

O uso de técnicas de Machine Learning como apoio na definição de domínios de minério: estudo de caso do corpo de minério Queimada – Mina Lamego, Quadrilátero Ferrífero

Matheus Luís de Sales Oliveira; Mariana Gazire Lemos; Fernanda Gontijo Fernandes Niquini; Raphael do Carmo Fernandes; Gabriel de Freitas Silva; Ricardo Oliveira de Araújo Mabub; Alexandre Souza de Oliveira

O depósito aurífero Lamego está localizado na porção norte do Quadrilátero Ferrífero, no município de Sabará, Minas Gerais, Brasil. O depósito é classificado como orogênico e está inserido no *Greenstone Belt* Rio das Velhas, borda sul do craton do São Francisco. Lamego exibe complexo aspecto estrutural e mineralização, o que torna prospecção um desafio para âmbito exploratório. Desta forma, além de metodologias tradicionais como mapeamento e sondagem, faz-se necessário contar com novas tecnologias e mecanismos a fim de extrair o máximo do recurso mineral.

A mineralização de Lamego é constituída por quatro corpos principais denominados Cabeça de Pedra, Arco da Velha, Carruagem e Queimada. Este último é um corpo de minério com características geológicas complexas que englobam dois tipos de mineralização associadas sendo, *shear related veins* e *replacement* em formação ferrífera bandada. Exibe padrões de dobramento e redobramento, além de eventos posteriores que rompem localmente a estrutura. Também, ostenta espessuras variadas e zoneamento de teores de ouro (Au), enxofre (S) e arsênio (As). Desta forma, a aplicação de algoritmos de análise de agrupamento para a definição de *clusters* torna-se uma importante ferramenta para auxiliar na definição dos diferentes domínios de minério ali presentes.

O banco de dados utilizado é composto exclusivamente por furos de sonda e antes da execução do algoritmo de agrupamento foi realizada uma análise exploratória de dados, que revelou a necessidade de remover *outliers* (teores e litologias) e amostras com teores de Au menores que 80% do *cut off grade*, garantindo assim a isonomia do banco de dados e restringindo a análise à estrutura mineralizada e sua envoltória. Ademais, para incorporar na análise as quatro diferentes litologias existentes, foram construídas três variáveis *dummies* (D1, D2 e D3). Dessa maneira, foram definidas 1537 amostras individuais nas quais a posição geográfica (X, Y e Z), os teores de Au, S e As, a densidade e as litologias (convertida em variáveis *dummy*) foram utilizadas como variáveis de input.

Com o banco de dados normalizado, a análise de agrupamentos foi executada através de Jupyter Notebooks na plataforma *Google Colab*, utilizando quatro diferentes algoritmos: k-means; hierarchical; dsclus; e acclus. Para a definição da quantidade de *clusters* foram utilizados os índices

de Silhouette, Calinski-Harabsz, *Weighted Cumulative Sum of Squares* (WCSS) e *spatial entropy* que, de maneira simplificada, são métricas para avaliar a similaridade entre as amostras alocadas dentro de um mesmo grupo. Os resultados obtidos com as técnicas aplicadas foram comparados com divisões propostas previamente através de mapeamento geológico-estrutural e modelamento geológico, visando identificar qual algoritmo gerou os resultados mais coerentes com os aspectos geológicos da região.

Para o estudo no Queimada, o método *acclus* com três *clusters* obteve a melhor performance estatística e resultados condizentes com o verificado em campo. Conclui-se, portanto, que técnicas de aprendizado de máquina mostram-se boas ferramentas para definição e melhor entendimento de alvos em depósitos estruturalmente controlados e de difícil compreensão.