

COMPARAÇÃO ENTRE OS CLASSIFICADORES SUPPORT VECTOR MACHINE E SPECTRAL ANGLE MAPPER APLICADO À DIFERENCIAÇÃO DAS FITOFISIONOMIAS DO PARQUE ESTADUAL DO ARAGUAIA (MT)

COMPARISON OF CLASSIFIER SUPPORT VECTOR MACHINE AND SPECTRAL ANGLE MAPPER APPLIED ON DIFFERENTIATION OF VEGETATION TYPES IN STATE PARK ARAGUAIA (MT)

Italo Luiz Corrêa Lenzi

Universidade Federal de Mato Grosso PPGCFA/UFMT

lenziilc@gmail.com

Gustavo Manzon Nunes

Professor, Faculdade de Engenharia Florestal FENF/UFMT

gustavomn@gmail.com

Resumo

A identificação e discriminação das diferentes fitofisionomias é uma das alternativas mais viáveis para o planejamento de ações de manejo, conservação e monitoramento em Unidades de Conservação (UC). O objetivo deste trabalho foi avaliar os classificadores digitais *Support Vector Machine* (SVM) e *Spectral Angle Mapper* (SAM) na caracterização de fitofisionomias existentes no Parque Estadual do Araguaia (PEA), localizado no município de Novo Santo Antônio, sendo delimitada pela confluência do Rio das Mortes e do Rio Araguaia. Através dos classificadores SVM e SAM foram processadas as imagens do sensor ASTER (*Advanced Spacebone Thermal Emission and Reflection Radiometer*). A coleta das amostras de treinamento para a geração das classificações digitais abrangeu as classes: água, campos de murundus, ipucas, monchão, cerradão, cerrado *stricto sensu*, bancos de areia e solo exposto. As amostras coletadas serviram de treinamento para os dois algoritmos. No algoritmo SVM foram utilizadas três opções de kernel. No algoritmo SAM foram utilizados dois valores de alfa (α). Com base no índice Kappa constatou-se que o algoritmo SVM obteve maior precisão na diferenciação das fitofisionomias, obtendo maior precisão no mapeamento.

Palavras-chave: Sensoriamento Remoto, Classificação Supervisionada, Tipologias Florestais

ABSTRACT

The identification and discrimination of different vegetation types are essential activities for the study of impacts of human activities, one of the most viable alternatives for planning management actions, conservation and monitoring in protected areas (UC). The objective of this study was to evaluate the digital classifier Support Vector Machine (SVM) and the Spectral Angle Mapper (SAM) in the characterization of existing vegetation types in the Araguaia State Park (PEA), in the municipality of Novo Santo Antonio, being bounded by the confluence of the Death River and Araguaia River. Through the SVM classifiers and SAM were processed images ASTER (*Advanced Thermal Emission and Reflection Spacebone Radiometer*). The collection of training samples to generate the digital classifications comprehended the classes: water, mounds fields, Ipucas (forest fragments located in depressions that favors its flooding), monchão (high ground of island covered with savannah species), savanna, cerrado, shoals and bare soil. The samples provided the training for the two

algorithms. In SVM algorithm were used three kernel options. In the SAM algorithm were used two alpha values (α). Based on the Kappa index was found that the SVM algorithm obtained more precise differentiation of vegetation types, obtaining greater accuracy in the mapping.

Keywords: Remote Sensing, Supervised Classification, Forest Type

INTRODUÇÃO

No território brasileiro encontramos inúmeros ecossistemas, associados a seis biomas distintos, estando assim entre os países com a maior diversidade de vida no planeta. Dentro deste contexto, as unidades de conservação representam uma das melhores estratégias de proteção ao patrimônio natural.

O Mato Grosso tem papel fundamental, no contexto geográfico da região Amazônica, destacando-se por sua extensão territorial, dispondo de uma superfície de 906.068,078 Km², com porções dos três importantes biomas brasileiros: Floresta Amazônica (52%), Cerrado ou Savana (41%) e Pantanal (7%), representando um elo de transição entre estes biomas. Basicamente apresenta dois tipos de clima, ao norte Equatorial e do centro ao sul o Tropical que lhe conferem um mosaico de vegetação que vai do florestal ao campestre. Distinguem como suas principais categorias fitoecológicas as formações: Floresta Ombrófila Densa, Floresta Ombrófila Aberta, Floresta Estacional Semidecidual, Cerrado e Áreas de Tensão Ecológica (contato entre tipos de vegetação) comumente denominada Ecótonos. Juntamente com esta diversidade e os atributos de caráter físico que enriquecem sua diversidade, abriga ainda nascentes de três importantes bacias hidrográficas: Platina, Amazônica e Araguaia-Tocantins (SONODA, 2004).

O Parque Estadual do Araguaia encontra-se na região da bacia Araguaia-Tocantins, inserido no Bioma Cerrado, que representa 23% do território brasileiro, tratando-se do segundo maior Bioma do país em área. O Cerrado é considerado um dos hotspots mundiais, isto é, um dos biomas mais ricos e ameaçados do planeta (MITTERMEIER et al., 1999). Porém a composição florística e as fitofisionomias presente na planície do Araguaia são pouco conhecidas, restringindo-se a levantamentos exploratórios como o executado pelo RADAMBRASIL (1981).

Para o mapeamento da cobertura vegetal é importante a avaliação da performance de algoritmos de classificação como neste caso o *Spectral Angler Mapper*(SAM) e *Support Vector Machine*(SVM). Nesta abordagem orientada a pixel, foram testados os algoritmos SAM e SVM, que apresentam a capacidade de aprendizado em sistemas complexos e lidam

com a resolução de interações não lineares na distinção de classes de objetos e frações de tipologias de cobertura da terra em imagens de satélite (LEHNERT et al., 2015; FERREIRA et al., 2016).

Vários estudos visando a análise da performance de algoritmos podem ser evidenciados, como o monitoramento do desmatamento e degradação em florestas tropicais (ASNER et al., 2009), diferenciação da cobertura florestal utilizando dados do sensor Hyperion (VYAS et al., 2011), uso em dados multiespectrais de alta e média resolução para detecção de mortalidade de árvores causada por besouros (HART & VEBLEN, 2015).

Com o crescente uso da tecnologia existente em Sensoriamento Remoto e suas aplicações o presente trabalho tem por objetivo determinar um algoritmo capaz de diferenciar com robustez e eficácia as fitofisionomias existentes no Parque Estadual do Araguaia (PEA), possibilitando no final a elaboração de um Mapa Temático visando a discriminação da cobertura vegetal, contribuindo no conhecimento da localização, distribuição espacial e geográfica de cada fitofisionomia.

MATERIAL E MÉTODOS

O PEA é o maior parque do estado do Mato Grosso, criado em 2001 pela Lei Estadual nº 7.517, o parque possui área total de 223.169,5 hectares e está inserido na categoria de Unidade de Proteção Integral, de acordo com o Sistema Nacional de Unidades de Conservação (SNUC, 2000). Localizado na região nordeste do estado entre as Latitudes 11° 45' S a 12° 38' S e Longitudes 50° 37' W a 50° 59' W, sua extensão é de aproximadamente 95 km, distância entre o extremo norte (encontro do Rio das Mortes com o Rio Araguaia) até o extremo sul. Inserido na zona de contato entre o Cerrado e a Floresta Amazônica, apresentando extensas áreas de campos sazonalmente inundados, denominados campos de murundus, complexos de Cerrado/Cerradão, Mata inundável (Ipucas) e Mata Seca (MARIMON & LIMA, 2001; RATTER et al; 2003).

As imagens provenientes do sensoriamento remoto vêm servindo como base para estudos e levantamentos geológicos, ambientais, agrícolas, cartográficos, florestais, urbanos, entre outros. Além disso, essas imagens passaram a representar uma das únicas formas viáveis para realizar monitoramentos ambientais tanto em escalas locais como em globais já que são produzidas com rapidez, eficiência e periodicidade (SOUSA, 2009).

Técnicas de classificação de imagens implicam na implementação de um processo de decisão para que o computador possa atribuir certo pixel a uma classe (NOVO, 1989).

Segundo Iwai (2003), são gerados neste processo, mapas temáticos ou cartas temáticas correspondentes aos temas de interesse, de acordo com critérios bem definidos. Cada pixel da imagem original é classificado em alguma das classes ou temas definidos e representado por símbolos gráficos ou cores. A maioria dos classificadores baseia-se exclusivamente na detecção da assinatura espectral de classes de cobertura do solo. Neste caso, para que a classificação seja bem sucedida, é necessário que as assinaturas espectrais dos alvos sejam bem definidas e distintas entre si.

Sensor ASTER (*Advanced Spaceborne Thermal Emission and Reflection Radiometer*)

O ASTER (*Advanced Spaceborne Thermal Emission and Reflection Radiometer*) foi lançado em dezembro de 1999, a bordo do satélite TERRA, como parte do programa EOS (*Earth Observing System*). Com o seu lançamento iniciou-se uma nova e promissora era do sensoriamento remoto orbital de recursos terrestres. Sua principal missão é de monitoramento ambiental e suas imagens apresentam uma série de aplicações em relação ao uso e ocupação da terra, destacando-se a classificação do uso e da intensidade de uso da terra (ZHU et al., 2002); confecção e atualização de mapas; monitoramento do desenvolvimento das cidades; monitoramento de projetos de desenvolvimento regionais; mapeamento de redes viárias; investigação do tráfego e das rotas de transporte e exame das medições de enchentes em regiões próximas ao nível do mar (ABRAMS & HOOK, 2002).

O ASTER possui 14 bandas espectrais, sendo composto por três subsistemas de imageamento independentes que coletam dados em várias porções do espectro eletromagnético: três bandas com resolução de 15m, cobrindo as faixas espectrais do visível (*Visible - VIS*), entre 0,52 e 0,69 μm , e infravermelho próximo (*Near infrared - NIR*), de 0,78 a 0,86 μm ; seis bandas, com 30m de resolução, posicionadas no infravermelho de ondas curtas (*Short Wave Infrared - SWIR*) de 1,60 a 2,43 μm , e cinco bandas com 90m de resolução, no infravermelho termal (*Thermal infrared - TIR*), entre 8,125 e 11,65 μm .

Utilizou-se de informações oriundas do Sensor ASTER, sendo três cenas correspondentes ao PEA, onde se procedeu a realização das etapas de pré-processamento descritas a seguir:

- *Correção Atmosférica*: os dados da cena original ASTER (L1B) foram convertidos para reflectância a partir de procedimentos de correção atmosférica, com a utilização do modelo de transferência radiativa *Moderate Resolution Atmospheric Radiance and Transmittance Model* (MODTRAN), tendo por base parâmetros regionais. As seguintes

condições de imageamento foram consideradas no modelo utilizado: (i) elevação média da região de estudo, (ii) altitude da plataforma, (iii) data da passagem, (iv) níveis de aerossóis (visibilidade), (v) coordenadas da área, (vi) quantidade de vapor d'água na atmosfera e (vii) modelo atmosférico (tropical) (ACORN, 2002). Previamente à correção atmosférica, as bandas SWIR do ASTER foram submetidas à correção do efeito *crosstalk* utilizando o *crosstalk correction software* (ERSDAC, 2003). O efeito *crosstalk* ocorre devido a dispersão da luz incidente na banda ASTER 4, a qual é transportada para o plano focal de outras bandas do SWIR, causando o aparecimento de “fantasmas” na interface entre superfícies de terra e água (IWASAKI & TONOOKA, 2005).

- *Reamostragem espacial de pixels*: dada a diferença de resolução espacial entre as bandas do VIS-NIR (15m) e do SWIR (30m), e visando o aproveitamento de ambos os conjuntos de bandas, foi realizada uma reamostragem das bandas do SWIR, aumentando artificialmente sua resolução para 15m, permitindo, assim, a composição de um conjunto de dados com nove bandas espectrais. Essa reamostragem é fundamental para etapas de processamento posteriores.

De modo a possibilitar a diferenciação das fitofisionomias presentes no PEA através dos algoritmos SAM (*Spectral Angler Mapper*) e SVM (*Support Vector Machine*) foram coletadas amostras de treinamentos das classes; Água, Bancos de Areia, Solo Exposto, Cerradão, Cerrado *Strictu Sensu*, Ipucas, Monção e Varjão; através destas amostras de treinamento e a fim de comparação entre os algoritmos gerou-se a biblioteca espectral com a média da reflectância para cada classe em cada banda do sensor, gerando a curva espectral característica de cada classe. Pois ambos os algoritmos baseiam-se na característica espectral do pixel para a sua diferenciação das demais classes

Classificação Supervisionada

O aprendizado de máquina está inserido na área de conhecimento denominada Inteligência Artificial (IA) e têm por objetivo desenvolver métodos, técnicas e ferramentas para construir máquinas inteligentes capazes de realizar as mais diversas tarefas. De acordo com Mitchell (1997), essas máquinas devem treinar sobre determinado conjunto de amostras e adquirir conhecimento de forma automática. As técnicas de aprendizado podem ser classificadas em supervisionadas (em que os rótulos das classes são previamente conhecidos e o algoritmo de aprendizado recebe um conjunto de exemplos de treinamento para cada classe) e não supervisionadas (em que os rótulos das classes não são conhecidos e o algoritmo de aprendizado procura formar agrupamentos ou clusters dos dados de entrada). Como exemplo

de algoritmos de aprendizado de máquina pode-se citar os que têm como inspiração os sistemas biológicos (Redes Neurais Artificiais (RNAs) e Algoritmos Genéticos), o aprendizado simbólico (Árvores de Decisão) e as teorias estatísticas (Support Vector Machines) (MITCHELL, 1997).

Nos métodos de classificação supervisionada, as classes são previamente definidas pelo analista, isto é, definidas ou caracterizadas através das amostras de treinamento. Os métodos pertencentes a este tipo de classificação utilizam algoritmos que realizam o reconhecimento dos padrões espectrais na imagem com base nessas amostras (MOREIRA, 2005). Os algoritmos SAM e SVM pertencentes a classificação supervisionada e foram utilizados nas experiências práticas deste trabalho.

Support Vector Machine (SVM)

Uma SVM é basicamente uma máquina linear, cuja ideia principal é constituir um hiperplano como superfície de decisão de tal forma que a margem de separação entre exemplos positivos e negativos seja máxima (HAYKIN, 1999). Este método foi desenvolvido pelo pesquisador Vladimir Vapnik e colaboradores (BOSER *et al.* 1992; CORTES & VAPNIK, 1995; VAPNIK, 1995).

O treinamento da SVM envolve a resolução de um problema quadrático, dependente dos vetores de treinamento e de parâmetros especificados pelo usuário. Neste método, a partir de um espaço de entrada de padrões não-linearmente separáveis é formado um novo espaço de características, em dimensão outra onde os padrões serão linearmente separáveis. Assim, um hiperplano de separação ótimo entre os exemplos é construído (VAPNIK, 1995).

O algoritmo pode ser descrito da seguinte forma: dadas 'D' amostras de treinamento $\{x_i, y_i\}$, com $i=1, 2, \dots, D$, onde $x_i \in \mathbb{R}^M$ é uma representação vetorial de um conjunto e $y_i \in \{-1, 1\}$ é sua classe associada. Nesse processo existe uma distribuição de probabilidade $P(x, y)$ desconhecida da qual os dados de treinamento serão retirados. Ou seja, o processo de treinamento consiste em treinar um classificador de forma que este aprenda um mapeamento $x \rightarrow y$ por meio de exemplos (classes) de treinamento $\{x_i, y_i\}$ de forma que a máquina seja capaz de classificar um exemplo (x, y) ainda não visto que siga a mesma distribuição de probabilidade (P) dos exemplos de treinamento.

O diferencial da SVM consiste em minimizar a expectativa de erro $\epsilon(\zeta)$ em uma classificação tal que $\epsilon(\zeta)$ é dado por:

$$\varepsilon(\zeta) = \int \frac{1}{2} |y - f(x, \zeta)| dP(x, y)$$

Equação 1




Figura 1- Esquema de classificação por meio do SVM, modificado de Huang et al. (2002) e Melgani e Bruzzone (2004).

O SVM possui quatro funções, sendo elas (i) linear, (ii) quadrática ou sigmoide, (iii) polinomial e (iv) função de base radial (FBR).

Spectral Angler Mapper (SAM)

O algoritmo de classificação supervisionada *Spectral Angle Mapper*, baseia-se na comparação do espectro da imagem com um espectro de referência, proveniente de bibliotecas espectrais ou de membros finais das imagens. A comparação é realizada por um critério de similaridade e, dessa forma, a identificação do material procurado é feita segundo o ajuste obtido entre as duas curvas espectrais. Quanto melhor for o ajuste, maior será a probabilidade da existência do material de referência no pixel da imagem. Basicamente, procura-se identificar a existência ou não do espectro de referência. A formulação matemática do SAM (KRUSE *et al.*, 1993) é oriunda da equação 2, sendo expressa na forma de ângulo e não de porcentagem.

$$SAM = \alpha = \cos^{-1} \frac{\sum_{i=1}^{nb} ER_i EI_i}{\sqrt{\sum_{i=1}^{nb} (EI_i)^2 \sum_{i=1}^{nb} (ER_i)^2}}$$

Desta forma, temos que o valor do SAM é expresso em radianos, sendo que, quanto menor o ângulo α , maior é a similaridade entre as curvas. O ângulo α , determinado pela função arco-cosseno apresenta uma variação de 0° até 90° .

Uma característica importante da SAM é que ela não é sensível à diferença de amplitude entre os espectros, e está relacionada somente com a forma do espectro (NOVO, 2008). A performance do algoritmo depende da escolha do conjunto de espectros de referência. Conforme mostrado na figura 2, os ângulos são tratados como vetores no espaço n-dimensional.




Figura 2 - Ilustração do ângulo espectral entre curvas de dois materiais diferentes (A e B) medidos pela técnica de mapeamento por ângulo espectral. Fonte: Guia do ENVI, Sulsoft (2006).

Validação do mapeamento

Um mapeamento seja ele de qualquer interesse, apoiado em sensoriamento remoto, necessita ser realizado com exatidão quando se deseja que as informações obtidas neste sejam confiáveis. Assim, parâmetros que indiquem que uma classificação quantificou determinada área próxima à realidade de seu uso são essenciais. A avaliação da acurácia pode ser obtida por meio dos coeficientes de concordância obtidos através de uma matriz de confusão. A matriz de erro ou matriz de confusão é uma matriz quadrada de números que expressam a quantidade de unidades amostrais, associada a uma dada categoria durante o processo de classificação efetuado, e à categoria real a que pertencem essas unidades. (MANGABEIRA, 2003 apud CONGALTON, 1991). A matriz de confusão restringe-se às linhas e colunas referentes às n classes. Os componentes da diagonal principal da matriz de confusão fornecem o número de pixels corretamente classificados para cada classe correspondente. A partir da

elaboração da matriz de confusão as seguintes medidas podem ser extraídas: Exatidão Global (EG), coeficiente de Kappa, dentre outros.

A Tabela 1, desenvolvida por Landis e Koch (1977), é utilizada como referência para classificar mapas resultantes da utilização de imagens provenientes do sensoriamento remoto. Na referida Tabela, são apresentados níveis de desempenho da classificação que indicam a qualidade do mapa temático de acordo com o valor de Kappa obtido.

Tabela 1–Valores de índice Kappa adotados para as classes temáticas estabelecidas

Valor de Kappa	Qualidade do mapa temático
<0,00	<i>Péssima</i>
0,00-0,20	<i>Ruim</i>
0,20-0,40	<i>Razoável</i>
0,40-0,60	<i>Boa</i>
0,60-0,80	<i>Muito boa</i>
0,80-1,00	<i>Excelente</i>

Adaptada de Landis e Koch (1977)

Para realizar a validação da classificação dos dados provenientes do sensoriamento remoto os autores utilizam o coeficiente de Kappa, como pode ser visto nos estudos de Nishida (1998) e Queiroz *et al* (2004).

Após as classificações gerou-se a matriz de confusão, possibilitando o cálculo do coeficiente Kappa, a fim de escolher a melhor classificação de cada algoritmo. As etapas do trabalho estão representadas no fluxograma abaixo (Figura 3).

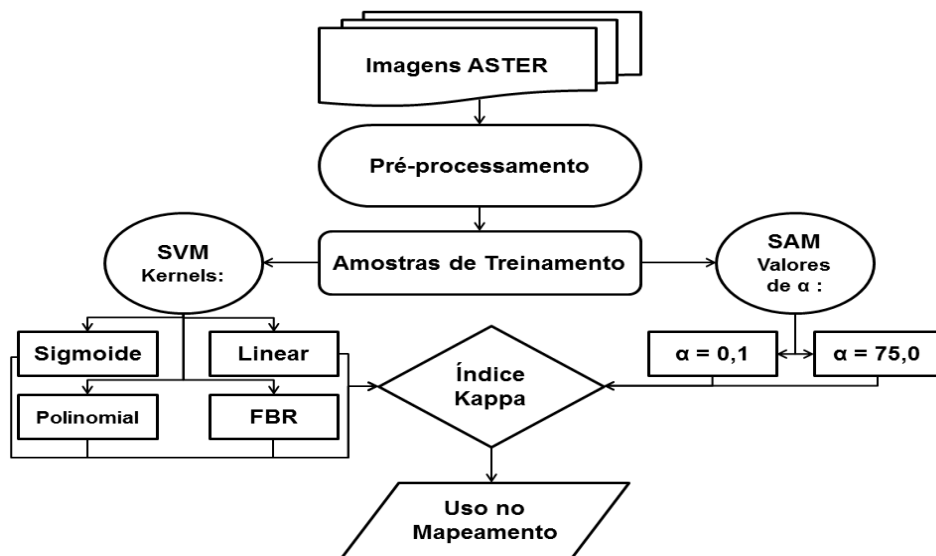


Figura 3 - Fluxograma das etapas de trabalho.

RESULTADOS E DISCUSSÃO

Os parâmetros internos utilizados e os resultados da validação do mapeamento utilizando o coeficiente Kappa extraídos da matriz de confusão estão descritos na tabela abaixo.

Tabela 2 – Parâmetros internos utilizados em cada algoritmo, (x) representa inexistência do parâmetro.

Parametro interno/Tipo de Função	SVM								SAM	
	Linear		Sigmoide		Polinomial		FBR		α = 0,1	α = 75,0
	Teste 1	Teste 2	Teste 1	Teste 2	Teste 1	Teste 2	Teste 1	Teste 2		
Grau de polinômio de kernel	x	x	x	x	2	2	x	x	x	
Bias na função	x	x	1	1	1	1	x	x		
Gama na função Kernel	x	x	0,11	1,50	0,11	1,50	0,11	1,50		
Parametro de Penalidade	100,00	1000,00	100,00	1500,00	100,00	1500,00	100,00	1500,00		
Níveis de Pirâmide	0	0	0	0	0	0	0	0		
Índice Kappa	0,9001	0,9002	0,8815	0,8815	0,8937	0,9063	0,9000	0,9001	0,5361	0,7001

Os valores ressaltados em verde indicam em cada algoritmo sua melhor configuração em termo de valores internos do Kernel para SVM e α para o SAM.

Os resultados das classificações após quantificação em área foram ilustrados no gráfico abaixo, onde é comparada a área total de cada classe por cada algoritmo.

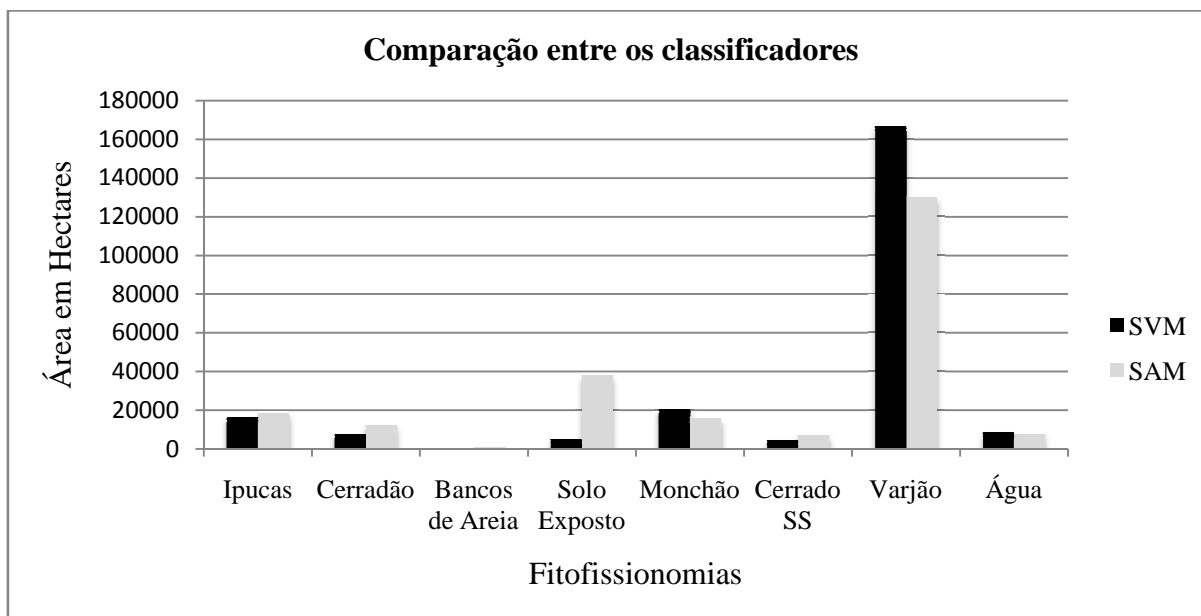


Gráfico 1 – Área em hectares por fitofisionomia classificada em cada algoritmo.

É possível concluir através de dados de levantamento de campo, que o algoritmo SAM confundiu uma área considerável de Varjão com Solo exposto, apresentando maior porção de Solo Exposto e menor porção em Varjão que o algoritmo SVM, isso pode ser explicado devido a resolução espacial do sensor ASTER, onde cada pixel representa uma área de 225 m², impossibilitando a diferenciação dessas formações que é composta por vários Monchões espaçados entre si, constituindo a classe Varjão.

O Varjão ou Campos de Murundus, segundo Araújo Neto et al. (1986), tem no Brasil Central o sentido de um campo úmido com “ilhas” de terra elevada, revestida com espécies de cerrado, denominadas de “murundus”, e estas ocorrem em um padrão regular.

Essas formações são denominadas pelos moradores da região do Araguaia de Varjão. Entretanto no meio científico, nas literaturas referentes a outras localidades do território brasileiro, elas também são denominadas de Campos de Murundus (MARIMON et al., 2008).

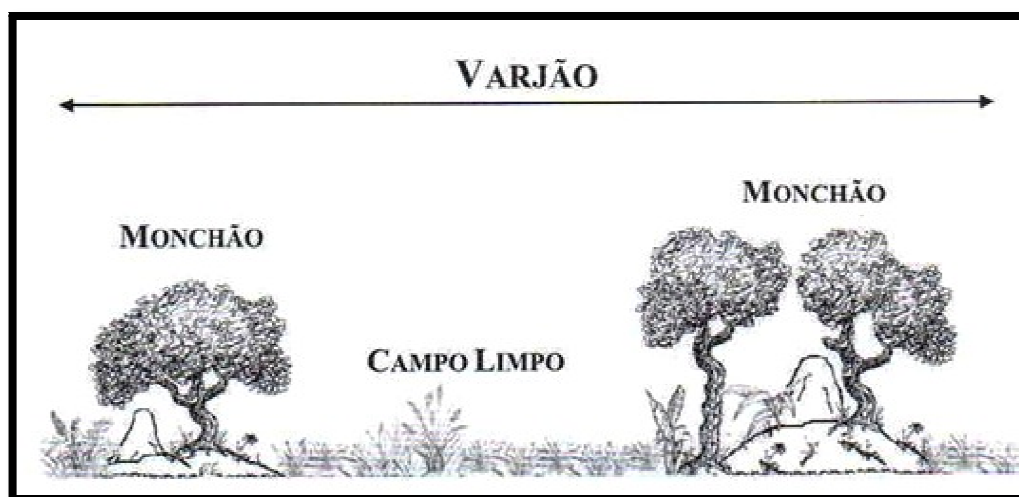


Figura 4 - Esquema geral de um varjão típico.
Fonte: Adaptado de Marimon et al. (2008)

A fonte de erro do algoritmo surge da mistura espectral causada por essa fitofisionomia, que apresenta diferentes densidades de murundus ao longo do PEA.

O gráfico demonstra a diferença de acurácia obtida entre os algoritmos SAM e SVM, de acordo com a Tabela 1, o algoritmo SAM encontra-se entre 0,60-0,80, sendo sua inserção na classe *Muito boa*, já o SVM encontra-se entre 0,80-1,00, sendo sua classificação Excelente e superior ao SAM, com pouca confusão entre a diferenciação das classes.

O resultado obtido foi o Mapa Temático do PEA que pode ser visualizado na Figura 5 abaixo, onde é possível distinguir cada fitofisionomia existente, sua localização e distribuição no interior do PEA.

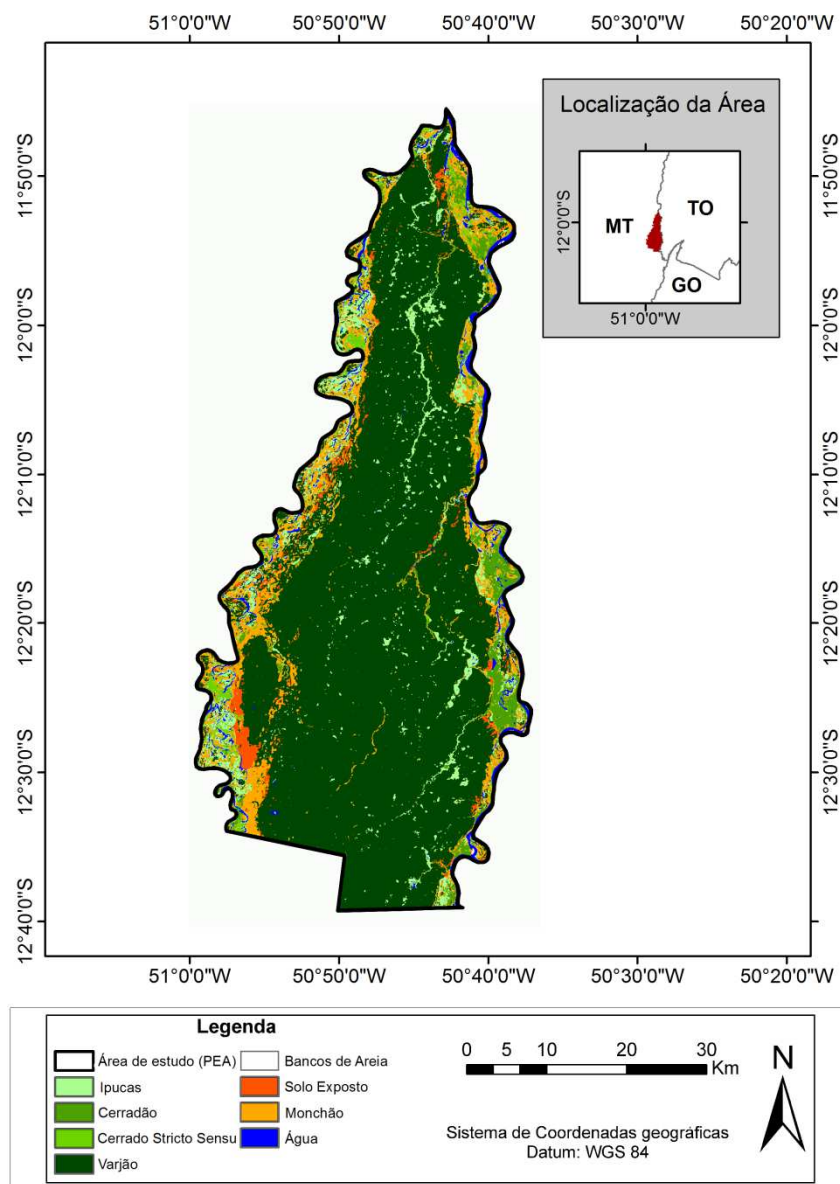


Figura 5 – Mapa Temático Do Parque Estadual do Araguaia gerado através do algoritmo SVM (*Support Vector Machine*).

CONCLUSÃO

Com base no coeficiente Kappa o algoritmo SVM apresentou maior acurácia na distinção das fitofisionomias, tendo ambos os algoritmos as mesmas amostras de treinamento. O SVM se apresentou como um ótimo algoritmo para aplicação em imagens de resolução espacial baixa a média, porém, o SAM se torna mais adequado em imagens hiperespectrais.

Na avaliação dos algoritmos o SVM neste caso apresentou melhor resultado, devido ao grande número de classes, em um estudo com menor número de classes o SAM pode apresentar vantagens em termos de menor número de amostras de treinamento e de menor

tempo para classificação, por ser um algoritmo mais simples, dispensando a análise estatística em seu processamento.

O algoritmo SVM demonstrou capacidade na discriminação das fitofisionomias de áreas sujeitas a inundação, como é o caso do Parque Estadual do Araguaia, em especial para as classes Solo Exposto e Varjão, onde a diferenciação é dificultada devido a mistura espectral.

REFERÊNCIAS

ABRAMS, M. E.; HOOK, S. J. **Aster User Handbook: Advanced Spaceborne Thermal Emission and Reflection Radiometer**. USA: NASA/Jet Propulsion Laboratory California Institute of Technology, 2, 2002. 135 p.

ACORN. **ACORN 4.0 tutorial**. (2002). EUA, AGI-Colorado, 2002. 109p.

ARAÚJO NETO, M. D. et al. The murundus of the Cerrado region of Central Brazil. **Jurnal of Tropical Ecology**, Cambridge: v. 2, p. 17-35, 1986.

ASNER, G.P.; KNAPP, D.; BALAJI, E.; PÁEZ-ACOSTA, A.G. Automated mapping of tropical deforestation and forest degradation: CLASlite. **Journal of Applied Remote Sensing** 3, 1–23. 2009.

BOSE, B.; GUYON, I; VAPNIK, V. N. A training algorithm for optimal margin classifiers. Annual Workshop on Computational Learning Theory, Pittsburgh. **Proceedings...San Mateo, CA: Morgan Kaufmann**, p. 144-152. 1992.

Brasil. Lei nº 9.985, de 18 de julho de 2000. **Institui o Sistema Nacional de Unidades de Conservação da Natureza – SNUC**. Brasília, DF, 2000.

CONGALTON, R.G.. A review of assessing the accuracy of classifications of remotely sensed data, **Remote Sensing of Environment**, 37: p 35-46. 1991.

CORTES, C.; VAPNIK, V. Support vector networks. **Machine Learning**. v. 20, n. 3, p. 273-297, 1995.

Earth Remote Sensing Data Analysis Center (ERSDAC). **The crostalk correction software user's guide**, 21 p. 2003.

FERREIRA, M. P. et al. Mapping tree species in tropical seasonal semi-deciduous forests with hyperspectral and multispectral data, **Remote Sensing of Environment**. v. 179, p. 66-78. 2016.

GUIA DO ENVI em Português, Sulsoft, 2006.

HART, S.J.; VEBLEN, T.T.. Detection of spruce beetle-induced tree mortality using high- and medium-resolution remotely sensed imagery. **Remote Sensing of Environment**. 168: 134–145, 2015.

HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. 2. ed. New Jersey, Prentice Hall, 1999. 842 p.

HUANG, J.; HU, R.; ZHANG, L.; ROZELLE, S. China's Agricultural Research Investment China Agricultural Press, Beijing, 2000. 105 p.

- IWAI, O. K. **Mapeamento do Uso do Solo Urbano no Município de São Bernardo do Campo, Através de imagens de Satélites**. Dissertação (Mestrado em Engenharia de Transportes) – Escola Politécnica da Universidade de São Paulo. São Paulo. 127 p. 2003.
- IWASAKI, A., & TONOOKA, H. Validation of a crosstalk correction algorithm for ASTER/SIWR. **IEEE transactions on Geoscience and Remote Sensing**, 43(12): p. 2747-2751,2005.
- KRUSE, F. A.; LEFKOFF, A. B.; and Dietz, J. B. Expert System-Based Mineral Mapping in northern Death Valley, California/Nevada using the Airborne Visible/Infrared Imaging Spectrometer (AVIRIS): **Remote Sensing of Environment**, Special issue on AVIRIS, v. 44, p. 309 - 336. 1993.
- LANDIS, J. R.; KOCH, G. C. The measurement of observer agreement for categorical data. **Biometrics**, v. 33, n. 1, p. 159-174, 1997.
- LEHNERT, L. W. et al.RetrievalofgrasslandplantcoverageontheTibetanPlateaubasedon a multi-scale, multi-sensorandmulti-method approach, **Remote SensingofEnvironment**, v. 164, p. 197-207,2015.
- MANGABEIRA, J. A. de. C., AZEVEDO, E. C. de, LAMPARELLI, R. A. C. **Avaliação do Levantamento do Uso das Terras por Imagens de Satélite de Alta e Média Resolução Espacial**. Campinas: Embrapa Monitoramento por Satélite, Comunicado Técnico 11. 16 p. 2003.
- MARIMON, B.S. & LIMA, E.S. Caracterização fitofisionômica e levantamento florístico preliminar no Pantanal dos Rios Mortes-Araguaia, Cocalinho, Mato Grosso, Brasil. **Acta Botânica Brasílica**, v.15, n.2, p.213-229. 2001.
- MARIMON, B.S. et al.**Pantanal do Araguaia – ambiente e povo: guia de ecoturismo**. Cáceres-MT: Editora UNEMAT,2008. 95 p.
- MELGANI, F.; BRUZZONE, L. Classification of hyperspectral remote sensing images with Support Vector Machines. **IEEE Transactions on Geoscience and Remote Sensing**, 42, p 1778 – 1790. 2004.
- MITCHELL, T. **Machine Learning**. New York: McGraw Hill, 1997. 414 p.
- MITTERMEIDER, R.; MYERS, N.; GIL, P.; MITTERMEIER, C. **Hotspots, earth's biologically richest and most endangered terrestrial ecoregions**. CEMEX/Cl. ToppanPrinting. 430p. 1999.
- MOREIRA, M. A. **Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação**. 3. Ed. Viçosa: UFV, 320 p. 2005.
- NISHIDA, W. **Uma Rede Neural Artificial para Classificação de Imagens Multiespectrais de Sensoriamento Remoto**. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal de Santa Catarina, Florianópolis, 1998.
- NOVO, E. M. L. M. **Sensoriamento Remoto, Princípios e Aplicações**; 2. Ed. São Paulo: EdgradBlucher LTDA., 269 p. 1989.
- NOVO, E.M.L.M. **Sensoriamento Remoto: Princípios e Aplicações**. 3 ed. São Paulo: Blucher, 2008.
- QUEIROZ, R. B.; SEVERINO, P. A. R.; RODRIGUES, A. T. U. Redes Neurais: Um Comparativo com Máxima Verossimilhança Gaussiana na Classificação de Imagens CBERS. In: WORKSHOP DE TECNOLOGIA DA INFORMAÇÃO APLICADA AO MEIO AMBIENTE, Itajaí. **Anais...** Universidade Vale do Itajaí: UVI, p. 746-749. 2004.

- RADAMBRASIL. **Levantamento de Recursos Naturais**. Ministério das Minas e Energia, 25, Folha SD-22/Goiás. 1981.
- RATTER, J. A .;BRIDGEWATER, S.; RIBEIRO, J. F. Analysis of the floristic composition of the brazilian cerrado vegetation III: Comparison of the woody vegetation of 376 areas. **Edinburgh J. Botany**.60 (1): 57-109. 2003.
- SONODA, F. A. A Fragilidade do sistema estadual de unidades de conservação o: o caso de Mato Grosso. In: CONGRESSO BRASILEIRO DE UNIDADES DE CONSERVAÇÃO. Curitiba. **Anais...**, 2004.
- SOUSA, B. F. S. **Aprendizado de Máquina Detecção do Uso do Solo no Bioma Caatinga Via Sensoriamento Remoto**. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Federal do Ceará, Fortaleza, 86 p. 2009.
- VAPNIK, V.N. **The Nature of Statistical Learning Theory**. New York, Springer-Verlag, 332 p. 1995.
- VYAS D.; KRISHNAYYAA, N.S.R.; MANJUNATHB, K.R.; Ray, S.S.; PANIGRAHY, S. Evaluation of classifiers for processing Hyperion (EO-1) data of tropical vegetation. **International Journal of Applied Earth Observation and Geoinformation**.13: 228–235, 2011.
- ZHU, G.; BLUMBERG, D. G. Classification using ASTER data and SVM algorithms; The case study of Beer Sheva, Israel. **Remote Sensing of Environment**. v 80 p 233– 240. 2002.

Recebido para publicação em 24/05/2016

Aceito para publicação em 06/06/2016