



UNIVERSIDAD DE CHILE
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
DEPARTAMENTO DE INGENIERÍA DE MINAS

DETERMINACIÓN DE MALLA ÓPTIMA DE PERFORACIÓN Y MUESTREO PARA UN DEPÓSITO AURÍFERO VETIFORME

TESIS PARA OPTAR AL GRADO DE MAGÍSTER EN MINERÍA

MARC ETIENNE MEULLE-STEF DURÁN

PROFESOR GUIA:
XAVIER EMERY

MIEMBROS DE LA COMISIÓN:
NADIA MERY GUERRERO
BRIAN TOWNLEY CALLEJAS
MOHAMMADALI MALEKITEHRANI

SANTIAGO DE CHILE

2024

Resumen

Los depósitos auríferos vetiformes suelen presentar una alta variabilidad, lo que genera gran dificultad para interpretar y modelar el comportamiento de las leyes del elemento de interés. A raíz de esto, surge la necesidad de generar una metodología que permita determinar el espaciamiento óptimo del muestreo para minimizar la incertidumbre y facilitar la categorización de los recursos minerales dentro del depósito.

En un escenario de recursos económicos limitados, las campañas de sondaje deben ser planificadas rigurosamente con el fin de obtener el máximo de información de tal manera que permita convertir asertivamente los recursos minerales inferidos en medidos e indicados. Con base en lo anterior, se debe conjugar la intención de capturar la mejor información con abarcar la mayor área posible.

En este trabajo se toma como caso de estudio una veta aurífera del Distrito Minero Alhué, ubicado en la zona central de Chile, a la cual se le efectúa un análisis geoestadístico paso a paso con el fin de determinar la incertidumbre, generar una guía para categorizar sus recursos minerales y finalmente establecer la configuración óptima del espaciamiento del muestreo.

La metodología propuesta consiste en preparar la base de datos de sondajes y canaletas para generar simulaciones mutigaussianas en un soporte puntual que representan diversos escenarios posibles de la realidad, luego generar puntos de muestreo artificial a un espaciamiento cuadrado de 15 m, 20 m, 30 m y 45 m y a estas muestras asignarle la ley entregada por una simulación en ese punto. A continuación, se realiza la predicción de la variable mediante kriging ordinario con cada una de las mallas performadas y el resultado se contrasta contra la distribución de los distintos escenarios. Finalmente, se propone un método de categorización de recursos minerales que considera como medidos todos aquellos bloques cuya ley difiere menos del 10% respecto al promedio de las simulaciones, mientras que, se considera como indicado a los bloques cuya ley difiere entre un 10-30% respecto a las simulaciones, finalmente los bloques que difieren más de un 30% se consideran inferidos. Dado que la distribución de las leyes de oro presenta alta variabilidad, se genera el mismo análisis de manera indirecta, a través de las variables acumulación y potencia, que presentan mayor continuidad espacial.

Por medio de la metodología indirecta, se determina que es posible emplear dos configuraciones de mallas para el muestreo en este tipo de depósito, sin disminuir la confianza en la categorización de recursos minerales. En primer lugar, se recomienda emplear una malla cuadrada de 30 m para las zonas de baja acumulación ya que presentan menor variabilidad, e incluso hasta 35 m de separación en zonas que se deseen descartar por el bajo contenido de oro o potencia. Luego, se recomienda emplear una malla cuadrada de 20 m en las zonas de mayor acumulación o como máximo 25 m para las zonas aledañas a sectores de baja acumulación.

Tabla de Contenido

1.	Introducción	1
1.1.	Objetivos	1
1.1.1.	Objetivos específicos	2
1.2.	Hipótesis, alcances y aportes.....	2
2.	Antecedentes del caso de estudio	3
3.	Estado del arte y trabajos anteriores.....	9
3.1.	Simulaciones y cuantificación de incertidumbre.....	9
3.2.	Categorización de Recursos.....	11
3.3.	Optimización de muestreo	13
3.4.	Análisis indirecto	16
3.5.	Novedad y aporte de este trabajo	16
4.	Metodología.....	17
5.	Desarrollo	19
5.1.	Análisis directo en 3D.....	19
5.2.	Análisis Indirecto en 2D	28
4.2.1.	Predicción mediante Cokriging	29
4.2.2.	Predicción mediante Cosimulaciones	32
5.3.	Categorización de recursos minerales.....	39
4.3.1.	Categorización de recursos minerales con metodología directa	40
4.3.2.	Categorización de recursos minerales con metodología indirecta	42
6.	Discusión	44
7.	Conclusión	47
8.	Bibliografía	48

Índice de Figuras

Figura 1: Ubicación distrito minero Alhué	3
Figura 2A: Análisis de blanco en laboratorio propio.....	5
Figura 2B: Análisis de blanco en laboratorio externo.	5
Figura 3A: Análisis de estándar en laboratorio propio.	5
Figura 3B: Análisis de estándar en laboratorio externo.....	5
Figura 4: Resultado del modelamiento de veta de oro.....	6
Figura 5: Resultado estimación de leyes de oro junto con las muestras empleadas.....	7
Figura 6: Resultado categorización de recursos bajo criterio expertol.....	8
Figura 7: Diferencia entre resultado de estimación y de simulaciones.....	9
Figura 8: Ejemplo de transformación <i>normal score</i>	11
Figura 9: Intervalos definidos para categorización de recursos minerales.....	18
Figura 10: límites del área a estudiar.	19
Figura 11: Frecuencia acumulada para leyes del área de estudio.....	20
Figura 12: Modelo de transformación gaussiano para muestras 3D.....	20
Figura 13A: Nube de correlación diferida para lag de 10 m en escenario 3D.	21
Figura 13B: Nube de correlación diferida de 100 m en escenario 3D.....	21
Figura 14: Variograma tradicional contra variograma de indicadores 3D.....	21
Figura 15: Análisis de rodograma y madograma 3D.	22
Figura 16: Variograma modelado 3D.	23
Figura 17: Gráfico de validación cruzada para el oro.	23
Figura 18: <i>Accuracy plot</i> para plan de simulación 3D.....	24
Figura 19: Gráfico de validación cruzada para oro predicho y real en entorno3D.	24
Figura 20: Ejemplo del resultado de las simulaciones efectuadas.....	25
Figura 21: Mallas sintéticas 3D con ley proveniente de simulación.	26
Figura 22: Variograma modelado a partir de malla sintética.	27
Figura 23: Nube de correlación entre oro real y predicho.	27
Figura 24: Resultado de predicción de oro mediante kriging ordinario con mallas 3D.....	28
Figura 25: Variograma experimental de los datos directos y conjunto.....	30
Figura 26: Variogramas modelados directos y conjunto.	30
Figura 27A: Nube de correlación para potencia.....	31
Figura 27B: Nube de correlación para acumulación.....	31
Figura 28A: Predicción Potencia.....	32
Figura 28B: Predicción Acumulación.....	32
Figura 29A: Modelo de transformación gaussiano para muestras de acumulación 2D.	32
Figura 29B: Modelo de transformación gaussiano para muestras de potencia 2D.	32
Figura 30A: Nube de dispersión de potencia y acumulación a un espaciamiento de 4 m... 33	
Figura 30B: Nube de dispersión de potencia y acumulación a un espaciamiento de 40 m. 33	
Figura 31A: Variograma contra variograma de indicadores 2D de potencia.	33
Figura 31B: Variograma contra variograma de indicadores 2D de acumulación.	33
Figura 32A: Análisis de rodograma y madograma 2D para potencia.	34
Figura 32B: Análisis de rodograma y madograma 2D para acumulación.	34
Figura 33: Modelo variográfico gaussiano conjunto en 2D para acumulación y potencia. . 35	
Figura 34A: <i>Accuracy plot</i> para plan de simulaciones de potencia 2D.	35
Figura 34B: <i>Accuracy plot</i> para plan de simulaciones de acumulación 2D.	35

Figura 35A: Gráfico de validación cruzada de potencia en entorno 2D.....	36
Figura 35B: Gráfico de validación cruzada de acumulación en entorno 2D.....	36
Figura 36A: Ejemplo de la distribución de potencia obtenida mediante las simulaciones.	36
Figura 36B: Distribución de acumulación obtenida mediante simulaciones.	36
Figura 37: Mallas sintéticas 2D con acumulación proveniente de simulación.	37
Figura 38: Modelo variográfico acumulación.	38
Figura 39: Nube correlación acumulación	38
Figura 40: Predicción de acumulación mediante kriging ordinario con mallas 2D..	39
Figura 41: Resultado de categorización 3D resultantes de las diversas mallas	40
Figura 42: Distribución porcentual de mineral según categoría por cada malla 3D.	41
Figura 43: Resultado de categorización 2D resultantes de las diversas mallas.	42
Figura 44: Distribución porcentual de onzas de oro según categoría para cada malla	43
Figura 45: Distribución de acumulación cubierta por sombra de recursos medidos e indicados.....	45
Figura 46: Halo de influencia de cada sondaje. A- Configuración de alta variabilidad en acumulación con malla 20 m. B- Configuración baja variabilidad en acumulación con malla 30 m.....	46

Índice de Tablas

Tabla 1A: Resumen análisis de blanco en laboratorio propio.	4
Tabla 1B: Resumen análisis de blanco en laboratorio propio.	4
Tabla 2: Resumen análisis de estándar en ambos laboratorio.	5
Tabla 3: Estadística básica de las muestras	20
Tabla 4: Plan de kriging para escenario 3D.	22
Tabla 5A: Estadística básica de la distribución de errores.	23
Tabla 5B: Estadística básica de la distribución de errores estandarizados.	23
Tabla 6: Parámetros empleados para simulaciones 3D.	25
Tabla 7: Plan de kriging para mallas sintéticas 3D.	27
Tabla 8A: Estadística básica de la distribución de errores.	27
Tabla 8B: Estadística básica de la distribución de errores estandarizados.	27
Tabla 9: Superior, estadísticas básicas. Inferior, correlación entre variables.	29
Tabla 10: Plan de cokriging para potencia y acumulación.	31
Tabla 11: Estadísticas básicas de los errores.	31
Tabla 12: Plan de cokriging para valores gaussianos de acumulación y potencia	34
Tabla 13: Parámetros cosimulaciones entre potencia y acumulación.	36
Tabla 14: Plan de kriging para acumulación	38
Tabla 15A: Estadística básica de la distribución de errores.	39
Tabla 15B: Estadística básica de la distribución de errores estandarizados.	39
Tabla 16: Cuantificación de los recursos de oro según su categorización 3D.	41
Tabla 17: Acumulación por malla y cuantificación por categoría.	43
Tabla 18: Onzas de oro por malla y categoría a partir de variable acumulación.	43
Tabla 19: Costo/beneficio de cada bloque según su destino.	45

1. Introducción

La minería ha logrado un nivel de perfeccionamiento tal que, para la evaluación de los recursos minerales de un yacimiento y sus reservas subsecuentes, es mandatorio contar con una guía para la medición de la incertidumbre asociada a la estimación y categorización de los mismos, y que, además, dicha incertidumbre responda a metodologías establecidas y replicables, más que al criterio de un experto. Es así como el código de reportabilidad JORC, cuyo propósito es definir un estándar mínimo para informar los resultados de la exploración, recursos y reservas de manera transparente, exige la categorización por medio de algún criterio estadístico y la cuantificación de los errores asociados (Ortiz y Emery, 2004).

La categorización de los recursos minerales en medidos, indicados e inferidos es algo controversial, puesto que existe más de una alternativa para realizarla y cada compañía minera cuenta con sus propios métodos. Entre las técnicas más comunes se encuentra: la distancia entre el bloque estimado y la muestra más cercana; la cantidad de muestras consideradas en la estimación del bloque; los alcances del variograma; la varianza del kriging; la incertidumbre asociada a la estimación de cada bloque por medio de simulaciones condicionales; entre algunos otros.

Como es sabido, si se requiere un mayor grado de certeza en los recursos se debe realizar campañas de perforación de sondajes para obtener más muestras, sin embargo, efectuar una campaña de sondajes extremadamente densa resulta costoso, poco operacional y de no ser bien planificada, la información obtenida podría resultar poco influyente (sobre-muestreo de algunas zonas o bien perforaciones lejanas que no permiten disminuir la incertidumbre). A raíz de lo anterior, se vuelve necesario efectuar una buena planificación del espaciamiento que deben tener las muestras para entregar el máximo de información. La mejor manera de obtenerlo es a través de la técnica geoestadística de simulaciones condicionales que hoy en día se posiciona como una metodología de vanguardia para generar un escenario posible de la realidad con el cual se puede determinar la incertidumbre y riesgo asociado a las estimaciones.

1.1. Objetivos

El objetivo de este estudio comprende la definición de una metodología que permita la determinación de la malla óptima de perforación para el muestreo de un depósito aurífero vetiforme, de tal manera de obtener la menor incertidumbre entre muestras y con ello conseguir una categorización como mínimo de recursos indicados sin perder operatividad ni descuidar los costos.

1.1.1. Objetivos específicos

- A. Cuantificar la incertidumbre de manera directa en escenario 3D por medio de simulaciones multigaussianas para 4 espaciamentos teóricos de muestreo.
- B. Cuantificar incertidumbre de manera indirecta en escenario 2D por medio de simulaciones multigaussianas para 4 espaciamentos teóricos de muestreo.
- C. Generar un criterio para la categorización de los recursos minerales basado en la distribución de frecuencia de las medias.
- D. Determinar espaciamiento óptimo para las perforaciones.

1.2. Hipótesis, alcances y aportes

Se plantea como hipótesis que es posible lograr una determinación predictiva de la anisotropía y continuidad de la distribución de leyes de oro para la optimización de las mallas de exploración y mejora de categorización de recursos minerales mediante el uso de técnicas de evaluación empleando simulaciones condicionales.

Para este estudio se utiliza como caso base una veta angosta de oro perteneciente al distrito minero Alhué (Región Metropolitana, Chile), que es explotada por medio del método subterráneo de *sublevel stoping* y que cuenta con muestras de sondajes y de canaletas de avance obtenidas bajo estricto control de QA/QC.

El aporte esperado de este trabajo radica en detallar la metodología que permite aplicar técnicas de geoestadística para determinar la incertidumbre en un yacimiento aurífero y con ello establecer un sistema de muestreo óptimo y una guía para la categorización de sus recursos minerales.

2. Antecedentes del caso de estudio

El distrito minero Alhué se ubica 180 km al sur de Santiago (Región Metropolitana, Chile), en la Cordillera de la Costa (Figura 1). En este sector se han descrito rocas volcánicas, volcanoclásticas y sedimentarias: tobas, andesitas, brechas y areniscas, con edades Cretácico Superior a Terciario, que son parte de la unidad informal Estratos Cerro Horcón de Piedra y Loma La Chicharra, correlacionables con la parte media de la Formación Lo Valle, del Cretácico Superior, las cuales son hospedadoras de vetas y brechas hidrotermales ricas en elementos metálicos, tal como, oro, plata, zinc, plomo y cobre (Quintana, 2018).




Figura 1: Ubicación distrito minero Alhué (Quintana, 2018).

Las unidades geológicas principales que albergan la totalidad de la mineralización económica corresponden a vetas silíceas, brechas hidrotermales y/o stockwork, todos de baja potencia (inferior a 3 m). Respecto a la roca caja, suele componerse de tobas y/o andesitas con presencia de vetillas que no revisten valor económico. Como eventos posteriores se observa la intrusión de filones y diques andesíticos, junto con la presencia de algunas fallas intermedias post-mineral.

Para este estudio, se cuenta con muestras de dos orígenes, el primero, de menor escala, corresponde a las muestras de sondajes exploratorios, que no suelen ser regulares en su distribución y tienden a sobremuestrear las zonas de altas leyes para identificar su extensión (interés económico). Y segundo, muestras de canaletas para

el corto plazo, que se obtienen desde las frentes de avances de los túneles en desarrollo y se encuentran separadas 3.3 m.

Los sondajes son perforados con diamantina a diámetros variables desde la superficie e interior mina, se busca interceptar las vetas de manera perpendicular a su rumbo y manteo. Las plataformas de perforación cumplen estándares corporativos de seguridad y de calidad para asegurar que las muestras no sean alteradas durante la operación. La ejecución de los sondajes se realiza por medio de empresas colaboradoras que son monitoreadas por personas calificadas de la empresa mandante. Durante la perforación y obtención de los testigos se controla estrictamente las prácticas operacionales, evitando problemas como alteración, contaminación o rotación de las muestras. Luego los sondajes son mapeados por geólogos especialistas quienes definen la extensión de cada muestra que posteriormente son enviadas a análisis químico en un laboratorio certificado.

Por su parte, la colección de muestras de canaletas se realiza de manera rutinaria disparo-a-disparo y es supervisada por el geólogo de producción quien vela por la correcta ejecución del procedimiento de trabajo. El primer hito a cumplir responde a la demarcación adecuada de las canaletas según las unidades minerales identificadas en la frente de avance (roca de caja, vetilleos y brechas hidrotermales), la extensión máxima de la unidad de muestreo es de 1 m y la mínima es de 0.2 m. La obtención de las muestras se realiza con golpes de combos de 4 libras de manera uniforme dentro los límites demarcados para cada canaleta, todo el material es colectado en un dispositivo llamado “cuna” y posteriormente envasado en bolsas que son selladas y etiquetadas en el acto. Luego se lava el combo y la cuna antes de proceder con la siguiente canaleta. Estas muestras son analizadas por el laboratorio propio.

Luego, con el fin de supervisar el control de calidad de cada laboratorio se envían muestras con leyes conocidas y certificadas para evaluar el sesgo y la exactitud de los resultados. Dentro de cada envío se incluye la inserción de materiales sin ley (blancos) para identificar la existencia de contaminación e incorrecta limpieza de los equipos de análisis entre cada muestra, en las Tablas 1A y 1B se resumen los resultados de los controles y luego en la Figura 2A y 2B se indica el detalle de los resultados obtenidos para los blancos analizados en laboratorio propio y externo de 23 y 31 envíos, respectivamente.

Tabla 1A: Resumen análisis de blanco en laboratorio propio.

Blanco Au Laboratorio Propio				
LD acep.	Media	n	Fuera de Rango	% Fuera de Rango
0.100	0.011	23	0	0.00%
Total:		23	0	0.00%

Tabla 1B: Resumen análisis de blanco en laboratorio propio.

Blanco Au Laboratorio Externo				
LD acep.	Media	n	Fuera de Rango	% Fuera de Rango
0.100	0.012	31	0	0.00%
Total:		31	0	0.00%




Figura 2A: Análisis de blanco en laboratorio propio.

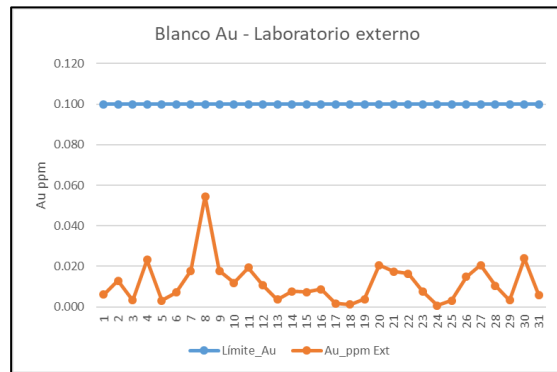


Figura 2B: Análisis de blanco en laboratorio externo.

El otro control empleado consiste en enviar muestras estándar con ley conocida y certificada, junto con duplicados de terreno para evaluar la exactitud de los análisis. En este contexto, se aceptan los resultados si es que el análisis de laboratorio no difiere más de dos desviaciones estándar respecto a la muestra conocida, en caso contrario se solicita reanálisis de todas las muestras involucradas en ese envío. En la Tabla 2 se indica el resumen de los resultados del análisis de muestras conocidas para 23 envíos en laboratorio propio y 31 en laboratorio externo. En las Figura 3A y 3B se grafican los resultados en detalle.

Tabla 2: Resumen análisis de estándar en ambos laboratorio.

Laboratorio	Au_ppm								
	Accept RR	Average Lab	DIF	n	$\geq 2SD / < -3SD$		$\geq 3SD$		% Exactitud_Au
					Out de Range	%Out de Range	Out de Range	%Out de Range	
Externo	1.404	1.380	-0.024	31	1	3.2%	0	0.0%	96.8%
Propio	6.904	6.850	-0.054	23	0	0.0%	0	0.6%	99.4%
Total:				54	1	1.9%	0	0.0%	98.1%



Figura 3A: Análisis de estándar en laboratorio propio.



Figura 3B: Análisis de estándar en laboratorio externo.

Los controles de calidad indicados anteriormente aseguran que la base de datos cuenta con información robusta para ser empleada en el proceso de modelamiento y estimación de los recursos minerales de la compañía.

El modelamiento de los recursos minerales se efectúa mediante la integración de las litologías de interés (vetas, brechas y/o stockwork) en una unidad mineral. Para ello se considera todas las muestras existentes, independiente de su ley. Luego se descuenta el volumen utilizado por filones andesíticos tardíos (Figura 4). En cuanto a la continuidad horizontal, existe buen nivel de información para ajustar el modelo, dado que en los túneles existen muestras de canaletas cada 3.3 m, sin embargo, la continuidad de información en la orientación vertical es inferior puesto que los bancos se separan 20 m entre sí y no necesariamente existe una buena densidad de sondajes para controlar los límites.

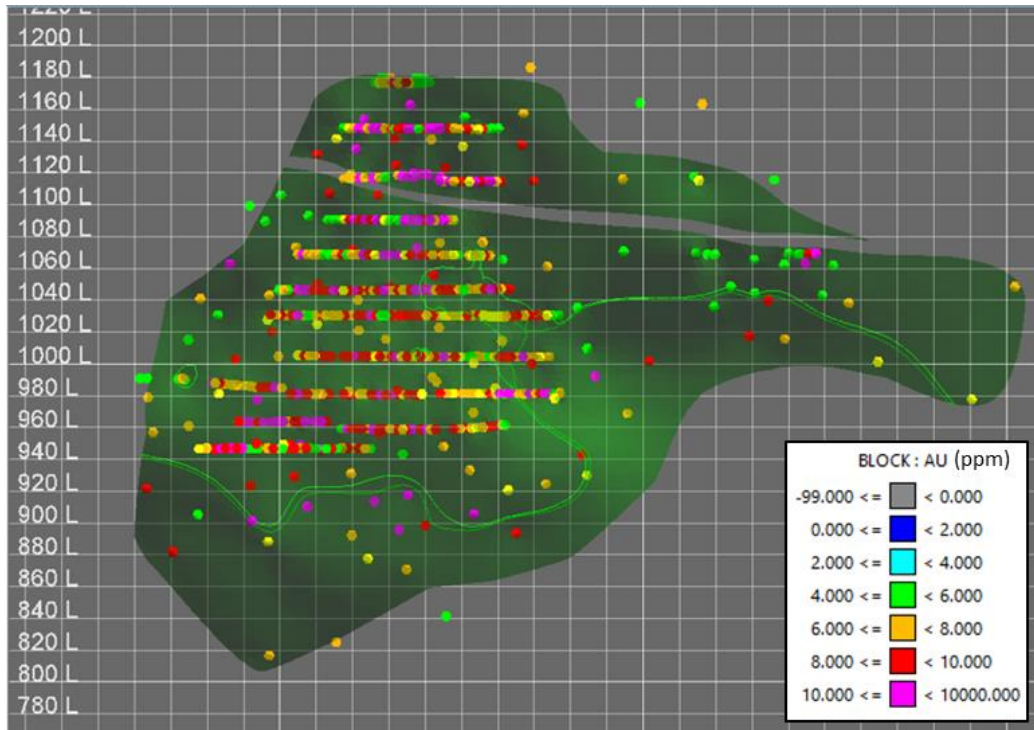


Figura 4: Resultado del modelamiento de veta de oro. Vista longitudinal. Notar que la franja subhorizontal superior corresponde a un filón andesítico post mineral.

Si bien el modelamiento puede ser, en parte, subjetivo y dependiente del experto que lo realice, los resultados operativos obtenidos en la totalidad del depósito demuestran que la metodología empleada es apropiada y se considera como válida para este estudio.

Luego de finalizado y aceptado el modelamiento, se procede a preparar la información para efectuar la estimación de los recursos minerales, para ello, lo primero que se ejecuta es un análisis exploratorio de los datos que ya se encuentran validados por el administrador de las bases de datos. Se presta especial énfasis a la distribución del oro, puesto que es habitual encontrar muestras con valores altamente pepíticos que de no controlarlos generarían una sobreestimación local y artificial de las leyes, lo que puede dar la falsa ilusión de un alto potencial económico para algún sector, que bien podría desencadenar interés para la producción asignándole recursos para explotarlo con resultados bajo lo esperado.

Una vez aceptada la base de datos se lleva a cabo la compositación de las muestras, que en este caso se efectúa mediante la ley media del sitio, ya que esto permite filtrar la alta variabilidad que presentan los datos de oro en el mismo perfil de muestreo, además, con esto se mejora la variografía y la predictibilidad del modelo, se elimina el efecto cuerda y se logra disminuir el efecto pepita. Luego se realiza el desagrupamiento basado en el método de las celdas, que para este depósito es de 30 m x 30 m (Carmona, 2020).

Una vez que la base de datos está compositada y libre de incongruencias, se realiza el análisis variográfico con el fin de obtener el plan de kriging para la estimación de las variables de oro de manera independiente. A contar de este punto se evidencia la baja continuidad espacial y alta variabilidad en la distribución del oro a lo largo del depósito.

En paralelo se genera un modelo de bloques, con tamaño variable de sus bloques para adaptarse a la geometría de veta angosta, ya que si se consideran bloques regulares no captarían la realidad de la potencia de la estructura y por otro lado, si fueran lo suficientemente pequeños como para dar cuenta de la resolución real de la estructura deberían ser de 0.2 m y en este caso la necesidad de recursos de procesamiento por parte de la computadora es demasiado alta, lo que conlleva un aumento significativo en el tiempo de espera y se vuelve extremadamente poco operativo.

Por su parte, la estimación se realiza mediante kriging ordinario en el modelo de bloques creado (Figura 5), considera todas las muestras independientemente de su origen, pero con algunas restricciones en el número máximo y mínimo de ellas empleadas en la predicción de cada bloque.

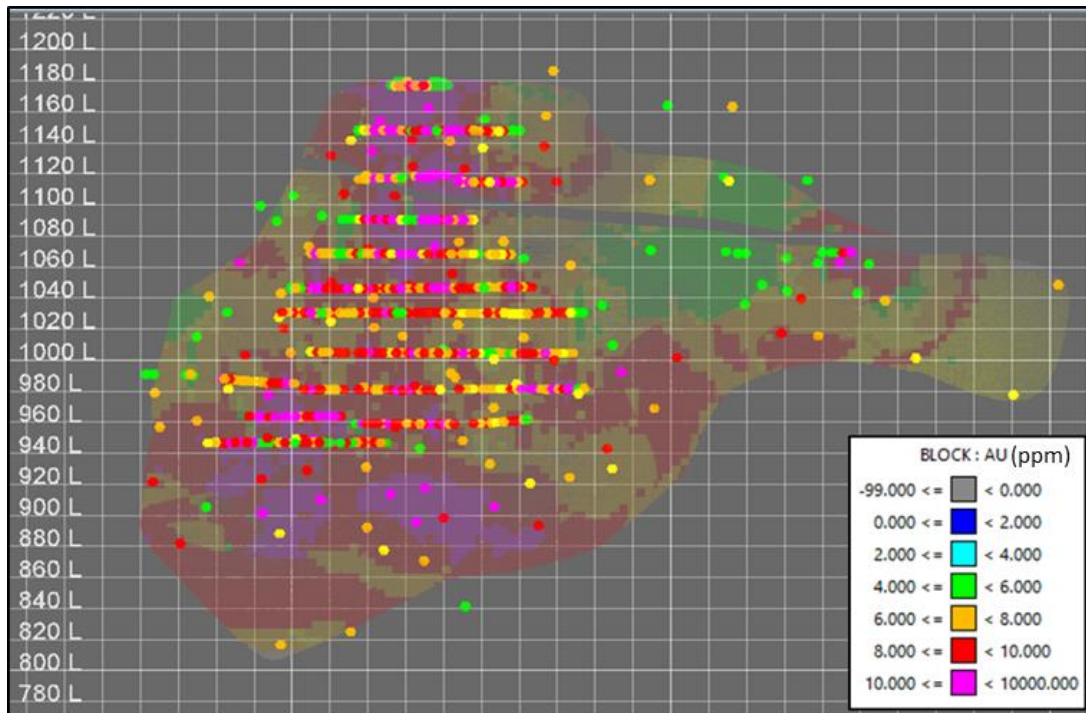


Figura 5: Estimación de leyes de oro con las muestras empleadas. Vista longitudinal.

Finalmente, bajo estándares corporativos y criterio experto se procede a categorizar los recursos según el grado de confianza y nivel de reconocimiento que exista en las labores (Figura 6). No obstante, la principal complicación radica en la cuantificación de la incertidumbre, dado que la mayoría de los métodos suelen ser subjetivos, y se basan por ejemplo en proximidad del bloque con las muestras, cantidad de muestras empleadas en la estimación del bloque, fracción o porcentaje del alcance del variograma, varianza del kriging, entre otros. Como elemento central en cada una de las metodologías de categorización expresadas se encuentra la ubicación de las muestras, por lo que se hace necesario que las campañas de sondajes sean planificadas apropiadamente con el fin de obtener el máximo de información y disminuir la incertidumbre, sin perder operatividad ni aumentar significativamente los costos. Un problema derivado de lo anterior, radica en que solo se utiliza la ubicación de las muestras y no la variabilidad que existe entre sus leyes, las que como indica Emery (2000) presentan mayor variabilidad a mayor ley, generando lo que se define como un efecto proporcional.

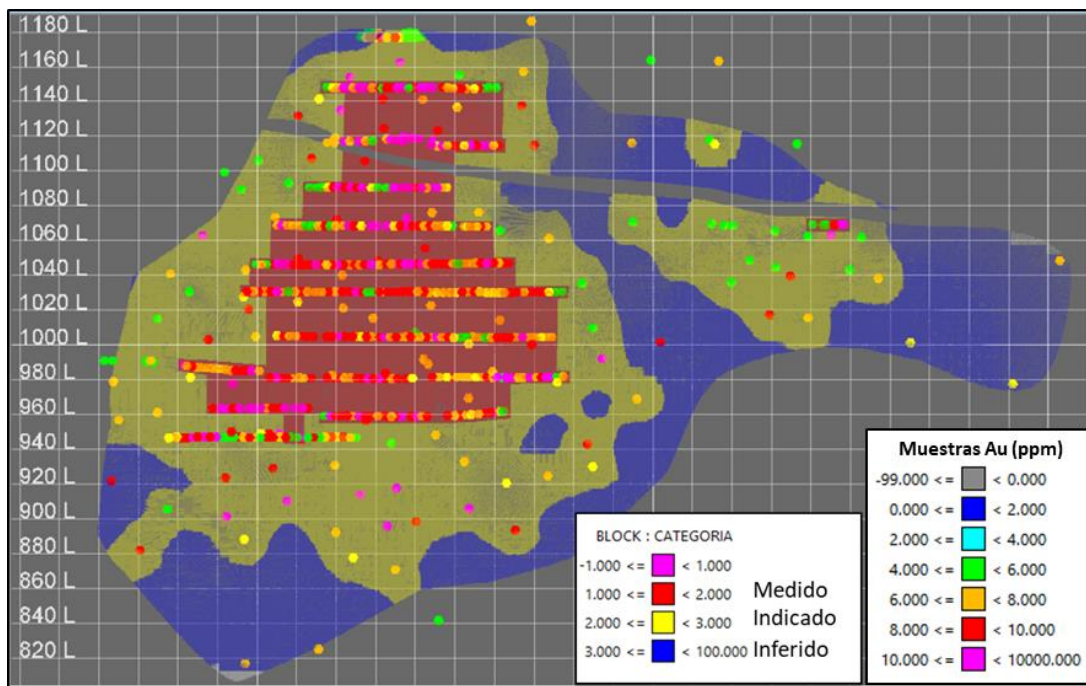


Figura 6: Resultado categorización de recursos bajo criterio experto con distribución de muestras. Vista longitudinal.

Con el fin de cuantificar la incertidumbre de buena manera, obtener resultados no suavizados y determinar cuál es la mejor malla de perforación de sondajes que permita categorizar los recursos minerales inmediatamente como medidos y/o indicados, se ejecuta un análisis de vanguardia que involucra la generación de escenarios equiprobables por medio de simulaciones multigaussianas y predicciones hipotéticas mediante kriging ordinario de mallas sintéticas regulares.

3. Estado del arte y trabajos anteriores.

3.1. Simulaciones y cuantificación de incertidumbre.

Si bien la estimación honra la información de las muestras, es localmente detallada y presenta un suavizamiento apropiado para visualizar tendencias, es inapropiado para simular valores extremos y estudiar la incertidumbre. En cambio, las simulaciones también reproducen la información local, pero, además, replican el histograma, representan la variabilidad espacial y también permiten estudiar la incertidumbre (Figura 7) (Rossi y Deutsch, 2014).

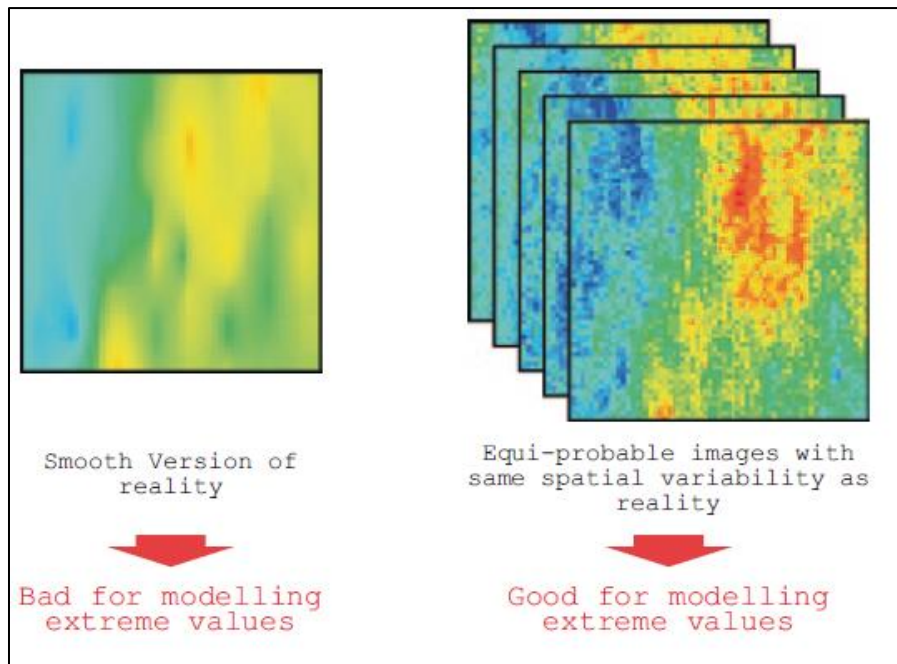


Figura 7: Diferencia entre resultado de estimación y de simulaciones (Rossi y Deutsch, 2014).

Por definición, la simulación condicional consiste en construir una realización que posee la misma distribución estadística y espacial que las muestras, en particular la misma media, la misma varianza y el mismo variograma, además de estar condicionada por esos datos experimentales, en otras palabras, donde existen datos la simulación y la realidad coinciden (Alfaro, 2015).

Un modelo de recursos completo no solo debe incluir la distribución de la ley estimada, sino también la información detallada de la incertidumbre y sus consecuencias (Rossi y Deutsch, 2014; Verly *et al.*, 2014). La estimación provee valores que, en promedio, se encuentran tan cercanos como es posible al valor real (desconocido), es insesgada, presenta error cuadrático mínimo y genera un efecto de suavizado. Mientras que las simulaciones reproducen la variabilidad original observada en los datos y permiten un estudio acabado de la incertidumbre, esto implica que los valores extremos de la distribución original son preservados.

Además, el modelo de incertidumbre también proporciona herramientas para el análisis de riesgo.

En este contexto, las simulaciones condicionales se han vuelto populares como una herramienta geoestadística que provee modelos de incertidumbre en las distintas etapas de un proyecto minero. Han sido empleadas como herramientas de control de ley en el corto plazo, para analizar el riesgo asociado a la clasificación de los recursos, para estudiar la incertidumbre de minar las reservas en la etapa de factibilidad (Martinez-Vargas, 2017). Otras aplicaciones incluyen el estudio de recuperación geometalúrgica y optimización de espaciamiento entre sondajes (Rossi y Deutsch, 2014). Asimismo, Cornah *et al.* (2013) validan que las simulaciones constituyen la mejor herramienta para cuantificar la incertidumbre en depósitos no metálicos de carbón en un horizonte temporal de 8 años de producción. En línea con lo anterior, Abzalov y Bower (2009) realizan 25 simulaciones para la determinación de incertidumbre en un depósito de bauxitas y generan un criterio de clasificación en función de volúmenes de producción trimestrales y anuales según la variación de la ley.

La simulación representa correctamente la proporción de altas y bajas leyes, la media, la varianza y otras estadísticas univariadas propias de las muestras. Reproduce fidedignamente la continuidad espacial de la variable, anisotropías, efecto pepita y otras características del modelo variográfico (Rossi y Deutsch, 2014). Se construye en una grilla fina para proveer el número suficiente de nodos dentro del bloque de interés. Durante su construcción se aplican muchas de las condiciones y requisitos de las estimaciones lineales y no lineales, sobre todo en lo que respecta a las decisiones de estacionaridad (Angulo, 2018).

Diversos autores (Rossi y Deutsch, 2014; Carmona, 2020, entre otros) coinciden en la necesidad de contar con datos que presenten una distribución gaussiana para efectuar las simulaciones, esto debido a sus propiedades estadísticas. La distribución gaussiana es derivada desde el teorema de límite central que es de los teoremas estadísticos más robustos. La ventaja de esta distribución es que se encuentra completamente caracterizada por la media y la desviación estándar. Rossi y Deutsch (2014) indican que existen muchas instancias en las que es más fácil predecir la incertidumbre de un sector no muestreado mediante una distribución gaussiana. Dado que los datos experimentales no suelen presentar una distribución gaussiana es común efectuar una transformación de los mismos por medio de una metodología denominada *normal score* que consiste en convertir los datos desde su distribución original a una distribución gaussiana univariable, de forma directa cuantil a cuantil (Figura 8) (Carmona, 2020).

Una vez realizada la transformación gaussiana, Li *et al.* (2004) plantean una metodología para determinar la incertidumbre presente en el sistema, la cual se detalla a continuación:

- 1- Generar un modelo de alta resolución del depósito usando simulaciones basada en la información geológica.

- 2- Rebloquear los puntos simulados al mismo tamaño del bloque usado en la estimación del modelo.
- 3- Estimar el modelo de bloques mediante un método convencional.
- 4- Calcular el error absoluto relativo para cada bloque en el depósito estimado en el paso 3 mediante la comparación con lo determinado en el paso 2.
- 5- Repetir para un gran número de realizaciones (ej. 50).
- 6- Resumir los resultados gráficamente para ilustrar las diferencias entre lo estimado y la “realidad”.

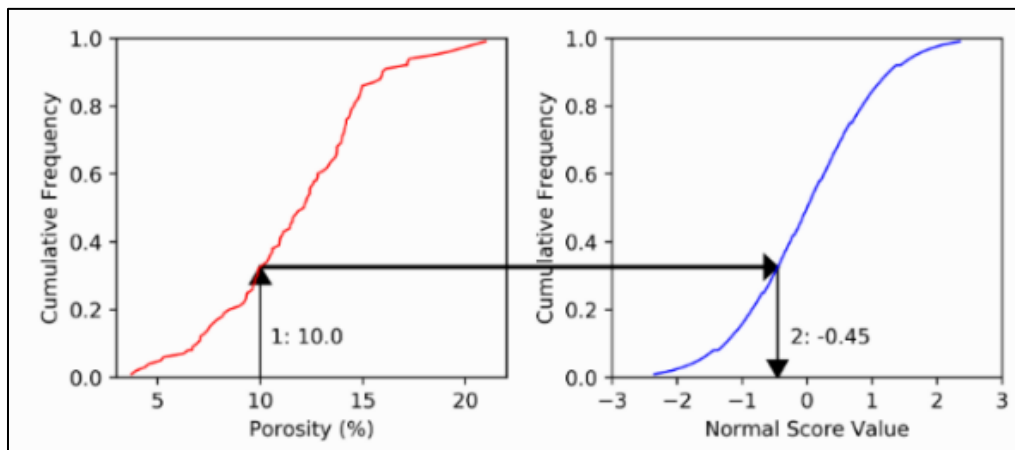


Figura 8: Ejemplo de transformación de distribución de porosidad a valores *normal score*. En el gráfico izquierdo se lee la frecuencia correspondiente al valor de porosidad 10.0 y en el derecho se va al mismo valor de frecuencia para leer el valor gaussiano (Carmona, 2020).

Para este trabajo se consideran algunas etapas del modelo de Li *et al* (2004) pero no su totalidad ya que el objetivo es distinto.

3.2. Categorización de Recursos

De acuerdo con Ortiz y Emery (2004), la categorización de los recursos y reservas minerales es una parte crucial dentro del proceso de evaluación de yacimientos dado el interés económico que desencadena. No obstante, esta etapa es una de las más subjetivas, ya que la determinación de la incertidumbre es realizada por una persona competente con un criterio apropiado. Con el pasar del tiempo, los códigos internacionales se han vuelto más estrictos y explícitos sobre las metodologías a emplear, aunque sin lograr llegar a un consenso.

Ortiz y Emery (2004) entregan una aproximación a los criterios que se pueden emplear para la determinación de la incertidumbre en la categorización. En primer lugar, sitúan un criterio geológico, asociado a la continuidad de la mineralización en el espacio y a la posible presencia de discontinuidades. Concluyen que este criterio es subjetivo y difícil de cuantificar, por lo que debe combinarse con algún otro. Como segundo criterio se encuentra el criterio geométrico que hace alusión a la relación existente entre el bloque estimado y las muestras cercanas, a este aspecto también

se refiere Deutsch *et al.* (2007), donde indican que se debe tener en cuenta la distancia a las muestras, la cantidad de muestras empleadas en la estimación del bloque, etc. El problema de este criterio es que no atiende la variabilidad espacial que pueda existir entre las muestras. Finalmente, el último criterio al cual se refieren corresponde al geoestadístico que hace referencia a la capacidad de entender cómo se distribuye la mineralización en el espacio (anisotropía) y para ello se basa en variogramas, correlogramas, varianza del kriging, etc. En este último criterio también se apoyan Ramadhan *et al.* (2020) quienes categorizan los recursos de carbón basados en los alcances del variograma respecto a las zonas con muestras y definen que los recursos minerales medidos se encuentran dentro del primer tercio del variograma, los indicados entre el primer y segundo tercio, y finalmente, los inferidos se encuentran en la porción final.

Una de las técnicas más utilizadas en la categorización de recursos minerales es por medio de la varianza del kriging, que es una variable inherente a la estimación mediante cualquier tipo de kriging y que considera la ubicación de las muestras. En general es una técnica aceptada, sin embargo, dado que solo considera la ubicación de las muestras y no su ley, suele presentar diferencias especialmente en las zonas de alta ley donde la variabilidad es mayor dado el efecto proporcional (Emery, 2000). Otras alternativas, también aceptadas, corresponden a definir una varianza relativa al dividir la varianza del kriging en la ley del bloque al cuadrado, o por medio de pasadas de estimación que se hacen cada vez menos restrictivas en cuanto a la cantidad de muestras que consideran para estimar un bloque (Ortiz y Emery, 2004).

Ahora bien, existe consenso en la academia que la mejor metodología para la determinación de la incertidumbre es por medio de simulaciones condicionales, que contemplan la generación de múltiples modelos numéricos que reproducen las características originales del depósito. Cada modelo tiene un histograma que fluctúa en torno al histograma representativo de la ley y reproduce la covarianza espacial, así como también coincide con los valores de las muestras (Ortiz y Emery, 2004).

Luego, es posible determinar la distribución de incertidumbre asociada a la ley de cada bloque y con ello determinar una varianza local a partir del histograma de leyes simuladas del bloque, que, a su vez, se diferencia de la varianza del kriging dado que en este caso si se considera la ley de las muestras y por lo tanto se hace cargo del efecto proporcional. Para categorizar por medio de simulaciones se puede emplear la varianza local, tal como la varianza del kriging o bien, calculando la varianza para un periodo de producción (mes, cuarto, año) y luego categorizar con base en el error de la ley promedio en el periodo (Ortiz y Emery, 2004).

Pese a existir una metodología relativamente establecida para categorizar recursos minerales por medio de la determinación de incertidumbre a partir de simulaciones condicionales, los diversos autores que tratan el tema no entregan criterios rígidos para clasificar los bloques según los intervalos de confianza que puedan determinarse (Ortiz y Emery, 2004; Rossi y Camacho, 2000). Es así como Rossi y Deutsch (2014), indican que el uso de realizaciones para obtener intervalos de confianza en la clasificación de recursos aún no es totalmente distribuido y que el

código JORC solicita la mejor medida posible de la incertidumbre, pero no entrega una guía para realizar la clasificación. Por otro lado, Deutsch *et al.* (2007) indican que este método no debiera ocuparse de manera independiente ya que los resultados son muy sensibles a la variación de parámetros en su definición.

Por su parte, Rossi y Deutsch (2014) plantean que no existe un criterio único para realizar los quiebres en la clasificación y que en realidad cada compañía minera define donde situar los límites de las categorías, y que en muchas oportunidades se correlaciona directamente con la precisión requerida en los estudios de pre-factibilidad/factibilidad. Pese a lo anterior, los autores entregan un criterio general para clasificar los recursos basado en la incertidumbre y bajo esta hipótesis clasifica el recurso medido como aquel que presenta una variación de $\pm 15\%$ el 90% de las veces, por su parte el recurso indicado cuenta con una variabilidad de $\pm 30\%$ el 90% del tiempo y finalmente, el recurso inferido cuenta con un error entre $\pm 30\%$ y $\pm 100\%$ el 90% de las veces. Si los materiales presentan un error sobre el $\pm 100\%$ no se deben clasificar como recursos y suelen llamarse “cielo azul” o “mineralización potencial”.

Emery *et al.* (2006) también tratan el tema de clasificación de recursos derivado de simulaciones condicionales y en su trabajo entregan 3 posibles aproximaciones para su categorización:

- 1) Clasificar cada bloque con base en la medida de incertidumbre local, por medio de la varianza relativa condicional o por el coeficiente de Gini (razón entre el indicador de dispersión y la media; que pertenece al intervalo $[0,1[$).
- 2) Clasificar cada bloque con base en el nivel de confianza. Para el recurso mineral medido la diferencia entre la ley simulada y la estimada es menor al 10% el 19/20 veces, el indicado presenta una diferencia relativa menor que 20% el 19/20 de las veces; todos los demás son inferidos.
- 3) Clasificar cada bloque con base en el nivel de confianza considerado en un volumen de producción. Alfaro (2015) también entrega una categorización basado en un plan de producción.

Por otro lado, Emery *et al.* (2006) y Dimitrakopoulos *et al.* (2009) identifican que debe definirse valores umbral para separar las categorías y que dichos valores deben reflejar la tolerancia de error que es aceptada localmente para la estimación de un bloque. Los quiebres los definen en función del coeficiente de variación condicional, que corresponde a la desviación estándar condicional dividida por la media; lo anterior respecto a un valor umbral que no especifican cómo determinarlo.

3.3. Optimización de muestreo

Es intuitivo pensar que, a mayor cantidad de muestras existe menor incertidumbre entre cada una de ellas, no obstante, planificar una campaña de sondeos no es algo trivial y requiere especial atención en la ubicación de los sectores que se quieren perforar sin perder de vista la componente económica de los costos asociados a esta

actividad, por lo tanto, es necesario contar con alguna herramienta que permita encontrar el punto óptimo para el cual se maximice la información colectada.

Respecto a lo anterior, McBratney *et al.* (1981) son pioneros en proponer que el muestreo debe realizarse en función de la variable regionalizada, ya que sostienen que las muestras están relacionadas y no son independientes entre sí. Reconocen como algo favorable que la varianza del kriging dependa solo de la ubicación de las muestras ya que con ello se conoce el resultado antes de realizar las perforaciones.

Como primera aproximación puede emplearse la metodología de McBratney *et al.* (1981), ya que independiente del valor medido en el sitio, solo la ubicación de las muestras es suficiente para obtener conclusiones preliminares. No obstante, este tipo de análisis no toma en cuenta el efecto proporcional, por lo que podría cometerse un error asociado a las zonas de altas leyes donde la variabilidad es mayor.

Respecto a lo anterior, Schofield (2001) identifica que existen múltiples variables que influyen en la definición de un espaciamiento óptimo de muestreo, pero concluye que uno de los más importantes corresponde a la calidad del muestreo, sobre todo en depósitos complejos como los auríferos en los cuales el 1% de las leyes superiores presenta distribución errática. Concluye que el kriging no es una buena herramienta para cuantificar la incertidumbre de la estimación y que una metodología apropiada es por medio de simulaciones.

Ahora bien, el problema del efecto proporcional puede abordarse desde el campo de las simulaciones multigaussianas, mediante las cuales puede determinarse la incertidumbre, el espaciamiento óptimo en las zonas donde también exista este efecto y el sistema cumpla más bien la condición de heteroscedasticidad (donde media y varianza fluctúan) que la de homocedasticidad (media y varianza constante), como se asume para el uso de la varianza del kriging (Angulo, 2018).

A la fecha varios autores han aplicado la técnica geoestadística de simulaciones multigaussianas con el fin de obtener el espaciamiento óptimo para realizar el muestreo sin perder operatividad ni costos. Dentro de la literatura disponible se resalta lo indicado por Martínez-Vargas (2017) que detalla un procedimiento para determinar la malla óptima considerando una variable económica. La metodología se expone a continuación:

- 1- Simular en una malla fina realizaciones del depósito mediante simulaciones condicionales con los sondeos de exploración.
- 2- Rebloquear la malla fina para obtener el mismo tamaño del bloque que será estimado.
- 3- Definir mallas de perforación a diferentes espaciamientos y asignarles la ley de las simulaciones.
- 4- Estimar los bloques usando las distintas mallas sintéticas.
- 5- Calcular el costo de clasificar erróneamente un bloque (mineral como estéril o al revés).
- 6- Calcular el costo de las perforaciones a diferente espaciamiento.

- 7- Graficar el costo total de perforar y el costo de clasificar erróneamente los bloques para definir la malla óptima.

Englund y Heravi (1992) expresan una metodología similar a la anterior, pero enfocado en un ambiente de contaminación ambiental para el cual centran el estudio en la presencia de contaminantes en unidades de remediación. A diferencia de Martínez-Varga (2017), estos autores plantean que la generación de la base de datos de muestras para efectuar las estimaciones debe hacerse de forma aleatoria y que ello conlleva un alto requerimiento de cálculo por parte de la computadora que lo ejecutará.

En línea con lo anterior, Magallanes y Sáez (2013) realizan exitosamente este tipo de estudio en un depósito de cobre-oro en Perú (Mina Tantahuatay). Como resultado obtienen que la mejor distribución para el muestreo es una malla de 40 m x 40 m ya que con ello se consigue un error del 15% al 90% de confianza. Por su parte, Rojas y Cáceres (2011) emplean exitosamente esta metodología en un proyecto en etapa de prefactibilidad, en el cual generan 25 simulaciones denominadas “realidad desconocida” y 4 mallas sintéticas de muestreo, con ello logran determinar el espaciamiento óptimo para que al menos un 80% de los recursos minerales se encuentre en la categoría de medidos, también evidencian que a un espaciamiento muy bajo aumenta significativamente el número de perforaciones y el aumento de confianza es marginal.

Por su parte, Afonseca y Silva (2022) llegan a la misma conclusión anterior, y además sostienen que el tiempo requerido para efectuar este tipo de análisis compensa totalmente la calidad de la información obtenida, por otro lado, indican que debe evaluarse la metodología de cada caso, ya que replicar la de otro yacimiento puede generar resultados no óptimos. La metodología propuesta por estos autores apunta a satisfacer las necesidades de precisión local y global simultáneamente, ya que el kriging per se no se hace cargo. Finalmente indican que si el efecto pepita es muy alto necesariamente se debe realizar más simulaciones.

En su tesis de magister, Angulo (2018) realiza un profundo análisis de malla de muestreo para diversas unidades geológicas de un depósito laterítico de níquel, y para ello se basa principalmente en el coeficiente de variación condicional. Finalmente concluye que la metodología es válida y útil para definir espaciamiento de muestreo.

Para este trabajo, se emplea la metodología indicada por Boyle (2009) y Martínez-Vargas (2017), vale decir, se realiza un set de simulaciones multigaussianas consideradas como representativas de la ley de oro en soporte puntual, luego se genera 4 arreglos de muestras hipotéticas equiespaciadas a 15 m, 20 m, 30 m y 45 m a las cuales se les asigna la ley determinada en el paso anterior. A continuación, se ejecuta la estimación con cada malla sintética mediante kriging ordinario y se analiza la diferencia que existe entre el valor del bloque determinado mediante estimación y la mayor frecuencia de leyes obtenidas a partir de las simulaciones.

Cabe mencionar que la metodología anterior es efectuada en un espacio de 3 dimensiones y luego en un espacio de 2 dimensiones (se explica en sección siguiente), con el fin de comparar y determinar si existe un mejoramiento en los resultados.

Finalmente, es necesario definir localmente cada metodología de estimación puesto que contar con un criterio regionalizado no es apropiado basado en Bertoli *et al.* (2013) que realizan un análisis geoestadístico para determinar los espaciamientos óptimos de muestreo en la Cuenca de Bowen-Australia y contrastan sus resultados con lo indicado en las guías de buenas prácticas para la estimación de carbón. Determinan que los espaciamientos indicados en la guía no representan de buena manera la variabilidad de los depósitos estudiados, ya que en algunos depósitos es demasiado optimista y en otros demasiado conservador.

3.4. Análisis indirecto

De manera complementaria a la metodología descrita anteriormente, se realiza un análisis indirecto basado en las variables de potencia y acumulación, que busca determinar si existe un aumento en la continuidad del recurso mineral en el espacio. La potencia corresponde al espesor real de la veta en el sitio de muestreo, medida perpendicularmente a sus paredes, mientras que la acumulación corresponde al producto entre la potencia y la ley de oro (Dominy *et al.*, 1999; Bertoli *et al.*, 2003; Zuñiga y Emery, 2010).

Utilizar estas variables de manera conjunta es conveniente ya que simplifica el escenario al reducir una dimensión. Por su parte, la acumulación presenta la característica de aditividad, por lo que puede ser promediada aritméticamente en un modelo de bloques y también presenta menor variabilidad espacial de sus datos puesto que disminuyen los valores extremos con la transformación (Meszaros, 2023).

Ahora bien, Meszaros (2023) también plantea ciertas desventajas asociadas al método, por ejemplo, la simplificación absoluta de una dimensión no permite identificar problemas geométricos de las estructuras, por lo que no es posible representar curvaturas o ramificaciones, la imprecisión de ubicar el espesor de un sondaje cuando éste atraviesa longitudinalmente a la veta. Por otro lado, también es poco operativo, por lo que no es posible de aplicar sistemáticamente en la industria.

Finalmente, se realiza el mismo análisis de categorización expuesto anteriormente, pero con la variable indirecta de acumulación, con el fin de evaluar la ocurrencia de un escenario más favorable.

3.5. Novedad y aporte de este trabajo

El aporte que pretende entregar este estudio es aplicar herramientas geoestadísticas que se encuentran a la vanguardia del conocimiento, objetivizar la categorización de recursos minerales y definir la malla óptima de muestreo para una veta de oro en un sistema de vetas angostas.

4. Metodología

Con base en la revisión bibliográfica efectuada en la sección anterior, se identifican los patrones claves para generar una metodología aplicada al caso de estudio en línea con lo que se ha desarrollado en la literatura.

Dada la complejidad que presenta la distribución espacial de la abundancia del oro se ejecutan dos análisis paralelos, el primero de forma directa, con los datos originales, tal como se utilizan en la operación en un escenario de 3 dimensiones. Y el segundo, de forma indirecta, que busca identificar una mayor continuidad en las variables al realizar simulaciones y estimaciones de forma conjunta entre potencia y acumulación en un escenario de 2 dimensiones.

Para ambos casos, ya sea el método directo o el indirecto, la secuencia de acción es prácticamente la misma. La primera etapa corresponde al análisis exploratorio de la base de datos que incluye eliminación de errores, duplicados, desagrupamiento y *capping*.

La siguiente etapa corresponde a la ejecución de las simulaciones, para ello se procede con la transformación gaussiana de las muestras puesto que su distribución es complementa conocida. Luego, es necesario validar la hipótesis multigaussiana pero dada su complejidad solo se realizan las pruebas para evaluar la hipótesis bigaussiana (análisis de madograma, rodograma, variograma de indicadores y nube de correlación diferida). A continuación, se realiza un análisis variográfico de valores gaussianos y subsecuente plan de simulaciones que son analizados por medio de validación cruzada (*accuracy plot* y gráfico de valor real vs valor simulado). Y finalmente, luego de todas las validaciones anteriores se procede con la ejecución de 40 simulaciones para el método directo con ley de oro y 40 cosimulaciones entre potencia y acumulación para el método indirecto, que son convertidas retrógradamente a valores reales.

Para el paso siguiente se realiza la definición de las mallas sintéticas de muestreo que, según el capítulo anterior, la mejor configuración corresponde a un arreglo cuadrado. Para este trabajo se definen mallas de 15 m*15 m, 20 m*20 m, 30 m*30 m y 45 m*45 m. A las muestras de cada una de las mallas indicadas se les asigna el valor de ley de oro/acumulación proveniente de una simulación aleatoria.

A continuación, se realiza el análisis variográfico y plan de kriging a partir del arreglo de las muestras equiespaciadas 15 m ya que cuenta con mayor densidad de información y es extrapolable a los arreglos más espaciados a raíz de su origen común en las simulaciones, vale decir, todas las muestras apuntan a representar la misma realidad equiprobable ya que provienen de la misma simulación. Se efectúa la validación cruzada correspondiente y la subsecuente estimación de las variables mediante kriging ordinario.

La determinación de la incertidumbre se efectúa por medio de la comparación entre el valor del bloque obtenido mediante la estimación respecto al histograma de distribución de los valores determinados por medio de las simulaciones. En función

de lo anterior, se define que aquellos bloques cuya ley estimada se encuentre dentro del intervalo del 10% ($\pm 5\%$) respecto a la mayor frecuencia de leyes proveniente de las simulaciones, se clasifica como recurso mineral medido, mientras que si la ley estimada se encuentra en el rango de un 30% ($\pm 15\%$) se clasifica como recurso mineral indicado, y finalmente, cualquier valor fuera del intervalo 30% ($\pm 15\%$) se considera como recurso mineral inferido. En la Figura 9 se representa de manera gráfica la metodología de categorización.

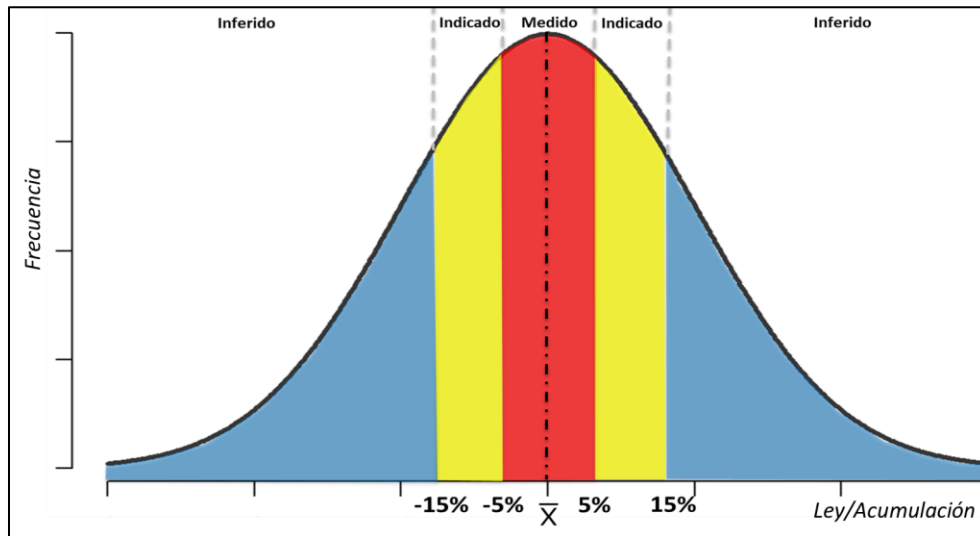


Figura 9: Intervalos definidos para categorización de recursos minerales en función de distribución de frecuencias. Ley en ppm y Acumulación en ppm*m.

5. Desarrollo

5.1. Análisis directo en 3D

Con el fin de facilitar los requerimientos computacionales y disminuir los tiempos de procesamiento se reduce el área de estudio a un sector de la veta de oro que comprende 300 m*300 m aproximadamente (Figura 10), la cantidad de muestras incluidas en el área total corresponde a 602, de las cuales 483 pertenecen a muestras de canaletas y las 119 restante a sondajes de exploración y producción.

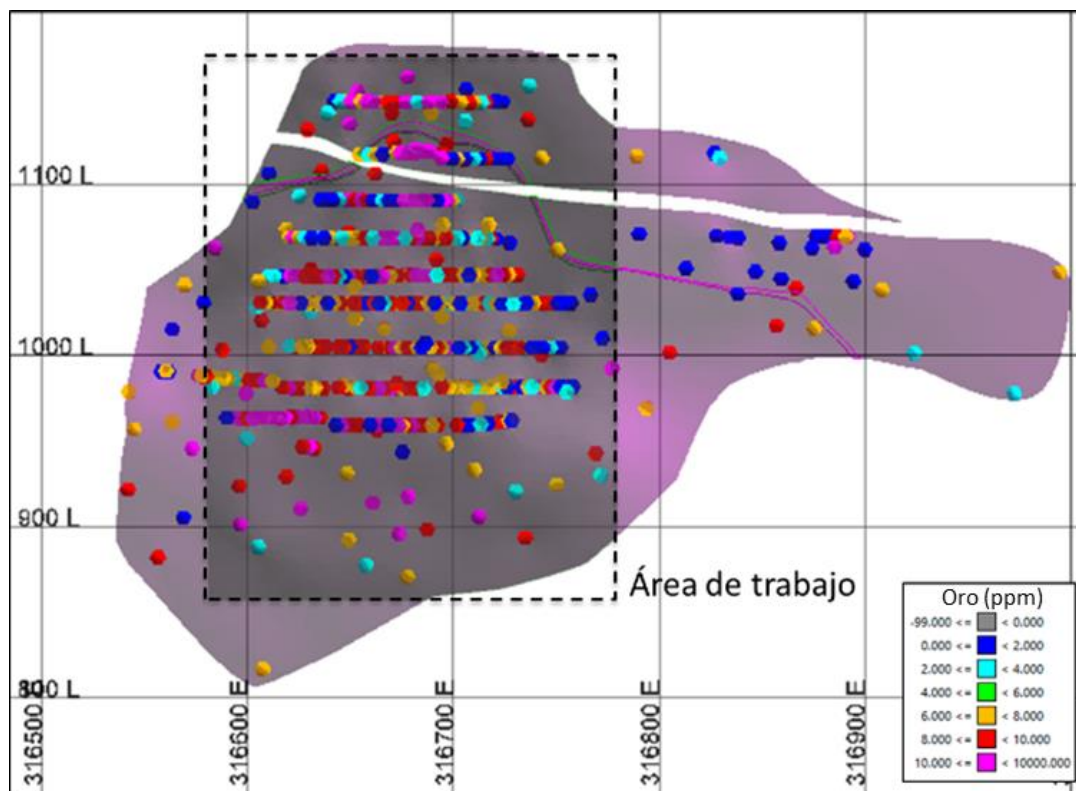


Figura 10: límites del área a estudiar.

La base de datos se encuentra validada por lo que no existe duplicados ni errores en la ubicación de las muestras. En la Figura 11 se ilustra la distribución de leyes del sector a estudiar, se observa la ocurrencia de valores extremos aislados.

Se realiza el desagrupamiento de los datos por medio del método de las celdas, para las cuales se considera una malla de 3 m*20 m y se determina la necesidad de aplicar un *topcut* en 15 ppm para controlar de buena manera los valores máximos. Luego de las consideraciones anteriores, la estadística básica de la base de datos queda de la siguiente manera (Tabla 3):

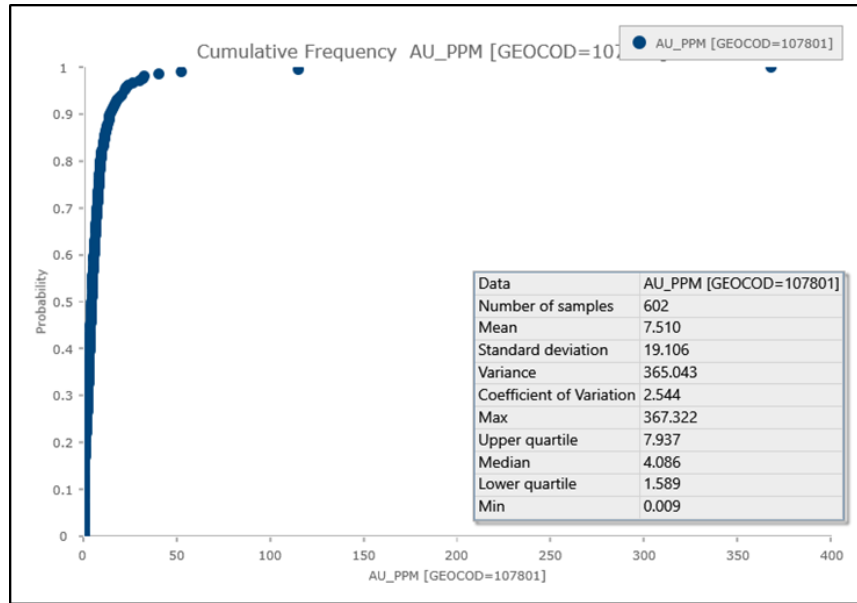


Figura 11: Frecuencia acumulada para leyes de las muestras incluidas en el área de estudio.

Tabla 3: Estadística básica de las muestras (en ppm).

Statistics for Au:		Global
number of data:		602
mean value:		5.1
variance:		19.6
minimum:		0.0
lower quartile:		1.5
median:		4.0
upper quartile:		7.9
maximum:		15.0

Luego de contar con la base de datos depurada se continúa con el procedimiento para efectuar simulaciones multigaussianas. El primer paso corresponde a transformar los datos a *normal score*, para ello se considera una distribución de leyes de 0 a 15 ppm (Figura 12).




Figura 12: Modelo de transformación gaussiano para muestras 3D.

El procedimiento requiere validar la hipótesis multigaussiana, no obstante, dada su complejidad, en este trabajo solo se valida la distribución bigaussiana y con ello se acepta la distribución multigaussiana. El primer paso corresponde a la revisión de la nube de correlación diferida para distintos espaciamientos, según lo exhibido en la Figura 13A y 13B, se observa que a un valor bajo la distribución es elongada, mientras que a valores altos tiende a generar una circunferencia, por lo que este postulado se cumple.




Figura 13A: Nube de correlación diferida para lag de 10 m en escenario 3D.




Figura 13B: Nube de correlación diferida de 100 m en escenario 3D.

Para la etapa siguiente se requiere el análisis de un variograma de indicadores contra el variograma original gaussiano (Figura 14). Se considera que las muestras con valor gaussiano bajo o son identificadas con un 0, mientras que todas las muestras superiores a este umbral son catalogadas con un 1. Para el análisis variográficos se utiliza una distribución omnidireccional dentro del plano de la veta (N330°/90°).

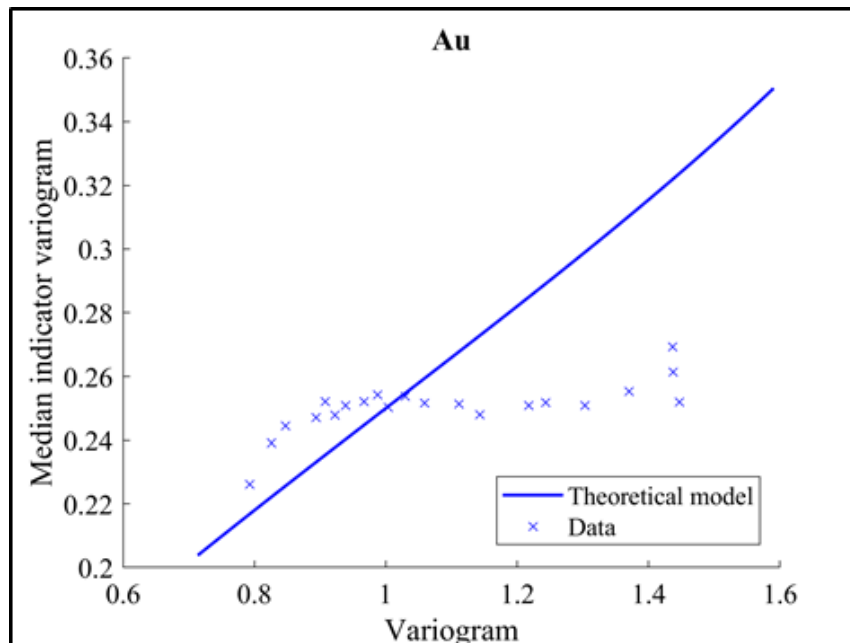


Figura 14: Variograma tradicional contra variograma de indicadores 3D.

Finalmente, se realiza el análisis de rodograma y madograma, conocidos como variogramas de orden $\omega=0.5$ y 1 , respectivamente, contra el variograma tradicional de orden $\omega=2$. Según la Figura 15 se observa que existe una buena afinidad entre los datos y los modelos, cumpliendo que la pendiente en cada conjunto de puntos experimentales en escala log-log responde a $\omega/2$.

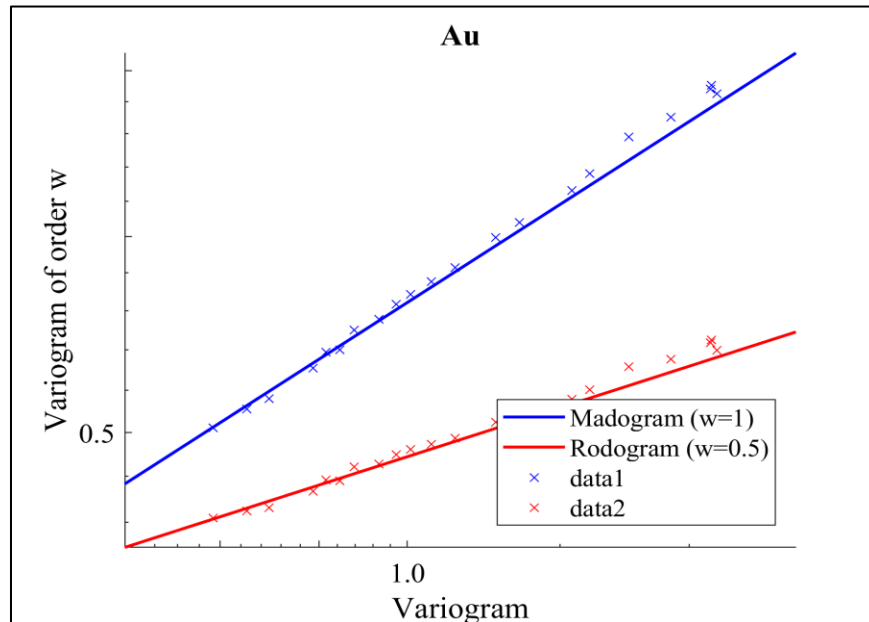


Figura 15: Análisis de rodograma y madograma 3D.

Se observa que el variograma de indicadores presenta un menor ajuste puesto que su construcción contiene más información y suele ser difícil de capturar por un modelo (multigaussiano u otro), mientras que los variogramas de distintos órdenes corresponden a una mezcla (promedio) de variogramas de indicadores y, por lo tanto, son más fáciles de reproducir, no obstante se valida la hipótesis bigaussiana y con ello la multigaussiana, Luego se procede a generar el plan de kriging de valores gaussianos para las simulaciones. Basado en lo anterior, el variograma se configura dentro de la actitud de la veta, vale decir, en un rumbo de 330° y manto vertical, con un lag de 22 m, y se modela con dos estructuras exponenciales de alcance máximo 100 metros, con un efecto pepita de 0.3 y contribuciones para alcanzar la meseta de 0.4 y 0.3, respectivamente (Figura 16). Se define un elipsoide de búsqueda orientado en la actitud de la veta con una elongación de 100 m y que considere 8 muestras por cada octante (Tabla 4).

Tabla 4: Plan de kriging para escenario 3D.

Radio de búsqueda	100 m
Dirección de búsqueda	330°
Muestras por octante	8
Interpolador	Kriging ordinario




Figura 16: Variograma modelado 3D.

A continuación, se realizan pruebas de validación para evaluar el plan de kriging. Se observa que la distribución de errores cuenta con una media cercana a 0 y una varianza pequeña (Tabla 5A), por lo que se da cuenta de las características de insesgo y optimalidad, respectivamente. Por su parte, la varianza del error estandarizado se concentra cercana a 1 (Tabla 5B) por lo que evidencia un plan de kriging apropiado. Finalmente, se observa que la capacidad predictiva del modelo variográfico es aceptable, pese a existir sesgo condicional (Figura 17).

Tabla 5A: Estadística básica de la distribución de errores.

Statistics for Er:		Global
number of data:		602
mean value:		-0.017
variance:		19.781

Tabla 5B: Estadística básica de la distribución de errores estandarizados.

Statistics for ErSTD:		Global
number of data:		602
mean value:		-0.003
variance:		1.596

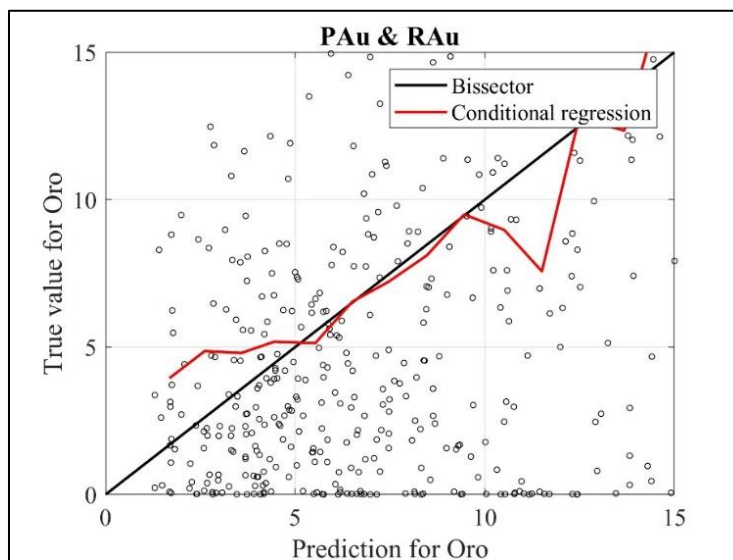


Figura 17: Gráfico de validación cruzada que relaciona el valor verdadero con el valor predicho para el oro.

Luego de validar el plan de kriging y el modelo variográfico, se procede a validar el plan de simulaciones por medio de un gráfico de exactitud (*accuracy plot*) donde se observa que pese a existir una tendencia levemente optimista del modelo éste se considera como válido (Figura 18).

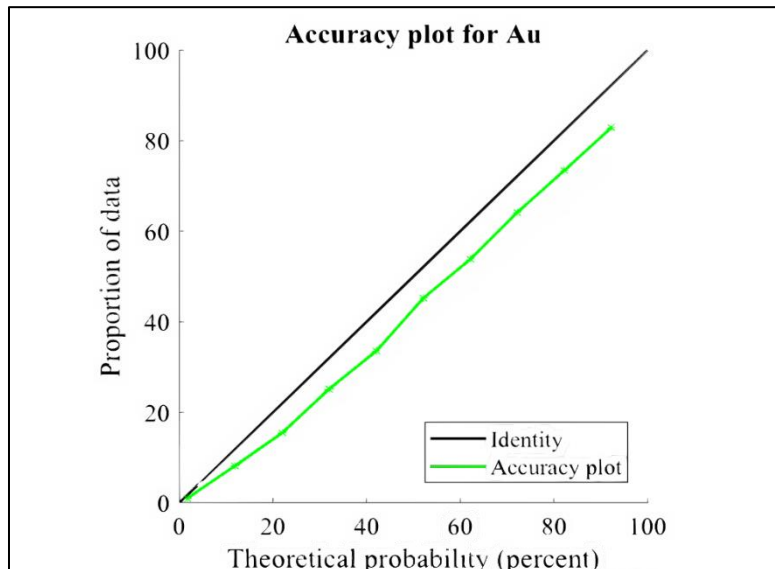


Figura 18: *Accuracy plot* para plan de simulación 3D.

Por el lado de la validación cruzada se observa un sesgo condicional bajo y una correlación aceptable entre los valores reales y los predichos por medio de las simulaciones (Figura 19).

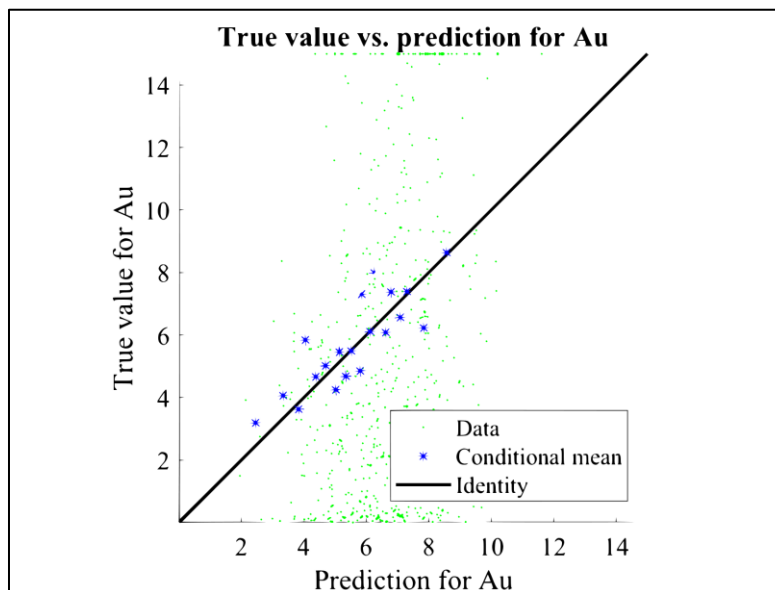


Figura 19: Gráfico de validación cruzada entre valor de oro predicho y real en entorno 3D.

Luego de las validaciones anteriores se procede a realizar 40 simulaciones en el *software Maptek-Vulcan*, por medio del algoritmo de bandas rotantes en un soporte

de bloque de 0.2 m (Tabla 6). En la Figura 20 se observa el resultado de una simulación aleatoria.

Tabla 6: Parámetros empleados para simulaciones 3D.

N° Simulaciones	40
Tamaño bloque	0.2 m*0.2 m
Radio de búsqueda	100 m
Dirección de búsqueda	330°
Muestras por octante	8
N° líneas rotantes	-
Ubicaciones simultáneas	-
Valor random (seed)	5611439
Interpolador	Kriging ordinario




Figura 20: Ejemplo del resultado de las simulaciones efectuadas.

Una vez obtenidas las simulaciones se procede a generar distintas mallas regulares de muestreo hipotéticas (15 m*15 m; 20 m*20 m; 30 m*30 m y 45 m*45 m) a las cuales se les asigna la ley de oro de la misma simulación aleatoria, que representa un escenario posible de la realidad (Figura 21).

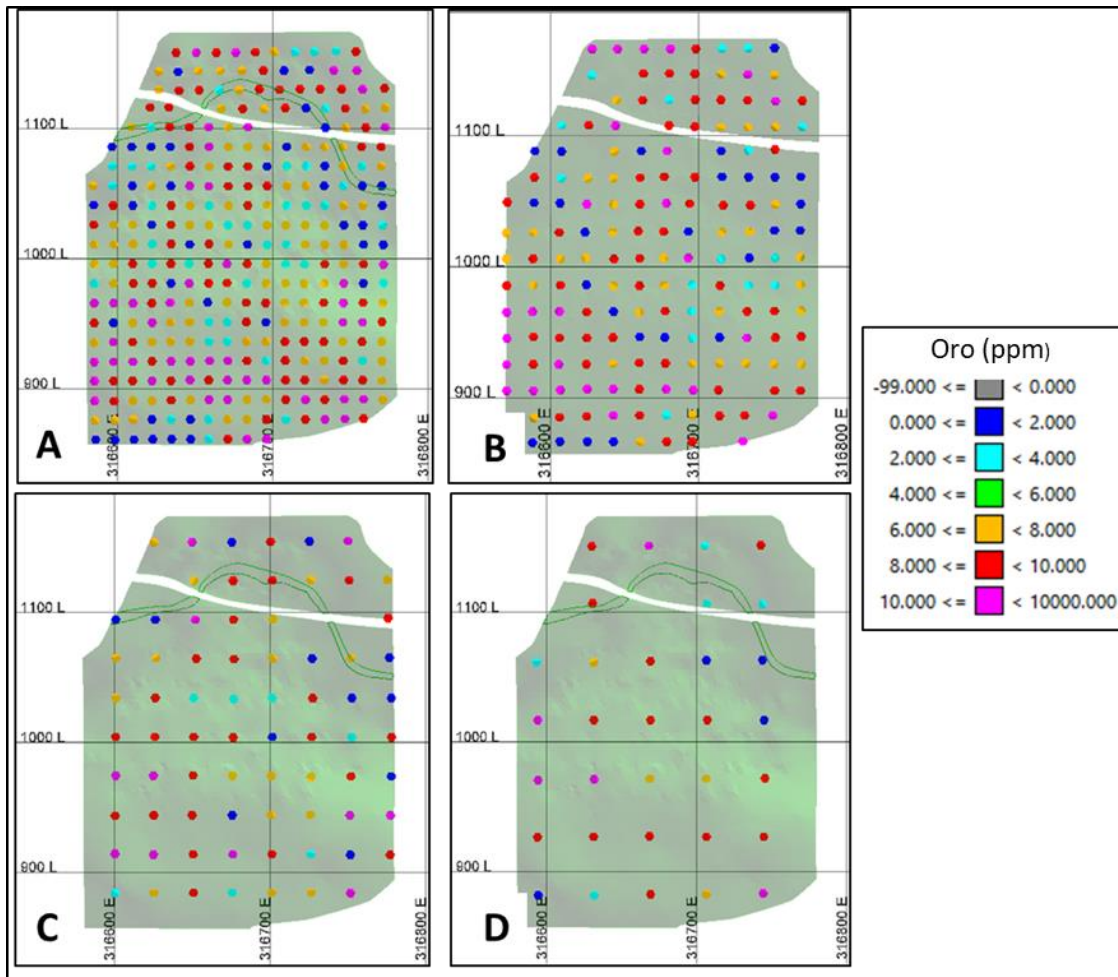


Figura 21: Mallas sintéticas 3D con ley proveniente de simulación. **A-** 15 m*15 m; **B-** 20 m*20 m; **C-** 30 m*30 m y **D-** 45 m*45 m.

Luego, se genera el análisis variográfico con las muestras de la malla más fina, para ello se considera un variograma experimental orientado en el rumbo de la veta, manto vertical y un lag de 20 m con 8 pasos. El ajuste del variograma se consigue con dos estructuras exponenciales de alcance 10 y 90 m, respectivamente (Figura 22). El plan de kriging que se valida a continuación considera que el elipsoide de búsqueda se encuentra contenida en el plano de la estructura, con un alcance de 90 m e incluye 8 muestras por octante (Tabla 7).

La distribución de errores exhibe media cercana a 0 (Tabla 8A), por lo que se da cuenta de las características de insesgo. Por su parte, la varianza del error estandarizado se concentra cercana a 1 (Tabla 8B) por lo que el modelo cuantifica bien la incertidumbre.




Figura 22: Variograma modelado a partir de malla sintética.

Tabla 7: Plan de kriging para mallas sintéticas 3D.

Radio de búsqueda	90 m
Dirección de búsqueda	330°
Muestras por octante	8
Interpolador	Kriging ordinario

Tabla 8A: Estadística básica de la distribución de errores.

	Global
number of data:	405
mean value:	0.002
variance:	0.951

Tabla 8B: Estadística básica de la distribución de errores estandarizados.

	Global
number of data:	405
mean value:	-0.002
variance:	1.752

Por su parte, el análisis de la nube de correlación muestra buena concordancia entre el valor real y el predicho, lo anterior indica un bajo sesgo condicional (Figura 23).

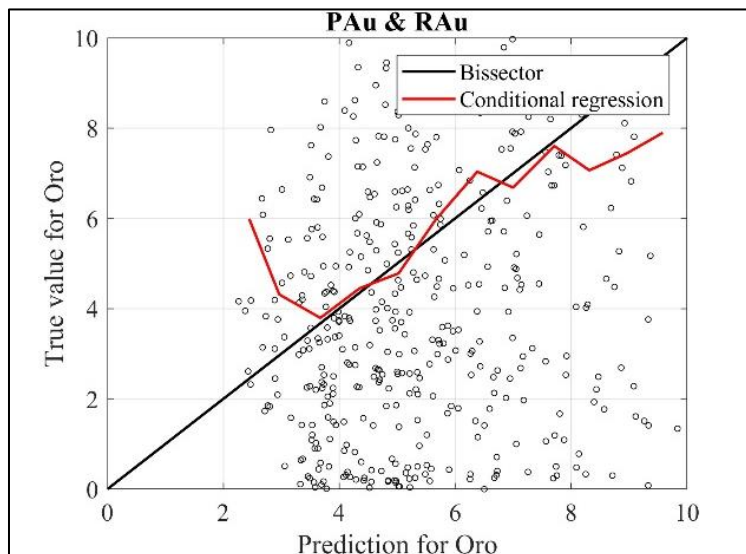


Figura 23: Nube de correlación entre oro real y predicho.

Con el plan de kriging validado anteriormente se procede a predecir la distribución de leyes de oro en los 4 escenarios de espacimiento, los resultados se observan en la Figura 24. Notar la pérdida de resolución conforme se aumenta la distancia entre las muestras.

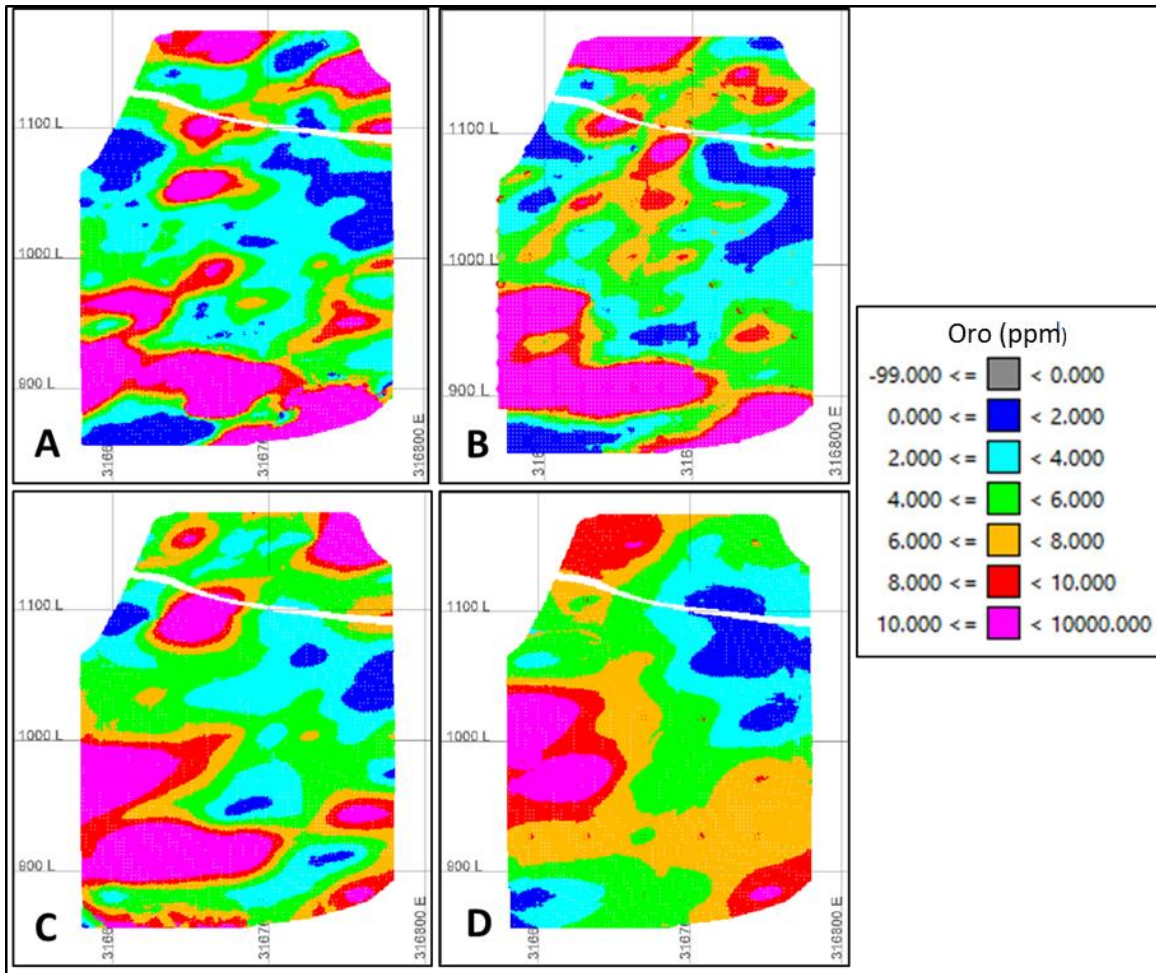


Figura 24: Resultado de predicción de oro mediante kriging ordinario con las diferentes mallas 3D. **A-** 15 m*15 m; **B-** 20 m*20 m; **C-** 30 m*30 m y **D-** 45 m*45 m.

5.2. Análisis Indirecto en 2D

Con el fin de evaluar una metodología alternativa a la anterior, se realiza un análisis indirecto de la distribución de la variable acumulación con el fin de identificar si existen mejoras significativas en los resultados a través de la predicción conjunta entre potencia y acumulación por medio de cokriging ordinario y de cosimulaciones. El primer paso común corresponde a la generación de una base de datos con estas variables, para ello se determina manualmente el espesor verdadero de la veta en cada sondaje, que no necesariamente coincide con el ancho del compuesto. En cambio, para las muestras de canaletas se considera que su espesor es el verdadero dado que son colectadas en túneles que se desarrollan en el rumbo de la estructura y por lo tanto los frentes de avance son perfectamente perpendiculares a ella. Luego

de determinar la potencia real de la estructura en cada punto de muestreo se calcula la acumulación.

La veta aurífera presenta un rumbo de N330° y un manteo subvertical, por lo que es necesario generar una rotación horizontal de 60° en sentido antihorario y luego una rotación vertical de 90° en sentido horario. Posteriormente, se busca y eliminar duplicados con un umbral de 0.2 m (tamaño mínimo de los compósitos). Con el objeto de reducir el efecto del muestreo preferencial, se procede a desagrupar las muestras en una malla de 3 m en eje X (corresponde a la distancia entre frentes de avance) por 20 m en eje Y (corresponde a la distancia entre niveles).

A continuación, se presentan las estadísticas básicas para la base de datos luego del análisis exploratorio (Tabla 9).

Tabla 9: Superior, estadísticas básicas base de datos (potencia en m y acumulación en ppm*m). Inferior, correlación entre variables.

	Potencia	Acumulación
number of data:	515	515
mean value:	1.149	8.613
variance:	0.632	91.143
minimum:	0.001	0
lower quartile:	0.5	1.572
median:	1	5.02
upper quartile:	1.7	11.648
maximum:	3.8	35
	Potencia	Acumulación
Potencia	1.000	0.642
Acumulación	0.642	1.000

4.2.1. Predicción mediante Cokriging

En función de la correlación existente se efectúa la predicción de la variable acumulación mediante cokriging ordinario con la variable potencia. Para ello, el análisis variográfico conjunto entre ambas variables se realiza en una dirección principal de búsqueda orientada en N45° con tolerancia de 22.5°, con 8 pasos de 25 m de separación y una tolerancia de 12.5 m; el resultado de lo anterior se presenta en la Figura 25.

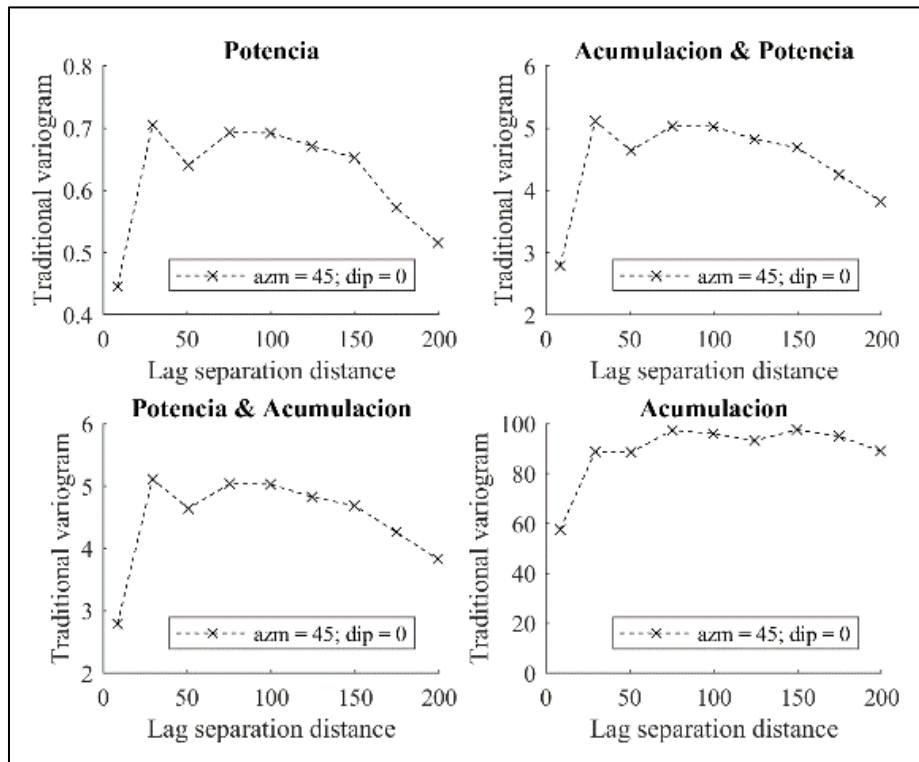


Figura 25: Variograma experimental de los datos directos y conjunto.

Por su parte, el mejor ajuste para modelar el variograma experimental conjunto se consigue con una estructura esférica de alcance 30 m y con efecto pepita tal como se muestra en la Figura 26.

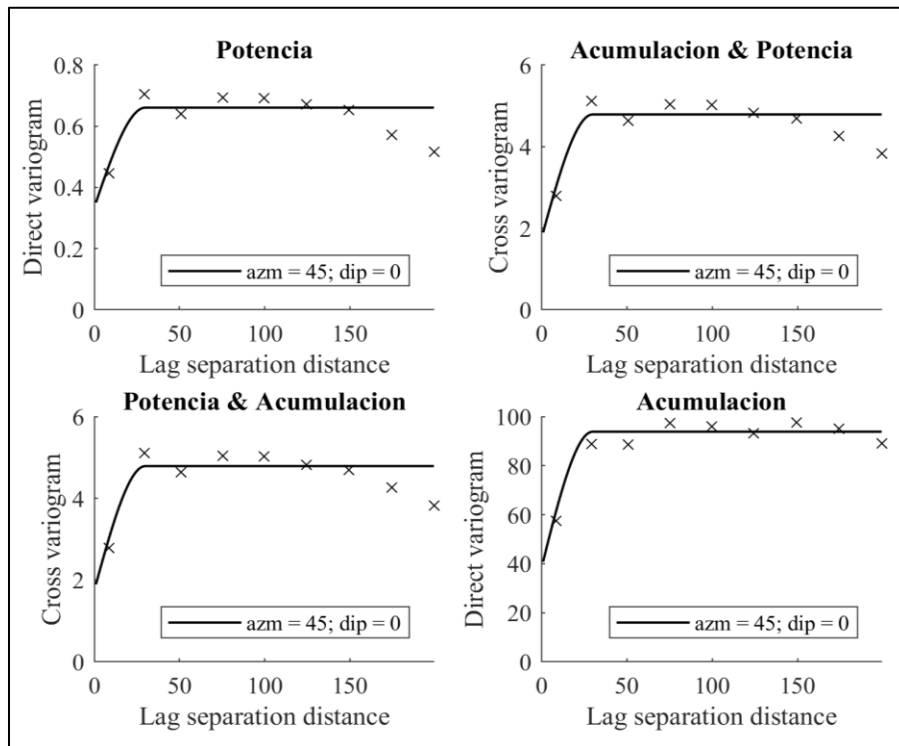


Figura 26: Variogramas modelados directos y conjunto.

A continuación, se realiza la validación cruzada de un plan de cokriging que considera elipse de búsqueda elongada 30 m según la dirección del variograma, dividido en octantes con 8 muestras en cada uno de ellos (Tabla 10).

Tabla 10: Plan de cokriging para potencia y acumulación.

Radio de búsqueda	30 m
Dirección de búsqueda	45°
Muestras por octante	8
Interpolador	Cokriging ordinario

Respecto al análisis de los errores se observa que la media es cercana a cero, por lo que se valida el insesgo, la varianza de los errores de la potencia es mínima, mientras que en la acumulación es más alta lo que habla de algunas pérdidas de precisión en la predicción, finalmente la varianza del error estandarizado es cercana a 1 en ambos casos, por lo que existe una buena determinación de la incertidumbre. En la Tabla 11 se resumen las estadísticas básicas de los errores.

Tabla 11: Estadísticas básicas de los errores.

	Error_Pot	Error_Ac	ESTD_Pot	ESTD_Ac
number of data:	509	509	509	509
mean value:	-0.013	-0.169	-0.019	-0.021
variance:	0.579	75.454	1.258	1.352
minimum:	-3.136	-25.828	-4.763	-3.626
lower quartile:	-0.454	-4.721	-0.646	-0.619
median:	-0.001	-1.344	-0.001	-0.179
upper quartile:	0.508	3.319	0.731	0.434
maximum:	2.569	32.979	3.895	4.707

Por su parte, el análisis de las nubes de correlación muestra buena concordancia entre el valor real y el predicho, lo anterior indica un bajo sesgo condicional (Figura 27A y 27B).

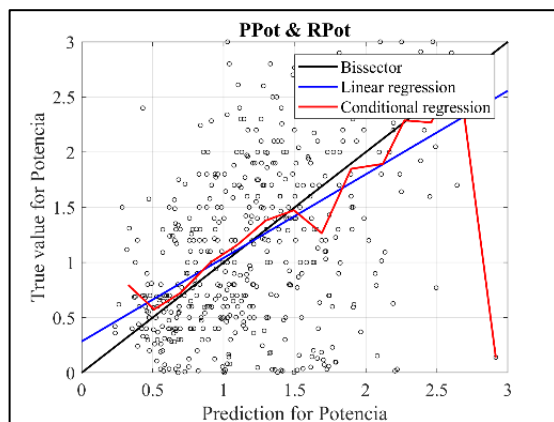


Figura 27A: Nube de correlación para potencia.

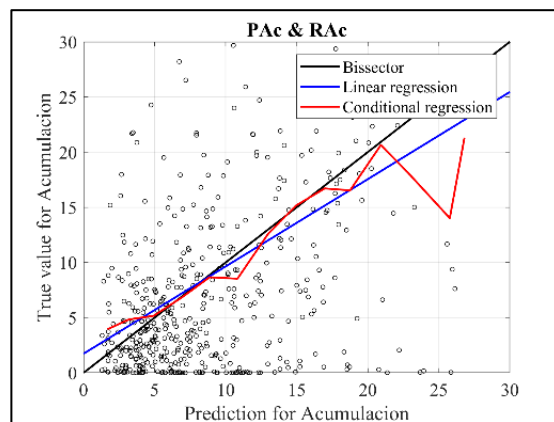


Figura 27B: Nube de correlación para acumulación.

Con base en lo anterior, se valida el plan de cokriging propuesto y se procede a realizar la predicción conjunta de las variables mediante medias relacionadas, se asume una distribución lineal de las medias y con ello se determina un factor de proporcionalidad de 7.5 (Ecuación 1.0), en un soporte de bloques de 12 m. Los resultados se presentan a continuación en la Figura 28A y 28B.

$$Ac = a + b * Pot; \text{ Si } Ac = 0 \rightarrow a = 0 \rightarrow Ac - b * Pot = 0 \rightarrow \frac{Ac}{Pot} = b \rightarrow b = 7.5 \quad (1.0)$$

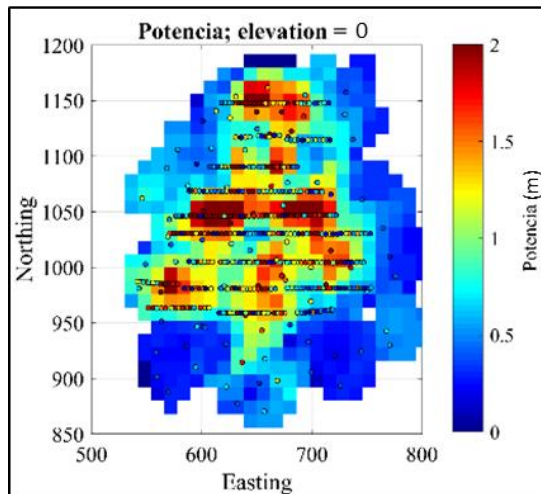


Figura 28A: Predicción Potencia.

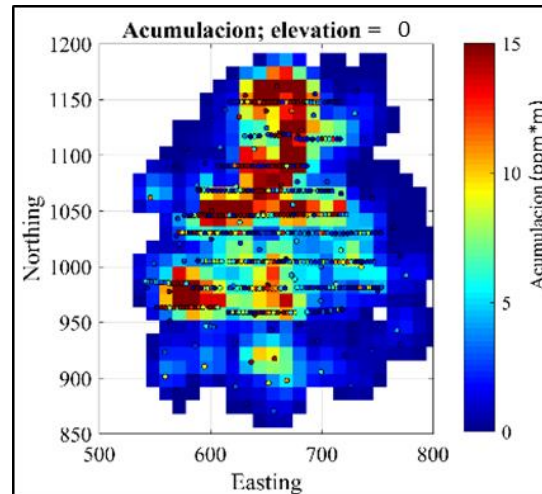


Figura 28B: Predicción Acumulación.

4.2.2. Predicción mediante Cosimulaciones

Dada la buena correlación existente entre las variables de acumulación y potencia, se determinará la incertidumbre a partir de cosimulaciones entre ellas. La primera etapa consiste en realizar la transformación *normal score* de los datos, para lo cual se considera que la distribución de la acumulación se encuentra comprendida entre el rango [0, 40]. Respecto al modelo de cola, se considera un valor igual a 1, mientras que para la cabeza se considera un valor de 0.5 (Figura 29A). Respecto a la potencia se considera un rango de entre [0, 4.0]; en cuanto al modelado de la cola se emplea un valor de 1.0 y en la cabeza de 0.5 (Figura 29B).




Figura 29A: Modelo de transformación gaussiano para muestras de acumulación 2D.




Figura 29B: Modelo de transformación gaussiano para muestras de potencia 2D.

A continuación, se procede a validar la hipótesis bigaussiana para extrapolarla a la distribución multigaussiana. En este sentido, se demuestra que la nube de dispersión para espaciamentos distintos experimenta un redondeamiento conforme aumenta la distancia de separación, tanto para acumulación como para potencia (Figura 30A y 30B).




Figura 30A: Nube de dispersión de potencia y acumulación a un espaciamiento de 4 m.




Figura 30B: Nube de dispersión de potencia y acumulación a un espaciamiento de 40 m.

Por su parte, la comparación entre el variograma de indicadores contra el variograma convencional muestra una buena relación entre el modelo y los datos (Figura 31A y 31B). Para lo anterior se considera que las muestras con valor gaussiano bajo o son identificadas con un 0, mientras que todas las muestras superiores a este umbral son catalogadas con un 1.




Figura 31A: Variograma contra variograma de indicadores 2D de potencia.

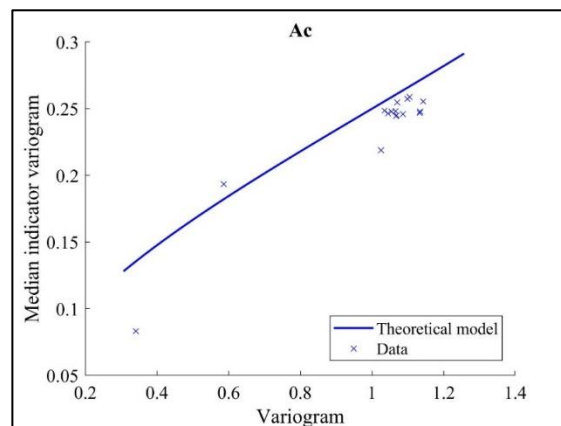


Figura 31B: Variograma contra variograma de indicadores 2D de acumulación.

Respecto al análisis de variogramas con distinto orden de ω se observa que existe una buena afinidad entre los datos y los modelos, notar que se cumple la condición sobre la pendiente ya que en cada conjunto de datos responde a $\omega/2$ en escala log-log (Figura 32A y 32B).




Figura 32A: Análisis de rodograma y madograma 2D para potencia.




Figura 32B: Análisis de rodograma y madograma 2D para acumulación.

Luego de realizadas y validadas las pruebas anteriores, se determina aceptar la hipótesis de distribución bigaussiana y, por lo tanto, también la hipótesis multigaussiana que constituye la base para efectuar las simulaciones.

A continuación, se procede con el análisis variográfico gaussiano conjunto. Para estas variables se encuentra que el mejor modelo variográfico se genera en un rumbo de $N45^\circ$ y con un manto vertical que es despreciable. El ajuste óptimo del modelo se logra con dos estructuras esféricas de alcance 30 y 100 m, un efecto pepita de 0.59 para la acumulación y 0.50 para la potencia (Figura 33). Es importante mencionar que en este caso se considera un efecto pepita elevado, dado que con ello se consigue un mejor ajuste en la validación cruzada de las simulaciones (*accuracy plot*). Por su parte, se define un elipsoide de búsqueda elongado 30 m según la orientación del variograma y con una restricción de 8 muestras por octante (Tabla 12).

Tabla 12: Plan de cokriging para valores gaussianos de acumulación y potencia

Radio de búsqueda	30 m
Dirección de búsqueda	45°
Muestras por octante	8
Interpolador	Cokriging ordinario

Una vez validado el modelo variográfico y el plan de kriging, se continúa con la validación del plan de simulaciones, para ello se calcula el gráfico de exactitud (*accuracy plot*) en el cual se evidencia una buena respuesta del modelo para potencia y acumulación (Figura 34A y 34B, respectivamente).

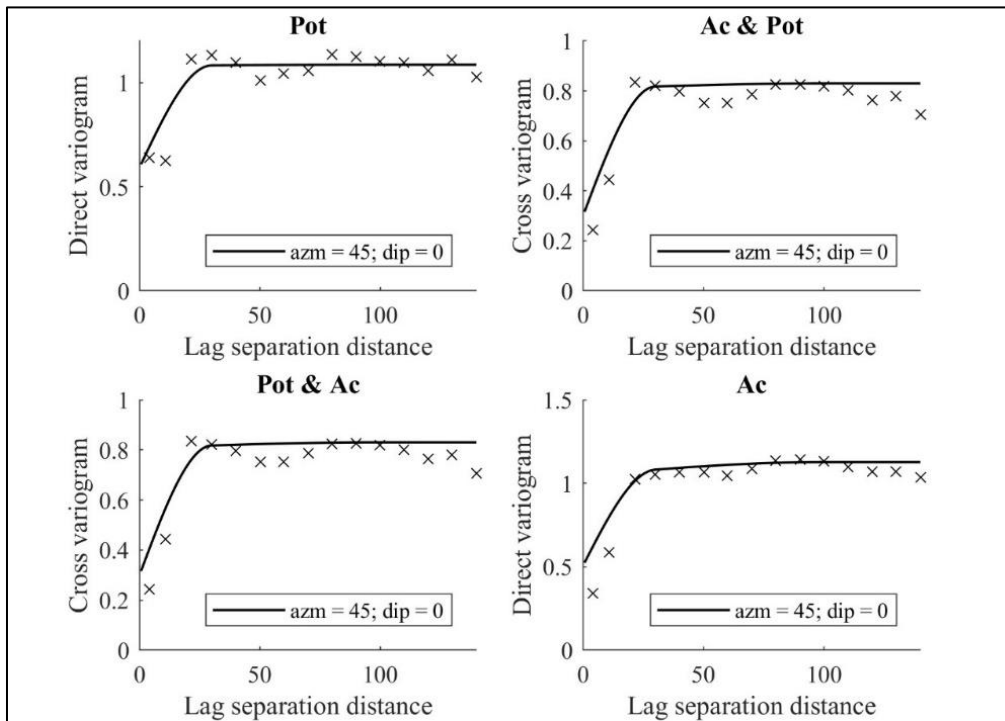


Figura 33: Modelo variográfico gaussiano conjunto en 2D para acumulación y potencia.




Figura 34A: Accuracy plot para plan de simulaciones de potencia 2D.




Figura 34B: Accuracy plot para plan de simulaciones de acumulación 2D.

Respecto a la validación cruzada del plan de simulaciones, se observa que existe un buen ajuste entre el valor predicho y real tanto para la potencia como para la acumulación (Figura 35A y 35B, respectivamente).

Luego de las consideraciones anteriores, se procede a generar 40 cosimulaciones por medio del algoritmo de las bandas rotantes en el software *XLIB* en un soporte puntual de bloques de 0.5 m (Tabla 13). Los resultados son posteriormente transformados y presentados como valores reales de potencia y acumulación (Figura 36A y 36B, respectivamente).




Figura 35A: Gráfico de validación cruzada entre valor de potencia predicho y real en entorno 2D.




Figura 35B: Gráfico de validación cruzada entre valor de acumulación predicho y real en entorno 2D.

Tabla 13: Parámetros cosimulaciones entre potencia y acumulación

N° Cosimulaciones	40
Tamaño bloque	0.5 m*0.5 m
Radio de búsqueda	100 m
Dirección de búsqueda	45°
Muestras por octante	8
N° líneas rotantes	1000
Ubicaciones simultánea	5000
Valor random (seed)	9784498
Interpolador	Kriging ordinario

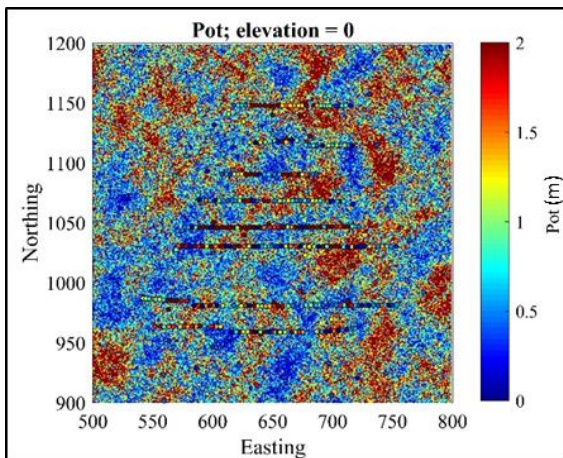


Figura 36A: Ejemplo de la distribución de potencia obtenida mediante las simulaciones.




Figura 36B: Ejemplo de la distribución de acumulación obtenida mediante simulaciones.

Al igual que en etapas anteriores se generan mallas de muestreo teórico con los mismos espaciamientos y a cada sitio se le asigna el valor de acumulación que indica una simulación aleatoria. En función de lo anterior, la configuración de muestreo queda representada en la Figura 37.

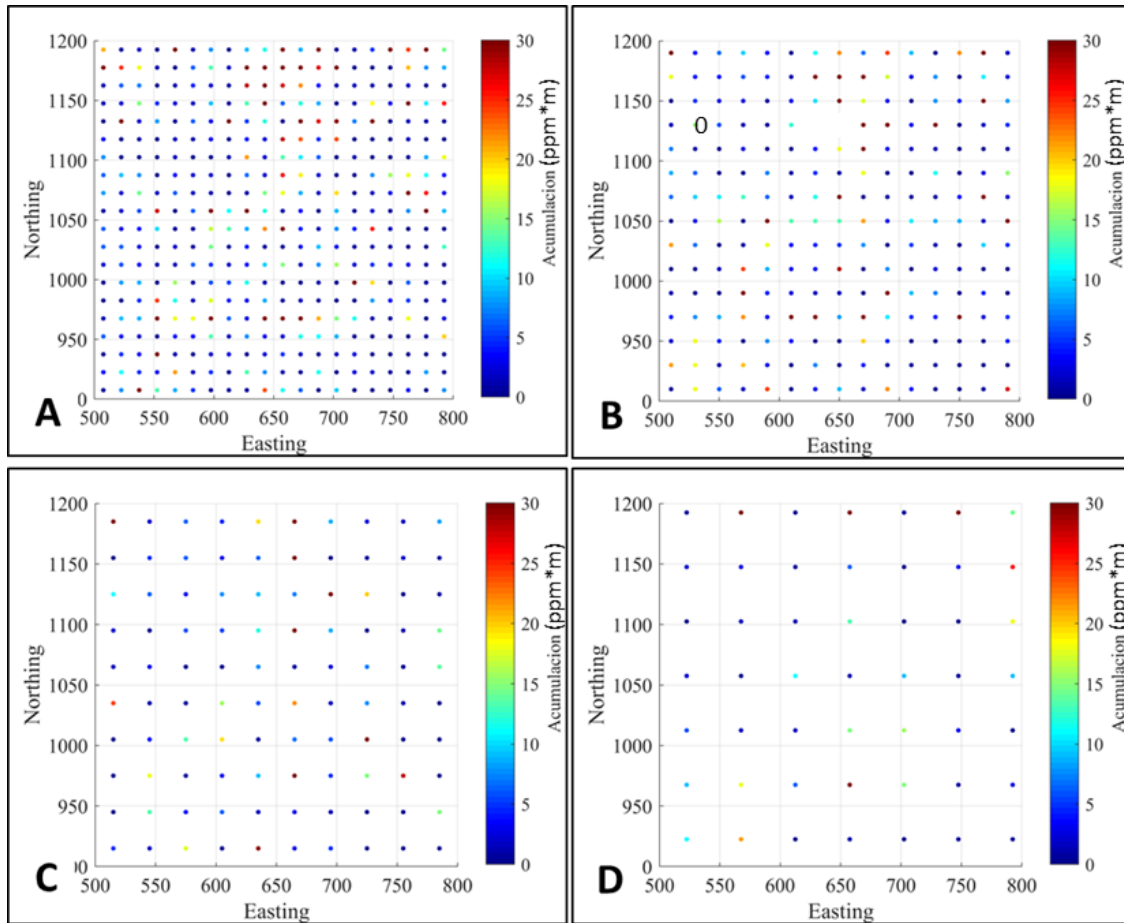


Figura 37: Mallas sintéticas 2D con acumulación proveniente de simulación. **A-** 15 m*15 m; **B-** 20 m*20 m; **C-** 30 m*30 m y **D-** 45 m*45 m.

A continuación, se realiza el análisis variográfico independiente con los datos de acumulación de la malla fina, que posteriormente se emplea en la estimación de cada uno de los escenarios.

Se encuentra que el mejor modelo variográfico se consigue con un azimut de $N45^\circ$, manto despreciable (escenario 2D) y 8 pasos de 15 m con tolerancia de 7.5 m. Mientras que el mejor ajuste se determina con 2 estructuras exponenciales, la primera de alcance 20 m y la segunda de 90 m, con contribuciones de 67 y 17, respectivamente; y con un valor del *nugget* de 10 (Figura 38).

Posteriormente, se efectúa la validación cruzada del plan de kriging para lo cual se define un elipsoide de búsqueda de 90 m, orientado en la dirección del variograma y dividido por octantes con 8 muestras en cada uno (Tabla 14).




Figura 38: Modelo variográfico acumulación.

Tabla 14: Plan de kriging para acumulación

Radio de búsqueda	90 m
Dirección de búsqueda	45°
Muestras por octante	8
Interpolador	Kriging ordinario

La nube de correlación entre los datos reales y los valores predichos (Figura 39) muestra buen ajuste por lo tanto se considera aceptable y por su parte, el análisis de los errores también indica que el plan de kriging es apropiado puesto que su media es cercana a 0 (Tabla 15A) y la varianza de los errores estandarizados es mínima y cercana a 1 (Tabla 15B).




Figura 39: Nube correlación acumulación

Tabla 15A: Estadística básica de la distribución de errores.

Statistics for Error:		Global
number of data:		400
mean value:	0.311	
variance:	25.966	

Tabla 15B: Estadística básica de la distribución de errores estandarizados.

Statistics for Error Estandarizado:		Global
number of data:		400
mean value:	-0.007	
variance:	0.664	

Basado en lo anterior, se realiza la estimación del modelo de bloques con cada una de las mallas indicadas. El resultado de las predicciones se exhibe en la Figura 40, en ella se observa que el suavizamiento propio del método es más notorio en los espaciamientos más elevados, donde, además, la estimación se vuelve menos confiable.

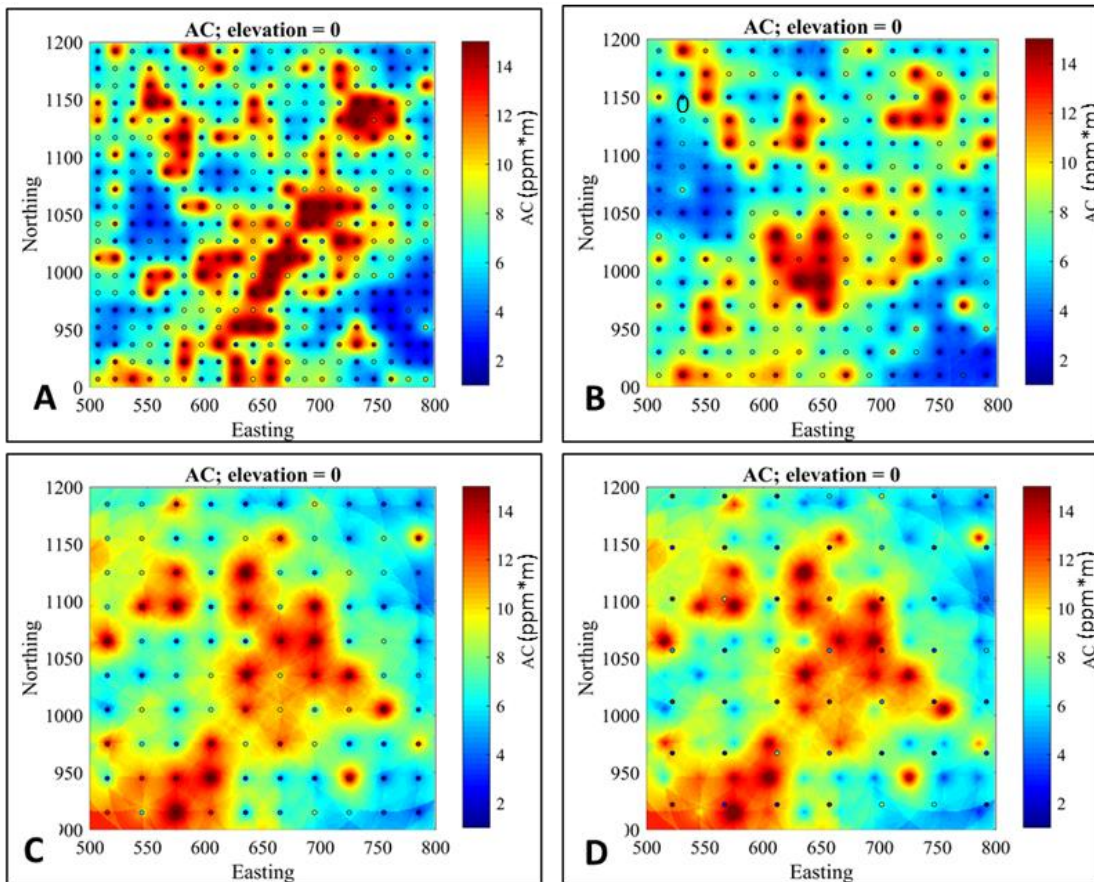


Figura 40: Predicción de acumulación mediante kriging ordinario con las diferentes mallas 2D. A- 15 m*15 m; B- 20 m*20 m; C- 30 m*30 m y D- 45 m*45 m.

5.3. Categorización de recursos minerales

Luego de todo el procedimiento realizado anteriormente, se procede a determinar una metodología simple, operativa y replicable de categorización para los recursos minerales estimados en la veta. Para ello, se utiliza como base la variabilidad de ley del bloque de acuerdo a las diferentes simulaciones y el resultado de la estimación. La metodología propuesta en este estudio consiste en contrastar la ley estimada por medio de kriging ordinario respecto a la distribución de frecuencia de las leyes

determinadas a partir de las simulaciones, tanto para la variable oro en el método directo, como de acumulación en el método indirecto.

Tal como se indica en el Capítulo 4, se clasifica el bloque como medido si la estimación difiere menos de un 10% respecto a la moda de las simulaciones, por su parte, se clasifica como indicado si oscila entre un 10-30% y finalmente, se considera como inferido si el valor del bloque se aleja más de un 30% respecto a las simulaciones.

4.3.1. Categorización de recursos minerales con metodología directa

A continuación, se aplica el criterio descrito anteriormente a los 4 modelos de bloques, correspondientes al resultado de la estimación de leyes de oro de cada malla sintética en el escenario 3D. El resultado de dicha categorización se evidencia en la Figura 41. Para las mallas menos espaciadas existe una dominancia de recursos minerales medidos e indicados, mientras que en las mallas menos densas predominan los recursos minerales inferidos.

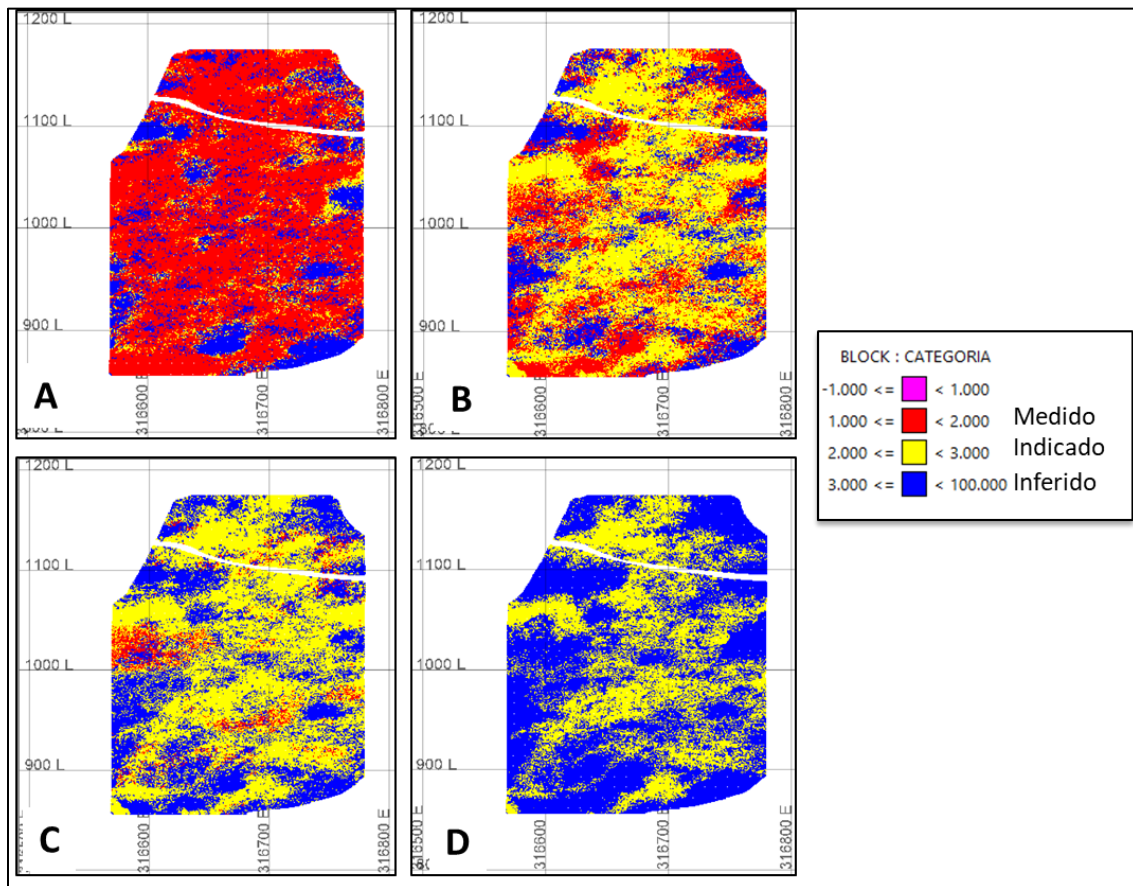


Figura 41: Resultado de aplicar criterio de categorización a los modelos de bloques 3D resultantes de las diversas mallas sintéticas. **A-** 15 m*15 m; **B-** 20 m*20 m; **C-** 30 m*30 m y **D-** 45 m*45 m.

Luego de categorizar los modelos de bloques, se realiza la cuantificación de los recursos minerales en función de la cantidad de metal contenido, expresado como onzas de oro, tal como se observa en la Tabla 16. En términos de los recursos minerales susceptibles a transformarse en reservas minerales (recursos medidos e indicados), se observa que con las primeras dos mallas se obtiene un resultado similar de onzas de oro, al igual que los recursos inferidos, mientras que para las mallas más espaciadas existe un aumento significativo de los recursos inferidos en desmedro de los medidos e indicados (Figura 41).

Tabla 16: Cuantificación de los recursos de oro según su categorización 3D, expresados en onzas de oro (Ley media en ppm y densidad constante de 2.5 t/m³).

	Ley Au	Onzas de oro			
		Medidas	Indicadas	Inferidas	Totales
Malla_15	7.1	41807	3352	21988	67147
Malla_20	7.5	12583	29712	28622	70918
Malla_30	7.1	3088	21771	41970	66829
Malla_45	7.2	0	16769	51045	67814

En la Figura 42 se observa la distribución porcentual de las onzas de oro por cada categoría de los recursos minerales. Se ratifica lo expresado en la Figura 39, donde se evidencia la disminución de los recursos minerales medidos e indicados conforme se aumenta el espaciamiento de muestreo.




Figura 42: Distribución porcentual de la cantidad de mineral según categoría por cada malla sintética 3D.

4.3.2. Categorización de recursos minerales con metodología indirecta

A continuación, se aplica la misma metodología para la categorización de recursos minerales pero basado en la variable acumulación del escenario 2D ya que presenta mayor continuidad espacial y además incluye intrínsecamente la incertidumbre del espesor de la veta. De manera análoga, para este caso se considera que si la acumulación estimada yace dentro del rango 10% ($\pm 5\%$) respecto a la mayor frecuencia de la acumulación simulada, el recurso mineral se considera como medido, mientras que, si se encuentra en el segmento de 10-30% ($\pm 15\%$) el recurso mineral se considera como indicado y finalmente, cualquier valor fuera de este umbral permite clasificar el bloque como recurso mineral inferido. Posteriormente se procede a rebloquear el modelo desde un soporte puntual de 0.5 m a un tamaño de bloque de 10 m, los resultados se exponen en la Figura 43.

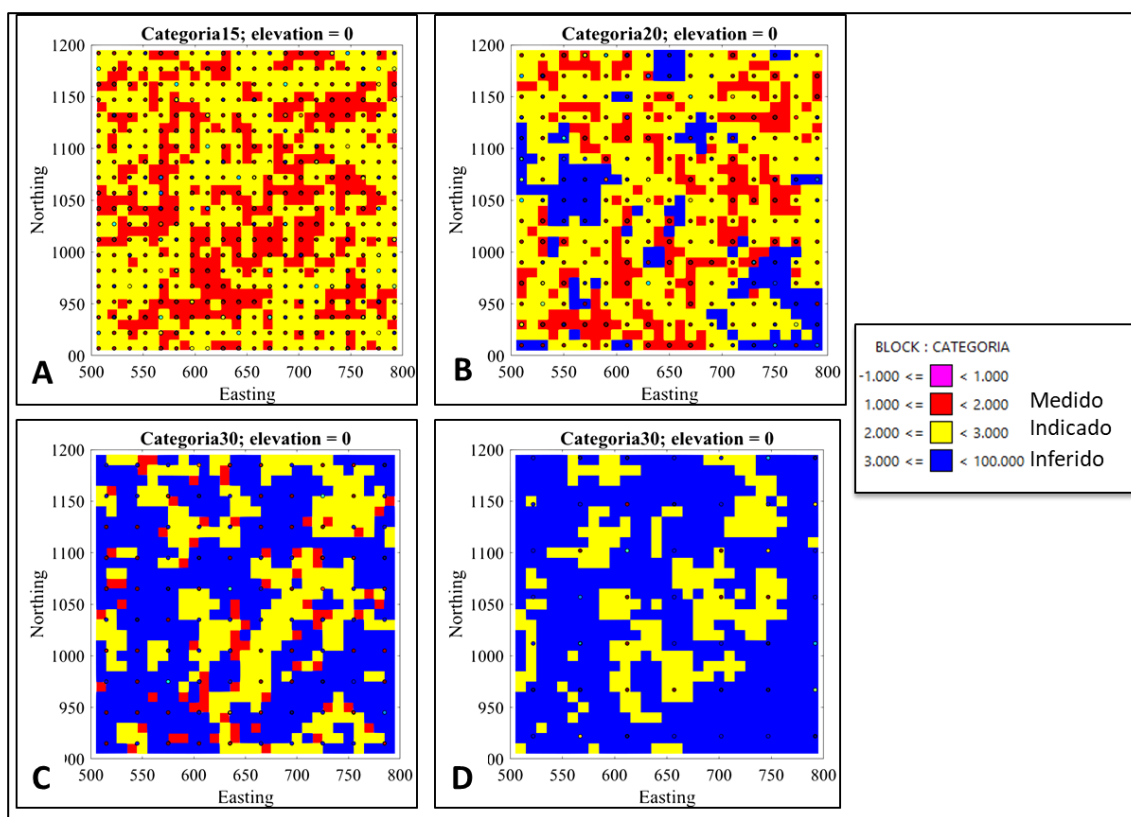


Figura 43: Resultado de aplicar criterio de categorización a los modelos de bloques 2D resultantes de las diversas mallas sintéticas. **A-** 15 m*15 m; **B-** 20 m*20 m; **C-** 30 m*30 m y **D-** 45 m*45 m.

La Tabla 17 presenta el resultado de la cubicación por malla de muestreo y por categoría del recurso mineral. Dado que la variable acumulación corresponde al producto entre la ley de oro y la potencia, se puede determinar el contenido de oro mediante la consideración de una densidad constante de 2.5 t/m³, los resultados de lo anterior se presentan en la Tabla 18.

Tabla 17: Acumulación promedio por malla y cuantificación de bloques por categoría en ppm*m.

	Acumulación	Medido	Indicado	Inferido
Malla_15	7.6	352	548	0
Malla_20	7.4	230	518	152
Malla_30	8.5	75	283	542
Malla_45	8.5	0	221	679

Tabla 18: Onzas de oro por malla y categoría del recurso mineral a partir de variable acumulación en ppm*m.

	Acumulación	Onzas de oro			
		Medidas	Indicadas	Inferidas	Totales
Malla_15	7.6	21462	33412	0	54874
Malla_20	7.4	13760	30990	9093	53843
Malla_30	8.5	5121	19322	37005	61447
Malla_45	8.5	0	15089	46358	61447

Finalmente, en la Figura 44 se muestra la distribución porcentual de las onzas de oro por cada categoría del recurso mineral y para cada una de las mallas de muestreo teorizadas. La información es concordante con lo observado en la Figura 43, donde se evidencia la dominancia de los recursos medidos e indicados en las primeras dos mallas, para luego decaer significativamente conforme aumenta el espaciamiento para dar lugar a un aumento notorio de los recursos inferidos.




Figura 44: Distribución porcentual de las onzas de oro según categoría del recurso para cada malla sintética a partir de la variable acumulación.

6. Discusión

En función de los resultados obtenidos es posible interpretar que la variable indirecta de acumulación presenta mayor continuidad espacial respecto a la distribución original de la ley de oro. De esta forma, existe una menor incertidumbre entre las muestras equiespaciadas del escenario 2D respecto al escenario inicial 3D. Basado en lo anterior, la categorización de los recursos minerales se ve favorecida con la metodología indirecta, ya que la suma de recursos minerales medidos e indicados alcanza un 100% con el espaciamiento de 15 m*15 m, luego decae a un 85% con el espaciamiento de 20 m*20 m, posteriormente, con el espaciamiento de 30 m*30 m baja a un 40% y finalmente, con la malla de 45 m*45 m, desciende hasta un 25%. Mientras que con el método directo se obtiene un 65%, 60%, 40% y 25%, respectivamente de recursos minerales medidos e indicados, considerar que se cuantifica en dominios distintos. Bajo este análisis, la mejor configuración para diseñar una malla de sondajes es con un espaciamiento de entre 20 m y 30 m (promedio de 25 m); ya que basado en la variable acumulación se observa que existe dominancia de recursos medidos para una separación de 20 m*20 m; mientras que para una configuración de 30 m* 30 m la mayor ocurrencia corresponde a recursos inferidos.

Ahora bien, al contrastar la categorización de los recursos minerales de la malla de 30 m* 30 m con la distribución de acumulación cosimulada (Figura 45) se observa que existe correlación entre las zonas de mayor acumulación con las zonas de recursos minerales inferidos, tal como indica el efecto proporcional. En este contexto es posible definir una malla diferenciada para el muestreo tal que, las áreas de baja acumulación que suelen presentar menor variabilidad se perforan con un espaciamiento de 30 m* 30 m; o máximo de 35 m* 35 m en los sectores que se busque condenar; mientras que los sectores con valores elevados de acumulación sean muestreados con un arreglo menos separado de 20 m* 20 m; o como máximo de 25 m* 25 m en las zonas cercanas a cuerpos de menor acumulación.

A continuación, se realiza un análisis rápido del precio de la información y del impacto económico que significa la clasificación errónea de un bloque de 10 m*10 m*1.2 m (espesor promedio), con densidad de 2.5 t/m³ y una ley promedio de 7.5 ppm (acumulación de 9 ppm*m). El potencial del bloque es de unas 72 onzas de oro, vale decir, US\$94,000 contenidos en 300 toneladas de mineral (se asume un precio de US\$1300 por onza de oro). No obstante, si el nivel de confianza es bajo y realmente el material es estéril se produce un gasto de U\$24,000 al extraerlo y procesarlo sin generar beneficio (se asume costo mina y planta de 40 U\$/t cada uno). En la Tabla 19 se exhiben de manera simplificada los costos o beneficios de clasificar un bloque de manera errada.




Figura 45: Distribución de acumulación cubierta por sombra de recursos medidos e indicados (área blanca), notar que los lugares no cubiertos por la sombra corresponden a recursos inferidos que coinciden con zonas de mayor acumulación.

Tabla 19: Costo/beneficio de cada bloque según su destino.

Material/Destino	Proceso (US\$)	Botadero (US\$)
Con ley	\$ 70,041	\$ -12,000
Sin ley	\$ -24,000	\$ -12,000

Del análisis anterior se desprende que prescindir de un sondaje en la zona de alta acumulación genera la pérdida de confianza en 4 bloques (Figura 46A) que podrían contener 290 onzas Au (US\$376,000) o bien, en el caso opuesto podría procesarse sin contar con ley de oro y costar US\$96,000 sin generar utilidades. Para el caso de las zonas de baja acumulación, cada sondaje permite aumentar la confianza de 9 bloques (Figura 46B) con el fin de condenar sectores y que no se desarrolle infraestructura ni interés económico al respecto.

Mediante el análisis indirecto se evidencia un aumento en la continuidad espacial de las variables y bajo este escenario es posible definir dos arreglos de mallas según la acumulación que existe, a valores bajos (subeconómicos) se alcanza un buen nivel de confianza en la categorización de los recursos minerales al sondear con un espaciamiento de 30 m*30 m, incluso con 35 m*35 m para los sectores con muy bajo valor de acumulación. Mientras que en las zonas mayor acumulación se propone

emplear un espaciamiento más reducido de 20 m*20 m o bien, 25 m*25 m en las zonas aledañas a sectores de baja acumulación.

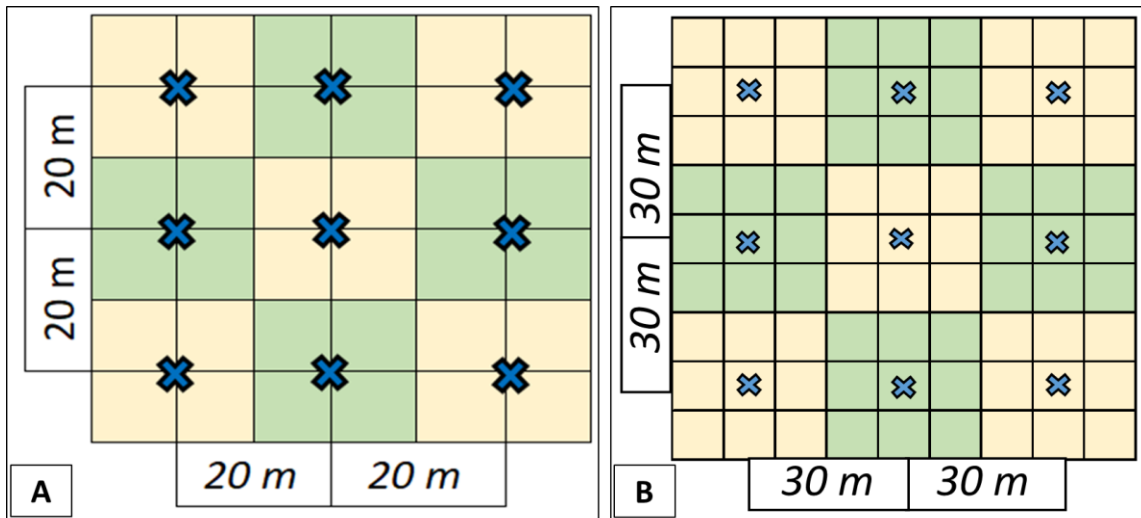


Figura 46: Halo de influencia de cada sondaje (cruz azul). **A-** Configuración de alta variabilidad en acumulación con malla 20 m. **B-** Configuración baja variabilidad en acumulación con malla 30 m.

Si bien el análisis indirecto requiere mayor cantidad de tiempo de procesamiento y resulta poco operativo en la cotidianidad, resulta ser la mejor herramienta para maximizar la separación entre perforaciones sin sacrificar confianza y con ello abarcar mayor área en la exploración a menores costos. Cabe mencionar que otra ventaja de la acumulación se produce por su naturaleza que incorpora la ley y la potencia, por lo tanto, permite incorporar la incertidumbre en ambas variables, en particular, la incertidumbre en la delimitación del ancho de la veta que es útil para comprobar y ajustar el modelamiento. Asimismo, es una variable aditiva y también, más adecuada para medir todas las fuentes de incertidumbre geológica, no solamente en ley.

Finalmente, puesto que se puede realizar mediciones directas del espesor de la veta a lo largo de todos los desarrollos, se recomienda que para las evaluaciones de mediano plazo se realice la predicción de manera conjunta con las leyes de oro vía acumulación, puesto que los resultados presentan mayor continuidad y confianza.

7. Conclusión

Con base en los resultados obtenidos, se concluye que es factible emplear técnicas geoestadísticas modernas en un sistema aurífero de vetas angostas y establecer una metodología cuantitativa para la determinación del espaciamiento entre las muestras con tal de favorecer la categorización de los recursos minerales. Dada la naturaleza del depósito es crucial asegurar la calidad de la información desde la toma de muestras, ya que en este tipo de yacimientos existe una variabilidad extremadamente alta que suele ser muy compleja de modelar y controlar.

La comparación entre los resultados del método directo de predicción 3D contra aquellos obtenidos de manera indirecta en un escenario 2D, demuestran que a través de este último se consigue una mayor continuidad espacial de la variable acumulación y, por lo tanto, la categorización de los recursos minerales se ve magnificada. Por otro lado, la variable acumulación también es ventajosa ya que presenta la condición de aditividad e incluye la ley y la potencia, por lo tanto, permite determinar ambas incertidumbres, lo que resulta útil en la etapa de modelamiento.

Se propone un método simple de categorización para los recursos minerales, basado en la relación que se produce entre la ley/acumulación estimada y el histograma de las leyes/acumulaciones simuladas. Se indica que si la ley/acumulación del bloque estimado se encuentra dentro del rango $\pm 5\%$ respecto a la mayor frecuencia, se categoriza como recurso mineral medido, mientras que si se sitúa en el intervalo $\pm 5\% - \pm 15\%$ se considera como recurso mineral indicado, finalmente, si escapa a estos rangos se clasifica como recurso mineral inferido.

En función de lo anterior, se determina que es posible aplicar dos configuraciones de espaciamiento según el valor de acumulación, la primera es aplicable para zonas de bajo valor económico que suelen presentar mayor continuidad, en este caso se debe realizar el muestreo en una malla cuadrada equidistanciada 30 m*30 m o incluso, 35 m*35 m si el sector presenta valores extremadamente bajos de acumulación. Por otro lado, la segunda configuración que debe aplicarse en los sectores de alta acumulación con mayor variabilidad (efecto proporcional) es una malla cuadrada de 20 m*20 m, o bien, 25 m*25 m en las zonas aledañas a sectores de baja acumulación. Cabe mencionar que en ambos casos de espaciamiento se cumple con el nivel de confianza para categorizar los recursos minerales como medidos e indicados.

8. Bibliografía

- Abzalov, M Z and Bower, J., 2009. Optimisation of the drill grid at the Weipa bauxite deposit using conditional simulation, in Proceedings Seventh International Mining Geology Conference 2009, pp 247-252. The Australasian Institute of Mining and Metallurgy: Melbourne.
- Afonseca, B.C, Miguel-Silva, V., 2022. Defining optimal drill-hole spacing: A novel integrated analysis from exploration to ore control. *Journal of the Southern African Institute of Mining and Metallurgy*, 122(6): 1–11.
- Alfaro, M., 2015. La Simulación Condicional en un Depósito Minero. Editorial UdeC.
- Angulo, J., 2018. Metodología Para la Optimización de la Malla de Muestreo de Corto Plazo de Lateritas Niquelíferas [tesis de maestría inédita]. Universidad de Chile.
- Bertoli, O., Mukangai, J., y Dunham, S., 2003. Two-Dimensional Geostatistical Methods - Theory, Practice and a Case Study from the 1A Shoot Nickel Deposit, Leinster, Western Australia. *Proceedings Fifth International Mining Geology*, 1 (1), 1-7.
- Bertoli, O., Paul, A., Casley, Z., Dunn, D., 2013. Geostatistical drillhole spacing analysis for coal resource classification in the Bowen Basin, Queensland. *International Journal of Coal Geology*, 112: 107-113.
- Boucher, A., Dimitrakopoulos, R., Vargas-Guzmán, J. A., 2004. Joint Simulations, Optimal Drillhole Spacing and the Role of the Stockpile. *Geostatistics Banff 2004*. pp 35-44.
- Boyle, C., 2009. Conditional Simulation Methods to Determine Optimum Drill Hole Spacing, *Advances in Orebody Modelling and Strategic Mine Planning*, vol(17). 67-77.
- Carmona, C., 2020. Estimación de Oro y Análisis de Incertidumbre Mediante Simulación Gaussiana, Veta Pedro Valencia Sur, Alhué, Chile [tesis de maestría inédita]. Universidad de Concepción.
- Cornah, A., Vann, J., Driver, I., 2013. Comparison of three geostatistical approaches to quantify the impact of drill spacing on resource confidence for a coal seam (with a case example from Moranbah North, Queensland, Australia). *International Journal of Coal Geology*, 112: 114–12.
- Deutsch, C, Leuangthong, O., y Ortiz, J., 2007. Case for geometric criteria in resources and reserves classification. *Transactions-society for mining metallurgy and exploration incorporated*, 322(1). 1-11.
- Dimitrakopoulos, R., Godoy, M.y Chou, C., 2009. Resource/Reserve Classification with Integrated Geometric and Local Grade Variability Measures.

- Advances in Orebody Modelling and Strategic Mine Planning, vol(17). 207-214.
- Dominy, S., Annels, A., Camm, G., Cuffley, B., y Hodkinson, I., 1999. Resource evaluation of narrow gold-bearing veins: Problems and methods of grade estimation. Transactions of the Institution of Mining and Metallurgy-Section A-Mining Industry, 108, A52.
- Emery, X., 2000. Geoestadística Lineal. Departamento de Ingeniería de Minas, Universidad de Chile, 411 p.
- Emery, X., Ortiz, J. y Rodríguez, J., 2006. Quantifying Uncertainty in Mineral Resources by Use of Classification Schemes and Conditional Simulations. Math Geol 38, 445-464.
- Englund, E. y Heravi, N., 1992. Conditional Simulation: Practical Application for Sampling Design Optimization. Geostatistics Troia. 613-624.
- Li, S., Dimitrakopoulos, R., Scott, J. y Dunn, D., 2004. Quantification of Geological Uncertainty and Risk Using Stochastic Simulation and Applications in the Coal Mining Industry. Orebody Modelling and Strategic Mine Planning, second edition. 185-192.
- McBratney, A.B., Webster, R., Burgess, T.M., 1981. The design of optimal sampling schemes for local estimation and mapping of regionalized variables—I: Theory and method. Computers & Geosciences, 7, 331-334.
- Magallanes, O. y Saez, F., 2013. Estudio de Espaciamiento Optimo de Taladros Usando Simulación Condicional en la Mina Tantahuatay. Congreso Internacional de Prospectores y Exploradores, ProExplo, vol(VIII). 1-15.
- Martinez-Vargas, A., 2017. Optimizing Grade-Control Drillhole Spacing with Conditional Simulation. Minería y Geología, vol(33). 1-12.
- Meszaros, L., 2023. Modelamiento de depósitos de vetas polimetálicas de geometría estrecha a través de geoestadística transitiva. Tesis de Postgrado. Universidad de Chile. Santiago. 145 p.
- Ortiz, J. y Emery, X., 2004. Categorización de Recursos y Reservas Mineras [sesión de conferencia]. 1st International Conference on Mining Innovation MININ.
- Quintana, K., 2018. Caracterización Petrográfica y Calcográfica de Zona Mina Este, Distrito Minero Alhué [tesis de pregrado inédita]. Universidad de Concepción.
- Ramadhan, M.D., Marwanza, I., Nas, C., Azizi, M.A., Dahani, W., Kurniawati, R., 2020. Drill Holes Spacing Analysis for Estimation and Classification of Coal Resources Based on Variogram and Kriging. IOP Conf. Ser.: Earth Environ. Sci. 819 012026.

- Rojas, O., Cáceres, A., 2011. The use of Conditional Simulation for Drill Hole Spacing Evaluation and Decision-Making in Telegrafo Project, Northern Chile. In: Eighth International Mining Geology Conference, New Zealand.
- Rossi, M. y Camacho, J., 2000. Simulaciones Condicionales Geoestadísticas Aplicada a la Clasificación de Recursos. <https://acortar.link/Oy42TY>
- Rossi, M. y Deutsch, C., 2014. Mineral Resource Estimation. Springer. 337 p.
- Schofield, N.A., 2001. Determining optimal drilling densities for near mine resources. In: Mineral Resource and Ore Reserve Estimation—The AusIMM Guide to Good Practice. AusIMM Monograph 23, pp 293–298.
- Verly, G., Postolski, T., Parker, H.M., 2014. Assessing Uncertainty with Drill hole Spacing Studies – Applications to Mineral Resources. Orebody Modelling and Strategic Mine Planning Symposium 2014, pp109-118. The Australasian Institute of Mining and Metallurgy: Melbourne.
- Zuñiga, R., y Emery, X., 2010. Evaluating mineral resources in a narrow vein-type deposit. En Proceedings of the IV International Conference on Mining Innovation MININ 2010 (p. 347-355). Gecamin Ltda, Santiago, Chile.