

Aprendizado Semi-Supervisionado aplicado a Segmentação de Imagens

Jefferson Antonio Ribeiro Passerini, Fabricio Aparecido Breve
Departamento de Estatística, Matemática Aplicada e Computação
Inst. de Geociências e Ciências Exatas, IGCE
Rio Claro, Brasil
jefferson.passerini@gmail.com, fabricio@rc.unesp.br

Resumo – A segmentação de imagens é um dos processos mais difíceis dentro do processamento de imagens, resultando em um elevado grau de dependência de especialistas humanos. A aplicação de processos de aprendizado de máquina semi-supervisionado como o modelo de Competição e Cooperação de Partículas permitem aumentar o grau de automação deste processo. Deste modo podemos concluir que a continuação dos estudos nesta área é relevante para melhoria dos processos de segmentação de imagens digitais.

Área: Inteligência Computacional

I. INTRODUÇÃO

A segmentação de imagens é o processo de identificar e separar estruturas e objetos relevantes em uma imagem, para a sua posterior análise e extração de informações [1].

A segmentação não é considerada uma atividade trivial, sendo um dos processos mais difíceis dentro do processamento de imagens [1].

A complexidade deste processo é determinada pela quantidade de fatores envolvidos. Pode-se observar fatores de baixo nível como as informações incluídas na própria imagem como sistema de cores, textura, brilho, entre outros. Existem também fatores de alto nível como a abstração da informação existente na imagem o que é difícil de determinar através de um algoritmo computacional [2].

Deste modo a criação de algoritmos de segmentação de imagens se demonstra uma tarefa árdua, pois dependem do domínio específico que pertence a imagem ou a um grupo destas, não sendo possível a aplicação de um mesmo algoritmo em diversas imagens de diferentes domínios. Assim um algoritmo que consiga realizar a segmentação de imagens totalmente automatizada ainda é um desafio.

Outra característica em segmentação de imagens é abundância de dados não-rotulados disponíveis em relação aos dados rotulados que são poucos e onerosos para serem gerados, devido à dependência de um especialista humano.

Deste modo a aplicação de algoritmos de segmentação que se utilizam de aprendizado semi-supervisionado mostra-se interessante. Neste modelo de aprendizado o especialista humano rotula apenas uma pequena quantidade de informações e a partir destas o algoritmo classifica as demais [3].

As abordagens de aprendizado semi-supervisionado utilizam-se dos dados rotulados e não rotulados em seu processo de treinamento. No processo de segmentação de imagens tais informações encontram-se disponíveis nos pixels

das imagens onde o algoritmo determina a relação entre os pixels rotulados e não rotulados através de sua similaridade [3].

Diante do exposto, neste trabalho foi estudado modelos de aprendizado semi-supervisionado baseado em redes complexas e desenvolvido o algoritmo de Competição e Cooperação de Partículas, conforme trabalhos publicados sobre este modelo, como referência para proposição de melhorias ao modelo.

II. CONCEITOS E TÉCNICAS

As redes complexas envolvem dados heterogêneos e não triviais, representados em uma estrutura de grafo. Os vértices do grafo representam as informações e as arestas representam as relações. Este é um modelo que possibilita representar de forma dinâmica as relações existentes na natureza, modificando a rede a cada alteração de estado ou ainda inclusão ou retirada de um elemento do grafo [4].

O modelo de Competição e Cooperação de Partículas [5] é um modelo de aprendizado semi-supervisionado baseado em grafos que é diferente de outros algoritmos que propagam rótulos de maneira global. Neste modelo a abordagem é local.

No modelo as partículas de cada classe competem e cooperam entre si para estabelecer um domínio sob os vértices não rotulados [5] [6].

III. METODOLOGIA DE DESENVOLVIMENTO

O modelo estudado é aplicado em duas fases, onde a primeira é caracterizada pela preparação da rede e a segunda é representada pelo laço principal do algoritmo onde ocorre a ação das partículas sobre a rede.

Na segmentação de imagens a preparação da rede é baseada na imagem a ser segmentada, onde os vértices representam os pixels e as arestas as relações de similaridade, determinadas pelas características de cada pixel [6] [7].

No modelo são extraídos de cada pixel as características: o sistema de cores RGB (vermelho, verde e azul), o brilho, a saturação e a matiz que compõem o sistema HSV (*Hue, Saturation, Value*), e métricas de vizinhança de cada um dos elementos anteriores como Média aritmética dos valores dos 8 vizinhos próximos (pixel) na imagem, assim como o seu desvio padrão. É considerada também a posição física de cada pixel na imagem, através do valor da posição X e Y de cada pixel, compondo um total de 20 características [6], posteriormente foi adicionado ao modelo [7] os componentes ExR, ExG e ExB.

As similaridades representadas pelas arestas são determinadas pela Distância Euclidiana do conjunto de características extraídas de cada pixel.

Um grafo não direcionado e sem pesos, $G = (V, E)$, é gerado onde o conjunto de vértices, $V = (v_1, v_2, \dots, v_{1n})$, representa os pixels da imagem, e o conjunto de arestas determinado pelas características extraídas dos pixels ligam os k-vizinhos próximos utilizando a Distância Euclidiana, onde, $E = (v_i, v_j)$ [6].

As partículas correspondem aos pixels que foram rotulados pelo especialista humano, e caminham pelo grafo cooperando com outras partículas de mesma classe e competindo por novos vértices com partículas de classes diferentes [5] [7] [8].

Na segunda fase de execução do algoritmo as partículas caminham pelo grafo ajustando os pixels (vértices) não rotulados. Os movimentos das partículas podem assumir características de movimento guloso ou aleatório.

Assim cada grupo de partículas tentam impedir que partículas de outra classe invadam seu território e ao mesmo tempo espalham seu domínio por vértices não dominados e tentam dominar vértices dominados por outras classes [5] [7] [8].

O algoritmo foi aplicado a uma imagem gabarito para avaliação de seu desempenho, conforme pode-se visualizar na Fig.1.

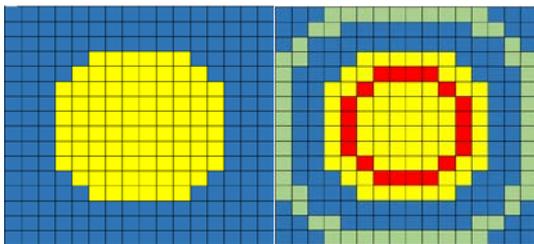


Fig.1 – Imagem Gabarito

Na Fig.1 é possível observar a imagem original e a imagem com pixels rotulados pelo especialista humano que determinará as partículas para o modelo.

IV. RESULTADOS PRELIMINARES

Durante a execução do modelo verificou-se a necessidade de ajustes manuais referente aos pesos que cada uma das 23 características extraídas assume durante o cálculo da Distância Euclidiana.

Dentre o conjunto de características existem atributos que são uteis na segmentação de uma determinada imagem e de outra não assume esse papel, sendo o inverso também verdadeiro.

Algoritmos de aprendizado de máquina costumam não ter bom desempenho com muitos atributos, problema conhecido como “mal da dimensionalidade”.

Fazendo-se necessário ajustes nos pesos ou realizar uma melhor seleção dos atributos que irão compor o cálculo da Distância Euclidiana [7].

Outra abordagem a ser estudada para o modelo é melhorar a qualidade da rede complexa que é criada na primeira fase do algoritmo, permitindo uma melhor separação entre os vértices de classes diferentes [9].

V. CONSIDERAÇÕES FINAIS

Os resultados deste estudo aqui apresentados permitem concluir que a continuação dos estudos da aplicação de algoritmos de aprendizado de máquina, mais especificamente aprendizado semi-supervisionado como o apresentado neste trabalho, são pertinentes para melhoria do grau de automação no processo de segmentação de imagens.

REFERÊNCIAS

- [1] R. Gonzalez e R. Woods, *Processamento digital de Imagens*, 3ª ed., São Paulo: Pearson Prentice Hall, 2010.
- [2] J. Shi e J. Malik, “Normalized cuts and image segmentation,” *IEEE Trans. Pattern Anal. Mach. Intell. IEEE Computer Society Washinton, DC, USA*, v.22, n.8., pp. p.888-905, Ago 2000.
- [3] O. Chapelle, B. Schölkopf e A. Zien, *Semi-Supervised Learning*, London: MIT Press, 2006.
- [4] T. C. Silva e L. Zhao, *Machine Learning in Complex Networks*, Springer International Publishing, 2016.
- [5] F. Breve, L. Zho, Q. M., P. W. e L. J., “Particle competition and cooperation in networks for semi-supervised learning,” *Knowledge and Data Engineering. IEEE Transactions on*, vol 24, n.9, pp. 1686-1698, Set 2012.
- [6] F. Breve, M. Quile e L. Zhao, “Interactive image segmentation of non-contiguous classes using particle competition and cooperation,” *In:15th International Conference on Computational Science and Its Applications. ICCSA.*, 2015.
- [7] F. Breve, “Auto feature weight for interactive image segmentation using particle competition and cooperation.,” *In: Proceedings - XI Workshop de Visão Computacional, WVC2015*, pp. p.164-169, 2015.
- [8] F. A. Breve, “Active semi-supervised learning using particle competition and cooperation in networks,” *Neural Networks (IJCNN). The 2012 International Joint Conference*, 2013.
- [9] F. Breve, “Building Networks for Image Segmentation using Particle Competition and Cooperation,” em *Computational Science and Its Applications – ICCSA 2017: 17th International Conference*, Trieste, Italy, 2017.