

## REDES NEURAIS APLICADAS AO ESTUDO DE FLORESTAS PRIMÁRIA E SECUNDÁRIA COM DADOS ESPECTRAL/TEXTURAL ALI/EO-1

### NEURAL NETWORKS APPLIED TO THE STUDY OF PRIMARY AND SECONDARY FORESTS WITH SPECTRAL/TEXTURAL ALI/EO-1 DATA

Ricardo Dal'Agnol da Silva<sup>1</sup>, Lênio Soares Galvão<sup>1</sup>, João Roberto dos Santos<sup>1</sup>

<sup>1</sup> Instituto Nacional de Pesquisas Espaciais - INPE, Av. dos Astronautas, 1758, 12.227-010 - São José dos Campos, SP, Brasil, {silvard, lenio, jroberto}@dsr.inpe.br

#### RESUMO

As sucessões secundárias são tipologias importantes para a manutenção da biodiversidade, regime hidrológico e sequestro de carbono. A utilização de métricas texturais GLCM pode colaborar na discriminação dessas classes por extrair a variabilidade espacial do dossel florestal. Assim sendo, também se faz necessária uma técnica como redes neurais artificiais para seleção dos atributos mais relevantes e integração desses dados. O objetivo do presente estudo foi de avaliar e comparar o uso de atributos espectrais ALI/EO-1 e métricas texturais GLCM utilizando a técnica de redes neurais artificiais *Multi-Layer Perceptron* para mapeamento da cobertura da terra na Floresta Nacional do Tapajós e arredores, com foco na discriminação das tipologias florestais primárias e sucessões secundárias. Observou-se que os atributos texturais mais relevantes foram a textura média das bandas 3, 4, 6, 7 e 8, e textura dissimilaridade da banda 8. Esses atributos, ao serem integrados aos dados espectrais em um conjunto híbrido, proporcionaram uma melhor discriminação entre as classes de NPV e solo, culturas agrícolas e SS1/SS2, SS1 e SS2, SS2 e SS3/FP. Dessa forma, as áreas de SS1, SS2, SS3 e FP puderam ser discriminadas com 89, 63, 62 e 83% de acurácia. Constatou-se exatidão global de 89% para a utilização dos dados híbridos contra 79% para dados somente espectrais.

**Palavras-chave:** Florestas tropicais, sucessões secundárias, redes neurais artificiais, ALI/EO-1, textura GLCM.

#### ABSTRACT

Secondary successions are important typologies for biodiversity maintenance, hydrological regimen, and carbon sequestration. The use of GLCM textural metrics can collaborate to discriminate these classes due to the extraction of the spatial variability of the forest canopy. Hence, it is also necessary a technique such as artificial neural networks to select the most relevant attributes and to integrate these data. The aim of this study was to evaluate and compare the use of ALI/EO-1 spectral attributes and GLCM textural metrics using the Multi-Layer Perceptron artificial neural networks technique for land cover mapping in the Tapajós National Forest and vicinity, focusing on the discrimination of primary forest and secondary successions. It was observed that the most important textural attributes were the mean texture of bands 3, 4, 6, 7 and 8, and the dissimilarity of band 8. These attributes, when integrated into the spectral data to compose a hybrid dataset, provided better discrimination between the classes of NPV and soil, crops and SS1/SS2, SS1 and SS2, SS2 and SS3/FP. Thereby, the SS1, SS2, SS3 and FP areas could be discriminated with 89, 63, 62 and 83% of classification accuracy. It was observed an overall accuracy of 89% using the hybrid dataset against 79% using only the spectral data.

**Keywords:** Tropical forests, secondary successions, artificial neural networks, ALI/EO-1, GLCM texture.

#### INTRODUÇÃO

As áreas de sucessão secundária (SS) correspondem a cerca de 20% da área desmatada na Amazônia Oriental (FEARNSIDE *et al.*, 2009). Essas áreas são, em sua grande maioria, geradas do desmatamento da floresta primária, que é seguido do uso na pecuária e agricultura por certo período de tempo, e em seguida abandonadas, iniciando-se assim, o processo de regeneração (PRATES-CLARK *et al.*, 2009). Esse ciclo ocorre visto que com o tempo de uso da terra há um declínio na produtividade e fertilidade do solo. Dessa forma, a regeneração florestal atua no controle do pH e na recuperação da fertilidade do solo, além de agir na

manutenção da biodiversidade e regime hidrológico, estabelecimento da conectividade entre remanescentes florestais e acúmulo de carbono atmosférico (NEPSTAD *et al.*, 1994; SHEVLIAKOVA *et al.*, 2009).

Devido à representatividade em área e serviços ecológicos prestados pela sucessão secundária (SS), o mapeamento dessas áreas se faz necessário para estudos científicos, como de mitigação de mudanças climáticas (SHEVLIAKOVA *et al.*, 2009). O levantamento da áreas de SS com dados de sensores remotos tem sido explorado por especialistas, porém com certa dificuldade de caracterização devido a fatores, como a influência da sombra sobre o dossel florestal provocada pela diferença de altura das árvores, heterogeneidade intrínseca da estrutura da vegetação e a saturação do sinal de resposta espectral do alvo sob determinadas condições (STEININGER, 2000). A composição de espécies, a estrutura florestal, o ângulo de arranjo das folhas e o estado fenológico da planta também podem afetar a reflectância do alvo medida pelos sensores remotos. Apesar de não existir um protocolo definitivo para a categorização das SS, um critério muito utilizado em ambientes amazônicos é do tempo/idade de regeneração (UHL *et al.*, 1988), dividindo-as em sucessão inicial (SS1 – até 5 anos), intermediária (SS2 – 5 a 15 anos) e avançada (SS3 – mais de 15 anos).

A combinação de dados espectrais de sensoriamento remoto com dados texturais pode melhorar a classificação da cobertura da terra, pois a textura reflete a heterogeneidade espacial da estrutura da vegetação e, portanto, pode ser utilizada para representar essas variações presentes, sobretudo nas SS (ASNER *et al.*, 2003). O método de extração de textura mais comumente utilizado é o *Gray-Level Co-occurrence Matrixes* (GLCM; HARALICK *et al.*, 1973). Esse método quantifica a frequência em que diferentes combinações de níveis de cinza ocorrem numa imagem de acordo com uma distância e ângulo determinados, gerando uma matriz de probabilidades e fornecendo oito métricas texturais. Nesse sentido, diversos estudos têm utilizado atributos de textura como complemento aos dados espectrais para o mapeamento de estádios de sucessão florestal (KIMES *et al.*, 1999; ASNER *et al.*, 2003; OTA *et al.*, 2011). Apesar disso, o entendimento sobre a real contribuição das métricas de textura na diferenciação de estádios de SS ainda é limitado (GALLARDO-CRUZ *et al.*, 2012).

Os dados do sensor Advanced Land Imager (ALI) / Earth Observing 1 (EO-1), protótipo do Operational Land Imager (OLI) / Landsat-8, têm sido utilizados para estudos de mapeamento do uso e cobertura da terra, estimativa de parâmetros biofísicos, detecção de queimadas, identificação de culturas, estimativa de produção agrícola, etc. O sensor ALI é um sensor multiespectral com resolução espacial de 30 m nas bandas espectrais e 10 m na banda pancromática. Ele adquire dados em nove bandas espectrais largas similares as do sensor OLI/Landsat-8 com resolução radiométrica de 12 bits. Dentre as bandas espectrais, duas são posicionadas na região do visível, duas na do infravermelho próximo (NIR) e três na do infravermelho de ondas curtas (SWIR). Elas possuem relação sinal/ruído quatro a dez vezes maiores que as do ETM+. Apesar de literatura reportar estudos em florestas tropicais, análises envolvendo SS em ambientes amazônicos não foram ainda feitas para esse sensor.

As redes neurais artificiais (RNA) têm sido muito utilizadas para integração de dados, onde o método mais aplicado é o *Multi-Layer Perceptron* (MLP) (KIMES *et al.*, 1999). As RNA são técnicas computacionais criadas para simular o funcionamento do cérebro humano, de forma a aprender um padrão de informações e promover uma generalização para outro conjunto de dados (HAYKIN, 1999). Dessa forma, a arquitetura de uma RNA no método MLP é composta de três camadas (*input*, *oculta* e *output*), nas quais são apresentados os dados (*input*), é realizado o processamento nos neurônios armazenando a informação em forma de pesos (*oculta*), e é apresentado o resultado final como classe mapeada (*output*). Devido a sua flexibilidade na modelagem de relações complexas não-lineares (como dos dados de textura e as classes de cobertura da terra), as RNA não requerem conhecimento prévio sobre distribuição ou relação entre variáveis, podendo ser utilizadas para seleção de atributos mais relacionados com a variável resposta (KIMES *et al.*, 1999). A interpretação dos pesos da RNA permite o entendimento da relevância dos atributos para o resultado (GARSON, 1991).

Portanto, o presente estudo tem o objetivo de avaliar e comparar o uso de atributos espectrais e métricas texturais derivados do sensor ALI/EO-1 através da técnica de redes neurais artificiais *Multi-Layer Perceptron* para mapeamento da cobertura e uso da terra na Floresta Nacional do Tapajós e arredores, com foco principal na discriminação das tipologias florestais primárias e sucessões secundárias.

## METODOLOGIA

A área de estudo corresponde à parte norte da Floresta Nacional do Tapajós (FNT) e seus arredores, onde o uso da terra tem sido direcionado para agricultura e pecuária (Figura 1). A FNT é uma unidade de conservação atualmente mantida pelo Instituto Chico Mendes de Conservação da Biodiversidade (ICMBio) / Ministério do Meio Ambiente (MMA), localizada no Estado do Pará, a oeste da rodovia Cuiabá-Santarém (BR-163) e a leste do Rio Tapajós, ocupando áreas dos municípios de Belterra, Aveiro, Rurópolis e Placas. A vegetação natural é classificada como Floresta Ombrófila Densa, com dominância de árvores de grande dimensão diamétrica e alta abundância de lianas lenhosas, palmeiras e epífitas, sendo que a variação topográfica local é fator determinante para a vegetação (GONÇALVES *et al.*, 2011). Os arredores da FNT apresentam áreas de sucessões secundárias em estádios regenerativos SS1, SS2 e SS3.




Figura 1. Localização da área de estudo no Estado do Pará e composição falsa-cor da imagem ALI/EO-1 com as bandas 5 (775-805 nm), 8 (1550-1750 nm) e 4 (630-690 nm) nas cores vermelho, verde e azul, respectivamente. A imagem foi adquirida em 21/08/2012.

Figure 1. Location of the study area in the State of Pará and false color composite of ALI/EO-1 bands 5 (775-805 nm), 8 (1550-1750 nm) and 4 (630-690 nm) in red, green and blue colors, respectively. The image was acquired in 08/21/2012.

A imagem do sensor ALI/EO-1 foi obtida pela plataforma *Earth Explorer* da USGS/NASA, adquirida pelo sensor na data 21/08/2012, órbita/ponto 227/62, com ângulo de visada +15,10° (direção de espalhamento frontal), 55° de elevação solar, 64° de azimute solar e nível de processamento L1T. O nível de processamento L1T corresponde à correção sistemática de radiometria, exatidão geométrica e exatidão topográfica com o modelo digital de elevação STRM. A banda pancromática não foi utilizada na análise.

Os pré-processamentos realizados foram a conversão para radiância e conversão para reflectância de superfície, os quais foram realizados no aplicativo ENVI 5.0.3 (ITT, 2013). Esse processo foi realizado pelo algoritmo *Fast Line-of-Sight Atmospheric Analysis of Spectral Hypercubes* (FLAASH), baseado na modelagem de transferência radiativa MODTRAN4. Esse modelo realiza a correção atmosférica minimizando e/ou removendo os efeitos de espalhamento e absorção atmosféricos.

A partir da imagem de reflectância de superfície, o método GLCM foi aplicado, gerando oito métricas de textura para cada uma das nove bandas ALI: média, variância, contraste, dissimilaridade, homogeneidade,

entropia, segundo momento angular e correlação (HARALICK *et al.*, 1973). O resultado foi a geração de 72 atributos texturais. Para o cálculo das métricas foi utilizada uma janela móvel de 3x3 pixels, determinada após vários testes, com deslocamento de 1 pixel e 64 níveis de cinza. A dimensão dessa janela foi utilizada por Asner *et al.* (2003) na região do Tapajós, onde apresentou melhor sensibilidade para distinção de alvos.

A fim de subsidiar o processo de mapeamento, foi realizada uma campanha de campo dos dias 7 a 18 de agosto de 2012, portanto, no mesmo mês de obtenção da imagem ALI. Foram coletados pontos observacionais das classes temáticas de uso e cobertura da terra nos arredores da FNT e de floresta primária no interior da FNT através de Sistema de Posicionamento Global (GPS) de navegação. O número de pontos coletados para as classes (com sua abreviação entre parênteses) foi: 14 de corpos d'água (água), 2 de culturas agrícolas (CA), 38 de pasto limpo/sujo (pasto), 13 de solo exposto/pousio (solo), 12 de vegetação não-fotossinteticamente ativa (NPV), 12 de floresta primária (FP), 11 de sucessão secundária inicial (SS1), 13 de sucessão secundária intermediária (SS2), e 4 de sucessão secundária avançada (SS3). Os pontos coletados foram verificados em série temporal TM/Landsat-5 para assegurar que eram áreas de regeneração florestal.

As áreas correspondentes aos pontos de observação foram vetorizadas como regiões de interesse (ROI) através do aplicativo ENVI 5.0.3. Foram aleatorizados 900 pixels amostrais (100 pixels por classe) sobre as ROI, extraindo os valores espectrais e texturais para cada pixel. Evitaram-se áreas com pixels de borda para minimizar a captura de zonas de transição entre classes vizinhas que poderiam introduzir variabilidade entre classes no cálculo da textura. Os 900 pixels foram divididos em três conjuntos amostrais independentes: treinamento (450 pixels; 50 por classe), validação (225 pixels; 25 por classe) e teste (225 pixels; 25 por classe). O conjunto de treinamento foi utilizado para promover o aprendizado da RNA; o conjunto de validação foi utilizado para monitorar o desempenho do treinamento da rede e promover sua parada; e o conjunto de teste foi utilizado para avaliação do desempenho de classificação.

O processo de classificação e avaliação foi realizado através de programação em ambiente MATLAB 2013a® (MATH WORKS INC., 2013). A RNA foi criada a partir da função *patternnet* do pacote *Neural Network Toolbox*, possuindo três camadas (*input*, *oculta*, *output*). O treinamento da rede foi realizado pelo algoritmo *backpropagation* de *Levenberg-Marquardt* (HAGAN; MENHAJ, 1994), pela função *trainlm*. Esse método de treinamento foi escolhido pelo bom desempenho e velocidade de treinamento, mesmo quando utilizado um grande número de *inputs* (HAGAN; MENHAJ, 1994). A taxa de aprendizagem aplicada foi de 0,01 e utilizaram-se dois critérios de parada: raiz do erro médio quadrático (RMSE) de 0,009 e de 10 épocas sem melhoria no desempenho. O treinamento é encerrado quando um dos critérios de parada é alcançado.

Inicialmente, os dados de treinamento, de validação e de teste foram importados no MATLAB. Os *inputs* foram padronizados para média igual a 0 e desvio padrão igual a 1. Foi calculado um número de neurônios (N) satisfatório numa relação de 10 vezes mais equações de treinamento do que de pesos (HEATH, 2010). Foi testada uma variação de cinco N para mais e para menos, e também dez variações de pesos iniciais aleatórios para maximizar o potencial de interpolação e extrapolação da RNA (ATKINSON; TATNAL, 1997). A avaliação para cada treinamento foi realizada a partir do índice *kappa*, calculado a partir da matriz de confusão com o conjunto de teste. Dessa forma, determinou-se o N e conjunto de pesos de melhor desempenho para o conjunto espectral e textural separadamente. Em seguida, foi calculada a contribuição relativa (CR) de cada atributo a fim de promover a seleção de atributos (GARSON, 1991). Os valores de CR foram analisados através de gráficos e definição de limiares empíricos de CR. Os atributos mais importantes para cada limiar foram mesclados em conjuntos híbridos (espectral mais textural). Uma análise comparativa dos conjuntos foi realizada pela exatidão global, índice *kappa* e teste Z (CONGALTON; MEAD, 1983). Por fim, comparou-se o conjunto híbrido de melhor desempenho com o conjunto espectral através da matriz de confusão, exatidão global, índice *kappa* e exatidão de classe. Um mapa de cobertura e uso da terra foi gerado para o melhor conjunto de dados.

## RESULTADOS E DISCUSSÃO

A seleção de atributos para os dados espectrais indicou baixa CR para as bandas 1 e 2, provavelmente devido a maior sensibilidade a efeitos atmosféricos dessas bandas e que não foram removidos por completo pelo uso de uma visibilidade média para a cena ALI por parte do FLAASH. Para as métricas texturais, as bandas 1 e 2

foram automaticamente retiradas da análise e os valores de CR foram representados em forma de gráfico (Figura 2). Observa-se que a textura média obteve resultado superior as demais métricas, especialmente para as bandas 3 (565 nm), 4 (660 nm), 6 (867 nm), 7 (1250 nm) e 8 (1650 nm). A banda 5 (790 nm) apresentou baixa CR provavelmente devido a forte correlação com a banda 6 (também do NIR), enquanto que a banda 9 (2215 nm) apresentou baixa CR provavelmente devido a forte correlação com a banda 8 (também do SWIR). Além da média, a textura dissimilaridade da banda 8 também apresentou resultado CR superior as demais.




Figura 2. Contribuição relativa das oito métricas de textura extraídas das bandas 3 a 9 do ALI/EO-1 no mapeamento da cobertura e uso da terra usando Redes Neurais Artificiais (RNA).

Figure 2. Relative contribution of the eight texture metrics extracted from the ALI/EO-1 bands 3 to 9 for land cover and land use mapping using Artificial Neural Network (ANN).

Foram traçados quatro limiares de CR: 2, 2,5, 3 e 5%. Os atributos acima desses limiares foram integrados a reflectância das bandas 3 a 9 para compor conjuntos híbridos. Os índices *kappa* para limiares 2, 2,5, 3 e 5% foram 0,85, 0,86, 0,87 e 0,83. O conjunto do limiar 3 apresentou melhor resultado, o qual foi estatisticamente superior ( $p = 0,012$ ) ao do limiar 5, e estatisticamente igual aos demais ( $p > 0,05$ ). Além de apresentar *kappa* melhor, o conjunto do limiar 3 utilizou uma menor quantidade de atributos, ou seja, uma arquitetura menos complexa. Dessa forma, determinou-se esse conjunto como o conjunto híbrido ótimo para o mapeamento: reflectância das bandas 3 a 9, textura média das bandas 3, 4, 6, 7 e 8, e textura dissimilaridade da banda 8.

Para os dados espectrais, a RNA foi treinada utilizando a reflectância das bandas 3 a 9, variando de 18 a 28 neurônios na camada oculta. O melhor resultado foi obtido com 27 neurônios, onde o treinamento foi interrompido com 16 iterações com um RMSE de 0,035. O motivo da parada foi não ter ocorrido melhoria no desempenho após 16 iterações. Para os dados híbridos, a RNA foi treinada utilizando a reflectância das bandas 3 a 9, textura média das bandas 3, 4, 6, 7 e 8, e textura dissimilaridade da banda 8. O número de neurônios na camada oculta variou de 12 a 22 onde o melhor resultado foi obtido com 12 neurônios após 19 iterações e RMSE de 0,017. O treinamento cessou por não haver melhoria no desempenho após 19 iterações. A matriz de confusão, o valor de exatidão global e o índice *kappa* foram calculados utilizando os pixels de teste para os dados espectrais (Tabela 1) e híbridos (Tabela 2).

Tabela 1. Matriz de confusão do mapa de cobertura e uso da terra gerado com dados espectrais (reflectância das bandas ALI 3 a 9), em percentagem. As abreviações são: EC = erros de comissão; EO = erros de omissão; ECI = exatidão da classe; e EG = exatidão global.

Table 1. Confusion matrix from the land use and land cover map generated with the spectral dataset (reflectance of the ALI bands 3 to 9), in percent. The abbreviations are: EC = error of commission; EO = error of omission; CA = class accuracy; and OA = overall classification accuracy.

| Classes        | Água | Solo | CA  | NPV | Pasto | SS1 | SS2 | SS3 | FP  | Total                                         | EC (%) |
|----------------|------|------|-----|-----|-------|-----|-----|-----|-----|-----------------------------------------------|--------|
| Água           | 100  | 0    | 0   | 0   | 0     | 0   | 0   | 0   | 0   | 100                                           | 0      |
| Solo           | 0    | 32   | 0   | 68  | 0     | 0   | 0   | 0   | 0   | 100                                           | 68     |
| CA             | 0    | 0    | 100 | 0   | 0     | 0   | 0   | 0   | 0   | 100                                           | 0      |
| NPV            | 0    | 4    | 0   | 96  | 0     | 0   | 0   | 0   | 0   | 100                                           | 4      |
| Pasto          | 0    | 0    | 0   | 0   | 100   | 0   | 0   | 0   | 0   | 100                                           | 0      |
| SS1            | 0    | 0    | 20  | 0   | 0     | 80  | 0   | 0   | 0   | 100                                           | 20     |
| SS2            | 0    | 0    | 28  | 0   | 0     | 16  | 44  | 0   | 12  | 100                                           | 56     |
| SS3            | 0    | 0    | 0   | 0   | 0     | 0   | 24  | 64  | 12  | 100                                           | 36     |
| FP             | 0    | 0    | 0   | 0   | 0     | 0   | 0   | 4   | 96  | 100                                           | 4      |
| <b>Total</b>   | 100  | 36   | 148 | 164 | 100   | 96  | 68  | 68  | 120 | <b>EG (%) = 79,11</b><br><b>Kappa = 0,765</b> |        |
| <b>EO (%)</b>  | 0    | 11   | 32  | 41  | 0     | 17  | 35  | 6   | 20  |                                               |        |
| <b>ECI (%)</b> | 100  | 31   | 68  | 57  | 100   | 69  | 35  | 62  | 77  |                                               |        |

Tabela 2. Matriz de confusão do mapa de cobertura da terra gerado com dados híbridos, em percentagem.

Table 2. Confusion matrix from the land cover map generated with the hybrid dataset, in percent.

| Classes        | Água | Solo | CA  | NPV | Pasto | SS1 | SS2 | SS3 | FP  | Total                                         | EC (%) |
|----------------|------|------|-----|-----|-------|-----|-----|-----|-----|-----------------------------------------------|--------|
| Água           | 100  | 0    | 0   | 0   | 0     | 0   | 0   | 0   | 0   | 100                                           | 0      |
| Solo           | 0    | 76   | 0   | 12  | 12    | 0   | 0   | 0   | 0   | 100                                           | 24     |
| CA             | 0    | 0    | 96  | 0   | 0     | 4   | 0   | 0   | 0   | 100                                           | 4      |
| NPV            | 0    | 8    | 0   | 92  | 0     | 0   | 0   | 0   | 0   | 100                                           | 8      |
| Pasto          | 0    | 0    | 0   | 0   | 100   | 0   | 0   | 0   | 0   | 100                                           | 0      |
| SS1            | 0    | 0    | 0   | 0   | 0     | 100 | 0   | 0   | 0   | 100                                           | 0      |
| SS2            | 0    | 0    | 16  | 0   | 0     | 8   | 76  | 0   | 0   | 100                                           | 24     |
| SS3            | 0    | 0    | 0   | 0   | 0     | 0   | 20  | 64  | 16  | 100                                           | 36     |
| FP             | 0    | 0    | 0   | 0   | 0     | 0   | 0   | 4   | 96  | 100                                           | 4      |
| <b>Total</b>   | 100  | 84   | 112 | 104 | 112   | 112 | 96  | 68  | 112 | <b>EG (%) = 88,89</b><br><b>Kappa = 0,875</b> |        |
| <b>EO (%)</b>  | 0    | 10   | 14  | 12  | 11    | 11  | 21  | 6   | 14  |                                               |        |
| <b>ECI (%)</b> | 100  | 70   | 83  | 82  | 89    | 89  | 63  | 62  | 83  |                                               |        |

A integração dos dados espectrais e texturais proporcionou melhoria na exatidão global de cerca de 10%. A exatidão da classe solo melhorou de 31 para 70%, diminuindo sua confusão com NPV, que melhorou de 57 para 82%. A identificação de CA aumentou de 68 para 83% devido à diminuição da confusão com SS1 e SS2. Água manteve-se com 100% de acerto. Pasto obteve resultado inferior, passando de 100 para 89%, com a introdução de 12% de confusão com solo. Com relação as classe de regeneração florestal, houve grande melhoria em SS1 (ECI = 69 para 89%) e SS2 (ECI = 35 para 63%). A variabilidade espacial contida nessas classes e extraída pelas métricas texturais provavelmente colaborou para a diminuição da confusão entre SS1 e SS2, e entre SS1/SS2 e CA. Apesar disso, não se observou melhoria para a classificação de SS3 (ECI = 62%). SS3 apresenta um dossel mais irregular que SS1 e SS2, com a presença de indivíduos emergentes. Por isso, esperava-se que essa variabilidade espacial proporcionasse uma melhor distinção dessa classe pelas métricas texturais. No entanto, observou-se que a confusão entre SS3 e SS2 diminuiu de 24 para 20%, ao passo que a confusão entre SS3 e FP aumentou de 12 para 16%. A classe FP obteve melhoria (ECI = 77 para 83%) devido a uma diminuição da confusão com SS2, apesar do aumento da confusão com SS3.

Os resultados observados corroboram com os obtidos por Kimes *et al.* (1999) ao mapear florestas tropicais primárias e secundárias na Amazônia com dados do *High Resolution Visible* (HRV)/SPOT-1. Observaram um ganho de exatidão de 83,5 para 89,9% ao utilizar dados híbridos. Ota *et al.* (2011) e Gallardo-Cruz *et al.*

(2012) reportaram que as métricas texturais podem apresentar melhor relação com a floresta com a utilização de alta resolução espacial.

Devido ao desempenho superior dos dados híbridos, este conjunto foi utilizado para gerar um mapa de cobertura e uso da terra (Figura 3). Observou-se uma grande concentração de áreas de FP (verde escuro) localizada no interior da FNT (parte oeste) e na parte central da imagem. A área no interior da FNT apresentou uma grande quantidade de pixels de SS2 e SS3 espalhados, provavelmente devido a pequenos distúrbios causados pelo homem no passado nessas regiões, como o manejo seletivo que foi feito ao sul da FNT. Além disso, constatou-se a presença de espalhamento atmosférico ao longo da FNT, que também pode ter introduzido variabilidade espectral. Observaram-se muitas áreas de SS2 na região sudoeste da imagem, em torno da vila de São Jorge. A área de SS3 do interior da FNT foi classificada corretamente, enquanto que algumas outras áreas pontuais que foram classificadas como SS3 podem ser consideradas áreas com certo nível de degradação da floresta, ao invés de áreas propriamente ditas de regeneração.




Figura 3. Mapa de cobertura e uso da terra gerado utilizando atributos híbridos (espectrais e texturais).  
Figure 3. Land use and land cover map generated using hybrid attributes (spectral and textural).

## CONCLUSÕES

A análise de seleção de atributos por redes neurais artificiais revelou que as métricas texturais de melhor contribuição para o processo de mapeamento foram a textura média das bandas 3, 4, 6, 7 e 8, e a dissimilaridade da banda 8, as quais foram incluídas junto a reflectância das bandas 3 a 9 para compor um conjunto híbrido. Esse conjunto híbrido apresentou exatidão global de 89%, contra 79% do mapa utilizando somente dados espectrais. A adição dessas métricas texturais melhorou a separação entre classes como NPV e solo, CA e SS1/SS2, SS1 e SS2, SS2 e SS3/FP, causando um ganho de exatidão global de 10%. As classes de sucessão secundária SS1, SS2, SS3 e FP puderam ser discriminadas com 89, 63, 62 e 83% de acerto, respectivamente, com confusões na ordem de 20% entre SS2/SS3 e SS3/FP.



## REFERÊNCIAS

- ASNER, G.P. *et al.* Scale dependence of biophysical structure in deforested areas bordering the Tapajós National Forest, Central Amazon. *Remote Sensing of Environment*, v. 87, p. 507-520, 2003.
- ATKINSON, P.M.; TATNALL, A.R.L. Neural networks in remote sensing. *International Journal of Remote Sensing*, v. 18, p. 699-709, 1997.
- CONGALTON, R.G.; MEAD, R.A. A quantitative method to test for consistency and correctness in photointerpretation. *Photogrammetric Engineering and Remote Sensing*, v. 49, n. 1, p. 69-74, 1983.
- FEARNSIDE, P.M. *et al.* Biomass and greenhouse-gas emissions from land-use change in Brazil's Amazonian "arc of deforestation": the states of Mato Grosso and Rondônia. *Forest Ecology and Management*, v. 258, n. 9, p. 1968-1978, 2009.
- GALLARDO-CRUZ, J. A. *et al.* Predicting Tropical Dry Forest Successional Attributes from Space: Is the Key Hidden in Image Texture? *PLoS ONE*, v. 7, n. 2, p. 1-12, 2012.
- GARSON, G.D. Interpreting neural-network connection weights. *AI Expert*, v.6, p. 47-51, 1991.
- GONÇALVES, F.G. *et al.* Stem volume of tropical forests from polarimetric radar. *International Journal of Remote Sensing*, v. 32, n. 2, p. 503-522, 2011.
- HAGAN, M.T.; MENHAJ, M. Training feed-forward networks with the Marquardt algorithm. *IEEE Transactions on Neural Networks*, v. 5, n. 6, p. 989-993, 1994.
- HARALICK, R.M. *et al.* Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, v.SMC-3, n. 6, p. 610-621, 1973.
- HAYKIN, S. *Neural networks: a comprehensive foundation*. 2.ed. Ontario-CA: Prentice Hall Int., 1999.
- HEATH, G.E. *Training the Neural Network*. 2010. Disponível em: <[http://www.mathworks.com/matlabcentral/newsreader/view\\_thread/295781#917734](http://www.mathworks.com/matlabcentral/newsreader/view_thread/295781#917734)>. Acesso em: 04 de jul.2013.
- ITT. *ENVI user's guide*. ITT visual information solutions: ITT visual information solutions, 2013.
- KIMES, D.S. *et al.* Mapping secondary tropical forest and forest age from SPOT HRV data. *International Journal of Remote Sensing*, v. 20, n. 18, p. 3625-3640, 1999.
- MATH WORKS INC. *MATLAB 2013a*. Natick, MA, 2013.
- NEPSTAD, D.C. *et al.* The role of deep roots in the hydrological and carbon cycles of Amazonian forests and pastures. *Nature*, v. 372, p. 666-669, 1994.
- OTA, T. *et al.* Influence of using texture information in remote sensed data on the accuracy of forest type classification at different levels of spatial resolution. *Journal of Forest Research*, v. 16, p. 432-437, 2011.
- PRATES-CLARK, C.C. *et al.* Implications of land-use history for forest regeneration in the Brazilian Amazon. *Canadian Journal of Remote Sensing*, v. 35, n. 6, p. 534-553, 2009.
- SHEVLIAKOVA, E. *et al.* Carbon cycling under 300 years of land use change: Importance of the secondary vegetation sink. *Global Biogeochemical Cycles*, v.23, GB2022, 2009.
- STEININGER, M.K. Satellite estimation of tropical secondary forest aboveground biomass data from Brazil and Bolivia. *International Journal of Remote Sensing*, v. 21, p. 1139-1157, 2000.
- UHL, C. *et al.* Abandoned pastures in eastern Amazônia, I: Patterns of plant succession. *Journal of Ecology*, v. 76, p. 663-681, 1988.