

CLASSIFICAÇÃO NÃO-SUPERVISIONADA DE IMAGENS DE SENSORES REMOTOS UTILIZANDO REDES NEURAI AUTO-ORGANIZÁVEIS E MÉTODOS DE AGRUPAMENTOS HIERÁRQUICOS

Unsupervised classification of remote sensors images using self-organizing neural networks and hierarchical clustering methods

Márcio Leandro Gonçalves^{1,2}
Márcio Luiz de Andrade Netto²
Jurandir Zullo Jr.³
José Alfredo Ferreira Costa⁴

¹**Pontifícia Universidade Católica de Minas Gerais – PUC Minas**
Departamento de Ciência da Computação
Av. Padre Francis Cletus Cox, 1661, CEP 37701-355, Poços de Caldas-MG, Brasil
marcio@pucpcaldas.br

Universidade Estadual de Campinas - UNICAMP

²**Faculdade de Engenharia Elétrica e de Computação – FEEC**

³**Centro de Pesquisas Meteorológicas e Climáticas Aplicadas à Agricultura – CEPAGRI**
Cidade Universitária Zeferino Vaz, CEP 13083-970, Campinas – SP, Brasil
marcio@dca.fee.unicamp.br, jurandir@cpa.unicamp.br

⁴**Universidade Federal do Rio Grande do Norte - UFRN**
Departamento de Engenharia Elétrica – DEE
Campus Universitário - Lagoa Nova, CEP 59072-970, Natal – RN, Brasil
alfredo@dee.ufrn.br

RESUMO

Este trabalho apresenta uma nova metodologia para a classificação não-supervisionada de imagens de sensoriamento remoto. Diferentemente dos métodos convencionais de classificação não-supervisionada, como o K-médias e o ISODATA, os quais se baseiam somente em técnicas de agrupamentos particionais, a metodologia proposta realiza a classificação automática de imagens através de uma abordagem inovadora empregando o Mapa Auto-organizável de Kohonen (SOM – *Self-Organizing Map*) em conjunto com um método de agrupamento hierárquico aglomerativo. O ponto chave do método proposto é executar o processo de análise de agrupamentos através de um conjunto de protótipos do SOM ao invés de trabalhar diretamente com os padrões originais da imagem. Essa estratégia reduz significativamente a complexidade da análise dos dados tornando possível a utilização de técnicas normalmente consideradas inviáveis para o processamento de imagens de sensoriamento remoto, como métodos de agrupamentos hierárquicos e índices de validação de agrupamentos. Através do SOM, o método proposto mapeia os padrões originais da imagem para uma grade de neurônios bidimensional procurando preservar a distribuição de probabilidade e a topologia dos mesmos. Posteriormente, um método de agrupamento hierárquico aglomerativo com restrições de conectividade é aplicado sobre a grade de neurônios já treinada, gerando um dendrograma simplificado para os dados da imagem. Cada nível do dendrograma apresenta uma configuração diferente de agrupamentos de neurônios (ou protótipos) do SOM que pode ser utilizada para representar as classes sobre as quais a imagem original será classificada. Aplicando versões modificadas de índices de validação de agrupamentos o método determina automaticamente o número ideal de agrupamentos da imagem não exigindo que o usuário defina previamente a quantidade de classes para realizar o processo de classificação. Os resultados experimentais mostram um exemplo de aplicação da metodologia proposta sobre uma imagem teste e compara o seu desempenho com o do algoritmo K-médias.

Palavras chaves: processamento digital de imagens, sensoriamento remoto, classificação não-supervisionada, redes neurais artificiais.

ABSTRACT

This work presents a new methodology for the unsupervised classification of remotely sensed images. Differently of the traditional methods of unsupervised classification, such as K-means and ISODATA, which use only partitional clustering techniques, the proposed methodology accomplishes the automatic classification of images through an innovative approach applying the Kohonen Self-Organizing Map (SOM) together with an agglomerative hierarchical clustering method. The key point of the proposed method is to execute the clustering process through a set of prototypes of the SOM instead of analyzing directly the original patterns of the image. This approach significantly reduces the complexity of the analysis becoming possible the use of techniques that normally are considered impracticable for the digital processing of remotely sensed images, such as hierarchical clustering methods and cluster validity indexes. Using the SOM, the proposed method maps the original patterns of the image to a set of neurons arranged in a two-dimensional lattice searching to preserve the probability distribution and the topology of the input space. Subsequently, an agglomerative hierarchical clustering method with restricted connectivity is applied on the lattice of neurons previously trained, generating a simplified dendrogram for the image data. Each level of the dendrogram corresponds to a different configuration of clusters of neurons (or prototypes) of the SOM that can be used to represent the classes on which the original image will be classified. Applying modified versions of cluster validity indexes the method automatically determines the ideal number of clusters of the image not demanding that the user previously defines the quantity of classes to execute the classification process. The experimental results show an application example of the proposed method on a test image and its performance is compared with the K-means algorithm.

Keywords: digital image processing, remote sensing, unsupervised classification, artificial neural networks.

1. INTRODUÇÃO

Desde o lançamento dos primeiros satélites voltados para a exploração de recursos terrestres, os métodos digitais de classificação de imagens de sensoriamento remoto têm adquirido uma importância crescente no reconhecimento automático de padrões da superfície terrestre (RICHARDS *et al.*, 2005). Atualmente a enorme quantidade de imagens que estão sendo coletadas por sistemas sensores cada vez mais modernos e sofisticados requer o desenvolvimento de metodologias de classificação inovadoras, as quais possibilitem uma exploração automática e eficiente do grande volume de dados disponíveis nas imagens e, ao mesmo tempo, tornem o processo de mapeamento de características da superfície terrestre menos subjetivo e com maior potencial de repetição em situações subsequentes.

Na literatura existe uma grande variedade de propostas de algoritmos para a classificação de imagens de sensoriamento remoto. Diferentes técnicas provenientes de diversas áreas de pesquisa estão sendo utilizadas como base para o desenvolvimento desses algoritmos, entre elas: a estatística (DEAN *et al.*, 2003), redes neurais (GONÇALVES *et al.*, 1996), máquinas de vetores-suporte (PAL *et al.*, 2005), algoritmos genéticos (ALIXANDRINI *et al.*, 2002), lógica nebulosa (WANG, 1990) e árvores de decisão (HANSEN *et al.*, 1996).

Em sensoriamento remoto tradicionalmente as técnicas de classificação de imagens são agrupadas em três categorias gerais: supervisionada, não-supervisionada e híbrida (LILLESAND *et al.*, 2000). Particularmente, a classificação não-supervisionada baseia-se no princípio de que o algoritmo

computacional é capaz de identificar por si só as classes dentro de um conjunto de dados. Esse tipo de classificação é frequentemente realizado através de métodos de agrupamentos (*clustering*).

Embora exista uma grande quantidade de diferentes métodos de agrupamentos na área de reconhecimento de padrões (XU *et al.*, 2005), a maioria dos softwares ou sistemas computacionais voltados para o processamento digital de imagens de sensoriamento remoto realiza a classificação não-supervisionada baseada em métodos de agrupamentos particionais, como o K-médias e o ISODATA (BALL *et al.*, 1967).

Apesar de serem amplamente utilizados esses métodos particionais de agrupamentos apresentam diversas limitações. As funções objetivo usadas por eles partem do pressuposto de que o número de agrupamentos ou classes, K , é conhecido a priori. Na hipótese de se ter escolhido um valor K' inadequado o método irá impor, pelo uso de técnicas de otimização, K' agrupamentos aos dados. O usuário também deve especificar manualmente vários parâmetros para controlar o processo de agrupamento, entre eles: os centróides iniciais de cada agrupamento, o número máximo de iterações, limiares para realizar a divisão, fusão ou exclusão de agrupamentos. O K-médias e o ISODATA são muito sensíveis a esses parâmetros, podendo gerar partições diferentes quando são feitas várias simulações para um mesmo conjunto de dados. Outras limitações não menos importantes desses algoritmos particionais são: o alto custo computacional quando o conjunto de dados a ser analisado é muito grande (a cada iteração todos os pixels da imagem são comparados com todos os centros de agrupamentos) e a existência de suposições sobre a forma dos agrupamentos. Geralmente apenas um protótipo

(centróide) é utilizado para representar um agrupamento, portanto esses métodos tornam-se adequados apenas para analisar agrupamentos que apresentam formatos hiperesféricos (GONÇALVES *et al.*, 2005).

Outra forma possível, mas não usual, de realizar a classificação não-supervisionada de imagens de sensoriamento remoto é através de métodos hierárquicos de agrupamentos. Diferentemente dos métodos particionais, os métodos hierárquicos não exigem que o usuário especifique previamente o número de agrupamentos e outros parâmetros adicionais. Outra vantagem significativa desses métodos é a de possibilitar a visualização do resultado da classificação por meio de um dendrograma, que ilustra de forma hierárquica o grau de semelhança entre os agrupamentos que são formados por fusões (ou divisões) em cada estágio sucessivo da análise. Entretanto, os métodos hierárquicos apresentam algumas características que inviabilizam a sua aplicação na classificação de imagens de sensoriamento remoto: (a) em geral requerem espaço de memória de ordem $O(N^2)$, onde N é o número de registros do conjunto de dados; (b) os resultados podem ser difíceis de interpretar, principalmente para conjuntos de dados grandes; (c) para determinar qual a linha de “corte” do dendrograma há a necessidade de se aplicar algum critério de decisão (DUDA *et al.*, 2002). Conseqüentemente, na literatura é quase imperceptível a existência de trabalhos que aplicam métodos hierárquicos de agrupamentos na análise de imagens de sensoriamento remoto.

Diante desse cenário, o presente trabalho apresenta uma nova metodologia para a classificação não-supervisionada de imagens de sensoriamento remoto. Na metodologia proposta o Mapa Auto-organizável de Kohonen (SOM – *Self-Organizing Map*) é utilizado para mapear os padrões originais da imagem para uma grade de neurônios bidimensional. O objetivo é quantizar e representar os padrões da imagem em um espaço de menor dimensão, buscando preservar a distribuição de probabilidade e a topologia dos mesmos. Posteriormente, um método de agrupamento hierárquico aglomerativo é aplicado sobre a grade de neurônios do SOM já treinado, gerando um dendrograma de neurônios agrupados com diferentes graus de similaridade. Cada nível do dendrograma obtido corresponde a uma configuração diferente de agrupamentos de neurônios do SOM que pode ser utilizada para representar as classes sobre as quais a imagem original será classificada.

Além de viabilizar a aplicação de um método hierárquico, a idéia de representar a imagem através dos neurônios de um SOM possibilita a descoberta de agrupamentos com geometrias complexas e variadas, tendo em vista que as classes da imagem são representadas por grupos de neurônios e não apenas por um único protótipo. Além disso, procurando explorar todas as propriedades do SOM e reduzir ainda mais o volume de processamento do processo de classificação, a metodologia proposta emprega um algoritmo de

agrupamento hierárquico com conectividade restrita e índices de validação de agrupamentos calculados de maneira modificada para determinar o número ideal de classes da imagem.

Buscando garantir ainda uma maior eficiência no processo de classificação, o método proposto extrai as informações da imagem por meio de janelas de pixels, a fim de incorporar informações de contexto. Seguindo essa abordagem, antes de se aplicar o algoritmo de agrupamento hierárquico o método filtra protótipos heterogêneos do SOM, os quais representam padrões (janelas de pixels) correspondentes a regiões de transição entre diferentes classes de cobertura terrestre. Os padrões originais associados a esses protótipos heterogêneos são classificados de forma particular somente no final do processo, considerando as classes dos pixels vizinhos que já foram rotulados.

O restante do artigo está organizado da seguinte forma: a seção 2 descreve sucintamente o SOM, a seção 3 apresenta uma breve explanação sobre métodos de agrupamentos hierárquicos aglomerativos, enquanto a seção 4 apresenta a metodologia de classificação proposta. Resultados experimentais mostrando uma comparação do método proposto com o algoritmo K-médias são mostrados na seção 5, e a seção 6 apresenta as conclusões e considerações finais.

2. MAPA AUTO-ORGANIZÁVEL DE KOHONEN

O Mapa Auto-organizável de Kohonen (SOM – *Self-Organizing Map*) é um tipo de rede neural artificial baseada em aprendizado competitivo e não-supervisionado, i.e., nenhuma informação sobre as classes dos sinais de entrada é utilizada no processo de ajuste dos pesos sinápticos da rede (KOHONEN, 1997).

A rede consiste essencialmente de duas camadas: uma camada de entrada I e uma camada de saída U com neurônios geralmente dispostos em um arranjo topológico bidimensional. A entrada da rede corresponde a um vetor p -dimensional, \mathbf{x} , geralmente no espaço \mathcal{R}^p . Todas as p componentes do vetor de entrada alimentam cada um dos neurônios do mapa. Cada neurônio i pode ser representado por um vetor de pesos sinápticos $\mathbf{w}_i = [w_{i1}, w_{i2}, \dots, w_{ip}]^T$, também no espaço p -dimensional.

Para cada padrão de entrada \mathbf{x} um neurônio é escolhido o vencedor, c , usando o critério de maior similaridade:

$$\|\mathbf{x} - \mathbf{w}_c\| = \min_i \{\|\mathbf{x} - \mathbf{w}_i\|\} \quad (1)$$

onde $\|\cdot\|$ representa a distância Euclidiana. Os pesos do neurônio vencedor, juntamente com os pesos dos seus neurônios vizinhos, são ajustados de acordo com a seguinte equação:

$$\mathbf{w}_i(t+1) = \mathbf{w}_i(t) + h_{ci}(t)[\mathbf{x}(t) - \mathbf{w}_i(t)] \quad (2)$$

onde t indica a iteração do processo de treinamento, $\mathbf{x}(t)$ é o padrão de entrada e $h_{ci}(t)$ é o núcleo de vizinhança ao redor do neurônio vencedor c . Este último termo é

uma função decrescente com o tempo e com a distância do neurônio i ao neurônio vencedor c , e geralmente corresponde ao produto de duas componentes: a taxa de aprendizado $\alpha(t)$ e a função de vizinhança $h(d,t)$:

$$h_{ci}(t) = \alpha(t) \cdot h(\|r_c - r_i\|, t) \quad (3)$$

onde r_i e r_c são, respectivamente, as posições do neurônio i e do neurônio vencedor no arranjo topológico da rede.

Uma propriedade importante do SOM, derivada da quantização vetorial gerada pelo algoritmo, é a de aproximar o espaço de entrada buscando preservar a ordenação topológica e a densidade dos dados. Isso possibilita obter informações dos agrupamentos de dados originais analisando as relações geométricas dos neurônios do mapa treinado (HAYKIN, 1999).

3. MÉTODOS DE AGRUPAMENTOS HIERÁRQUICOS AGLOMERATIVOS

Mais comuns dentre os métodos de agrupamentos hierárquicos, as técnicas aglomerativas iniciam a análise dos dados considerando a existência de N agrupamentos, cada um deles contendo exatamente um único objeto do conjunto de dados. Sucessivas operações de fusão entre os agrupamentos são então efetuadas até que exista um único agrupamento contendo todos os N objetos. Os passos de um método hierárquico aglomerativo podem ser descritos da seguinte forma:

1. Inicie com N agrupamentos C_1, C_2, \dots, C_N cada um contendo exatamente um único objeto.
2. Determine o par de agrupamentos distintos (C_i, C_j) , de modo que:

$$D(C_i, C_j) = \min_{\substack{1 \leq m, l \leq N \\ m \neq l}} D(C_m, C_l) \quad (4)$$

onde $D(*,*)$ é uma função de distância.

3. Forma-se um novo agrupamento C_k pela união dos agrupamentos C_i e C_j , i.e., $C_k = C_i \cup C_j$.
4. Calculam-se as novas distâncias, $D(C_k, C_l)$, entre o novo agrupamento C_k e todos os outros restantes.
5. Repita os passos 2, 3 e 4 até que todos os objetos estejam em um único agrupamento.

Existem diversas variantes de métodos hierárquicos aglomerativos baseadas em diferentes formas de calcular a distância $D(*,*)$ entre o agrupamento formado (C_k) e todos os outros agrupamentos. Os métodos de agrupamentos hierárquicos aglomerativos mais simples e populares são o método de Ligações Simples (ou de vizinhos mais próximos) e o de Ligações Completas (XU *et al.*, 2005).

Os resultados de um método hierárquico aglomerativo são usualmente descritos por um diagrama de similaridade, chamado de dendrograma. O

dendrograma hierarquiza o grau de semelhança entre os agrupamentos tornando possível obter uma visão bidimensional da similaridade ou dissimilaridade de todos os dados. Esta propriedade facilita a comparação de diferentes configurações de agrupamentos para um mesmo conjunto de dados. Entretanto, para se determinar o nível apropriado do dendrograma ou o número ideal de agrupamentos algum critério de decisão deve ser empregado.

4. METODOLOGIA PROPOSTA

A metodologia proposta neste trabalho essencialmente busca explorar em conjunto as propriedades do SOM e dos métodos de agrupamentos hierárquicos aglomerativos para realizar a classificação não-supervisionada de imagens de sensoriamento remoto. A Fig. 1 ilustra de maneira simplificada o método proposto e a seguir são apresentadas as suas etapas principais:

1. *Amostragem*: amostras na forma de janelas de pixels são coletadas de maneira uniforme sobre toda a região da imagem e fornecidas como padrões de entrada para o SOM.
2. *Treinamento do SOM*: o treinamento não-supervisionado do SOM é realizado e um mapa de características da imagem composto pelos neurônios da rede (protótipos) é obtido.
3. *Filtragem de protótipos*: os protótipos do SOM que apresentam atividade nula são descartados e aqueles que apresentam alto grau de heterogeneidade espectral (protótipos heterogêneos) são excluídos do próximo passo.
4. *Análise hierárquica aglomerativa*: um método de agrupamento hierárquico aglomerativo com restrições de conectividade é aplicado sobre os protótipos do SOM já filtrado, gerando um dendrograma do mapa.
5. *Avaliação dos agrupamentos*: um índice de validação de agrupamentos calculado de forma modificada é aplicado em todos os níveis do dendrograma obtido no passo 4 para determinar o número ideal de agrupamentos.
6. *Classificação do SOM*: os protótipos do SOM são rotulados de acordo com as classes de protótipos determinadas no passo 5.
7. *Classificação da imagem*: os protótipos do SOM rotulados no passo 6 em conjunto com os protótipos heterogêneos (filtrados no passo 3) são utilizados como referência para classificar todos os pixels da imagem.
8. *Refinamento*: cada um dos pixels da imagem que foram associados a algum protótipo heterogêneo é reclassificado utilizando a classe do pixel vizinho que apresenta a menor distância (espectral) a ele.

Nas próximas subseções cada um dos passos da metodologia proposta é explicado com maiores detalhes.

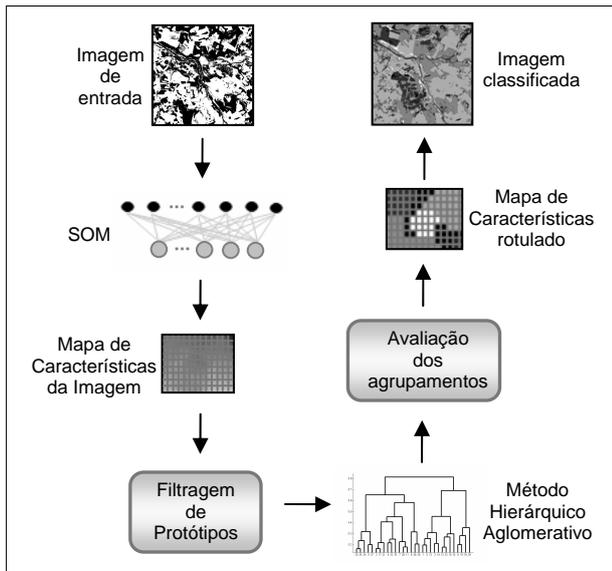


Fig. 1 – Ilustração da metodologia de classificação.

4.1 Amostragem

O passo 1 da metodologia proposta consiste em coletar um conjunto de amostras da imagem para realizar o treinamento do SOM. Diferentemente de abordagens pixel a pixel que utilizam apenas a informação espectral de pontos individuais para encontrar regiões homogêneas, o presente trabalho realiza a amostragem da imagem através de janelas de pixels. A idéia é incorporar no processo de classificação informações de vizinhança (contexto), tendo em vista que pixels isolados não são capazes de representar a maioria dos padrões de cobertura terrestre, especialmente no caso de imagens que apresentam resoluções espaciais mais altas. Embora a estratégia de utilizar informações de pixels vizinhos apresente um maior custo computacional do que uma abordagem pixel a pixel, na literatura vários trabalhos têm mostrado que esse esforço é justificado por um aumento proporcional na acurácia da classificação (MAGNUSSEN *et al.*, 2004).

Outros dois pontos importantes relacionados com o processo de amostragem são a forma de extração das janelas amostrais e o tamanho das mesmas.

As janelas amostrais são coletadas de maneira uniforme sobre toda a região da imagem, sem sobreposições e em intervalos regulares (de no máximo 10 pixels). Todas as amostras são quadradas e possuem o mesmo tamanho.

A determinação do tamanho das amostras não é uma tarefa simples de ser automatizada. Dependendo das características da imagem a ser classificada, janelas muito pequenas podem não capturar o padrão particular das classes, enquanto janelas maiores podem incluir pixels de mais do que uma classe. No entanto, partindo de um tamanho não inferior a 5x5, o usuário possui dentro da metodologia proposta um certo grau de flexibilidade para definir a dimensão das janelas amostrais, não sendo portanto essa tarefa um ponto crítico do processo. Caso sejam capturadas janelas

amostrais que incorporem mais de uma classe, o método proposto (através dos passos 3 e 8) trata de maneira diferenciada os protótipos do SOM que representam essas janelas heterogêneas. Além disso, protótipos que possuem mais de uma classe podem funcionar como bordas no mapa de características do SOM contribuindo para a separação dos agrupamentos.

4.2 Treinamento do SOM

Para realizar o treinamento do SOM é necessário especificar alguns parâmetros que definem a estrutura do mapa e que controlam o treinamento propriamente dito. Com o objetivo de garantir um bom mapeamento dos padrões originais, a metodologia proposta define de modo particular os parâmetros da rede baseando-se na literatura existente, em testes experimentais e em algumas peculiaridades da aplicação do SOM em imagens de sensores remotos. Todavia, alternativas também podem ser buscadas para se obter bons mapas. Uma boa revisão sobre os parâmetros de treinamento do SOM pode ser obtida em COSTA, (1999).

A metodologia proposta utiliza os seguintes parâmetros para realizar o treinamento da rede:

- Inicialização dos pesos: linear
- Apresentação dos padrões: em lote
- Número de épocas de treinamento: 500
- Tipo de função de vizinhança: gaussiana
- Formato do arranjo: retangular.

O tamanho do mapa é um dos parâmetros livres do SOM que depende particularmente da imagem de entrada. O principal propósito para escolher um tamanho apropriado para o SOM é realizar um bom mapeamento dos padrões da imagem no arranjo topológico de neurônios. Contudo, o desempenho da metodologia de classificação proposta não é significativamente afetado se tamanhos suficientemente grandes para o SOM forem utilizados. Embora mapas com dimensões maiores do que a necessária apresentem uma quantidade maior de neurônios inativos, i.e., neurônios que não possuem nenhum padrão de entrada associado a eles, este evento não é prejudicial dentro da metodologia proposta. Assim como o método trata de maneira adequada protótipos heterogêneos, o mesmo acontece com os protótipos inativos.

No final da etapa de treinamento do SOM tem-se, portanto, um conjunto de protótipos (neurônios) que representam todos os padrões de entrada coletados a partir da imagem original.

4.2.1 Mapa de Características da Imagem

A metodologia proposta possui uma particularidade em relação ao mapeamento da imagem através do SOM que deve ser destacada. Uma vez que os neurônios do SOM são dispostos espacialmente na forma de uma grade retangular, e considerando ainda

que nesta rede neural os vetores de pesos de cada neurônio possuem as mesmas dimensões que os padrões de entrada (que neste caso são janelas de pixels), torna-se possível gerar uma imagem da grade de neurônios do mapa. Conforme mostra a Fig. 2, os neurônios ou protótipos do SOM (através dos seus vetores de pesos sinápticos) correspondem a janelas de pixels, o que permite a visualização dos mesmos na forma de uma imagem. Essa representação visual da grade de neurônios do SOM, após o seu treinamento não supervisionado, foi denominada aqui de *Mapa de Características da Imagem* (MCI).

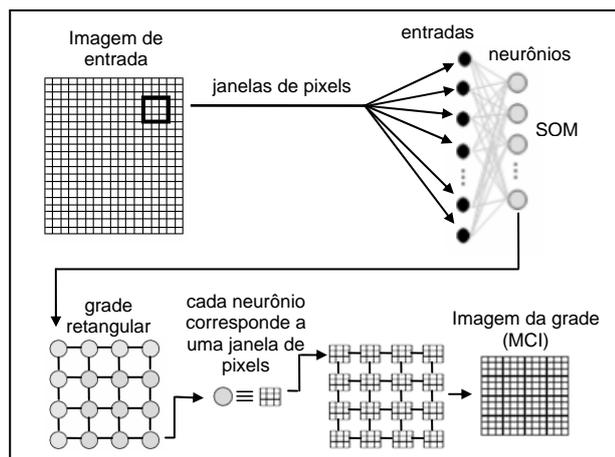


Fig. 2 – Ilustração do processo de construção do Mapa de Características da Imagem.

Conforme será apresentado nos resultados experimentais (seção 5), através do MCI é possível visualizar o mapeamento dos padrões da imagem de entrada realizado pelo SOM e suas respectivas propriedades.

4.3 Filtragem de protótipos

O passo 3 da metodologia proposta consiste em filtrar dois tipos de protótipos que geralmente aparecem no mapeamento dos padrões da imagem através do SOM. Esses protótipos são chamados aqui de *inativos* e *heterogêneos*.

Os protótipos inativos correspondem àqueles neurônios que apresentam atividade nula no processo de aprendizado competitivo do SOM, e por isso não possuem nenhum padrão de entrada associado a eles. Esses protótipos são simplesmente descartados do processo não passando para as próximas etapas da análise.

Os protótipos heterogêneos são aqueles que apresentam alto grau de heterogeneidade espectral e estão associados normalmente a padrões de entrada que possuem mais do que uma classe de cobertura terrestre. Na maioria das vezes esses padrões correspondem a regiões de transição entre classes de cobertura terrestre presentes na imagem e são capturados em decorrência da amostragem realizada por janelas de pixels. Os protótipos considerados heterogêneos são excluídos do passo 4 da análise, onde é aplicado o método de

agrupamento hierárquico. Essa exclusão é realizada com o objetivo de não permitir que esses protótipos e, conseqüentemente, os padrões associados a eles sejam atribuídos erroneamente a uma das classes que os compõe. Os protótipos heterogêneos são reincorporados apenas nos procedimentos adotados nos passos 7 e 8 do método proposto.

Para medir o grau de heterogeneidade de cada protótipo é aplicado um índice, denominado aqui de *Índice de Heterogeneidade Espectral* (IHE), definido da seguinte forma:

$$IHE = \frac{1}{M} \sum_{i=1}^M CV_i \quad (5)$$

onde M é o número de bandas espectrais da imagem consideradas na análise e CV_i é o coeficiente de variação (dispersão relativa) dos níveis de cinza de todos os pixels na banda espectral i do protótipo. Os protótipos cujos IHE's satisfazem a relação dada abaixo são considerados heterogêneos e, conseqüentemente, serão filtrados:

$$IHE > \mu_{IHE} + \frac{1}{2} \sigma_{IHE} \quad (6)$$

μ_{IHE} e σ_{IHE} são, respectivamente, a média e o desvio padrão dos IHE's de todos os protótipos.

O tempo de processamento consumido por esta etapa de filtragem de protótipos é compensado não apenas pela redução do número de protótipos que serão analisados no passo 4 do método, mas principalmente por um possível aumento na precisão de classificação da imagem. Protótipos inativos e heterogêneos podem funcionar como "unidades de interpolação" no mapa de neurônios facilitando a separação das classes de agrupamentos.

4.4 Análise Hierárquica Aglomerativa

No quarto passo da metodologia proposta, um método de agrupamento hierárquico aglomerativo é aplicado sobre o conjunto de protótipos do SOM já treinado e filtrado. O objetivo desse passo é agrupar protótipos e conjuntos de protótipos em diferentes níveis de similaridade buscando descobrir a estrutura (ou classes) dos mesmos. O método de Ligações Simples (ou dos vizinhos mais próximos) foi utilizado nesta abordagem, porém outros métodos hierárquicos podem ser empregados.

Uma característica importante da estratégia de análise hierárquica apresentada neste trabalho é a imposição de restrições às possíveis fusões dos protótipos do SOM. Um algoritmo hierárquico aglomerativo uma vez aplicado sobre os agrupamentos de neurônios do SOM deve respeitar as relações topológicas do espaço de saída da rede. Diferentemente da abordagem tradicional de métodos de agrupamentos hierárquicos, que consiste em comparar todos os pares de objetos ou grupos de objetos para decidir sobre uma fusão, a abordagem utilizada neste trabalho verifica a

possibilidade de efetuar fusões somente entre pares de neurônios ou grupos de neurônios que sejam adjacentes (ou vizinhos) na grade do SOM.

No final desta etapa tem-se um dendrograma que mostra de maneira hierárquica a relação de semelhança entre os protótipos e agrupamentos de protótipos do SOM. Lembrando que os protótipos do SOM representam todos os padrões de entrada, o dendrograma gerado reflete, portanto, as relações existentes entre os dados e agrupamentos de dados da imagem original, podendo ser visto então como um dendrograma simplificado da imagem.

4.5 Avaliação dos agrupamentos

Em cada nível do dendrograma obtido no passo anterior há uma configuração diferente de agrupamentos para os protótipos do SOM, e conseqüentemente, para o conjunto de dados da imagem. Portanto, como em qualquer método de agrupamento hierárquico, há a necessidade de se aplicar algum critério para verificar qual nível do dendrograma representa a configuração ideal de agrupamentos (ou o número ideal de classes).

Uma saída usual é a aplicação de índices de validação de agrupamentos que incorporem medidas de dispersão intra e inter-agrupamentos (MAULIK *et al.*, 2002). A estratégia consiste em aplicar o índice de validação em todos os níveis do dendrograma e escolher aquele nível em que o índice apresenta o valor ótimo dentre todos os valores obtidos.

Entretanto, deve-se observar que a implementação da maioria dos índices de validação de agrupamentos exige um alto custo computacional. Devido a isso, quando o número de agrupamentos e o volume do conjunto de dados são muito grandes a utilização desses índices torna-se proibitiva. As imagens de sensoriamento remoto são um exemplo típico. Conforme descrito em JI (2003), índices de validação são freqüentemente ignorados em aplicações de sensoriamento remoto e por isso não estão disponíveis na maioria dos pacotes de processamento de imagens.

No entanto, como na metodologia proposta o dendrograma obtido no passo anterior não é construído em função dos padrões originais da imagem, e sim, por um pequeno conjunto de neurônios do SOM que os representam, a aplicação de um índice de validação de agrupamentos em cada nível do dendrograma se torna viável, pois a quantidade de dados a ser avaliada neste caso é bem inferior a do conjunto de padrões extraídos diretamente da imagem.

Embora o SOM realize uma boa aproximação para o espaço de entrada, é certo que a estratégia de aplicar um índice de validação sobre os protótipos da rede, ao invés de aplicá-lo diretamente sobre os padrões originais da imagem, poderá causar alguma diferença numérica nos resultados. Para diminuir possíveis erros de aproximação, o método proposto modifica a forma de calcular os índices de validação. Os índices são calculados utilizando não apenas os vetores de pesos

dos protótipos do SOM, mas também o nível de atividade de cada um deles. O nível de atividade de um protótipo é igual ao número de padrões de entrada que estão associados a ele pelo processo de mapeamento do SOM.

Para exemplificar a modificação aplicada nos cálculos dos índices considere a fórmula descrita na equação (7). Esta fórmula e variantes da mesma são comumente utilizadas em alguns índices de validação de agrupamentos para calcular a distância (δ_{ij}) entre dois agrupamentos de dados C_i e C_j (BEZDEK *et al.*, 1998).

$$\delta_{ij} = \frac{1}{|C_i||C_j|} \sum_{x \in C_i, y \in C_j} d(x, y) \quad (7)$$

Na fórmula acima, $d(*,*)$ é uma medida de distância, e $|C_i|$ e $|C_j|$ representam o número de pontos nos agrupamentos de dados C_i e C_j , respectivamente. Como se pode notar, δ_{ij} é determinada basicamente através dos cálculos das distâncias entre todos os pares de pontos x e y pertencentes aos agrupamentos de dados C_i e C_j . Se $|C_i|$ e $|C_j|$ são muito grandes o cálculo de δ_{ij} torna-se custoso demais.

Aplicando a estratégia apresentada aqui, o cálculo da distância entre os agrupamentos C_i e C_j , equivalente ao apresentado na equação (7), fica formulado da seguinte maneira:

$$\delta_{ij}^{SOM} = \frac{1}{|C_i||C_j|} \sum_{w_i \in W_i, w_j \in W_j} h(w_i) \cdot h(w_j) \cdot d(w_i, w_j) \quad (8)$$

onde W_i e W_j referem-se a quantidade de protótipos dos mesmos, $d(*,*)$ é a mesma medida de distância usada na equação (7), $h(w_i)$ é o nível de atividade do protótipo w_i pertencente a W_i e $h(w_j)$ é o nível de atividade do protótipo w_j pertencente a W_j .

Enquanto δ_{ij} se baseia nas distâncias entre todos os pares de pontos pertencentes a C_i e C_j , δ_{ij}^{SOM} se baseia nas distâncias apenas entre os pares de pontos pertencentes a W_i e W_j . Logo, nota-se que δ_{ij}^{SOM} é um cálculo aproximado de δ_{ij} , porém com um custo bem menor de processamento, pois as quantidades $|W_i|$ e $|W_j|$ geralmente são bem menores que $|C_i|$ e $|C_j|$. A inclusão dos níveis de atividade $h(.)$ dos protótipos no cálculo de δ_{ij}^{SOM} ajuda a diminuir o efeito dos erros de quantização decorrentes do mapeamento realizado pelo SOM.

Um outro ponto importante desta etapa do método proposto é a escolha do índice de validação que será aplicado de forma modificada em todos os níveis do dendrograma. Na metodologia proposta neste trabalho foi aplicado o índice de validação CDbw (*Composing Density Between and Within Clusters*) proposto em HALKIDI *et al.* (2002). Além de se basear em dois conceitos importantes, a densidade intra-agrupamento e a separação entre os agrupamentos, este índice foi escolhido por apresentar características que o

tornam capaz de avaliar de maneira adequada agrupamentos de dados que tenham formatos arbitrários e complexos, o que não acontece com a maioria dos outros índices de validação existentes na literatura.

4.6 Classificação do SOM

Uma vez definido o nível do dendrograma que apresenta a melhor configuração de agrupamentos para os protótipos do SOM e, portanto, para os padrões da imagem, o passo 6 do método proposto consiste apenas em rotular esses protótipos. Os protótipos pertencentes a um mesmo agrupamento recebem um rótulo particular e correspondem a uma determinada classe de cobertura terrestre presente na imagem.

De acordo com a metodologia proposta, cada classe de cobertura terrestre descoberta será representada então por um grupo de protótipos do SOM e não apenas por um protótipo individual.

4.7 Classificação da Imagem

Para realizar a classificação da imagem, os protótipos heterogêneos que foram filtrados no passo 4 são agora reincorporados e considerados também como uma classe. Para isso, todos eles recebem um mesmo rótulo, que obviamente deve ser diferente daqueles usados para rotular as outras classes de protótipos no passo anterior.

Janelas de pixels da imagem com dimensões iguais a das amostras de treinamento são comparadas com todos os protótipos do SOM. Essa comparação é realizada através das distâncias calculadas entre a janela de pixels considerada e cada um dos protótipos. O pixel central da janela de pixels recebe o rótulo do protótipo que apresenta a menor distância a ela. A imagem é então inteiramente percorrida até que todos os pixels sejam classificados dessa forma.

4.8 Refinamento

No último passo do método proposto, o resultado do processo de classificação realizado na etapa anterior é aprimorado. Os pixels da imagem que receberam o rótulo da classe de protótipos heterogêneos são reclassificados. Cada um desses pixels é comparado com os seus pixels vizinhos na imagem que não foram rotulados pela classe de protótipos heterogêneos. Eles recebem um novo rótulo que será igual ao do vizinho que apresenta a distância mínima a ele em termos de atributos espectrais.

5. RESULTADOS EXPERIMENTAIS

Esta seção apresenta um exemplo de aplicação da metodologia proposta sobre uma imagem teste. Os resultados são comparados com aqueles obtidos a partir da aplicação do algoritmo K-médias sobre a mesma imagem.

Todos os experimentos apresentados nesta

seção foram realizados em uma máquina com processador AMD Athlon™ XP 2600+ 1,91GHZ e 1GB de memória RAM.

A Fig. 3 mostra uma composição colorida da imagem utilizada nos testes. A imagem é composta pelas bandas espectrais 3, 4 e 5 do satélite Landsat-5 (TM), possui 496x512 pixels e mostra a cidade de Manaus e o encontro dos Rios Negro e Solimões. A cena apresenta 4 grandes classes de cobertura terrestre: área urbana, vegetação e dois padrões de água (um mais escuro correspondente ao Rio Negro e outro de cor mais arroxeada correspondente ao Rio Solimões). Pequenas áreas com vegetação rala ou desmatada também aparecem na cena, mas com uma densidade muito baixa. Esta imagem foi cedida pelo Instituto Nacional de Pesquisas Espaciais (INPE).



Fig. 3 – Composição colorida da imagem teste.

Aplicando a metodologia proposta foi realizado inicialmente o processo de amostragem da cena. Janelas amostrais de tamanho 5x5 foram coletadas de maneira uniforme sobre toda a região da imagem, sem sobreposições e em intervalos regulares de 10 pixels, totalizando cerca de 2500 amostras obtidas sem a intervenção do usuário.

Um SOM composto de 100 neurônios dispostos em uma grade retangular de dimensão 10x10 foi treinado com todas as amostras coletadas anteriormente. Os demais parâmetros do SOM foram definidos de acordo com as especificações apresentadas na seção 4.2.

A Fig. 4 ilustra o MCI obtido após o treinamento do SOM. Conforme descrito na seção 4.2.1, o MCI é uma imagem gerada a partir da grade de neurônios do SOM já treinado.

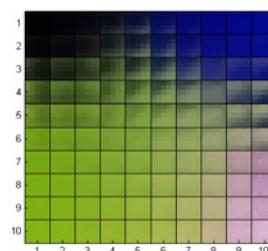


Fig. 4 – MCI obtido após o treinamento do SOM.

Cada pequeno quadrado no MCI corresponde à

imagem de um protótipo (ou neurônio) do SOM. Através deles é possível visualizar as propriedades do mapeamento realizado pela rede neural. As quatro grandes classes de cobertura terrestre presentes na imagem original aparecem em forma de agrupamentos no MCI. No canto superior esquerdo se encontram os protótipos correspondentes ao padrão de água mais escuro, no canto superior direito estão presentes os protótipos referentes à outra classe de água (mais arroxeadada), no canto inferior direito (em rosa) se encontra aqueles que correspondem à área urbana, e do canto inferior esquerdo ao centro do MCI estão os protótipos associados à classe vegetação. Se observarmos a imagem original, verifica-se que a classe vegetação é aquela que apresenta a maior área de ocupação na cena. Sendo assim, como o SOM reflete a distribuição de probabilidade dos dados de entrada, os protótipos associados à classe vegetação (em verde no MCI) se apresentam em maior número do que os protótipos das outras classes. A propriedade de ordenação topológica do SOM também pode ser notada. Os protótipos das duas classes de água presentes na imagem original aparecem próximos um dos outros na parte superior do MCI, isto porque os dados de entrada correspondentes a essas duas classes possuem uma maior similaridade espectral em comparação com os atributos espectrais das outras duas classes de cobertura.

Após o treinamento do SOM, a próxima etapa a ser executada é a filtragem dos protótipos inativos e heterogêneos. A Fig. 5a mostra o nível de ativação de cada um dos protótipos do SOM, i.e., o número de padrões de entrada (amostras) que estão associados a cada um deles através do mapeamento efetuado pelo SOM. Observa-se que os protótipos localizados nas posições da grade (1,5), (3,2), (4,8) e (6,10) apresentam níveis de ativação nulos e, portanto, não possuem nenhum padrão de entrada associado a eles. De acordo com o método proposto, esses protótipos são simplesmente descartados do processo não passando para as próximas etapas da análise.

A Fig. 5b apresenta os valores (em porcentagem) dos IHE's de cada protótipo. Conforme apresentado na seção 4.3, o IHE mede o grau de heterogeneidade espectral dos protótipos do SOM. Os protótipos com IHE's cujos valores satisfazem o critério dado em (6) são considerados heterogêneos e devem ser filtrados. Desse modo, como os valores obtidos nesse experimento para a média (μ_{IHE}) e para o desvio-padrão (σ_{IHE}) dos IHE's foram, respectivamente, 11.89 e 8.93, os protótipos que apresentam valores de IHE's acima de 16.35 (limiar obtido de acordo com o critério dado em (6)) são então considerados heterogêneos e por isso são filtrados. Esses protótipos (marcados em negrito na Fig. 5b) serão reconsiderados somente nos dois últimos passos da metodologia de classificação.

Sendo assim, do total de 100 protótipos do SOM, 25 deles (entre inativos e heterogêneos) foram filtrados, restando 75 protótipos para serem analisados nas duas próximas etapas.

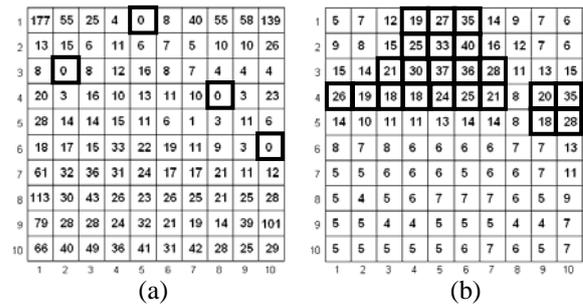


Fig. 5 – (a) Níveis de ativação dos protótipos do SOM (protótipos com níveis de ativação nulos estão marcados em negrito). (b) Valores dos IHE's dos protótipos do SOM (protótipos considerados heterogêneos estão marcados em negrito).

De acordo com o método proposto, a etapa seguinte consiste em aplicar o método hierárquico aglomerativo sobre os protótipos do SOM filtrado. Conforme descrito na seção 4.4, o método das Ligações Simples é utilizado nesta abordagem e as fusões entre os protótipos (ou grupos de protótipos) são efetuadas respeitando a vizinhança topológica dos mesmos na grade retangular do SOM. O dendrograma possui 75 níveis, cada um deles apresentando uma configuração diferente de agrupamentos de protótipos do SOM que, por conseguinte, produz uma classificação diferente para a imagem original.

Além de possibilitar a classificação da imagem em diferentes níveis de agrupamentos, o dendrograma obtido permite que o usuário analise de maneira particular cada uma das uniões realizadas entre os protótipos ou grupos de protótipos, e também a hierarquia das mesmas. Se ressaltarmos ainda que no método proposto o usuário pode visualizar a imagem de cada protótipo do SOM através do MCI, a análise do dendrograma se torna muito mais clara e eficiente, facilitando a compreensão das relações existentes entre os diferentes padrões presentes na imagem.

É importante observar que esse tipo de análise somente é possível devido ao mapeamento realizado pelo SOM. A rede neural “resume” os padrões originais da imagem por meio de um pequeno conjunto de protótipos viabilizando assim a construção de um dendrograma simplificado. Se porventura o SOM não fosse utilizado para representar os dados de entrada, a construção do dendrograma ou a interpretação do mesmo se tornaria impraticável, pois o mesmo teria 2500 níveis de agrupamentos caso fossem consideradas todas as amostras coletadas da imagem.

Dando continuidade na execução das etapas do método proposto, o índice de validação de agrupamentos CDbw, calculado de forma modificada, é aplicado em todos os níveis do dendrograma para determinar qual a configuração de agrupamentos ideal dentre as 75 obtidas. Com o objetivo de comparar as duas formas de cálculo, a Fig. 6 mostra os valores do índice de validação em suas versões modificada e original. O gráfico apresenta somente os valores entre os níveis 61 e 74 do dendrograma. Para os níveis

inferiores a 61 os valores do índice são menores do que aqueles apresentados no gráfico, ou até mesmo nulos, devido à existência de níveis que possuem agrupamentos com apenas um único protótipo. O número de agrupamentos ou de classes do nível 61 ao 74 decresce, respectivamente, de 15 até 2.

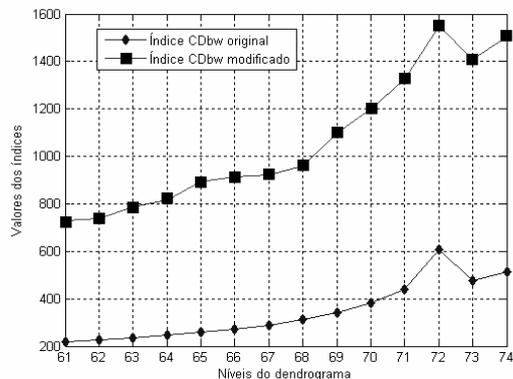


Fig. 6 – Valores do índice CDbw nas suas formas modificada e original.

Como esperado, a estratégia de modificar a computação de índices de validação de agrupamentos (descrita na seção 4.5) apresenta erros de aproximação, porém a variação dos valores é semelhante ao da versão original, não comprometendo a tomada de decisão sobre o número de agrupamentos ideal dos dados. A vantagem principal em usar a versão modificada do índice está no seu tempo de processamento. Neste experimento, enquanto o tempo gasto para calcular o índice CDbw na forma original (para todo o dendrograma) foi de 784 segundos, a versão modificada exigiu apenas 32 segundos. É importante observar que esta diferença significativa ocorre devido ao volume de dados considerados por cada uma das formas de cálculo do índice. O cálculo do índice CDbw na sua forma original foi executado em cada nível do dendrograma considerando as 2500 amostras coletadas da imagem, enquanto o cálculo da versão modificada considera apenas os 100 protótipos do SOM e os seus respectivos níveis de ativação.

Para o índice CDbw, quanto maior o seu valor melhor é a configuração de agrupamentos avaliada. Sendo assim, dentre todos os níveis do dendrograma obtido neste experimento o nível 72 é aquele que apresenta o maior valor para o índice (conforme mostra o gráfico da Fig. 6), e portanto, o melhor conjunto de agrupamentos para os protótipos do SOM. A Fig. 7 mostra o MCI classificado de acordo com as classes de agrupamentos do nível 72. Comparando com a imagem do MCI na Fig. 4, nota-se que os protótipos do SOM são agrupados em 4 classes, correspondendo adequadamente às 4 grandes classes de cobertura terrestre presentes na imagem. Os quadrados marcados com um “X” no MCI classificado são os protótipos descartados na etapa de filtragem do método proposto. É interessante notar que tais protótipos funcionam como “unidades de interpolação” e certamente contribuíram para o processo de separação da maioria das classes.

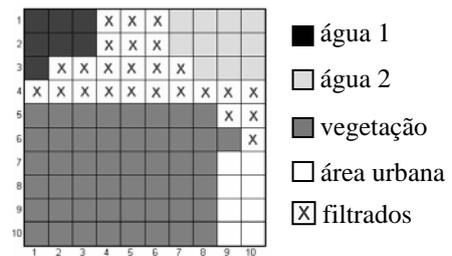


Fig. 7 – MCI classificado de acordo com a melhor configuração de agrupamentos do dendrograma.

Terminada a etapa de classificação dos protótipos do SOM, os dois últimos passos do método concentram-se na classificação de todos os pontos da imagem original. Para isso, os protótipos heterogêneos (filtrados anteriormente) voltam a ser incorporados no processo e considerados também como uma classe. Deste modo, no penúltimo passo do método proposto, 5 classes de protótipos do SOM são utilizadas como referência para realizar a classificação da imagem, as 4 classes do nível escolhido no dendrograma (apresentadas na Fig. 7) e a classe dos protótipos heterogêneos. A imagem é percorrida inteiramente considerando janelas de pixels com dimensões 5x5 (iguais aos das janelas amostrais) e comparado-as com todos os protótipos do SOM. O pixel central da janela de pixels recebe o rótulo do protótipo que apresenta a menor distância a ela.

Por fim, a última etapa do método, denominada aqui de “refinamento”, é aplicada. Um total de 26585 pixels da imagem foi associado à classe de protótipos heterogêneos. Esses pixels são reclassificados e recebem um novo rótulo, igual ao do pixel vizinho que apresenta a menor distância a ele (em termos de atributos espectrais). A Fig. 8 mostra o resultado da classificação da imagem original pela metodologia proposta (as 4 classes são representadas pelas mesmas cores utilizadas na Fig. 7).

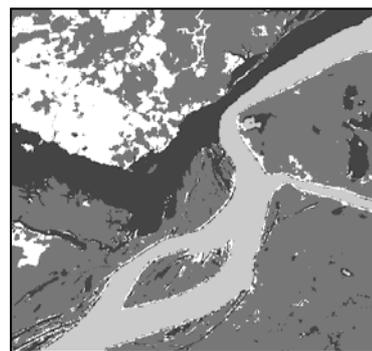


Fig. 8 – Resultado da classificação da imagem teste pela metodologia de classificação proposta.

Portanto, de acordo com a metodologia proposta, a imagem teste foi classificada em 4 classes, as quais correspondem aos 4 padrões de cobertura terrestre de maior predominância na cena. Algumas pequenas áreas de vegetação rala ou desmatada presentes na imagem foram classificadas como área

urbana, por serem espectralmente muito semelhantes aos padrões dessa classe e por se apresentarem com baixa densidade em comparação com os outros padrões de cobertura.

A Fig. 9 mostra o resultado da classificação da imagem teste pelo algoritmo K-médias considerando o número de classes igual a 4. O algoritmo foi executado usando cinco inicializações diferentes para os centróides de cada uma das classes e um número máximo de iterações igual a 100.

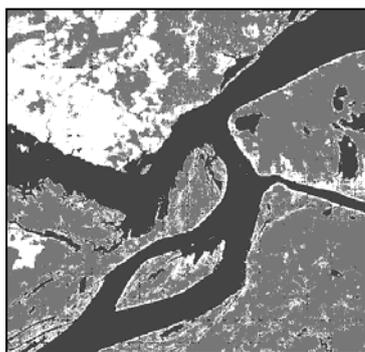


Fig. 9 – Resultado da classificação da imagem teste pelo algoritmo K-médias considerando k=4.

Diferentemente do método proposto, o algoritmo K-médias não discriminou um dos padrões de água predominantes na imagem e classificou as áreas de vegetação da cena em duas outras categorias. O algoritmo também confundiu áreas de vegetação rala ou desmatada com padrões de área urbana, porém de forma bem mais acentuada que o método proposto aqui. Os dois padrões de água existentes na imagem teste somente são discriminados pelo algoritmo K-médias se considerarmos um número de agrupamentos maior ou igual a 5. No entanto, embora o algoritmo classifique a vegetação em várias categorias diferentes, a confusão entre as áreas de vegetação rala com os padrões de área urbana permanece para qualquer número de classes.

Realizando uma análise visual das imagens classificadas pelos dois métodos (Figs. 8 e 9), observa-se que a imagem resultante da metodologia proposta apresenta um aspecto visual melhor. Enquanto a classificação pelo algoritmo K-médias possui uma aparência mais salpicada, a imagem produzida pelo método proposto se apresenta de forma mais homogênea em todas as áreas classificadas. Essa diferença no aspecto visual certamente se dá em virtude das formas pelas quais os dois métodos tratam a imagem. Enquanto o algoritmo K-médias utiliza uma abordagem pixel a pixel para realizar a classificação, o método proposto trabalha com janelas de pixels, as quais incorporam informações de vizinhança e por isso permitem obter uma classificação resultante de melhor qualidade.

Procurando realizar uma análise mais criteriosa e menos subjetiva da classificação obtida pela metodologia proposta, e considerando a ausência de verdade terrestre para a imagem teste, o presente trabalho realiza a classificação da imagem de modo

supervisionado e considera os resultados da mesma como referência (ou “verdade”). A classificação supervisionada, considerando as 4 classes predominantes na imagem, foi feita através de uma Rede Neural de *Perceptrons* Multicamadas com o algoritmo de treinamento *Backpropagation*. Essa classe de redes neurais tem sido amplamente empregada para realizar a classificação supervisionada de imagens de sensoriamento remoto (GONÇALVES, 1997).

A matriz de confusão e o índice de concordância *Kappa* foram calculados a partir da comparação entre a imagem classificada pelo método proposto e a imagem referência (resultante da classificação supervisionada). Analisando a matriz de confusão apresentada na Tabela 1 e considerando que o valor alcançado para o índice de concordância *Kappa* foi igual a 0.96, podemos considerar que o resultado da classificação da imagem teste pelo método apresentado neste trabalho foi bastante satisfatória.

TABELA 1 – MATRIZ DE CONFUSÃO DAS CLASSES PARA A IMAGEM CLASSIFICADA PELO MÉTODO PROPOSTO (%).

Classes	água1	agua2	veg.	urbana	Total
água1	96.43	0.40	0.34	0.20	16.64
água2	0.61	99.35	0.04	0.09	15.19
veg.	2.89	0.02	98.89	6.73	53.29
urbana	0.06	0.23	0.73	92.98	14.88
Total	100	100	100	100	100

Por fim, a Tabela 2 mostra o tempo de processamento consumido (em segundos) neste experimento por cada uma das etapas da metodologia de classificação proposta.

TABELA 2 – TEMPO CONSUMIDO PELO MÉTODO DE CLASSIFICAÇÃO PROPOSTO.

Etapas do método	Tempo consumido
Amostragem	10
Treinamento do SOM	40
Filtragem de protótipos	2
Análise hierárquica	0.5
Avaliação	32
Classificação do SOM	0.4
Classificação da imagem	66
Refinamento	4
Total	154.9

O tempo total gasto pelo método para realizar a classificação da imagem foi de aproximadamente 155 segundos. O treinamento do SOM, a avaliação dos agrupamentos e a classificação final da imagem foram as etapas que consumiram mais tempo de processamento.

Já o tempo consumido pelo algoritmo K-médias na classificação da mesma imagem (considerando k igual a 4) foi de aproximadamente 93 segundos, realizando cinco inicializações diferentes para os centróides das classes (como feito nos experimentos).

Embora o algoritmo K-médias tenha apresentado um tempo de processamento inferior ao da metodologia proposta, os dois métodos possuem princípios e características muito diferentes, que devem ser consideradas na avaliação de suas complexidades de cálculo.

Uma diferença importante entre os dois métodos está na quantidade de classes analisada por eles para realizar a classificação da imagem. O método proposto avalia diferentes configurações de agrupamentos para os dados, enquanto que o algoritmo K-médias realiza a classificação da cena apenas para uma única quantidade de classes definida a priori. O tempo gasto pelo método proposto para avaliar 75 configurações diferentes de agrupamentos foi de 32 segundos. Se resolvêssemos utilizar uma estratégia semelhante para o algoritmo K-médias, ou seja, realizar diferentes classificações da imagem variando o número de classes (k) e depois aplicar o índice de validação CDbw para decidir qual delas é a melhor, o tempo de processamento seria tão elevado ao ponto de tal estratégia ser considerada impraticável. Basta levarmos em conta o tempo gasto na aplicação do índice CDbw para avaliar a classificação produzida pelo algoritmo K-médias apresentada na Fig. 9. O tempo consumido foi de 1890 segundos, muitíssimo superior ao tempo gasto pelo método proposto para avaliar diversas configurações de agrupamentos para imagem.

Diante dessas observações e considerando ainda os possíveis benefícios das outras técnicas e procedimentos empregados na metodologia proposta (como a filtragem de protótipos, a análise hierárquica e o refinamento da classificação), conclui-se que o tempo de processamento consumido pelo método apresentado é perfeitamente admissível, o que ressalta ainda mais a viabilidade de aplicação do mesmo.

6. CONCLUSÕES E CONSIDERAÇÕES FINAIS

Neste trabalho foi apresentada uma nova metodologia para a classificação não-supervisionada de imagens de sensoriamento remoto. O ponto chave do método proposto é realizar a análise de agrupamentos da imagem através de um conjunto de protótipos do SOM ao invés de trabalhar diretamente com os padrões originais da cena. Essa abordagem reduz significativamente a complexidade da análise tornando possível a utilização de técnicas que são normalmente consideradas inviáveis para o processamento de imagens de sensoriamento remoto, como por exemplo, métodos de agrupamentos hierárquicos e índices de validação de agrupamentos.

O método proposto apresenta uma série de vantagens e potencialidades que o colocam como uma alternativa bastante diferenciada para a classificação não-supervisionada de imagens. Entre elas, podemos destacar:

- A não exigência de uma definição a priori do número de classes para realizar a classificação da

imagem, o que não acontece na maioria dos métodos convencionais de classificação não-supervisionada;

- O método possui apenas dois parâmetros que devem ser definidos pelo usuário (o tamanho das amostras e do SOM), e mesmo assim é bastante robusto quanto à escolha dos mesmos;

- O simples uso de janelas de pixels permite incorporar informações de contexto e textura sem nenhum cálculo explícito de medida. Essa abordagem contribui para a qualidade da classificação resultante;

- A utilização de um método de agrupamento hierárquico aglomerativo permite que o usuário compreenda em diferentes níveis de agrupamentos as relações existentes entre os padrões de cobertura terrestre presentes na imagem. Além disso, caso o usuário deseje, a imagem pode ser classificada considerando diferentes quantidades de classes;

- A representação distribuída das classes por meio de grupos de protótipos dá ao método a potencialidade de descobrir agrupamentos de dados que possuem geometrias complexas e variadas. Métodos como o K-médias utilizam apenas um único protótipo (centróide) para representar cada classe e por isso são capazes de detectar adequadamente apenas agrupamentos que tenham formatos hiperesféricos;

- O método pode determinar sem nenhuma intervenção do usuário o número ideal de agrupamentos ou de classes da imagem;

- O método classifica de maneira diferenciada pixels situados em regiões de transição entre classes. Esse procedimento contribui para aumentar a exatidão da classificação resultante.

Tendo em vista que a maioria dos métodos convencionais de classificação não-supervisionada de imagens de sensoriamento remoto se baseiam somente em métodos de agrupamentos particionais (como o K-médias e o ISODATA), a possibilidade de utilização de um método de agrupamento hierárquico para analisar a imagem é certamente um dos benefícios mais importantes proporcionado pelo uso do SOM nesta abordagem. Além disso, a imposição de restrições às possíveis fusões dos protótipos do SOM diminui ainda mais a complexidade computacional do método de agrupamento hierárquico aplicado.

A estratégia de modificar o cálculo de índices de validação de agrupamentos utilizando os protótipos do SOM também contribui para o bom desempenho do método. Apesar dos erros de aproximação, o cálculo modificado do índice não compromete a tomada de decisão sobre o número ideal de classes da imagem e ainda colabora significativamente na redução do tempo de processamento global.

Além da imagem teste utilizada nos experimentos mostrados aqui, o método proposto também foi aplicado em outras imagens de média e alta resolução com números variados de classes, tendo apresentado resultados satisfatórios.

Finalmente, é importante ressaltar ainda que, apesar dos trabalhos já desenvolvidos que aplicam as Redes Neurais na classificação de imagens de sensores

remotos apresentem bons resultados em comparação com os métodos convencionais, a maioria desses trabalhos, além de abordar muito superficialmente o processo de classificação em si, não explora todo o potencial que as redes neurais podem oferecer. De fato, redes neurais de *Perceptrons* Multicamadas com algoritmo de treinamento *backpropagation* são utilizadas como se fossem a única alternativa para os classificadores estatísticos convencionais. Portanto, o presente trabalho também mostra, através da aplicação do SOM, que alternativas no campo das redes neurais podem ainda ser exploradas e aplicadas na análise de imagens de sensoriamento remoto.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALIXANDRINI, M. J. JR., CENTENO, J. A. S. Experimento da Aplicação de Algoritmos Genéticos para a Integração de Dados Espectrais e Textura na Classificação de Imagens de Alta Resolução. In: **Anais do Simpósio Brasileiro de Geomática**, pp. 212-217, 2002.
- BALL, G., HALL, D. A Clustering Technique for Summarizing Multivariate Data. **Behavior Science**, v. 12, pp. 153-155, 1967.
- BEZDEK, J. C., PAL, N. R. "Some new indexes of cluster validity", **IEEE Transactions on Systems Man and Cybernetics**, v. 28, pp. 301-315, 1998.
- COSTA, J. A. F. **Classificação Automática e Análise de Dados por Redes Neurais Auto-organizáveis**. 1999. Tese (Doutorado em Engenharia Elétrica). Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas-SP.
- DEAN, A. M., SMITH, G. M. An Evaluation of Per-Parcel Land Cover Mapping using Maximum Likelihood Class Probabilities. **International Journal of Remote Sensing**, v. 24, n. 14, July 2003.
- DUDA, T., CANTY, M. Unsupervised Classification of Satellite Imagery: choosing a good algorithm. **International Journal of Remote Sensing**, v. 23, n. 11, June 2002.
- GONÇALVES, M. L., NETTO, M. L. A., ZULLO JUNIOR, J. A. Neural Architecture for Image Classification using Kohonen Feature Extraction. In: **Proceedings of XVIII International Congress for Photogrammetry and Remote Sensing (ISPRS, Comission II)**, v. 31, pp. 117-122, Viena, 1996.
- GONÇALVES, M. L. **Uma Arquitetura Neural Modular para a Classificação de Imagens Multiespectrais de Sensoriamento Remoto**. 1997. Dissertação (Mestrado em Engenharia Elétrica). Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas-SP.
- GONÇALVES, M. L., NETTO, M. L. A., COSTA, J. A. F., ZULLO JUNIOR, J. Automatic Remotely Sensed Data Clustering by Tree-Structured Self-Organizing Maps. In: **Proceedings of IEEE International Geoscience and Remote Sensing Symposium (IGARSS'05)**, v.1, 4 p., Seoul, July 2005.
- HALKIDI, M., VAZIRGIANNIS, M., "Clustering validity assessment using multi representatives". In: **Proceedings of SETN Conference**, Thessaloniki, Grécia, 2002.
- HANSEN, M., DUBAYAH, R., DEFRIES, R. Classification Trees: An Alternative to Traditional land Cover Classifiers. **International Journal of Remote Sensing**, v. 17, n. 5, 1996.
- HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. New York: Prentice-Hall, 2nd edition, 1999.
- JI, M. "Using fuzzy sets to improve cluster labeling in unsupervised classification," **International Journal of Remote Sensing**, v. 24, pp. 657-671, 2003.
- KOHONEN, T. **Self-Organizing Maps**, 2nd Edition, Berlin: Springer Verlag, 1997.
- LILLESAND, T. M., KIEFER, R. W. **Remote Sensing and Image Interpretation**, John Wiley & Sons, inc., 2000.
- MAGNUSSEN, S., BOUDEWYN, P., WULDER, M. Contextual Classification of Landsat TM Images to Forest Inventory Cover Types. **International Journal of Remote Sensing**, v. 25, n. 12, pp. 2421-2440, 2004.
- MAULIK, U., BANDYOPADHYAY, S. Performance Evaluation of Some Clustering Algorithms and Validity Indices. **IEEE Transactions on Pattern Analysis and Machine Intelligence**. v. 24, n. 12, December 2002.
- PAL, M., MATHER, P. M. Support Vector Machines for Classification in Remote Sensing. **International Journal of Remote Sensing**, v. 26, n. 5, March 2005.
- RICHARDS, J. A. Analysis of Remotely Sensed Data: The Formative Decades and the Future. **IEEE Transactions on Geoscience and Remote Sensing**, v. 43, n. 3, March 2005.
- WANG, F. Fuzzy Supervised Classification of Remote Sensing Images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 28, n. 2, March 1990.
- XU, R., WUNSCH II, D. Survey of Clustering Algorithms. **IEEE Transactions on Neural Networks**. v. 16, n. 3, May 2005.