

DESENVOLVIMENTO DE ALGORITMO DE DEEP LEARNING COM DADOS AEROGEOFÍSICOS PARA INVESTIGAÇÃO DE ALVOS EXPLORATÓRIOS AURÍFEROS

Phillipe Ferreira Lima

Vinícius Hector Abud Louro

Instituto de Geociências/Universidade de São Paulo

phillipe@usp.br

Objetivos

O objetivo deste projeto é produzir indicadores de potencial mineralização de ouro decorrente de processos de alteração hidrotermal utilizando algoritmos de Deep Learning a fim de diminuir o tempo investido no processamento de dados. Com a identificação acontecendo por meio do uso de técnicas para manipulação dos dados gamaespectrométricos a fim de auxiliar na identificação destes processos. Com as técnicas utilizadas sendo a identificação de concentrações anômalas de K, baixos valores de Th/K e altos valores de fator F. A aplicação do modelo gerado para sua validação foi na porção Leste da Província Aurífera da Alta Floresta localizada no Estado do Mato Grosso, local este reconhecido pelo seu potencial aurífero. Um objetivo secundário foi a exploração de diferentes algoritmos de Deep Learning, análise e controle de qualidade dos resultados obtidos a fim de se obter as ferramentas que melhor se adéque ao problema e configurações da pesquisa.

Métodos e Procedimentos

Levantamentos gamaespectrométricos adquirem emissões de radiação eletromagnética emitida pelo decaimento de elementos radioativos em uma determinada região. Com base nisso é possível se obter estimativas das concentrações dos elementos K, U e Th, a partir de equipamentos

aerotransportados para uma dada região (Kearey et al., 2002).

Anomalias de K podem indicar depósitos pôrfiros de Cu-Au e depósitos de ouro epitermal, resultados de processos de alteração serícita ou potássica (Dickson e Scott. 1997). Mapas produzidos com a razão Th/K e fator F (K^*U/Th) fornecem uma indicação mais precisa dos locais com alteração hidrotermal relacionadas a mineralização de ouro e cobre (Ribeiro et al., 2014).

Estes dados gamaespectrométricos foram usados para o treinamento de redes de Deep Learning para o reconhecimento destas assinaturas relevantes para a identificação de potenciais mineralizações de ouro. Deep Learning é uma subárea de Machine Learning que são modelos matemáticos criados com a capacidade de fazerem previsões ou tomarem decisões a partir de conjuntos de dados e sem serem explicitamente programados (Goodfellow et al., 2016). Deep Learning portanto faz o reconhecimento dos padrões presentes nos dados através de modelos matemáticos baseados em rede neurais artificiais (Goodfellow et al., 2016 e Schmidhuber, 2015) Foi utilizado aprendizagem supervisionada para o treinamento da rede. Esta técnica consiste na apresentação dos dados para o algoritmo de Deep Learning com etiquetas da classe de cada dado. Estas etiquetas foram criadas a partir de um banco de dados de imagens gamaespectrométrica obtida no banco de

dados geocientífico da CPRM. A rede neural utilizada para aprendizagem dos padrões dos dados e geração dos modelos foi a rede YOLOv5 (Jocher, 2021). Este é capaz de classificar imagem e caracterizar os limite da classe procurada dentro da imagem.

Resultados

Os modelos treinados não apresentaram evidência de overfitting. A aplicação destes para validação nos dados de teste apresentam resultados satisfatório. Estes nas imagens de teste identificam quase todas as regiões de interesse.

Os resultados obtidos pelo algoritmo construído a partir de três modelos de Deep Learning (anomalia de K, baixos valores de Th/K e altos valores fator F) aplicados sobre o mapa gamaespectrométrico ternário da porção Leste da PAAF é ilustrado na figura 1. Através de dados de ocorrências minerais de ouro e localidades de garimpos obtidos da literatura (Silva e Abram, 2008) é possível verificar que regiões indicadas pela aplicação do algoritmo no mapa da PAAF vão de encontro com informações sobre garimpos, locais com potencial para mineralizações e minas.

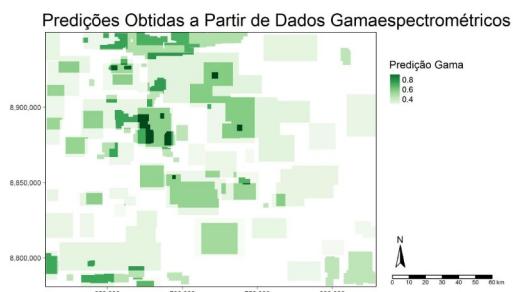


Figura 1: Mapa com as previsões de potencial de mineralização por processo hidrotermal para a porção leste da PAAF gerado pelo algoritmo integrado de modelos de Deep Learning para o processamento de dados gamaespectrométricos.

Conclusões

Assim como para qualquer área de estudo na qual se pretende aplicar técnicas de Deep Learning é necessário a busca por redes neurais capazes de se ajustar e solucionar o problema necessário, sem perder de foco a disponibilidade de recursos e dados para a realização do projeto. Desta forma a utilização

de Deep Learning na área de mineração precisa de uma busca crítica de quais algoritmos utilizar de acordo com estas peculiaridades.

Os resultados obtidos evidenciam que o uso de Machine Learning podem auxiliar na interpretação de dados gamaespectrométricos e gerar insights sobre regiões remotas. Somado a isso a principal vantagem é a diminuição do tempo investido no processamento e delimitação de alvos exploratórios a parir de dados de aerolevantamentos geofísicos. Com esta diminuição de tempo é possível transferir mais tempo para a interpretação através de conhecimentos geológicos e geofísicos dos resultados gerados pelo modelo.

Referências Bibliográficas

- Dickson, B.L., Scott, K.M., 1997. Interpretation of aerial gamma-ray surveys-adding the geochemical factors. AGSO Journal of Australian Geology and Geophysics, 17, 187-200.
- Goodfellow, I., Bengio, Y., Courville, A., 2016. Deep Learning. MIT Press, <http://www.deeplearningbook.org> (acessado em 07/09/2021).
- Jocher, G., Stoken, A., Jirka Borovec, J., NanoCode012, ChristopherSTAN, Changyu, L., Yu, L., 2021. ultralytics/yolov5: v4.0 - nn.SiLU() activations, Weights & Biases logging, PyTorch Hub integration. Zenodo.
- Kearey, P., Brooks, M., Hill, I., 2002. An Introduction to Geophysical Exploration. by Blackwell Science Ltd.
- Ribeiro, V.B., Mantovani, M.S.M.; Louro, V.H.A., 2014. Aerogamaespectrometria e suas aplicações no mapeamento geológico. Terra Didatica, 10, 29-51.
- Schmidhuber, J., 2015. Deep learning in neural networks: An overview. Neural Networks, 61, 85-117.
- Silva M.G. & Abram M.B. 2008. Projeto metalogenia da Província Aurífera Juruena-Teles Pires, Mato Grosso. Goiânia, Serviço Geológico Brasileiro, CPRM, 212p.