

JORNADA PCI

APRESENTAÇÃO DE PROJETO – 2021/2022

BOLSISTA: Rayan Tadeu Barbosa

SUPERVISOR: Marcelo Portes de Albuquerque

MODALIDADE: PCI-DD

Inteligência Artificial: Segmentação não supervisionada aplicada à análise de imagens de lâminas de arenito

Resumo: Neste trabalho é apresentado um modelo híbrido não supervisionado, para a caracterização granulométrica a partir de imagens de lâminas de arenito. O modelo apresentado faz uso de um processo iterativo de segmentação de grãos baseada em Redes Neurais Convolucionais (RNC) não supervisionada e técnicas de processamento de imagens digitais (PDI). Inicialmente a imagem da lâmina de arenito foi dividida em sub-imagens equalizadas e um filtro passa-baixo foi utilizado para atenuar ruídos oriundos do processo de aquisição da imagem. Posteriormente, uma sub-imagem foi segmentada utilizando a RNC proposta. Técnicas de transferência de aprendizado foi aplicada para garantir que as mesmas informações fossem compartilhadas em todas as sub-imagens definidas. Por fim, a transformada de watershed foi utilizada restaurando o formato correto do grão permitindo assim a realização dos cálculos granulométricos. Os resultados encontrados demonstraram que a metodologia apresentada conseguiu reproduzir valores próximos dos encontrados em experimentos de laboratório realizados com modelos da peneira.

Metodologia: A metodologia apresentada faz uso de uma RNC não supervisionada proposta por Kanazaki, 2018. Uma das principais vantagens deste modelo RNC está relacionada ao fato de a mesma não requerer treinamento supervisionado ou pesos pré treinados. Ou seja, os rótulos ou classificação pixel-wise da imagem é realizada através de uma combinação de RNC e PDI.

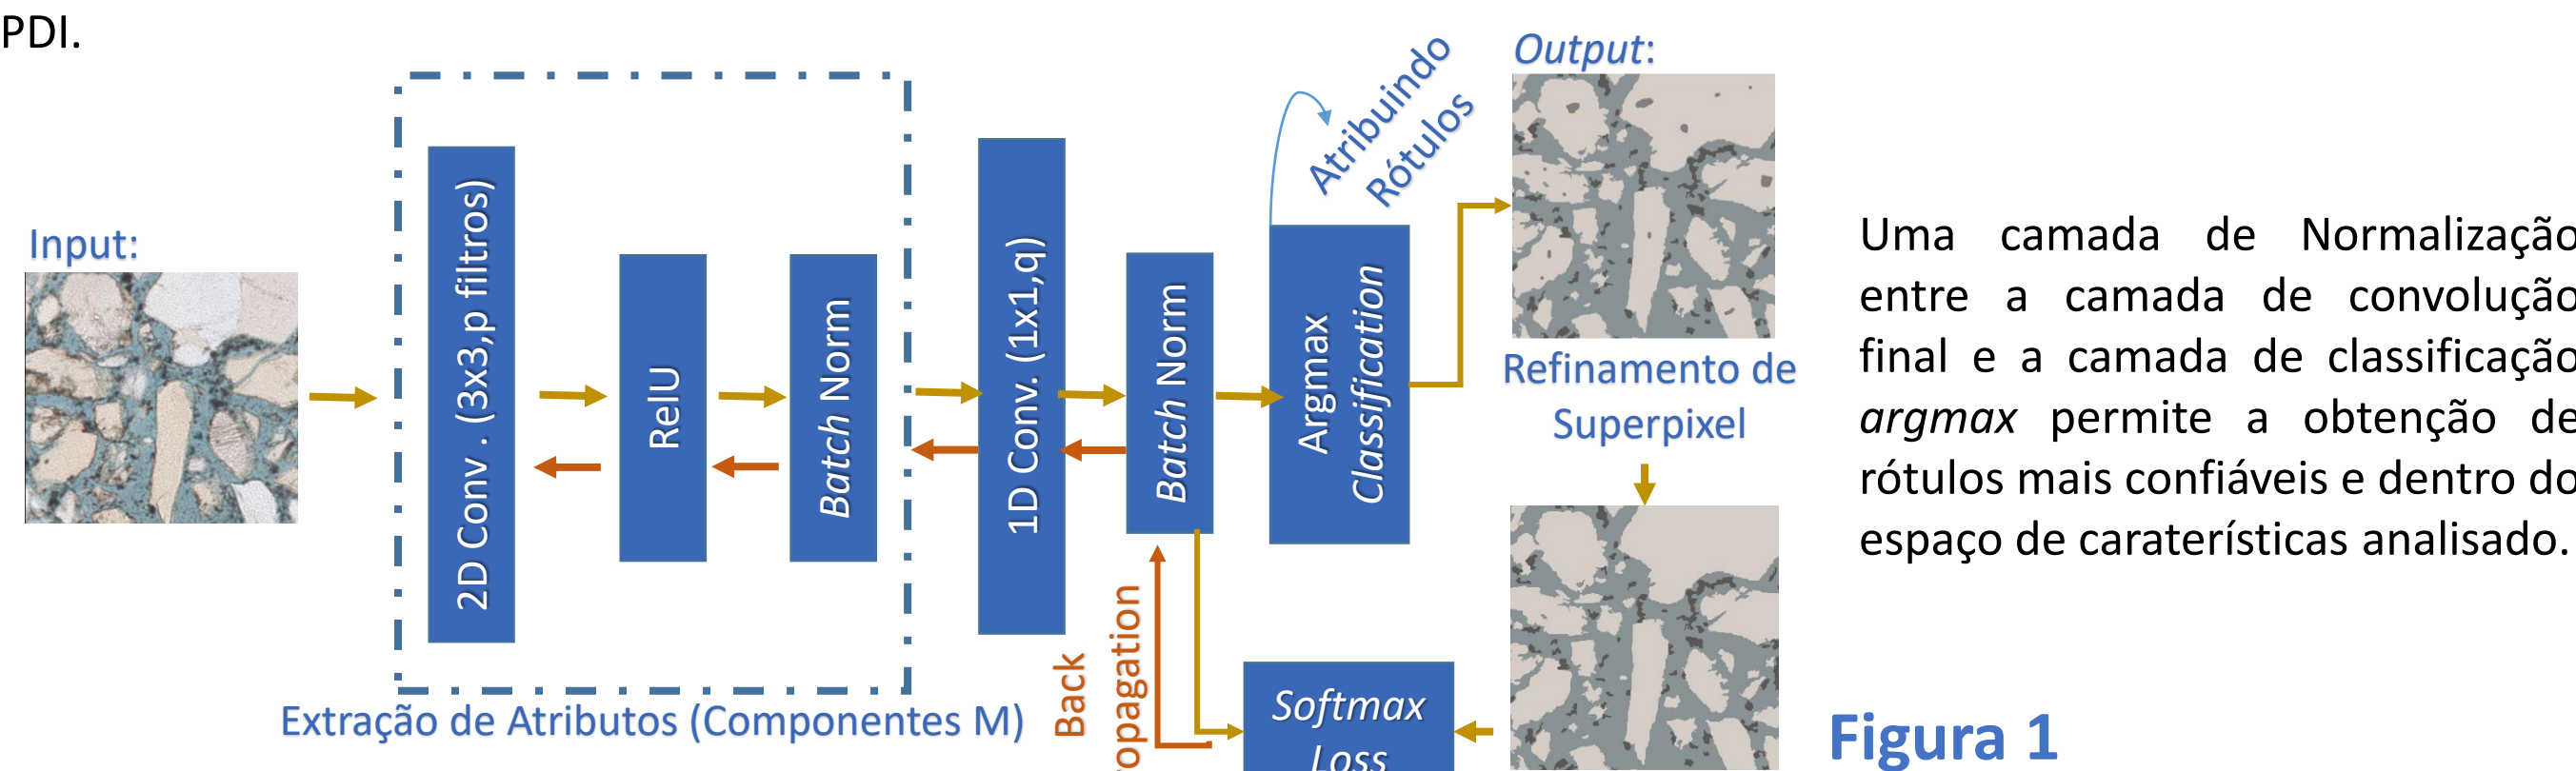


Figura 1

Devido ao tamanho, complexidade e ruído da lâmina utilizada, foi necessário uma etapa de pré-processamento. Dois passos foram utilizados para esta tarefa: (1) adequação das dimensões da imagem a fim de conseguir processá-la na rede RNC conforme Figura 2 apresentada e (2) atenuação de ruídos, com filtro mediana suave com kernel 3x3.




Figura 2

A RNC utilizada é composta de 2 camadas convolucionais e a quantidade de filtros destas camadas variou de 4 a 50 filtros. No processo de atribuição de rótulos dos pixels segmentados foram testados dois algoritmos o Simple Iterative Clustering (SLIC) e o algoritmo baseado em gráficos proposto por (Felzenszwalb and Huttenlocher, 2014). Sendo este último escolhido na geração dos resultados finais por apresentar modelos de melhor acurácia. Ademais, foi aplicada uma técnica de *Transfer Learning*, treinando inicialmente a rede com um dos cortes da imagem e introduzindo seus pesos no processamento dos demais cortes. Esta abordagem otimiza a segmentação dos demais cortes, levando a um resultado de segmentação mais homogêneo.

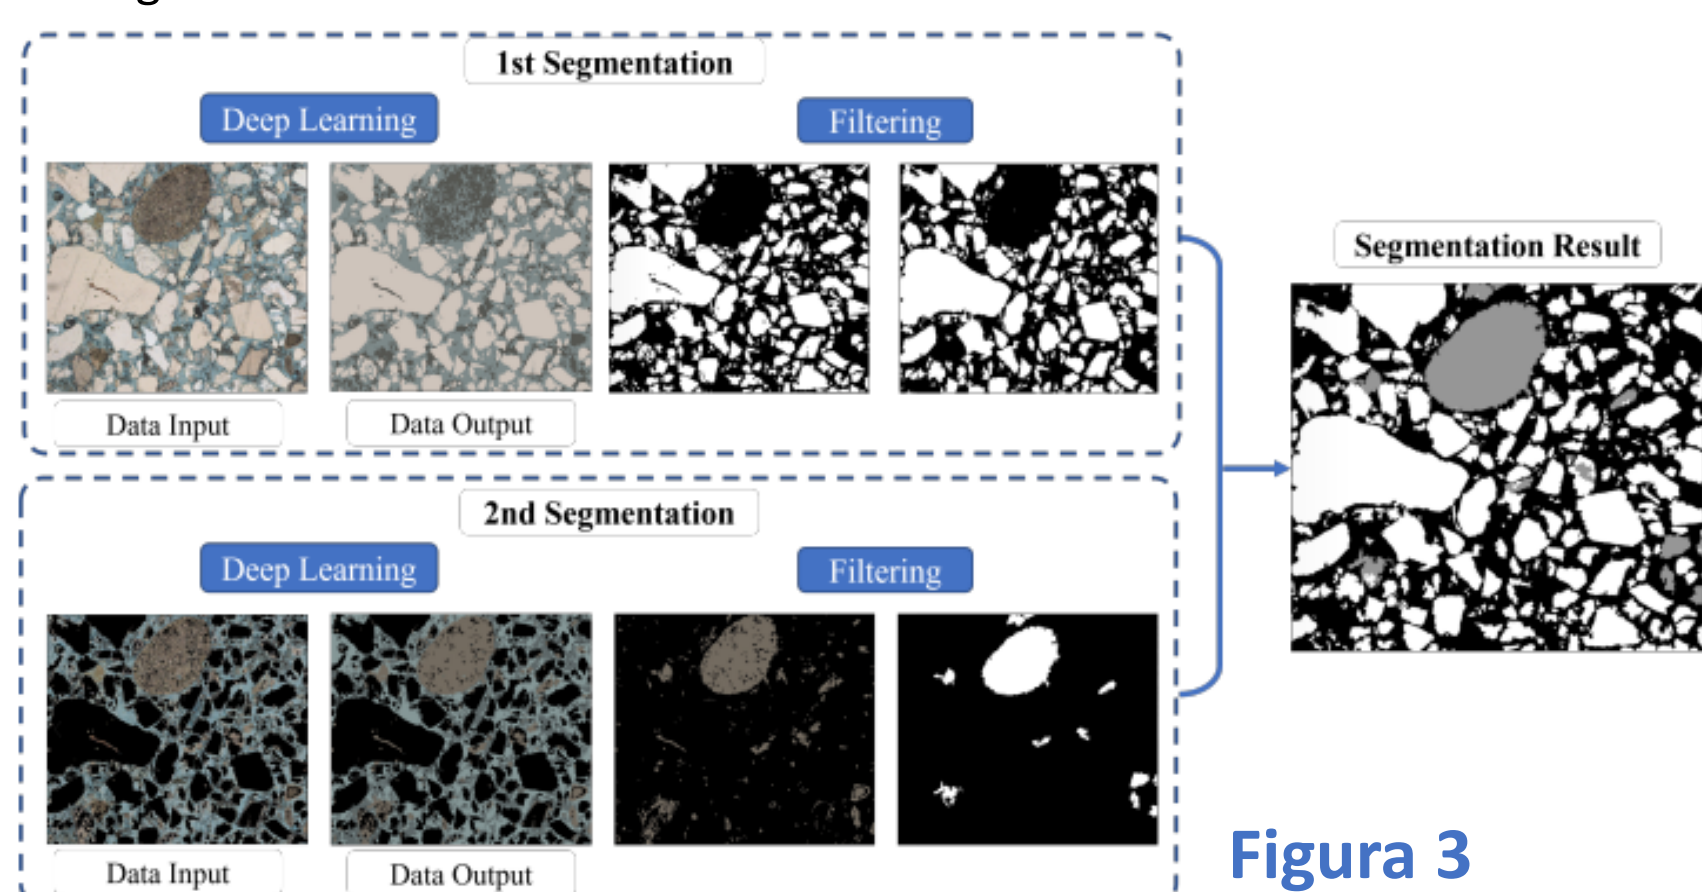


Figura 3

Um processo iterativo visando corrigir os erros causados devido a qualidade da imagem e as diferentes texturas dos grãos presentes na imagem foi implementado. Após o Treinamento da rede, a máscara do resultado da segmentação foi utilizada e através da sua superposição com o corte de imagem original, foi possível remover cada grão de cor clara, que a RNC conseguiu segmentar corretamente na sua primeira operação a partir da imagem original

Em seguida, a RNC foi treinada novamente, porém desta vez utilizando apenas os grãos não detectados na primeira operação. Após o segundo processo de segmentação, as imagens de segmentação geradas em ambas as operações foram devidamente filtradas, para produzir segmentação final da imagem cortada.

A qualidade da segmentação produzida pela rede foi avaliada visualmente e através do coeficiente de similaridade Jaccard, ou Interseção sobre a união (IoU). Para a aferir a IoU entre a máscara real do corte produzida manualmente e a sua correspondente segmentação, foram selecionados os cortes pertencentes a diagonal principal da grid de recortes 6x6 mostrado na figura 4. Através da métrica utilizada, foi obtido um valor médio de 0.75.

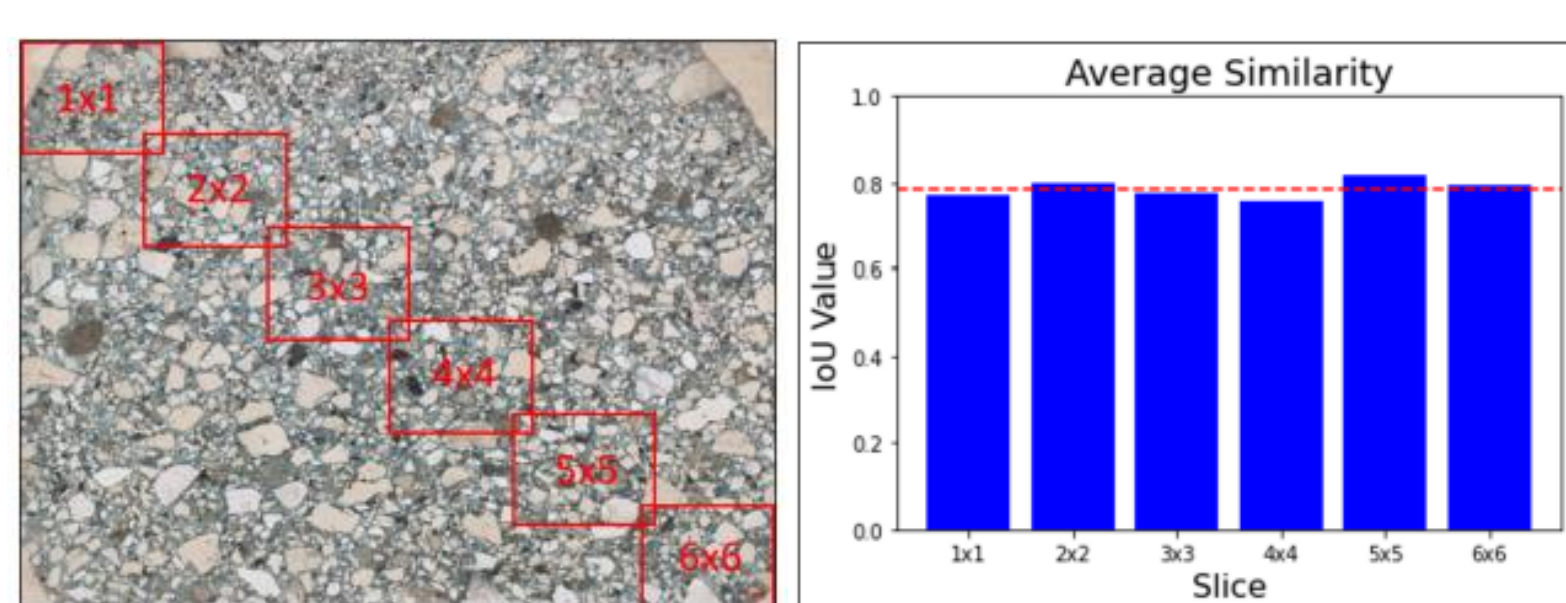



Figura 4



Visando a identificação dos limites entre os grãos identificados na segmentação, foram realizadas correções morfológicas e a transformada Watershed. O primeiro criando marcadores de confiança buscando limitar a sobre-segmentação da ferramenta e um segundo método, original, onde são aplicados duas vezes a ferramenta Watershed, variando apenas o valor da Matriz de Passagem.

Figura 5

Abaixo um esquema mostrando o passo a passo do método proposto para a obtenção dos limites dos grãos segmentado:

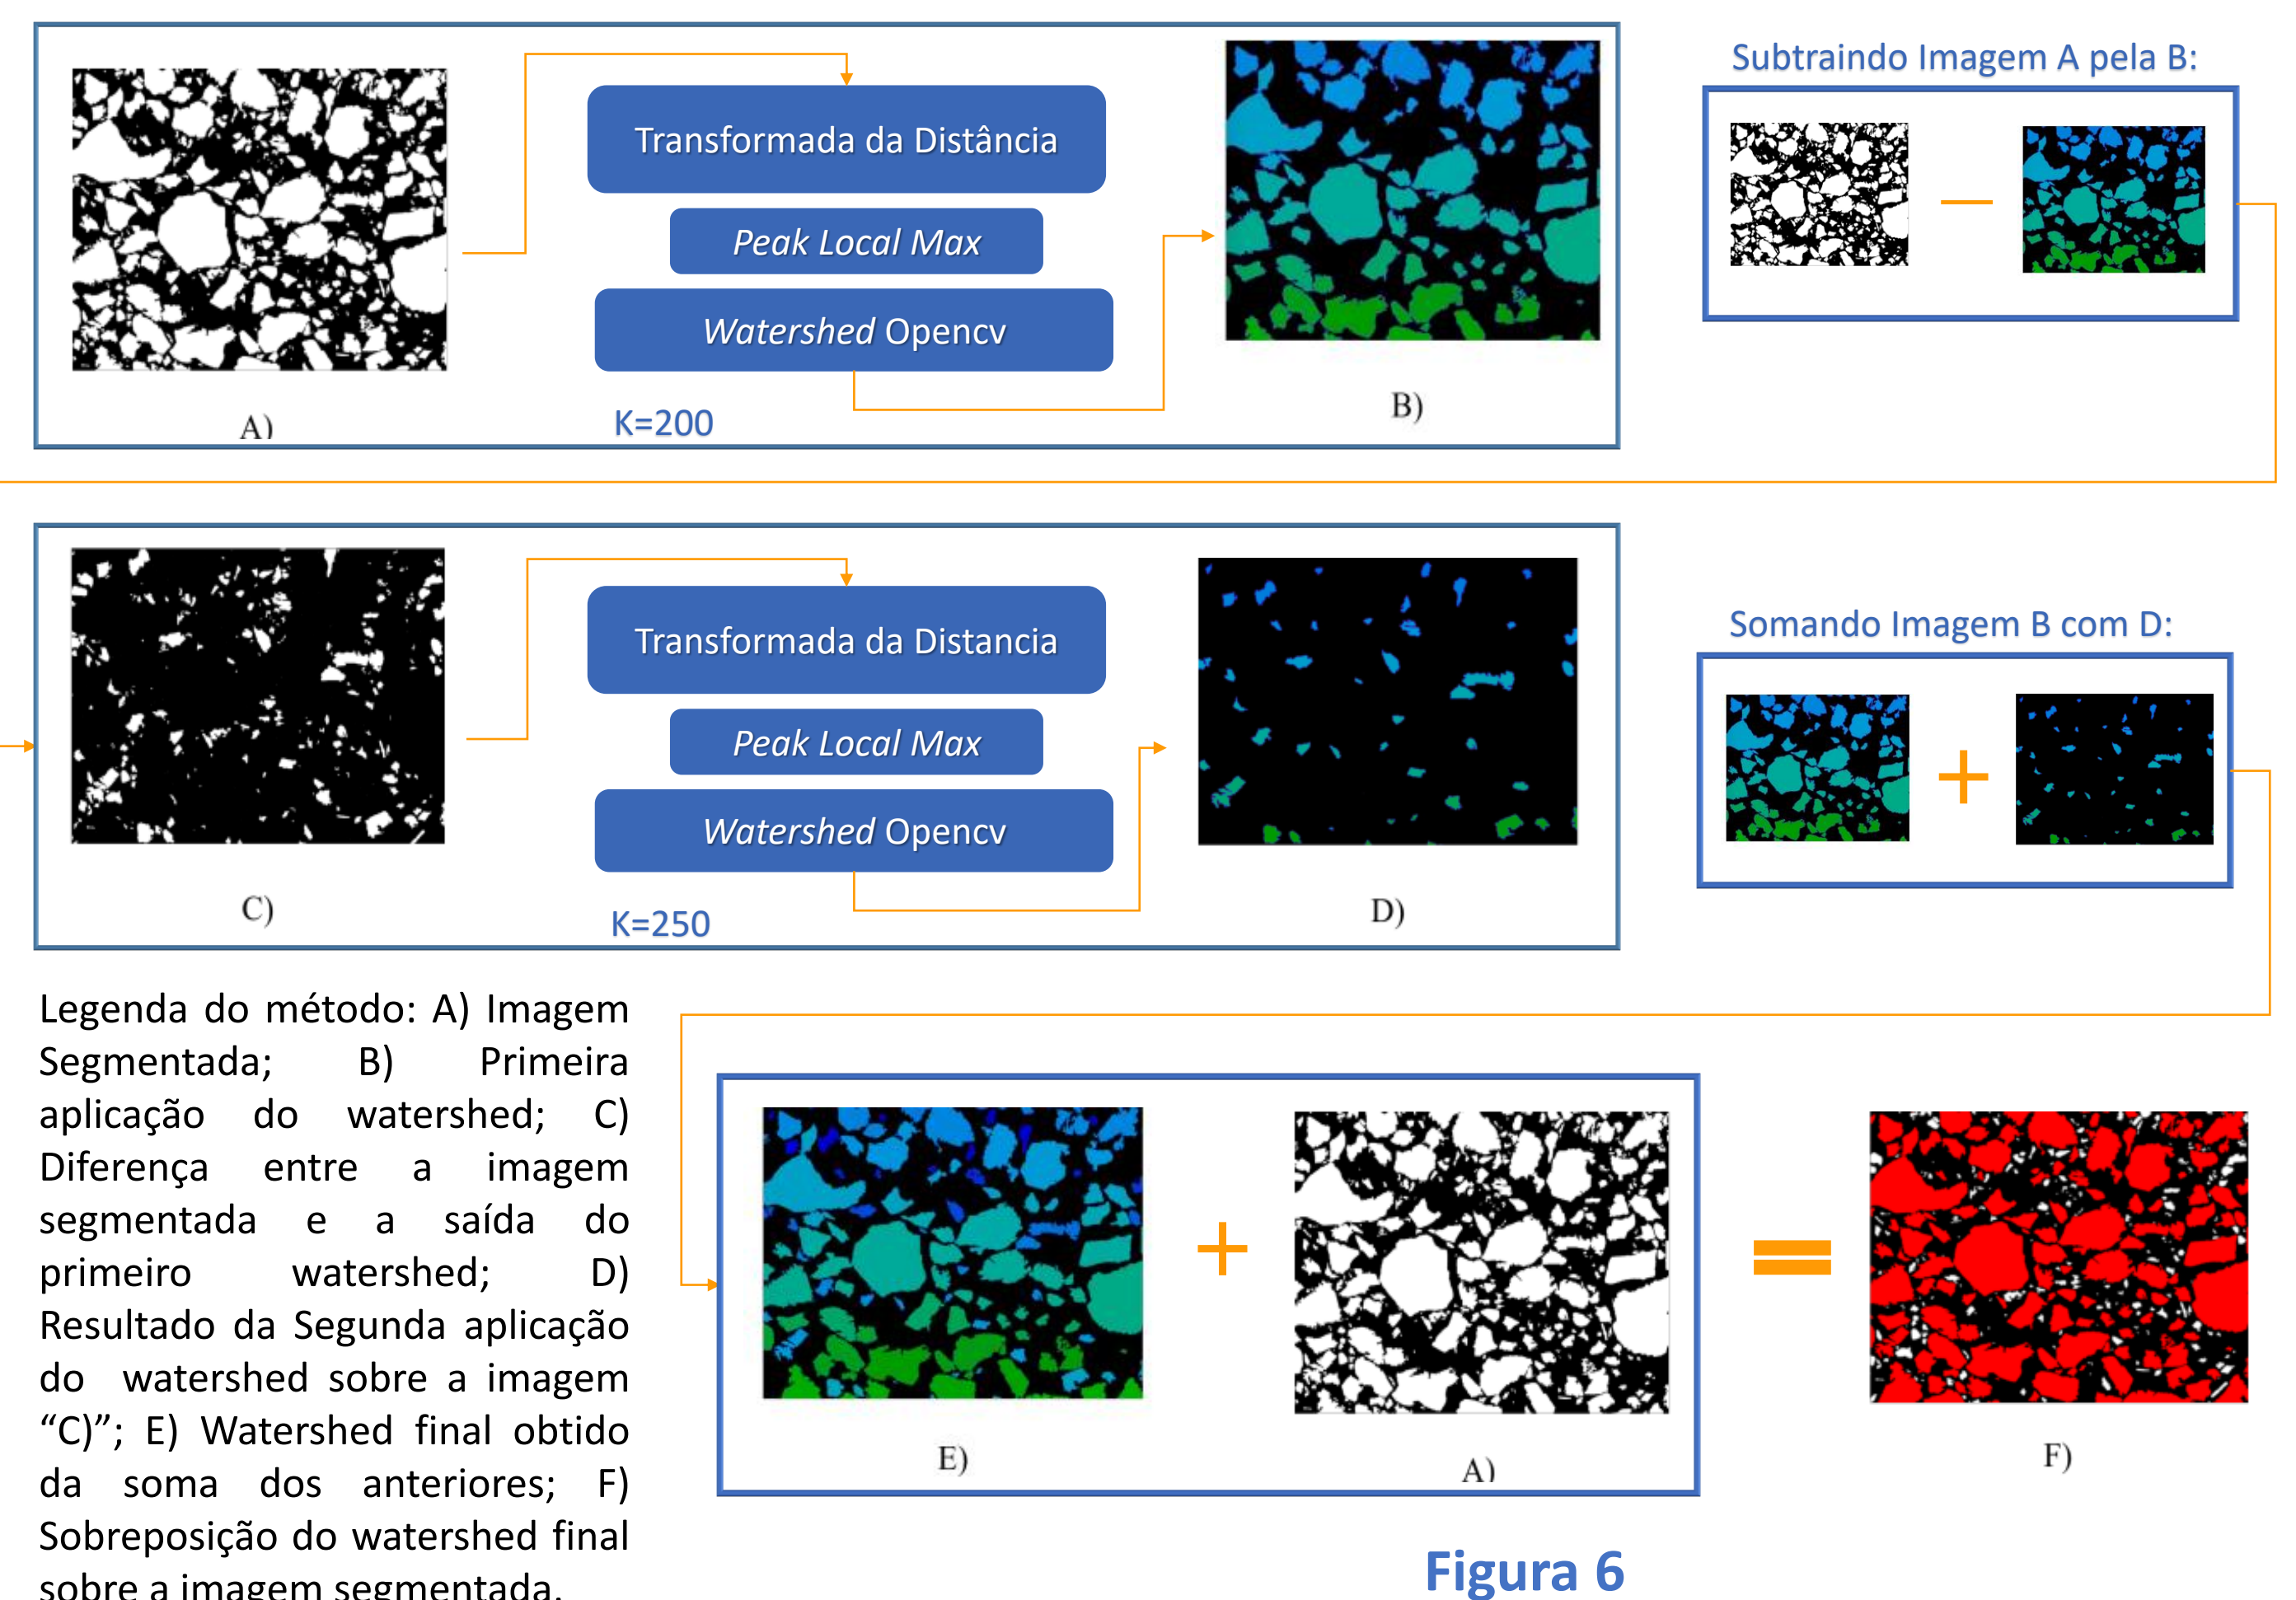


Figura 6

Resultados: Nos resultados apresentados é possível observar que o método proposto conseguiu abranger uma maior porção dos polígonos na segmentação, além de também obter uma melhor separação entre os grãos quando comparado ao método morfológico, o que refletiu em uma menor amplitude do pico do gráfico de análise granulométrica.




Figura 7

Através do mapa de segmentação obtido foi realizado o cálculo granulométrico. Sendo assim, a classificação granulométrica de cada grão segmentado foi obtida através do cálculo do comprimento de seu maior eixo. A curva granulométrica e a respectiva classificação dos grãos identificados na lâmina é apresentada na figura 8. Foi possível obter um gráfico próximo ao observado pelo método empírico da peneira. Apesar da complexidade e da qualidade dos dados e considerando a diferença entre os métodos aplicados foram adotadas duas considerações para a aprovação dos resultados: (i) a tolerância de aproximadamente 10% entre as medidas apresentadas entre as curvas obtidas pelo método proposto e a peneira; (ii) a região do máximo global da curva de estudo deve estar localizada no mesmo intervalo de tamanho de grão na qual é apresentada pela peneira (0.500-0.250mm).




Figura 8

Conclusão: A partir dos resultados apresentados, obtidos através do método de segmentação não supervisionada utilizando redes neurais convolucionais, podemos identificar que o método aplicado neste trabalho, apesar do tamanho, complexidade e falhas da imagem utilizada, obteve um melhor resultado na segmentação de grãos com baixa complexidade, textura e cor clara (representada principalmente por grãos de quartzo e plagioclásio), bem como em seu contorno grão-poro, do que em grãos com textura mais escura e mais complexa (grãos vulcânicos, granada e opacos não classificados litologicamente na seção delgada). Cabe ressaltar a proximidade do resultado obtido quando comparado com um método empírico mais caro e demorado como a peneira.

Referências:

- Kanazaki, A., 2018. Unsupervised image segmentation by backpropagation, in: 2018 IEEE International conference on acoustics, speech and signal processing (ICASSP), IEEE, pp. 1543-1547.
- Felzenszwalb, P., Huttenlocher, D., 2014. Efficient graph-based image segmentation. International Journal of Computer Vision 59(2), 167-181