

Avaliação do método SCTMS na extração de feições em cartas topográficas matriciais

Raphael L F Greco*, Wagner B da Silva
Instituto Militar de Engenharia
Praia Vermelha, Rio de Janeiro, RJ, Brasil.
Praça General Tibúrcio, 80, 22290-270,
*raphaelluiz88@gmail.com

RESUMO: Este artigo avalia a utilização do método Superpixel based color topographic map segmentation method (SCTMS) na classificação de simbologias presentes em cartas topográficas matriciais, definidos pelo manual técnico de convenções cartográficas do exército brasileiro. O SCTMS possui três etapas em seu processo: detecção de bordas, segmentação por watershed com união de bacias similares e classificação via SVM. A fim de verificar o desempenho do método, foi realizada uma comparação entre a classificação manual e a classificação do SCTMS de recortes de cartas topográficas. O resultado dessa análise apresentou-se favorável, com indicações porém de necessidades, de pesquisas futuras com relação aos parâmetros adotados no método.

PALAVRAS-CHAVE: Engenharia cartográfica. Processamento digital de Imagens. Dupla cor opoente. Watershed. Superpixel. SVM. SCTMS.

ABSTRACT: This paper evaluates how Superpixel based color topographic map segmentation method (SCTMS) classifies symbologies in a digitalized topographic map, defined by brasilian army cartographic convention technical manual. SCTMS has three steps in your process: boundary detection, watershed segmentation with similar basin union and SVM classification. The method evaluation was made by comparison between manual classification and SCTMS classification from clips of topographic maps. The result of this analysis was favorable, with indications although of future research needs regarding the parameters adopted in the method.

KEYWORDS: Surveying Engineering. Digital Image Processing. Double color opoente. Watershed. Superpixel. SVM. SCTMS.

1. INTRODUÇÃO

Dentre as fontes de dados geográficos utilizadas na construção de Sistemas de Informação Geográficos (SIG), encontram-se as cartas topográficas analógicas. Estas podem ser digitalizadas matricialmente por meio de escâneres. Nesses casos, todas as informações geográficas encontram-se dispostas em um único plano de informações colorido que consiste de feições lineares, tais como curvas de nível e estradas, áreas como vegetações e massas d'água e pontos como edificações [1, 2].

Ao longo de diversos séculos foram produzidos inúmeros exemplares analogicamente que hoje se encontram digitalizados por meio de escâneres específicos para este tipo de trabalho, dando origem aos mapas matriciais. Com a evolução da Cartografia, os mapas passaram a ser criados digitalmente, necessitando-se de uma nova forma de armazenamento da informação, conhecida como vetorial.

A motivação deste trabalho baseia-se no potencial de informações extraídas dos arquivos vetoriais na aplicação de um SIG. Como a aquisição manual dos vetores através das cartas matriciais é um processo dispendioso tanto em recursos humanos quanto temporais, o processamento de mapas digitais coloridos, em formato matricial, visa facilitar a extração das informações contidas na carta por meio de automatizações.

De acordo com [3], existem desafios na realização da extração automática de feições a partir da carta matricial que fazem com que a extração direta a partir da cor seja difícil. Devido a essas dificuldades na aplicação de métodos automáticos e no elevado custo dos manuais, existe uma grande quantidade de produtos matriciais que não possuem o seu correspondente vetorial.

A fim de ilustrar esta demanda, no cenário internacional, podem-se tomar como exemplos dois centros de distribuição de informações geográficas, o United States Geological Survey (USGS) e o Centro de Sistemas de Informações Geográficas em Sinica, Taiwan, os quais lançaram mais de 178.000 e

160.000 cartas matriciais em 2015 e 2006, respectivamente. Estes produtos são provenientes de mapeamento histórico, recuperado e digitalizado, não possuindo, em sua maioria, o correspondente vetorial [4, 5, 6].

No cenário nacional, existem dois grandes órgãos que são responsáveis pela cartografia sistemática, o Instituto Brasileiro de Geografia e Estatística (IBGE) e a Diretoria do Serviço Geográfico (DSG). Em pesquisa realizada nos bancos de dados desses órgãos em 2016, considerando apenas cartas do mapeamento sistemático, foi constatada a existência de 12.413 cartas topográficas matriciais, das quais 7.556 possuem seu correspondente vetorial, resultando em um montante de 4.857 cartas a serem vetorizadas [7, 8].

De acordo com [9], este passivo existente criou uma demanda no meio científico de tal forma que, nos últimos 45 anos, foram desenvolvidos diversos métodos para realizar a extração de feições em cartas matriciais de forma automática, como pode ser visto em [4]. Essa gama de métodos baseia-se na aplicação de diversas técnicas de segmentação de imagem colorida, como pode ser visto em [3, 10, 11, 12, 13, 14, 15, 16, 17, 18].

Como objeto de estudo, foi escolhido o método superpixel based color topographic map segmentation method (SCTMS) desenvolvido por [3]. Este método foi aplicado na extração das feições da carta, criando classes baseadas nas cores das feições. Contudo, tendo em vista a utilização do resultado da extração como insumo para vetorização, o ideal é que sejam criadas classes para as diferentes simbologias presentes no catálogo de símbolos para cartas topográficas [19]. Sendo assim, este trabalho tratará da avaliação do método SCTMS aplicado com objetivo de extração de feições em classes distintas baseadas na simbologia.

2. FUNDAMENTAÇÃO TEÓRICA

O método SCTMS tem por objetivo segmentar a imagem em *superpixels* e classificar estes segmentos, utilizando descritores de cor e textura através do método de máquina de ve-


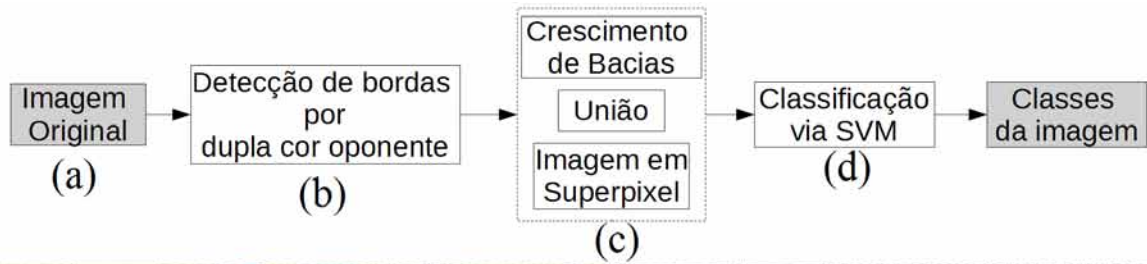


Fig. 1 – Diagrama de fluxo do SCTMS com exemplos de cada etapa. (a) Imagem original. (b) Imagem de intensidade de bordas. (c) Imagem original sobreposta aos polígonos gerados na etapa de segmentação por superpixel (d) Resultado da classificação via SVM.

tor suporte (SVM). Para tal, o método apresenta-se dividido em três etapas: detecção de bordas, segmentação e classificação. Estes passos encontram-se ilustrados na FIG. 2.1, a qual contém um exemplo do resultado de cada um deles.

Primeiramente, aplica-se o mecanismo da dupla cor oponente proposto por [20], a fim de se obter uma imagem com destaque das feições lineares. Este método possui como origem uma das modelagens biológicas do sistema visual humano, relacionado à detecção de bordas em imagens coloridas. São utilizados os descritores de cor, apresentado em [21], baseados na existência de dois canais neurais, presentes no sistema visual humano, com a função de transmitir informação de cor no caminho entre a retina e o córtex [22].

Em seguida, aplica-se o método do crescimento de bacias (*watershed*), proposto por [23] sobre esta imagem de bordas. Este método de segmentação possui como uma de suas características a segmentação excessiva de imagens. Para minimizar este efeito, [3] propõe a geração de uma imagem em *superpixels*, cuja geometria é definida a partir da união de segmentos adjacentes que obedeçam um critério de similaridade, baseado na distância euclidiana no espaço de cores *CIE L*a*b**, definido em [24].

Este critério de similaridade é definido da seguinte forma: Os superpixels i e j serão unidos se e somente se i for o mais semelhante de j e vice-versa e, a distância entre eles deve ser menor que uma tolerância estipulada (tol). O superpixel mais semelhante a outro é o que possuir menor distância dentre todos os adjacentes. A distância utilizada no cálculo da tolerância e na definição do *superpixel* mais similar é definida no espaço das médias das componentes de cor, $\bar{L}, \bar{a}, \bar{b}$ e esta apresentada na Eq. 1.

$$dist = \sqrt{(\bar{L}_i - \bar{L}_j)^2 + (\bar{a}_i - \bar{a}_j)^2 + (\bar{b}_i - \bar{b}_j)^2} \quad (1)$$

Definida a geometria dos *superpixels*, são geradas 12 imagens para serem empregadas como descritores no SVM, de acordo com a lista a seguir:

- Média: medida de cor, definido pela média dos pixels através da Eq. 2. Onde: i corresponde ao i -ésimo *superpixel*, n_i é a quantidade de pixels em i e M_i é a média dos pixels de i , gerando, para cada componente, as imagens M_i^L, M_i^a, M_i^b :

$$dM_i = \frac{1}{n_i} \sum_{k \in i} x_k \quad (2)$$

- Desvio padrão: medida do contraste das intensidades presentes em um *superpixel*, definida através da Eq. 3. Onde: D_i corresponde ao desvio padrão dos pixels de i , gerando, para cada componente, as imagens D_i^l, D_i^a, D_i^b :

$$D_i = \sqrt{\frac{1}{n_i} \sum_{k \in i} (x_k - \bar{x}_i)^2} \quad (3)$$

- Suavidade: medida de ruído presente em um *superpixel*, calculada através do desvio padrão, de acordo com a Eq. 4. Onde S_i corresponde à suavidade do *superpixel* i , gerando, para cada componente, as imagens: S_i^l, S_i^a, S_i^b .

$$S_i = 1 - \frac{1}{1 + D_i^2} \quad (4)$$

- Entropia: medida de variabilidade, utilizada para descrever a intensidade de compactação de um *superpixel*, definida pela Eq. 5. Onde n_{x_k} corresponde à quantidade de pixels com intensidade x_k dentro do superpixel i e E_i representa a entropia do *superpixel* i , gerando, para cada componente, as imagens: E_i^l, E_i^a, E_i^b .

$$E_i = - \sum_{k \in i} \frac{n_{x_k}}{n_i} \cdot \log_2 \left(\frac{n_{x_k}}{n_i} \right) \quad (5)$$

A classificação é dividida em duas etapas: preparo e treinamento. No preparo, são selecionadas amostras para cada classe desejada. Neste trabalho deseja-se classificar cada simbologia em sua respectiva classe e para exemplificar a diferença entre este tipo de classificação e a utilizada por [3], pode-se observar a Fig. 2, a qual representa a classe manguezal [19]. A classificação adotada em [3] considera as linhas azuis, verdes e o fundo desta simbologia como pertencendo a três classes distintas. Contudo, neste trabalho, a simbologia como um todo será classificada em apenas uma classe.




Fig. 2 – Simbologia representante da classe manguezal. Fonte: [19]

- Para a fase de treinamento do classificador, faz-se necessário a escolha do *kernel* e dos parâmetros deste. A fim de selecioná-los, foi utilizada a concatenação dos métodos *k-fold cross-validation* e *grid-search* [25]. Além disto, por se tratar de uma classificação com múltiplas classes, foi escolhido o método um contra um [3, 25, 26, 27].

3. EXPERIMENTOS

O método para extração de simbologias foi aplicado em extratos de quatro cartas distintas retiradas do Banco de dados Geográficos do Exército (BDGEx), de acordo com a Tabela 1, todas com resolução de 600 dpi [7]. Todos os recortes foram selecionados em cartas com qualidade ruim, com muitas regiões apresentando cores misturadas e falsa-cor.

A fim de avaliar a qualidade da classificação, foi utilizada a medida F1, média harmônica entre a precisão e a sensibilidade [3], comparando-se o resultado obtido através do SCTMS com uma classificação manual. Esta métrica consiste em um estimador de acurácia, o qual apresenta valores pertencentes ao intervalo [0,1], sendo 0 e 1, classificações totalmente falhas e perfeitas de cada classe, respectivamente.

Tab 1: Materiais utilizados

Nome da carta	Escala	Dimensões
Limoeiro	1:100.000	676 x 747
Tapira	1:100.000	804 x 721
Brasília	1:250.000	896 x 711
Santos	1:250.000	750 x 506

Nas etapas do SCTMS, existem alguns parâmetros a serem definidos pelo usuário. De acordo com Liu et al. (2016) [3], a variação destes parâmetros possui influência insignificante no resultado da classificação. Desta forma, os mesmos foram definidos para os experimentos realizados neste trabalho como:

- Detecção de bordas: desvio padrão do filtro gaussiano ($\sigma = 1.0$); pesos dos canais oponentes ($w_1=0$ e $w_2=0,6$); número de orientações ($N_0=16$).
- Segmentação: tolerância para união ($tol=5$). Tal valor foi adotado com a finalidade de reduzir a quantidade de uniões indesejadas.
- Classificação: quantidade de divisões do *k-fold cross-validation* ($k = 5$); demais parâmetros definidos através de *grid-search*.

As classes para as amostras de treinamento foram definidas de acordo com a lista a seguir:

- Preto: grid (na cor preta), toponímias de localização, contornos de estrada, edificações, cercas, trilhas, ferrovias, barragens e ponto cotado confirmado;
- CN: linhas na cor sépia, representando: curvas de nível, cotas e pontos cotados;
- Hidro_1: linhas na cor azul, representando: trechos de drenagem, rios (temporários e permanentes), borda de massa d'água, toponímias de hidrografia, aquedutos e grid;
- Hidro_2: áreas na cor azul caracterizando massas d'água;
- Veg_1: vegetações que possuem simbologia simples na cor verde;
- Veg_2: vegetações com simbologia complexa composta por círculos verdes sobre cor de fundo (geralmente branca ou bege), de acordo com a Fig. 3;
- Veg_3: vegetações com simbologia complexa composta por regiões "rajadas" verdes sobre cor de fundo (geralmente branca ou bege), de acordo com a Fig. 3;
- Veg_4: vegetações com simbologia simples na cor de fundo (geralmente branca ou bege);
- Verm_1: parte vermelha das estradas com simbologia simples na cor vermelha escura;
- Verm_2: área urbana com simbologia complexa de pontos vermelhos sobre cor de fundo (geralmente branca ou bege) com simbologia simples vermelha clara, de acordo com a Fig. 3;

Alagada: representa a simbologia complexa composta por linhas azuis sobre cor de fundo (geralmente branca ou bege), de acordo com a Fig. 3.




Fig. 3 – Exemplos das classes definidas a partir de simbologias complexas

4. RESULTADOS

As medidas F1 encontradas pelas comparações entre a classificação manual e via SCTMS dos recortes apresentados na Tabela 1 estão dispostos na Tabela 2. As células sem valores significam que a classe não estava presente no recorte considerado.

Tab 2: Medidas F1 da comparação entre o resultado do SCTMS e o da classificação manual

Classe	Limoeiro	Tapira	Brasília	Santos	Média
Preto	0.7082	0.6571	0.5306	0.5675	0.6159
CN	0.5540	0.7025	0.4814	0.5008	0.5597
Hidro_1	0.7198	0.6428	0.6494	0.5697	0.6454
Hidro_2	0.9115	--	0.9598	0.9696	0.9470
Veg_1	0.9340	0.8312	0.5948	0.6787	0.7597
Veg_2	0.6758	0.9125	0.8606	0.6137	0.7656
Veg_3	0.9280	0.9207	0.8375	0.4997	0.7965
Veg_4	--	--	--	0.7277	0.7277
Verm_1	0.7173	0.7733	0.8030	0.4939	0.6969
Verm_2	0.7445	0.7742	0.9019	--	0.8069
Alagada	--	--	--	0.6271	0.6271

Analisando-se a Tabela 2, percebe-se que, em alguns casos, o resultado da classificação apresentou desempenho relativamente baixo, principalmente no recorte feito na carta de Santos, na qual duas classes apresentaram medida F1 inferior a 0.5. Contudo, comparando-se os resultados obtidos com os apresentados em [3], observa-se que o desempenho do método para reconhecimento de simbologias apresenta resultado semelhante ao da literatura. Considerando-se a média do resultado para cada classe, observa-se que o desempenho do SCTMS apresentou-se favorável à classificação de simbologias para as regiões testadas, apresentando maior dificuldade na identificação das curvas de nível.

5. CONCLUSÕES

Foi avaliado o desempenho do método SCTMS na classificação de simbologias em cartas topográficas matriciais. Os resultados mostram que o método apresenta-se deficiente para alguns casos. Contudo, apresenta-se coerente com a literatura correspondente à aplicação na extração de feições classificadas por cores. Sendo assim, são necessárias avaliações mais profundas nesta nova aplicação, visto que, ao tentar classificar as simbologias, os parâmetros que a priori eram pouco influentes no método podem tomar novas proporções.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] MIAO, Q. et al. Linear Feature Separation From Topographic Maps Using Energy Density and the Shear Transform. *IEEE Transactions on Image Processing*, v. 22, n. 4, p. 1548 - 1558, Abril 2013.
- [2] LIU, T. et al. Color topographical map segmentation Algorithm based on linear element features. *Multimedia Tools and Applications*, v. 75, n. 10, p. 5417-5438, 2016. ISSN 1573-7721.
- [3] LIU, T. et al. SCTMS: Superpixel based color topographic map segmentation method. *Journal of Visual Communication and Image Representation*, v. 35, p. 78-90, Fevereiro 2016.
- [4] CHIANG, Y.-Y.; LEYK, S.; KNOBLOCK, C. A. A survey of digital map processing techniques. *ACM Computing Surveys (CSUR)*, v. 47, n. 1, Julho 2014. ISSN 0360-0300.
- [5] USGS. historical Topographic Maps | topoview, 2016. Disponível em: <https://ngmdb.usgs.gov/maps/topoview>. Acesso em: Dez 2016.
- [6] KHOTANZAD, A.; ZINK, E. Contour line and geographic feature extraction from USGS color topographical paper maps. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 25, n. 1, p. 18 - 31, Janeiro 2003.
- [7] BDGEX. Banco de Dados Geográficos do Exército Brasileiro, 2016. Disponível em: <http://www.geoportal.eb.mil.br/mediador>. Acesso em: Dezembro 2016.
- [8] IBGE. Instituto Brasileiro de Geografia e Estatística, 2016. Disponível em: <http://www.ibge.gov.br/home/geociencias/default_prod.shtm#GEOG>. Acesso em: Dezembro 2016.
- [9] FREEMAN, H.; PIERONI, G. G. Eds. *Map Data Processing*. [S.l.]: Academic Press, Incorporated, 1981.
- [10] SAHOO, P. K.; SOLTANI, S.; WONG, A. K. C. A survey of thresholding techniques. *Computer Vision, Graphics, and Image Processing*, v. 41, n. 2, p. 233-260, Fevereiro 1988.
- [11] PAL, N. R.; PAL, S. K. A review on image segmentation techniques. *Pattern Recognition*, v. 26, n. 9, p. 1277-1294, Setembro 1993.
- [12] CHENG, H. D. et al. Fuzzy homogeneity approach to multilevel thresholding. *IEEE Transactions on Image Processing*, v. 7, n. 7, p. 1084 - 1086, Julho 1998. ISSN 1941-0042.
- [13] CHENG, H. D. et al. Color image segmentation: Advances and prospects. *Pattern Recognition, Logan*, v. 34, n. 12, p. 2259-2281, Dezembro 2001.
- [14] CHENG, H. D.; JIANG, X. H.; WANG, J. Color image segmentation based on homogram thresholding and region merging. *Pattern Recognition, Logan*, v. 35, n. 2, p. 373-393, Fevereiro 2002.
- [15] CAI, W.; CHEN, S.; ZHANG, D. Fast and robust fuzzy c-means clustering algorithms incorporating local information for image segmentation. *Pattern Recognition, Nanjing*, v. 40, n. 3, p. 825-838, Julho 2007. ISSN 0031-3203.
- [16] KRINIDIS, S.; CHATZIS, V. A robust fuzzy local information C-means clustering algorithm. *IEEE Transactions on Image Processing*, v. 19, n. 5, p. 1328 - 1337, Janeiro 2010.
- [17] LIU, T. et al. A contour-line color layer separation algorithm based on fuzzy clustering and region growing. *Computers & Geosciences*, v. 88, p. 41-53, março 2016.
- [18] MELLO, C. A. B.; COSTA, D. C.; SANTOS, T. J. D. Automatic image segmentation of old topographic maps and floor plans. *IEEE International Conference on Systems, Man, and Cybernetics (SMC)*. Seoul, South Korea : IEEE. 2012. p. 132-137.
- [19] DSG. Manual Técnico de Convenções Cartográficas T-34-700, 1ª e 2ª Partes. Diretoria do Serviço Geográfico. Brasília. 2002
- [20] YANG, K. et al. Efficient color boundary detection with color-opponent mechanisms. *Computer Vision and Pattern Recognition (CVPR)*. Portland, Estados Unidos: IEEE. 2013. p. 2810-2817.
- [21] ZHANG, J.; BARHOMI, Y.; SERRE, T. A New Biologically Inspired Color Image Descriptor. *European Conference on Computer Vision - ECCV*. Berlin, Heidelberg: Springer. 2012. p. 312-324.
- [22] KAISER, P. K.; BOYNTON, R. M.; SWANSON, W. H. *Human Color Vision*. Washington DC: Optical Society of America, v. 287, 1996.
- [23] VINCENT, L.; SOILLE, P. Watersheds in digital spaces: an efficient algorithm based on immersion simulations. *IEEE transaction on pattern analysis & machine intelligence*, v. 13, n. 6, p. 583-598, Junho 1991.
- [24] ICC. ICC Specifications, 2016. Disponível em: <http://color.org/icc_specs2.xalter>. Acesso em: Agosto 2017.
- [25] NEGRI, R. G. Máquina de Vetores de Suporte Adaptativa ao Contexto: formalização e aplicações em Sensoriamento Remoto, Tese (Doutorado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos. 2013. 166 p.
- [26] BOW, S. T. *Pattern Recognition and Image Processing*. 2nd. ed. New York, NY: Dekker, Macel, 2002.
- [27] THEODORIDIS, S.; KOUTROUMBAS, K. *Pattern Recognition*. 4th. ed. San Diego: Academic Press, 2009.