

Revista Brasileira de Cartografia (2012) N<sup>o</sup> 64/5: 589-599  
Sociedade Brasileira de Cartografia, Geodésia, Fotogrametria e Sensoriamento Remoto  
ISSN: 1808-0936

## **AT-SOM: MAPAS AUTO-ORGANIZÁVEIS ATENUANTES**

*AT-SOM: Attenuating Self-Organizing Maps*

**Rogério Galante Negri<sup>1</sup> & Carlos Alberto Pires de Castro Filho<sup>1,2</sup>**

**<sup>1</sup>Instituto Nacional de Pesquisas Espaciais - INPE**

**Divisão de Processamento de Imagens - DPI**

Av. dos Astronautas, 1.758 – 12227-010 – São José dos Campos – SP – Brasil  
rogerio@dpi.inpe.br; pires@dpi.inpe.br;

**<sup>2</sup>Diretoria de Serviço Geográfico - DSG**

Quartel General do Exército, Bloco “F”, 2<sup>o</sup> Piso,  
Setor Militar Urbano – 70630-901 – Brasília – DF – Brasil

*Recebido em 21 de junho, 2011/ Aceito em 26 de novembro, 2011*

*Received on June 21, 2011/ Accepted on November 26, 2011*

### **RESUMO**

Mapas Auto-Organizáveis (SOM) são modelos de Rede Neurais Artificiais inspirados no comportamento do córtex cerebral humano, os quais podem ser empregados na classificação de imagens. Este trabalho apresenta um método de classificação de imagens baseado em SOM, denominado Mapas Auto Organizáveis Atenuantes (At-SOM), capaz de reduzir os efeitos provocados pela classificação baseada em *pixels*. Para isto, o método desenvolvido é munido de um processo iterativo que reduz os valores dos *pixels* de um mesmo agrupamento. Um estudo de caso sobre a exatidão dos métodos At-SOM, *Expectation Maximization*, *Fuzzy C-Médias* e o método SOM clássico foi realizado, tomando como base um problema específico de classificação de tipos de cobertura da terra em uma imagem do sensor LANDSAT-5 TM. O método proposto, associado à função de vizinhança topológica *Chapéu Mexicano*, mostrou maior acurácia com relação aos demais métodos.

**Palavras chaves:** Classificação de Imagem, Baseado em *Pixel*, Variação de SOM, Umento de Acurácia.

### **ABSTRACT**

Self-Organizing Maps (SOM) are Artificial Neural Network models bio-inspired by the behavior of the human cerebral cortex. These models can be used as unsupervised image classification methods. This paper presents an image classification method based on Attenuating Self-Organizing Maps (At-SOM) able to reduce the effects caused by the pixel-based classification. The developed method has an attenuation process to decrease iteratively the pixels values that belongs to a same cluster. A case study assessing the At-SOM, Expectation Maximization, Fuzzy C-Means and the classic SOM methods accuracy was conducted for a specific land cover classification problem using LANDSAT-5 TM image sample. The proposed method associated with Mexican Hat topological neighborhood function achieved better accuracy over other methods.

**Keywords:** Image Classification, Pixel-based, SOM Based, Accuracy Increase.

## 1. INTRODUÇÃO

Nas geociências, os métodos de *reconhecimento de padrões* têm se mostrado úteis para detecção de alvos em imagens obtidas por sensores remotos. Aplicações com diferentes propósitos podem ser citadas, como no monitoramento de recursos naturais referentes às florestas (PRODES, 2006), rios (SILVA *et al.*, 2009) e geleiras (MENDES JUNIOR *et al.*, 2009), no estudo de áreas afetadas por desastres naturais (CHESNEL *et al.*, 2007) e no planejamento urbano (ALVES *et al.*, 2009; RIBEIRO *et al.*, 2009).

A aplicação de métodos de reconhecimento de padrões em imagens visando à identificação de feições recebe o nome de *classificação de imagens*. Nas aplicações em sensoriamento remoto, este processo pode ser realizado sobre características específicas como as radiométricas, de textura, de forma e de contexto espacial (MATHER, 1999).

Os recentes avanços tecnológicos têm causado o aumento do número de satélites em operação, o que consequentemente têm aumentado a quantidade de imagens coletadas e armazenadas diariamente, gerando por sua vez grandes bases de dados. Para lidar com essa crescente quantidade de dados, algoritmos de classificação mais eficazes tornam-se necessários (KORTING *et al.*, 2008).

Uma das características dos métodos de classificação de imagens é o seu tipo de aprendizado. Um classificador cujo aprendizado é supervisionado necessita de um conjunto de treinamento, de onde possa extrair informações para modelagem de uma regra de classificação. Após esta fase de modelagem, o classificador é utilizado na classificação de novas informações.

Em oposição, o aprendizado não supervisionado não usufrui de informações externas. Neste caso, o aprendizado é baseado em analogias construídas ao observar todo o conjunto de dados a ser classificado, produzindo como resultado agrupamentos compostos por padrões similares. Uma vantagem dos métodos não supervisionados é a independência de conjuntos de treinamento para induzir o conhecimento, já que existem custos relacionados à obtenção de tais informações, sejam eles o tempo, recursos financeiros ou a necessidade de um especialista (KIYASU *et al.*, 2009).

Segundo Wu *et al.* (2008), os classificadores também podem ser categorizados como métodos *baseado em pixel* ou *baseado em regiões*. No primeiro caso os *pixels* são classificados individualmente, já no segundo caso, a imagem é dividida previamente em regiões com a aplicação algoritmos de segmentação, e então, a classificação é realizada sobre estas regiões. Uma das principais vantagens quanto o uso de métodos baseados em regiões é reduzir a classificação de *pixels isolados*, o que ocorre frequentemente na classificação baseada em pixels (GUO *et al.*, 2007), no entanto, o desempenho de tais métodos dependem do processo de segmentação que antecede a classificação (LIU E XIA, 2010).

Quando os métodos baseados em *pixels* são empregados, uma medida usualmente adotada para redução da classificação de *pixels* isolados é a aplicação de filtros, como por exemplo, o filtro de maioria. Este filtro consiste em observar cada *pixel*, e os respectivos vizinhos contidos em uma janela de dimensão fixa, visando à substituição do seu valor por aquele de maior frequência em sua vizinhança. Embora este processo efetue com sucesso a eliminação de *pixels* isolados, surge como efeito colateral a degradação das bordas dos alvos e a possível eliminação de estruturas lineares, como por exemplo, estradas e rios. Dessa forma, é preferível o uso de métodos baseados em *pixels* que minimize a classificação de *pixels* isolados e dispense qualquer tipo de pós-processamento adicional.

Dentre diferentes métodos difundidos na literatura, a classificação por Máxima Verossimilhança (*Maximum Likelihood*) (RICHARDS E JIA, 2005), Maximização de Esperança (*Expectation Maximization*) (DEMPSTER, 1977), Máquinas de Vetores Suporte (*Support Vector Machines*) (VAPNIK, 1998) e os classificadores baseados em Redes Neurais Artificiais (RNAs), são usualmente empregados nos problemas de classificação de imagens de Sensoriamento Remoto.

As RNAs são sistemas computacionais que apresentam características similares às observadas nos neurônios do cérebro humano. Tais características referem-se ao aprendizado, armazenamento do conhecimento e a capacidade

de generalização a partir do conhecimento adquirido (IYODA, 2000).

Como ferramenta no processo de reconhecimento de padrões, as RNAs apresentam algumas vantagens sobre os métodos tradicionais. Dentre estas vantagens, destaca-se a capacidade de resolver problemas não lineares de alta complexidade, robustez na manipulação de dados ruidosos e não exigência de suposições sobre os dados, como normalidade ou igualdade de variância (RICHARDSON *et al.*, 2003).

Os Mapas Auto-Organizáveis (SOM – Self-Organizing Maps) são exemplos de modelos de RNAs (KOHONEN, 1989). Sua formulação é baseada no comportamento do córtex cerebral humano, onde determinadas regiões são responsáveis pela execução de habilidades específicas. Diferentes aplicações deste modelo sobre dados de sensores remotos têm sido realizadas. Neste caso pode-se citar as análises exploratórias (FREITAS *et al.*, 2009), a investigação de fenômenos relacionados à expansão urbana (ALMEIDA *et al.*, 2009) e os processos de seleção de atributos e de classificação de imagens.

No contexto de classificação de imagens, o SOM clássico é caracterizado como um método de aprendizado não supervisionado baseado em *pixels*. Este método analisa iterativamente o comportamento dos *pixels* de uma dada imagem e os associa a um determinado neurônio. Neste processo iterativo os neurônios adaptam-se ao comportamento dos dados, aprimorando assim a capacidade de representá-los. Ao fim do processo, cada neurônio reflete o comportamento de um determinado conjunto de *pixels*, sendo então capaz de discriminar a imagem analisada em diferentes agrupamentos.

Apesar de possuir as vantagens referentes ao aprendizado não supervisionado, imagens classificadas pelo método SOM tendem a apresentar *pixels* isolados, prejudicando assim a definição dos alvos. Dessa forma, este trabalho tem por objetivo propor uma variação do método SOM, que aplicado em problemas relacionados a imagens, seja capaz de reduzir os efeitos provocados pela classificação baseada em *pixels*.

## 2. MAPAS AUTO-ORGANIZÁVEIS

Como mencionado anteriormente, os SOM são modelos de RNAs que simulam o comportamento do córtex cerebral humano. Nesta região, existem áreas específicas responsáveis pela realização de determinadas atividades sensoriais, como por exemplo, a visão, a audição e a capacidade motora (KOHONEN, 1989).

Outra característica que inspira a formalização do método SOM é a relação topológica existente entre os neurônios. Para uma determinada ativação cerebral, o grau de ativação dos neurônios vizinhos diminui à medida que aumenta a distância da região de ativação inicial (HAYKIN, 1999). Neste contexto, o SOM tornou-se um exemplo tradicional de RNA que utiliza o aprendizado não supervisionado e produz uma visualização do espaço de atributos em menor dimensão que o dado de entrada, preservando suas relações topológicas (HAYKIN, 1999).

O método SOM consiste em mapear padrões de entrada a partir de uma grade de neurônios e representá-los em um determinado espaço de saída. Os padrões de entrada, e seus respectivos atributos, variam de acordo com a aplicação do SOM, em classificação de imagens, cada padrão de entrada é um *pixel* e seus atributos são os valores nas bandas que o compõe. Cada neurônio é composto por um vetor de pesos com mesma dimensão dos padrões de entrada. A representação desta relação entre os vetores de peso e os elementos do espaço de entrada é ilustrada na Figura 1.

Durante a execução de uma RNA deste tipo estão envolvidos três principais processos: *competição*, *cooperação* e *adaptação*.

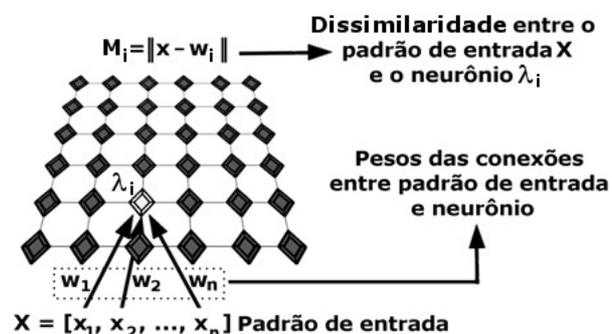


Fig. 1 - Organização topológica dos neurônios e sua relação com os padrões de entrada.

Supondo que os padrões de entrada sejam vetores representados por  $\mathbf{x} = [x_p, \dots, x_n]$  e que os pesos relacionados a um neurônio  $i$  em particular seja representado por  $\mathbf{w}_i = [w_{ip}, \dots, w_{in}]$ , o processo de *competição* consiste em encontrar o neurônio cuja dissimilaridade para um dado padrão de entrada seja mínima.

Para isso, considerando a distância euclidiana como critério de dissimilaridade,  $\lambda_i$ , para  $i = 1, \dots, k$ , é o neurônio selecionado tal que a relação da Equação 1 seja atendida.

$$\lambda_i \equiv \arg \min_{i=1, \dots, k} \|\mathbf{x} - \mathbf{w}_i\| \quad (1)$$

Após identificar o neurônio que melhor responde ao estímulo apresentado, o mesmo é incentivado a responder de forma ainda melhor a este tipo de estímulo. Para isso é realizada a atualização do vetor de pesos relacionados a este neurônio.

A atualização dos pesos consiste em um processo de *cooperação*. Na cooperação o neurônio selecionado proporciona não só a atualização de seu vetor de pesos, mas também a atualização de outros neurônios contidos em uma determinada vizinhança.

Uma maneira de realizar esta atualização é fazendo o uso de funções de vizinhança topológica. Segundo Haykin (1999), estas funções devem ser simétricas em relação ao ponto de máximo, ocupado pelo neurônio selecionado. As funções “Chapéu Mexicano” (Equação 2), “Sino” (Equação 3) e “Bolha” (Equação 4) são alguns exemplos típicos de função de vizinhança. Nestas equações,  $d_{i,j}$  representa a distância euclidiana entre o neurônio  $\lambda_i$  e seu vizinho  $\lambda_j$ . Já o parâmetro  $r$  define a largura destas funções, isto é, a zona de abrangência da vizinhança onde ocorre o processo de cooperação. A Figura 2 ilustra estas funções para uma grade de topologia retangular de dimensão 20x20, sendo (10,10) a posição do neurônio selecionado e  $r$  igual a 3.

$$N(\lambda_i, \lambda_j, r) = \left( 1 - 2 \left( \frac{d_{i,j}}{r} \right)^2 \right) e^{-\left( \frac{d_{i,j}}{r} \right)^2} \quad (2)$$

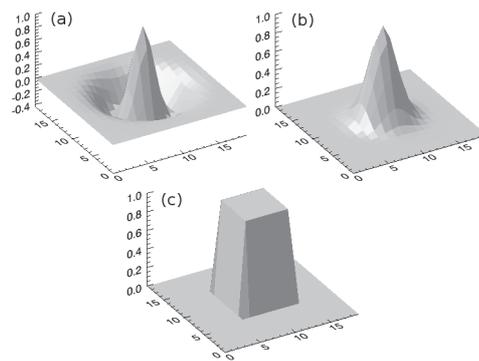
$$N(\lambda_i, \lambda_j, r) = e^{-\frac{d_{i,j}^2}{2r}} \quad (3)$$

$$N(\lambda_i, \lambda_j, r) = \begin{cases} 1, & \text{se } d_{i,j} \leq r \\ 0, & \text{caso contrário} \end{cases} \quad (4)$$

Por fim, o processo de *adaptação* é responsável pelo ajuste dos pesos dos neurônios durante a fase de aprendizado. Este processo é representado pela Equação 5 onde  $\gamma$  e  $n$  representam respectivamente a taxa do processo de aprendizado e o índice da atual iteração. Observa-se na Equação 5 que os valores de  $\gamma$  e  $r$  podem variar em função de  $n$  durante o processo de aprendizado, e por isso são denotados em função de  $n$  (i.e.,  $\gamma(n)$  e  $r(n)$ ):

$$\mathbf{w}_j(n+1) = \mathbf{w}_j(n) + \gamma(n) \times N(\lambda_i, \lambda_j, r(n)) \times [\mathbf{x} - \mathbf{w}_j(n)] \quad (5)$$

O processo de treinamento é executado por um número limitado de iterações, isto é, a imagem



**Fig. 2** – Exemplos de função vizinhança topológica: Chapéu Mexicano (a), Sino (b) e Bolha (c).

é analisada inteiramente e sequencialmente, *pixel-a-pixel*, por um número de vezes determinado pelo usuário. Ao fim desta etapa, cada neurônio é tomado como um representante de um agrupamento, e por sua vez, cada padrão passa a pertencer a um dado agrupamento em função da relação dada pela Equação 1.

### 3. O MÉTODO PROPOSTO

A proposta deste estudo consiste na incorporação de dois procedimentos adicionais ao SOM, construindo assim uma variante deste método. O primeiro procedimento se refere a uma redução na dimensão do mapa de neurônios ao longo do processo de aprendizado. Associado a esta redução ocorre uma *atenuação* da variação dos valores dos atributos dos *pixels* que pertencem

a um mesmo agrupamento. A adição destes procedimentos é motivada pelo uso do SOM em classificação de imagens e tem por objetivo a redução da classificação de *pixels* isolados, efeito este intrínseco aos métodos baseados *em pixel*.

Para isso, inicialmente é definido pelo usuário uma taxa de aprendizado ( $\gamma$ ), uma função de vizinhança topológica e seus respectivos parâmetros, como, por exemplo, sua largura ( $r$ ). Além disso, o usuário também determina as dimensões iniciais do mapa de neurônios, cujos vetores de pesos são inicializados aleatoriamente.

As primeiras etapas são idênticas às realizadas pelo método de SOM clássico, onde os *pixels* são fornecidos sequencialmente, fazendo com que os pesos do mapa de neurônios sejam adaptados. Este processo é realizado iterativamente por um número determinado de vezes, também definido inicialmente pelo usuário.

Ao fim deste procedimento, os neurônios possuem conhecimento adquirido a respeito da imagem analisada. Neste momento, eles são capazes de particionar a imagem em diferentes agrupamentos, cada um deles representado por um neurônio específico.

No contexto da modelagem matemática do método SOM, o conhecimento adquirido é representado pelos valores ajustados dos pesos dos neurônios. Já, a capacidade de particionar a imagem em diferentes agrupamentos é sintetizada pela Equação 1, sendo cada agrupamento composto pelos *pixels* cuja dissimilaridade à um dado neurônio é mínima. Como propriedade imediata dos agrupamentos gerados, é esperado que os *pixels* que os compõem sejam semelhantes entre si, apresentando pequenas variações.

Buscando minimizar estas variações entre *pixels* do mesmo agrupamento, tornando-os cada vez mais próximo do valor médio deste agrupamento, uma nova etapa, denominada por *atenuação*, é acrescentada à formulação original do SOM. Para isso é utilizada a Equação 6, onde  $f(\mathbf{x})$  é resultado da redução de variação de um dado *pixel*  $\mathbf{x}$  pertencente ao agrupamento  $\lambda_i$ , cujo vetor médio é  $\mu_i$ . Por conveniência,  $\lambda_i$  representa neste instante um agrupamento, embora seja equivalente a um neurônio, como definido inicialmente.

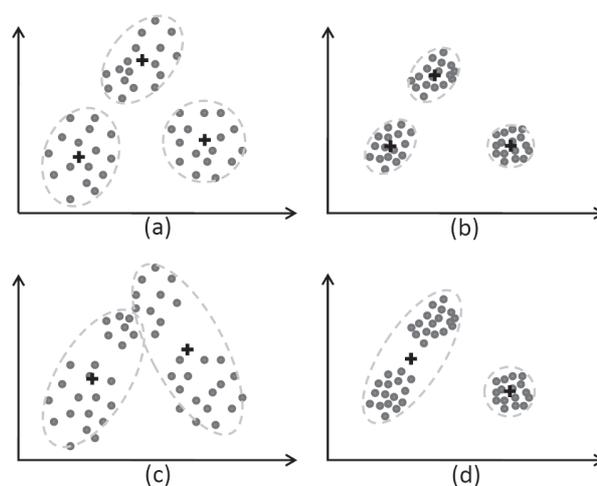
$$f(\mathbf{x}) = \mu_i + \frac{\mathbf{x} - \mu_i}{2}; \mathbf{x} \in \lambda_i \quad (6)$$

O conceito de atenuação introduzido denomina o método proposto por “Mapas Auto-Organizáveis Atenuantes” (At-SOM).

Esquemáticamente, é possível observar os resultados proporcionados pela etapa de atenuação, como apresenta a Figura 3. Nas Figuras 3.a e 3.c o agrupamento ocorre sem a atenuação em três e dois grupos, respectivamente. Já, nas Figuras 3.b e 3.d os padrões são agrupados com auxílio do processo de atenuação, mais uma vez em três e dois grupos, respectivamente. Observa-se que o processo de atenuação é capaz de modificar a distribuição dos padrões, gerando agrupamentos que não concorrem entre si, o que pode ser observado ao comparar as Figuras 3.c e 3.d.

Como resultado das iterações das etapas anteriores, é gerada uma nova imagem, a qual será processada novamente a partir de um mapa de neurônios de menor dimensão. A vantagem na redução de dimensão do mapa de neurônios é que a cada redução as variações dos valores dos *pixels* que compõem um mesmo agrupamento tendem a ser minimizadas, assim como a diferença com relação aos elementos pertencente a agrupamentos diferentes tendem a aumentar. Conseqüentemente, a cada iteração torna-se mais fácil separar os *pixels* da imagem gerada em grupos distintos.

Os procedimentos descritos sobre o método proposto são realizados sequencialmente até que seja alcançada uma dimensão mínima para o mapa



**Fig. 3** – Padrões agrupados em três grupos sem (a) e com (b) o processo de atenuação. Em seguida, agrupados em dois grupos sem (c) e com (d) o processo de atenuação.

de neurônios. A Figura 4 ilustra um diagrama com as diferentes etapas deste método.

A implementação computacional do método proposto foi realizada em linguagem de programação IDL (*Interactive Data Language*).

#### 4. METODOLOGIA

Para avaliação do método proposto, foi realizado um experimento prático envolvendo a classificação de um segmento de imagem LANDSAT-5 TM, adquirida em 23 de setembro de 2009. Em função do custo computacional exigido, o segmento de imagem adotado possui dimensão de 200x200 pixels.

Este segmento de imagem representa uma região localizada ao longo da rodovia BR-163, próxima à Floresta Nacional do Tapajós, no Estado do Pará. A seleção desta região é justificada pelo conhecimento dos tipos de cobertura da terra existentes no local, devido a um levantamento de campo conduzido no mesmo período do imageamento, além de apresentar uma clara delimitação entre tais tipos de cobertura.

Os tipos identificados de cobertura da terra foram: agricultura (dois tipos identificados – diferentes estágios de desenvolvimento), solo exposto, pastagem, floresta nativa e áreas de floresta modificadas pela ação antrópica e que atualmente estão em regeneração. A Figura 5 ilustra o segmento de imagem empregado e os diferentes tipos de cobertura da terra identificados.

Embora os tipos de cobertura da terra tenham sido observados em campo e identificados

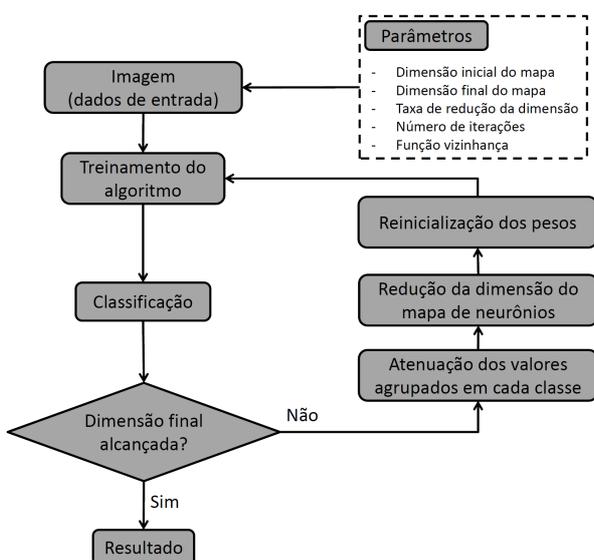


Fig. 4 – Diagrama de etapas do método At-SOM.

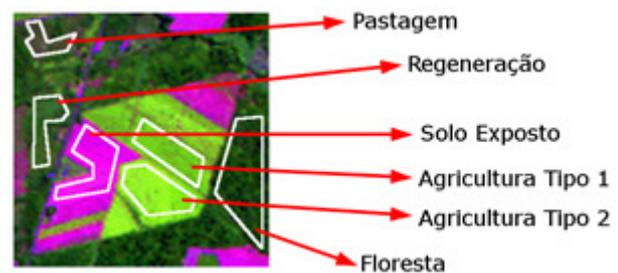


Fig. 5 – Segmento de imagem utilizado e amostras dos diferentes tipos de cobertura da terra (polígonos de borda branca).

visualmente na imagem de estudo, é necessário que haja separabilidade espectral entre tais alvos, caso contrário, os métodos de classificação tornam-se incapazes de distingui-los. Para efeito de verificação, o gráfico apresentado na Figura 6 ilustra a separabilidade espectral entre as diferentes amostras selecionadas.

Com objetivo de avaliar o desempenho do método proposto, foram realizadas classificações com os diferentes tipos de funções de vizinhança topológica apresentadas na Seção 2. Em cada classificação realizada foram utilizados mapas inicialmente com 16x16 neurônios, reduzindo a uma taxa de 4x4 até atingir uma dimensão mínima de 8x8 neurônios.

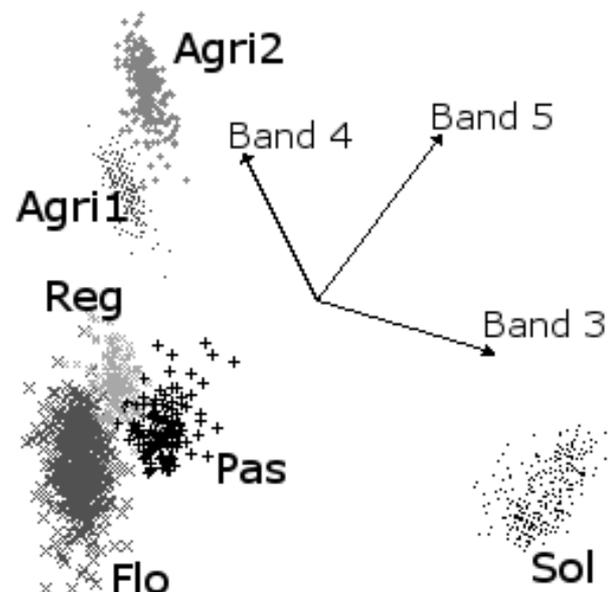


Fig. 6 – Representação das amostras identificadas na Figura 5 no espaço de atributos tridimensional, onde se verifica a separabilidade espectral entre os tipos de cobertura da terra segundo as bandas 3, 4 e 5 da imagem LANDSAT-5 TM.

A taxa de aprendizado ( $\gamma$ ) utilizada foi de 0,1, decrescendo linearmente durante 1500 iterações ( $n$ ) até atingir o valor 0,01. As larguras das funções topológicas ( $r$ ) adotadas variam de acordo com as dimensões dos mapas de neurônios, equivalendo a 25% da largura dos mapas. Apenas as bandas 3, 4 e 5 do segmento de imagem LANDSAT-5 TM foram considerados no processo de aprendizado e classificação.

Ao término do processo de aprendizado, o mapa de neurônios possui dimensão 8x8, logo, este mapa é capaz de representar até 64 agrupamentos. No entanto, como já verificado, o segmento de imagem adotado contém 6 diferentes tipos cobertura da terra. Dessa forma, com o objetivo de restringir o número de agrupamentos que o mapa de neurônios é capaz de representar, foi conduzido um agrupamento dos 64 neurônios, com uso do método K-Médias, para geração de 6 grupos de neurônios. Assim, os *pixels* que pertencem aos neurônios, de um mesmo agrupamento de neurônios, são reagrupados em um único conjunto.

Cabe ressaltar que os agrupamentos gerados são baseados apenas no comportamento espectral da imagem. Ainda, uma vez que o método possui aprendizado não supervisionado, não existe uma ligação direta entre os agrupamentos espectrais identificados no espaço de atributos da imagem e os tipos de cobertura da terra identificados espacialmente na imagem. Esta ligação é definida manualmente ao fim do processo de agrupamento, comumente denominado por “rotulação de alvos” ou “interpretação de agrupamentos”.

A avaliação das classificações foi feita através da construção das matrizes de confusão, calculadas sobre as amostras identificadas na Figura 5, e em seguida, foi computada a acurácia global. Esta medida representa a porcentagem de *pixels* classificados corretamente com relação às classes que abrangem o problema de classificação. Mais detalhes sobre a acurácia global são encontrados em Congalton e Green (1999).

Para comparar o desempenho do método desenvolvido, a imagem adotada neste estudo também foi classificada pelo método SOM clássico, conforme descrito por Kohonen (1989), e pelos métodos *Expectation Maximization* (EM) e *Fuzzy C-Médias* (FCM), todos de aprendizado não supervisionado baseados em *pixel*. Para

maiores detalhes sobre estes métodos sugere-se consultar Theodoridis e Koutroumbas (2006).

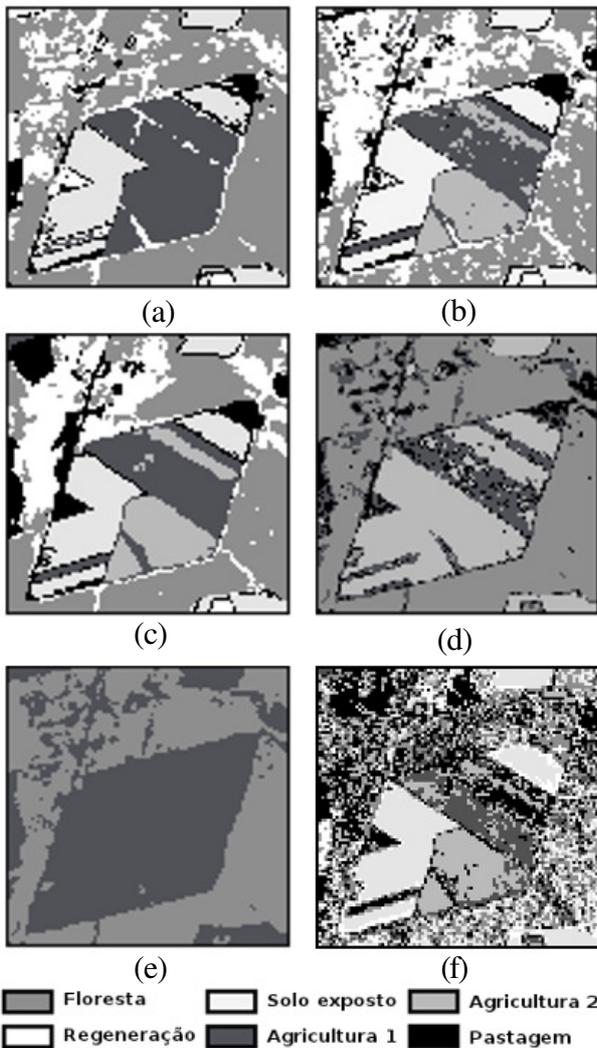
## 5. RESULTADOS E ANÁLISES

De acordo com a metodologia descrita na seção anterior, a Figura 7 ilustra os resultados obtidos pelos métodos EM, FCM, SOM clássico e pelo método proposto utilizando as funções de vizinhança topológica *Chapéu Mexicano*, *Sino* e *Bolha*. A Tabela 1 apresenta os índices de acurácia global de cada uma das classificações geradas, calculadas a partir das amostras de cobertura da terra identificadas na Figura 5. Tais amostras abrangem as seguintes quantidades de *pixels*: 668 para Floresta, 267 para Solo exposto, 258 para Agricultura do tipo 1, 365 para Agricultura do tipo 2, 158 para Regeneração e 105 para Pastagem.

Segundo a matriz de confusão da Tabela 2, o método EM não foi capaz de distinguir os diferentes tipos de agricultura, sendo todos classificados como Agricultura do tipo 1. Também não foi possível distinguir a região de Pastagem, cuja região na imagem foi classificada como Floresta ou Regeneração. Apesar destas confusões, o método apresentou uma acurácia global de 71,19% em função dos resultados para as áreas de Floresta, Solo exposto e Agricultura 1. A imagem classificada (Figura 7.a), apresentou poucos *pixels* isolados.

O método FCM obteve acurácia global de 89,35%, apresentando poucos erros de classificação, como se pode observar na matriz de confusão da Tabela 3. Neste caso houve dificuldade em distinguir a área de Pastagem, em sua maioria (79,05%) foi classificada como Regeneração. Apesar da alta acurácia global, a imagem classificada (Figura 7.b), quando comparada com a obtida pelo método de EM, apresentou uma quantidade maior de *pixels* isolados, prejudicando assim a definição das diferentes tipos de cobertura.

A imagem classificada pelo SOM clássico é ilustrada na Figura 7.f, e sua matriz de confusão na Tabela 4. É possível observar a classificação frequente de *pixels* isolados nas regiões de Pastagem, Regeneração, Floresta, e, em menor quantidade, na região de Agricultura do tipo 1. A confusão espectral na classificação destes tipos de cobertura não foi verificada nos demais resultados de classificação. Conseqüentemente, conforme apresentado na Tabela 1, este método alcançou o



**Fig. 7** – Imagem classificada pelos métodos de EM (a), FCM (b), At-SOM – Chapéu Mexicano (c), At-SOM – Sino (d), At-SOM – Bolha (e) e SOM – Clássico (f).

segundo mais baixo índice de acurácia dentre todos os resultados observados.

O maior índice de exatidão, dentre os métodos analisados, foi alcançado pelo At-SOM com uso da função vizinhança Chapéu Mexicano. A acurácia global de 95,61% reflete a capacidade de distinção entre os tipos de cobertura da terra, como ilustra a Figura 7.c e a matriz de confusão da Tabela 5.

Já, a classificação gerada pelo método At-SOM com uso da função Bolha obteve a mais baixa acurácia, não conseguindo distinguir a maioria dos tipos de cobertura da terra considerados neste estudo. Neste caso a imagem foi classificada somente em Floresta ou Agricultura do tipo 1, conforme a Figura 7.e e a matriz de confusão da Tabela 6. Estes resultados foram ocasionados pelas

**Tabela 1** – Índice de acurácia das classificações geradas.

Métodos	Acurácia (%)
<i>Expectation Maximization</i>	71,19
<i>Fuzzy C-Médias</i>	89,35
SOM – Clássico	59,95
At-SOM – Chapéu Mexicano	95,61
At-SOM – Sino	66,58
At-SOM – Bolha	50,71

**Tabela 2** – Matriz de confusão da classificação por *expectation maximization* (%).

Class.\Verd.	Flo.	Sol.	Agr. 1	Agr. 2	Reg.	Pas.
Floresta	99,25	0	0	0	31,45	43,81
Solo Exposto	0	100	0	0	0	0
Agricultura 1	0	0	100	100	0	0
Agricultura 2	0	0	0	0	0	0
Regeneração	0,75	0	0	0	68,55	56,19
Pastagem	0	0	0	0	0	0

**Tabela 3** – Matriz de confusão da classificação por *fuzzy c-médias* (%).

Class.\Verd.	Flo.	Sol.	Agr. 1	Agr. 2	Reg.	Pas.
Floresta	87,28	0	0	0	0,63	0
Solo Exposto	0	100	0	0	0	0
Agricultura 1	0	0	92,25	1,37	0	0
Agricultura 2	0	0	7,75	98,63	0	0
Regeneração	12,72	0	0	0	99,37	79,05
Pastagem	0	0	0	0	0	20,95

equações definidoras deste método. Na Equação 4 observa-se uma relação booleana a qual, aplicada na Equação 5, prejudicou a etapa de *adaptação*. Neste sentido, foi distinguido o agrupamento formado por Floresta, Pastagem e Regeneração do agrupamento composto pelos tipos de Agricultura e Solo Exposto. Esta estrutura de agrupamento pode ser verificada na Figura 6.

Por fim, o método At-SOM associado à função Sino também apresentou dificuldades em distinguir os diferentes tipos de cobertura da terra observados, conforme exibido a Figura 7.d. Neste caso não são observadas na matriz de confusão da Tabela 7 classificações de Solo exposto e de Regeneração, além de existir grande confusão sob a amostra de Pastagem. Mais uma vez estes resultados foram ocasionados pelas equações definidoras deste método.

Em especial, na função Chapéu Mexicano, a existência de uma região de estímulo (valores positivos) seguida de uma região penalizadora à cooperação entre os neurônios (valores negativos) foi importante para melhor definição dos

agrupamentos, e que por sua vez, propiciou melhor separação entre os tipos de cobertura da terra analisados. A ausência desta região penalizadora na função Sino pode justificar a perda de desempenho de exatidão comparado ao resultado obtido com a função Chapéu Mexicano. Consequentemente, por apenas definir uma vizinhança onde deve haver cooperação entre os neurônios, sem considerar uma redução gradual dada pela distância, como define a função Sino, é justificado o desempenho ainda mais baixo com uso da função Bolha.

**Tabela 4** – Matriz de confusão da classificação por som clássico (%).

Class.\Verd.	Flo.	Sol.	Agr. 1	Agr. 2	Reg.	Pas.
Floresta	29,47	0	0	0	9,18	0,88
Solo Exposto	17,24	100	0	0	0	2,43
Agricultura 1	11,02	0	82,13	6,84	4,8	0
Agricultura 2	11,73	0	14,31	90,51	23,31	5,52
Regeneração	17,35	0	0	0	1,41	0
Pastagem	13,18	0	3,56	2,64	61,3	91,17

**Tabela 5** – Matriz de confusão da classificação por at-som – chapéu mexicano (%).

Class.\Verd.	Flo.	Sol.	Agr. 1	Agr. 2	Reg.	Pas.
Floresta	96,41	0	0	0	0	0
Solo Exposto	0	100	0	0	0	0
Agricultura 1	0	0	96,9	0	0	0
Agricultura 2	0	0	3,1	100	0	5,52
Regeneração	3,59	0	0	0	86,79	25,71
Pastagem	0	0	0	0	13,21	74,29

**Tabela 6** – Matriz de confusão da classificação por at-som – bolha (%).

Class.\Verd.	Flo.	Sol.	Agr. 1	Agr. 2	Reg.	Pas.
Floresta	99,7	0	0	0	70,44	45,71
Solo Exposto	0	0	0	0	0	0
Agricultura 1	0,3	100	100	100	29,56	54,67
Agricultura 2	0	0	0	0	0	0
Regeneração	0	0	0	0	0	0
Pastagem	0	0	0	0	0	0

**Tabela 7** – Matriz de confusão da classificação por at-som – sino (%).

Class.\Verd.	Flo.	Sol.	Agr. 1	Agr. 2	Reg.	Pas.
Floresta	99,25	0	0	0	70,44	45,71
Solo Exposto	0	0	0	0	0	0
Agricultura 1	0,3	0	67,44	0,27	27,04	41,9
Agricultura 2	0	100	14,73	99,45	0	0
Regeneração	0	0	0	0	0	0
Pastagem	0,45	0	17,83	0,27	2,52	12,38

## 6. CONCLUSÕES E CONSIDERAÇÕES FINAIS

Conforme a análise dos resultados do estudo de caso realizado, observou-se que cada método de classificação empregado obteve resultados consideravelmente diferentes no que se refere à confusão entre os tipos de cobertura, às acurácias globais e às imagens classificadas. Nenhum tipo de cobertura da terra observado apresentou confusão em todos os métodos, o que evidencia a possibilidade de separação entre os mesmos.

Com relação ao método proposto (At-SOM), o resultado de melhor acurácia foi obtido com uso da função Chapéu Mexicano, superando inclusive as acurácias globais obtidas pelos métodos EM e FCM. No entanto, o mais baixo índice de acurácia também foi obtido pelo método At-SOM, quando associado à função vizinhança do tipo Bolha. Com isso, induz-se que um dos fatores decisivos à acurácia é a função de vizinhança topológica.

As análises realizadas sobre as imagens classificadas mostraram que o método proposto foi capaz de reduzir a presença de *pixels* isolados. Isto ocorreu em função do processo de atenuação, cujo propósito é aumentar a separabilidade espectral dos alvos a partir de modificações sucessivas sobre a imagem original.

O alto custo computacional, característica do método SOM clássico (KOHONEN, 1989), continuou sendo uma fragilidade presente no método proposto. Este fator impediu a aplicação deste método em imagens de dimensões maiores, assim como a execução de estudos sobre a sensibilidade dos parâmetros.

Como perspectiva futura ao desenvolvimento de novos trabalhos, sugere-se o estudo de meios para redução do custo computacional exigido durante a etapa de aprendizado. Novos testes com imagens de outros sensores, com dimensões maiores, diferentes quantidades de bandas e tipos de cobertura, assim como uma análise de sensibilidade dos parâmetros, são verificações necessárias para que se possa solidificar a viabilidade deste método de classificação.

## AGRADECIMENTOS

Os autores agradecem a CAPES pelo suporte financeiro.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ALMEIDA, C. M.; ALVES, C. D.; PEREIRA, M. N.; MIGLIORANZA, E.; TOMÁS, L. R. Morphological metrics and unsupervised neural networks to analyze urban sprawl and intercity commuting. *Simpósio Brasileiro de Sensoriamento Remoto*, Florianópolis, 2007. **Anais**. p. 5059-5066, 2007.
- ALVES, C. D.; PEREIRA, M. N.; FLORENZANO, T. G. Mapeamento das novas formas de ocupação urbana por meio da análise orientada a objeto. Estudo de caso: aglomeração urbana de Piracicaba. *Simpósio Brasileiro de Sensoriamento Remoto*, Natal, 2009. **Anais**. p. 569-576, 2009.
- CHESNEL, A.; BINET, R.; WALD, L. Object oriented assessment of damage due to natural disaster using very high resolution images. *IEEE International Geoscience & Remote Sensing Symposium*, Barcelona, 2007. **Anais**. p. 3736-3739, 2007.
- CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. Lewis Publisher, Boca Raton, 1999. 160p.
- DEMPSTER, A. P.; LAIRD, N. M.; RDIN, D. B. Maximum Likelihood from Incomplete Data via the EM Algorithm. **Journal of the Royal Statistical Society**, v. 39, p.1-38, 1977.
- FREITAS, R. M.; ADAMI, M.; RUDORFF, B. F. T.; SHIMABUKURO, Y. E.; ROSA, R. R.; SILVA, J. D. S.; ARCOVERDE, G. F. B. Análise exploratória de dados multitemporais de sensoriamento remoto usando mapas auto-organizáveis: estudo em áreas de expansão da cana-de-açúcar. *Simpósio Brasileiro de Sensoriamento Remoto*, Natal, 2009. **Anais**. p. 7797-7804, 2009.
- GUO, Q.; KELLY, M.; GONG, P.; LIU, D. An Object-Based Classification Approach in Mapping Tree Mortality Using High Spatial Resolution Imagery. **GIScience Remote Sensing**, v.44, n.1, p.24-47, 2007.
- HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. New York: Prentice-Hall, 2nd edition, 1999. 900p.
- IYODA, E. M. **Inteligência computacional no projeto automático de redes neurais híbridas e redes neurofuzzy heterogêneas**. Dissertação de Mestrado em Engenharia Elétrica, UNICAMP, Campinas, 2000. 166p.
- KOHONEN, T. **Self-organization and associative memory**. 3rd edition. New York: Springer-Verlag, 1989.
- KIYASU, S.; YAMADA, Y.; MIYAHARA, S. Semi-supervised land cover classification of remotely sensed data using two different types of classifiers. **International Conference on Control, Automation and Systems**, Fukuoka, p.4874-4877, 2009.
- KORTING, T. S.; FONSECA, L. M. G.; BACAO, F. L. Expectation-Maximization x Self-Organizing Maps for Image Classification. *Signal-Image Technologies and Internet-Based System*, International IEEE Conference, 2008. **Anais**. p. 359-365, 2008.
- LIU, D.; FAN, X. Assessing object-based classification: advantages and limitations. **Remote Sensing Letters**, v.1, n.4, p.187-194, 2010.
- MATHER, P. M. **Computer Processing of Remotely-Sensed Images - A Introduction**. New York: John Wiley & Sons, Second edition, 1999. 292p.
- MENDES JUNIOR, C. W.; ARIGONY-NETO, J.; RIBEIRO, R. R.; SIMÕES, J. C. Estudo das variações espaço-temporais de fácies de geleiras da região nordeste da península Antártica (1993-2000) através de imagens ERSAMI SAR. *Simpósio Brasileiro de Sensoriamento Remoto*, Natal, 2009. **Anais**. p. 7331-7338, 2009.
- PRODES, Programa de cálculo do desflorestamento da Amazônia. **Instituto Nacional de Pesquisas Espaciais**. Disponível em <<http://www.obt.inpe.br/prodes/>>. Acesso: 18 abril 2009.
- RIBEIRO, B. M. G.; KUX, H. J. H. Classificação Orientada a Objeto para Mapeamento do Uso do Solo - Métodos de Análise de Expansão Urbana. *Simpósio Brasileiro de Sensoriamento Remoto*, Natal, 2009. **Anais**. p. 7893-7900, 2009.
- RICHARDS, J. A.; JIA, X. **Remote Sensing Digital Image Analysis: An Introduction**. Berlin : Springer-Verlag, 4th edition, 2006. 439.

*AT-SOM: mapas auto-organizáveis atenuantes*

- RICHARDSON, A. J.; RISIEN, C.; SHILLINGTON, F.A. Using self-organizing maps to identify patterns in satellite imagery. **Progress In Oceanography**, v. 59, n.2, p. 223 - 239, 2003.
- SILVA, C. C.; SANTOS, W. P. Análise de Imagens CBERS da Bacia do Rio São Francisco utilizando Mapas Auto-Organizados de Kohonen e Classificador K-Médias. Simpósio Brasileiro de Sensoriamento Remoto, Natal, 2009. **Anais**. p. 2209-2216, 2009.
- THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern Recognition**. 3rd edition, San Diego: Academic Press, 2006.
- VAPNIK, V. N. **Statistical Learning Theory**. New York: Wiley-Interscience, 1998. 736p.