

Segmentação de Núcleos Celulares em Exames de Citologia com Papanicolau

André Victória Matias, Luiz Antonio Buschetto Macarini

Objetivo

O objetivo do trabalho é verificar a viabilidade de utilização de métodos de visão computacional clássica e *deep learning* para segmentação de núcleos de células em imagens de microscopia usando coloração de Papanicolau. Essa segmentação será usada como base para, posteriormente, serem detectadas anomalias celulares que indiquem a presença um câncer. A longo prazo, tem-se como objetivo desenvolver uma ferramenta de auxílio ao diagnóstico precoce de câncer de maneira a facilitar a análise desse tipo de exame pelo especialista.






Imagem original com as marcações feitas por especialistas

Visão Computacional Clássica

Para segmentação utilizando visão computacional clássica calculou-se o histograma da imagem e partir deste, fez-se o cálculo de desvio padrão. Baseado nisto, escolhe-se entre cinco faixas de valores R, G e B para realizar a segmentação por cores. Após este processo, isola-se cada grupo de *pixels* e filtra-se por área e circularidade. Estas detecções foram utilizadas como sementes para a aplicação do *Active Contours without Edges* (ACWE) e *Geodesic Active Contours* (GAC). Com o primeiro método, foi obtido um valor de **Intersection Over Union (IoU) de 2,7%** e **99,2% de pixel accuracy**. Já com o GAC, obteve-se um **IoU de 2,9%** e uma **acurácia de 99,8%**.



Resultado da aplicação do ACWE




Resultado da aplicação do GAC

Deep Learning

Para segmentação através de *deep learning* foi utilizada uma rede *Unet* com as arquiteturas ResNet34 e ResNet50 como *backbone*. O treinamento foi realizado de maneira progressiva, iniciando com as imagens reduzidas para 300x400 *pixels*, aumentando para 600x800 *pixels* e concluindo com o tamanho original, 1200x1600 *pixels*.

O modelo de rede com melhor desempenho para 1200x1600 *pixels* usou ResNet34 com *weight decay* 10^{-2} , obtendo **47,3% de IoU e 99,5% de pixel accuracy** no conjunto de dados de teste. Por limitações técnicas, só foi possível treinar a ResNet50 com imagens até 600x800 *pixels*, onde obteve-se **43,7% de IoU e 99,5% de pixel accuracy**, enquanto com a ResNet34 obteve-se **45,6% de IoU e 99,5% de pixel accuracy** com imagens de mesma dimensão.



Resultado obtido utilizando segmentação semântica - ResNet34 1200x1600

Conclusões

A partir dos experimentos executados, pode-se concluir que a utilização de redes neurais convolucionais trouxe um resultado significativamente melhor (em relação ao IoU) quando comparada com a abordagem clássica. Os dois métodos de contornos ativos trouxeram resultados similares entre si, mas apresentaram um desempenho inferior quando comparados com as redes neurais. A utilização de um modelo de rede neural mais complexa (ResNet50) não trouxe melhora aos resultados, já que a ResNet34 apresentou o melhor desempenho. Além disso, a acurácia foi alta para todos os métodos, mostrando que, isoladamente, não é uma medida adequada a esta aplicação. O valor elevado em todos os casos ocorre porque há um desbalanceamento entre as classes.