

Aprendizado de máquina aplicado à segmentação interativa de imagens

Bárbara Ribeiro da Silva,
Fabrício Aparecido Breve
UNESP – Universidade Estadual Paulista “Júlio de Mesquita Filho”
Rio Claro, Brasil
barbararibs@gmail.com, fabricao@rc.unesp.br

Resumo—Aplicação de técnicas de aprendizado semi-supervisionado para a realização de tarefas de segmentação interativa de imagens, estendendo o modelo de competição e cooperação entre partículas, para realizar classificação semi-supervisionada dos pixels das imagens.

Área: “Matemática e Inteligência Computacional”

I. INTRODUÇÃO

A tarefa de segmentação exige uma análise detalhada da imagem, identificando oscilações em cores, intensidade e brilho. Para classificar bem uma imagem é necessário entender as possíveis divisões nela existentes. Para tanto existe o processo de segmentação, que consiste na repartição da imagem em múltiplos segmentos, regiões e objetos.

Aprendizado de máquina é a disciplina na qual se desenvolvem algoritmos que melhoram automaticamente com a experiência, imitando o comportamento de aprendizado humano. Nesse projeto serão utilizadas técnicas de aprendizado semi-supervisionado, uma das categorias de aprendizados de máquinas, que combina dados rotulados e não rotulados a fim de obter uma melhor classificação. As informações de rótulos de alguns pixels da imagem serão fornecidas interativamente pelo usuário, e o algoritmo deverá ser capaz de propagar os rótulos para os demais pixels da imagem.

Para cada figura inserida no programa, o usuário interage realizando pequenas marcações nas partes cujo rótulo é conhecido.

O modelo de competição e cooperação entre partículas [1] é uma abordagem de aprendizado semi-supervisionado bastante promissora para segmentação de imagens. Entretanto é necessário adaptá-la para a tarefa específica de classificar pixels de imagens, visto que esta abordagem foi desenvolvida originalmente para classificação de dados em geral, baseados em vetores de características.

No algoritmo de competição e cooperação entre partículas original, os dados vetoriais são transformados em uma rede complexa, com base na distância entre os pares de amostras. No caso das imagens, as redes geradas serão redes regulares, onde os dados (pixels) estão distribuídos em grades e conectados somente aos seus vizinhos imediatos na imagem, caso tenham características semelhantes.

Na segmentação interativa de imagens é desejável que o especialista humano possa interagir, classificando manualmente novos pixels caso tenha percebido algum segmento sendo classificado incorretamente. No caso do

aprendizado semi-supervisionado, os algoritmos são capazes de classificar grandes bases de dados onde apenas um pequeno subconjunto de dados estão rotulados.

O objetivo deste projeto de pesquisa é estender o modelo de competição e cooperação entre partículas para tratar o problema de segmentação de imagens de maneira interativa. Deste modo, partículas serão criadas para pixels da imagem rotulados pelo usuário e, através dos mecanismos de competição e cooperação, tais rótulos poderão se espalhar para os demais pixels.

II. METODOLOGIA DE DESENVOLVIMENTO

Uma primeira abordagem de competição de partículas foi desenvolvida para detectar comunidades em redes [2]. Neste modelo, partículas caminham em uma rede e competem umas com as outras de forma que cada uma tenta possuir a maior quantidade possível de nós. Ao mesmo tempo, cada partícula evita que outras partículas invadam seu território. Finalmente, cada partícula fica confinada dentro de uma comunidade da rede.

Com base na abordagem de competição de partículas, [1] e [3] desenvolveram um modelo de aprendizado semi-supervisionado baseado em grafos. Dentre várias melhorias, o modelo novo apresenta mecanismos de competição e cooperação combinados em um esquema único. Partículas representando uma mesma classe caminham em uma rede de maneira cooperativa para propagar seu rótulo. Ao mesmo tempo, partículas de diferentes classes competem entre si para determinar a borda das classes. Este algoritmo é capaz de classificar dados linearmente inseparáveis, em um tempo de execução menor que outros algoritmos tradicionais, devido a menor complexidade computacional.

Nos modelos tradicionais de aprendizado semi-supervisionado baseado em grafos, a informação de rótulos é propagada de todos os nós para todos os nós em cada passo do algoritmo, levando em consideração os pesos das arestas. No modelo de partículas a propagação de rótulos ocorre de forma local, ou seja, em cada passo do algoritmo cada partícula escolhe um vizinho para propagar seu rótulo. Deste modo, cada partícula visita apenas nós que potencialmente pertençam ao seu time, não visitando nós que já estejam dominados por outra partícula.

Cada pixel da imagem é convertido em um nó do grafo. A vizinhança é definida da seguinte forma. Cada nó é conectado aos 8 nós que correspondem aos 8 pixels mais próximos na imagem. Porém, quando dois nós vizinhos correspondem a

pixels com características muito divergentes, de acordo com um dado limiar, a conexão é eliminada. Em seguida são inseridas partículas, de acordo com a posição do pixel a qual ela se refere, utilizando a primeira figura de entrada, como base para saber a cor original do pixel.

As partículas escolhem os nós a serem visitados com base em uma de duas regras. A cada iteração a partícula escolhe uma das regras aleatoriamente com probabilidades pré-definidas. As duas regras são descritas a seguir:

- Regra aleatória: a partícula escolhe aleatoriamente, com iguais probabilidades, qualquer um dos nós vizinhos do nó em que ela se encontra. A regra aleatória não se preocupa com os níveis de domínio ou distância do nó-casa com os possíveis nós a serem visitados, sendo útil para exploração e aquisição de novos nós.
- Regra gulosa: a partícula escolhe aleatoriamente qualquer um dos nós vizinhos do nó em que ela se encontra, com probabilidades calculadas de forma diretamente proporcionais ao nível de dominância do time dessa partícula em cada nó, e inversamente proporcionais à distância de cada nó ao nó casa dessa partícula.

Dessa forma, ao escolher a regra gulosa, as partículas tendem a ficarem em territórios já dominados e preferem nós próximos de sua origem (em sua vizinhança), ou seja, elas assumem um comportamento mais conservador e defensivo. Por outro lado, ao escolher a regra aleatória as partículas ignoram níveis de dominância e distâncias e tem maior probabilidade de escolher nós que não dominam e nós distantes de sua origem, assumindo assim um comportamento de exploração maior.

III. RESULTADOS PRELIMINARES

No momento o projeto encontra-se na etapa de construção da rede. Para ilustrar esta etapa, a imagem mostrada na Figura 1 foi utilizada como entrada, após ser reduzida para uma escala de 10x7 pixels.



Fig. 1. Exemplo de entrada do programa.

Utilizando as demarcações mostradas na Figura 2 foram definidos os pixels rotulados pelo usuário, que devem dar origem às respectivas partículas.



Fig. 2. Exemplo de entrada de partículas no programa.

A Figura 3 representa o grafo montado com base nas distâncias entre os valores dos pixels, utilizando os 8 vizinhos mais próximos, extraídos da Figura 1, e a inserção de partículas, as quais estão representadas no grafo pelos nós marcados com as respectivas cores de seus pixels. Cada partícula corresponde a um pixel rotulado pelo usuário (representados em branco na Figura 2). Nós não rotulados (sem classificação prévia) estão representados na cor azul.




Fig. 3. Grafo.

IV. CONSIDERAÇÕES FINAIS

O próximo passo neste projeto será criar um layout para que o usuário possa inserir interativamente marcações na figura e então criar as partículas em tempo de execução.

Posteriormente será desenvolvida a etapa de classificação, onde as partículas caminharão pelo grafo, com a finalidade de separar as partes ou objetos da imagem.

Ao final destes passos o algoritmo será adaptado para figuras mais complexas, mais ricas em detalhes e cores.

REFERÊNCIAS

- [1] Breve, F., L. Zhao, M. Quiles, W. Pedrycz, and J. Liu (2012). Particle competition and cooperation in networks for semi-supervised learning. Knowledge and Data Engineering, IEEE Transactions on 24(9), 1686–1698.
- [2] Quiles, M. G., L. Zhao, R. L. Alonso, and R. A. F. Romero (2008). Particle competition for complex network community detection. Chaos 18(3), 033107.
- [3] Breve, F. A., L. Zhao, and M. G. Quiles (2009). Particle competition in complex networks for semisupervised classification. In J. Zhou (Ed.), Complex (1), Volume 4 of Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering, pp. 163–174. Springer.

III Workshop do Programa de Pós-Graduação em Ciência da Computação: “Implantação do Doutorado no PPGCC-UNESP: reflexões, perspectivas e ações”, Unesp, Rio Claro, 2 e 3 de maio de 2013.

Agradecimentos à FAPESP e ao CNPq.