

---

# Curso MINERÍA

---

Profesor: Dr. Julián M. Ortiz

---

# 04 – Desarrollo Minero

---

---

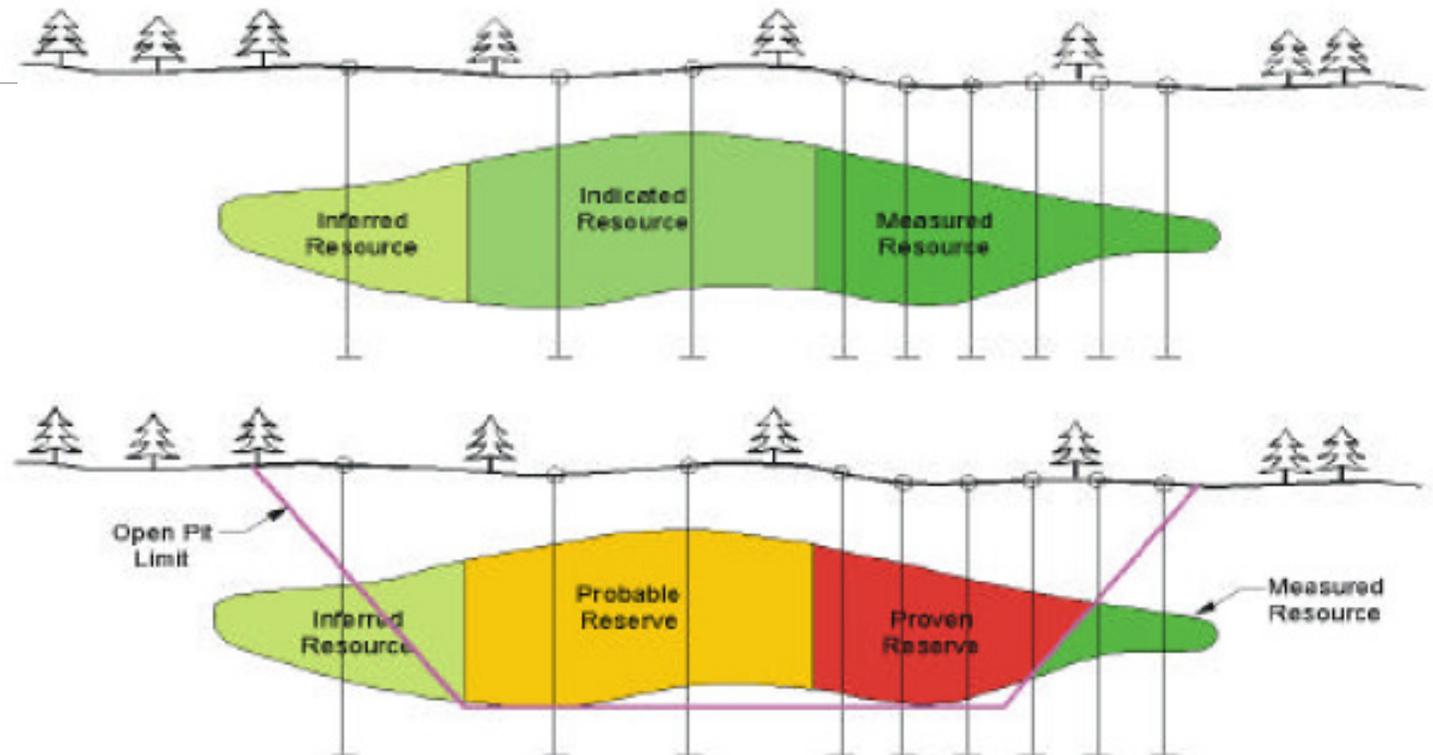
# Evaluación de recursos y reservas

---



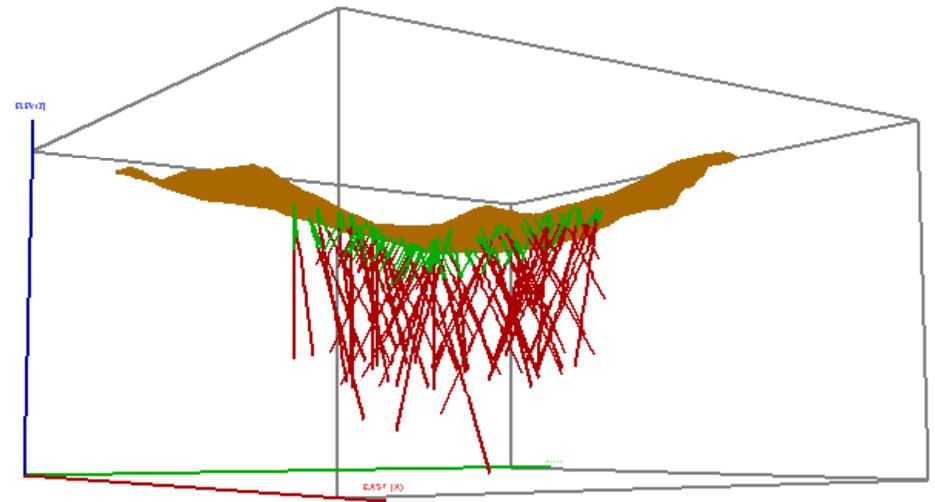
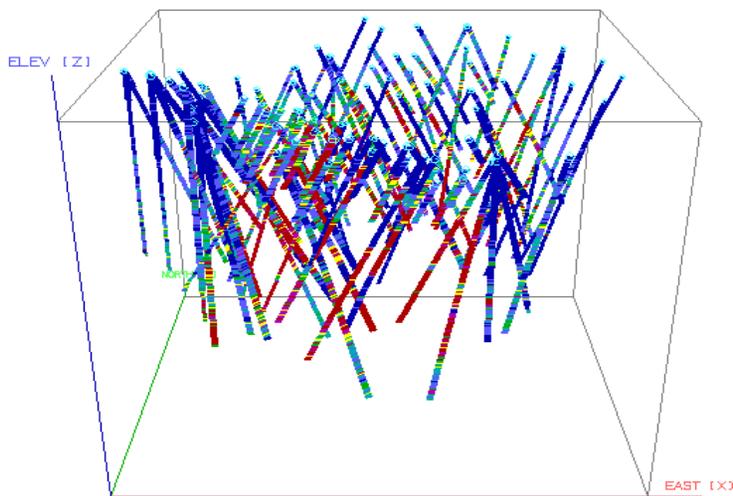
# Generalidades

- La determinación de los recursos es una etapa crítica en los proyectos mineros
  - Se requiere una cuantificación de la **cantidad y calidad** de los recursos
  - Se requiere una cuantificación del **error**
  - Se deben definir los **recursos bancables** para buscar el financiamiento del proyecto
  - Existen estándares internacionales para el **reporte** de recursos y reservas



# Generalidades

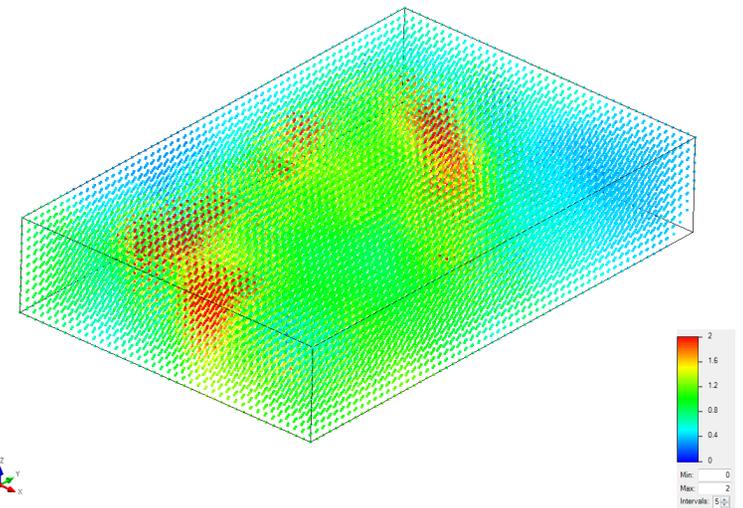
- La exploración avanzada genera una base de datos proveniente de una campaña de sondajes en una grilla pseudo-regular



- ¿Cómo cuantificamos los recursos?

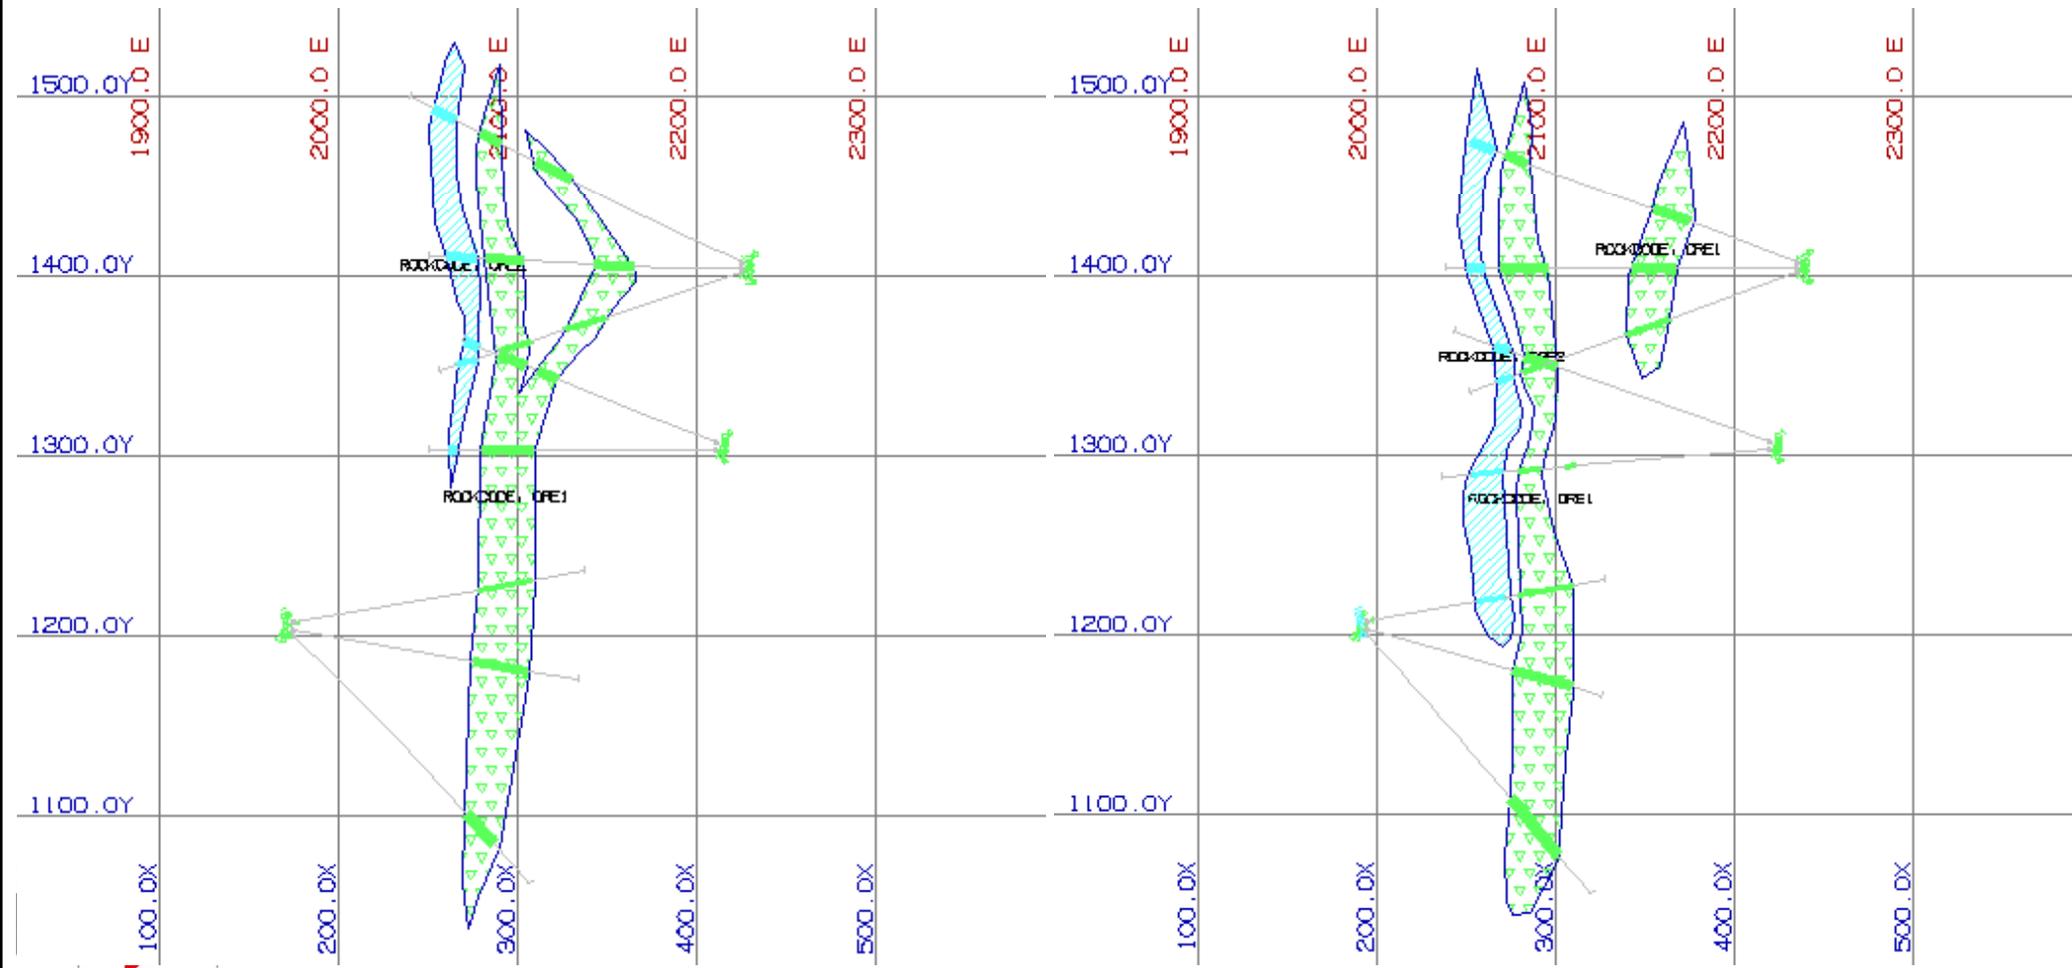
# Generalidades

- Procedimiento típico:
  - Interpretación del depósito → modelo geológico
  - Análisis de datos → representatividad / chance (valores erráticos → outliers)
  - Análisis de continuidad espacial:
    - Mineralización
    - Leyes
  - Estimación
  - Error asociado a la estimación / categorización
  - Validación de modelos



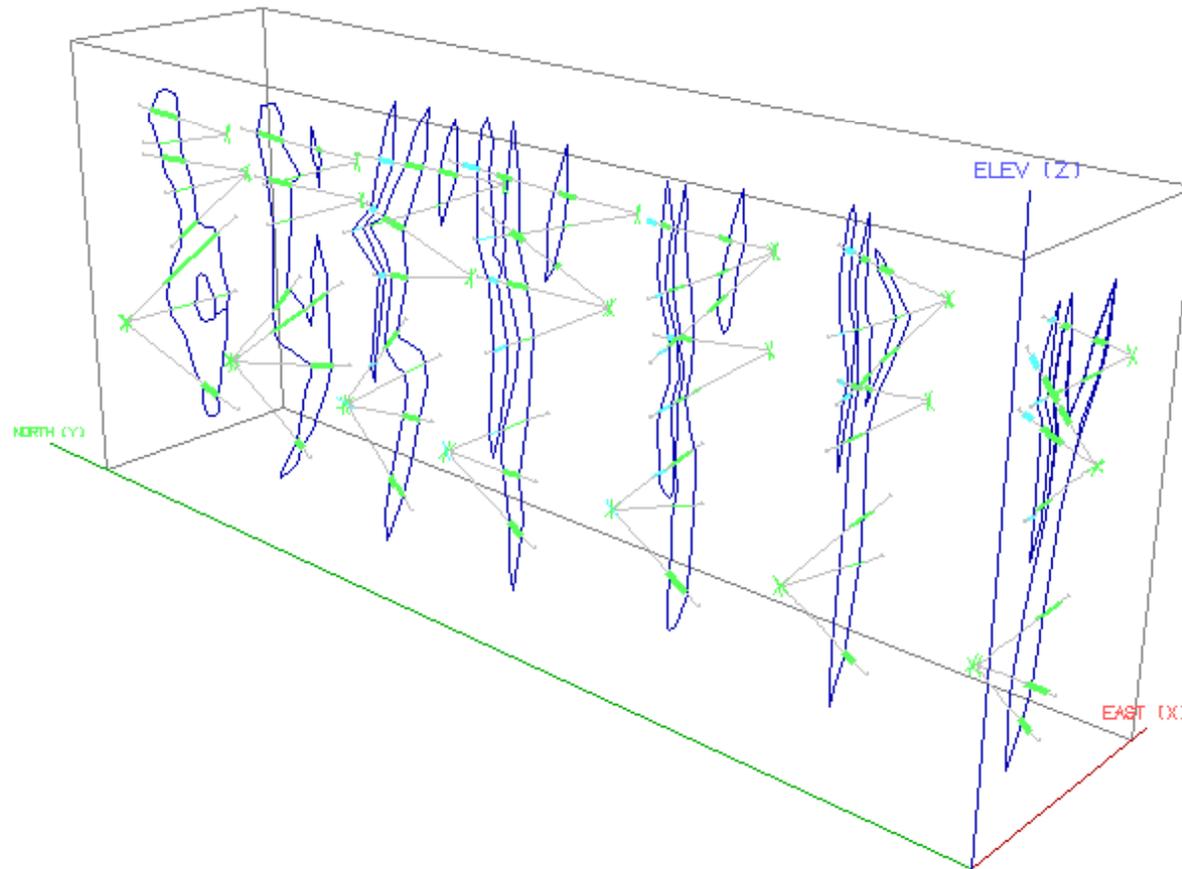
# Interpretación geológica

- Análisis utilizando plantas y secciones → Isoleyes / Mineralización / Alteración / Litología / Estructuras



# Interpretación geológica

- Visualización en 3-D  $\Rightarrow$  interpretación



---

# Interpretación geológica

---

- Se deben definir volúmenes en los que la variable en estudio tenga un comportamiento “homogéneo”
  - Geológicamente
  - Estadísticamente
- Dentro de cada unidad de estimación, las muestras son homogéneas → “no mezclar peras con manzanas”



¿Cuál es la ley en este punto?

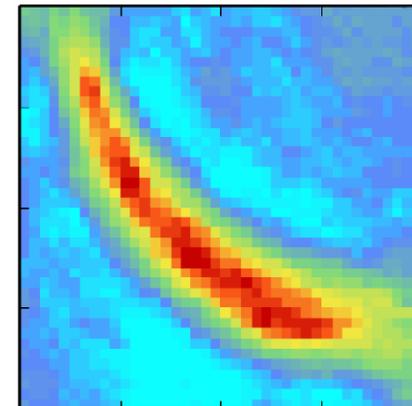


---

# Generalidades

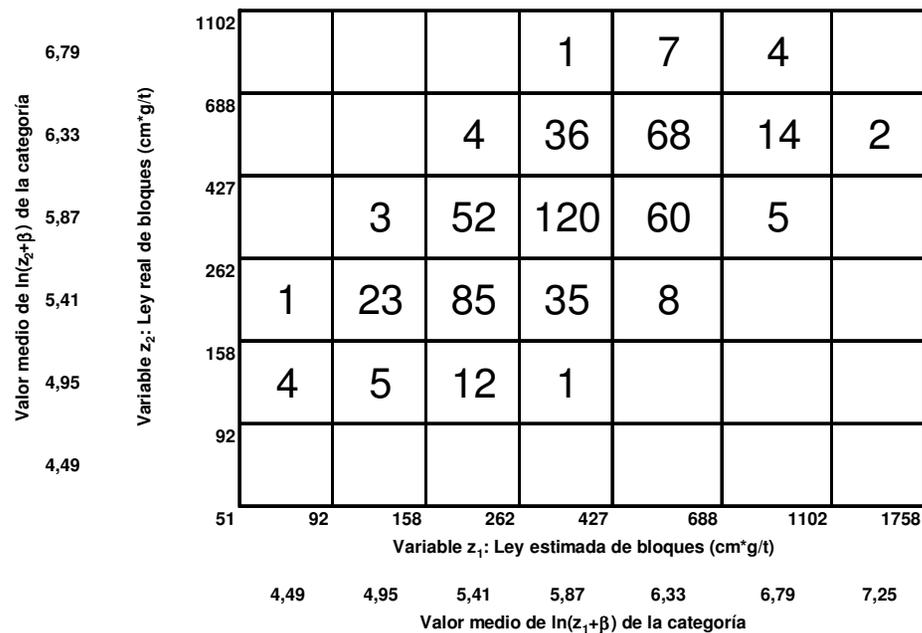
---

- La **estadística** se ocupa de los métodos científicos para recolectar, organizar, resumir, presentar y analizar datos así como obtener conclusiones válidas y tomar decisiones razonables sobre la base de dicho análisis.
- La **geoestadística** es una rama de la estadística aplicada que pone énfasis en:
  - El contexto geológico de los datos,
  - La relación espacial entre los datos, y
  - Datos medidos con un soporte volumétrico y precisión diferentes.
- La geoestadística es útil para:
  - Cuantificar aspectos geológicos.
  - Estimación / Simulación.
  - Cuantificación de la incertidumbre.
  - Diseño de muestra.
  - Análisis de riesgo.



# Primeras aplicaciones

- Regresión Lognormal: Mina Harmony (Sudáfrica).



- Sesgo Condicional: subestimación de leyes bajas y sobreestimación de leyes altas.

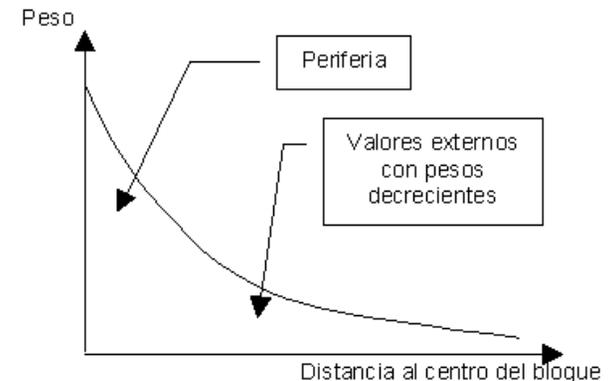
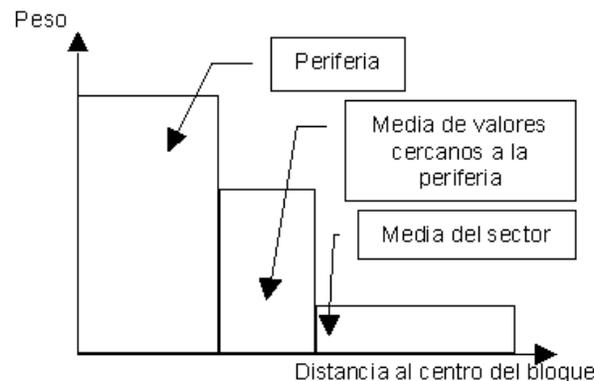
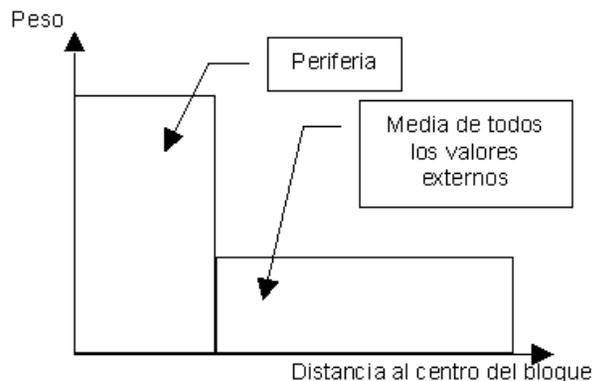
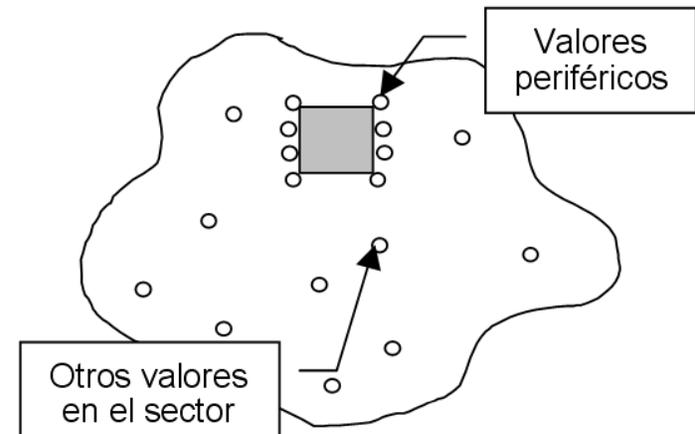
# Paso de la regresión a promedios ponderados

- Ecuación de la recta de regresión:

$$\hat{z}_2 = z_1 \cdot \left( r \cdot \frac{s_{z_2}}{s_{z_1}} \right) + m \cdot \left( 1 - r \cdot \frac{s_{z_2}}{s_{z_1}} \right)$$

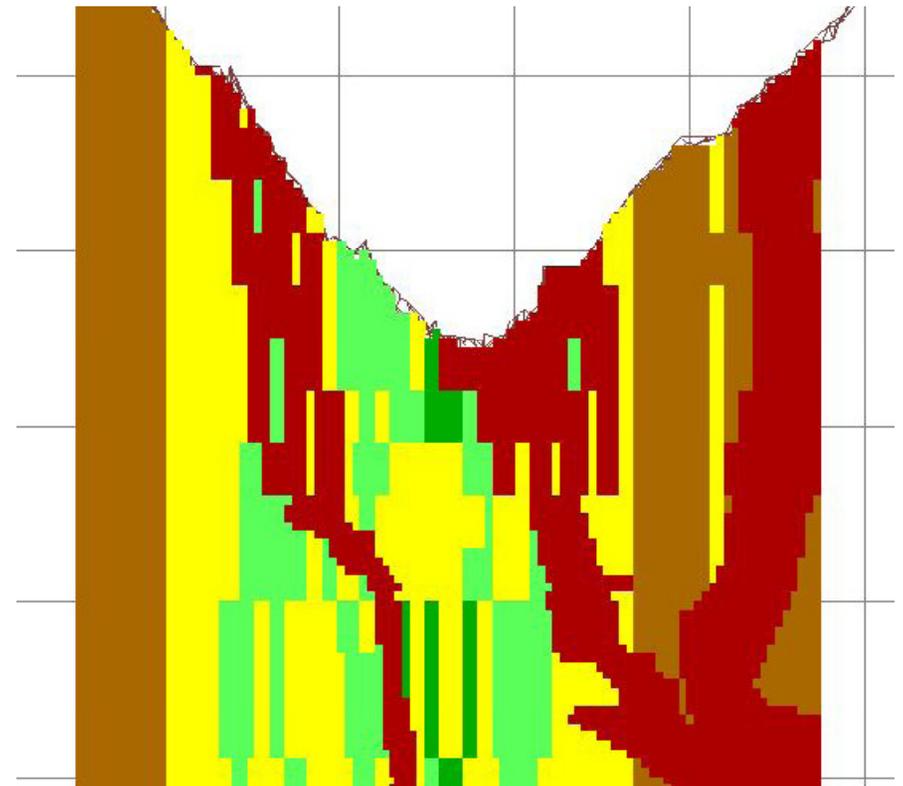
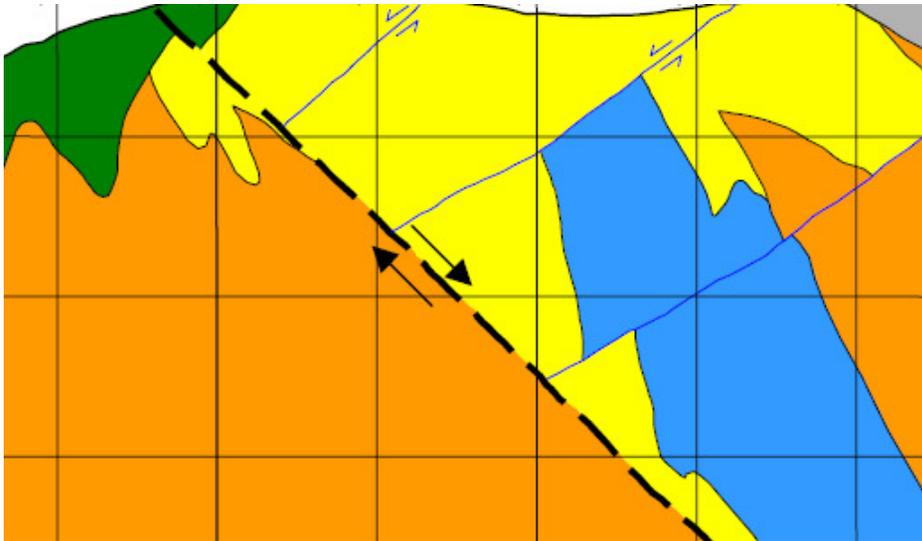
es un promedio ponderado de la ley de los valores periféricos y de la media del sector.

- Origen del kriging



# Modelos geológicos

- Combinación de características geológicas
  - Litologías
  - Alteraciones
  - Mineralización

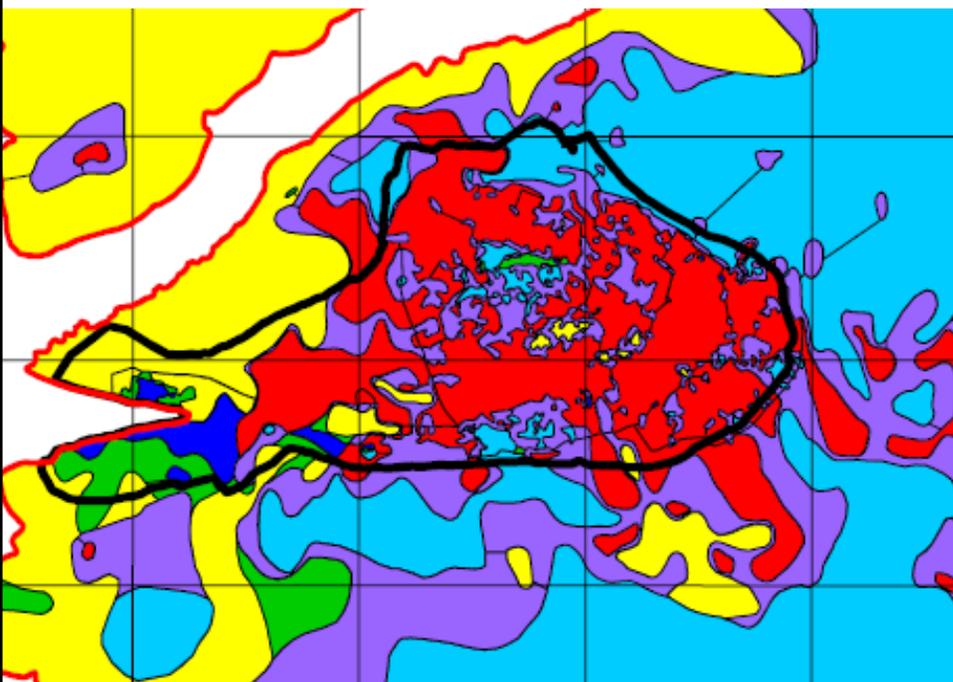


---

# Modelos geológicos

---

- Modelos complejos:
  - Usualmente, se definen varias “poblaciones” litológicas, de alteración, de mineralización...
  - Unidades geológicas se definen en base a estas características



---

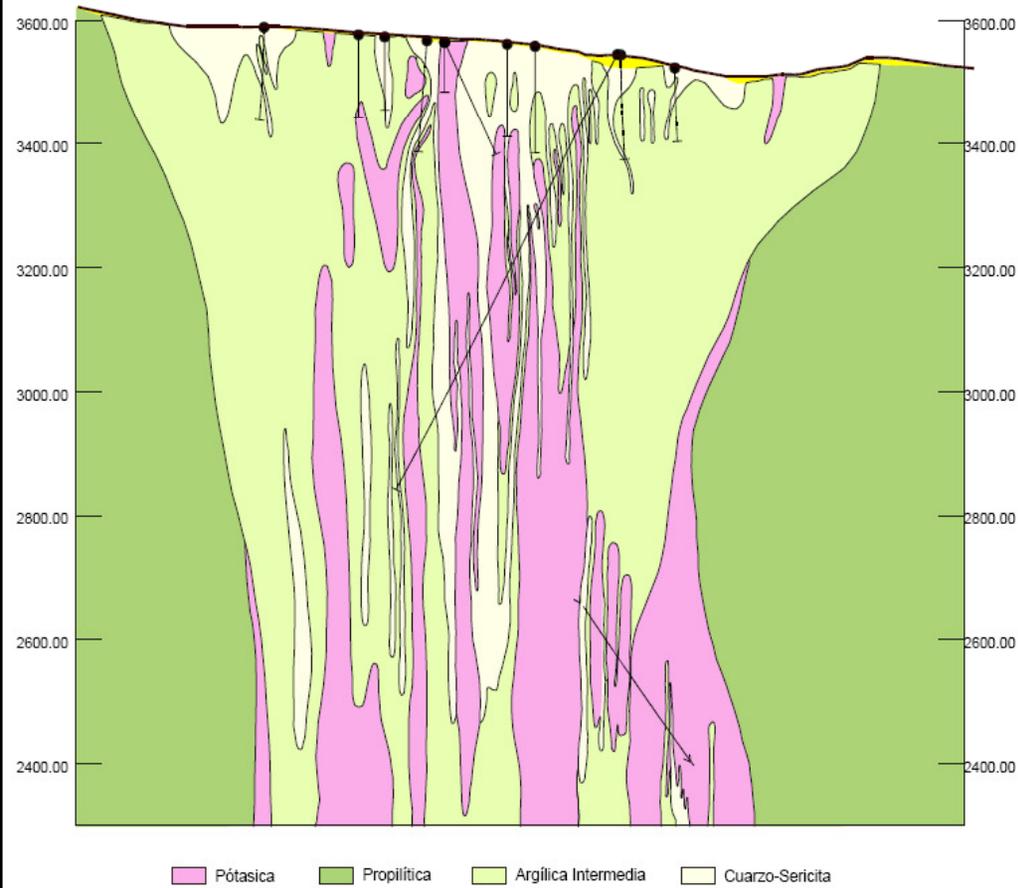
# Definición de unidades geológicas

---

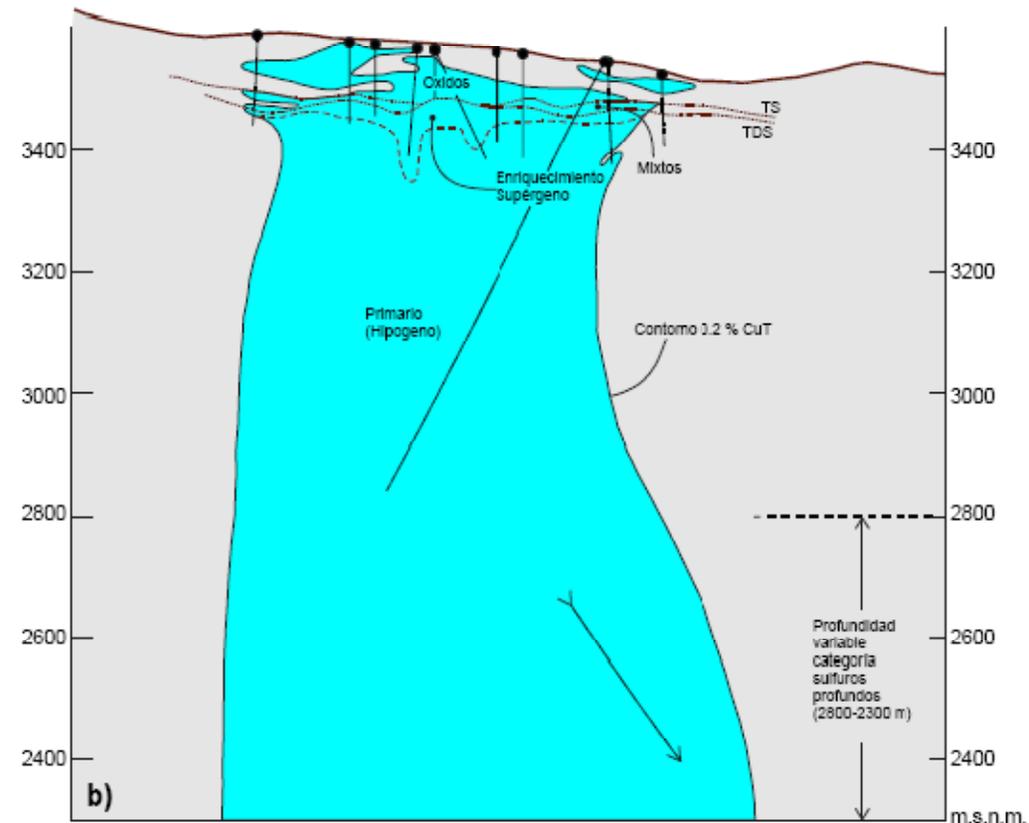
- Para estimación de leyes (modelo de recursos/reservas):
  - Combinación de poblaciones litológicas, de alteración y mineralización
  - Se deben agrupar de modo de combinar datos con:
    - Características geológicas relevantes (depende del uso que se le dará al modelo)
    - Número de datos razonable para inferencia de parámetros estadísticos de la población
- Dificultades:
  - Se desconoce la extensión de las unidades
  - Tipo de límites presentes: duros, blandos, transicionales

# Más ejemplos

## Alteración

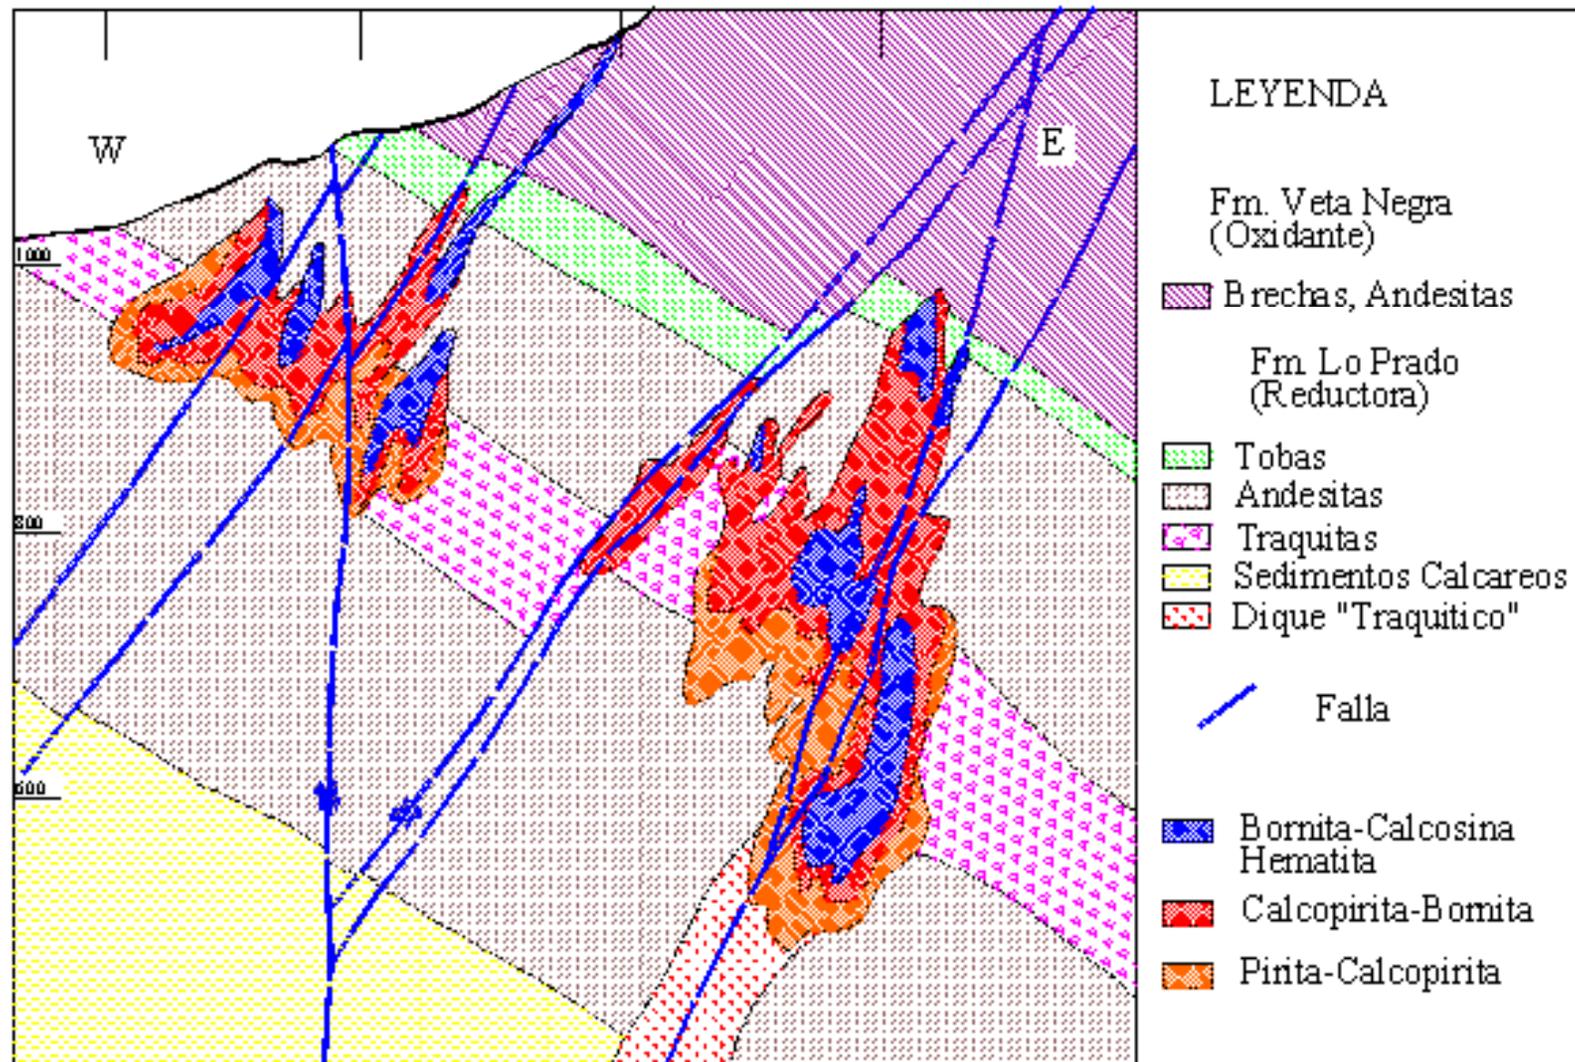


## Mineralización económica



# Más ejemplos

## SECCION GEOLOGICA MINERALOGICA - SECTOR SUR MINA EL SOLDADO

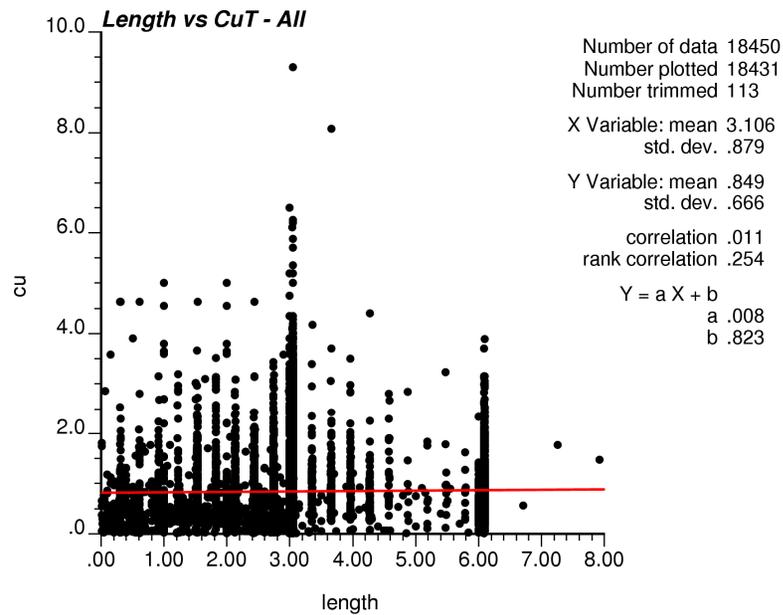
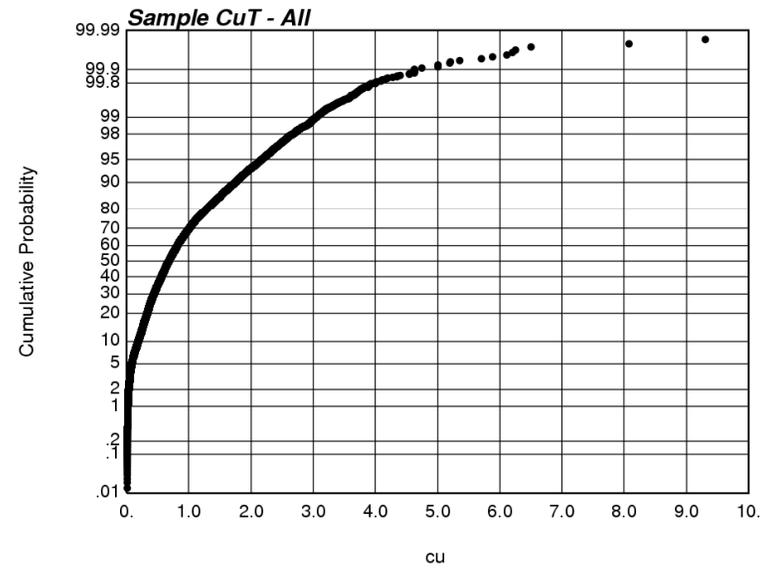
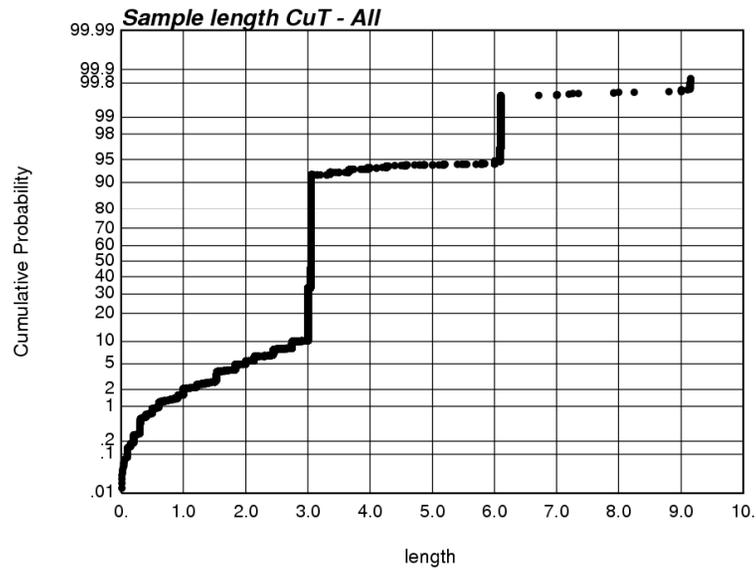


---

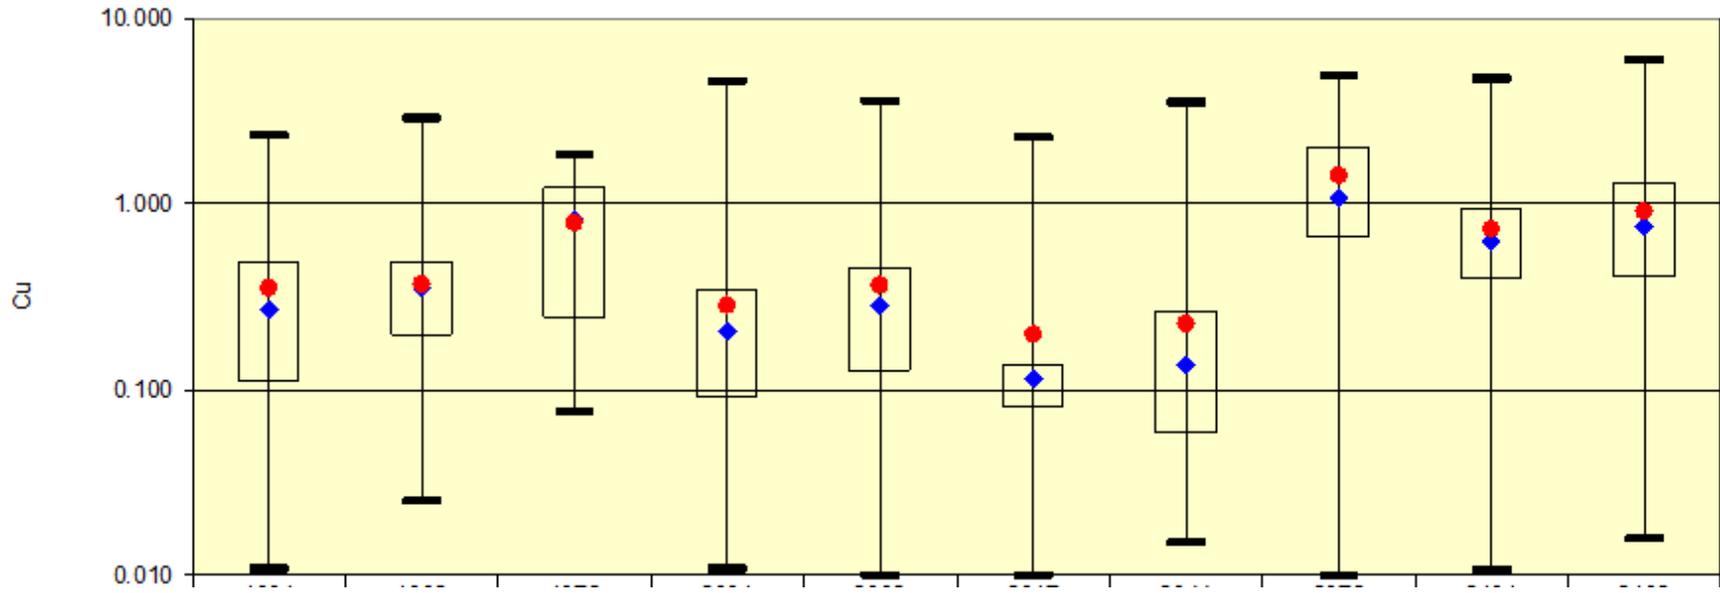
# Análisis de datos

---

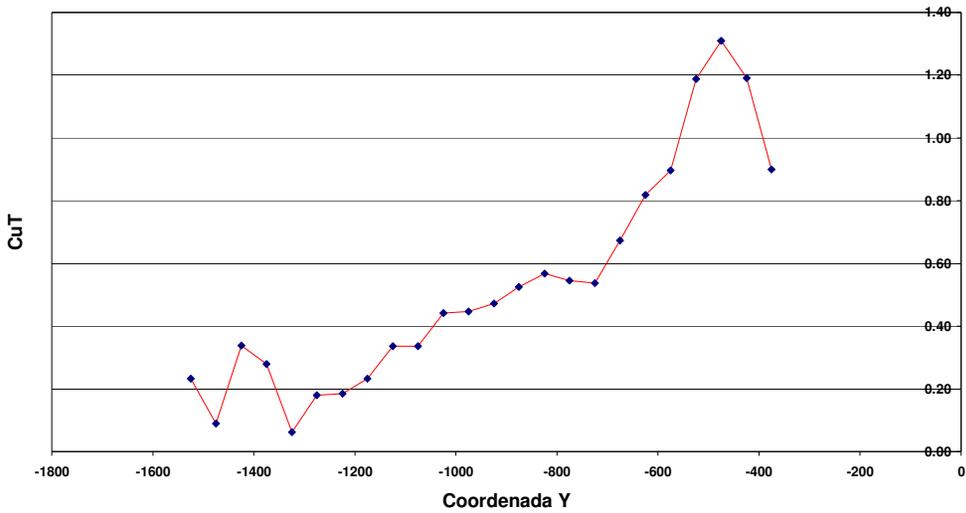
- En esta etapa, se busca:
  - Caracterizar las poblaciones a partir de las muestras
    - Representatividad
    - Valores aberrantes
  - Definir un soporte adecuado de trabajo (compositación), de modo de tener compósitos igualmente representativos (las muestras pueden ser de distintos largos → no “pesan” todas lo mismo)
  - Definir qué combinaciones de unidades geológicas son válidas para la estimación
  - Definir el tipo de contacto entre las unidades: límite duro/blando



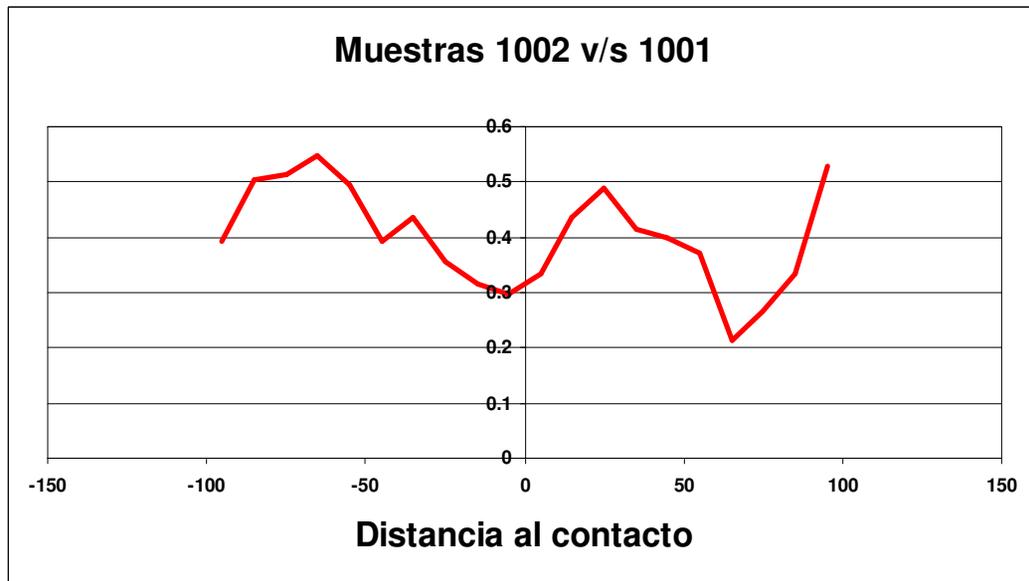
### Box Plot UE Cu Desagrupadas Con Muestras Validadas



Derivas CuT  
Eje Y



Muestras 1002 v/s 1001



---

# El problema de la estimación

---

- Asumimos que estamos trabajando dentro de una unidad geológica consistente...
- ¿De qué manera combinamos la información de las muestras?

---

# Estimación

---

- Dado que el muestreo es parcial y sólo nos indica lo que sucede en las posiciones de los datos, es necesario **estimar el valor de la ley en puntos sin muestra**.
- Además, estamos interesados en saber el valor de la ley de un **bloque** de dimensiones diferentes a las de la muestra → **cambio de soporte**
- Definiremos estimadores con ciertas características:
  - **Lineal**: el valor estimado es una combinación lineal de los datos disponibles (usualmente en una vecindad del punto a estimar)
  - **Insesgado**: en promedio, el estimador entrega el valor correcto, sin sesgo sistemático (pero con cierta imprecisión)
  - **Óptimo**: el estimador será tal que minimice la varianza del error de estimación (será por lo tanto el más preciso).

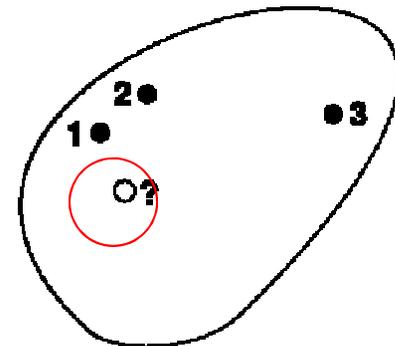
# Estimadores lineales ponderados

- La idea básica es estimar el valor de un atributo (digamos, la ley de Au) en una posición donde no conocemos el valor verdadero

$$Z^*(u) = \lambda_0 + \sum_{i=1}^n \lambda_i \cdot Z(u_i)$$

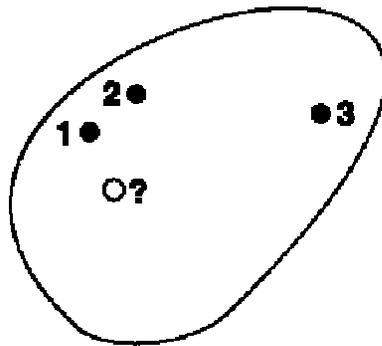
donde  $u$  se refiere a la posición,  $Z^*(u)$  es una estimación en la posición  $u$ , hay  $n$  valores de datos  $Z(u_i)$ ,  $i=1, \dots, n$ , y  $\lambda_i$  se refiere a los ponderadores.

- ¿Qué factores podrían considerarse en la asignación de los ponderadores?
  - **cercanía** a la posición que está siendo estimada
  - **redundancia** entre los valores de datos
  - **continuidad** anisótropa (dirección preferencial)
  - magnitud de la continuidad / variabilidad



# Estimadores lineales ponderados

- Asignar todos los ponderadores a los datos más cercanos (estimador tipo **poligonal**)
- Asignar los ponderadores inversamente proporcional a la distancia de la posición que se está estimando (esquemas de **inverso de la distancia**)

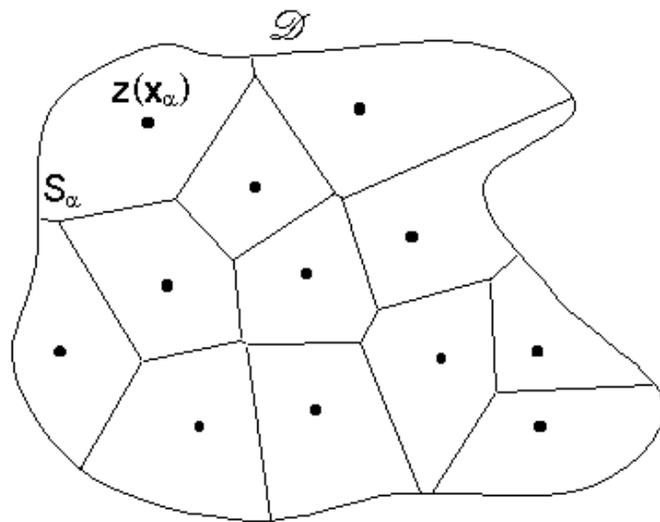


$$\lambda_i = \frac{1}{c + d_i^w} \Big/ \sum_{i=1}^n \frac{1}{c + d_i^w}$$

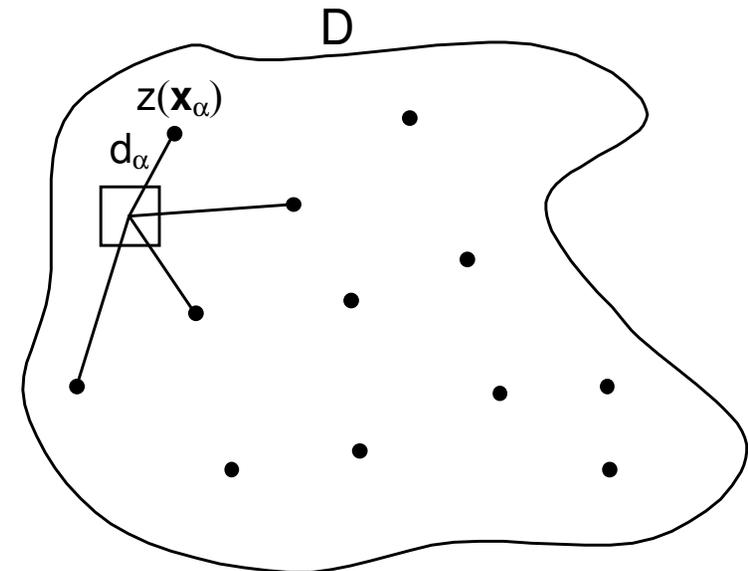
donde  $d_i$  es la distancia entre el dato  $i$  y la posición que se está estimando,  $c$  es una constante pequeña, y  $w$  es una potencia (usualmente entre 1 y 3).

# Estimadores lineales ponderados

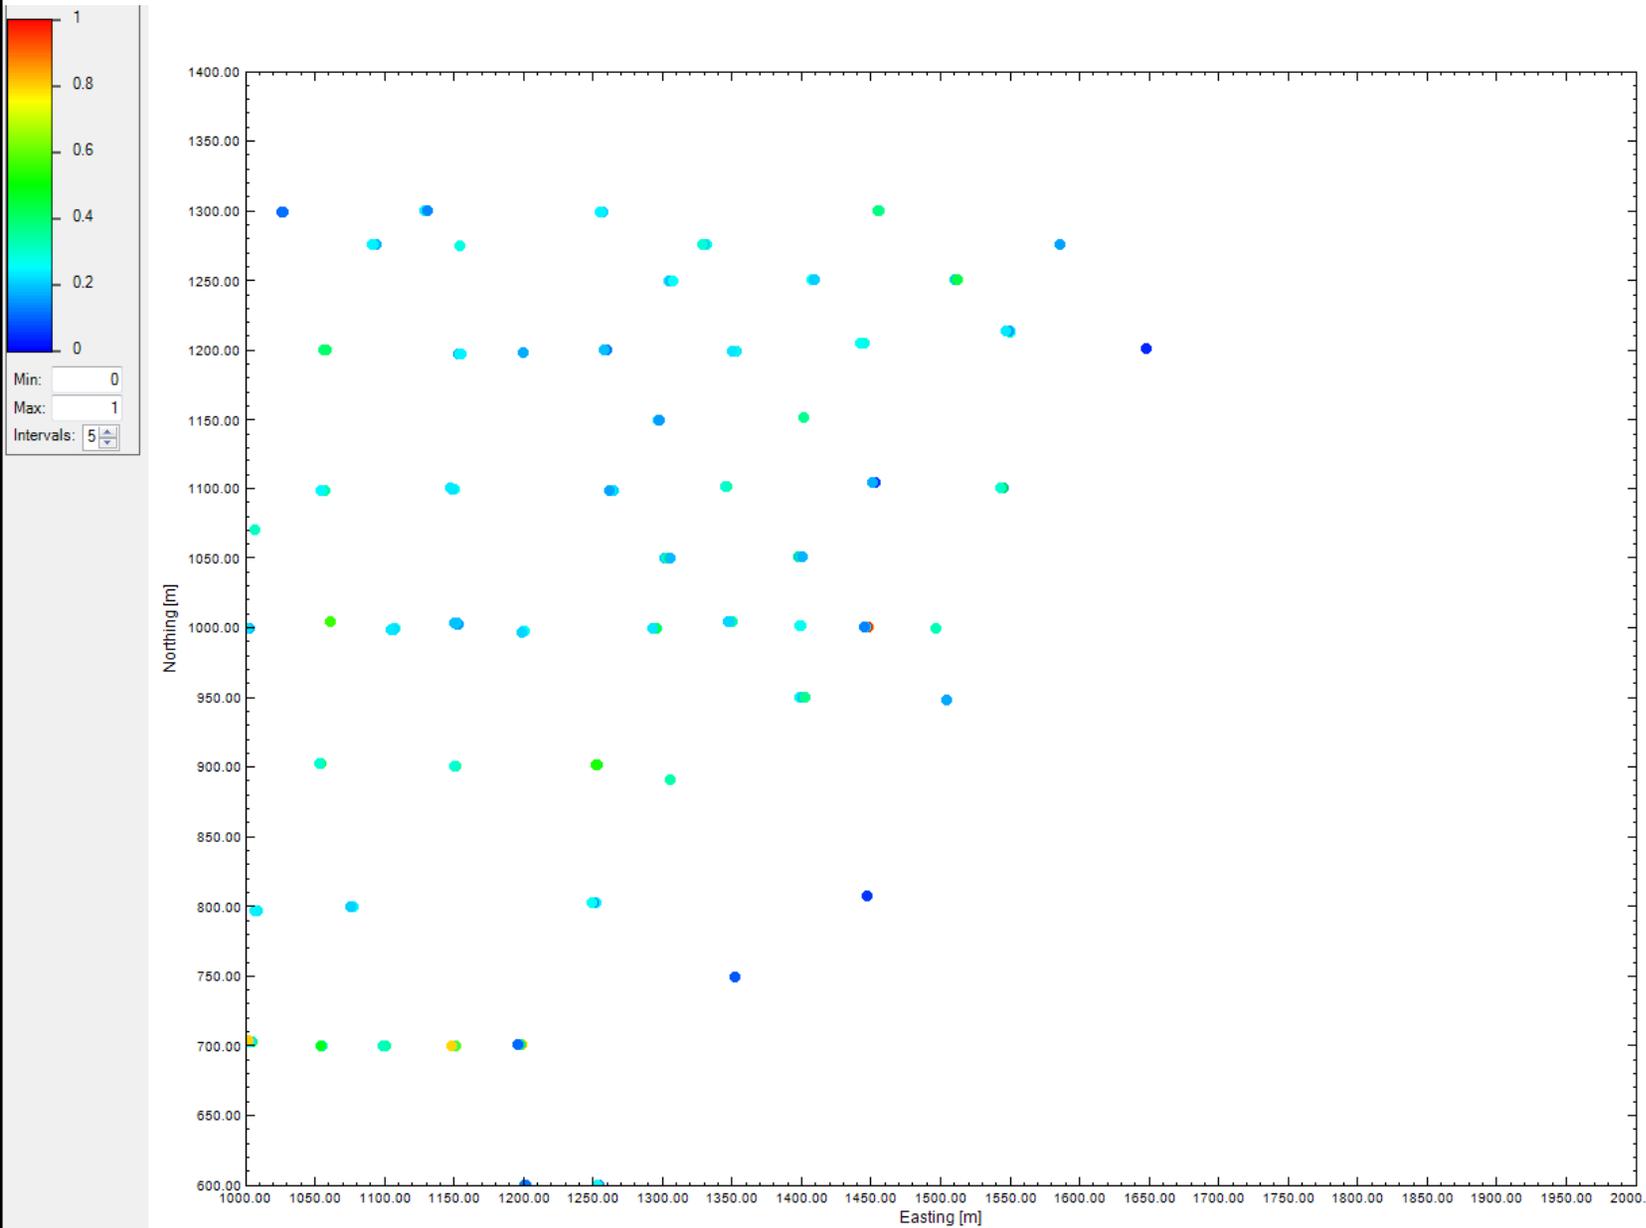
- Polígonos: el valor del punto corresponde al de la muestra más cercana
- Inverso de la distancia



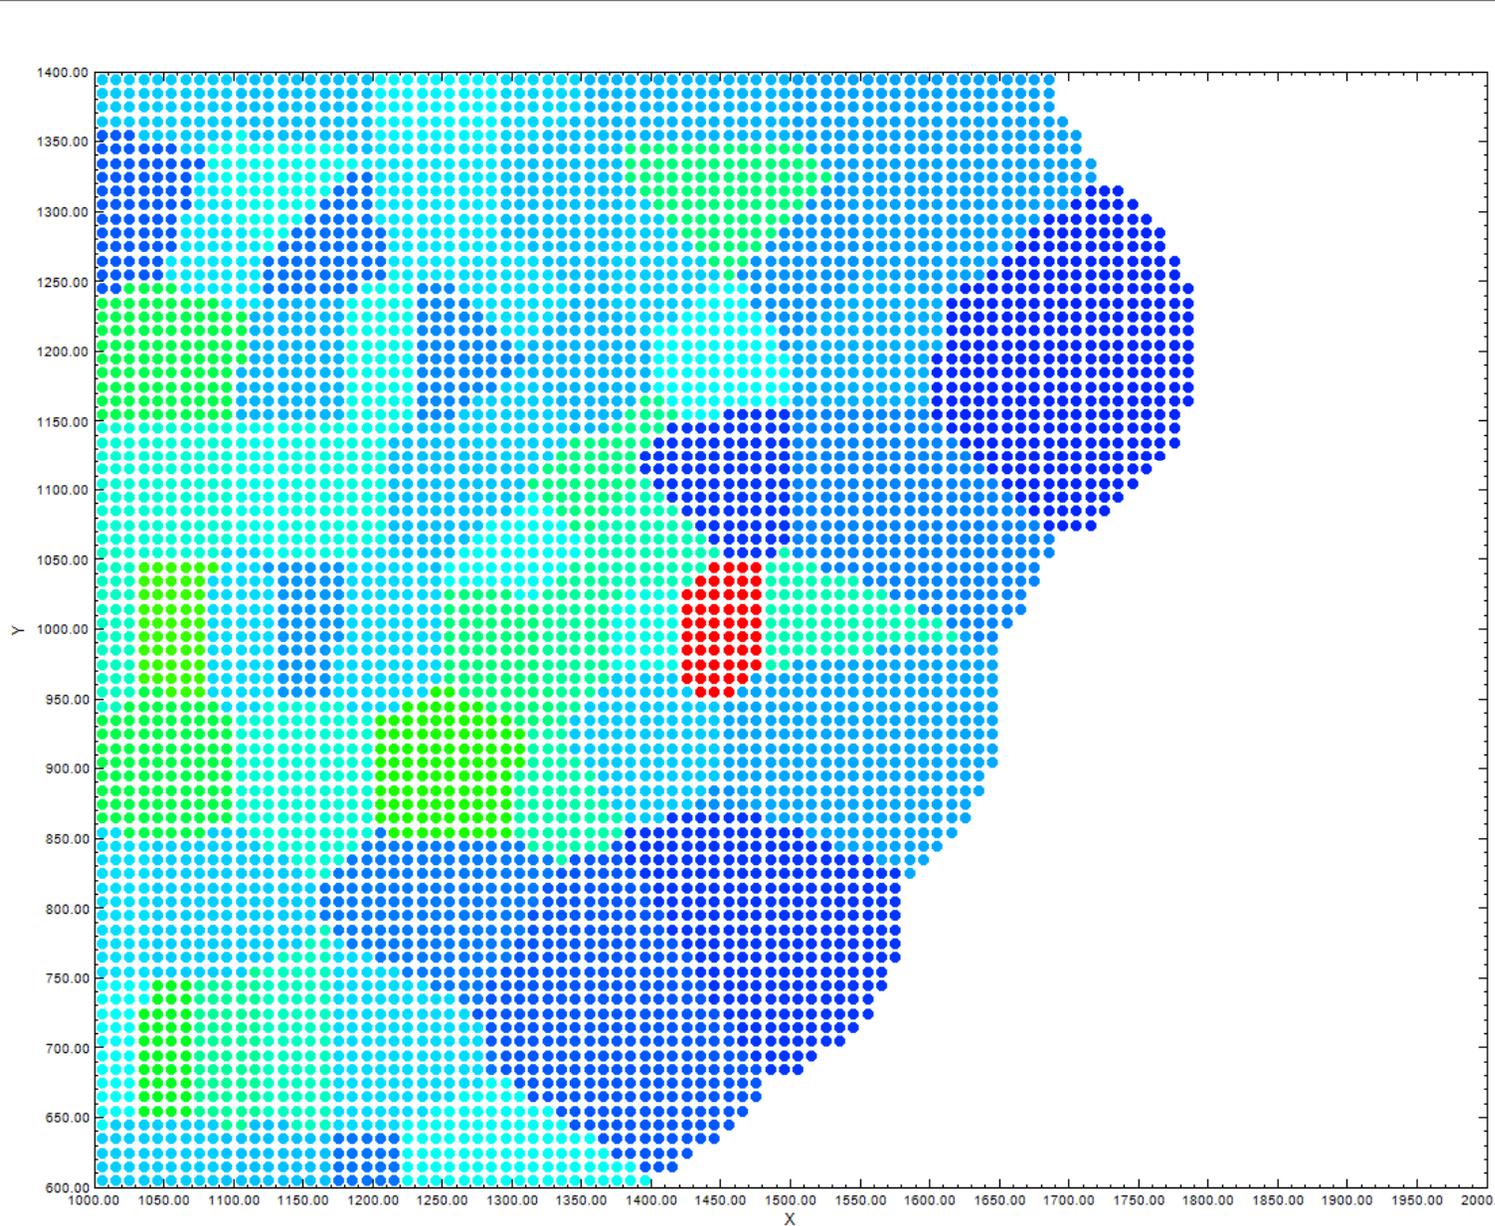
$$z(\mathbf{x}) = \frac{\sum_{\alpha=1}^{n(\mathbf{x})} \frac{z(\mathbf{x}_\alpha)}{d_\alpha^p}}{\sum_{\alpha=1}^{n(\mathbf{x})} \frac{1}{d_\alpha^p}}$$



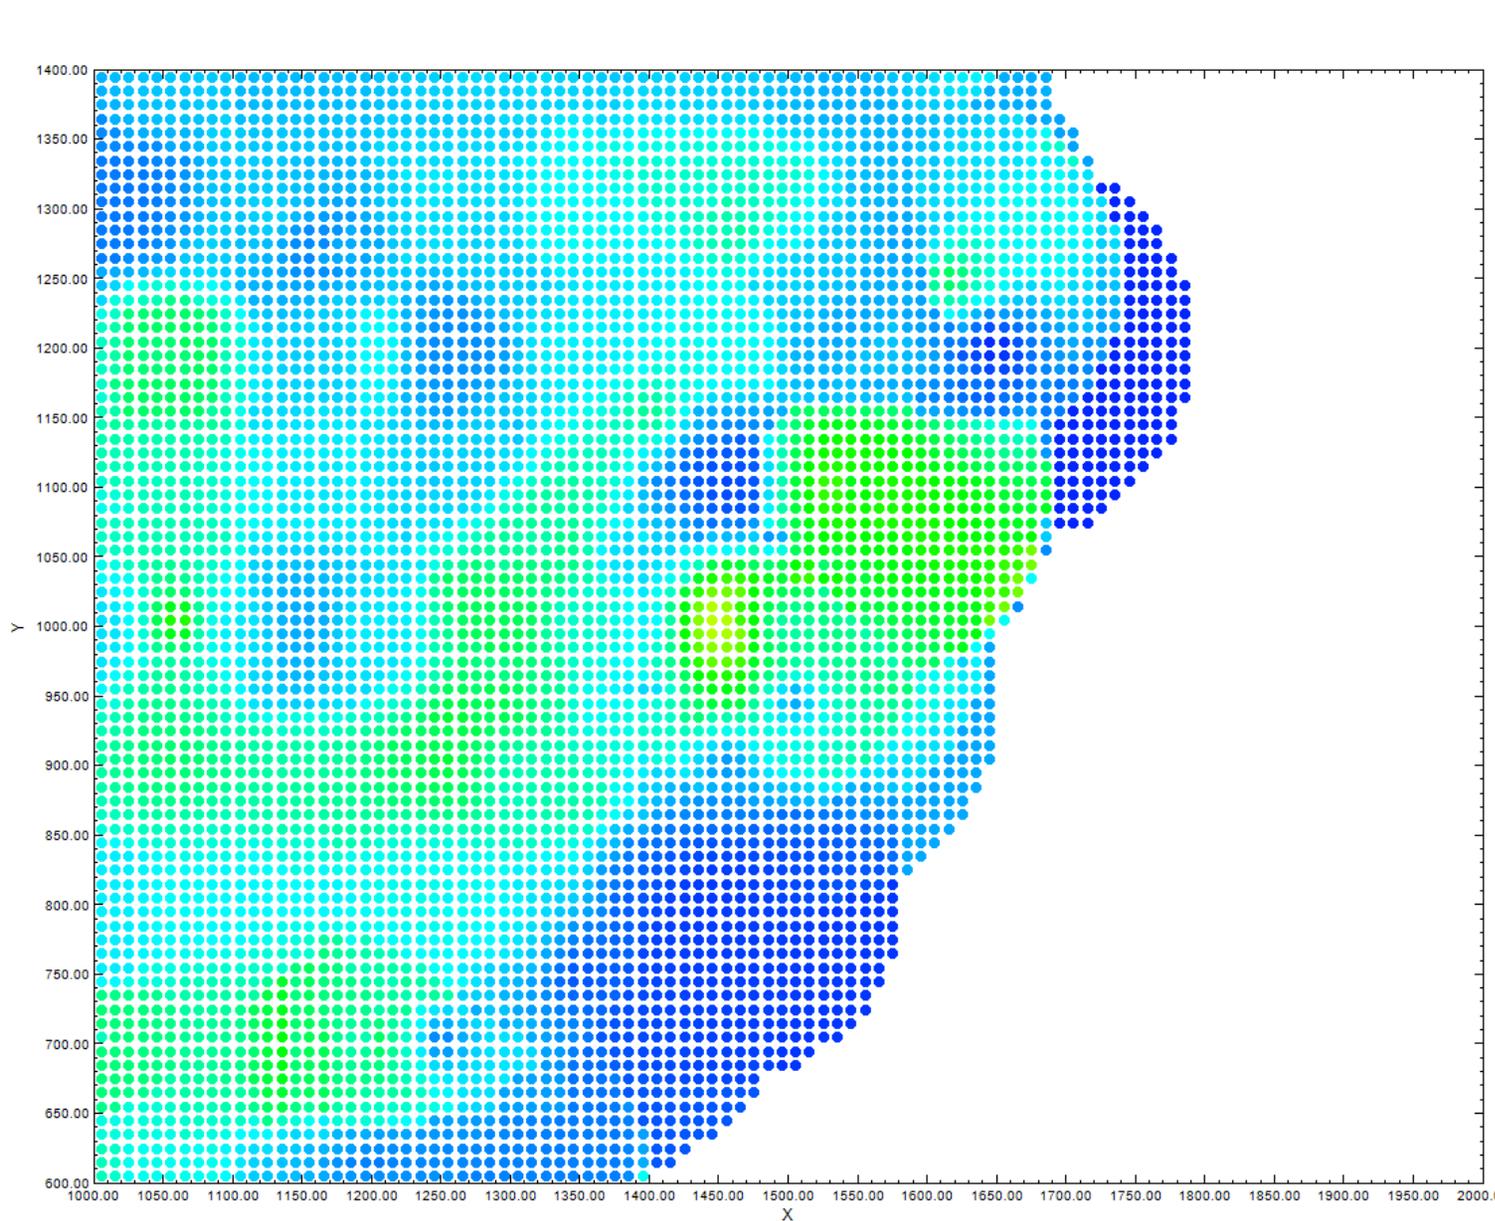
# Ejemplo Simple - Datos



# Ejemplo Simple – Vecino más cercano



# Ejemplo Simple – Inverso de la distancia



---

# Estimadores lineales ponderados

---

- **Kriging** es “una colección de técnicas generalizadas de regresión lineal para minimizar una varianza de estimación definida de un modelo a priori de covarianza” (R. Olea, 1991).
- Kriging es el **mejor estimador lineal insesgado**.
- “El mejor” solamente en el sentido del error de mínimos cuadrados para un modelo dado de covarianza / varianza



# Kriging

- Considere los valores de residuos respecto a la media:

$$Y(u_i) = Z(u_i) - m(u_i), \quad i = 1, \dots, n$$

donde  $m(u)$  podría ser constante, variable localmente o considerada constante pero desconocida.

- El variograma se define como:

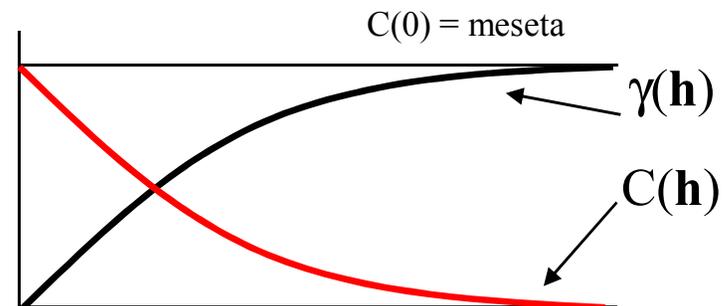
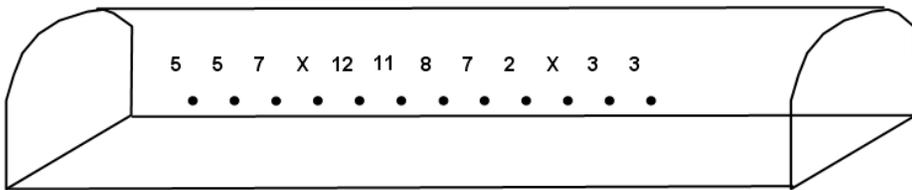
$$2 \gamma(h) = E\{[Y(u) - Y(u + h)]^2\}$$

- La covarianza se define como:

$$C(h) = E\{Y(u) Y(u + h)\}$$

- Relación entre el variograma y la covarianza:

$$\Rightarrow C(h) = C(0) - \gamma(h)$$



# Kriging Simple

- Considere un estimador lineal: 
$$Y^*(\mathbf{u}) = \sum_{i=1}^n \lambda_i \cdot Y(\mathbf{u}_i)$$

donde  $Y(\mathbf{u}_i)$  son los residuos e  $Y^*(\mathbf{u})$  es el valor estimado (la media debe agregarse posteriormente)

- La varianza del error se define como  $E\{[Y^*(\mathbf{u}) - Y(\mathbf{u})]^2\}$

$$E\{[Y^*(\mathbf{u})]^2\} - 2 \cdot E\{Y^*(\mathbf{u}) \cdot Y(\mathbf{u})\} + E\{[Y(\mathbf{u})]^2\} \quad A^2 - 2ab + b^2$$

$$\sum_{i=1}^n \sum_{j=1}^n \lambda_i \lambda_j E\{Y(\mathbf{u}_i) \cdot Y(\mathbf{u}_j)\} - 2 \cdot \sum_{i=1}^n \lambda_i E\{Y(\mathbf{u}) \cdot Y(\mathbf{u}_i)\} + C(\mathbf{0})$$

$$\sum_{i=1}^n \sum_{j=1}^n \lambda_i \lambda_j C(\mathbf{u}_i, \mathbf{u}_j) - 2 \cdot \sum_{i=1}^n \lambda_i C(\mathbf{u}, \mathbf{u}_i) + C(\mathbf{0})$$

---

# Kriging Simple

---

- Los ponderadores óptimos (que minimizan la varianza del error)  $\lambda_i$ ,  $i=1, \dots, n$  pueden determinarse tomando derivadas parciales con respecto a los ponderadores

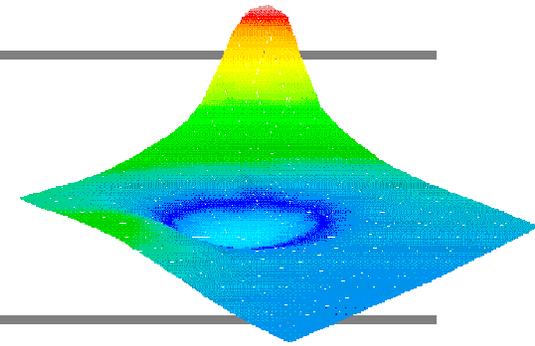
$$\frac{\partial [ \quad ]}{\partial \lambda_i} = 2 \cdot \sum_{j=1}^n \lambda_j C(\mathbf{u}_i, \mathbf{u}_j) - 2 \cdot C(\mathbf{u}, \mathbf{u}_i), \quad i = 1, \dots, n$$

e igualándola a cero

$$\sum_{j=1}^n \lambda_j C(\mathbf{u}_i, \mathbf{u}_j) = C(\mathbf{u}, \mathbf{u}_i), \quad i = 1, \dots, n$$

- Este sistema de  $n$  ecuaciones con  $n$  ponderadores desconocidos es el **sistema de kriging simple** (KS)

# Kriging Simple



- El kriging minimiza esta varianza de estimación para obtener los ponderadores. Derivando e igualando a cero, se obtiene el sistema de kriging simple:

$$\begin{pmatrix} C(\mathbf{x}_1 - \mathbf{x}_1) & \cdots & C(\mathbf{x}_1 - \mathbf{x}_n) \\ \vdots & & \vdots \\ C(\mathbf{x}_n - \mathbf{x}_1) & \cdots & C(\mathbf{x}_n - \mathbf{x}_n) \end{pmatrix} \begin{pmatrix} \lambda_1 \\ \vdots \\ \lambda_n \end{pmatrix} = \begin{pmatrix} C(\mathbf{x}_1 - \mathbf{x}_0) \\ \vdots \\ C(\mathbf{x}_n - \mathbf{x}_0) \end{pmatrix}$$

- Y por lo tanto:

$$Z^*(\mathbf{x}_0) = \sum_{\alpha=1}^n \lambda_{\alpha} \cdot Z(\mathbf{x}_{\alpha}) + \left(1 - \sum_{\alpha=1}^n \lambda_{\alpha}\right) \cdot m$$

$$\sigma_{KS}^2(\mathbf{x}_0) = C(\mathbf{0}) - \sum_{\alpha=1}^n \lambda_{\alpha} C(\mathbf{x}_{\alpha} - \mathbf{x}_0)$$

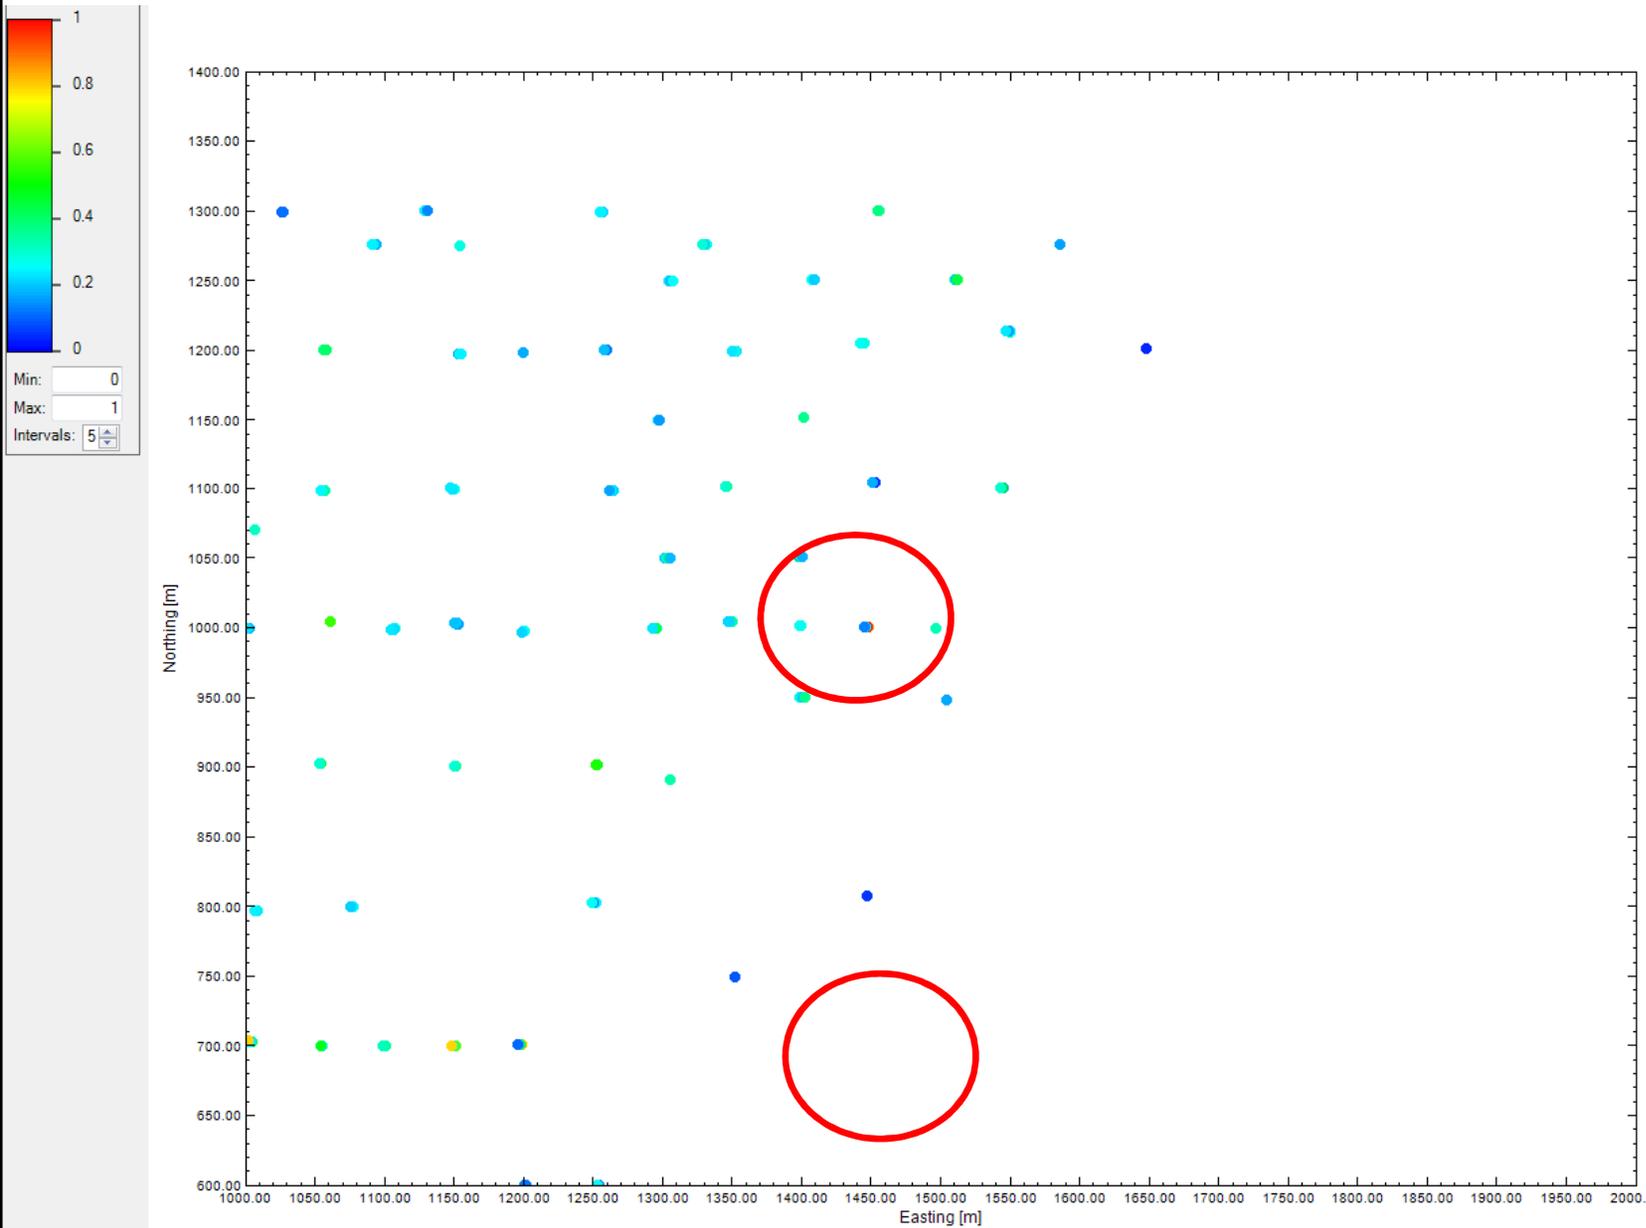
---

# Kriging Simple

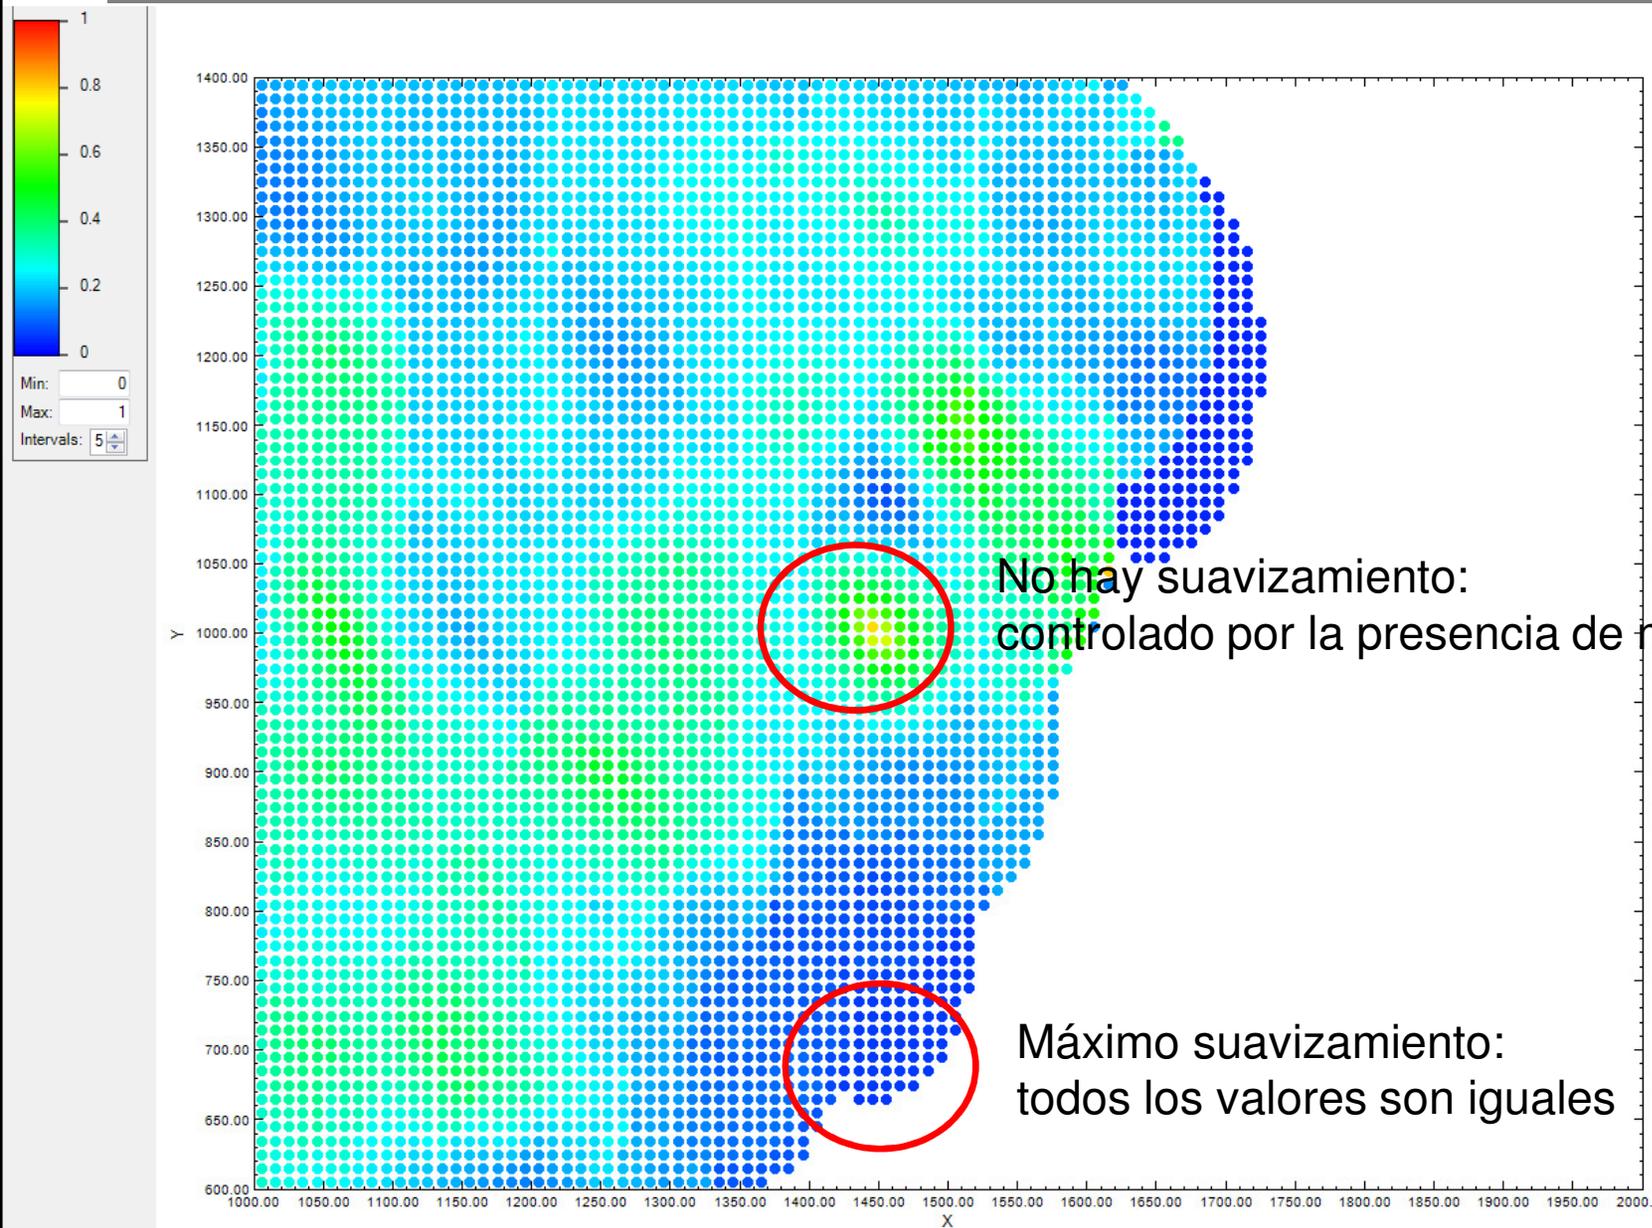
---

- Algunas propiedades:
  - Existe una **solución única** al sistema de ecuaciones si la matriz de covarianza es definida positiva → esta es la razón para modelar el variograma con modelos lícitos
  - El estimador de kriging es **insesgado** (por construcción)
  - Es el **mejor** estimado (minimiza la varianza de estimación)
  - Es un interpolador exacto
- En resumen:
  - Kriging simple asume la media constante y conocida
  - Como veremos más adelante, es la base de los métodos de simulación
  - Puede calcularse también para estimar el valor sobre un bloque
  - No se usa en la práctica para estimar

# Ejemplo Simple - Datos



# Ejemplo Simple - Kriging



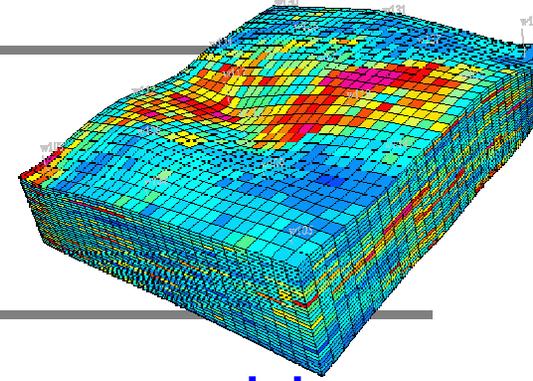
---

# Propiedades del Kriging Simple

---

- La varianza de kriging puede calcularse antes de tener la información (sólo se requiere conocer el variograma)
  - Definición de grillas óptimas de exploración
  - Grillas para categorización de recursos
- Kriging considera:
  - Geometría del volumen a estimar:
  - Distancia de la información:
  - Configuración de los datos:
  - Continuidad estructural de la variable considerada:
- El efecto suavizador de kriging puede predecirse

# Kriging Ordinario



- En la mayoría de los casos **la media es desconocida**
- Kriging Ordinario: estimador lineal que no considera la media conocida

$$Z^*(u_0) = \sum_{\alpha=1}^n \lambda_{\alpha} \cdot Z(u_{\alpha})$$

- Requiere imponer la condición de insesgo:

$$\begin{aligned} E[Z^*(u_0) - Z(u_0)] &= \sum_{\alpha=1}^n \lambda_{\alpha} \underbrace{E[Z(u_{\alpha})]}_m - \underbrace{E[Z(u_0)]}_m \\ &= m \left( \sum_{\alpha=1}^n \lambda_{\alpha} - 1 \right) \end{aligned} \quad \longrightarrow \quad \sum_{\alpha=1}^n \lambda_{\alpha} = 1$$

- Los ponderadores se encuentran planteando:

$$\min \text{Var}[Z^*(u_0) - Z(u_0)] = \sum_{\alpha=1}^n \sum_{\beta=1}^n \lambda_{\alpha} \cdot \lambda_{\beta} \cdot C(u_{\alpha} - u_{\beta}) + C(\mathbf{0}) - 2 \sum_{\alpha=1}^n \lambda_{\alpha} \cdot C(u_{\alpha} - u_0)$$

$$\text{s.a.} \quad \sum_{\alpha=1}^n \lambda_{\alpha} = 1$$

# Kriging Ordinario

- En este caso se minimiza la varianza **sujeito a que la suma de los ponderadores sea igual a 1**.
- El sistema de kriging ordinario queda:

$$\begin{pmatrix} C(\mathbf{x}_1 - \mathbf{x}_1) & \cdots & C(\mathbf{x}_1 - \mathbf{x}_n) & 1 \\ \vdots & & \vdots & \vdots \\ C(\mathbf{x}_n - \mathbf{x}_1) & \cdots & C(\mathbf{x}_n - \mathbf{x}_n) & 1 \\ 1 & \cdots & 1 & 0 \end{pmatrix} \begin{pmatrix} \lambda_1 \\ \vdots \\ \lambda_n \\ -\mu \end{pmatrix} = \begin{pmatrix} C(\mathbf{x}_1 - \mathbf{x}_0) \\ \vdots \\ C(\mathbf{x}_n - \mathbf{x}_0) \\ 1 \end{pmatrix}$$

y

$$Z^*(\mathbf{x}_0) = \sum_{\alpha=1}^n \lambda_{\alpha} \cdot Z(\mathbf{x}_{\alpha})$$

$$\sigma_{KO}^2(\mathbf{x}_0) = \sigma^2 - \sum_{\alpha=1}^n \lambda_{\alpha} C(\mathbf{x}_{\alpha} - \mathbf{x}_0) + \mu$$

# Kriging Ordinario

- O en términos de variograma:

$$\begin{pmatrix} \gamma(\mathbf{x}_1 - \mathbf{x}_1) & \cdots & \gamma(\mathbf{x}_1 - \mathbf{x}_n) & 1 \\ \vdots & & \vdots & \vdots \\ \gamma(\mathbf{x}_n - \mathbf{x}_1) & \cdots & \gamma(\mathbf{x}_n - \mathbf{x}_n) & 1 \\ 1 & \cdots & 1 & 0 \end{pmatrix} \begin{pmatrix} \lambda_1 \\ \vdots \\ \lambda_n \\ \mu \end{pmatrix} = \begin{pmatrix} \gamma(\mathbf{x}_1 - \mathbf{x}_0) \\ \vdots \\ \gamma(\mathbf{x}_n - \mathbf{x}_0) \\ 1 \end{pmatrix}$$

y

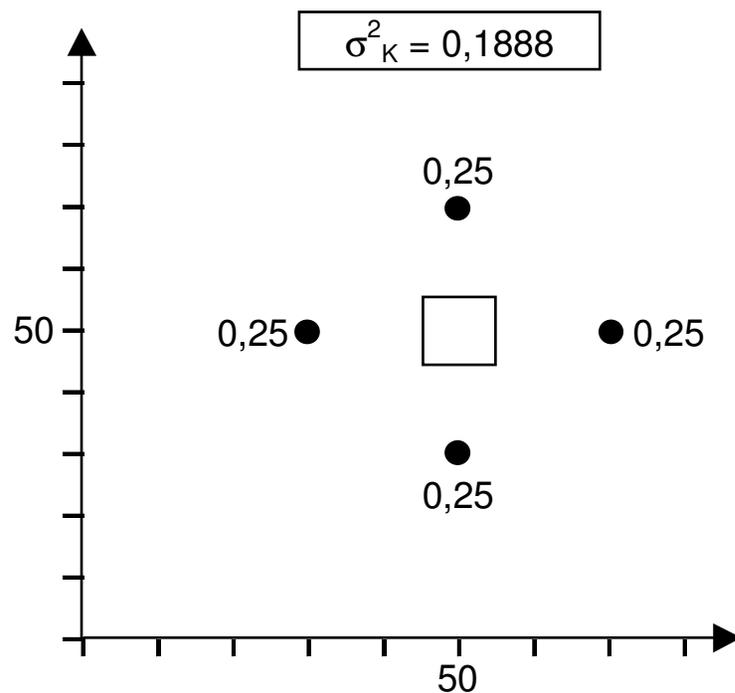
$$Z^*(\mathbf{x}_0) = \sum_{\alpha=1}^n \lambda_{\alpha} \cdot Z(\mathbf{x}_{\alpha})$$

$$\sigma_{KO}^2(\mathbf{x}_0) = \sum_{\alpha=1}^n \lambda_{\alpha} \gamma(\mathbf{x}_{\alpha} - \mathbf{x}_0) + \mu$$

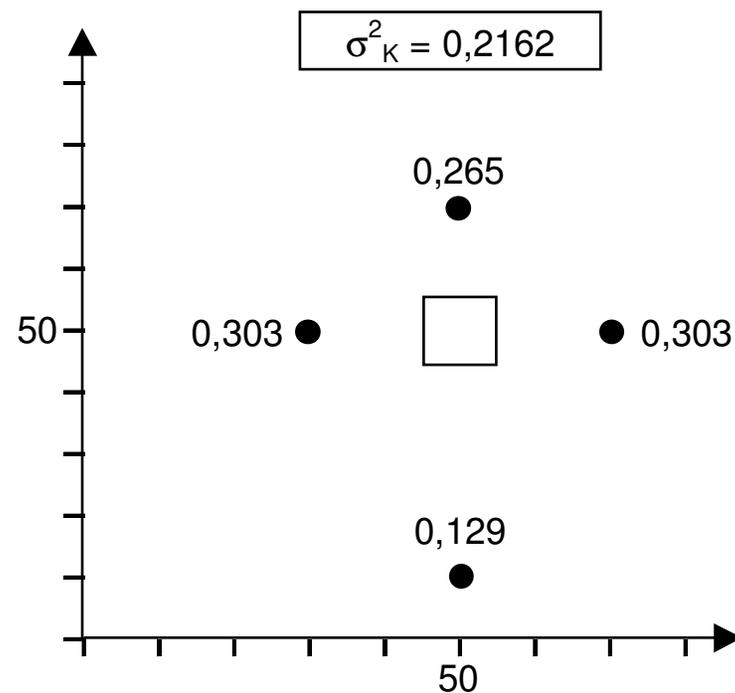
# Efecto de Distancia

- Caso base y efecto del aumento en la distancia sobre los ponderadores ( $\gamma(h) = 0,2 + 0,8 \cdot Sph(100)$ )

Caso base



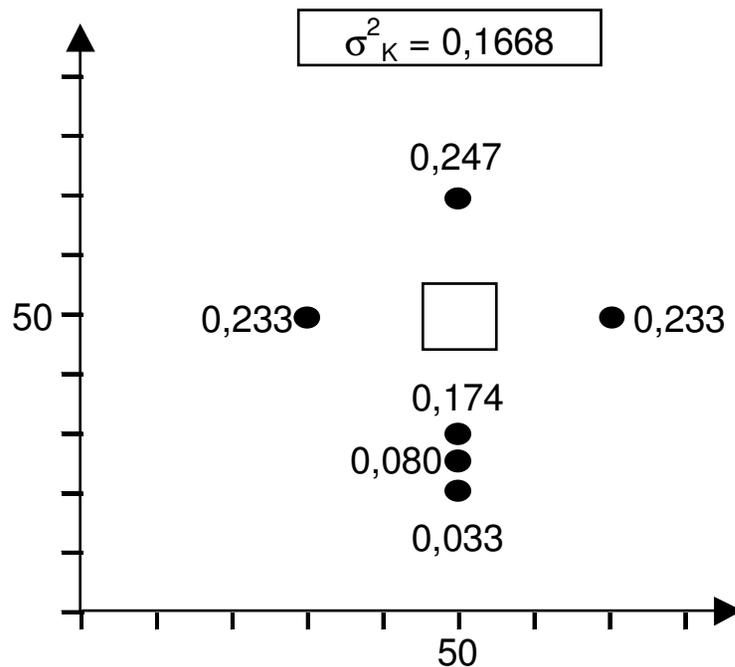
Efecto de distancia



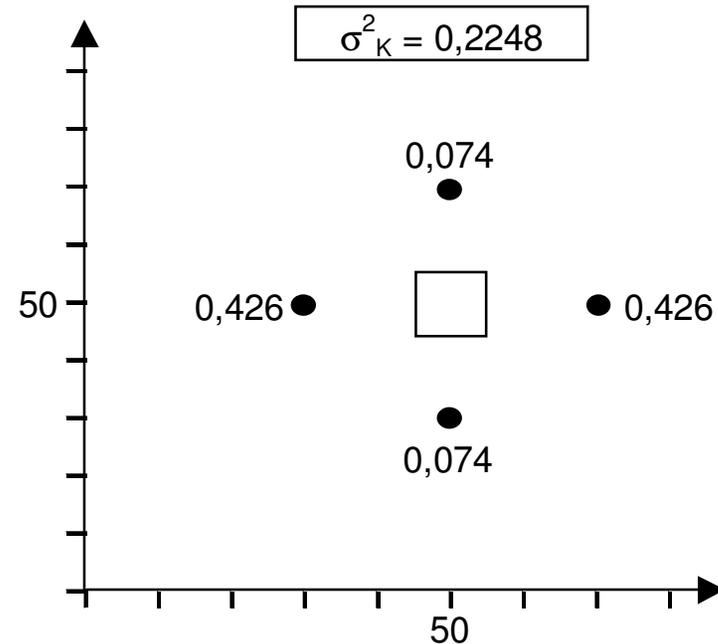
# Efecto Pantalla y Anisotropía

- Efecto pantalla y de la anisotropía (Anis. Geom. 4 x 1) sobre los ponderadores ( $\psi(h) = 0,2 + 0,8 \cdot Sph(100)$ )

Efecto pantalla



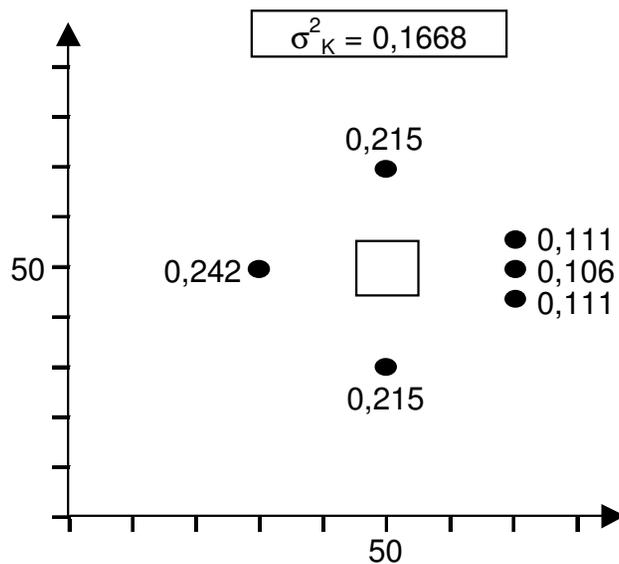
Efecto de la anisotropía



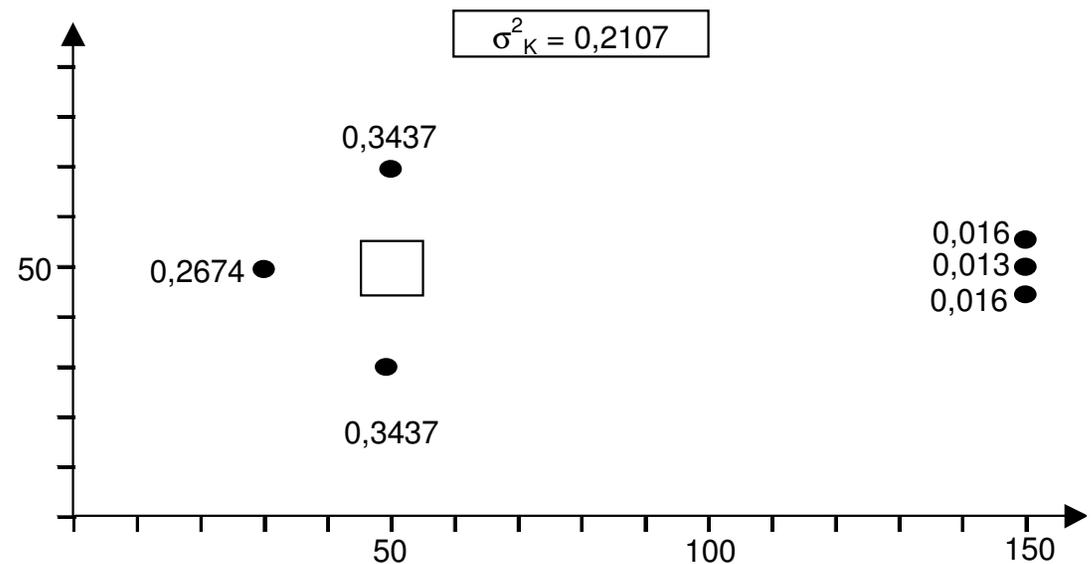
# Efecto de Declusterización y Distancia

- Efecto de declusterización y declus. + distancia sobre los ponderadores  $\{ \chi(h) = 0,2 + 0,8 \cdot Sph(100) \}$

Efecto de declusterización

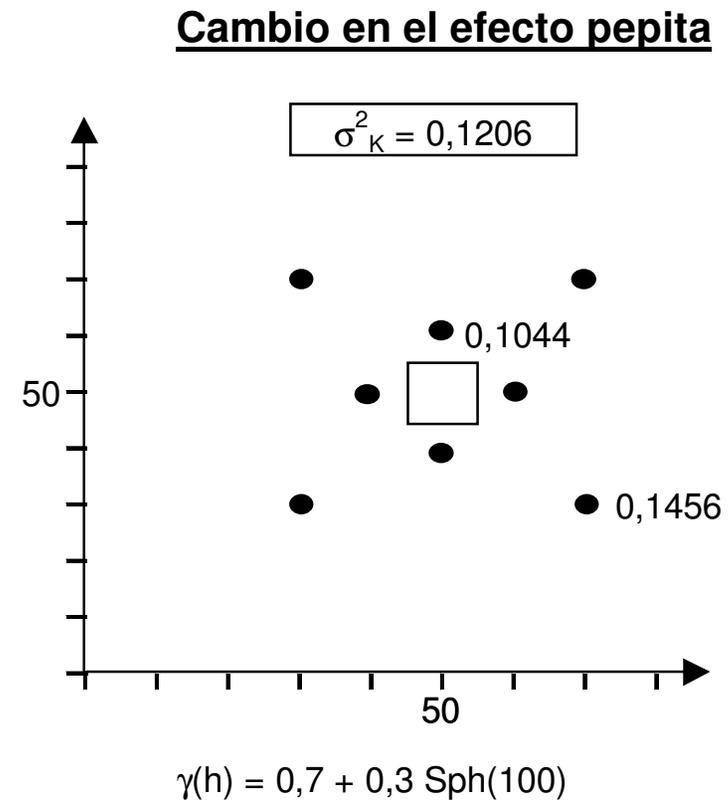
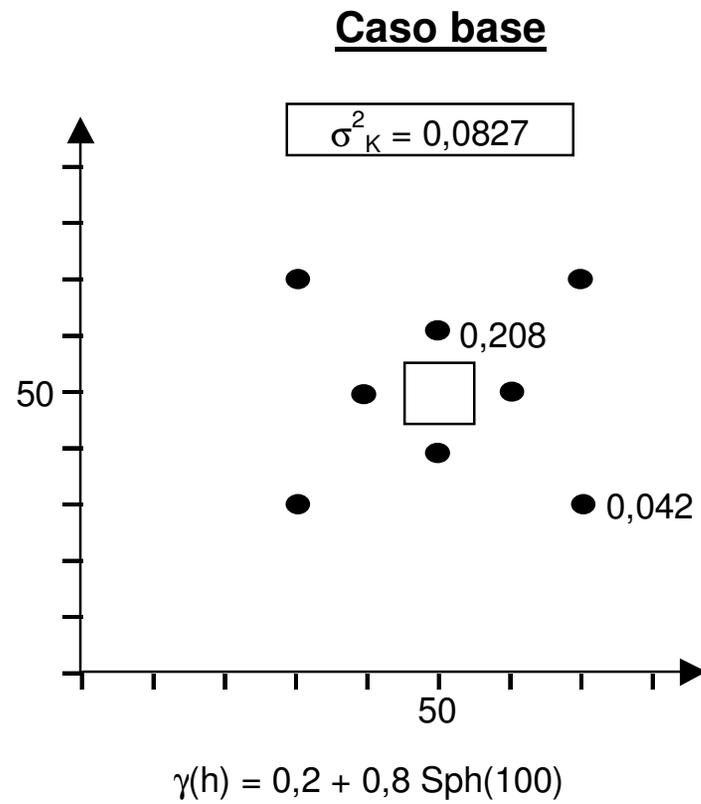


Efecto de decl. + distancia



# Cambio en efecto pepita

- Efecto sobre los ponderadores de un cambio en el efecto pepita del modelo variográfico



---

# Validaciones Cruzadas

---

- Parámetros de kriging.
- Criterios:
  - Media compósitos = Media puntos estimados (sesgo global)
  - Medias condicionales (sesgo condicional)
  - Varianza (estimado-real) baja
  - Distribución de errores estandarizados (debe estar centrada en 0)
- Elección del mejor plan de kriging

---

# Plan de Kriging

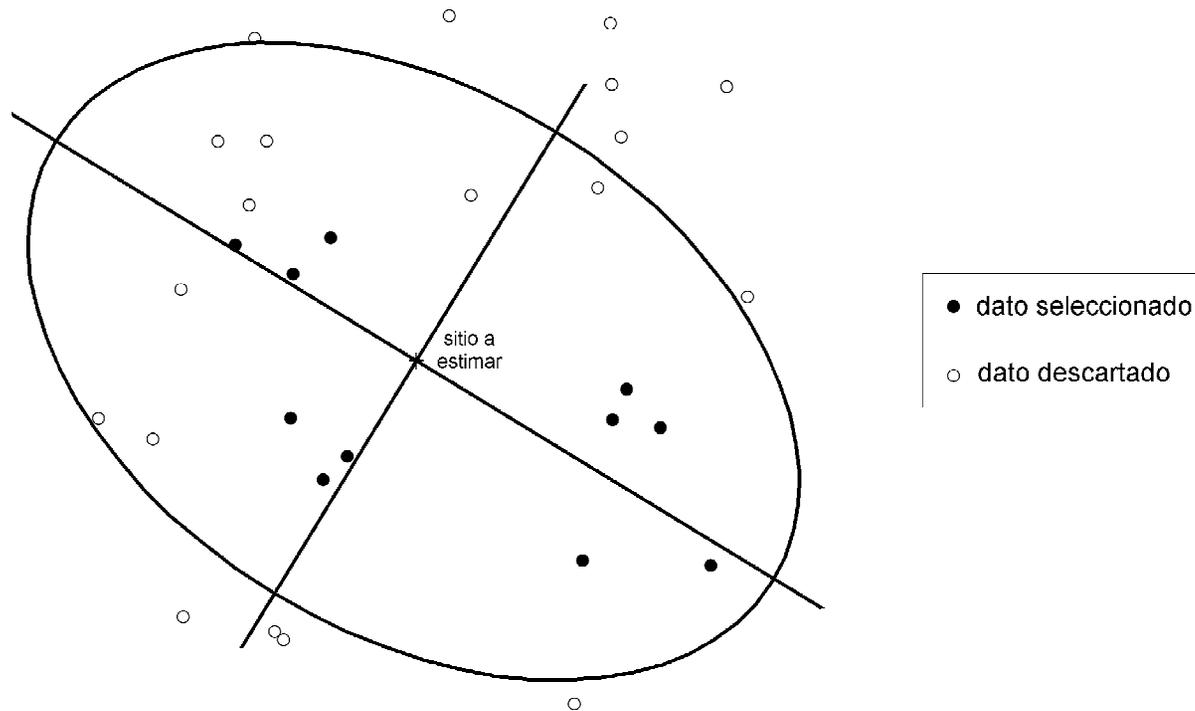
---

- ¿Cuáles son los datos a utilizar en la estimación?
- **Vecindad móvil:** se usa sólo los datos cercanos al sitio (bloque) a estimar
  - En general, se toma una vecindad en forma de elipse (2D) o elipsoide (3D), orientado según la anisotropía observada en el variograma
  - Se suele dividir la vecindad en octantes en 3D y buscar datos en cada sector
  - Los radios del elipse (elipsoide) no necesariamente corresponden a los alcances del variograma, sino que se definen de manera de poder encontrar suficientes datos para hacer la estimación

# Plan de Kriging

## Ejemplo de vecindad móvil

### *Búsqueda de tres datos por cuadrante*



---

# Validación del kriging

---

- Para validar los parámetros del kriging (modelo de variograma, vecindad elegida), se puede usar los siguientes métodos:
  - **Validación cruzada**: se estima sucesivamente cada dato considerando solamente los datos restantes
  - **Jack-knife**: se divide la muestra inicial en dos partes (por ejemplo, cuando hay dos campañas de sondajes), y se estima una parte a partir de la otra
- Luego, se hace un estudio estadístico de los errores cometidos para saber si el kriging fue “satisfactorio” (buena precisión, poco sesgo condicional...)

---

# Validación del kriging

---

- Criterios de validación:
  - **medias de los errores y de los errores estandarizados**: deben ser cercanas a cero → estimador sin sesgo
  - **varianza de los errores**: debe ser la más baja posible → estimador preciso
  - **varianza de los errores estandarizados**: debe ser cercana a 1 → el variograma cuantifica adecuadamente la incertidumbre
  - **nube de dispersión entre valores reales y estimados**: la regresión debe acercarse a la diagonal → insesgo condicional

---

# Validación del kriging

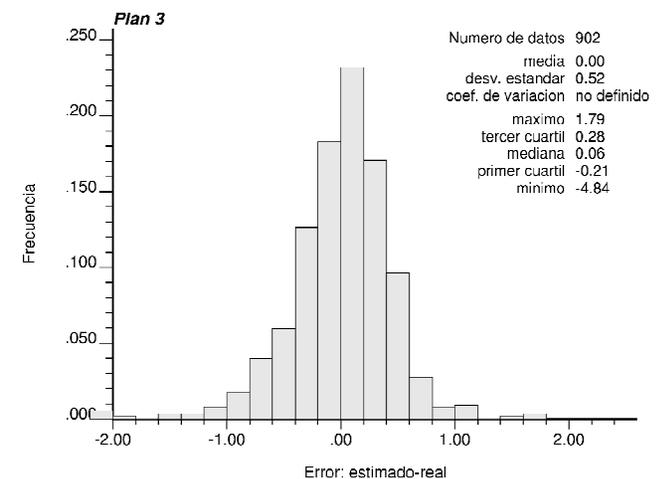
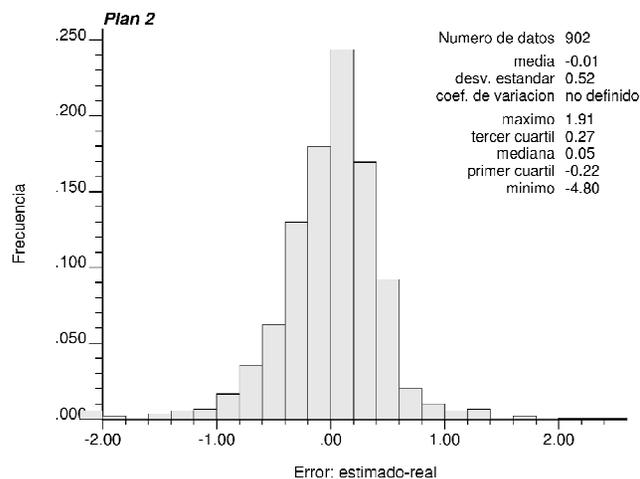
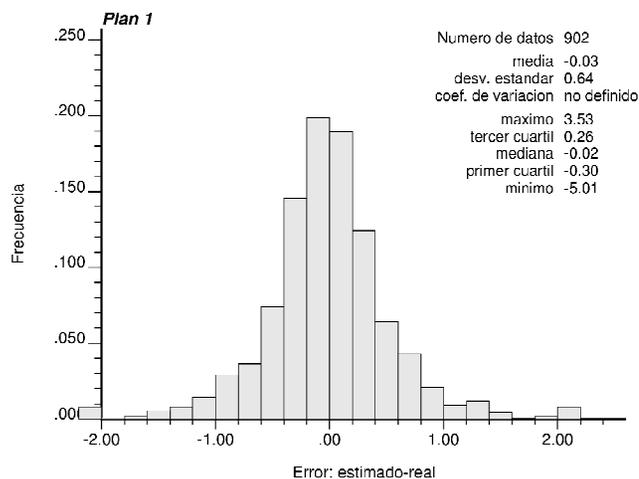
---

Ejemplo: jack-knife entre dos campañas de sondaje de exploración, usando kriging ordinario. Se busca poner a prueba distintas vecindades de kriging.

- **Plan 1:** estimar con los 2 datos más cercanos
- **Plan 2:** estimar con los 24 datos más cercanos (3 por octante)
- **Plan 3:** estimar con los 48 datos más cercanos (6 por octante)

# Validación del kriging

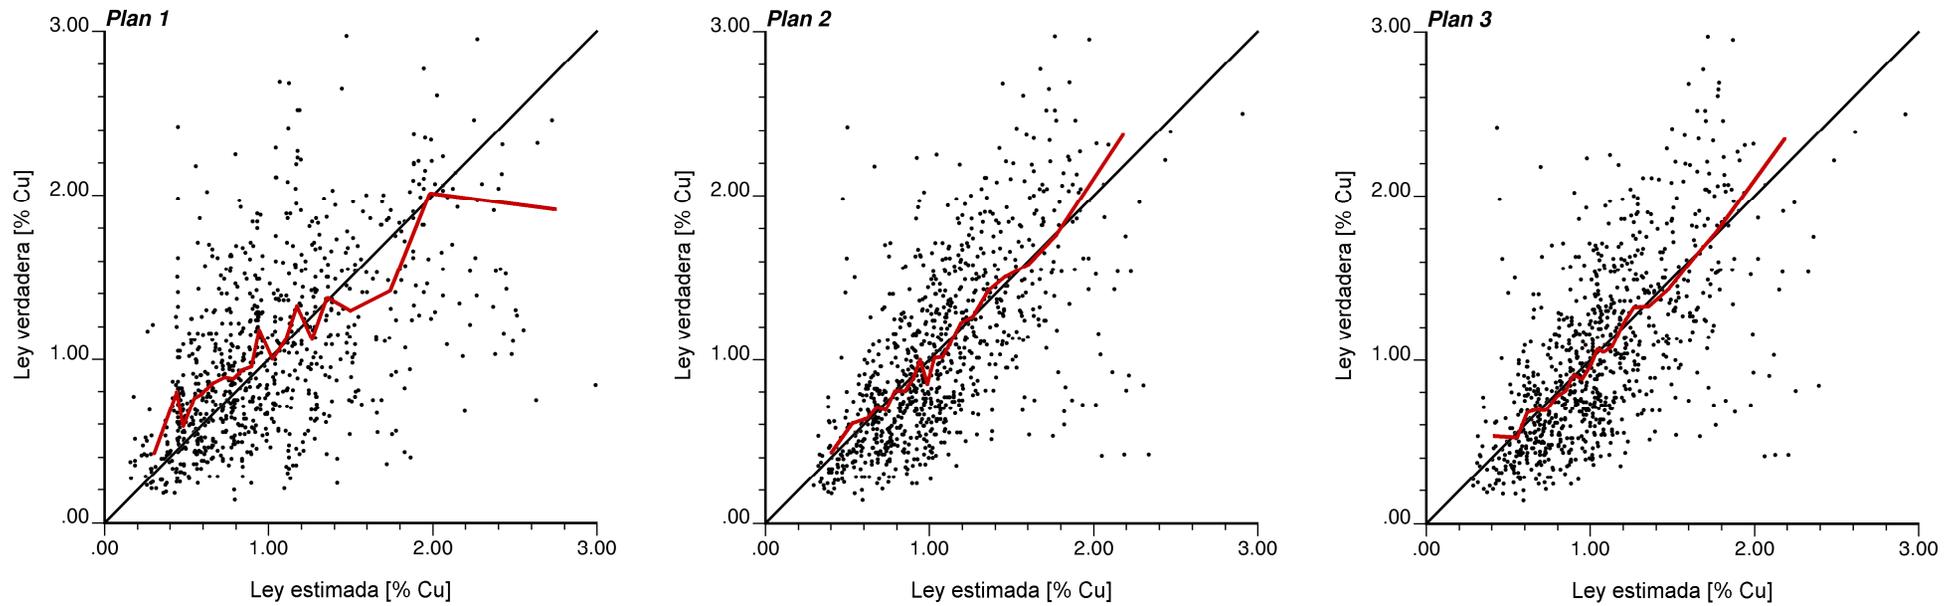
## Histogramas de los errores cometidos



Las medias de los errores son casi nulas → insesgo  
La mayor precisión se alcanza en los planes 2 y 3

# Validación del kriging

## Nubes de correlación entre leyes reales y estimadas



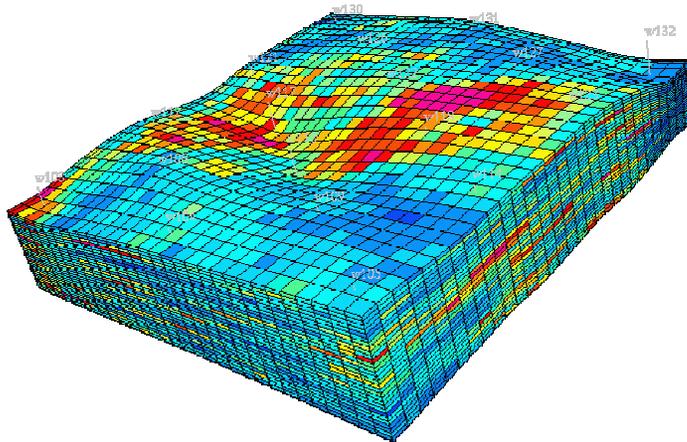
El sesgo condicional y la dispersión de la nube son mínimos en los planes 2 y 3

# Kriging y la geoestadística minera convencional

- En el modelamiento de recursos mineros, convencionalmente se utiliza la **estimación** → se obtiene un sólo mapa (suave)
- Kriging: mejor estimador lineal insesgado

$$Z^*(\mathbf{u}) = a + \sum_{i=1}^n \lambda_i \cdot Z(\mathbf{u}_i)$$

- Construcción de modelos de bloques



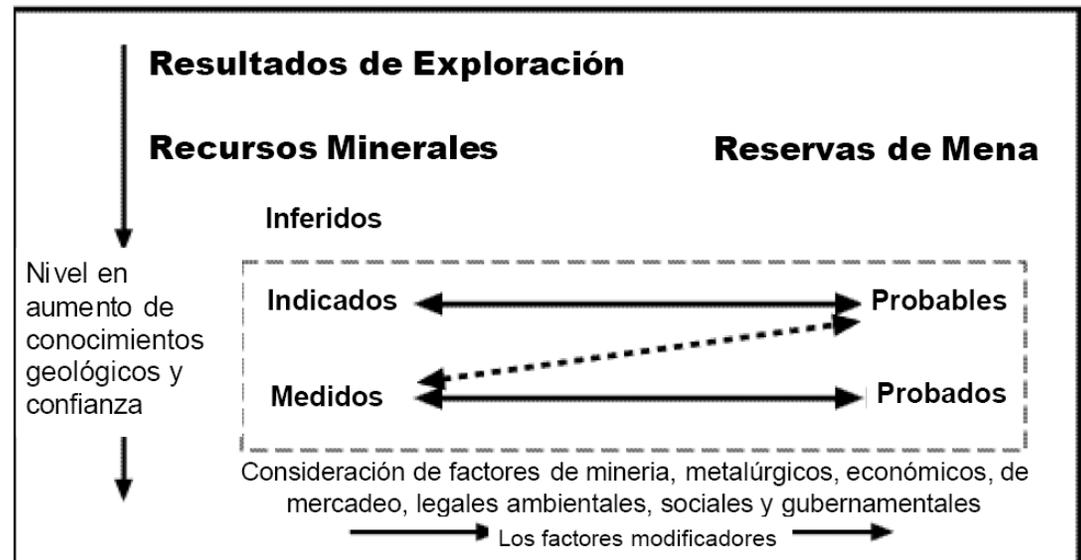
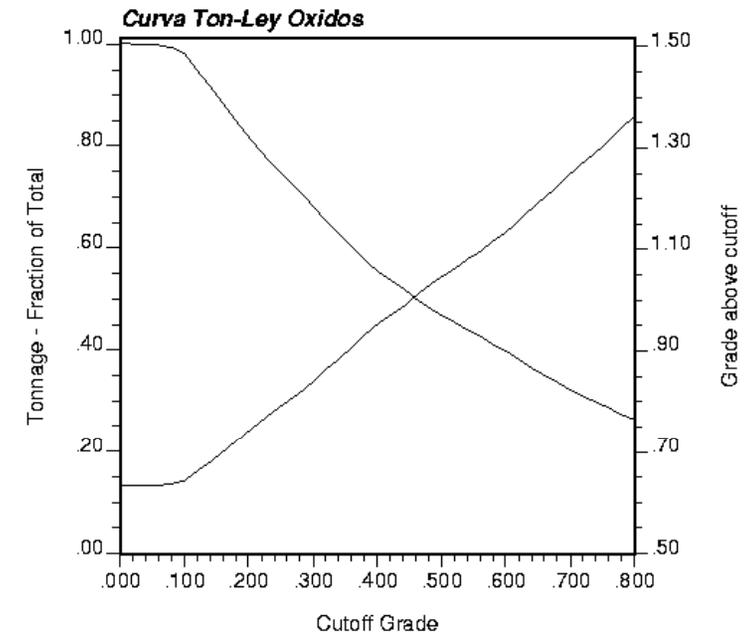
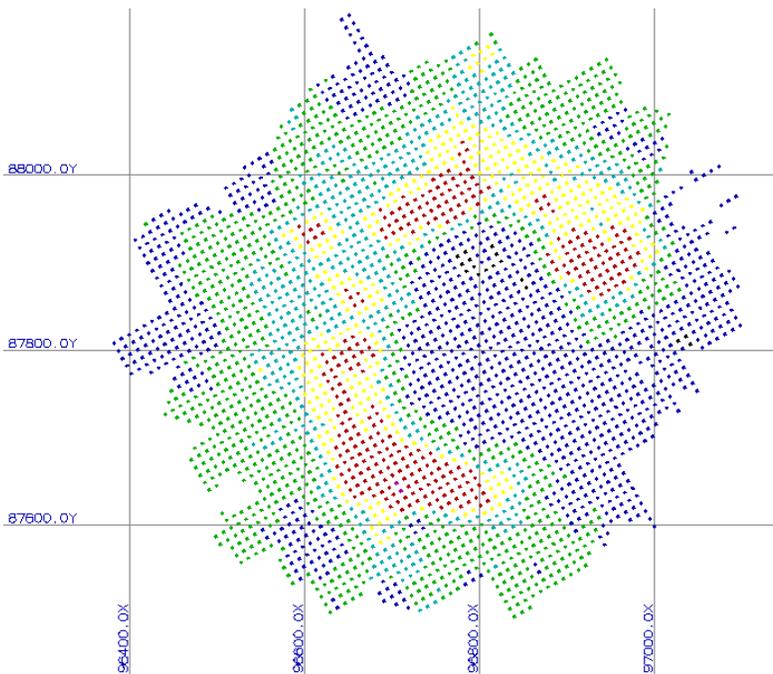
Modelo de Bloques  
→ Recursos

Diseño Minero →  
Reservas

Planificación  
Minera

# Modelo de bloques e inventario

- El resultado de la estimación es:
  - Un modelo de bloques
  - Una curva tonelaje ley (categorización)



---

# Categorización

---

- **Recurso Mineral:**

Concentración u ocurrencia de material de interés económico intrínseco en o sobre la corteza de la Tierra en forma y cantidad en que haya probabilidades razonables de una eventual extracción económica.

La ubicación, cantidad, ley, características geológicas y continuidad de un Recurso Mineral son conocidas, estimadas o interpretadas a partir de **evidencia y conocimientos específicos geológicos**.

Los Recursos Minerales se subdividen, en orden de confianza geológica ascendente, en categorías de *Inferidos*, *Indicados* y *Medidos*.

---

# Categorización

---

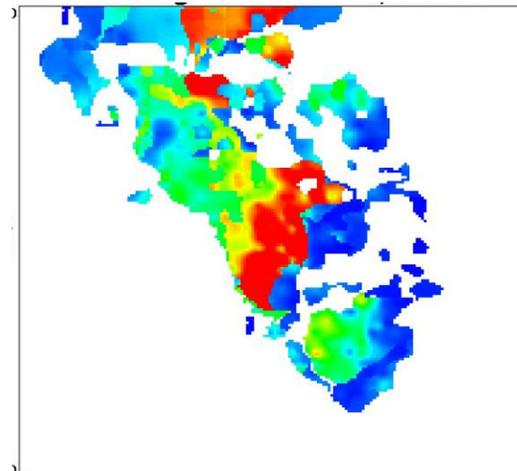
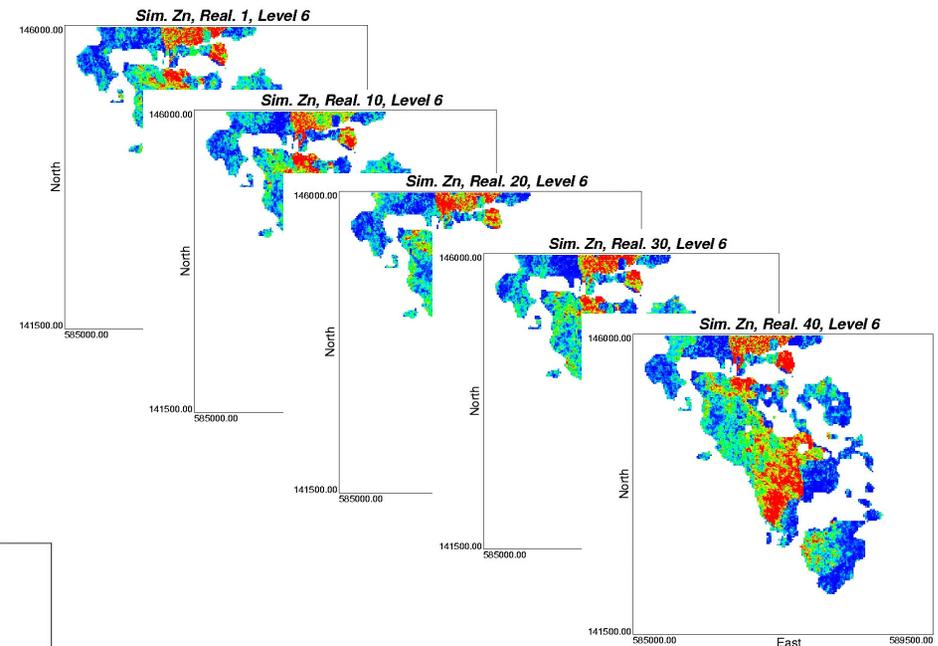
- Reserva Minera:

Es la parte económicamente explotable de un Recurso Mineral Medido o Indicado. Incluye dilución de materiales y tolerancias por pérdidas que se puedan producir cuando se extraiga el material. Se han realizado las evaluaciones apropiadas, que pueden incluir estudios de factibilidad y contemplan la consideración de y modificación por factores razonablemente asumidos de extracción, metalúrgicos, económicos, de mercados, legales, ambientales, sociales y gubernamentales. Estas evaluaciones demuestran en la fecha en que se reporta que **podría justificarse razonablemente la extracción**.

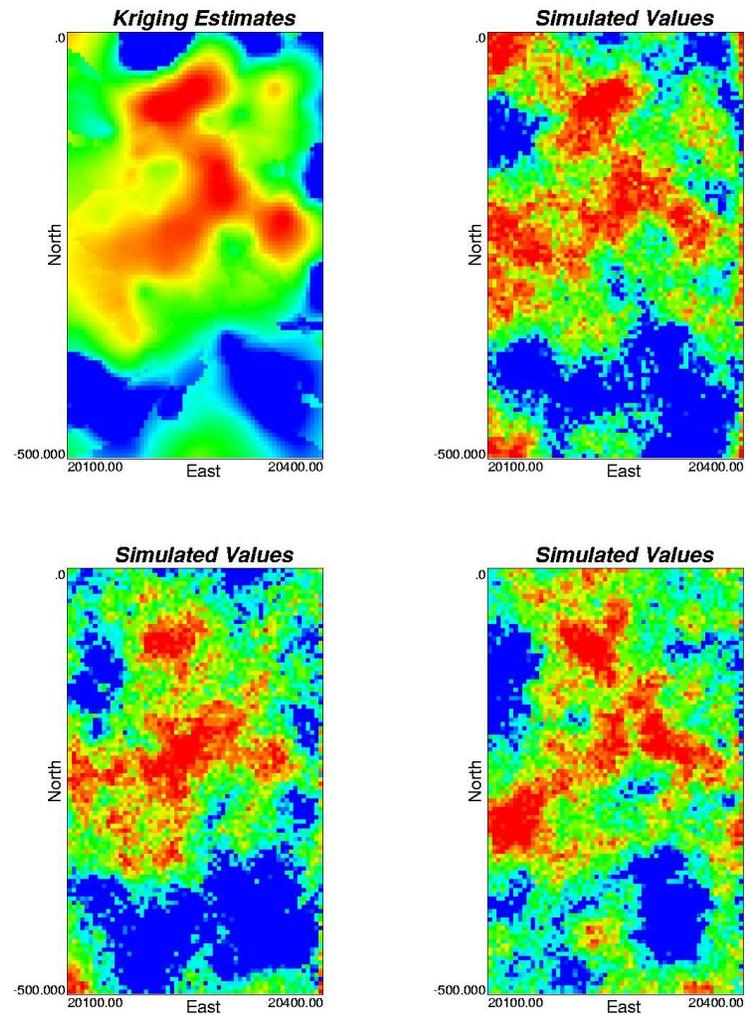
Las Reservas Mineras se subdividen, en orden creciente de confianza, en Reservas *Probables* y Reservas *Probadas*. Nótese que la definición de Reservas *Posibles* ha caído en desuso, debido a que los códigos no autorizan declarar reservas que provienen de recursos geológicos inferidos.

# Geoestadística moderna

- Existe un error asociado que debe ser tomado en cuenta
- Geoestadística moderna → **simulación condicional**
- Se generan varios modelos numéricos válidos (o plausibles); cada uno con la variabilidad correcta.
- Un mapa de valores estimados puede obtenerse a partir de las realizaciones.

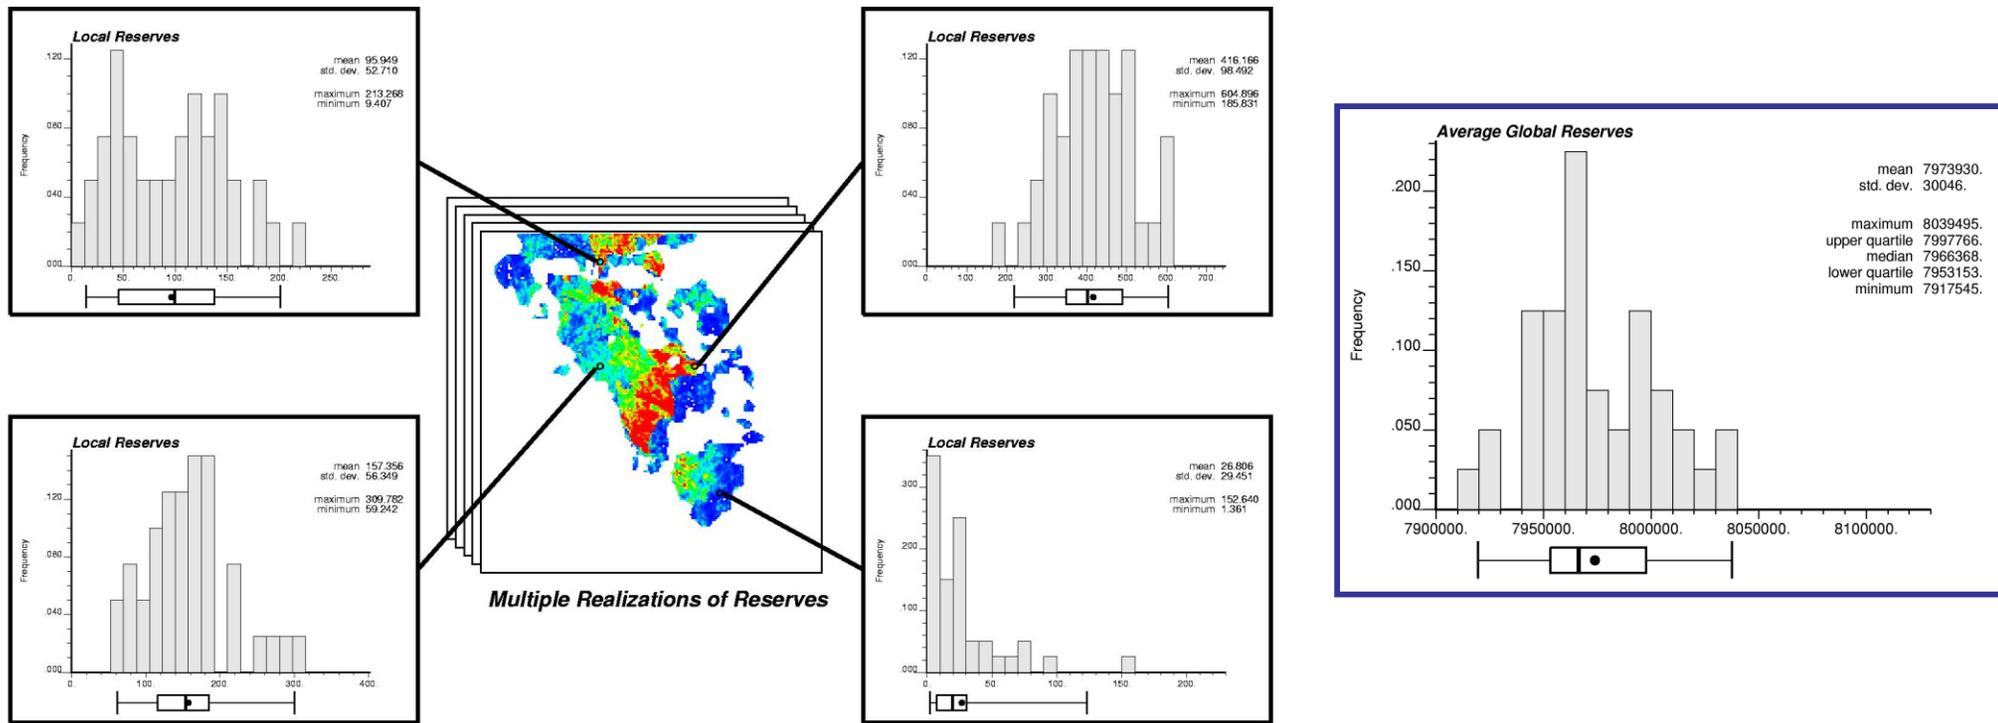


# Geoestadística moderna



# Evaluación de incertidumbre

- Los modelos simulados permiten incorporar funciones de recuperación metalúrgica y determinar la incertidumbre en el fino (metal) :



Incetidumbre local

Incetidumbre global

---

# Nuevas problemáticas

---

- **Modelamiento geo-minero-metalúrgico:**
  - Incorporar variables geo-metalúrgicas al modelamiento
  - Mejorar la toma de decisiones
    - Consumo de energía
    - Consumo de ácido
    - Presencia de minerales que perjudican el proceso o aumentan costos
    - Combinación de elementos que pueden afectar el proceso
- **Modelamiento multivariable con restricciones:**
  - CuT vs CuS
  - Análisis composicional
- **Optimización para diseño considerando escenarios simulados**
  - Intensivo numéricamente
  - Difícil de incorporar el factor temporal