

IDENTIFICAÇÃO DE PONTOS PARA A EXTRAÇÃO DE ESTRADAS EM IMAGENS SAR AEROTRANSPORTADAS: UMA ABORDAGEM BASEADA EM MAPAS AUTO-ORGANIZÁVEIS

Rodolfo G. Lotte¹, Cláudia M. de Almeida² e José Demísio S. da Silva^{1†}

¹Laboratório Associado de Matemática e Computação Aplicada - LAC

²Divisão de Sensoriamento Remoto - DSR

Instituto Nacional de Pesquisas Espaciais - INPE

rodolfo.lotte@inpe.br, almeida@dsr.inpe.br

Resumo – A grande vantagem na utilização de imagens de radar (*Radio Detection and Ranging*) é a possibilidade de levantamento em áreas frequentemente recobertas por nuvens, uma vez que o imageamento por sensores ativos independe das condições atmosféricas presentes na região de interesse. Muitas vezes, o mapeamento a partir dessas imagens é realizado manualmente, exigindo tempo e esforço consideráveis por parte do intérprete. O presente artigo aborda a utilização dos Mapas Auto-Organizáveis (*Self-Organizing Maps - SOM*) como método de identificação de pontos em imagens. Cada ponto identificado representa um elemento pertencente a uma estrada. Com o propósito de qualificar os resultados, estes foram submetidos a uma medida de desempenho específica para a extração de estradas, apresentando como resultado, seus índices de correção, perfeição e qualidade, sendo o último essencial no desempenho de determinados extratores de estradas em imagens digitais.

Palavras-chave – imagens de radar, visão computacional, mapas auto-organizáveis e extração de estradas.

Abstract – The great advantage in the usage of radar images is the possibility of surveying areas often covered by clouds, since the imaging by active sensors is independent of atmospheric conditions in the region of interest. The mapping from these images is often done manually, requiring considerable time and effort from the interpreter. This article discusses the use of Self-Organizing Maps - SOM as a method of identifying points in images. Each point represents an identified element belonging to a road. In order to qualify the results, these were submitted a specific measure of performance for the extraction of roads, presenting as a result, their rates of correctness, completeness and quality, the latter being essential in the performance of certain roads extractors in digital images.

Keywords – radar images, computer vision, self-organizing maps, and road extraction.

1. INTRODUÇÃO

O uso de imagens de radar (*Radio Detection and Ranging*) para o reconhecimento de padrões terrestres e o levantamento de informações acerca de mudanças nos alvos da superfície vem sendo muito utilizado em diferentes áreas de aplicação, tais como: geologia, hidrologia, oceanografia, cartografia e outras. O funcionamento dos radares imageadores é baseado na transmissão de micro-ondas em uma determinada faixa na superfície. As imagens são formadas através da radiação emitida pelos sensores e retroespalhada pelos objetos. Existem fatores que são considerados como obstáculos na formação de imagens óticas. No entanto, alguns desses fatores são desprezíveis no imageamento por radar, tais como nuvens, horário do dia, sombras causadas por grandes edifícios e árvores. Parte da energia emitida pelos sensores é absorvida pelo objeto, e o restante é retroespalhada. Essa energia é retornada ao sensor e medida pelo mesmo. Desta forma, a aquisição da imagem é possível em qualquer horário do dia, sob quaisquer condições de tempo, necessitando somente de condições propícias de sobrevoo.

O imageamento por radar permite auxiliar inúmeras áreas de estudo, entre estas a geologia, na análise de fendas, foliações geológicas, no estudo do relevo e na prospeção do solo para a identificação de áreas com recursos minerais etc. Na hidrologia, são tratados problemas como o gerenciamento dos recursos hídricos, a detecção de umidade do solo, pontos de alagamento. Na oceanografia, no monitoramento do mar, poluição marinha causada por derramamentos de óleo, detecção de navegações em áreas de pesca ilegal, apoio para o estabelecimento de rotas marítimas e identificação de ondas internas.

O processo de extração de estradas é considerado como sendo um componente de grande importância na cartografia [1]. A extração de estradas pode ser usada em algumas aplicações, tais como correção automática e atualização do mapeamento cartográfico. Geralmente, são utilizados dois métodos para a obtenção da rede de estradas. O primeiro é realizado por uma equipe de especialistas que vão a campo para o levantamento de informações quanto à localização e estrutura das estradas, processo que consome tempo e esforço. No segundo método, a extração de estradas é realizada por meio de dados de sensoriamento remoto aerotransportado ou orbital. Este segundo processo pode ser categorizado como manual, semi-automático ou automático. A

extração manual implica um operador humano para o delineamento de estradas, enquanto que o processo semi-automático requer a interferência humana para conduzir o processo. E, finalmente, o processo automático não requer interferências humanas [2].

A extração de feições lineares utilizando o imageamento por radar é ainda uma questão científica em aberto, e as aplicações existentes exprimem soluções diferenciadas. A extração de feições lineares pode ser aplicada em áreas como o mapeamento cartográfico, a correção automática ou a atualização de produtos em sistemas de informação geográfica (*Geographic Information Systems - GIS*), entre outras.

1.1 Trabalhos anteriores

Há inúmeras técnicas disponíveis atualmente para extração de estradas. Com a grande disponibilidade de artigos abordando o problema, nota-se um intenso avanço no desenvolvimento de novos métodos nas últimas décadas [1,3,4], tanto em imagens óticas como de radar. Alguns dos trabalhos anteriores consagrados estão organizados a seguir, de acordo com os respectivos métodos de extração. Em vista do grande escopo de métodos disponíveis, este trabalho busca mostrar as principais contribuições.

1. Semeação automática (*Automatic Seeding*): A técnica consiste em identificar pontos na imagem, cuja localização caracterize o centro de uma estrada. Alguns métodos necessitam de pontos iniciais como ponto de partida para o algoritmo, a exemplo do roteamento de estradas (*road trackers*) e modelos de contornos ativos (*snakes*). Harvey [5] destaca a importância da qualidade dos pontos iniciais para o desempenho do algoritmo de extração. Doucette et al. [1] apresentaram o método de semeação automática utilizando o algoritmo de detecção de bordas paralelas (*Anti-parallel Centerline Extraction - ACE*). Hu et al. [6] utilizaram o mesmo processo para o roteamento de estradas.
2. Classificação: O processo de classificação consiste em categorizar os dados presentes nas imagens em diferentes classes de padrões, de forma que seja atribuída uma identidade ou valores de probabilidade para os dados analisados. Os valores de probabilidade indicam a probabilidade de certo dado pertencer a uma determinada classe de padrão. Embora os classificadores sejam utilizados para categorizar os dados, no imageamento por radar eles são utilizados como classificadores: espectrais, texturais, geométricos, contextuais e geradores automático de classes de padrões [2]. Doucette et al. [7] utilizaram a imagem classificada como produto de entrada na aquisição dos eixos centrais das vias por meio do algoritmo SORM (*Self-Organizing Road Map*).
3. Transformada de Hough: A Transformada de Hough (TH) é um operador matemático capaz de detectar formas geométricas em imagens digitais, tais como linhas retas, círculos e elipses. Desenvolvida em 1962 por Paul Hough [8], o método consiste em aplicar na imagem original uma transformação, tal que todos os pontos pertencentes a um mesmo segmento sejam mapeados em um único ponto no domínio da TH. Por ser um operador muito eficiente na detecção de linhas, a TH é muito utilizada na resolução do problema da extração de feições lineares em imagens de radar. Dell'Acqua et al. [9] apresentaram uma variação do algoritmo, de forma a serem consideradas diferentes larguras para as feições. Amberg et al. [10] utilizaram, a princípio, a Programação Dinâmica para a extração dos eixos centrais das vias, e posteriormente, a TH é utilizada para a conexão dos pontos descontínuos provenientes da extração.
4. Morfologia matemática: A morfologia matemática é utilizada há muito tempo no processamento de imagens digitais, e as aplicações realizadas com operadores morfológicos remetem à Teoria dos Conjuntos. Processos como *união* e *intersecção* podem ser aplicados às imagens e são comumente utilizados como filtros nas etapas de pré e pós-processamento. Operações mais complexas envolvem efeitos de manipulação dos objetos presentes na cena, tais como dilatação, erosão e outras. Desta forma, os operadores são utilizados, entre muitas coisas, para a remoção de pequenas regiões, buracos e suavização de formas e contornos. Idbraim et al. [11] utilizaram operadores morfológicos para a união dos resultados obtidos em um filtro direcional. Chanussot et al. [12] utilizaram esta abordagem como forma de remoção de trechos espúrios na imagem.
5. Roteamento de estradas: O processo de roteamento de estradas consiste em traçar retas entre os pontos que representam a localização dos segmentos de interesse. O algoritmo possui duas etapas fundamentais: primeiro, uma função que determina a posição do ponto seguinte, e na sequência, uma segunda função de refinamento. Ao fim do processo, obtém-se a rede completa de estradas, e as linhas conectadas representam então o eixo central das feições. Hu et al. [6] utilizaram o processo de roteamento de estradas baseado na classificação dos "rastros" da estrada. Wiedemann e Ebner [13] utilizaram fatores de distância e hipóteses para a conexão de segmentos descontínuos.
6. Segmentação: O processo de segmentação em imagens digitais é o processo de agrupamento de dados dentro de subconjuntos, com o objetivo de simplificar a representação da imagem e, conseqüentemente, facilitar o seu processo de análise. O resultado gerado a partir deste processo consiste em um conjunto de regiões ou conjunto de contornos. Os *pixels* pertencentes ao mesmo conjunto possuem características similares, e cada conjunto difere significativamente de seus vizinhos. A segmentação tem um papel importante no processamento de imagens de radar. Alguns trabalhos a utilizam como principal técnica na extração de estradas [14, 15].
7. Modelo de contorno ativo (*Snakes*): Trata-se de um processo iterativo e adaptativo para a identificação de contornos de objetos. O método, desenvolvido inicialmente por Kass et al. [16], consiste em uma curva poligonal inserida no interior do objeto, a qual evolui a fim de se alinhar ao seu contorno. *Snakes* são utilizadas na extração de estradas e na identificação do

eixo central das vias presentes nas imagens. A abordagem original possui muitas variações. Gruen e Li [4] utilizaram uma extensão ao método, cuja abordagem permite extrair os eixos centrais das vias em imagens óticas, eliminando obstáculos que muitas vezes dificultam tal extração. Mayer et al. [17] utilizaram o método *ribbon-snakes* para a aquisição das bordas paralelas ao eixo central, de acordo com uma constante de largura pré-definida.

O propósito deste trabalho é abordar o método de Semeação Automática para a identificação de pontos que caracterizam a presença de uma estrada em uma imagem SAR, utilizando para isto os Mapas Auto-Organizáveis. Harvey [5] destaca a importância da qualidade dos pontos para um bom desempenho do método de extração. Serão abordadas duas formas de varredura da imagem, e cada uma apresenta uma precisão distinta de identificação. Porém, é necessário avaliar os parâmetros da rede em cada utilização, buscando minimizar os erros de comissão e omissão na identificação de pontos destes modelos.

2. O IMAGEAMENTO POR RADAR

A geometria básica da formação de uma imagem SAR aerotransportada pode ser ilustrada pela Figura 1, em que V determina a velocidade segundo a qual a plataforma se move em uma determinada direção, conhecida também por direção de azimute. O parâmetro H representa a altitude em que ela se encontra. Esta plataforma transporta uma antena com observação lateral, que ilumina a superfície em estudo com pulsos de radiação eletromagnética. A distância da plataforma até a área iluminada é conhecida como *slant range* R_0 , e a distância da superfície da Terra sobre a qual se encontra a plataforma (nadir) até a área iluminada é conhecida como *ground range*, expresso por R_g na Figura 1 [18].




Figura 1: Geometria de imageamento de radares aerotransportados de visada lateral.

Fonte: Adaptado de Oliver e Quegan [18].

Tipicamente, os sistemas de imageamento por radar possuem dois tipos de plataformas: aeronaves ou satélites. A obtenção de imagens SAR por plataformas aerotransportadas permite a aquisição de dados em qualquer momento e em qualquer parte da superfície da Terra, embora dependam das condições de tempo para o sobrevoo. Os satélites podem visualizar uma área maior da superfície da Terra. Por estarem continuamente em órbita terrestre, é relativamente fácil coletar imagens da mesma área de modo sistemático, a fim de monitorar mudanças na biosfera.

As imagens de radar são geradas a partir da emissão de pulsos de largura T_p em intervalos de T segundos. Utilizando o modelo de ponto fixo P , mostrado na Figura 1, o sistema de imageamento SAR possui um intervalo de tempo $(t_s - t_e)$, em que t_e representa o ponto onde é iniciada a transmissão dos pulsos pelo sensor, e t_s , o ponto final da transmissão. Neste intervalo, o radar envia N pulsos e coleta N pulsos resultantes do retorno do ponto P . As amostras recebidas são retidas na memória. Durante este intervalo, a plataforma se desloca $(t_s - t_e)$ metros com velocidade V . Este intervalo é conhecido como comprimento de abertura sintética [18].

As imagens obtidas por radar são caracterizadas, na maioria das vezes, pelo *speckle*, ruído decorrente da natureza coerente da radiação emitida para a formação das imagens. Tal ruído é modelado como sendo um ruído multiplicativo, variando sua intensidade de acordo com a força do sinal. O ruído é caracterizado por um aspecto granuloso nas imagens SAR, o que muitas vezes dificulta a interpretação dos alvos. Na maioria das vezes, é necessário submeter a imagem a rotinas de filtragem para a minimização do ruído ou realce das vias, fazendo com que se maximize a compreensão das áreas a serem extraídas. Alguns métodos de extração de estradas dispensam a utilização de filtros de suavização [4, 7]; outros, no entanto, ainda necessitam da filtragem [3, 9, 11].

3. SEMEAÇÃO AUTOMÁTICA

Como dito anteriormente, o método de semeação automática não é necessariamente um método de extração, mas sim um grande auxiliar neste processo. Ele possibilita identificar os pontos que caracterizam a presença de uma estrada na imagem.

Para tanto, será utilizado um método de classificação utilizando métricas em Inteligência Artificial (IA), que são caracterizadas por simular, computacionalmente, os comportamentos e a aprendizagem humana. O método denominado Mapas Auto-Organizáveis será abordado na Seção seguinte.

3.1 Mapas Auto-Organizáveis

Os Mapas Auto-Organizáveis, ou simplesmente rede SOM, pressupõem o aprendizado não supervisionado, em que é necessário apresentar à rede os padrões a serem reconhecidos, porém, o treinamento é realizado de forma menos exaustiva. A ativação dos neurônios, por sua vez, é realizada em um processo de “competição” entre os mesmos. As redes SOM são também chamadas de Mapas de Kohonen, fazendo referência ao seu criador Teuvo Kohonen [19]. A rede de Kohonen não possui camada intermediária, e sua arquitetura é constituída por apenas uma camada de entrada e uma de saída, sendo que esta última representa o mapa de neurônios, (Figura 2a). A aprendizagem ocorre obtendo-se a localização do neurônio vencedor, isto é, suas coordenadas cartesianas no mapa. Este processo é realizado obtendo-se o neurônio com menor valor, segundo a norma euclidiana (Equação 1).

$$i(X) = \underset{j,k}{\operatorname{arg\,min}} \|X - W_{j,k}\| \quad \begin{cases} j = 1, 2, \dots, n \\ k = 1, 2, \dots, n \end{cases} \quad (1)$$

Em que $\|\cdot\|$ denota a norma euclidiana entre os valores de entrada X , e $W_{j,k}$, correspondentes aos pesos de cada neurônio (j, k). E $i(X)$ descreve a posição do neurônio vencedor no mapa [20]. Todos os pesos dos neurônios vizinhos ao neurônio vencedor são atualizados obedecendo o seguinte critério:

$$W(t+1)_{j,k} = \begin{cases} W(t)_{j,k} + \eta(t) * \sigma * [X - W(t)_{j,k}], & \sigma \neq 0 \\ W(t)_{j,k}, & \sigma = 0 \end{cases} \quad (2)$$

Em que $\eta(t)$ é a taxa de aprendizagem da rede, que decai a cada iteração do treinamento conforme a propriedade $\eta_0[e^{-\frac{t}{T}}]$, em que η_0 é a taxa de aprendizagem inicial e T é o número máximo de épocas. A variável σ denota a influência do neurônio analisado em relação ao vencedor, obedecendo um determinado raio de vizinhança, (Figura 2b), ou seja, ela identifica o quão perto os nós estão; quanto maior o valor, maior a proximidade. Se o neurônio não estiver próximo o suficiente do neurônio vencedor, sua influência será nula, e conseqüentemente, não será aplicado o ajuste. É possível agregar tipos distintos de vizinhança entre os nós do mapa. Neste trabalho, o valor de σ é obtido por meio da Equação 3, que possui propriedade gaussiana (Figura 2c).

$$\sigma = e^{-\left(\frac{dist}{2*diam^2}\right)} \quad (3)$$

Em que $dist$ representa a distância Euclidiana entre o neurônio vencedor e o neurônio em questão, e $diam$ o raio de vizinhança.




Figura 2: Rede SOM: (a) Exemplo de arquitetura. (b) Raio de vizinhança de um neurônio vencedor. (c) Valores de σ de alguns neurônios vizinhos.

Fonte: Adaptado de Haykin [20].

3.2 Classificação e Identificação

No processo de classificação e marcação dos pontos na imagem, o mapa de pesos finais foi de extrema importância. Ele permitiu determinar quais padrões apresentados eram, de fato, uma possível estrada. Este procedimento foi realizado da seguinte forma:

- Obtenção da norma do mapa de pesos finais de treinamento ou Matriz U (Figura 3a).
- Apresentam-se os padrões iniciais de treinamento à rede para a obtenção dos centros de cada aglomerado.
- Calcula-se o raio de cada aglomerado a partir dos centros obtidos. Este processo é realizado obtendo-se o perfil ao longo da linha em que se encontra o centro analisado. O mínimo mais próximo deste centro é caracterizado como a fronteira do aglomerado, e conseqüentemente seu raio (Figuras 3b e 3c).




Figura 3: Treinamento cooperativo: (a) Exemplo do mapa da norma dos pesos finais (Matriz U). (b) Perfil ao longo da linha do centro analisado. (c) Cálculo do raio por meio do perfil.

Obtendo-se o raio do aglomerado, é possível então refinar o processo de sementeação atribuindo um raio de pertinência, ou seja, restringindo-se o raio do aglomerado. Cada um dos padrões que é apresentado à rede tem um ponto no mapa que o identifica. Esta localização, quanto mais próxima de algum centro, mais similar será daquele centro. Desta forma, restringindo-se a área do aglomerado, saber-se-á que os pontos marcados no processo de sementeação terão maior similaridade com os padrões treinados (Figura 4). Este processo foi realizado com o objetivo de agregar limiares diferentes para cada aglomerado, pois uma vez que cada um deles possui raios distintos, é necessário que a análise das distâncias euclidianas sejam realizadas proporcionalmente, cabendo ao usuário fornecer apenas a porcentagem de redução referente ao raio do aglomerado.




Figura 4: Processo de classificação das estradas.

De acordo com a Figura 3a, no treinamento da rede SOM deste trabalho, foram utilizados nove padrões de entrada (nove aglomerados). Os oito primeiros padrões correspondem a uma determinada orientação do perfil claro de uma estrada, e um último padrão representa o padrão não referente a estradas. A utilização deste último padrão possibilitou a criação de uma área de “escape” no próprio mapa de neurônios. Desta forma, os padrões não referentes a estradas sobressaem-se em relação ao conjunto dos outros oito aglomerados, permitindo o cálculo mais apurado dos padrões de interesse. Foram realizados testes não utilizando este último padrão. No entanto, os resultados foram insatisfatórios, justamente pelos pontos no processo de classificação estarem localizados, por muitas vezes, em uma fronteira de decisão entre dois ou mais aglomerados.

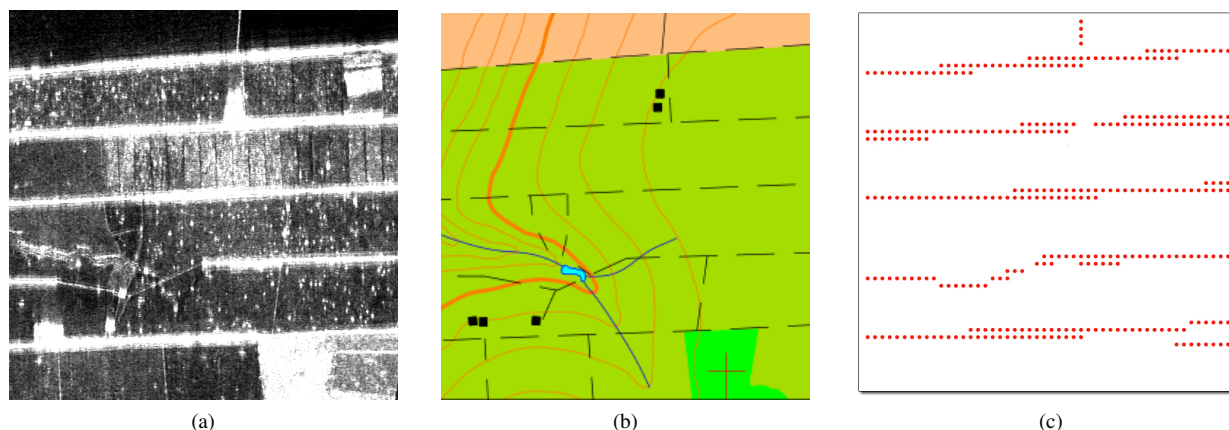
4. RESULTADOS

4.1 Dados utilizados

Para a realização dos experimentos de ambos os métodos, foi adotado um recorte de uma imagem SAR (513x513 *pixels*), que recobre a região de Paragominas no estado do Pará, com resolução radiométrica de 8 *bits* e espacial de 2,5 metros na banda P. A imagem foi adquirida com o sensor OrbisAR no período de aerolevantamento entre 11 de fevereiro de 2007 e 13 de março de 2007, com altitude de 11.000 m (Figuras 5a e 5b). Todas as rotinas de implementação, bem como os experimentos, foram realizados no ambiente de desenvolvimento MATLAB versão 7.8.0.347. Os testes foram realizados sobre a imagem original com extensão *tiff*, e os resultados finais mostrados no padrão *jpg*.

4.2 Resultados

Em imagens SAR, nem sempre as estradas são encontradas com perfis mais claros. No entanto, as estradas na imagem utilizada é formada por estradas com este perfil. Desta forma, a RNA foi treinada para reconhecer somente este padrão. A orientação de uma estrada na imagem é uma informação desconhecida e desta forma, foram criadas oito diferentes orientações do perfil claro. Para a janela de cada padrão, foi definida a dimensão de 19x19 *pixels*. Por convenção, os dados de cada padrão foram



(a)

(b)

(c)

Figura 5: Imagem utilizada nos experimentos: (a) Recorte da imagem SAR (Banda P). (b) Referência cartográfica. (c) Modelo de referência para a medida de desempenho do método.

Fonte: Orbisat [21].

alinhados em um vetor, de forma que se tornassem um padrão unidimensional, definindo a arquitetura da rede com 361 entradas e camada de saída como um mapa bidimensional de dimensão 60x60.

Após o treinamento da rede, é realizada a leitura dos valores de cada *pixel*. É estabelecida uma grade da mesma dimensão que os padrões de treinamento, de forma que ela seja varrida na imagem em saltos pré-definidos. Os valores de cada quadrante lido são atribuídos como uma entrada para a rede. Como detalhado na Seção 3.1, após o treinamento da rede é possível classificar o que é e o que não é estrada na imagem. Os pontos que caracterizam a presença de uma estrada foram sinalizados de acordo com a distância euclidiana entre o neurônio vencedor (do respectivo padrão apresentado) e cada centro dos oito padrões que caracterizam uma estrada. A partir deste cálculo, pode-se analisar se o padrão esta dentro do raio de pertinência dos aglomerados de interesse, e se assim estiver, o *pixel* central deste padrão é então sinalizado como pertencente a uma estrada. Foram definidos alguns valores *ad-hocs*¹, tais como variável de aprendizado, número de épocas e número de neurônios na camada de saída, baseando-se somente em dados experimentais.

Para a validação do método apresentado neste trabalho, foram adotados as medidas de desempenho para a extração de estradas abordada por Harvey [5]. No entanto, a abordagem tratada pelo autor especifica medidas de desempenho para segmentos lineares, em que é definido um modelo de referência, e a partir deste, obtêm-se os valores de desempenho do método. Seguindo o mesmo conceito, define-se um modelo de referência para a identificação dos pontos Figura (5c). Na Figura 6, é apresentada a sequência de resultados de acordo com os valores do raio de pertinência (Tabela 1).

Tabela 1: Medida de desempenho.

	Pertinência*	Perfeição	Correção	Qualidade
Experimento 1	10%	0,95	0,43	0,73
Experimento 2	20%	0,88	0,48	0,70
Experimento 3	30%	0,84	0,65	0,75
Experimento 4	40%	0,65	0,79	0,72
Experimento 5	50%	0,10	0,78	0,55

* As porcentagens de *pertinência* dizem respeito à redução do raio do aglomerado.

Analisando a Tabela 1 e a Figura 6, percebe-se claramente que o raio de pertinência afeta diretamente o fator de correção, que consiste na porcentagem de pontos que o modelo de referência cobre o obtido. Assim, entende-se que, à medida que o raio se reduz, são reduzidos também os pontos marcados incorretamente. No entanto, alguns dos pontos não são marcados, afetando o fator de qualidade.

5. CONCLUSÃO

O presente artigo apresentou a utilização dos mapas auto-organizáveis como abordagem na sementeção automática de estradas em uma imagem SAR aerotransportada. Os resultados indicam eficiência na utilização da rede SOM como modelo classificador

¹Hipótese informal, definida sem um mecanismo explicativo essencial.

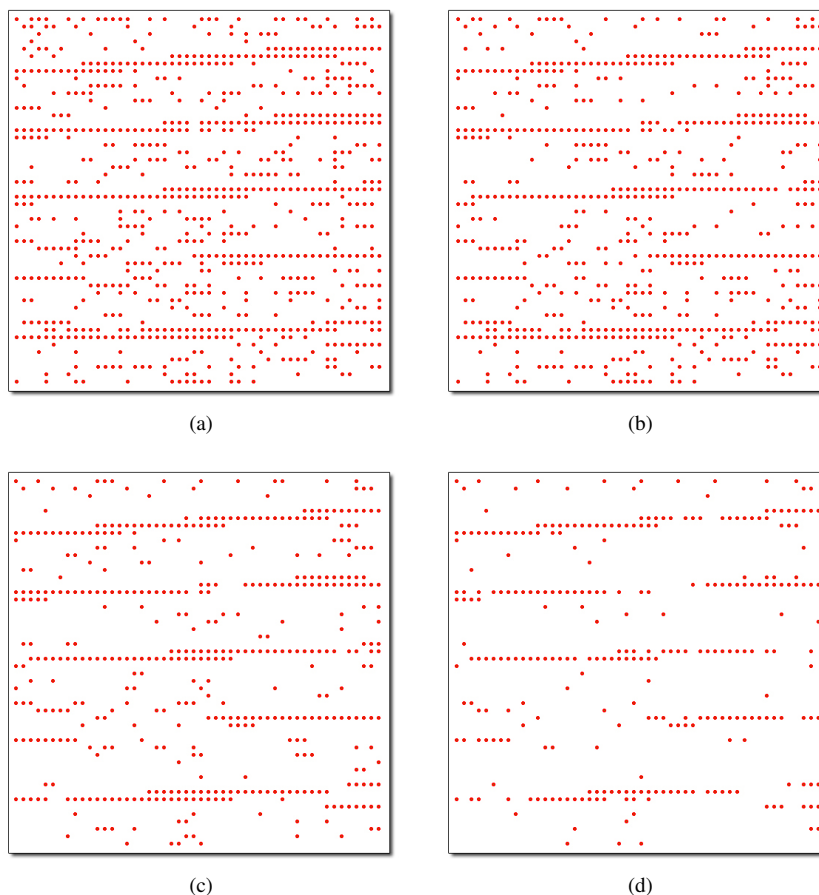


Figura 6: Resultados da identificação. (a) Experimento 1. (b) Experimento 2. (c) Experimento 3. (d) Experimento 4.

de dados, e portanto, um bom método na sementeção automática de estradas em imagens de radar. O processo de identificação foi realizado sem a necessidade de qualquer pré-processamento na imagem, tais como filtros suavizadores e filtros de realce.

O conceito para a obtenção dos raios de cada aglomerado, apresentado na Seção 3.2, permitiu que se analisasse cada padrão de maneira diferenciada em cada um dos setores do mapa de Kohonen. Isso fez com que se maximizasse a porcentagem de pontos identificados corretamente, e, conseqüentemente, o aumento da qualidade dos resultados.

Muitos trabalhos abordam algoritmos de extração de estradas utilizando o processo de sementeção. No entanto, grande parte destes trabalhos utiliza o processo de sementeção semi-automático, no qual é necessário que o usuário especifique pontos próximos à feição de interesse. O processo de sementeção apresentado neste trabalho é realizado de modo automático com o auxílio das redes neurais artificiais. Em face das características da imagem SAR utilizada nos experimentos, são sinalizados muitos pontos espúrios, ocasionando erros de comissão em grande quantidade. Uma solução para isto seria a criação de um algoritmo de poda, que viabilizaria a escolha dos melhores pontos entre aqueles identificados, eliminando os demais.

Agradecimentos

Os autores agradecem o apoio financeiro da CAPES, FINEP e CNPq.

Dedicatória

“Que o teu trabalho seja perfeito para que, mesmo depois da tua morte, ele permaneça”—Leonardo da Vinci. Ao querido professor, orientador e grande amigo Dr. José Demísio Simões da Silva, que apesar de nos deixar uma enorme saudade, deixa também seus ensinamentos, ética, profissionalismo, humor e amizade. Elementos que o fizeram tão querido por nós, amigos do INPE. Que Deus o abençoe onde estiver.

REFERÊNCIAS

- [1] P. Doucette, P. Agouris and A. Stefanidis. “Automated road extraction from high resolution multispectral imagery”. *Photogrammetric engineering and remote sensing*, vol. 70, no. 12, pp. 1405–1416, Dezembro 2004.

- [2] A. C. Hauptfleisch. “Automatic road network extraction from high resolution satellite imagery using spectral classification methods”. Master’s thesis, University of Pretoria, Fevereiro 2010.
- [3] F. Tupin, H. Maître, J.-F. Mangin, J.-M. Nicolas and E. Pechersky. “Detection of linear features in SAR images: Application to road network extraction”. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 36, no. 2, pp. 434–453, Março 1998.
- [4] A. Gruen and L. H. “Semi-automatic linear feature extraction by dynamic programming and LSB-Snakes”. *Photogrammetric engineering and remote sensing*, vol. 63, no. 8, pp. 985–995, 1997.
- [5] W. A. Harvey. “Performance evaluation for road extraction”. In *Proceedings of the ISPRS Workshop on 3D Geospatial Data Production: Meeting Application Requirements*, 1999.
- [6] J. Hu, A. Razdan, J. Femiani, M. Cui and P. Wonka. “Road network extraction and intersection detection from aerial images by tracking road footprints”. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 45, no. 12, pp. 4144–4156, 2007.
- [7] P. Doucette, P. Agouris, A. Stefanidis and M. Musavi. “Self-organised clustering for road extraction in classified imagery”. *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 55, pp. 347–358, Fevereiro 2001.
- [8] P. V. C. Hough. “Method and means for recognizing complex patterns”. *United States Patent*, , no. 3069654, 1962.
- [9] F. Dell’Acqua and P. Gamba. “Detection of urban Structures in SAR images by robust fuzzy clustering algorithms: the example of street tracking”. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 39, no. 10, Outubro 2001.
- [10] V. Amberg, M. Coulon, P. Marthon and M. Spigai. “Structure extraction from high resolution SAR data on urban areas”. In *Proceedings of IEEE International Geoscience and Remote Sensing Symposium*, vol. 3, pp. 1784–1787, Setembro 2004.
- [11] S. Idbraim, D. Mammass, D. Aboutajdine and D. Ducrot. “An automatic system for urban road extraction from satellite and aerial images”. *WSEAS Trans. Sig. Proc.*, vol. 4, pp. 563–572, October 2008.
- [12] J. Chanussot, G. Mauris and P. Lambert. “Fuzzy Fusion Techniques for Linear Features Detection in Multitemporal SAR Images”. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 37, no. 3, Maio 1999.
- [13] C. Wiedemann and H. Ebner. “Automatic Completion and Evaluation of Road Networks”. *International Archives of Photogrammetry and Remote Sensing*, vol. XXXIII, no. B3, 2000.
- [14] C. Zhang. “Towards an operational system for automated updating of road databases by integration of imagery and geodata”. *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 58, pp. 166–186, 2004.
- [15] J. B. Mena and J. A. Malpica. “An automatic method for road extraction in rural and semi-urban areas starting from high resolution multi-spectral satellite imagery”. *Pattern Recognition Letters*, vol. 26, pp. 1201–1220, 2005.
- [16] M. Kass, A. Witkin and D. Terzopoulos. “Snakes: Active Contour Models”. *International Journal of Computer Vision*, vol. 1, no. 4, pp. 321–331, 1987.
- [17] H. Mayer, I. Laptev, A. Baumgartner and C. Steger. “Automatic road extraction based on multi-scale modeling, context, and snakes”. *International Archives of Photogrammetry and Remote Sensing*, vol. XXXII, no. Part-3-2W3, pp. 106–113, 1997.
- [18] C. Oliver and S. Quegan. *Understanding Synthetic Aperture Radar Images*. Artech House Publishers, Boston, 1998.
- [19] T. Kohonen. “Self-organized formation of topologically correct feature maps”. *Biological Cybernetics*, vol. 43, pp. 59–69, 1982a.
- [20] S. Haykin. *Neural Network: A Comprehensive Foundation*. Macmillan College Publishing Company, 1994.
- [21] “ORBISAT DA AMAZÔNIA IND. E AEROLEVANTAMENTO S.A.” Imagem da cidade de Paragominas (PA) e entorno 2007. Imagem de radar de abertura sintética aerotransportado. Sensor OrbiSAR. Aquisição entre 11 fev. 2007 e 13 mar. 2007. Bandas X e P. CD-ROM, 2010.