

# Identificação mineral baseada em técnicas de *deep learning*

## Mineral identification based on deep learning

Nancy Baygorrea

Bolsista PCI, Eng. Químico, D.Sc.

Otávio da Fonseca Martins Gomes

Supervisor, Eng. Químico, D.Sc.

### Resumo

A quantificação de minerais em imagens de minérios e rochas depende da prévia identificação e segmentação desses minerais. Os métodos clássicos de segmentação, como limiarização (*thresholding*), são efetivos em muitos casos. No entanto, quando o material apresenta textura complexa ou quando os minerais têm características semelhantes na imagem, esses métodos falham. Por outro lado, métodos de segmentação baseada em aprendizado profundo (*deep learning*) têm se mostrado promissores para diversas aplicações, embora haja poucos exemplos na caracterização mineral. Neste trabalho, apresentamos um estudo de caso em que um método de segmentação baseado em *deep learning* foi capaz de reconhecer biotita, plagioclásio e óxidos, com 90.6% de acurácia, em imagens de lâminas de rocha, obtidas em microscópio eletrônico de varredura (MEV).

**Palavras chave:** Deep learning, aprendizado profundo, caracterização de minérios, MEV.

### Abstract

The quantification of minerals in images of ores and rocks depends on the previous identification and segmentation of these minerals. Classic segmentation methods, such as thresholding, are effective in many cases. However, when the material has a complex texture or when minerals have similar characteristics in the image, those methods fail. On the other hand, segmentation methods based on deep learning have shown promise for several applications, although there are few examples in mineral characterization. In this work, we present a case study in which a segmentation method based on deep learning was able to recognize biotite, plagioclase, and oxides with 90.6% accuracy in images from rock thin sections, obtained on a scanning electron microscope (SEM).

**Key words:** Deep learning, ore characterization, SEM.

## 1. Introdução

De forma simples, segmentar uma imagem significa etiquetar seus pixels, de tal forma que pixels pertencentes à mesma categoria tenham a mesma etiqueta alocada. Existe muita literatura clássica sobre métodos de segmentação. Não obstante, não existe um modelo teórico genérico de segmentação que sempre funcione e a escolha do método mais adequado depende essencialmente do problema em questão. De fato, a segmentação é geralmente a tarefa mais difícil em um procedimento de processamento de imagens. A partir do resultado da segmentação, são realizadas as medidas. Assim, a segmentação pode determinar o eventual sucesso ou fracasso da análise.

Os métodos clássicos de segmentação, como limiarização (*thresholding*), são efetivos em muitos casos de caracterização de minérios. No entanto, quando a textura complexa ou quando os minerais presentes têm características semelhantes na imagem, esses métodos falham. Por outro lado, métodos de segmentação baseada em aprendizado profundo (*deep learning*) têm se mostrado promissores para diversas aplicações, embora haja poucos exemplos na literatura referentes à caracterização mineral (Filippo et al., 2021; Karimpouli et al., 2020).

## 2. Objetivos

Implementar e testar um método de *deep learning* para a segmentação de biotita, plagioclásio e óxidos, em imagens de lâminas de rocha, obtidas em microscópio eletrônico de varredura (MEV).

## 3. Material e Métodos

### 3.1. Segmentação com técnicas clássicas, para fins de comparação

A segmentação das fases (biotita, plagioclásio e óxidos) utilizando técnicas clássicas se iniciou com uma limiarização de Otsu para separá-las do restante da imagem. Assim, desde que a forma geométrica dos minerais de interesse são ovais ou retangulares, aplicamos o método de *blobs* (usando a técnica do determinante gaussiano – DOG) na imagem binarizada. A Fig.1 mostra essas etapas em uma imagem de teste.



Figura 1. Imagem de teste: (a) original (MEV); (b) binarizada; e (c) Blob – DOG.

Logo, após operações morfológicas (uma dilatação e uma erosão) utilizando componentes conexas, pode-se obter as ROI (*Region of interest*), tendo assim regiões etiquetadas. Nele, houve 134 *blobs* reconhecidos (Fig. 2). Logo, esses *blobs* podem ser armazenados de forma crescente em relação ao tamanho para serem analisadas individualmente.




Figura 2. Os 3 maiores *blobs* identificados.

Dependendo da forma geométrica dos minerais que se está querendo analisar, podem ser selecionados ou eliminados os *blobs* que satisfazem ou não. Esses *blobs* são armazenados como máscaras. Além disso, pode-se aproveitar o módulo `reg.prop` da biblioteca `skimage` para assim criar uma *dataframe*, conforme a Fig 3.

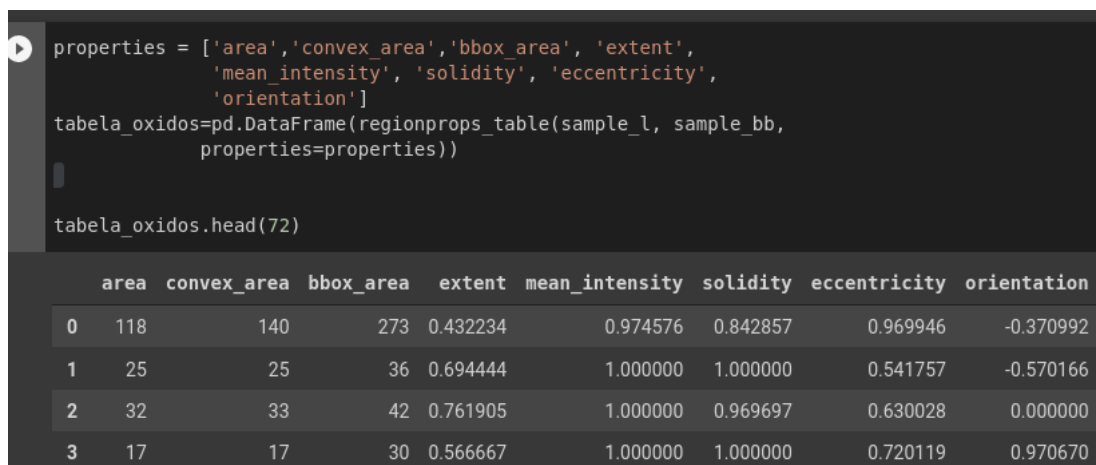


Figura 3. Propriedades dos *blobs* para identificar as fases de interesse e sua respectiva tabela.




Figura 4. Segmentação dos óxidos: (a) 20 dos 84 *blobs* identificados na imagem teste; (b) imagem dos óxidos segmentados.

A Fig. 4 apresenta a segmentação dos óxidos. Logo, utilizando um módulo do skimage, pode se quantificar o minério. Analogamente, pode ser feito para a biotita e o plagioclásio. Cabe ressaltar que esse método só segmenta um elemento por vez. Então, busca-se novas metodologias que capazes de fazer a segmentação multiclasse, sempre considerando o custo computacional.

### 3.2. Segmentação com *deep learning*

O primeiro passo na tentativa de treinar um modelo de segmentação é preparar o *dataset*. Para isso, uma ferramenta chamada Labelme foi utilizada para gerar manualmente as máscaras de segmentação *ground truth*. Assim, na pasta dataset há um conjunto de imagens de 512x512 de formato jpg e as máscaras de formato png. Desde que se precisa segmentar as 4 fases (biotita, plagioclásio, óxidos, buraco/resina), teremos 4 classes. Cada classe tem um único ID na imagem segmentada, os valores dos pixels denotam a classe do pixel correspondente. Isso é um formato comum usado por muitos dos *datasets* e *keras segmentation*. Assim, classe0 = `_background_`, classe1 = biotita, classe2 = buraco, classe3 = óxidos, classe4 = plagioclásio, conforme mostrado na Fig. 5.




Figura 5. (a) Imagem de teste original; (b) imagem anotada.

Usualmente, modelos de segmentação baseados em *deep learning* são construídos sobre redes neurais convolucionais (CNN). Tais modelos, como ResNet, VGG ou MobileNet, são escolhidos para a rede base. Algumas camadas iniciais *deep learning* da rede neural base são usados no *encoder* e o restante da rede de segmentação é construída sobre ele. Para muitos dos modelos de segmentação, qualquer rede neural base pode ser usada. No nosso experimento, foi usado o modelo `vgg_unet`, o modelo base VGG 16 e o modelo de segmentação U-Net. Experimentalmente, foi comprovado que a U-Net pode ser usada para objetos de pequeno tamanho. Então, a pasta dataset foi dividida em 4 pastas, `data_train`, `data_test`, `annotation_train`, `annotation_test`. Nas duas primeiras, estão as imagens para treinamento e para teste, respectivamente; nas duas últimas, estão as anotações *ground truth* para treino e de teste.

O modelo U-Net foi construído com pré-requisitos mínimos: keras==2.3.1, tensorflow==2.1.0, keras\_application==1.0.8, image-classifiers==1.0.0 efficientnet==1.0.0, com uma base pré-treinada U-Net, acrescentando camadas para ajustar o shape do *input*, acrescentando 5 convolução 2D e seu respectivo *batchNormalization*.

#### 4. Resultados, discussão e considerações finais

O resultado do treinamento da rede se mostra na Fig. 6. Observe a diferença entre a máscara *input* dada na Fig. 5b e a imagem resultante na Fig. 6b. Percebe-se um resultado promissor do uso do *deep learning* para a identificação dos minerais, e, portanto, a quantificação.




Figura 6. (a) Imagem usada para treinar a CNN; (b) imagem multiclasse segmentada resultante.

Como trabalho futuro, sugere-se o emprego de métodos *Data Augmentation*. A questão da escassez de dados para treinamento é crucial, particularmente nesse caso para a análise de fases que tenham formas irregulares e variadas. Além disso, sugere-se também experimentar técnicas de *Transfer Learning* a fim de generalizar a técnica para outras rochas e minérios.

#### 5. Agradecimentos

Os autores agradecem ao Programa PCI pela bolsa e ao CETEM por todo apoio.

#### 6. Referências Bibliográficas

FILIPPO, M.P.; GOMES, O.F.M.; COSTA, G.A.O.P.; MOTA, G.L.A. Deep learning semantic segmentation of opaque and non-opaque minerals from epoxy resin in reflected light microscopy images. **Minerals Engineering**, 2021.

KARIMPOULI, S.; TAHMASEBI, P.; SAENGER, E.H. Coal cleat/fracture segmentation using convolutional neural networks. **Nat. Resour. Res.** 2020, 29, 1675–1685.