

AVALIAÇÃO DA ACURÁCIA TEMÁTICA PARA CLASSIFICAÇÃO DE IMAGENS UTILIZANDO ABORDAGENS POR PIXEL E POR OBJETOS

A. F. M. Mastella¹, C. A. O. Vieira¹

¹Universidade Federal de Santa Catarina, Brasil

CT04-4

RESUMO

O objetivo deste artigo é avaliar a acurácia temática de uma classificação supervisionada, numa imagem de satélite Landsat 8, sensor OLI, do município de Nova Veneza/SC, utilizando abordagens por pixel e por objeto. Foram utilizados 03 (três) diferentes classificadores: Mínima Distância Euclidiana (MDE), Máxima Verossimilhança (MAXVER) e SEGCLASS. Os dois primeiros, baseados em classificação por pixel, e o último, por objeto. A acurácia temática foi medida através dos coeficientes – e suas variâncias – Kappa, Tau e teste estatístico Z, derivados da Matriz de Erro (ME). Resultados indicaram, estatisticamente, o melhor desempenho da classificação por objeto em relação às classificações por pixel. Verificou-se, através do teste estatístico Z, que todas as classificações são estatisticamente diferentes, e comparando-se os índices Kappa, o melhor desempenho foi obtido pelo classificador SEGCLASS, seguido do MAXVER, e por último, do MDE, embora os classificadores apresentaram valores muito próximos.

Palavras chave: Classificação de imagens, Abordagem por pixel e por objeto, Acurácia Temática

ABSTRACT

The objective of this article is to assess the thematic accuracy of a supervised classification, on a Landsat 8 image, OLI sensor, from the municipality of Nova Veneza/SC, using pixel-based and object-based approaches. It was used 03 (three) different classifiers: Minimum Euclidian Distance, Maximum Likelihood and SEGCLASS. The first two, based on classification by pixel, and the last, by object. The thematic accuracy was measured by the coefficients – and their variances – Kappa, Tau and statistical test Z, derived from the Error Matrix. Results indicated a statistically better performance of the classification by object in relation to the classifications by pixel. It was verified, through the statistical test Z, that all the classifications are statistically different, and comparing the Kappa indexes, the best performance was obtained by the SEGCLASS classifier, followed by the other ones, although the classifiers presented very close values.

Keywords: Image classification, Pixel and object based classifications, Thematic accuracy

1- INTRODUÇÃO

O homem faz parte da natureza, e neste processo de interação, acaba transformando a paisagem. Deste modo, um bom uso da Terra (UT), por parte dos gestores, precisa ser levado em consideração. Através dos produtos do sensoriamento remoto orbital, é possível classificar imagens, gerar mapas de UT, monitorar áreas florestais, etc. Porém, todo processo de classificação deve haver uma posterior validação. O uso da Matriz de Erro (ME) e índices estatísticos derivados, ajudam a estimar a acurácia destes produtos. Atualmente, há uma tendência de mudança de estratégia, de uma classificação por pixel, para uma abordagem por objeto, embora não se tenham comparações entre a acurácia temática desses produtos. O objetivo desse artigo é a avaliar a acurácia para classificação de imagens de satélite, utilizando

abordagens por pixel e por objeto, a partir dos índices derivados das ME.

2- REFERENCIAL TEÓRICO

Stehman e Czaplewski (1998) sugerem que para uma boa avaliação da acurácia temática, após a classificação de imagens, são necessários três passos: modelo de amostragem (definição das amostras, classes, representados pelos dados de referência), modelo de resposta (uso da melhor regra de decisão) e estimação e análise da acurácia temática (índices derivados da ME).

Uma Matriz de Erro (ME) é um arranjo quadrado disposto em linhas e colunas, e expressa o número de unidades amostrais, inicialmente atribuídas, confrontando os dados de referência (colunas), com os dados classificados (linhas) (Congalton e Green, 1999; Vieira, 2000, p. 140). Através da ME, é possível derivar

índices estatísticos como: exatidão global, índice Kappa, Tau, teste Z, dentre outros.

O coeficiente Kappa é uma medida de quão bem a classificação concorda com os dados de referência. É expresso através de medidas de concordância, indicada pelos elementos da diagonal da ME, subtraídos da discordância, indicada pelos produtos das somas marginais das linhas e colunas da ME (Congalton e Green, 1999; Vieira, 2000, p. 82). O índice Kappa pode ser estimado pela seguinte equação:

$$\hat{K} = \frac{P_0 - P_c}{1 - P_c}, \quad (1)$$

onde \hat{K} é a estimativa Kappa, P_0 é a concordância, e P_c a discordância (Congalton e Green, 1999). Já sua variância, é assim expressa:

$$Var(K_a) = \frac{1}{n} \left[\frac{\theta_1(1-\theta_1)}{(1-\theta_2)^2} + 2 \frac{(1-\theta_1)(2\theta_1\theta_2 - \theta_3)}{(1-\theta_2)^3} + \frac{(1-\theta_1)^2(\theta_4 - 4\theta_2^2)}{(1-\theta_2)^4} \right], \quad (2)$$

onde $Var(K_a)$ é a variação aproximada do Kappa, e as equações 3, 4, 5 e 6, suas variáveis:

$$\theta_1 = \frac{1}{n} \sum_{i=1}^k n_{ii}, \quad (3)$$

$$\theta_2 = \frac{1}{n^2} \sum_{i=1}^k n_{i+} n_{+i}, \quad (4)$$

$$\theta_3 = \frac{1}{n^2} \sum_{i=1}^k n_{ii} (n_{i+} + n_{+i}), \quad (5)$$

e

$$\theta_4 = \frac{1}{n^3} \sum_{j=1}^k n_{ij} (n_{j+} + n_{+i})^2, \quad (6)$$

Já o índice Tau, fornece uma medida quantitativa relativamente precisa e intuitiva sobre a acurácia da classificação, sendo superficialmente similar ao Kappa (Figueiredo e Vieira, 2007), calculado da seguinte forma:

$$T = \frac{P_0 - P_r}{1 - P_r}, \quad (7)$$

onde T é o coeficiente Tau, P_0 é a concordância real, e P_r é a concordância aleatória, calculados da seguinte forma (Figueiredo e Vieira, 2007):

$$P_0 = \frac{\sum_{i=1}^c x_{ii}}{n}, \quad (8)$$

e

$$P_r = \sum_{i=1}^c P_{i+} P_i = \frac{1}{n^2} \sum_{i=1}^c x_{i+} x_i, \quad (9)$$

sendo $P_{i+} = \left(\frac{x_{i+}}{n}\right)$ a distribuição marginal dos dados de referência, e $P_i = \left(\frac{x_i}{n}\right)$ as probabilidades *a priori* para cada classe.

Quanto ao teste Z, é usado para analisar o quanto uma medida se afasta da média, em termos de

desvio padrão, analisando 01 (uma) ou 02 (duas) MEs, normalmente distribuídas, identificando, individualmente, um índice Kappa, segundo a equação:

$$Z = \frac{\hat{k}_1}{\sqrt{\widehat{var}(k_1)}}, \quad (10)$$

ou para duas classificações, assim expressos (Congalton e Green, 1999):

$$Z = \frac{|\hat{k}_1 - \hat{k}_2|}{\sqrt{\widehat{var}(k_1) + \widehat{var}(k_2)}}, \quad (11)$$

onde, para um teste individual (Equação 10), Z pode ser testado, assumindo a hipótese nula ($H=0$), que é rejeitada se $Z \neq 0$, \hat{K} é o índice Kappa, e \widehat{var} , sua variância. Pode também utilizar a Matriz de Significância (MS), que serve como abordagem alternativa para comparação de ME independentes, com os resultados sumarizados na forma de MS, no qual os elementos da diagonal principal indicam se o resultado da respectiva classificação é estatisticamente diferente de uma classificação randômica (Equação 10), e os elementos fora da diagonal (Equação 11), a comparação estatística do desempenho dos classificadores, pelo teste Z (Vieira, 2000).

3- ÁREA DE ESTUDO

Nova Veneza (NV) é um município localizado no sul do estado de Santa Catarina ($28^{\circ}38'12''S; 49^{\circ}29'52''O$). Limita-se ao norte com Siderópolis, ao sul com Meleiro, a leste com Criciúma e Forquilha, a sudoeste e oeste com Morro Grande, e a noroeste com Bom Jardim da Serra e São José dos Ausentes (RS) (Fig. 1). Possui uma população de 13.309 habitantes, tendo seu UT voltado à rizicultura (7.800 ha), mineração de argila e seixos (29 ha), banana (15 ha), pastagens (228 ha), pecuária (87 ha), milho (750 ha), fumo (90 ha), feijão (195 ha), aviários e indústria (463 ha), bem como conflitos no tocante ao abastecimento de água *versus* agricultura, entre produtores, bem como poluição fluvial do rio Mãe Luzia. Possui um clima mesotérmico, tipo úmido (Cfb), com chuvas para o trimestre outubro, novembro e dezembro de 2016, para este estudo de caso, entre 500-600mm (100 a 200mm por mês), e as temperaturas, entre 20-22°C, e 18-20°C, na parte noroeste do município (Mastella, 2017).

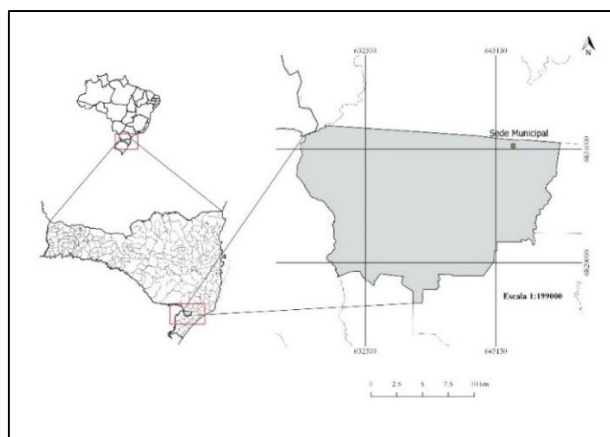


Fig. 1 – Localização da área de estudo.

4- MATERIAIS E MÉTODOS

Os materiais utilizados nesta pesquisa foram:

- Imagem de satélite Landsat 8, órbita ponto 220/080, sensor OLI, data de 03 de novembro de 2016, resolução espacial de 30m (multiespectral), 4.70% de nuvens, qualidade 09, disponibilizadas pelo Instituto Nacional de Pesquisas Espaciais – INPE (<http://www.dgi.inpe.br/siteDgi/index_pt.php>), no dia 15 de novembro de 2016;
- O Sistema de Informação Geográfica (SIG) QGIS Wien (ambiente SIG Aberto e Livre), para recorte e reamostragem da imagem, de 16 *bits* para 8 *bits*;
- O aplicativo Google Earth Pro, para coleta amostral, em seguida à aquisição da imagem de satélite, a fim de criar um Mapa de Referência (MR), para posterior validação do processo de classificação;
- O Sistema IDRISI 16.03 The Taiga Edition, Clark Labs., da Clark University (2009), usado para vetorização e composição do MR, classificação do MR, uso dos classificadores por pixel (MDE e MAXVER) e classificação por objeto (SEGCLASS), criação dos mapas temáticos, e formulação das ME; e
- Programa Kappa Analysis, desenvolvidos em C padrão, disponibilizado por Vieira (2000), para realizar as análises da avaliação da acurácia, a partir dos índices derivados das ME, bem como da MS;

4.1- Métodos

Após a aquisição da imagem de satélite, recortou-se à área de estudo, através do sistema “OSGeo4w Shell (GDAL)”, e a georreferenciou-se num sistema de coordenadas conhecida (SIRGAS2000 / UTM fuso 22S). Com a imagem exportada para ambiente IDRISI, e a partir da coleta amostral para definição das classes do mapa, através do *software* Google Earth Pro, foram definidas 04 (quatro) classes

informacionais para o estudo – Floresta, Culturas Agrícolas, Solos Expostos e Pastagem. Após a vetorização e definição do tamanho das amostras (180 amostras por classe), bem como uso das bandas 2 à 7 da imagem de satélite, o MR foi gerado, em ambiente IDRISI.

Em seguida à criação do MR, foi realizada a classificação das imagens, utilizando 03 (três) classificadores supervisionados, com abordagens por pixel e por objeto. A abordagem por pixel utilizou os classificadores da Mínima Distância Euclidiana (MDE), e da Máxima Verossimilhança (MAXVER). Por último, a classificação por objeto, o SEGCLASS. O classificador SEGCLASS utilizou uma imagem segmentada, confeccionada a partir das bandas 2 à 7 da imagem de satélite, uma janela de abertura 3x3, fator de peso médio variável para calcular a similaridade entre a vizinhança segmentada de 0.5, e similaridade de tolerância para controlar o nível de generalização, correspondente à segmentação, de 10 (dez). Valores 0 (zero), para similaridade de tolerância, indicam o início da partição dos limites das regiões (bacia). Assim, quanto maior o valor de tolerância, menor serão os segmentos de saída (valores dentro de 10 a 100 satisfazem o nível de generalização) (Eastman, 2009).

Após feita a segmentação, o classificador SEGCLASS utilizou a imagem segmentada, mais a imagem classificada pelo algoritmo MAXVER, gerando a sua imagem classificada. Posterior à composição dos mapas, foram geradas as ME de cada classificador, em ambiente IDRISI. A partir delas, com o uso do *software* Kappa Analysis, foram derivados os índices Kappa, Tau e teste estatístico Z, sendo confrontados e sumarizados em forma de MS.

5- RESULTADOS E ANÁLISE DOS RESULTADOS

A Fig. 2 apresenta o MR utilizado no processo de validação. Na Tab. 1, é apresentado a MS, onde aparecem os resultados dos índices derivados da ME,

tais como: exatidão global, Kappa, Tau e teste Z, para cada classificador:

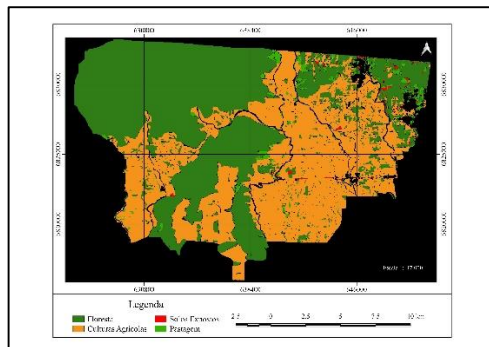


Fig. 2 – Mapa de Referência a partir da vetorização das classes na área de estudo.

TABELA 1 – MATRIZ DE SIGNIFICÂNCIA PARA COMPARAÇÃO ENTRE OS CLASSIFICADORES, USANDO OS RESULTADOS DO KAPPA ANALYSIS.

CLASSIFICADORES	MDE	MAXVER	SEGCLASS
<i>Exatidão Global</i>	70.4	73.5	74.6
<i>KAPPA</i>	0.5180	0.5686	0.5798
<i>TAU</i>	0.605230	0.646918	0.660956
<i>VAR</i>	0.000001	0.000001	0.000001
MDE	518.087		
MAXVER	35.723	568.607	
SEGCLASS	43.647	7.924	579.813

O classificador MDE obteve uma exatidão global de 70.4%, contra 73.5% do MAXVER, e 74.6%, do classificador SEGCLASS (Tab. 1). Este último classificador, mostrando-se levemente superior aos demais. Quanto ao Kappa individual, os classificadores por pixel apresentaram um valor de 0.5180 (MDE), 0.5686 (MAXVER), contra 0.5798, do classificador por objeto SEGCLASS. Este último, mostrando-se melhor. A variância para os classificadores foi a mesma.

Quanto ao índice Tau, o melhor resultado ficou com o classificador por objeto SEGCLASS (0.660956), contra 0.646918 (MAXVER) e 0.605230 (MDE), dos classificadores por pixel. O teste Z para dois Kappa resultou num total de 35.723 dos classificadores MDE x MAXVER, 43.647 dos classificadores MDE x SEGCLASS, e por último, com melhor resultado, no tocante à média, os classificadores MAXVER x SEGCLASS (7.924). Considerando que estes valores são maiores que o valor tabelado de $Z=1.96$, conclui-se que essas classificações, individualmente, são melhores que uma classificação aleatória, e na comparação entre eles, verifica-se que [cada classificador] tiveram performances estatisticamente diferenciadas.

Nas fig. 3, 4 e 5 são apresentados os mapas gerados pelos classificadores por pixel, MDE (Fig. 3) e MAXVER (Fig. 4), e por objeto (SEGCLASS) (Fig. 5), respectivamente.

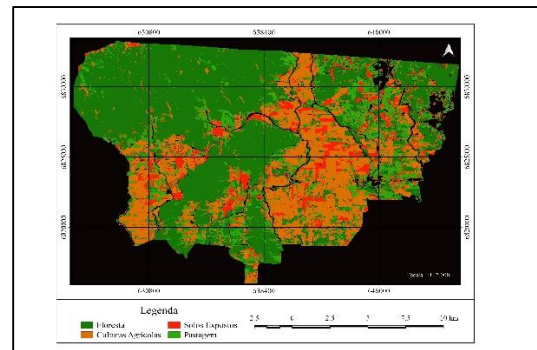


Fig. 3 – Mapa temático gerado pelo classificador Mínima Distância Euclidiana (MDE).

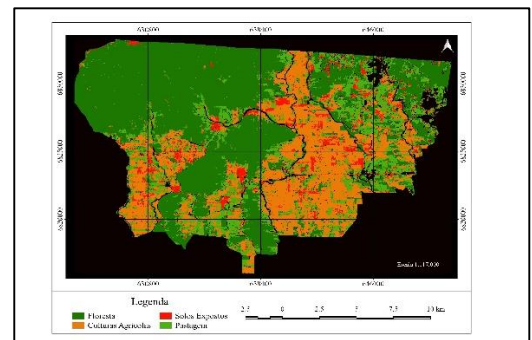


Fig. 4 – Mapa temático gerado pelo classificador Máxima Verossimilhança (MAXVER).

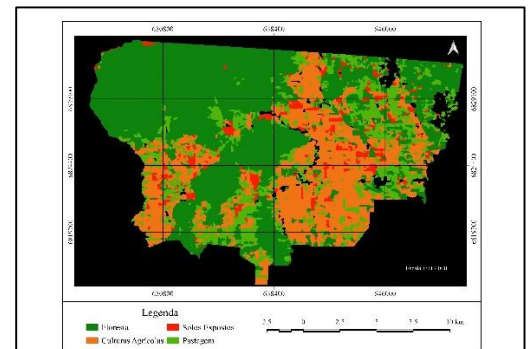


Fig. 5 – Mapa temático gerado pelo classificador por objeto SEGCLASS.

Os mapas foram todos classificados de acordo com as classes Floresta, Culturas Agrícolas, Solos Expostos e Pastagem. Na Fig. 3, gerada pelo classificador por pixel MDE, a parte noroeste, centro-sudeste e nordeste do município, foram classificadas majoritariamente como Floresta. A parte central foi classificada como Culturas Agrícolas e Solos Expostos. A região nordeste, sudeste, sul, e bordas da categoria Floresta, foi classificada como Pastagem. No mapa gerado pelo classificador por pixel MAXVER (Fig. 4), a região noroeste, centro-sul e sudoeste, e parte da região nordeste de NV, foi classificada como Floresta. A região centro-sul, sudoeste, e uma pequena parte da região leste de NV, como Culturas Agrícolas. A região centro-leste e oeste, como Solos Expostos. Já a região central de NV (nordeste), sudeste, sudoeste, tiveram classificação Pastagem. Por fim, o mapa gerado pelo classificador por objeto SEGCLASS (Fig. 5), teve as regiões nordeste,

noroeste e centro-oeste, classificadas como Floresta. A parte oeste, norte e centro-sul, como Culturas Agrícolas. A região oeste e centro-leste, houve uma considerável classificação de Solos Expostos. E a região norte, nordeste e sul, teve sua cobertura da Terra classificada como Pastagem.

Baseado no MR, o classificador MDE sobrepôs algumas áreas da categoria Floresta, pelas classes Culturas Agrícolas e Pastagem. A classe Culturas Agrícolas teve classificações como Solos Expostos. A classe Solos Expostos apresentou menor classificação em relação à classificação do MAXVER. Por fim, a borda das classes apresentaram-se dissolvidas. Quanto ao classificador por pixel, MAXVER, teve uma boa classificação da classe Floresta, porém, sobreposta por Pastagem, devido a respostas espectrais semelhantes, além de uma grande sobreposição da classe Solos Expostos à classe Culturas Agrícolas (respostas espectrais semelhantes). Não obstante, apresentou uma classificação razoável no tocante à Solos Expostos, em relação ao MR. A classe Pastagem adentrou a classe Floresta e Culturas Agrícolas, mas obteve melhores resultados que o classificador MDE. Quanto à borda das classes, apresentaram-se um pouco apagadas, complexas. Por fim, o classificador por objeto, SEGCLASS, teve uma boa classificação, com pouca sobreposição da classe Solos Expostos à classe Culturas Agrícolas. Teve, assim como o classificador MDE, baixa classificação da classe Solos Expostos em relação ao classificador MAXVER, e boa classificação da classe Pastagem. Suas bordas apresentaram-se mais nítidas, entretanto, pouco realistas.

Como NV tem seu UT destinado, quase que, completamente, à agricultura temporária (arroz e milho), e devido o plantio destas culturas realizarem-se no trimestre setembro, outubro e novembro, é notório a quantidade de solos arados e gradados. A partir destas características, bem como da aquisição da imagem de satélite dar-se neste período (03 de novembro de 2016), têm-se um perfil (ambiente) bastante homogêneo no tocante ao UT. Estas características dificultam uma correta coleta amostral, na classificação do MR, além de confundir os classificadores quanto à classificação (Floresta, devido a quase idêntica assinatura espectral à classe Pastagem; Culturas Agrícolas, devido a similaridade da aragem e preparo da terra, à classe Solos Expostos – topos de morros, terraplenagens; e Pastagens, confundindo-se com Culturas Agrícolas, já em processo de crescimento (como alguns plantios dão-se a partir de setembro, levando 160 a 180 dias para colheita, até novembro, as plantações estão com 60 dias, já com tamanho razoável, dando a entender, orbitalmente, tratem-se de pastagens).

6- CONCLUSÕES E SUGESTÕES

Os objetivos de avaliar o nível de acurácia de mapas da cobertura da Terra, do município de Nova Veneza/SC, usando abordagens por pixel e por objetos,

a partir de uma classificação supervisionada, foram alcançados satisfatoriamente. O desempenho dos classificadores foram efetivamente avaliados através dos índices derivados das ME, sumarizados na MS, destacando o classificador por objeto SEGCLASS, como melhor classificador, neste estudo de caso. As limitações residem na impossibilidade de uma análise multitemporal, a fim de melhorar a classificação dos alvos, melhorando assim a amostragem, bem como a melhor descrição dos alvos no tocante à classificação.

Quanto as sugestões, recomenda-se fazer uma melhor amostragem o mais próximo da obtenção da imagem de satélite possível, a fim de haver compatibilidade da imagem do satélite com as amostras do MR. Ainda recomenda-se a utilização de outros classificadores, como o classificador supervisionado Redes Neurais Artificiais (RNA), que possibilita a manipulação eficiente de grandes quantidades de dados, e que não assume nenhuma distribuição para as classes em análises. Por fim, recomenda-se, cada vez mais, o uso de classificações seguindo uma abordagem por objeto, já que generaliza melhor as classes, define melhor as bordas, bem como as discontinuidades.

REFERÊNCIAS BIBLIOGRÁFICAS

Congalton, R. G e K. Green, 1999. Assessing the accuracy of remotely sensed data: principles and practices / Russell G. Congalton and Kass Green. -- 2nd ed., ISBN 978-1-4200-5512-2

Eastman, J. R., 2009. Idrisi Taiga. Worcester, MA: Clark University.

Figueiredo, G. C e C. A. O. Vieira, 2007. Estudo do Comportamento dos índices de Exatidão Global, Kappa e Tau, comumente usados para avaliar a classificação de imagens do sensoriamento remoto, em Anais do XIII Simpósio Brasileiro de Sensoriamento Remoto, pp. 5755-5762.

Mastella, A. F. M., 2017. Avaliação da acurácia temática para classificação de imagens de satélite: estudo de caso no município de Nova Veneza/SC. Trabalho de Conclusão de Curso (graduação). Universidade Federal de Santa Catarina – UFSC. Florianópolis, 92 páginas.

Stehman, S. V. e R. L. Czaplewski, 2000. Design and analysis for thematic map accuracy assessment fundamental principles. Remote Sensing of Environment, pp.331-344.

Vieira, C. A. O., 2000. Accuracy of Remotely Sensing Classification of Agricultural Crops: A Comparative Study. Thesis (Doctor of Philosophy). University of Nottingham, United Kingdom, 321 páginas.