

Explorando as Propriedades do Mapa Auto-organizável de Kohonen na Classificação de Imagens de Satélite

Márcio L. Gonçalves^{1,2}, Márcio L. de Andrade Netto², José Alfredo F. Costa³

¹Curso de Ciência da Computação - PUC Minas *campus* de Poços de Caldas
Av. Padre Francis Cletus Cox, 1661 – Cep: 37701-355 – Poços de Caldas, MG

²Faculdade de Engenharia Elétrica e de Computação
Universidade Estadual de Campinas (UNICAMP) – Campinas, SP

³Departamento de Engenharia Elétrica
Universidade Federal do Rio Grande do Norte (UFRN) – Natal, RN
marcio@pucpcaldas.br, marcio@dca.fee.unicamp.br, alfredo@dee.ufrn.br

Abstract. *This work presents a methodology for the land-cover classification of satellite images which explores the self-organizing map (SOM) properties. The proposed method performs a cluster analysis of the image data using a three-stage approach. Firstly, the original patterns of the image are clustered using the SOM, after that the SOM is filtered, and then segmented through a hierarchical clustering method which uses the neighborhood relation of the neurons and incorporates spatial information in the merging criterion. The experimental results show an application example of the proposed methodology on an IKONOS image.*

Resumo. *Este trabalho apresenta uma metodologia que explora as propriedades do mapa auto-organizável (SOM) para realizar a classificação de padrões de cobertura terrestre em imagens de satélite. O método proposto efetua uma análise de agrupamentos dos dados da imagem empregando uma abordagem em três estágios. Primeiramente, os padrões originais da imagem são agrupados usando o SOM, em seguida o SOM é filtrado, e então segmentado através de um método de agrupamento hierárquico que utiliza as relações de vizinhança dos neurônios e incorpora informações espaciais em seu critério de fusão. Os resultados experimentais mostram um exemplo de aplicação da metodologia proposta sobre uma imagem IKONOS.*

1. Introdução

O mapa auto-organizável (SOM - *self-organizing map*), proposto por Kohonen (1997), tem sido frequentemente utilizado em inúmeras aplicações, incluindo áreas como reconhecimento de padrões, processamento de sinais, compressão de dados, modelagem biológica e mineração de dados. O SOM é um tipo de rede neural artificial baseada em aprendizado competitivo e não-supervisionado. Propriedades importantes como a capacidade de aproximar o espaço de entrada, ordenação topológica e casamento de densidade, aliadas a simplicidade do modelo e a facilidade de implementação do seu algoritmo de aprendizagem justificam o sucesso do SOM e o colocam como um dos principais modelos de redes neurais na atualidade.

Este trabalho apresenta uma metodologia que explora as características e propriedades do SOM para realizar a classificação não-supervisionada de padrões de cobertura terrestre em imagens de sensoriamento remoto. 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, 2005). Atualmente a enorme quantidade de imagens que estão sendo coletadas por sistemas sensores cada vez mais modernos e sofisticados requerem o desenvolvimento de metodologias de classificação inovadoras, as quais possibilitem uma exploração automática e eficiente do grande volume de informações 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 subseqüentes.

O método de classificação proposto aqui realiza uma análise de agrupamentos dos dados da imagem empregando uma abordagem constituída de três estágios de processamento através do SOM. Primeiramente, o SOM é utilizado para agrupar os padrões originais da imagem em um conjunto reduzido de protótipos (neurônios) dispostos em um arranjo retangular bidimensional. Em seguida, o SOM passa por um processo de filtragem onde protótipos que representam regiões de transição entre diferentes classes de cobertura terrestre são descartados do próximo estágio de processamento e aqueles que apresentam atividade nula são eliminados. No terceiro e último estágio da análise, um método de agrupamento hierárquico que respeita as relações de vizinhança dos neurônios e que incorpora informações espaciais em seu critério de fusão é utilizado para segmentar o SOM gerando um dendrograma de seus protótipos. 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.

2. O SOM

O SOM é uma rede neural artificial que define um mapeamento de um espaço de entrada p -dimensional contínuo para um conjunto finito de protótipos (neurônios), que são dispostos em um arranjo topológico, geralmente bidimensional (Kohonen, 1997).

A rede consiste essencialmente de duas camadas de neurônios: uma camada de entrada I e uma camada de saída U (camada de Kohonen). 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 então por um vetor de pesos $\mathbf{w}_i = [w_{i1}, w_{i2}, \dots, w_{ip}]^T$, também no espaço p -dimensional.

Para cada padrão de entrada 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:

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

onde t indica a iteração do processo de treinamento, $\mathbf{x}(t)$ é o padrão de entrada e $h_c(t)$ é o núcleo de vizinhança em torno do neurônio vencedor.

Uma vez garantida a convergência do seu algoritmo de aprendizagem, o arranjo de neurônios do SOM reflete características estatísticas importantes do espaço de entrada. As principais propriedades da rede podem ser resumidas como seguem (Haykin, 2001):

1) *Aproximação do espaço de entrada*: o SOM tem como objetivo básico armazenar um conjunto grande de vetores de entrada encontrando um conjunto menor de protótipos (vetores de pesos sinápticos $\mathbf{w}_i$) de modo a fornecer uma boa aproximação para o espaço de entrada original. A base teórica dessa estratégia está fundamentada na teoria da quantização vetorial, cuja motivação é a redução de dimensionalidade ou a compressão de dados.

2) *Ordenação Topológica*: ao realizar o mapeamento não-linear dos vetores de entrada para o arranjo de neurônios da rede, o algoritmo do SOM tenta preservar ao máximo a topologia do espaço original, ou seja, procura fazer com que neurônios vizinhos no espaço de saída apresentem vetores de pesos que representem padrões vizinhos no espaço de entrada.

3) *Casamento de Densidade*: o mapeamento efetuado pelo SOM reflete a distribuição de probabilidade dos dados no espaço de entrada original. Regiões do espaço de entrada de onde os vetores de amostra $\mathbf{x}$ são retirados com uma alta probabilidade de ocorrência são mapeadas para domínios maiores no espaço de saída, e portanto com melhor resolução que regiões no espaço de entrada de onde vetores de amostra $\mathbf{x}$ são retirados com uma baixa probabilidade de ocorrência.

3. Classificação Não-supervisionada de Imagens de Sensoriamento Remoto

O processo de classificação não-supervisionada de imagens de sensoriamento remoto baseia-se no princípio de que o algoritmo computacional é capaz de identificar por si só as classes dentro do conjunto de dados da imagem. Esse tipo de classificação é freqüentemente realizado através de métodos de agrupamentos (*clustering*). Embora exista uma grande quantidade de diferentes métodos de agrupamentos na área de reconhecimento de padrões (Xu and Wunsch II, 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 and Hall, 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 classes é conhecido a priori. 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. Essas exigências certamente aumentam o nível de interação do usuário com o algoritmo computacional, aumentando conseqüentemente o grau de subjetividade do processo de

categorização da imagem. Outras limitações não menos importantes de 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.

Uma 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 classes 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 (qual o número ideal de agrupamentos) há a necessidade de se aplicar algum critério de decisão.

4. Metodologia Proposta

O método não-supervisionado de classificação de imagens de satélite proposto aqui tem como princípio básico 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. Para tanto, uma abordagem dividida em três estágios de processamento através do SOM é utilizada com o objetivo de descobrir agrupamentos de protótipos representativos para cada uma das classes de interesse da imagem. Os três estágios de processamento, que consistem basicamente no treinamento, filtragem e segmentação do SOM, são descritos nas subseções seguintes.

4.1 Treinamento

No primeiro estágio de processamento um conjunto de amostras coletadas a partir da imagem original é utilizado 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 método proposto 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 presentes nas imagens de satélite. As janelas amostrais são coletadas de maneira uniforme sobre toda a região da imagem, sem a intervenção do usuário, sem sobreposições e em intervalos regulares. Todas as amostras são quadradas e possuem o mesmo tamanho.

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, outras 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 linear dos pesos, apresentação dos padrões em lote, número de épocas de treinamento igual a 500 (quinhentos), tipo de função de vizinhança gaussiana e formato retangular para o arranjo bidimensional de neurônios.

O tamanho do mapa (número de neurônios) é um dos parâmetros livres do SOM que depende dos objetivos desejados para a classificação. Se o objetivo é detectar todos os padrões da imagem, inclusive aqueles com baixa probabilidade de ocorrência, mapas de tamanhos maiores devem ser empregados na análise, caso contrário, se o interesse se concentra apenas nos padrões mais predominantes da cena então um tamanho menor para o SOM pode ser utilizado.

No final da etapa de treinamento do SOM tem-se, portanto, um conjunto reduzido de protótipos (neurônios) dispostos em um arranjo retangular bidimensional, os quais representam todos os padrões de entrada coletados a partir da imagem original.

4.2 Filtragem

O segundo estágio da abordagem proposta consiste em filtrar dois tipos de protótipos que geralmente aparecem no mapeamento dos padrões da imagem através do SOM. Esses protótipos, chamados aqui de *inativos* e *heterogêneos*, podem funcionar como bordas (ou “unidades de interpolação”) no arranjo retangular de neurônios do SOM contribuindo para a separação de agrupamentos.

Os protótipos inativos correspondem àqueles neurônios que apresentam atividade nula no processo de aprendizado competitivo do SOM, ou seja, não possuem nenhum padrão de entrada associado a eles. Esses protótipos são simplesmente eliminados da análise.

Os protótipos heterogêneos são aqueles que apresentam alto grau de heterogeneidade espectro-textural 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 meio de janelas de pixels. Os protótipos considerados heterogêneos são excluídos do estágio seguinte da análise. Essa exclusão é realizada com o objetivo de não permitir que esses protótipos e, conseqüentemente, os padrões da imagem associados a eles sejam atribuídos erroneamente a uma das classes que os compõe. Os pixels da imagem associados aos protótipos heterogêneos são classificados de maneira especial somente no final do processo usando as informações dos rótulos de seus pixels vizinhos.

O grau de heterogeneidade espectro-textural de cada protótipo do SOM é calculado através de uma medida estatística baseada na matriz de co-ocorrência de níveis de cinza proposta por Haralick et al. (1973). Considerando que os protótipos do

SOM possuem as mesmas dimensões que as amostras de dados utilizadas para treinar a rede, as quais nesta abordagem correspondem a janelas de pixels, conseqüentemente eles também podem ser vistos como janelas de pixels (pequenas imagens). Sendo assim, é possível medir a probabilidade de co-ocorrência de níveis de cinza i e j (separados por uma distância d numa direção θ) em cada um dos protótipos do SOM. A energia (ou segundo momento angular) foi a medida estatística aplicada aqui para medir a heterogeneidade dos protótipos com base na matriz de co-ocorrência de níveis de cinza de cada um deles. Esta medida, descrita pela equação (3), apresenta valores próximos de 1 quando a área de interesse apresenta textura uniforme (níveis de cinza próximos) e valores que tendem a zero caso a área não seja uniforme.

$$ENE = \sum_i \sum_j P(i, j)_{d, \theta}, \quad (3)$$

onde $P(i, j)_{d, \theta}$ representa a freqüência relativa com que dois pixels vizinhos (i e j), separados por uma distância d na direção θ , ocorrem em um protótipo do SOM.

Os protótipos cujos valores de energia (ENE) satisfazem a relação dada abaixo são considerados heterogêneos e, conseqüentemente, são filtrados:

$$ENE > \mu_{ENE} + \frac{1}{2} \sigma_{ENE}. \quad (4)$$

μ_{ENE} e σ_{ENE} são, respectivamente, a média e o desvio padrão dos valores de energia de todos os protótipos do SOM.

4.3 Segmentação

No último estágio do processo de análise de agrupamentos da imagem um método de agrupamento hierárquico aglomerativo é aplicado para agrupar protótipos semelhantes no SOM já treinado e filtrado.

O método hierárquico utilizado aqui apresenta duas características importantes. A primeira delas é a imposição de restrições às possíveis fusões dos protótipos do SOM. 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 protótipos ou grupos de protótipos que sejam adjacentes (ou vizinhos) na grade do SOM. Essa estratégia já foi utilizada com sucesso em Costa (2005). Outra característica importante é que além de utilizar a informação de distância o critério de fusão empregado também se baseia em informações espaciais dos pixels da imagem associados aos protótipos do SOM.

A informação de distância (D_{ij}) entre dois agrupamentos de protótipos i e j do SOM é calculada usando a métrica euclidiana e o método de vizinhos mais próximos (ou de ligações simples). Os valores de D_{ij} são normalizados para o intervalo $[0,1]$.

As informações espaciais são calculadas através de dois índices, denominados *índice de fronteira espacial* e *índice de compacidade espacial*. Esses índices, desenvolvidos por Marçal e Castro (2005), são calculados nesta abordagem através da imagem classificada com base nos agrupamentos (ou classes) de protótipos em cada

nível do dendrograma gerado pelo método hierárquico.

O índice de fronteira espacial (IFE_{ij}) calcula o tamanho da fronteira entre todos os pares de classes (i,j) considerando oito vizinhos para cada pixel (quatro adjacentes e quatro oblíquos). A sua fórmula é dada como segue:

$$IFE_{ij} = 1 - \frac{1}{2} \left(\frac{f_{ij}}{\sum_{k=1(k \neq i)}^N f_{ik}} + \frac{f_{ij}}{\sum_{k=1(k \neq j)}^N f_{kj}} \right), \quad (5)$$

onde f_{ij} representa a quantidade de vezes que as classes i e j são vizinhas na imagem e N é o número de classes no nível do dendrograma que está sendo analisado. A utilização deste índice se justifica pela idéia de que duas classes que possuem uma fronteira espacial significativa devem estar mais propensas a uma fusão do que classes que possuem pouca ou nenhuma fronteira espacial na imagem.

O índice de compacidade espacial (ICE_{ij}) se baseia na quantidade de vezes (f_{ii}) que pixels de uma mesma classe i são vizinhos na imagem. Este índice que busca penalizar a fusão de classes compactas é dado da seguinte forma:

$$ICE_{ij} = \frac{1}{2} \left(\frac{f_{ii}}{f_{ii} + 6 \sum_{k=1(k \neq i)}^N f_{ik}} + \frac{f_{jj}}{f_{jj} + 6 \sum_{k=1(k \neq j)}^N f_{jk}} \right). \quad (6)$$

Da mesma forma que o índice IFE_{ij} , o ICE_{ij} resulta valores no intervalo [0,1].

O critério adotado aqui estabelece que o par de classes de protótipos (i,j) do SOM que apresentar o valor mais baixo resultante do cálculo da média entre D_{ij} , IFE_{ij} e ICE_{ij} é aquele que deve ser escolhido para a fusão.

No final deste estágio tem-se então um dendrograma de protótipos do SOM. Cada nível do dendrograma apresenta uma configuração diferente de agrupamentos (ou classes) de protótipos que pode ser utilizada para realizar a classificação da imagem.

5. Resultados Experimentais

Uma imagem de 385×350 pixels composta por três bandas espectrais do satélite IKONOS (cedida pela Engesat/Brazil, © Space Imaging) foi utilizada para testar a metodologia de classificação proposta. A cena mostra parte de uma área com pivots de irrigação na região de Andaraí – BA e apresenta 06 classes de cobertura terrestre predominantes: vegetação rasteira, mata, dois padrões de solo nu e dois tipos de culturas agrícolas. A Figura 1(a) mostra uma composição colorida da imagem utilizada nos testes.

De acordo com os procedimentos descritos na subseção 4.1, 1292 janelas amostrais de tamanho 9×9 foram coletadas a partir da imagem teste e utilizadas para treinar um SOM composto por 225 neurônios dispostos em uma grade retangular 15×15. A Figura 1(b) ilustra a imagem de cada um dos protótipos do SOM dispostos na grade

após o término do treinamento. Através dela é possível visualizar a formação de agrupamentos que correspondem aos padrões de cobertura terrestre presentes na imagem e verificar as propriedades de ordenação topológica e de casamento de densidade do SOM. Classes de cobertura terrestre com atributos espectrais semelhantes foram mapeadas em regiões vizinhas no mapa e aquelas que ocupam áreas maiores na imagem também foram mapeadas para um número maior de protótipos na grade do SOM.




Figura 1. (a) Composição colorida da imagem utilizada nos experimentos. (b) Imagem dos protótipos do SOM na grade retangular 15x15 após o treinamento. OBS: as imagens são apresentadas em escalas diferentes.

No estágio seguinte da análise, 49 protótipos do SOM foram filtrados. Dentre eles, 10 apresentaram atividade nula e 39 demonstraram um alto grau de heterogeneidade espectro-textural, uma vez que apresentaram valores de energia (ENE) acima do limiar apresentado na equação (4). As matrizes de co-ocorrência de níveis de cinza foram calculadas para cada protótipo nas quatro direções (0° , 45° , 90° e 135°) e a uma distância de um pixel ($d = 1$).

Após o estágio de filtragem, o método de agrupamento hierárquico (descrito na subseção 4.3) foi aplicado sobre os 176 protótipos restantes. Com isso, um dendrograma contendo 176 níveis de configurações de agrupamentos diferentes para o SOM filtrado foi gerado.

Utilizando a informação de que a imagem apresenta 6 classes de cobertura terrestres predominantes (citadas anteriormente), aquele nível do dendrograma que apresentou 6 agrupamentos (ou classes) de protótipos para o SOM foi escolhido para realizar a classificação da cena. A Figura 2(a) mostra a grade de protótipos do SOM segmentada em 6 agrupamentos. Os protótipos marcados com ‘o’ e com ‘x’ correspondem, respectivamente, aos protótipos inativos e heterogêneos filtrados na etapa anterior. É possível observar que tais protótipos funcionam como “bordas” separando algumas classes de protótipos do SOM.

Para realizar a classificação final, a imagem foi percorrida inteiramente tomando janelas de pixels com dimensões 9×9 (iguais às das janelas amostrais) e comparado-as com todos os protótipos do SOM. Essa comparação foi feita através das distâncias calculadas entre a janela de pixels considerada e cada um dos protótipos. Ao pixel central de cada janela de pixels da imagem foi atribuído o rótulo do protótipo que apresentou a menor distância a ela. Em seguida, cada um dos pixels associados aos protótipos heterogêneos do SOM foi classificado atribuindo um rótulo igual ao do pixel

vizinho (já classificado) com a menor distância a ele em termos de atributos espectrais. A Figura 2(b) mostra a imagem teste classificada pelo método proposto.




Figura 2. (a) Grade de protótipos do SOM segmentada em 6 agrupamentos. (b) Imagem teste classificada pelo método proposto.

Com o objetivo de validar a classificação resultante do método proposto, e considerando ainda a ausência de “verdade terrestre” para a imagem teste, foi realizada uma classificação supervisionada da imagem através de uma Rede Neural de *Perceptrons* Multicamadas, e o resultado da mesma foi utilizado como referência (ou “verdade”) para o cálculo do índice de concordância *kappa* (normalmente utilizado para avaliar a precisão de classificação de imagens de satélite). O valor obtido para o índice calculado com as duas imagens foi de 0.82, o que nos permite concluir que a qualidade da classificação produzida pelo método proposto foi bastante satisfatória.

6. Conclusões e Considerações Finais

Este trabalho mostra que o SOM pode ser uma ferramenta eficaz para realizar a análise de agrupamentos de imagens de satélite. Ao invés de trabalhar diretamente com os padrões originais da cena o método proposto analisa os dados da imagem através de um conjunto de protótipos do SOM. 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. Além disso, o método apresenta outras vantagens e potencialidades que o colocam como uma alternativa promissora para a classificação de imagens de satélite. 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 de imagens de satélite.
- 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 hipersféricos.
- A utilização de um método de agrupamento hierárquico permite que o usuário compreenda em diferentes níveis de agrupamentos as relações existentes entre os padrões de cobertura terrestre presentes na imagem. Isto pode ser muito útil em situações onde a estrutura da informação presente na imagem não é muito clara. Além

disso, caso o usuário deseje, a imagem pode ser classificada considerando diferentes quantidades de classes.

- O método proposto apresenta um mecanismo de fusão eficiente utilizado pelo método de agrupamento hierárquico empregado para segmentar o SOM, o qual respeita as relações de vizinhança do SOM evitando que todos os pares de agrupamentos sejam analisados para se decidir sobre uma nova fusão. Além disso, as fusões não são decididas considerando somente a informação de distância entre os agrupamentos. Informações espaciais sobre os agrupamentos também são incorporadas e certamente contribuem no processo de separação das classes.

Como trabalho futuro, pretende-se aplicar versões modificadas de índices de validação de agrupamentos, conforme proposto em (Gonçalves et al., 2006), para decidir de maneira automática qual o nível do dendrograma do SOM apresenta o número ideal de agrupamentos para realizar a classificação da imagem. Pretende-se também realizar comparações de desempenho e complexidade com métodos convencionais de classificação de imagens de sensoriamento remoto.

Referências

- Ball, G. and Hall, D. (1967), "A Clustering Technique for Summarizing Multivariate Data", *Behavior Science*, v. 12, p. 153-155.
- Costa, J. A. F. (1999), Classificação Automática e Análise de Dados por Redes Neurais Auto-organizáveis. Tese (Doutorado em Engenharia Elétrica). Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas-SP.
- Costa, J. A. F. (2005), "Segmentação do SOM por Métodos de Agrupamentos Hierárquicos com Conectividade Restrita", In: *Anais do VII Congresso Brasileiro de Redes Neurais*, outubro 2005, Natal, RN.
- Gonçalves, M. L., Netto, M. L. A., Costa, J. A. F. and Zullo Jr., J. (2006), "Data Clustering using Self-Organizing Maps segmented by Mathematic Morphology and Simplified Cluster Validity Indexes", In: *Proceedings of IEEE International Joint Conference on Neural Networks*, Vancouver, July 2006, p. 8854-8861.
- Haralick, R. M., Shanmugam, K. and Dinstein, I. (1973), "Textural Features for Image Classification", In: *IEEE Transactions on Systems, Man and Cybernetics*, v. 3, n. 6, p. 610-621.
- Haykin, S. (2001), Redes neurais: princípios e práticas. Porto Alegre: Bookmann, 2 ed..
- Kohonen, T. (1997), Self-Organizing Maps, Springer Verlag (Berlim), 2nd edition.
- Marçal, A. R. S. and Castro, L. (2005), "Hierarchical Clustering of Multispectral Images Using Combined Spectral and Spatial Criteria", In: *IEEE Geoscience and Remote Sensing Letters*, v. 2, n. 1, p. 59-63.
- Richards, J. A. (2005) "Analysis of Remotely Sensed Data: The Formative Decades and the Future", In: *IEEE Transactions on Geoscience and Remote Sensing*, v. 43, n. 3, p. 422-432.
- Xu, R. and Wunsch II, D. (2005), Survey of Clustering Algorithms. In: *IEEE Transactions on Neural Networks*. v. 16, n. 3, p. 645 - 678.