

PROPOSTA DE UMA MEDIDA PARA AVALIAÇÃO DE CLASSIFICAÇÃO EM BORDAS

Rogério Galante Negri¹
Luciano Vieira Dutra²
Sidnei João Siqueira Sant'Anna²

¹ Universidade Estadual Paulista – UNESP
Instituto de Ciência e Tecnologia – Departamento de Engenharia Ambiental
Rodovia Presidente Dutra, km 137,8 – 12247-004 – São José dos Campos – SP, Brasil
rogerio.negri@ict.unesp.br

² Instituto Nacional de Pesquisas Espaciais – INPE
Divisão de Processamento de Imagens
Caixa Postal 515 – 12245-970 – São José dos Campos – SP, Brasil
{dutra, sidnei}@dpi.inpe.br

Abstract. An important step made after obtain image classification results is the accuracy assessment. The accuracy assessment has been intensively studied by researchers in remote sensing. Usually, these measures are computed with basis on samples distributed over the image, within well defined regions and a priori known. This paper proposes a new measure for classification assessment over edges of objects. A case study about the land use and cover classification on an Amazon region adopting an ALOS-PALSAR image and Support Vector Machine was performed. The results show that the use of this new measure together the *Kappa* coefficient can provide a more robust analysis regarding the classification results.

Keywords: classificação de imagens, avaliação, bordas

1. Introdução

A *classificação de imagens* de Sensoriamento Remoto é uma das mais importantes aplicações de Reconhecimento de Padrões em estudos ambientais. Uma importante etapa realizada após a obtenção dos resultados de classificação é a avaliação de sua acurácia.

De acordo com Pantaleão e Scofield (2009), a avaliação da acurácia dos resultados de classificação têm sido intensamente estudada pelos pesquisadores em sensoriamento remoto. Várias medidas foram desenvolvidas e testadas para diferentes conjuntos de dados. Dentre as diversas medidas propostas na literatura, o coeficiente *Kappa* (CONGALTON; GREEN, 2009) é usualmente adotado. O cálculo destas medidas é geralmente efetuado com base em amostras distribuídas sobre a imagem, no interior de alvos bem definidos e conhecidos *a priori*. Com isso, estima-se que a exatidão calculada sobre tais amostras reflita a exatidão a respeito da imagem classificada.

Uma forma alternativa de avaliar resultados de classificação é através da quantificação da acurácia nas bordas de objetos classificados. Esta avaliação torna-se importante, por exemplo, nas aplicações que necessitam de informações precisas a respeito da delimitação entre regiões identificadas por intermédio de procedimentos de classificação de imagens.

Este trabalho propõe uma nova medida para avaliação de classificação em bordas de objetos. Um estudo de caso sobre a classificação do uso e cobertura do solo em uma região da Amazônia a partir de uma imagem do sensor ALOS-PALSAR é apresentado. Neste estudo, diferentes resultados de classificação, contextuais e insensíveis ao contexto, obtidas com uso do método

Máquina de Vetores Suporte (SVM - *Support Vector Machine*) são comparados através do coeficiente *Kappa* e da nova medida proposta, denominada por coeficiente *Upsilon*.

2. O Coeficiente Upsilon

Independentemente dos métodos e dados utilizados, a acurácia dos resultados de classificação devem ser analisadas, para que então seja possível julgá-los confiáveis ou não. Ao longo dos anos, diferentes medidas de acurácia tem sido desenvolvidas, podendo cada uma ser mais relevante que outra diante um objetivo particular (LIU; FRAZIER; KUMAR, 2007). Dentre as diversas medidas de concordância, uma das mais utilizadas é o coeficiente *Kappa*.

Nas aplicações em sensoriamento remoto, é usual que o cálculo das medidas de acurácia seja realizado com base em amostras de “verdades terrestre” localizadas no interior de regiões referentes as classes temáticas mapeadas. Uma forma alternativa de avaliar resultados de classificação é através da quantificação da acurácia nas bordas de objetos (regiões) da imagem classificada.

Este trabalho introduz uma medida de quantificação de acurácia em bordas. A motivação da medida, denominada Coeficiente *Upsilon* (Υ), é quantificar não só a quantidade de pixels classificados corretamente nas bordas, como também a fidelidade com relação à posição das bordas nos resultados de classificação.

O termo “bordas” é definido como a transição entre duas classes temáticas. Pixels localizados em bordas correspondem aos pixels que compõem a região de uma dada classe e possuem algum pixel vizinho que faz parte de outra região, relativa a outra classe. Baseado nesta definição, um *conjunto de pixels de borda* é composto por pixels associados a duas classes diferentes e estão localizados nas bordas entre tais classes.

O desenvolvimento da medida de avaliação parte de um resultado de classificação e de um conjunto de pixels de borda, composto por z_1 pixels referentes a uma dada classe ω_1 e z_2 pixels referentes a ω_2 . São denotados por v_1 e v_2 a quantidade de elementos do conjunto de pixels de borda classificados corretamente, com relação as classes ω_1 e ω_2 , respectivamente. Por sua vez, \bar{v}_1 e \bar{v}_2 representam as quantidades classificadas incorretamente, com relação às classes ω_1 e ω_2 , respectivamente, tal que $\bar{v}_1 = z_1 - v_1$ e $\bar{v}_2 = z_2 - v_2$. Baseado nestas quantidades, é formulada a seguinte expressão:

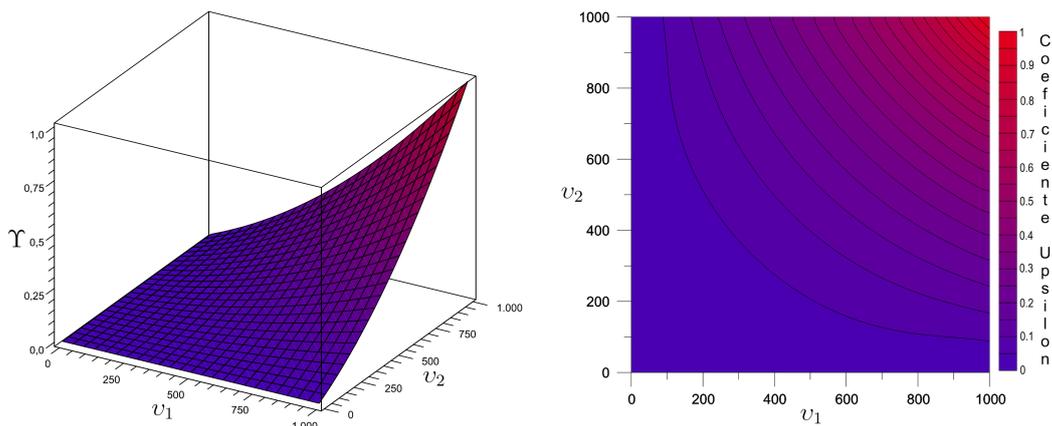
$$\Upsilon = \frac{\left(1 - \frac{\bar{v}_1}{z_1}\right) \cdot \left(1 - \frac{\bar{v}_2}{z_2}\right) \cdot (v_1 + v_2)}{z_1 + z_2}. \quad (1)$$

Na expressão (1) os fatores $\left(1 - \frac{\bar{v}_1}{z_1}\right)$ e $\left(1 - \frac{\bar{v}_2}{z_2}\right)$ atuam como ponderadores no cálculo da medida, fazendo com que ao aumentar o número de classificações incorretas, seja com relação a classe ω_1 ou ω_2 , menor será o valor de Υ . Em termos práticos, estes fatores impedem que o valor resultante de Υ possa depender apenas do percentual de classificações corretas em ω_1 ou ω_2 .

Com algumas manipulações algébricas em (1) é obtida a seguinte expressão equivalente, em função apenas dos valores z_1 , z_2 , v_1 e v_2 :

$$\Upsilon = \frac{v_1 \cdot v_2 \cdot (v_1 + v_2)}{z_1 \cdot z_2 \cdot (z_1 + z_2)}. \quad (2)$$

Na Figura 1 são mostrados dois gráficos que ilustram o comportamento do coeficiente *Upsilon* em função de diferentes valores de v_1 e v_2 , para z_1 e z_2 ambos iguais a 1000. É possível verificar na Figura 1(a) que $\Upsilon \rightarrow 0$ quando $v_1 \rightarrow 0$ ou $v_2 \rightarrow 0$; por outro lado, $\Upsilon \rightarrow 1$ quando $v_1 \rightarrow z_1$ e $v_2 \rightarrow z_2$, simultaneamente. O gráfico da Figura 1(b) é uma representação da superfície apresentada na Figura 1(a), na forma de curvas de nível.



(a) Comportamento do coeficiente *Upsilon* (b) Comportamento do coeficiente *Upsilon* representado em curvas de nível

Figura 1: Gráfico do coeficiente *Upsilon*, considerando dois conjuntos com 1000 pixels em cada classe.

3. Classificação Pontual e Contextual de Imagens com SVM

Máquina de Vetores de Suporte (*Support Vector Machine - SVM*) é um método de Reconhecimento de Padrões que tem se tornado popular desde sua introdução. Este método tem recebido grande atenção por parte da comunidade científica devido a características como: algoritmo de arquitetura simples, complexidade computacional moderada, boa capacidade de generalização e robustez perante o fenômeno de Hughes (BRUZZONE; PERSELLO, 2009).

O conceito central deste método visa a distinção entre padrões através de hiperplanos cuja margem de separação é máxima. Um hiperplano de separação equivale ao lugar geométrico onde a seguinte função discriminante torna-se nula:

$$f(\mathbf{x}) = \langle \mathbf{w}, \mathbf{x} \rangle + b \tag{3}$$

sendo \mathbf{w} o transposto do vetor ortogonal ao hiperplano de separação $f(\mathbf{x}) = 0$ e b é um escalar real tal que $|b|/\|\mathbf{w}\|$ representa a distância entre o hiperplano e a origem do espaço de atributos.

Os parâmetros \mathbf{w} e b que determinam o hiperplano de margem máxima são obtidos com a resolução do seguinte problema de otimização quadrática, com base nos padrões do conjunto de treinamento $\mathcal{D}_l = \{(\mathbf{x}_i, \omega_j) : i = 1, \dots, m; j = 1, 2\}$ (THEODORIDIS; KOUTROUMBAS, 2008):

$$\begin{aligned} \max_{\lambda} L_D(\lambda) &= \sum_{i=1}^m \lambda_i - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m \lambda_i \lambda_j y_i y_j \langle \mathbf{x}_i, \mathbf{x}_j \rangle \\ \text{sujeito a: } &\begin{cases} 0 \leq \lambda_i \leq C, i = 1, \dots, m \\ \sum_{i=1}^m \lambda_i y_i = 0 \end{cases}, \end{aligned} \tag{4}$$

onde λ_i são multiplicadores de Lagrange, $y_i = \{-1, +1\}$ são indicadores da classe de \mathbf{x}_i , e o parâmetro C , introduzido para o tratamento de casos não linearmente separáveis, atua como um limitante superior para os valores de λ_i . Sendo $SV = \{\mathbf{x}_i : \lambda_i \neq 0; i = 1, \dots, l\}$, o conjunto de vetores suporte, o parâmetro \mathbf{w} é computado por $\sum_{\mathbf{x}_i \in SV} \lambda_i y_i \mathbf{x}_i$, já b equivale a $1 - \langle \mathbf{w}, \mathbf{x} \rangle$ para $\mathbf{x}_i \in SV$ tal que $f(\mathbf{x}_i) = 1$.

Com a determinação de $f(\mathbf{x})$, um dado padrão \mathbf{x}_i é classificado na classe ω_1 desde que $f(\mathbf{x}_i) \geq 0$, ou na classe ω_2 quando $f(\mathbf{x}_i) < 0$. Nestas condições, o método SVM é capaz de realizar a classificação de padrões entre apenas duas classes. A aplicação deste método em problemas que abrangem mais que duas classes faz necessário o emprego de estratégias multiclasses, por exemplo, a estratégia Um-Contra-Todos (*One-Against-All - OAA*). O produto

interno $\langle \mathbf{x}_i, \mathbf{x}_j \rangle$ presente no problema (4) pode ser substituído por funções simétricas $k(\mathbf{x}_i, \mathbf{x}_j)$ que atendam as condições do Teorema de Mercer, denominadas funções *kernel* (SCHÖLKOPF; SMOLA, 2002). Dentre diversas, a função *kernel* polinomial, $k(\mathbf{x}_i, \mathbf{x}_j) = (\langle \mathbf{x}_i, \mathbf{x}_j \rangle + 1)^p$, com $p \in \mathbb{R}^*$, é comumente utilizada nas aplicações em sensoriamento remoto.

De acordo com o estudo apresentado em Mountrakis, Im e Ogole (2011), a grande maioria das pesquisas científicas que utilizam SVM na classificação de imagens de sensoriamento remoto adotam a abordagem pontual, isto é, a classificação da imagem é realizada a partir da classificação individual de cada um de seus pixels. As informações utilizadas no processo de classificação referem-se aos atributos dos pixels, sem necessariamente considerar a informação de sua vizinhança espacial. Em especial, os métodos baseados em pixels capazes de incorporar a informação da vizinhança espacial no processo de classificação são denominados “contextuais”.

Os métodos pontuais tendem a produzir resultados de classificação com menores níveis de exatidão, quando comparados aos contextuais. Por outro lado, a dilatação dos alvos identificados na imagem classificada é um efeito colateral comum dos métodos contextuais.

Uma simples forma de derivar uma versão contextual do método SVM é através da adoção de técnicas de suavização. Estas técnicas incluem a aplicação de filtros sobre os rótulos da imagem classificada e a incorporação de bandas adicionais, tais como medidas de textura, antes do processo de classificação pontual. Aplicação do Filtro da Moda sobre um dado resultado de classificação pontual é uma forma de suavização comumente adotada. A principal característica deste processo é a homogeneização¹ do resultado de classificação pontual. Tratando-se de um filtro, o aumento da dimensão da janela espacial que define a região de influência implica na produção de classificações contextuais mais homogêneas. Outra característica relevante é o baixo custo computacional exigido.

Outra versão contextual de SVM pode ser obtida pela integração deste método em uma arquitetura MRF (*Markovian Random Field* - Campos Aleatórios Markovianos), através do algoritmo ICM (*Iterative Conditional Modes* - Modas Condicionais Iterativas). De modo sucinto, esta integração é realizada com a transformação da regra de decisão do método SVM, originalmente baseada na relação de distância entre padrões ao hiperplano de separação, em distribuições de probabilidade, segundo o método proposto em Platt (2000). Posteriormente, as distribuições de probabilidade são inseridas nos algoritmos ICM (BESAG, 1986).

Neste trabalho, a integração entre SVM e ICM será denotada por SVM+ICM. A aplicação do Filtro da Moda como técnica de suavização será denotado por SVM+Moda($u \times v$), sendo $u \times v$ a dimensão da região de influência de tal filtro. Maiores discussões sobre SVM+ICM e SVM+Moda são encontrados em (NEGRI, 2013).

4. Experimento Realizado

Para a realização deste estudo foi empregado um extrato de 600×600 pixels de dimensão de uma imagem adquirida em 13 de Março de 2009 pelo sensor PALSAR, a bordo do satélite ALOS, sobre uma região no entorno da Floresta Nacional do Tapajós, no Estado do Pará. Esta imagem possui aproximadamente 20m de resolução espacial nas polarizações HH, HV e VV, em amplitude. Dentre os diferentes tipos de cobertura da terra existentes na cena, foram identificadas amostras de Floresta Primária, Regeneração, Pastagem, Agricultura e Solo Exposto. A Figura 2 identifica o extrato da imagem ALOS-PALSAR considerada neste experimento, assim como as respectivas amostras empregadas no treinamento dos métodos e na avaliação (teste) dos resultados de classificação. A quantidade de pixels que compreendem as amostras de treinamento e teste são apresentadas na Tabela 1.

Ainda, são ilustradas na Figura 2 três conjuntos de pixels localizados nas bordas de regiões

¹Redução ou eliminação do efeito “sal e pimenta”.

entre as classes Floresta Primária e Solo Exposto; Pastagem e Floresta Primária; e Agricultura e Floresta Primária. A seleção destes pixels foi realizada a partir da análise visual da imagem. O objetivo da seleção destes pixels é quantificar a acurácia dos resultados gerados pelos métodos analisados com relação à classificação das bordas a partir do uso do coeficiente *Upsilon*. A quantidade de pixels utilizados para avaliar a classificação nas bordas das regiões consideradas é apresentada na Tabela 2.

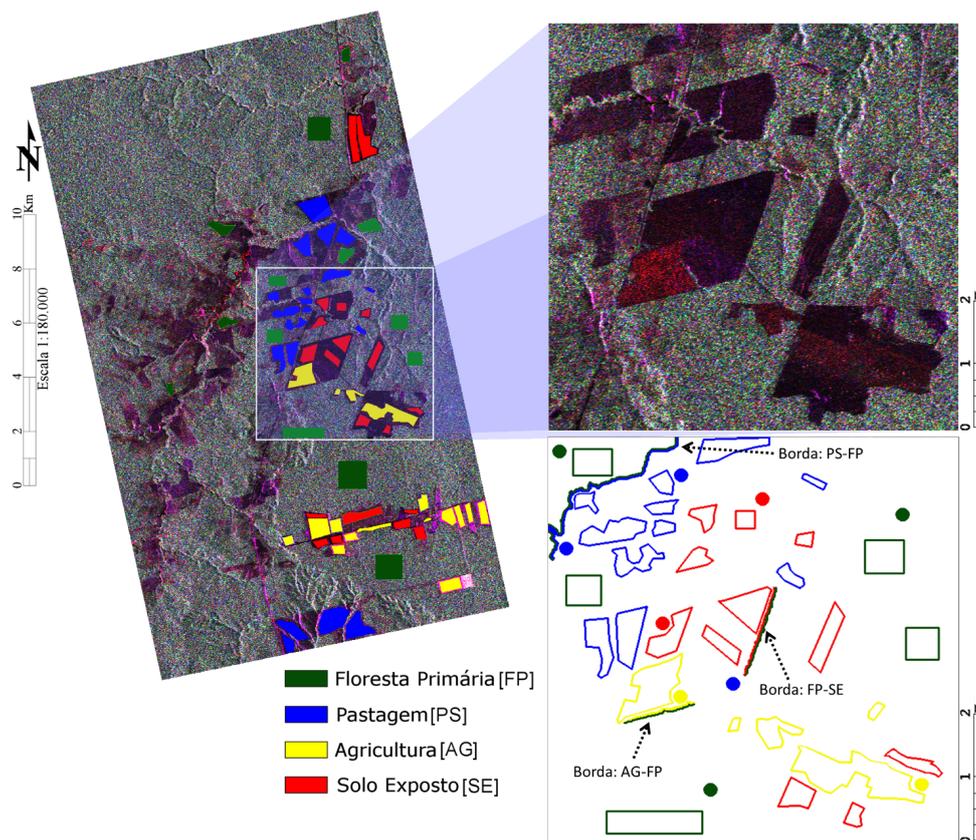


Figura 2: Extrato da imagem ALOS PALSAR contendo as amostras de treinamento (círculos cheios) e de validação (polígonos vazios), e os pixels selecionados para avaliação das classificações nas bordas entre regiões de diferentes classes.

Tabela 1: Amostras de treinamento e validação.

Classes	Quantidade de pixels	
	Treinamento	Teste
Floresta Primária	768	14136
Agricultura tipo	512	14678
Pastagem	768	14395
Solo Exposto	512	14207

A imagem considerada neste estudo foi classificada pelos métodos SVM, SVM+ICM e SVM+Moda. Cabe mencionar que a estratégia multiclases OAA e a função *kernel* polinomial foram adotadas. A seleção dos parâmetros penalidade (C) e grau (p) do *kernel* polinomial foi efetuada a partir de um procedimento de Busca Exaustiva, indicando que os valores de C e p mais adequados ao problema são 1000 e 3, respectivamente. A respeito do método SVM+Moda,

Tabela 2: Quantidade de pixels selecionados para verificar a acurácia nas bordas entre regiões de diferentes classes.

<i>Bordas</i>	<i>Quantidade de pixels</i>
Floresta Primária/Solo Exposto (FP-SE)	314/343
Pastagem/Floresta Primária (PS-FP)	804/720
Agricultura/Floresta Primária (AG-FP)	276/242

foram empregadas janelas espaciais de dimensão 3×3 , 5×5 e 7×7 para definir a região de influência do Filtro da Moda. Os resultados de classificação são apresentados na Figura 3.

As acurácias das classificações obtidas pelos métodos considerados neste estudo foram medidas segundo os coeficientes *Kappa* e *Upsilon*. Estas medidas foram calculadas segundo as amostras (regiões e bordas) identificadas na Figura 2. Os gráficos da Figura 4 comparam os desempenhos dos diferentes métodos segundo as medidas *Kappa* e *Upsilon*.

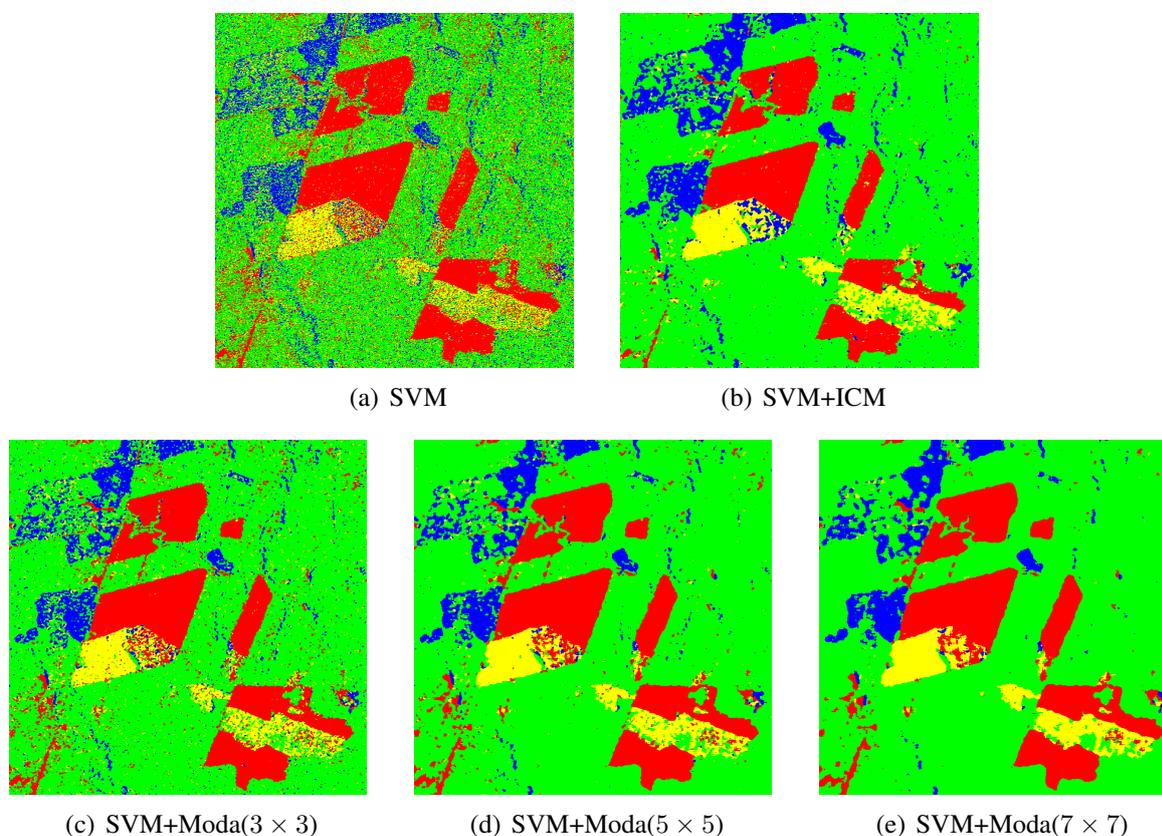


Figura 3: Classificações obtidas pelos métodos SVM, SVM+ICM e SVM+Moda.

Inicialmente, como esperado, nota-se que os métodos SVM+ICM e SVM+Moda proporcionaram resultados de classificação mais homogêneos em comparação ao SVM. Este comportamento é refletido diretamente nos valores do coeficiente *Kappa*, como mostra o gráfico da Figura 4(a). A aplicação do teste de hipóteses, para comparação entre os valores de *Kappa* entre classificações (CONGALTON; GREEN, 2009), revela, com 90% de confiança, que os resultados obtidos pelos métodos SVM+ICM e SVM+Moda(7×7) são estatisticamente iguais. Adotando ainda o mesmo nível de confiança, verifica-se que SVM+ICM possui acurácia estatisticamente superior às demais classificações.

Por outro lado, quando a avaliação passa a ser baseada na acurácia sobre as bordas das regiões consideradas, verifica-se que o método SVM+ICM produz resultados mais acurados em

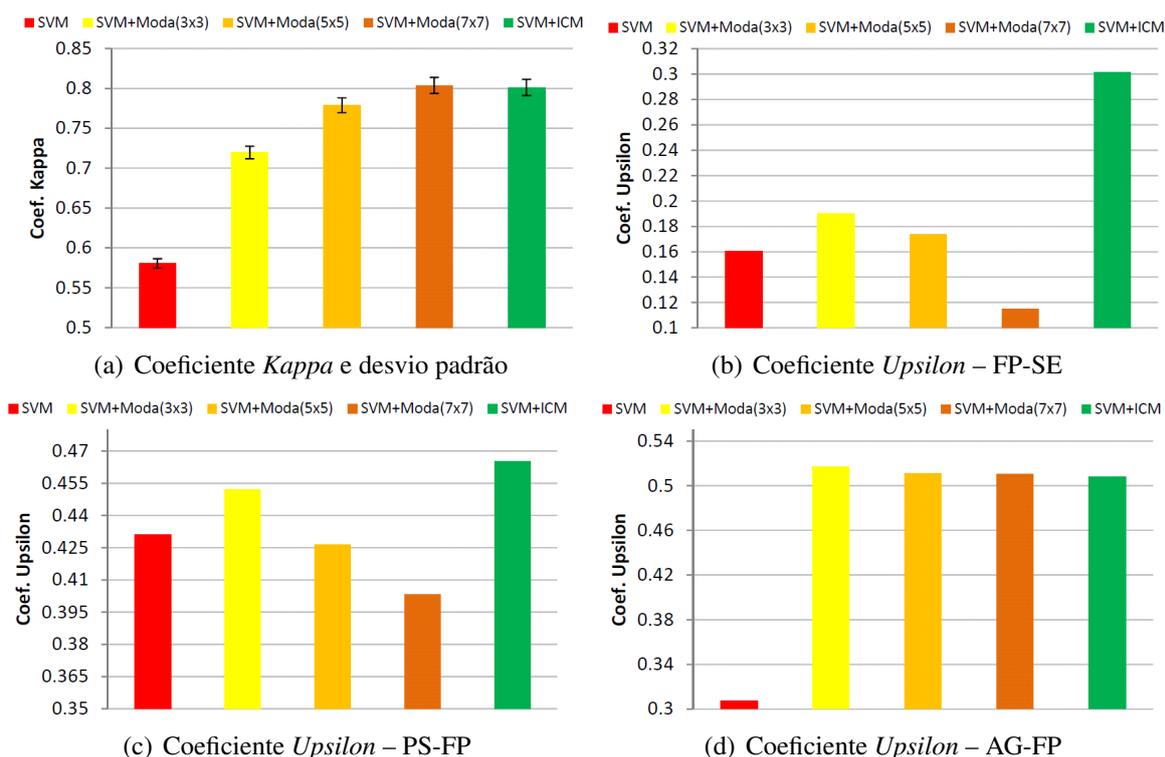


Figura 4: Gráfico dos coeficientes *Kappa* e *Upsilon* obtidos a partir das imagens classificadas.

comparação ao SVM e SVM+Moda nos casos das bordas entre regiões de Floresta Primária e Solo Exposto (Figura 4(b)), e entre Floresta Primária e Pastagem (Figura 4(c)); e apresenta ainda resultados semelhantes ao SVM+Moda nas bordas entre regiões de Floresta Primária e Agricultura (Figura 4(d)).

Dessa forma, o método SVM+ICM foi ainda capaz de melhorar a classificação no interior das regiões (homogeneização) como também melhorou a classificação nas bordas, ao contrário de SVM+Moda, que apesar de homogeneizar as regiões, em alguns casos causou a degradação das bordas das regiões.

Cabe observar ainda que os incrementos na dimensão da região de influência do Filtro da Moda provoca em todos os casos (menor intensidade entre Floresta Primária e Agricultura) uma queda gradativa na acurácia sobre bordas. Tal comportamento já é esperado, uma vez que quanto maior é a dimensão deste filtro, maior é o efeito de dilatação causado.

5. Conclusões

Neste trabalho foi proposta uma nova medida para acurácia de classificação, denominada Coeficiente *Upsilon*. Ao contrário de medidas usualmente empregadas nas aplicações em sensoriamento remoto, o Coeficiente *Upsilon* é específico para avaliação da acurácia das classificações nas bordas entre regiões.

Para verificar a aplicação da nova medida proposta, foi realizado um estudo de caso sobre a classificação do uso e cobertura do solo em uma região amazônica, utilizando uma imagem do sensor PALSAR, o método SVM e suas versões contextuais SVM+ICM e SVM+Moda. Os resultados mostraram que o Coeficiente *Upsilon* proporciona uma forma diferenciada de avaliar resultados de classificação, e ainda, seu uso combinado com outro coeficiente de acurácia pode proporcionar uma análise mais apurada dos resultados. Através do uso conjunto dos coeficientes *Kappa* e *Upsilon*, foi possível verificar que o método SVM+ICM apresenta vantagens sobre

SVM+Moda.

Como perspectiva futura, pretende-se desenvolver estudos a fim de determinar uma medida de desvio para o Coeficiente *Upsilon*.

Agradecimentos

Os autores agradecem à FAPESP (proc. 2014/14830-8), CNPQ (proc. 151571/2013-9) e CAPES pelo auxílio financeiro.

Referências

- BESAG, J. On the statistical analysis of dirty pictures. *Journal of the Royal Statistical Society*, B-48, p. 259–302, 1986.
- BRUZZONE, L.; PERSELLO, C. A novel context-sensitive semisupervised SVM classifier robust to mislabeled training samples. *IEEE Transactions on Geoscience and Remote Sensing*, v. 47, n. 7, p. 2142–2154, 2009.
- CONGALTON, R. G.; GREEN, K. *Assessing the accuracy of remotely sensed data: principles and practices*. Boca Raton: CRC Press, 2009. 183 p. ISBN 978-1-4200-5512-2.
- LIU, C.; FRAZIER, P.; KUMAR, L. Comparative assessment of the measures of thematic classification accuracy. *Remote Sensing of Environment*, v. 107, n. 4, p. 606 – 616, 2007.
- MOUNTRAKIS, G.; IM, J.; OGOLE, C. Support Vector Machines in Remote Sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing Society*, v. 66, n. 3, p. 247–259, 2011.
- NEGRI, R. G. *Máquina de Vetores de Suporte Adaptativa ao Contexto: formalização e aplicações em Sensoriamento Remoto*. 166 p. Tese (Doutorado) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2013.
- PANTALEÃO, E.; SCOFIELD, G. B. Comparação entre medidas de acurácia de classificação para imagens do satélite alos. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14. (SBSR). *Anais...* São José dos Campos: Instituto Nacional de Pesquisas Espaciais (INPE), 2009. p. 7039–7046. ISBN 978-85-17-00044-7.
- PLATT, J. C. Probabilistic outputs for Support Vector Machines and comparisons to regularized likelihood methods. In: SMOLA, A. et al. (Ed.). Cambridge: MIT Press, 2000. p. 61–74. ISBN 9780262194488. *Advances in Large Margin Classifiers*.
- SCHÖLKOPF, B.; SMOLA, A. J. *Learning with kernels : support vector machines, regularization, optimization, and beyond*. [S.l.]: MIT Press, 2002. (Adaptive computation and machine learning).
- THEODORIDIS, S.; KOUTROUMBAS, K. *Pattern Recognition*. 4th. ed. San Diego: Academic Press, 2008. 984 p. ISBN 9781597492720.