



Boletín de la Sociedad Geológica del Perú

journal homepage: www.sgp.org.pe ISSN 0079-1091

Aprendizaje Automático Aplicado a la Integración de Múltiples Criterios Cuantitativos y Cualitativos para la Clasificación de Recursos Minerales

David F. Machuca-Mory, Ilkay Cevik

Resumen

La clasificación de los recursos minerales en las categorías de Medidos, Indicados e Inferidos tiene como objetivo comunicar el nivel de confianza asociado a los tonelajes y leyes reportados en una Declaración de Recursos Minerales. Para esto se deben considerar múltiples criterios cuantitativos y cualitativos relacionados a la calidad e integridad de los datos, al nivel de confianza y conocimientos geológicos, a la continuidad y la estimación de las leyes, y a los prospectos razonables de una eventual extracción económica. Se propone una metodología basada en la asignación de puntajes entre cero y uno a cualquier número y tipo de criterios de clasificación presentes en el modelo numérico de recursos. En cada bloque del modelo un puntaje alto indica un alto nivel de confianza. La forma de las funciones sigmoideas usadas en la asignación de puntajes puede ser modificada para permitir una relación no lineal entre el criterio de clasificación y su puntaje. A cada criterio se le asigna un peso que depende de su relevancia para la clasificación de recursos. La suma ponderada de puntajes es calculada para cada bloque y es modificada por el puntaje asignado al nivel de confianza geológica. Un algoritmo de agrupamiento espacial de datos es aplicado a las sumas ponderadas de puntajes para producir tres categorías. Posteriormente, el algoritmo de Máquinas de Vector Soporte es aplicado para suavizar los contactos entre las tres categorías y definir la clasificación final, la cual es revisada y validada por la Persona Competente responsable de la Declaración de Recursos Minerales. Esta metodología es demostrada por medio de casos reales.

Palabras Clave: Clasificación de Recursos Minerales, Aprendizaje Automático

Machine Learning Applied to the Integration of Multiple Quantitative and Qualitative Criteria for the Classification of Mineral Resources

Abstract

The classification of mineral resources into the Measured, Indicated and Inferred categories is intended to communicate the level of confidence associated with the tonnages and grades reported in a Mineral Resource Statement. This requires consideration of multiple quantitative and qualitative criteria related to the data quality and completeness, the level of geological confidence and knowledge, the grade continuity and estimation metrics, and the reasonable prospects for eventual economic extraction. A methodology is proposed based on assigning scores between zero and one to any number and type of classification criteria present in the numerical resource model. At each block of the model a high score indicates a high level of confidence. The shape of the sigmoid functions used in the score assignment can be modified to allow for a non-linear relationship between the classification criterion and its score. Each criterion is assigned with a weight that depends on its relevance to the resource classification. The weighted sum of scores is calculated for each block and is modified by the score assigned to the geological confidence level. A spatial clustering algorithm is applied to the weighted sums of scores to produce three categories. Subsequently, the Support Vector Machines algorithm is applied to smooth the contacts between the three categories and define

the final classification, which is reviewed and validated by the Competent Person responsible for the Mineral Resource Statement. Real case studies are used to demonstrate this methodology.

Keywords: Mineral Resources Classification, Machine Learning

Desarrollo

Introducción

El Comité para los Estándares Internacionales de Reporte de Reservas Minerales (CRIRSCO, por sus siglas en inglés) agrupa diversas sociedades técnicas relacionadas a la minería representado varios países, incluyendo Canadá, EE. UU., Colombia, Chile, Brasil, Turquía, Kazakstán, Mongolia, Rusia, Sudáfrica, Indonesia, Australasia y la Unión Europea. El CRIRSCO ha consolidado los códigos y estándares para el reporte público de recursos minerales de sus países miembros y ha producido una definición consistente de los Recursos Minerales. Todos estos códigos para el reporte público de recursos minerales subdividen, en orden creciente de su confianza geológica, en las categorías de Inferidos, Indicados y Medidos.

En la práctica actual, los recursos minerales son comúnmente estimados por medio de modelos computacionales tridimensionales que caracterizan la forma, cantidad y ley de los materiales de interés económico. La Persona Competente, quien es responsable de la estimación de los recursos, clasifica diferentes porciones de este modelo en las tres categorías de recursos considerando múltiples criterios relacionados al nivel de confianza en la estimación. Estos criterios pueden ser clasificados en dos grupos: criterios cuantitativos y criterios cualitativos.

Los criterios cuantitativos, o numéricos, son normalmente resultados o medidas que derivan de la metodología de estimación de leyes (CIM, 2019). Estos criterios pueden incluir, entre otros, el número de datos y taladros usados para la estimación, la proximidad a los datos, la distancia relativa a la medida de continuidad espacial, la varianza del krigeado, y medidas de confianza derivadas de estudios probabilísticos (Emery et al, 2006). La clasificación de recursos basada en estos criterios es relativamente práctica y sencilla, pero puede resultar en límites entre categorías que son

inconsistentes con otros criterios más importantes, como la certeza geológica y los prospectos de eventual extracción económica. Este tipo de clasificación es conocido como “perro moteado” (Stephenson et al, 2006).

Los criterios cualitativos pueden ser más difíciles de codificar en un modelo numérico, ya sea porque involucran un componente subjetivo importante, o su cuantificación resulta en valores de lógica difusa. Entre estos criterios se pueden incluir la certeza en la interpretación geológica y de la continuidad de las leyes, la calidad relativa de diversos tipos de datos usados en la estimación, la accesibilidad a los cuerpos mineralizados, la confianza en los parámetros metalúrgicos, geomecánicos y económicos, y factores sociales, ambientales y legales.

La combinación de múltiples criterios cuantitativos y cualitativos para la clasificación de recursos puede ser una tarea muy difícil. Estos criterios pueden ser divergentes y difíciles de codificar en el modelo numérico. Debido a esto, la Persona Competente comúnmente se basa en su conocimiento, experiencia previa o postulados que no siempre pueden ser incorporados explícitamente durante el trazado de los límites entre las diferentes categorías de recursos.

En este trabajo se propone una metodología asistida por algoritmos de aprendizaje automático (“machine learning”) para facilitar la integración de múltiples criterios cuantitativos y cualitativos en la clasificación de recursos. Lejos de ser una “caja oscura”, esta metodología permite el control de la Persona Competente sobre parámetros importantes tales como el peso asignado a cada criterio y la edición final de los límites entre categorías. Gracias a esto, la metodología propuesta es transparente y auditable.

Metodología

La metodología propuesta para la clasificación de recursos asistida por algoritmos de aprendizaje automático requiere que los criterios cuantitativos y cualitativos sean codificados en las unidades de volumen, o bloques, que discretizan el modelo de recursos. No es necesario que el tamaño de estos bloques sea equivalente a la unidad mínima selectiva de minado, sino que pueden ser más grandes. Esto se debe a que en un modelo

de recursos de largo plazo es más importante la clasificación de volúmenes de producción relevantes para el planeamiento de minado a largo plazo que la clasificación del mineral a explotarse día a día. Otras ventajas de usar bloques más grandes que la unidad mínima selectiva de minado para la clasificación de recursos son la reducción del riesgo de producir el efecto de “perro moteado” y la reducción del tiempo de ejecución de los algoritmos.

Los criterios cualitativos en cada bloque son valorados según su nivel de confianza correspondiente. Así, un bloque donde la certeza geológica es grande recibe un valor alto para este criterio, o un bloque donde la calidad de roca sea pobre o incierta recibe un valor bajo. La confianza geológica puede ser comunicada a través del modelo geológico, donde se pueden asignar valores que reflejen el nivel de conocimiento y certeza geológica a los diversos objetos tridimensionales que lo conforman, tales como cuerpos mineralizados, fallas u otros sólidos y superficies que representan los controles de mineralización.

Una vez que un número de criterios cuantitativos y cualitativos que la Persona Competente considera relevantes son codificados en el modelo de recursos, la metodología propuesta procede en tres etapas:

- 1) Asignación de puntajes y pesos a los criterios de clasificación de recursos
- 2) Agrupamiento en tres categorías
- 3) Suavizado y edición de los límites entre categorías

En la primera etapa los valores de los criterios cuantitativos y cualitativos en cada bloque son transformados en puntajes entre 0 y 1 con la ayuda de funciones sigmoideas de tipo:

$$y_i(\mathbf{u}) = \frac{1}{1+e^{-c_i(x_i(\mathbf{u})-b_i)}} \in [0,1] \quad (1)$$

Donde es el puntaje resultante entre 0 y 1 asignado a un criterio en el bloque centrado en una ubicación , es el valor original de cada criterio para el mismo bloque, y son constantes que determinan

el centro y la amplitud de la función sigmoidea y es el número de Euler. Al escoger un valor para, la Persona Competente puede determinar un umbral crítico para cada criterio de clasificación. El valor de , también escogido por la Persona Competente, determina el impacto que tendrá el umbral crítico escogido en la clasificación de recursos. El signo de determina si el puntaje resultante es inversamente (signo negativo) o directamente (signo positivo) proporcional al valor original de cada criterio. Adicionalmente, la Persona Competente asigna un peso a cada criterio que refleja la importancia que considera que debe tener cada criterio. Así, en cada bloque se obtiene la suma ponderada:

$$\bar{y}(\mathbf{u}) = \frac{\sum_i^n \omega_i \cdot y_i(\mathbf{u})}{\sum_i^n \omega_i} \in [0,1] \quad (2)$$

El puntaje asignado a la confianza geológica puede formar parte de los criterios incluidos en esta suma ponderada. Sin embargo, si se considera que la confianza geológica, u otro criterio cualitativo, debe tener una importancia preponderante, la suma ponderada es ajustada por el puntaje asignado a este criterio en cada bloque. De esta forma, el puntaje final asignado a cada bloque viene a ser:

$$\bar{y}(\mathbf{u}) = \alpha_i(\mathbf{u}) \frac{\sum_i^n \omega_i \cdot y_i(\mathbf{u})}{\sum_i^n \omega_i} \in [0,1] \quad (3)$$

En el segundo paso los puntajes obtenidos para cada bloque usando la ecuación (2) o la ecuación (3), según sea el caso, son agrupados usando el algoritmo de agrupamiento k-medoids (Schubert y Rousseeuw, 2019). El desempeño de este agrupamiento es evaluado por el análisis visual de la distribución espacial de los tres grupos resultantes y con la ayuda de gráficos estadísticos. Si los grupos no forman poblaciones claramente distintas espacial y estadísticamente, la Persona Competente puede reajustar iterativamente los parámetros de la asignación de puntajes y los pesos asignados a cada criterio. Si se observa que el grupo representado los bloques de mas alta confianza aparecen adyacentes a los bloques de menor confianza, una zona colchón puede ser introducida entre estas dos categorías, de forma que en la clasificación final siempre aparecerá la categoría de recursos indicados entre las categorías de medidos e inferidos. El ancho de esta zona colchón puede ser escogido con relación a la continuidad espacial de las leyes y/o el espaciamiento de los datos.

En el tercer paso, el algoritmo de maquinas de vector soporte (Cortes y Vapnik, 1995) es aplicado para suavizar los contactos entre los tres grupos producidos por el algoritmo de agrupamiento. Este suavizado es requerido para facilitar la toma de decisiones sobre los recursos y el trabajo de planeamiento de minado. Durante este paso, la Persona Competente debe revisar estos contactos y, de ser necesario, puede editarlos manualmente según su criterio, experiencia y conocimiento.

Caso de Estudio

La Figura 1 ilustra la aplicación de la metodología propuesta para la clasificación de recursos de oro en un depósito orogénico en África nororiental. Ocho criterios fueron considerados, incluyendo medidas de desempeño del krigeado, la calidad y cantidad de los datos usados y la distancia a la superficie. La suma ponderada de los puntajes asignados a estos criterios fue multiplicada por el puntaje dado a la certeza geológica. Luego del suavizado, los contactos entre las tres categorías de recursos solo necesitaron ediciones mínimas.

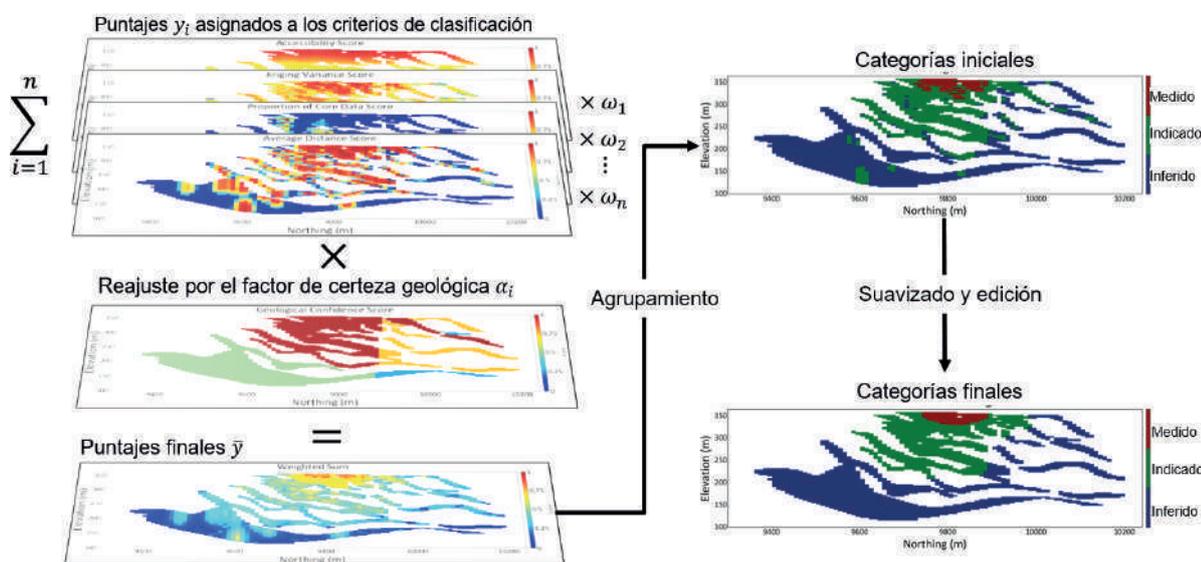


Figura 1: Aplicación de la metodología propuesta para la clasificación de recursos de oro en un depósito orogénico en África nororiental

Conclusiones

La metodología propuesta permite la incorporación de múltiples criterios cuantitativos y cualitativos en la clasificación de recursos minerales de manera flexible, reproducible y auditable. Los resultados son comparables a la clasificación realizada manualmente por una Persona Competente, pero requieren de menor tiempo y esfuerzo. Es sumamente importante que los resultados sean revisados y validados por la Persona Competente.

Contribuciones Técnicas y Científicas

Se propone una metodología reproducible, auditable y eficiente para la clasificación de Recursos Minerales. Esta metodología no se basa en unos pocos criterios cuantitativos, como es la práctica común, sino que incorpora múltiples

criterios cuantitativos y cualitativos, entre los cuales la confianza geológica es preponderante.

Referencias Bibliográficas

- CRIRSCO (2019). International Reporting Template for the public reporting of Exploration Results, Mineral Resources and Mineral Reserves. Committee for Mineral Reserves International Reporting Standards, Council of Mining and Metallurgical Institutions. http://crirSCO.com/templates/CRIRSCO_International_Reporting_Template_November_2019.pdf
- CIM (2019) Estimation of mineral resources & mineral reserves best practice guidelines. Canadian Institute of Mining. <https://mrmr.cim.org/en/best-practices/estimation-of-mineral-resources-mineral-reserves>.
- Emery, X., Ortiz, J. M., & Rodríguez, J. J. (2006).

Quantifying uncertainty in mineral resources by use of classification schemes and conditional simulations. *Mathematical geology*, 38(4), 445-464.

Stephenson, P. R., Allman, A., Carville, D. P., Stoker, P. T., Mokos, P., Tyrrell, J., & Burrows, T. (2006, August). MINERAL RESOURCE CLASSIFICATION—IT'S TIME TO SHOOT THE "SPOTTED DOG"! In *Proceedings Sixth International Mining Geology Conference* (pp. 91-96).

Schubert, E., & Rousseeuw, P. J. (2019, October). Faster k-medoids clustering: improving the PAM, CLARA, and CLARANS algorithms. In *International conference on similarity search and applications* (pp. 171-187). Springer, Cham.

Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20(3), 273-297.