




Cartógrafo.CL/01-2021



Hugo Neira Santander

Cartógrafo, Universidad
Tecnológica Metropolitana,
Postítulo en Geomática
Aplicada, Universidad de Chile

Chile



h.neira@smm.cl

Análisis multicriterio y predicción con Machine Learning para determinar blancos de exploración de pórfidos cupríferos en la franja Paleoceno-Oligoceno, región de Antofagasta, Chile

RESUMEN

En la actualidad, la exploración geológica está procesando una gran cantidad de datos geológicos y geoquímicos, capturados mediante productos geoespaciales y tecnología, que permiten definir un área de interés. Por otra parte, la inteligencia artificial intenta proponer soluciones al trabajo con datos geocientíficos, analizando millones de datos en diferentes dimensiones y épocas. Como ciencia de datos, permite explorar, analizar y predecir información a partir de los mismos datos.

Este estudio se ubica entre la latitud $21^{\circ}30'S$ y $23^{\circ}30'S$, región de Antofagasta, Chile; analiza una zona que para algunas empresas mineras y de inversión está considerada madura en términos de exploración, y cuyos depósitos más expuestos o evidentes ya han sido encontrados. Ante esta situación se busca aclarar, ¿qué tan conveniente es seguir explorando esta zona? Esto es parte esencial de lo que se abordará en este trabajo.

El área tiene características mineralógicas correspondientes a pórfidos cupríferos metálicos, depósitos Cu-(Mo), de los más importantes a nivel mundial. Se encuentra ubicada geológicamente en la franja Eoceno-Oligoceno paralela a la zona de subducción, entre la Placa de Nazca y la Placa Sudamericana. Dicha convergencia de placas ha generado una serie de yacimientos alineados en torno a la evolución geológica de la falla oeste.

Se busca definir potenciales blancos de exploración minera en la zona mencionada, utilizando Machine Learning y Análisis Multicriterio (AHP) con las siguientes variables: geología, fallas geológicas, alteración hidrotermal, franjas metalogénicas, geofísica y muestras de geoquímica. Cada una de ellas es analizada y, además, se le asignan puntajes de importancia para determinar las zonas de interés prospectivo minero.

INTRODUCCIÓN

El norte de Chile es un constante desafío para la minería. El tiempo de caminar por el desierto y encontrar yacimientos, se podría afirmar que es parte del pasado. Hoy, para definir un área de interés o blancos, se requiere de mayores insumos y tecnología. Cada vez son menos los potenciales lugares prospectivos superficiales o visibles al especialista, por lo tanto, se necesita el uso de nuevas metodologías para encontrar un blanco de exploración.

La zona que se analizará es considerada madura para algunas empresas, en términos de exploración, pues sus depósitos más expuestos o evidentes ya han sido encontrados. Ante esta situación se busca aclarar cuan conveniente es seguir explorando esta zona. Esto es parte esencial de lo que se abordará en este trabajo.

El área tiene características mineralógicas correspondientes a pórfidos cupríferos (Maksaev *et al.*, 2007) de los más importantes a nivel mundial. Se encuentra ubicada geológicamente en la franja Eoceno-Oligoceno paralela a la zona de subducción entre la Placa de Nazca y la Placa Sudamericana. Dicha convergencia de placas ha generado una serie de yacimientos alineados en torno a la evolución geológica de la falla oeste (Ossandón *et al.*, 2001).

Este trabajo intentará definir potenciales blancos de exploración minera en la zona mencionada, utilizando las siguientes variables: geología, fallas, alteración hidrotermal, franjas metalogénicas, geofísica y muestras de geoquímica.

Objetivo

Determinar potenciales blancos de interés de exploración minera entre los 21°30' y los 23°30' de latitud sur, de la Región de Antofagasta, Chile.

Para determinar los blancos de interés se aplicarán metodologías, adquiridas en el Diplomado en Geomática Aplicada, tales como; Geoprocesamiento, Geoestadística, Machine Learning, Radar, Multiespectral, entre otros.

Área de estudio

El área de estudio corresponde a un sector de 23.000 km², correspondiente a ocho cuadrángulos del Sernageomin (Servicio Nacional de Geología y Minería). Hojas: Pampa Unión, Cerro Quimal, Sierra Gorda, Moctezuma-Llano De Quimal, Río Salvador, Calama, Sierra De Moreno y Cerro Jaspe-Chitigua.

La principal ciudad del área es Calama y entorno a esta, se encuentran algunos de los principales yacimientos de Chile (Figura 1).

METODOLOGÍA

Para determinar los blancos de interés, se utilizaron seis coberturas para realizar los análisis. Los cuales se hicieron en las siguientes plataformas: Google Earth Engine (GEE) y European Space Agency (ESA). Mediante los siguientes softwares: Qgis 3.14, Sentinel Application Platform (SNAP) y R Studio.

Se genera un esquema del proceso y se construye un diagrama de flujo (Figura 2), en el que se detallan los procesos que se realizan con cada uno de los insumos, para determinar las variables que se utilizan en el análisis.

- Imagen Landsat 8
- Imagen Radar SAR
- Alteración Hidrotermal Aster
- Franjas Metalogénicas
- Fallas geológicas
- Geofísica (Magnetometría)
- Geoquímica muestras de roca, análisis de cobre (Cu)

Variables del estudio.



Geología

Debido a la extensión del área del proyecto, la geología representa un desafío importante, ya que el objetivo es lograr predecirla con Machine Learning (con el software R), a través de una clasificación supervisada con muestras en el área.

La cobertura que permite realizar la predicción es un ráster agrupado (stack) de una colección de imágenes Landsat 8, procesadas en Google Earth Engine (Gorelick *et al.*, 2007), más imagen de Radar SAR (modificado de Copernicus Sentinel, dato 2019), procesada en SNAP e índices de alteración hidrotermal (Sultan *et al.*, 1986; Sabins, 1999; Gad & Kusky, 2006).

En total, el stack de ráster contiene 18 bandas que fueron utilizadas para la clasificación de la geología en el área de estudio.

Además, como predictores se dispone de 2800 geopuntos (puntos de control geológico) con 29 clases (Figura 3), correspondientes a muestras que identifican el tipo de roca o suelo y su edad geológica.




Figura 1. Área de estudio para la búsqueda de blancos de exploración de interés minero.




Figura 2. Diagrama de flujo del proceso de análisis para la identificación de nuevos blancos de exploración.

Debido a la dispersión de la información, existen zonas con muy pocos datos, lo que representa un desafío en la predicción, sumado a que la geología es clave como insumo base, para el análisis de exploración, por ejemplo, las unidades intrusivas (las que se forman a partir de un enfriamiento lento, a gran profundidad y en grandes masas del magma (Aguilar, 2008)) son las que alojan los principales yacimientos de la zona.




Figura 3. Distribución de los 2800 geopuntos en el área de estudio (izquierda). Clases predictoras para obtener la geología del sector (derecha)

Se realiza una programación en R Studio, para evaluar dos tipos de clasificación supervisada: Support vector machine (SVM) y Principal Component Analysis (PCA).

De los dos resultados obtenidos, el SVM (Tabla 1) logró una exactitud de un 84 %, por sobre PCA que obtuvo un 73 %.

Confusion Matrix and Statistics

	21	11	16	17	15	1	3	27	20	10	9	5	8	12	4	23	29	22	26	28	14	7	13	25	6	24	19	2	18
21	211	12	10	3	7	1	0	0	2	7	0	0	0	0	0	1	0	0	0	0	0	0	0	0	1	0	0	0	0
11	9	139	2	0	3	2	0	0	1	1	1	0	0	3	0	3	14	6	0	0	1	0	0	0	0	1	0	0	0
16	11	6	486	27	14	15	1	4	11	2	0	2	4	2	1	0	1	1	1	0	0	1	0	0	0	1	0	9	2
17	2	0	19	202	2	2	0	6	4	2	0	1	2	2	0	0	1	1	0	0	3	1	0	0	0	0	0	0	0
15	5	2	3	2	198	1	0	2	3	8	0	1	0	1	0	13	0	1	4	0	0	0	0	0	0	0	0	0	1
1	0	0	2	0	0	35	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	0	0	1	0	62	0	0	0	0	0	0	0	0	1	0	1	0	0	0	0	0	0	0	0	0	0	0
27	0	5	0	1	3	3	0	80	0	4	0	0	0	0	0	0	3	0	0	1	0	0	0	0	0	0	0	0	0
20	4	3	2	1	1	1	0	0	180	6	0	0	0	3	0	1	0	1	0	0	0	0	0	0	0	1	0	0	0
10	4	4	3	3	1	0	0	1	4	266	0	0	0	5	0	0	9	0	1	3	0	0	0	0	0	1	0	0	2
9	0	0	0	0	0	0	0	0	0	0	54	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	0	0	0	0	0	0	0	9	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
8	0	0	0	0	1	0	0	0	0	0	0	1	48	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2
12	0	1	1	0	0	0	2	0	2	1	0	0	0	41	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
4	0	0	0	0	0	0	0	0	0	0	0	0	0	8	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
23	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	10	0	0	0	0	0	0	0	0	0	0	0	0	0
29	0	1	0	0	2	1	0	0	0	0	0	0	0	0	0	0	44	0	0	0	0	0	0	0	0	0	0	0	0
22	3	1	2	2	1	0	0	4	4	2	0	0	1	1	0	0	0	145	0	3	0	0	0	0	0	0	3	0	0
26	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6	0	0	0	0	0	0	0	0	0	0
28	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0
14	0	0	0	0	0	0	0	0	1	0	1	0	0	0	0	0	0	0	0	15	0	0	0	0	0	0	0	0	0
7	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4	0	0	0	0	0	0	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	11	0	0	0	0	0	0	0
25	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	14	0	0	0	0	0	0
6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	8	0	0	0	0	0
24	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3	0	0	0	0
19	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	76	0	0
2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
18	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

Overall Statistics

Accuracy : 0.8417
95% CI : (0.8277, 0.8551)
No Information Rate : 0.1894
P-Value [Acc > NIR] : < 2.2e-16

Kappa : 0.8254

Mcnemar's Test P-Value : NA

Tabla 1. Matriz de confusión SVM clasificación Geología.

Luego se aplica un filtro de mayoría (Sovann y Aing, 2015), para eliminar la dispersión de píxeles individuales (efecto sal y pimienta), con lo que se obtiene la geología del área de estudio (Figura 4).




Figura 4. Resultado de la clasificación supervisada aplicando SVM, para predecir las unidades geológicas presentes en el área de estudio.

El siguiente proceso es la reclasificación por grupos de roca y edades, según importancia para la exploración minera (Villela y Cantallop, 2016). Se distinguen tres principales grupos: Rocas Intrusivas (Intrusivas Paleozoico, Intrusivo Cretácico, Intrusivo Eoceno e Intrusivo Paleoceno), Rocas Volcánicas (Volcánico Paleoceno y Volcano Sedimentario Cretácico) y Rocas Estratificadas (Estratificadas Paleozoico, Estratificado Cretácico, Estratificados Jurásico y Estratificado Eoceno).

Cabe señalar que en esta etapa se descartan todos los tipos de depósitos (Aluvial Coluvial Pleistoceno-Holoceno, Antrópico, Antrópico Relave, Calizas Mioceno Superior Plioceno, Ciudad, Depósito aluvial coluvial y Plantaciones), por no presentar interés prospectivo, por lo cual se con valor cero.

De este proceso, se obtienen tres ráster que se les aplica un análisis multicriterio, Analytic Hierarchy Process (AHP), para lo cual son estandarizados según idoneidad como roca huésped para albergar yacimientos (Aguilar, 2008), luego se construye una matriz (Tabla 2), donde se le asignan pesos de importancia a cada variable para finalmente obtener un ráster de favorabilidad geológica para prospectos mineros (Figura 11).

	Intrusivo	estratificado	Volcánicas
Intrusivo	1	5	7
estratificado	0.2	1	3
Volcánicas	0.1428	0.3	1
Suma	1.3428	6.3	11

	Intrusivo	estratificado	Volcánicas	PESO
Intrusivo	0.74471254	0.793650794	0.63636364	0.72490899
estratificado	0.14894251	0.158730159	0.27272727	0.19346665
Volcánicas	0.10634495	0.047619048	0.09090909	0.08162436

λ	3.09011566
CI	0.04505783
CI/2	0.02252891
CR	0.03884296

Como CR < 0.1, se puede concluir que los resultados son consistentes.

Tabla 2. Matriz de pesos de factores en los tres ráster reclasificados y estandarizados de la cobertura de geología.

Alteración hidrotermal

Esta cobertura es un insumo que fue proporcionado por la Compañía Minera Sumitomo Metal Mining Chile, para el desarrollo de este estudio, la cual encargó a Sumie Consultant Co. Ltd, en el 2006, realizar un análisis de imágenes ASTER en Chile, con el propósito de extraer regiones de interés de depósitos de cobre y oro.

Se trabajó con siete tipos de alteración existentes en el área; calcita, epidota, clorita, illita, jarosita, caolinita, alunita pirofilita. Estas fueron agrupadas según importancia para la detección de pórfidos cupríferos, según Lowell y Gilbert, 1970. Fueron reclasificados en tres grupos característicos de este tipo de depósitos cupríferos. El primer grupo es alteración propilítica (calcita, epidota, clorita); el segundo es filica (illita, clorita) y el tercer grupo es argílica avanzada (caolinita, jarosita, alunita pirofilita) (Figura 5).

Posterior a la reclasificación se procede a la aplicación del AHP, para lo cual se estandarizan los valores (Astudillo, 2008) de las tres variables (alteración propilítica, alteración filica y alteración argílica avanzada). Luego se construye una matriz (Tabla 3), donde se le asignan pesos de importancia a cada variable de alteración, para finalmente obtener un ráster de favorabilidad de alteraciones hidrotermales para pórfidos cupríferos (Figura 12).




Figura 5. Alteraciones hidrotermales obtenidas con índices del sensor ASTER, 2006. Alteración propilítica (izquierda), alteración filica (centro) y alteración argílica avanzada (derecha).

	propilítico	filico	argilico avan.
propilítico	1	7	0.3333
filico	0.1428	1	0.1428
argilico avan.	3	7	1
Suma	4.1428	15	1.4761

	propilítico	filico	argilico avan.	PESO
propilítico	0.24138264	0.466666667	0.22579771	0.31128234
filico	0.03446944	0.066666667	0.09674141	0.06595917
argilico avan.	0.72414792	0.466666667	0.67746088	0.62275849

λ 3.19822188
CI 0.09911094
CI/2 0.04955547
CR 0.08544047

→ Como CR< 0.1, se puede concluir que los resultados son consistentes.

Tabla 3. Matriz de pesos de factores en los tres ráster reclasificados y estandarizados de la cobertura de alteración hidrotermal.

Franjas metalogénicas

Corresponden a las macro unidades emplazadas paralelas a la zona de subducción entre la Placa de Nazca y la Placa Sudamericana. Dicha convergencia permite las condiciones para la generación de un conjunto de yacimientos alineados con una determinada edad geológica y agrupados en estas franjas (Camus, 2003).

Las franjas metalogénicas de mayor importancia económica en Chile son de edades: Jurásico, Cretácico temprano, Paleoceno-Eoceno temprano, Eoceno tardío-Oligoceno temprano, Mioceno temprano a medio y Mioceno medio a Plioceno temprano.

Para la construcción de las franjas, se modificó el Mapa Geológico de Chile, 2003 (Sernageomin), categorizando 11 clases (Figura 6); Basamento metamórfico Paleozoico, Volcanismo (Cenozoico), Sedimentario (Moderno), Sedimentario Marino (Mesozoico), Sedimentario (Terciario), Sedimentario (Mesozoico), Volcanismo (Mesozoico), Intrusivo (Mioceno-Plioceno), Intrusivo (Eoceno-Oligoceno),

Intrusivo (Paleoceno) e Intrusivo (Mesozoico). Estas fueron rasterizadas y posteriormente se estandarizaron según su importancia (Tabla 4); principalmente, por proceso de mineralización (Sillitoe y Perelló, 2005; Maksiyev *et al.*, 2007). Esto con el fin de aplicar AHP y así obtener un ráster de favorabilidad metalogénica para definir blancos de exploración (Figura 13).




Figura 6. Franjas metalogénicas, del área de estudio agrupadas para definir blancos de exploración.

	Basamento metamórfico Paleozoico	Volcanismo (Cenozoico)	Sedimentario (Moderno)	Sedimentario Marino (Mesozoico)	Sedimentario (Terciario)	Sedimentario (Mesozoico)	Volcanismo (Mesozoico)	Intrusivo (Eoceno-Oligoceno)	Intrusivo (Paleoceno)	Intrusivo (Mesozoico)
Basamento metamórfico Paleozoico	1	5	9	9	9	9	5	1	1	1
Volcanismo (Cenozoico)	0.2	1	3	3	3	3	0.2	0.1428	0.1428	0.1428
Sedimentario (Moderno)	0.1111	0.3333	1	1	1	1	0.2	0.1111	0.1111	0.1111
Sedimentario Marino (Mesozoico)	0.1111	0.3333	1	1	1	1	0.2	0.1111	0.1111	0.1111
Sedimentario (Terciario)	0.1111	0.3333	1	1	1	1	0.2	0.1111	0.1111	0.1111
Sedimentario (Mesozoico)	0.1111	0.3333	1	1	1	1	0.2	0.1111	0.1111	0.1111
Volcanismo (Mesozoico)	0.2	5	5	5	5	5	1	0.1428	0.1428	0.1428
Intrusivo (Eoceno-Oligoceno)	1	7	9	9	9	9	7	1	5	5
Intrusivo (Paleoceno)	1	7	9	9	9	9	7	0.2	1	1
Intrusivo (Mesozoico)	1	7	9	9	9	9	7	0.2	1	1
Suma	4.8444	33.3332	48	48	48	48	28	3.13	8.73	8.73

	Basamento metamórfico Paleozoico	Volcanismo (Cenozoico)	Sedimentario (Moderno)	Sedimentario Marino (Mesozoico)	Sedimentario (Terciario)	Sedimentario (Mesozoico)	Volcanismo (Mesozoico)	Intrusivo (Eoceno-Oligoceno)	Intrusivo (Paleoceno)	Intrusivo (Mesozoico)	PESO
Basamento metamórfico Paleozoico	0.206423912	0.1500006	0.1875	0.1875	0.1875	0.1875	0.178571429	0.319488818	0.114547537	0.114547537	0.183358
Volcanismo (Cenozoico)	0.041284782	0.0300012	0.0625	0.0625	0.0625	0.0625	0.007142857	0.045623003	0.016357388	0.016357388	0.0406766
Sedimentario (Moderno)	0.022933697	0.00999904	0.020833333	0.020833333	0.020833333	0.020833333	0.007142857	0.035495208	0.012726231	0.012726231	0.0184357
Sedimentario Marino (Mesozoico)	0.022933697	0.00999904	0.020833333	0.020833333	0.020833333	0.020833333	0.007142857	0.035495208	0.012726231	0.012726231	0.0184357
Sedimentario (Terciario)	0.022933697	0.00999904	0.020833333	0.020833333	0.020833333	0.020833333	0.007142857	0.035495208	0.012726231	0.012726231	0.0184357
Sedimentario (Mesozoico)	0.022933697	0.00999904	0.020833333	0.020833333	0.020833333	0.020833333	0.007142857	0.035495208	0.012726231	0.012726231	0.0184357
Volcanismo (Mesozoico)	0.041284782	0.1500006	0.104166667	0.104166667	0.104166667	0.104166667	0.035714286	0.045623003	0.016357388	0.016357388	0.0722004
Intrusivo (Eoceno-Oligoceno)	0.206423912	0.21000084	0.1875	0.1875	0.1875	0.1875	0.25	0.319488818	0.572737686	0.572737686	0.2881389
Intrusivo (Paleoceno)	0.206423912	0.21000084	0.1875	0.1875	0.1875	0.1875	0.25	0.063897764	0.114547537	0.114547537	0.1709418
Intrusivo (Mesozoico)	0.206423912	0.21000084	0.1875	0.1875	0.1875	0.1875	0.25	0.063897764	0.114547537	0.114547537	0.1709418

λ 11.69191517
 CI 0.069191517
 CI/2 0.034595758
 CR 0.02321863

Como $CR < 0.1$, se puede concluir que los resultados son consistentes.

Tabla 4. Matriz de cálculo de pesos de factores en los 11 ráster reclasificados y estandarizados de la cobertura de franjas metalogénicas



Fallas geológicas

El sistema de fallas estudiado de rumbo principalmente norte-sur y sureste-noroeste, es paralelo a la zona de subducción chileno-peruana, en el norte de Chile. Se considera relacionado con un importante fenómeno estructural de transpresión (Riedel, 1929), ocurrido durante el Eoceno tardío-Oligoceno a lo largo de sus principales fallas (Mpodozis *et al.*, 1993; Maksaev y Zentilli, 1999).

Esta cobertura corresponde a una compilación de las estructuras del Mapa Geológico de Chile, 2003 (Sernageomin) y estructuras Niemeyer, 2008 (Figura 7). Las fallas fueron categorizadas según su rumbo y estandarizadas (Niemeyer y Urrutia, 2009), para posteriormente realizar un análisis AHP, con el fin de obtener un ráster de favorabilidad de fallas geológicas para identificar prospectos mineros (Figura 14).




Figura 7. Fallas geológicas, categorizadas y estandarizadas para blancos de exploración (Niemeyer y Urrutia, 2009), del área de estudio.

Geofísica

El principal uso de la geofísica en la exploración minera y, específicamente, en la identificación de pórfidos cupríferos es su aplicación en la detección de anomalías y en la presencia de magnetita hidrotermal o destrucción de minerales magnéticos (Piñana y Vivallos, 2015) por alteración fílica.

Para este trabajo, se cuenta con un dato aeromagnético de la zona de estudio (Figura 8) y con lineamientos geofísicos (magnéticos y señal analítica) que fueron categorizados y estandarizados según el rumbo utilizado en las clases de las fallas geológicas de este estudio (Mpodozis *et al.*, 1993; Makshev y Zentilli, 1999), para posteriormente generar mediante AHP un modelo de Favorabilidad geofísica para blancos de exploración (Figura 15).

AHP a variables blancos de exploración (targets)

Una vez que se tienen los resultados de las cinco variables de blancos de exploración (targets), se procede a la realización mediante análisis multicriterio (AHP), para obtener el ráster de Blancos de Exploración de recursos minerales metálicos. En resumen, es la suma de todas las variables por un peso según importancia prospectiva. Cabe señalar que las variables vienen estandarizadas y normalizadas en escala de 0 a 1, por lo que se procede a construir la matriz de asignación de pesos a cada variable (Tabla 5).

Los ráster que serán utilizados en la matriz son los siguientes:

- Favorabilidad Geológica para blancos de exploración;
- Favorabilidad Alteración para blancos de exploración;
- Favorabilidad Franjas Metalógicas para blancos de exploración;
- Favorabilidad Fallas Geológicas para blancos de exploración;
- Favorabilidad de Lineamientos geofísicos para blancos de exploración.




Figura 8. Fallas geológicas, categorizadas y estandarizadas para blancos de exploración (Niemeyer y Urrutia, 2009), del área de estudio.

	Geología	Alteración	Franjas Metal	Geofísica	Estructuras
Geología	1	3	5	3	5
Alteración	0.333333333	1	3	3	3
Franjas Metal	0.2	0.2	1	0.333333333	0.333333333
Geofísica	0.333333333	0.333333333	3	1	3
Estructuras	0.2	0.333333333	3	0.333333333	1
Suma	2.066666667	4.866666667	15	7.666666667	12.33333333

	Geología	Alteración	Franjas Metal	Geofísica	Estructuras	Peso
Geología	0.483870968	0.61643836	0.333333333	0.39130435	0.40540541	0.446
Alteración	0.161290323	0.20547945	0.2	0.39130435	0.24324324	0.240
Franjas Metal	0.096774194	0.04109589	0.066666667	0.04347826	0.02702703	0.055
Geofísica	0.161290323	0.06849315	0.2	0.13043478	0.24324324	0.161
Estructuras	0.096774194	0.06849315	0.2	0.04347826	0.08108108	0.098
						1

Tabla 5. Matriz de cálculo de pesos de las variables resultantes, realizado a los 5 ráster de favorabilidad para blancos de exploración.

De estos pesos se obtiene un mapa que muestra las zonas más idóneas para realizar exploración geológica y minera. Producto que se le denomina, Blancos de Exploración de Recursos Minerales Metálicos (Figura 16).

Geoquímica

La geoquímica como insumo para determinar blancos de exploración geológica resulta un método indirecto, ya que generalmente el blanco de interés se encuentra definido con anterioridad y, por lo tanto, la geoquímica de superficie es un validador de un blanco. Cabe señalar que su principal ventaja, es la rapidez de los resultados y es de los menos costosos económicamente en la exploración.

Es importante señalar que la geoquímica se ocupa de determinar la abundancia relativa y absoluta de los elementos de la tierra y del estudio de su distribución y dispersión (Rose *et al.*, 1979).

Para este estudio, se cuenta con 1567 muestras de roca de superficie (Figura 9) con los datos de concentración de Cu. Corresponden a diversas campañas realizadas durante más de 15 años, representando un dato duro en toda el área de estudio. Debido a que no tienen una continuidad espacial, por ser de distintos proyectos, su distribución es muy aleatoria y genera zonas con agrupamientos de datos (clúster), lo que imposibilitó realizar una interpolación con los datos (Figura 10).




Figura 9. Distribución de las muestras de roca, se puede apreciar los clústeres con datos (izquierda) y las concentraciones de Cu en el área de estudio (derecha).




Figura 10. Interpolación Kriging del Cu en el área de estudio.

Sin embargo, se cambia la estrategia y no es utilizada como otra de las variables para determinar los blancos de exploración, por el contrario, se aplica para predecir el Cu en el área de estudio, a través de Machine Learning (usando el software R Studio), por medio de una regresión lineal.

El objetivo es obtener un ráster complementario al de los blancos de interés, para generar un nuevo producto que considere el resultado del análisis multicriterio (AHP) de las variables vistas anteriormente (Geología, Alteración, Fallas, Franjas y Geofísica), más el resultado de la predicción del Cu.

De esta forma, lo primero que se realiza es un cruce de la ubicación de las muestras de Cu con las firmas espectrales de la imagen utilizada en este trabajo, es decir, cada punto se cruza con las 18 bandas de la imagen Landsat 8+SAR+índices y se obtiene el valor píxel de esa intersección para cada muestra (Tabla 6).

Tabla 6: Resultado del cruce de las muestras de roca (Cu) y las firmas espectrales de la imagen Landsat 8+SAR+índices

x	y	Cu_PPM	L8_SAR_GEE_PSA056_AOI.1	L8_SAR_GEE_PSA056_AOI.2	L8_SAR_GEE_PSA056_AOI.3	L8_SAR_GEE_PSA056_AOI.4	L8_SAR_GEE_PSA056_AOI.5	L8_SAR_GEE_PSA056_AOI.6	L8_SAR_GEE_PSA056_AOI.7	L8_SAR_GEE_PSA056_AOI.8	L8_SAR_GEE_PSA056_AOI.9	L8_SAR_GEE_PSA056_AOI.10	L8_SAR_GEE_PSA056_AOI.11	L8_SAR_GEE_PSA056_AOI.12	L8_SAR_GEE_PSA056_AOI.13	L8_SAR_GEE_PSA056_AOI.14	L8_SAR_GEE_PSA056_AOI.15	L8_SAR_GEE_PSA056_AOI.16	L8_SAR_GEE_PSA056_AOI.17	L8_SAR_GEE_PSA056_AOI.18
497596	7422560	21	1.211654425	1.711892605	2.21314168	2.461059332	3.342936039	2.819793463	1.826545238	0.662035286	1.711892605	1.952772021	1.510493517	1.358332157	1.185525179	1.000000000	0.822222222	0.644444444	0.466666667	0.288888889
497577	7422460	248	1.111427426	1.600775838	2.099108696	2.303612947	3.213487148	2.607340813	1.888660192	0.653218329	1.600775838	2.007456064	1.530881763	1.394976974	1.23247683	1.069966011	0.907936508	0.745893995	0.583851482	0.421808969
497693	7422364	149	1.148403168	1.649721265	2.046838522	2.22416544	2.996339798	2.64203763	1.782334447	0.683112979	1.649721265	1.816278351	1.463886738	1.347174883	1.134101868	0.921015753	0.708984247	0.496952741	0.284921235	0.072880729
497903	7422224	23	1.387910843	1.935602427	2.425688028	2.787035704	3.85541296	3.342505455	1.747726083	0.629164279	1.935602427	1.991841316	1.589410067	1.383338213	1.153450012	0.924567807	0.705432193	0.486467807	0.267532193	0.048532193
497996	7422435	59	1.054274201	1.503744125	1.921027064	2.150271654	2.929950476	2.755476475	1.822132349	0.655651748	1.503744125	1.948436856	1.525200009	1.362595439	1.063318968	0.802222222	0.599999999	0.397777778	0.195555556	0.093333333
498039	7422437	44	1.148946643	1.633722901	2.109442949	2.413724422	3.297680616	3.037622452	1.835979939	0.639674723	1.633722901	2.018506765	1.56329453	1.366220832	1.085612416	0.822222222	0.622222222	0.422222222	0.222222222	0.022222222
497776	7422521	34	1.00602448	1.384869456	1.605352044	1.675778031	2.067619085	1.97359252	1.59573853	0.776425421	1.384869456	1.493806468	1.287953734	1.233826399	1.04764235	0.84764235	0.64764235	0.44764235	0.24764235	0.04764235
497625	7422607	276	1.251791239	1.759145141	2.265845299	2.516148329	3.158973932	2.705511093	1.810082436	0.712727258	1.759145141	1.795743823	1.394170165	1.255480051	1.167607069	0.967607069	0.767607069	0.567607069	0.367607069	0.167607069
497531	7422558	28	1.350437641	1.938879848	2.744907141	2.883957624	4.067627907	2.647017002	2.032605648	0.674817681	1.938879848	2.097926855	1.481881738	1.410432577	1.536683679	1.536683679	1.536683679	1.536683679	1.536683679	1.536683679
497304	7422629	29	1.174731016	1.645480394	2.10003376	2.447278261	3.449846268	2.67243433	1.787672043	0.608732581	1.645480394	2.096558009	1.642757535	1.409666538	1.29090035	1.174731016	0.952468984	0.730186968	0.507904952	0.285622936
497267	7422742	271	1.352369666	1.850377798	2.393153906	2.812944889	4.044064999	3.020493269	1.769600391	0.591769397	1.850377798	2.185534716	1.689847469	1.437662363	1.338875651	1.133887565	0.933887565	0.733887565	0.533887565	0.333887565
497613	7422916	14	1.716517568	2.429037809	3.332403421	3.797752142	4.522161484	3.432186365	1.94137454	0.736904979	2.429037809	1.861708999	1.357027054	1.190746903	1.31757462	1.190746903	1.190746903	1.190746903	1.190746903	1.190746903
497942	7422666	13	1.027114034	1.451622367	1.769101977	1.968177795	2.350529671	2.156645298	1.722400784	0.752639711	1.451622367	1.619243264	1.328656912	1.194266915	1.089900851	0.974266915	0.858866915	0.743426915	0.627986915	0.512546915
497863	7420643	18	1.867644072	2.538650513	3.538702965	4.120485783	4.976629257	3.611738443	1.894741654	0.711064219	2.538650513	1.960344434	1.406342745	1.207777262	1.377904058	1.377904058	1.377904058	1.377904058	1.377904058	1.377904058
498116	7420376	7	1.85263896	2.461926937	3.197824478	3.586183548	4.110561848	2.788671494	1.726091504	0.777953148	2.461926937	1.669652224	1.285424471	1.146221876	1.474021554	1.474021554	1.474021554	1.474021554	1.474021554	1.474021554

Luego, se entrena el modelo de regresión con PLS, RF y SVM. Se compara la *performance* de los tres modelos usando el error cuadrático medio (RMSE), dando como mejor resultado el PLS, por tener el menor RMSE (Gráfico 1).




Gráfico 1. RMSE de los valores observados versus los valores predichos.



Finalmente, se procede con PLS a realizar la predicción del Cu sobre la imagen Landsat 8+SAR+índices (Figura 17).

Luego, el resultado de la predicción del Cu se suma al resultado del análisis multicriterio de todas las variables (Blancos de Exploración de Recursos Minerales Metálicos), y se obtiene la intersección de los productos para finalmente tener una cobertura vectorial (shape) correspondiente a los mejores blancos prospectivos para la exploración minera, entre los 21°30' y los 23°30' de latitud sur, de la Región de Antofagasta (Figura 18).

RESULTADOS

A continuación, se mostrarán los resultados obtenidos para cada variable de este trabajo.




Figura 11. Mapa de Favorabilidad geológica, se aprecian en naranjos y rojo las zonas con potencial prospectivo.




Figura 12. Mapa de Favorabilidad de Alteración Hidrotermal, se aprecian en amarillos, naranjos y rojo las mejores zonas con potencial prospectivo.




Figura 13. Mapa de Favorabilidad de Franjas Metalogénicas, se destacan en colores azules y celestes oscuros las mejores zonas con potencial prospectivo.




Figura 14. Mapa de Favorabilidad de Fallas Geológicas, se destacan en colores amarillos, naranjos y rojo las principales estructuras (Traza Falla Oeste) que contienen mineralización.




Figura 15. Mapa de Favorabilidad de Lineamientos magnéticos, se destacan en colores naranjos y rojo el límite entre un bajo y un alto magnético, característicos de los yacimientos de esta zona.




Figura 16. Mapa de áreas prospectivas de recursos minerales metálicos, se destaca en color naranjos y rojos las zonas de mejor ponderación (derecha), se valida el resultado con la incorporación de los principales yacimientos del área como; Chuquibambilla, Spence, Sierra Gorda, entre otros (centro), se cargan las áreas del Sistema de Información Geológica de Exploración (SIGEX) reportados entre el 2013 y el 2017 del Sernageomin, para ver que se ha explorado de los blancos obtenidos.




Figura 17. Mapa de predicción del Cu en superficie, en color rojo destaca las zonas de mayor interés (derecha) y se valida el resultado con la incorporación de los principales yacimientos del área (izquierda).




Figura 18. Definición de blancos de interés para exploración minera, se obtiene con la suma del mapa de áreas prospectivas más el de predicción del Cu, definiendo varios lugares de interés para posibles futuros yacimientos.

CONCLUSIONES

El presente estudio(*) utilizó como estructura de análisis una rama de la inteligencia artificial (Machine Learning) y el análisis multicriterio, para determinar blancos de exploración minera.

Cabe señalar que la exploración geológica en Chile tiene una metodología de trabajo muy madura y que ha sido probada durante décadas con excelentes resultados, Chuquicamata, El Teniente, Collahuasi, Spence, Gaby, solo por nombrar algunos. Así también, como ha habido éxitos, también hay muchos proyectos que no estuvieron a la altura de lo que se requería y en la evaluación fueron descartados, por tener un bajo interés prospectivo. Las razones son múltiples, por ejemplo, malos resultados de las campañas de sondaje, por las bajas leyes del mineral, por encontrarse cubierto el yacimiento (potencial profundo), entre otras. Cada una de estas operaciones involucran millones de pesos a los inversionistas, los que cada vez están más conservadores a la hora de explorar, por los factores mencionados anteriormente.

En este contexto, el estudio se enfocó en dar una mirada a la utilización de los datos y analizarlos en múltiples dimensiones y niveles. Gran parte de las empresas cuentan con grandes repositorios de datos que generalmente son analizados de forma aislada, sin extrapolarlos a otras variables y quedando la mayoría de las veces almacenados en los datos históricos de una empresa. Sin embargo, la utilización del Machine Learning ofrece una nueva perspectiva, ya que permite analizar datos a partir de datos, correlacionándolos, extrayendo información, clasificándolos, clusterizando o realizando regresiones. Es decir, este tipo de modelos permite obtener nuevos resultados y una nueva mirada de los datos, a través de la programación de algoritmos que interrelacionen la información de las variables. El Machine Learning construye un algoritmo a medida de cada necesidad, con las variables y dimensiones que sean requeridas.

Este trabajo no consideró otros niveles de datos, que hubiesen nutrido aún más el modelo predictivo como, por ejemplo, información de sondaje, imágenes hiperespectrales, medición estructural, espectrómetro de minerales (Terraspec), por nombrar algunas. Por lo tanto, el método tiene la capacidad de hacer análisis y cruce de las variables con la información que esté disponible. El algoritmo permite la parametrización de todas las variables, así como el ajuste de la *performance* del modelo.

Con respecto a los resultados obtenidos, lo primero que resalta es que tanto en el análisis multicriterio como en la predicción con Machine Learning del Cu, se destacan los grandes yacimientos del área: Chuquicamata, Sierra Gorda, Spence, Esperanza, Gaby, El Abra, Distrito Centinela, Radomiro Tomic, Mansa Mina y Polo Sur. Esto sirve como primer validador del modelo. Un segundo elemento validador es la incorporación de los proyectos reportados por las empresas entre el 2013 y el 2017 a Sernageomin a través de SIGEX, donde algunos de estos proyectos fueron trabajos de exploración en los blancos obtenidos en los resultados de este trabajo.

Para finalizar, es importante señalar que el uso de inteligencia artificial, específicamente en trabajos de exploración geológica, requiere de toda la información que esté disponible para el proyecto, y que se encuentre espacialmente bien ubicada, para que el modelo sea coherente. Toda esta información sustenta al algoritmo predictivo, ya que, si hay inconsistencias en la información ingresada al modelo, este va a predecir erróneamente y los resultados serán incorrectos. Resulta también fundamental contar con especialistas, cuyo conocimiento geológico permita ir parametrizando, ajustando y evaluando el modelo resultante.

<https://www.sernageomin.cl/sigex/>

(*) El autor agradece a la Geóloga Paula Muñoz (Universidad de Chile), Sumitomo Metal Mining Chile, por su apoyo en el desarrollo de este trabajo de investigación.

REFERENCIAS

1. Aguilar, J. (2008). Caracterización Geotécnica y Estructural de La Rampa de Exploración y del Túnel de Drenaje, Mina Chuquicamata (Tesis de pregrado, Universidad de Chile).
2. ASF DAAC 2015, contains modified Copernicus Sentinel data 2019, processed by ESA.
3. Astudillo, N. (2008). Mineralogía Magnética y Paleomagnetismo en los Mega yacimientos tipo Pórfido-Cuprífero Chuquicamata y El Teniente, Chile (Tesis de doctorado, Universidad de Chile).
4. Camus I., F. 2003. Geología de los sistemas porfíricos en los Andes de Chile. SERNAGEOMIN: 267 p., il; fot.col., Santiago.
5. Gad, S. & T. Kusky (2006). Lithological mapping in the Eastern Desert of Egypt, the Barramiya area, using Landsat thematic mapper (TM). *Journal of African Earth Sciences*, 44(2): 196-202.
6. Gorelick, N., M. Hancher, M. Dixon, S. Ilyushchenko, D. Thau, & R. Moore (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*.
7. Lowell, J.D. & J.M. Guilbert (1970) Lateral and Vertical Alteration-Mineralization Zoning in Porphyry Ore-Deposits. *Economic Geology*, 65, 373-408.
8. Maksaev, V., B. Townley, C. Palacios, & F. Camus (2007). Metallic ore deposits. In *The Geology of Chile* (Moreno, T.; Gibbons, W.; editors). The Geological Society, London: 179-199. London.
9. Maksaev, V. & M. Zentilli (1999). Fission track thermochronology of the Domeyko Cordillera, Northern Chile: implications for Andean tectonics and porphyry copper metallogenesis. *Exploration and Mining Geology* 8 (1-2): 65-89.
10. Mpodozis, C.; N. Marinovic, & I. Smoje (1993). Eocene left lateral Strike-Slip faulting clockwise block rotations in the Cordillera de Domeyko, West of Salar de Atacama, Northern Chile. In *Symposium Andean Geodynamics*, No. 2: 225-228. Oxford, U.K.
11. Niemeyer, H. & Urrutia, C. (2009). Transcurrencia a lo largo de la Falla Sierra de Varas (Sistema de fallas de la Cordillera de Domeyko), norte de Chile. *Andean Geology*. 36. 37-49.
12. Ossandón G, R. Fréaut, LB. Gustafson, DD. Lindsay, & M. Zentilli (2001) Geology of the Chuquicamata Mine: A progress report: *Economic Geology* 96: 351-366.
13. Piñana, X. y J. Vivallos (2015). Relación entre mineralización y anomalías magnéticas entre los 25° y 26°S de Chile: Cordillera de la Costa y sector occidental de la Cordillera de Domeyko. *Congreso Geológico Chileno*, 14, La Serena, Chile, 4 - 8 octubre 2015, 2015, pp.180-183 (v.2)
14. Rose, A. W., H. E. Hawkes, & J. S. Webb (1979). *Geochemistry in Mineral Exploration*. Second edition. xvii + 657 pp.
15. Riedel, W. (1929): Zur Mechanik geologischer Brucherscheinungen. - *Zentralblatt fuer Mineralogie, Geologie und Palaeontologie* p.354-368 Stuttgart.
16. RStudio Team (2020). RStudio: Integrated Development for R. RStudio, PBC, Boston, MA URL. <http://www.rstudio.com/>
17. Sabins, F.F. (1999). Remote Sensing for mineral exploration. *Ore Geology Review*, 14(3-4): 157-183.
18. Sillitoe, R. & J. Perelló (2005). Andean copper province: Tectonomagmatic settings, deposit types, metallogeny, exploration, and discovery. *Economic Geology 100th Anniversary Volume*. 845-890.
19. Sovann, P. & Ch. Aing (2015). InVEST Implementation in the Eastern Plain Landscape: An InVEST Land Use/ Land Cover Map Preparation for Mondulkiri Province. 10.13140/RG.2.2.11658.31687.

20. Sultan, M., R.E. Arvidson, N.C. Sturchio (1986). Mapping of serpentinites in the Eastern Desert of Egypt using Landsat Thematic Mapper data. *Geology* 14, 995–999.
21. Villela, D. y J. Cantallopis (2016). Franjas metalogénicas de los Andes Centrales: blancos clave para la exploración minera. URL <https://www.cochilco.cl/Paginas/Inicio.aspx>

Hugo Neira Santander

Cartógrafo (UTEM), Postítulo en Geomática Aplicada (U. de Chile), Diplomado en Medioambiente y Ordenamiento Territorial, *"en curso"* (U. de Chile).

Especialista en modelos predictivos con Machine Learning, aplicado a la geología y minería. Durante seis años se desempeña como Encargado de la Unidad de Cartografía en el Departamento de Geología Aplicada del Servicio Nacional de Geología y Minería (SERNAGEOMIN).

Actualmente, se desempeña en la labor de GIS Manager de la Compañía Minera Sumitomo Metal Mining Chile.

Se sugiere citar:

Neira Santander, H. (2021). Análisis Multicriterio y Predicción con Machine Learning para determinar blancos de exploración de recursos minerales metálicos tipo pórfidos cupríferos, depósitos Cu-(Mo), en la franja Paleoceno – Oligoceno entre 21°30'S y 23°30'S de la Región de Antofagasta, Chile. *Revista Cartógrafo.CL* 1(1), pp. 77-98.



Bajo Licencia Creative Commons
Atribución 4.0 Internacional.