

Mapeamento prospectivo mineral da Província Aurífera de Alta Floreste usando métodos de aprendizado de máquina

Victor Silva dos Santos

Prof. Dr. Vinicius Hector Abud Louro

Instituto de Geociências / Universidade de São Paulo

victor.silva.santos@usp.br

Objetivos

Neste estudo, quatro dos mais utilizados algoritmos de aprendizado de máquina (ML), incluindo random forest (RF), support vector machine (SVM), gradient boosting (GB) e k-nearest-neighbors (kNN), foram empregados numa abordagem SIG do mapeamento de áreas prospectivas para ouro em uma região polimetálica no setor leste da Província Aurífera de Alta Floreste (PAAF), Mato Grosso, Brasil. A incerteza associada a escolha da classe “não-depósito” em modelos de ML também foi abordada.

Métodos e Procedimentos

As variáveis utilizadas consistem de dados aerogeofísicos, geoquímicos, estruturais, de sensoriamento remoto e modelo digital de elevação (MDE), divididos em conjuntos de treino (região norte) e de teste (região sul), utilizados em problemas de classificação. Mil modelos de cada tipo algoritmo foram computados considerando localizações conhecidas de depósitos e minérios primários como classe-alvo, e localidades chamadas “não-depósito” como contra-exemplos (aleatoriamente amostradas em novas posições a cada iteração). Foram utilizadas as bibliotecas Fatiando a Terra e Scikit-learn da linguagem Python nas etapas de processamento e modelagem de dados.

Resultados

Foi calculada a média e variância dos modelos, assim como as medidas de performance mais comumente aplicadas em problemas de aprendizados de máquina, para a geração de

mapas prospectivos (Figura 1) e gráficos de acurácia, recall e f1 score de cada iteração (Figura 2), que mostram quão susceptíveis são os modelos de ML às variações de localidades “não-depósito”.

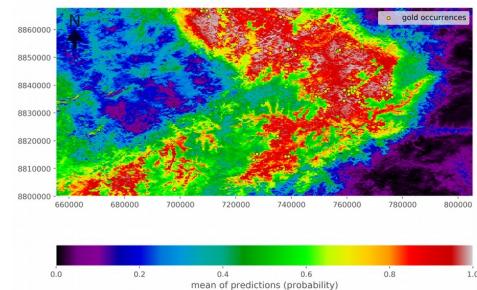


Figura 1: média de mil modelos RF.

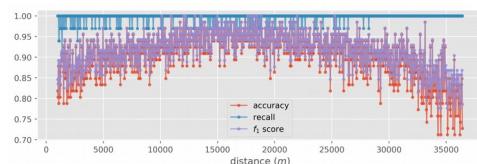


Figura 2: métricas de modelos RF em mil iterações.

Conclusões

Foi possível analisar e quantificar a incerteza associada a classe “não-depósito” em problemas de classificação para geração de mapas prospectivos, assim propondo novas métricas a serem consideradas nesse tipo de problema.

Referências Bibliográficas

Carranza, E. J. M. and Laborte, A. G., 2015. Data-driven predictive mapping of gold prospectivity: application of Random Forests algorithm. *Ore Geology Reviews*, 71:777–787.