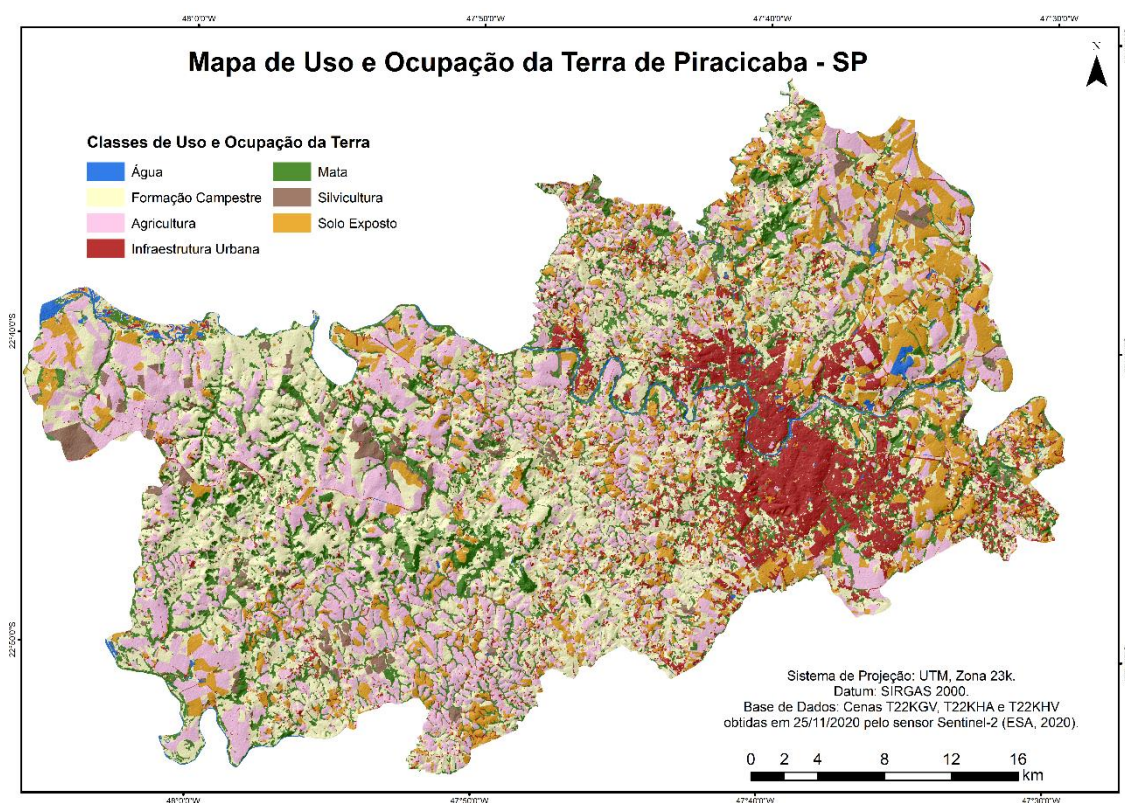


Figura 5. Classificação de Uso e Ocupação da Terra utilizando o classificador SVM nas imagens Sentinel -2

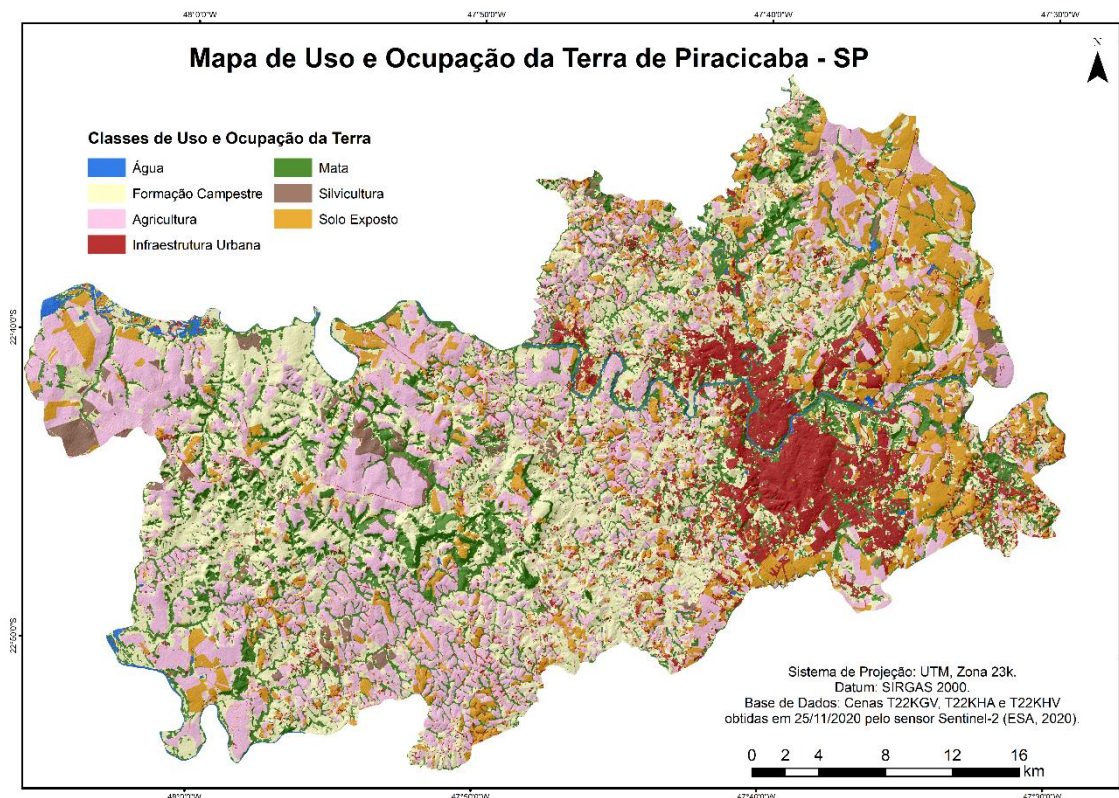


Tabela 2. Percentual da área ocupada nos diferentes usos classificados nos métodos KNN e SVM em imagens Sentinel-2

Classes	Área Identificada (%)	
	T22_KNN	T22_SVM
Água (AG)	1,12	1,00
Agricultura (AC)	23,02	24,77
Formação campestre (FC)	32,12	30,40
Infraestrutura urbana (IU)	11,05	10,22
Mata (MT)	15,61	16,53
Silvicultura (SI)	3,00	2,63
Solo exposto (SE)	14,10	14,46
Total	100,00	100,00

Cerca de 32,12% do município na classificação pelo método KNN foi associado a classe de formação campestre. No classificador SVM esta classe ocupou 30,4%. Assim como nas classificações com o sensor CBERS-04A esta classe foi a mais representativa, com pequeno aumento do percentual nas imagens Sentinel-2. A classe de agricultura permaneceu semelhante nas imagens, ocupando 23,02% para o KNN e 24,77% no SVM.



O mesmo pode ser observado para as classes de mata e solo exposto, relativas às áreas de galeria e preparação para o cultivo.

Avaliação do desempenho

Para avaliar o desempenho dos classificadores geramos matrizes de confusão para cada uma das quatro imagens, utilizando 350 pontos de controle.

Quadro 2. Matriz de confusão da classificação pelo algoritmo KNN em imagens CBERS-4A

		Uso Identificado pela Imagem CBERS-04A WPM								
		AC	AG	FC	IU	MT	SI	SE	Total	EC
Classificação CBERS KNN	AC	54	0	8	0	1	2	11	76	0,289
	AG	0	11	0	0	0	0	0	11	0
	FC	34	0	58	0	10	0	3	105	0,448
	IU	1	0	0	32	0	2	2	37	0,135
	MT	3	0	6	0	43	1	0	53	0,189
	SI	1	0	0	0	2	15	0	18	0,167
	SE	3	1	0	0	2	0	45	51	0,118
	Total	96	12	72	32	58	20	60	350	
EO	0,438	0,083	0,194	0	0,259	0,25	0,25			
Exatidão Global:					Índice Kappa:					
0,737					0,677					

Quadro 3. Matriz de confusão da classificação pelo algoritmo SVM em imagens CBERS-4A

		Uso Identificado pela Imagem CBERS-04A WPM								
		AC	AG	FC	IU	MT	SI	SE	Total	EC
Classificação CBERS SVM	AC	72	0	6	0	1	0	1	80	0,1
	AG	0	11	0	0	0	0	0	11	0
	FC	20	0	64	0	3	1	0	88	0,273
	IU	2	0	0	32	0	0	1	35	0,086
	MT	0	0	2	0	53	2	0	57	0,07
	SI	1	0	0	0	1	17	0	19	0,105
	SE	1	1	0	0	0	0	58	60	0,033
	Total	96	12	72	32	58	20	60	350	
EO	0,25	0,083	0,111	0	0,086	0,15	0,033			
Exatidão Global:					Índice Kappa:					
0,877					0,849					



Verificamos através da matriz de confusão do Quadro 2 que o classificador KNN na imagem CBERS-04A apresentou exatidão global de 73,7% e Índice Kappa de 0,677, considerado muito bom (CONGALTON; GREEN, 1999).

A classe formação campestre apresentou o maior erro de comissão nesta classificação, com 44%, na qual a confusão ocorreu com áreas de cultivos agrícolas. A classe de agricultura apresentou erro de 28,9%, confundida com áreas de solo exposto e formação campestre. Sobre os erros de omissão, verifica-se que 43% das amostras de agricultura foram classificadas em outras classes, com destaque para a classe de formação campestre. Já as áreas de solo exposto apresentaram 25% de erro atribuídos em grande parte a classe de agricultura.

A classificação pelo algoritmo SVM na imagem CBERS-04A (Quadro 3) apresentou Exatidão Global de 87,7% e 0,849 de Índice Kappa, ficando na classe excelente (CONGALTON; GREEN, 1999).

Observa-se 27% de erro de comissão para a classe de formação campestre, confundida em sua maioria com áreas de agricultura. Em relação aos erros de comissão, destacamos que 25% dos pontos identificados como agricultura foram classificados como outras classes, em sua maioria a formação campestre. Ambos os erros foram menores no classificador SVM.

Nos Quadros 4 e 5 observamos as matrizes de confusão para as classificações geradas a partir das imagens Sentinel-2.

Quadro 4. Matriz de confusão da classificação pelo algoritmo KNN em imagens Sentinel-2

		Uso Identificado pela Imagem CBERS-04A WPM								EC
		AC	AG	FC	IU	MT	SI	SE	Total	
Classificação T22 KNN	AC	58	0	7	0	2	1	10	78	0,256
	AG	0	9	0	0	0	0	1	10	0,1
	FC	30	1	58	1	6	3	3	102	0,431
	IU	1	1	0	31	0	1	3	37	0,162
	MT	1	1	6	0	45	4	0	57	0,211
	SI	0	0	0	0	4	11	1	16	0,313
	SE	6	0	1	0	1	0	42	50	0,16
	Total	96	12	72	32	58	20	60	350	
EO	0,396	0,25	0,194	0,031	0,224	0,45	0,3			
Exatidão Global:					Índice Kappa:					
0,726					0,663					



Quadro 5. Matriz de confusão da classificação pelo algoritmo SVM em imagens Sentinel -2

		Uso Identificado pela Imagem CBERS-04A WPM								
		AC	AG	FC	IU	MT	SI	SE	Total	EC
Classificação T22 SVM	AC	73	0	5	1	3	0	5	87	0,161
	AG	0	10	0	0	0	0	0	10	0
	FC	20	0	66	0	3	1	0	90	0,267
	IU	0	1	0	30	0	0	2	33	0,091
	MT	1	0	1	0	52	4	0	58	0,103
	SI	0	0	0	0	0	15	0	15	0
	SE	2	1	0	1	0	0	53	57	0,07
	Total	96	12	72	32	58	20	60	350	
EO	0,24	0,167	0,083	0,063	0,103	0,25	0,117			
Exatidão Global: 0,854					Índice Kappa: 0,82					

Verificamos que a classificação pelo método KNN apresentou Índice de exatidão global de 72,5% e Índice Kappa de 0,663 entrando na classe muito bom (CONGALTON; GREEN, 1999).

Os maiores erros de comissão nesta classificação estão relacionados a classe de formação campestre em que, segundo a matriz de confusão, cerca de 43% foram confundidos com outros usos, principalmente com agricultura. A classe silvicultura apresentou 31% de erros de comissão, sendo acrescentados nas áreas de mata. Em relação aos erros de omissão pelo classificador KNN, destaca-se que 39% das áreas de agricultura foram classificadas em outros usos, com destaque para áreas de formação campestre, e 30% das áreas de solo exposto, sendo classificado em sua maioria como agricultura.

Já o classificador SVM apresentou exatidão global de 85,4% e Índice Kappa de 0,82 considerado excelente (CONGALTON; GREEN, 1999). O maior erro de comissão também foi identificado na classe de formação campestre, com 26,7% confundindo sobretudo com áreas de agricultura. As demais classes apresentaram baixo erro. Quanto aos erros de omissão, destaca-se o cultivo agrícola com 24% da área confundida principalmente com a classe de formação campestre. Observa-se também que 25% da área de silvicultura foi confundida com a classe de mata.



CONSIDERAÇÕES FINAIS

A partir da identificação das classes, quantificamos a área de cada uma delas para os dois classificadores. As classificações pelos métodos KNN e SVM apresentaram padrões semelhantes de porcentagem da área entre as classes de uso e ocupação da terra nas duas imagens, ou seja, nas classes com maior área identificada pelo KNN do que pelo SVM em uma das imagens, foi observado que o mesmo ocorreu na outra. Na média das quatro classificações, a classe de Formação Campestre representa aproximadamente 30% da área de estudo, seguido por Agricultura com 25%, Mata 16%, Solo Exposto 14%, Infraestrutura Urbana 11%, Silvicultura 3% e Água 1%.

Verificamos através da matriz de confusão que o classificador KNN na imagem CBERS-04A apresentou exatidão global de 73,7% e Índice Kappa de 0,677, considerado muito bom. Já para o classificador SVM obteve-se Exatidão Global de 87,7% e Índice Kappa de 0,849, entrando na classe excelente (CONGALTON; GREEN, 1999).

A validação dos resultados obtidos na classificação da imagem Sentinel-2 apresentou Exatidão Global de 72,5% e Índice Kappa de 0,663 considerado muito bom para o KNN, e Exatidão Global de 85,4% e Índice Kappa de 0,82% para o SVM, classificado como excelente (CONGALTON; GREEN, 1999).

Verifica-se que as maiores confusões ocorreram entre as classes de formação campestre e agricultura, e solo exposto e agricultura. Estas confusões podem estar relacionadas ao estágio fenológico e às características espectrais e de textura em que a maior parte dos cultivos agrícolas (como o da cana-de-açúcar) se encontravam na data do imageamento da área. Observamos que muitas das áreas se encontram em fase de colheita e início de plantio, com a existência de muitas áreas de solo exposto preparadas para o plantio misturadas com cultivos já em um período inicial.

REFERÊNCIAS

- AMIRI, F. *et al.* Multi-temporal landsat images based on eco-environmental change analysis in and around Chah Nimeh reservoir, Balochestan (Iran). **Environmental Earth Sciences**, v. 72, n. 3, p. 801-809, 2014.
- CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. Boca Raton: CRC Press, 1999. 137p.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Censo demográfico 2010**. IBGE: Instituto Brasileiro de Geografia e Estatística, 2010.



INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Produção da Agrícola Municipal 2019**. Rio de Janeiro: IBGE, 2020.

INSTITUTO DE PESQUISA E PLANEJAMENTO DE PIRACICABA (IPPLAP). **A Cidade**. Disponível em <<http://ipplap.com.br/site/a-cidade/>> Acesso em 21 dez.de 2020.

MOUNTRAKIS, G.; I.M, J.; OGOLE, C. Support vector machines in remote sensing: a review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.66, p.247-259, 2011.

NOI, P. N; KAPPAS, M. Comparison of Randon Forest, k-Nearest Neighbor, and Suport Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery. **Sensors**, v. 18, n.18, p.1-20, 2018.

OLIVEIRA, J. C. C. *et al.* Uso e ocupação do solo do município de Campina Verde – MG. In: **Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto**, p. 2430 – 2433. INPE, 2019.

PERTILLE, C. T. *et al.* Estudo da eficiência de classificações supervisionadas aplicadas em imagem de média resolução espacial. **BIOFIX Scientific Journal**, v. 3 n. 2 p. 289-296 2018.

QUEIROZ, T. B *et al.* Avaliação do desempenho da classificação do uso e cobertura da terra a partir de imagens Landsat 8 e Rapideye na região central do Rio Grande do Sul. **Geociências**, v. 36, n. 3, p. 569 - 578, 2017.