

Comparação entre os Classificadores Máxima Verossimilhança, SVM e Rede Neural MLP para Uso e Cobertura da Terra em Parcela da FLONA Tapajós e Arredores

Mariane Souza Reis¹

¹ Instituto Nacional de Pesquisas Espaciais - INPE
Caixa Postal 515 - 12227-010 - São José dos Campos - SP, Brasil
reis@dsr.inpe.br

Abstract. The available tools to classify an image have grown in the last years, with the development of more efficient algorithms and computer technology. This paper aims to evaluate the performance of two supervised classifiers using different parameters, Support Vector Machine and MLP based Neural Net, when compared with Maximum likelihood, on an image from Landsat5 satellite's sensor Thematic Mapper. The study area is located in a parcel and surroundings of Floresta Nacional do Tapajós, in which there is forest in different stages, new and old regeneration and agriculture. The respective Kappa coefficient was validated using a hypothesis test with 5% of significance. It was defined six classes of land use and land cover associated with Primary Forest and Primary Forest in Exploration, Degraded Forest, Old Regeneration and Intermediate Regeneration, Initial Regeneration, Prepared Soil for Agriculture and Soybean with 100 days from sowing, Pasture and Soybean with 40 days from sowing. Although SVM has showed good results, it was statistically similar to maximum likelihood. Neural Network has showed statistically inferior or equal results, but demanded more time, process capacity and is more difficult, due the necessity to choose more parameters. It was concluded that future investigations are needed to achieve the optimum classification using the chosen algorithms.

Palavras-chave: remote sensing, image processing, pattern recognition, sensoriamento remoto, processamento de imagens, reconhecimento de padrões.

1. Introdução

Imagens adquiridas por sensoriamento remoto têm mostrado potencial para fornecer dados sobre diferentes variáveis ambientais, uma vez que é possível utilizar diferentes sensores para registrar a radiação eletromagnética refletida ou emitida por diversos alvos, em diferentes resoluções espaciais, temporais, radiométricas ou espectrais (JENSEN, 2009). Para Crosta (1999), a distinção e identificação de diferentes materiais da superfície terrestre é um dos principais objetivos do sensoriamento remoto, sendo que o produto dessa atividade é muitas vezes uma imagem classificada.

Uma classificação consiste em organizar objetos entre classes que os diferenciem por determinada qualidade (TAN et al., 2009) e pode ser enquadrada em três categorias: supervisionada, não supervisionada e semi-supervisionada. Na primeira, os dados de treinamento para as classes escolhidas são selecionados pelo usuário, de forma que a classificação seja realizada a partir de informações conhecidas. Na classificação não supervisionada, as classes são definidas segundo o algoritmo e critérios do classificador, sem a influência do usuário na classificação. Para a classificação semi-supervisionada, adicionam-se dados de treinamento para classes conhecidas, mas são classificadas também classes não pré-definidas que devem ser rotuladas pelo usuário (THEODORIDIS e KOUTROUMBAS, 2009).

Dentre os classificadores supervisionados, o de máxima verossimilhança está entre os mais populares, juntamente com redes neurais (HUANG et al., 2002). O Classificador de Máxima Verossimilhança (MaxVer) é um classificador paramétrico, baseado no teorema de Bayes, que avalia a probabilidade condicional de cada classe supondo que os atributos sejam incondicionalmente independentes, dado o rótulo da classe a priori. São considerados robustos para os pontos de ruídos isolados e para atributos irrelevantes, sendo que atributos correlacionados podem degradar o desempenho, porque a suposição de independência condicional deixa de ser verdadeira para esses atributos (TAN et al., 2009).

Segundo Huang et al. (2002), Redes Neurais Artificiais (*Artificial Neural Network -ANN*) evitam alguns dos problemas dos MaxVer por adotar uma aproximação não paramétrica. Uma ANN é constituída de um conjunto interconectado de nodos e ligações direcionais. O mais simples e mais utilizados modelo de ANN é o perceptron multicamadas (*Multi-layer Perceptron – MLP*), devido à sua habilidade de manipular qualquer tipo de dados numéricos e sua liberdade em relação à suposição de distribuição estatística dos dados (PAL e MATHER, 2003). No entanto, a escolha da arquitetura da rede pode ser difícil, pela quantidade de parâmetros exigidos.

Uma técnica de classificação que tem recebido atenção nos últimos anos é a Máquina de Vetores Suporte (*Support Vector Machine – SVM*), que segundo Huang et al. (2002) representam um grupo teoricamente superior de algoritmos de aprendizado de máquina. O SVM emprega algoritmos de otimização para localizar os limiares ótimos entre as classes, de forma que a inclusão de novas amostras tenha o menor erro possível, assim diminuindo a confusão entre as classes (HUANG et al., 2002). Este limite de decisão acaba sendo o hiperplano de margem máxima das instâncias de treinamento (TAN et al., 2009). Trabalhos comparando classificações entre MaxVer, ANN e SVM (HUANG et al., 2002; PAL e MATHER, 2003) encontraram maiores valores de precisão para classificação de uso e cobertura da terra quando utilizaram SVM, ainda que utilizando diferentes parâmetros.

Nesse sentido, este trabalho visa comparar e avaliar a classificação de uso e cobertura da terra para uma parcela da Floresta Nacional (FLONA) do Tapajós e arredores, utilizando MaxVer, ANN e SVM em diferentes arquiteturas, sendo o último utilizando kernel linear e RBF (Radial Bases Function), por serem os mais comumente utilizados e de simples sintonia dos parâmetros.

2. Metodologia de Trabalho

2.1. Materiais

Nesta seção serão descritos a área de estudo, os materiais e a metodologia utilizada para o trabalho.

2.1.1. Área de estudo

A área de estudo se localiza na Amazônia brasileira, abrangendo parte do município de Belterra e uma pequena área de Santarém, ambos no estado do Pará, mesorregião do Baixo Amazonas (Figura 1).

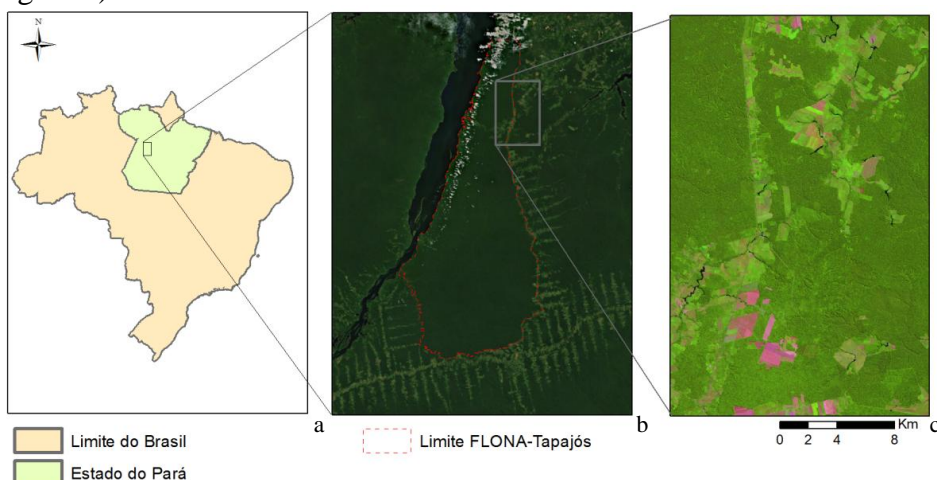


Figura 1- Área de estudo. a) Localização no Brasil e no Estado do Pará; b) Limites da Flona; c) Área de Estudo, composição colorida 5(R)4(G)3(B) da imagem LANDSAT5/TM, órbita/ponto 227/62 de 29 de junho de 2010.

Segundo Guimarães e Pyle (1999), a região possui clima dominante AmW (chuvas do tipo monção) de acordo com a classificação de Köppen, com duas estações bem definidas,

uma seca e outra chuvosa, com as chuvas predominantemente entre dezembro e maio, sendo que a temperatura média do mês mais frio não é menor que 18°C.

A vegetação da FLONA é do tipo Floresta Ombrófila Densa, caracterizada por árvores de grande porte, lianas lenhosas, palmeiras e epífitas, com árvores emergentes em relevo ondulado, platôs dissecados e áreas submontanas, ao sul (ESCADA et al., 2009) e o terreno possui constituição de superfície plana com partes levemente acidentadas (GUIMARÃES; PYLE, 1999).

Segundo Aragão (2004), o processo de ocupação ocorreu ao longo da BR-163, com a abertura de estradas vicinais para estabelecer pequenas propriedades rurais após o desmatamento das áreas de floresta primária. Há também mosaicos de vegetação secundária, em diversos estágios, pastagens e áreas cultivadas inseridas em uma matriz de floresta primária. O sistema de produção característico da região do Tapajós consiste no plantio em pequenas áreas de culturas de mandioca, milho, feijão e arroz e principalmente soja (ARAGÃO, 2004). Segundo Escada et. al (2009), a região é considerada como área de alto risco de febre aftosa. Como não é permitida a exportação de gado vivo para outras áreas, a comercialização deste e da carne bovina fica restrita ao mercado local não sendo comuns áreas de pasto para criação de gado.

2.2 Metodologia

Para atingir o objetivo de estudar e avaliar os resultados obtidos por diferentes configurações de SVM e ANN, quando comparados com máxima verossimilhança para o mapeamento do uso e cobertura da terra na área de estudo, foram utilizadas as imagens correspondentes às bandas 1 a 5 e 7 de uma imagem do sensor *Thematic Mapper* (TM) do satélite Landsat5, da órbita-ponto 227/62 (Sistema WRS), de 29 de junho de 2010, adquiridas pelo catálogo do Instituto Nacional de Pesquisas Espaciais (INPE) (Figura 1c). Segundo Jensen (2009), estas imagens possuem resolução espacial nominal de 30 metros, resolução radiométrica de 8 bits e sete bandas espectrais, sendo 3 na região do visível, 1 no infravermelho próximo, 2 no infravermelho médio e 1 no infravermelho distante. Foram utilizados também um computador e os softwares ENVI 4.8 e Microsoft Excel.

As etapas foram: 1) Determinação das classes; 2) Seleção e sorteio de amostras de treinamento e validação; 3) Classificação da imagem pelos métodos de Máxima Verossimilhança (MaxVer), Máquina de Vetores Suporte (SVM) e Rede Neural baseada em MLP (Multi Layers Perceptron); 4) Cálculo das matrizes de confusão, Índice Kappa e Índice de Exatidão Global; 5) Teste de hipótese unilateral para os Índices Kappa, para 95% de confiança que o valor do índice é estatisticamente diferente de 0 e que o Índice 1 é maior que o índice 2, a 5% de significância.

As classes analisadas foram baseadas nos resultados obtidos por Pereira (2012). Para cada classe, foram coletados dois conjuntos de amostras, sendo que foram sorteados de forma aleatória, sem repetição, 200 pontos de cada classe do primeiro conjunto para o treinamento do algoritmo. Este procedimento foi repetido para o segundo grupo, o grupo de teste, para o cálculo da matriz de confusão e índice Kappa

No ENVI 4.8, testaram-se os classificadores de Máxima Verossimilhança, sem limiar mínimo de probabilidade, SVM Linear (com custo em 0,1; 1; 10; 100; 1000 e 10000), SVM RBF (com todas as combinações com custo igual a 0,1; 1; 10; 100 e 1000 e gama igual a 0,001; 0,01; 0,1; 1 e 10) e ANN com modelo de ativação logístico, cujos parâmetros variados estão descritos na Tabela 1.

Tabela 1 – Variações do ANN adotados para a classificação no ENVI 4.8.

Sigla	T.T.C.	T.R.	T.M.	T. RMS E.C.	# H.L.	# N.T.I.	MIN O.A.T.
ANN0 (default)	0,9	0,2	0,9	0,1	1	1000	0,0
ANN1	0,9	0,2	0,1	0,1	1	1000	0,0
ANN2	0,9	0,1	0,1	0,1	1	1000	0,0
ANN3	0,9	0,1	0,1	0,1	2	1000	0,0
ANN4	0,5	0,1	0,1	0,1	1	1000	0,0
ANN5	0,4	0,1	0,1	0,1	1	1000	0,0
ANN6	0,3	0,1	0,1	0,1	1	1000	0,0
ANN7	0,2	0,1	0,1	0,1	1	1000	0,0
ANN8	0,1	0,1	0,1	0,1	1	1000	0,0
ANN9	0,1	0,1	0,1	0,1	2	1000	0,0
ANN10	0,1	0,1	0,1	0,1	4	4000	0,0
ANN11	0,005	0,1	0,1	0,1	3	1000	0,0
ANN12	0,2	0,1	0,1	0,1	3	1000	0,0

Onde: T.T.C. = *Training Threshold Contribution*; T.R.= *Training Rate*; T.M. = *Training Momentum*; T. RMS E.C. = *Training RMS Exit Criteria*; # H.L. = *Number of Hidden Layers*; #N.T.I. = *Number of Training Iteration* e MIN O.A.T. = *Min Output Activation Threshold*.

3. Resultados e Discussão

3.1 Determinação das classes

As classes determinadas encontram-se descritas na Tabela 3. A localização das amostras de treinamento e validação encontra-se na Figura 2.

Tabela 2 - Classes utilizadas para classificação do uso e cobertura da terra da área de estudo.

Classes	Descrição	Número de pixels (treinamento)	Número de pixels (validação)
FP e FPE	Floresta primária, não modificada por atividade humana.	5 256	5 535
	Floresta primária em exploração, com desmatamento seletivo.		
FD, RA e Rint	Floresta degradada sofreram atividades de fogo	4 937	2 823
	Regeneração antiga, floresta secundária em regeneração há mais de 20 anos		
	Florestas secundárias com 8 a 20 anos de regeneração		
RI	Regeneração inicial, Florestas secundárias em regeneração há menos de 20 anos	789	231
PA	Pasto Sujo	1 396	594
	Agricultura Pousio de 7 a 24 meses		
	Pasto Limpo		
	Pasto Limpo com Babaçu e Inajá		
SP e S100	Solo Preparado para Agricultura ou em pousio após a colheita	1620	445
	Soja pronta para a colheita, com aproximadamente 100 dias da semeadura.		
S40	Soja com aproximadamente 40 dias da semeadura	825	209

Fonte: Pereira (2012) (modificado).




Figura 2 – Amostras coletadas. Imagem em escala de cinza, banda 5 da Imagem Landsat5/TM. a) localização das amostras de treinamento; b) localização das amostras de validação.

3.2 Classificações

Os valores dos índices kappas para SVM Linear encontram-se na Tabela 3, para SVM RBF na Tabela 4 e para ANN na Tabela 5. O Índice Kappa para MaxVer foi de 0,7470.

Tabela 3 - Tabela de valores do índice kappa para SVM Linear.

Custo	Kappa
0,1	0,7530
1	0,7640
10	0,7740
100	0,7600
1000	0,7600
10000	0,7500

Para SVM Linear, os valores de kappa se alteram conforme varia o custo, sendo que um custo igual a 10 apresenta um limite seletivo o bastante para isolar as classes, diminuindo a confusão, mas abrangente o suficiente para permitir uma boa generalização, com a entrada de novos dados.

Tabela 4 - Valores do índice kappa para classificações utilizando SVM RBF.

Custo	Gama				
	0,001	0,01	0,1	1	10
0,1	0,7160	0,7160	0,7160	0,7160	0,7740
1	0,7160	0,7160	0,7160	0,7160	0,7160
10	0,7730	0,7730	0,7730	0,7730	0,7160
100	0,7650	0,7650	0,7650	0,7650	0,7730
1000	0,7740	0,7740	0,7740	0,7160	0,7650

Observa-se que para SVM RBF, um maior custo ou maior gama não estão diretamente relacionados com um maior valor de kappa, sendo que para um custo menor (0,1), um

aumento do valor de gama é pouco expressivo. O valor de gama ganha mais importância para custos mais altos.

Nas diferentes arquiteturas de ANN, nota-se uma melhora com a diminuição do valor de *Training Treshold Contribution*, responsável por ajustar mudanças para o peso dos nós. O aumento do número de camadas escondidas também mostrou bons resultados, mas apenas quando este peso interno é menor (cerca de 0,1). Um maior número de camadas também exige maior número de iterações quando os demais parâmetros se mantêm constantes, exigindo mais tempo de processamento.

Tabela 5 - Valores dos índices Kappas para ANN.

Classificação	Kappa
ANN0	0.7690
ANN1	0.7680
ANN2	0.7640
ANN3	0.7400
ANN4	0.7630
ANN5	0.7640
ANN6	0.7630
ANN7	0.7670
ANN8	0.7670
ANN9	0.7720
ANN10	0.7610
ANN11	0.7710
ANN12	0.7700

Alguns exemplos da imagem classificada se encontram na Figura 3.

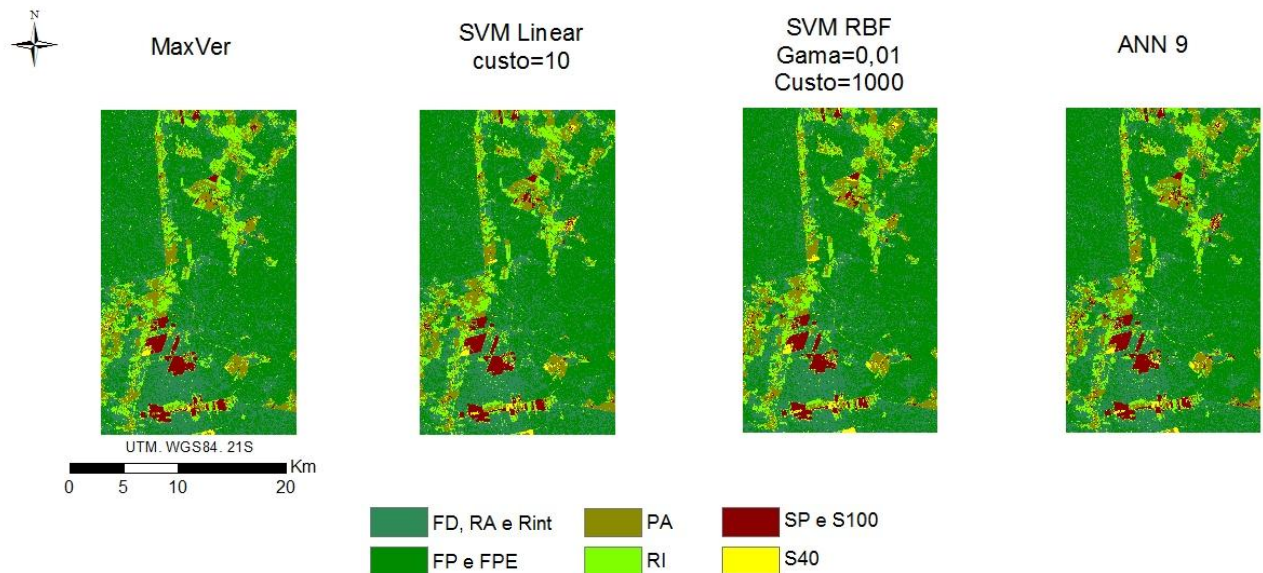


Figura 3 - Exemplos de imagens classificadas obtidas.

O teste de hipótese revelou que todos os kappas obtidos são estatisticamente iguais ao obtido por MaxVer. Todas as classificações por ANN são iguais entre si, para o conjunto de validação adotado, sendo que as classificações obtidas pela ANN3 foram as que possuíram os piores resultados, sendo igual às outras classificações por ANN e inferior aos SVM RBF com custo 10 ou custo 100, para qualquer gama, e SVM Linear com custo 10. Esse efeito

provavelmente se dá pelo fato de um maior custo tornar o modelo mais rigoroso, mas também com menor capacidade de generalização.

4. Conclusões

O classificador SVM se mostrou eficiente para a área de estudo, mas para os dados avaliados não há diferença significativa quanto comparado com o MaxVer. Redes Neurais não se mostraram muito eficientes, levando-se em conta tanto o resultado final, quanto a dificuldade na sintonia dos parâmetros quanto o tempo de processamento. Enquanto o SVM, em outros trabalhos, se mostrou bastante eficiente e capaz de lidar com uma alta dimensionalidade de dados, para os dados utilizados neste trabalho há a necessidade de uma investigação mais completa e meticulosa dos parâmetros utilizados.

Agradecimentos

Ao Instituto Nacional de Pesquisas Espaciais pelas instalações e equipamentos. À Luciana de Oliveira Pereira pela disponibilização dos dados utilizados em sua dissertação. Ao Dr. Luciano Vieira Dutra pelas orientações iniciais. Ao Dr. Guaraci José Erthal, pelo esclarecimento de dúvidas e o empenho na procura dos parâmetros ótimos para os classificadores.

Referências Bibliográficas

ARAGÃO, L. E. O. C. Modelagem dos padrões temporal e espacial da produtividade primária bruta na região do Tapajós: uma análise multi-escala. 2004. 286 p. (INPE-11423-TDI/951). **Tese** (Doutorado em Sensoriamento Remoto). Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2004.

CROSTA, A.P. Processamento Digital de Imagens de Sensoriamento Remoto. Campinas: IG/UNICAMP. 1999.

ESCADA, M. I. S.; AMARAL, S.; RENNÓ, C. D.; PINHEIRO, T. F. **Levantamento do uso e cobertura da terra e da rede de infraestrutura no distrito florestal da BR- 163**. São José dos Campos: INPE, 2009. 52 p. (INPE-15739-RPQ/824). Disponível em: <<http://urlib.net/sid.inpe.br/mtc-m18@80/2009/04.24.14.45>>. Acesso em 05 jun 2012.

GUIMARÃES, E.G.T.; PYLE, E.H. 1999. **Levantamento florestal de 20 ha na Floresta Nacional do Tapajós**. LBA, Santarém, Pará. 30pp.

HUANG, C.; DAVIS, L. S.; TOWNSHEND, J. R. G. An assessment of support vector machines for land cover classification. **International Journal of Remote Sensing**, v. 23, n. 4, p. 725-749, 2002.

JENSEN, J.R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos: Parêntese. 2009. 598p.

OLIVEIRA, J. A.; DUTRA, L. V.; RENNÓ, C. D. Aplicação de métodos de extração e seleção de atributos para classificação de regiões. **Anais XII Simpósio Brasileiro de Sensoriamento Remoto**, Goiânia, p. 4201-4208, 2005.

PAL, M.; MATHER, P.P. Support Vector classifiers for Land Cover Classification. **Map India 2003: Image Processing & Interpretation**. Map India conference. 2003. Disponível em: <<http://arxiv.org/ftp/arxiv/papers/0802/0802.2138.pdf>>. Acesso em 10 jun 2012.

PEREIRA, L.O.P. Avaliação de Métodos de Integração de Imagens Ópticas e Radar para Classificação do Uso e Cobertura da Terra na Região Amazônica. 2012. 271p. **Dissertação** (Mestrado em Sensoriamento Remoto). Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2012.

TAN, P.; STEINBACH, M.; KUMAR, V. **Introdução ao Data Mining: Mineração de Dados**. Rio de Janeiro: Editora Ciência Moderna Ltda., 2009.

THEODORIDIS, S.; KOUNTROUMBAS, K. **Pattern Recognition**. Canada: Academic Press, 2009. 961p.