

# Modelamiento de recursos y recuperación de metales en un yacimiento polimetálico

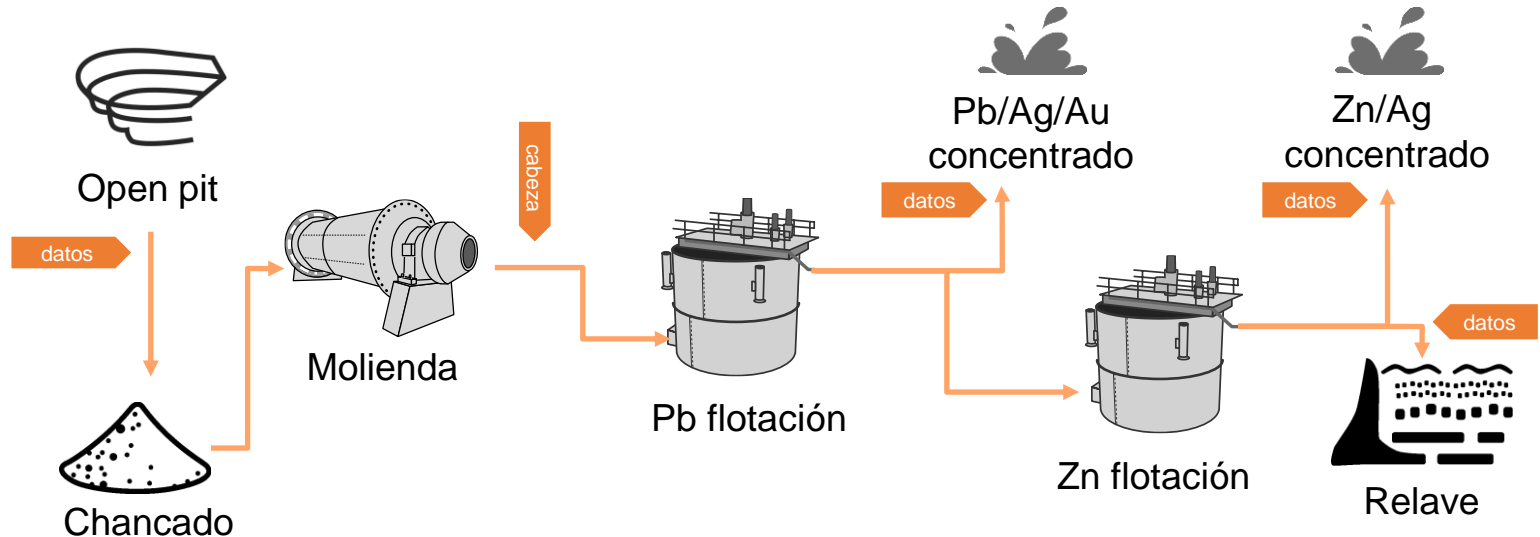
Aplicación de inteligencia artificial en la estimación de recursos y reservas minerales

*Fabián Soto Fernández*

*foto@alges.cl*

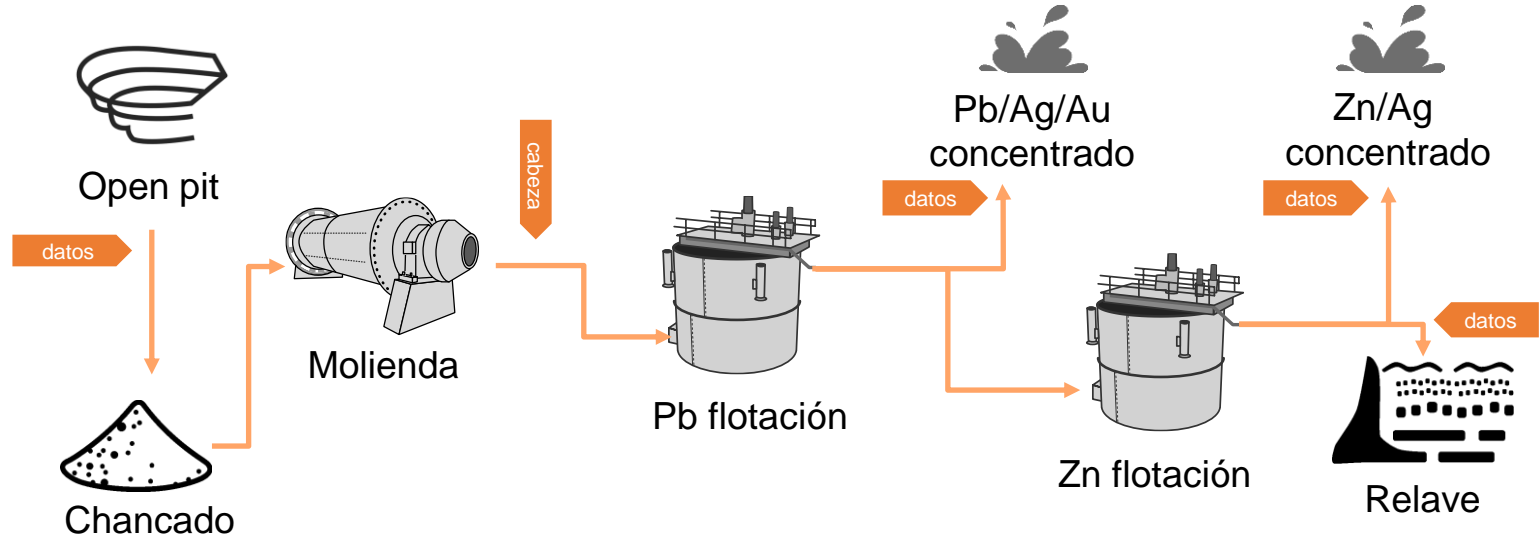
# Modelar **leyes de oro** y su **recuperación** mediante Geoestadística y ML. Problemáticas asociadas:

1. Consistencia de datos (no hay dispatch)
2. No se cuenta con ensayos metalúrgicos, solo datos históricos de planta
3. Yacimiento complejo
4. Escasa información de reactivos
5. Planificación a corto plazo



El proyecto buscaba modelar el oro y su recuperación mediante Geoestadística y ML. Como resultado se obtuvo:

1. Conceptualización y metodología de modelamiento
2. Un modelo de ML para la predicción de la recuperación en planta
3. Un modelo de bloques con la recuperación y el oro estimado
4. Un esquema para la predicción de la recuperación en el próximo periodo (\*)
5. Una serie de Scripts de Python para reproducir los resultados



DATOS DISPONIBLES



POZOS DE  
VOLADURA




MODELO DE  
CORTO PLAZO



POLÍGONOS  
EJECUTADOS




PROCESOS DE  
PLANTA




UTP  
(UNIDAD TEMPORAL  
DE PROCESAMIENTO)



MACHINE LEARNING



GEORREFERENCIACIÓN



MODELO DE BLOQUES  
CON PREDICCIÓN

Como resultado final, se obtuvo un **modelo de bloques completo** con la predicción del oro y su recuperación

## Creación de UTP's



UTP

## Estructura espacial de datos



MODELO DE BLOQUES

## Estructura temporal de datos


time_id	Datos mina	Datos planta
⋮	⋮	⋮



## Georreferenciación

Tonelajes de polígonos

	FECHA	POLÍGONO	TONELAJE...
UTP 1	DÍA 1	2	10
UTP 2	DÍA 2	2	5
	DÍA 2	1	7
UTP 3	DÍA 3	1	8
	DÍA 3	2	7
UTP 4	DÍA 4	1	4




	FECHA	POLÍGONO	TONELAJE...
UTP 1	DÍA 1	2	10
UTP 2	DÍA 2	2	5
	DÍA 2	1	7
UTP 3	DÍA 3	1	8
	DÍA 3	2	7
UTP 4	DÍA 4	1	4

	BLOCK_ID
UTP 1	1,4,5,6,9,...
UTP 2	2,3,8,12,...
UTP 3	7,10,15,16,...
UTP 4	11,13,14,15,...


(\*) Resultado de creación de UTP

FECHA	RECUPERACIÓN
DÍA 1	0.42
DÍA 2	0.55
DÍA 3	0.62
DÍA 4	0.51

(\*) Resultado de predicción ML



GEORREFERENCIACIÓN

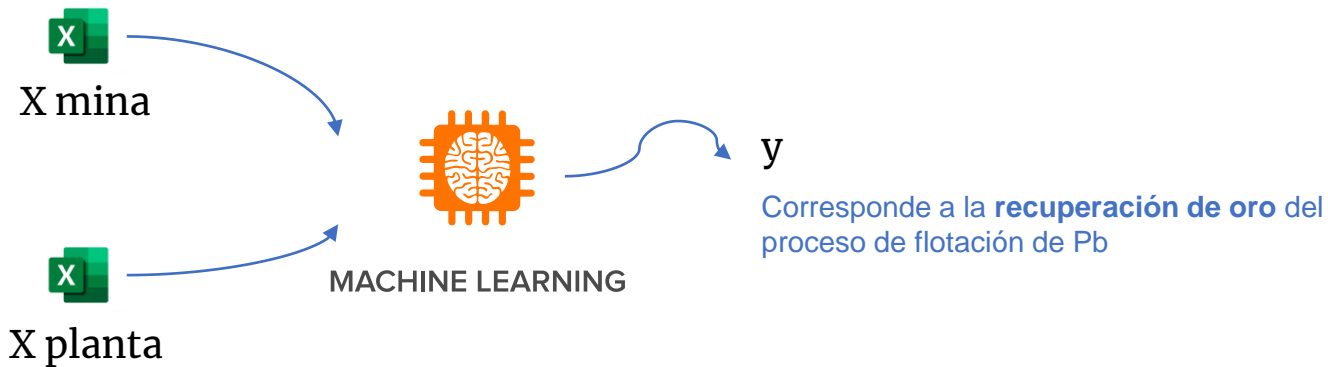


- Nuestro **proceso** utiliza **diferentes métodos de ML** con el objetivo de encontrar aquel que se ajusta mejor, minimizando el error.
- La **estrategia de modelamiento** se considera dentro de los métodos ML, y cada una de esta se evalúa utilizando de este flujo.

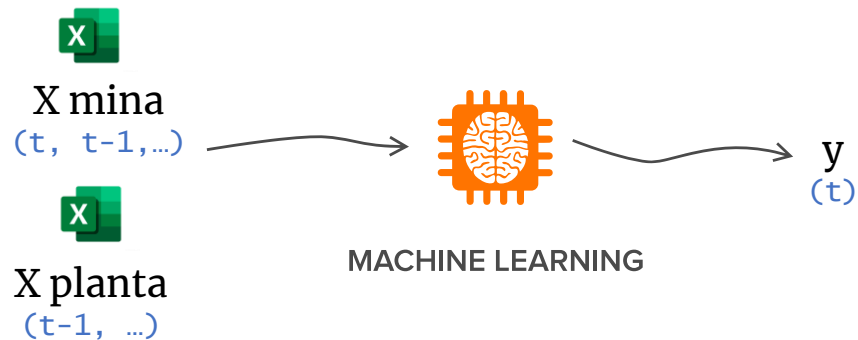
### Tipos de modelación:

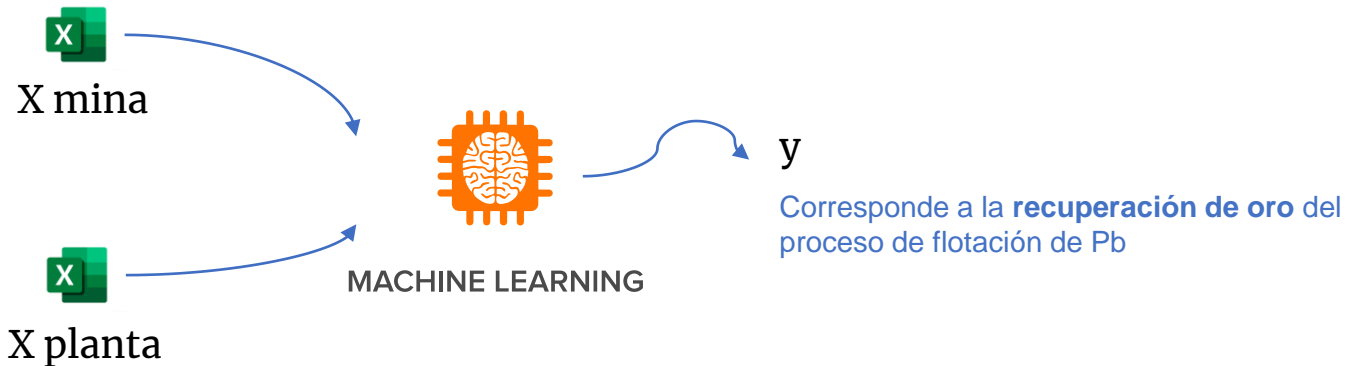
- **Modelación directa.** Modelo de ML con input de mina y variables de planta para predecir directamente la recuperación
- **Modelación con escenarios simulados.** Modelo ML con inputs de mina y ***variables de planta simuladas*** para predecir la recuperación. Este caso se utiliza cuando una UTP todavía no ha sido procesada en planta (predicción)



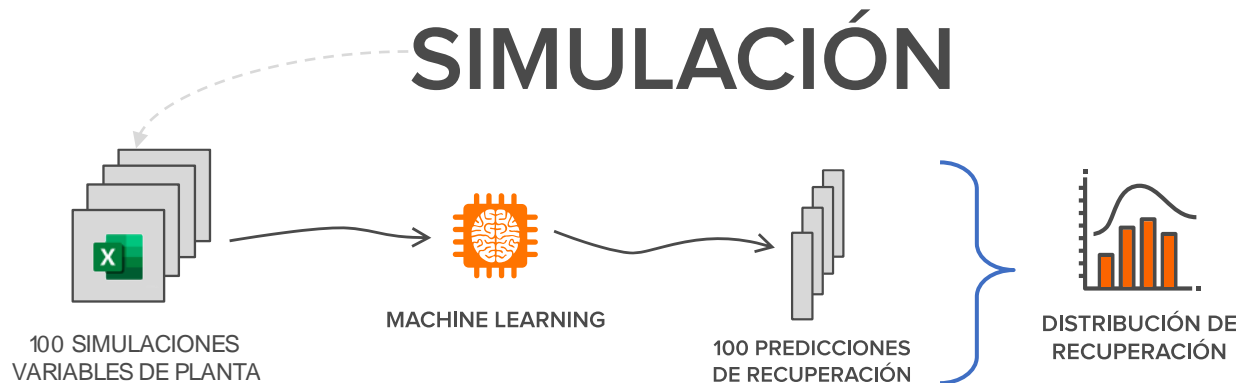


¿Cómo predecir la recuperación si no tenemos los datos futuros de planta?







¿Cómo predecir la recuperación si no tenemos los datos futuros de planta?





## Filtro de variables

- Filtro de variables que presentan muchos datos faltantes
- Filtro de variables que tengan mucha redundancia entre sí
- Transformaciones de los datos
- Selección de variables más relevantes para la predicción





## Algoritmos como regresores

- Partial Least Square (PLS)

Number of components: 1 to 225 (cantidad de mediciones)

- Gradient Boosting (GB)

Boosting algorithm: gbdt, dart

Learning rate: 0.15, 0.1, 0.05, 0.01, 0.005, 0.001

Number of boosted trees: 100, 200, 300, 500, 1000

Metric: l2, l1

- Random Forest (RF)

Number of trees: 50, 75, 100, 125, 150, 175, 200, 225, 250

Number of features: auto, sqrt, log2

The maximum depth of the tree: 3, 4, 5, 6, 7, 8

Se utilizarán las combinaciones de PLS, GB, RF con **selectores GB y RF**: PLS-GB, PLS-RF, GB-GB, GB-RF, RF-GB, RF-RF.



MODEL  
EVALUATION


**Model Evaluation**  
*Modelo directo con  
desfase temporal*

Regressor	Feature Selection	MSE	Corr(spearman)
Partial Least Square	Gradient Boosting	0.0161	0.7912
Gradient Boosting	Gradient Boosting	0.0189	0.4559
Random Forest	Gradient Boosting	0.0171	0.7706
<b>Partial Least Square</b>	<b>Random Forest</b>	<b>0.0171</b>	<b>0.8588</b>
Gradient Boosting	Random Forest	0.0169	0.6676
Random Forest	Random Forest	0.0153	0.65




## MODEL EVALUATION

# Model Evaluation *Modelo directo con desfase temporal*




## Variables utilizadas

Mina	Planta
BM_Mn	Au
Excel_Pb	Corriente 9
Excel_Zn	Ag
BM_Tonelaje	Pb
BM_Ag	Malla -325
	Bi
	Corriente 8
	Fe
	Tonelaje 4
	Tonelaje 6
	Malla 325
	Mn
	Malla 50
	Tonelaje 9
	Tonelaje




Regressor	Feature Selection	MSE	Corr(spearman)
Gaussian Process	Gradient Boosting	0.0081	0.877



El conjunto de validación fue la recuperación entre el 01 de diciembre de 2020 y el 14 de diciembre de 2020



# Predicción del modelo de bloques de recuperación



- Se predijeron los bloques a explotar el 2021 con datos históricos
- Un sector no se estima debido a la falta de información

# Predicción del próximo periodo (resultado)



X mina

Próximos 7 días



Tabla Aportes TSG

date	shift	var_1	...	var_n	tonnage	polygon
30/02/2021	1	...	...	...	Tp1	p1
31/02/2021	1	...	...	...	Tp2	p2
01/03/2021	1	...	...	...	Tp3	p3



Directorio con polígonos

345

367



MB corto plazo



X planta



Consumo de bolas y amperajes



Control de reactivos



Reporte de balance metalúrgico


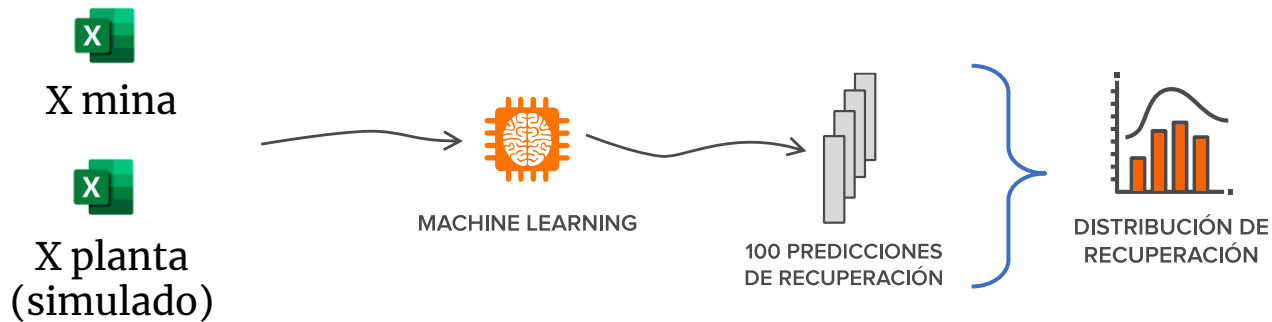


100 SIMULACIONES  
VARIABLES DE PLANTA

2020

- Preparación de datos para el próximo período: 7 días
- Simular datos de planta para el próximo período usando un histórico definido
- Predecir datos procesados usando modelo ML entrenado para simulaciones

# Predicción del próximo periodo (resultado)



1. Se desarrolló una metodología para el modelamiento de recuperación de oro.
2. Se implementó un modelo de ML para la predicción de la recuperación en planta, con un buen desempeño.
3. Se construyó un modelo de bloques con la recuperación y las leyes de oro estimadas.
4. Se diseñó un esquema para la predicción de la recuperación en el próximo periodo.

# Modelamiento de recursos y recuperación de metales en un yacimiento polimetálico


Aplicación de inteligencia artificial en la estimación de recursos y reservas minerales

*Fabián Soto Fernández*

*foto@alges.cl*


## Caso de estudio

- Simulación de condiciones operativas
  - Últimas **6 semanas** con datos de 2020
  - Se predice la siguiente semana en base a todos los datos anteriores
- \* Antes de la predicción semanal, se realiza un re-entrenamiento del sistema



Modelo directo  
*MAE: 0,523*

Modelo simulación  
*MAE: 0,565*



Esta secuencia de etapas corresponde al **flujo metodológico** utilizado para generar un modelo de bloques con oro y su recuperación

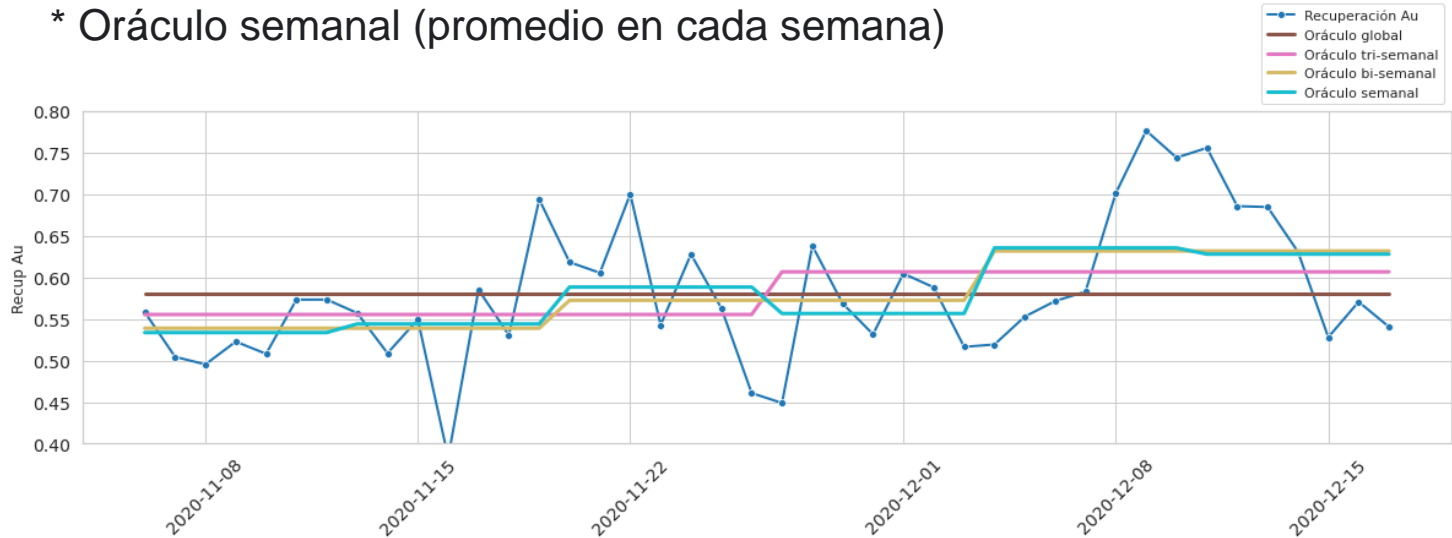
**Etapas configurables:** Cada etapa cuenta con sus propios parámetros, los cuales pueden ser modificados en el futuro

**Ejecución:** Cada etapa tiene un *jupyter notebook* asociado para su ejecución

**Actualización:** Este flujo es posible de ejecutar en cualquier momento, particularmente cuando se tengan más datos y/o condiciones más específicas, actualizando así el modelo de bloques (oro y su recuperación)

## Caso de estudio

- Para contrastar desempeño, se diseñan 4 oráculos (utilizando los datos mismos de recuperación del período analizado)
  - \* Oráculo global (promedio de recuperación en los 42 días)
  - \* Oráculo tri-semanal (promedio cada tres semanas)
  - \* Oráculo bi-semanal (promedio cada dos semanas)
  - \* Oráculo semanal (promedio en cada semana)



Oráculos  
MAE: 0,640 – 0,592




## Caso de estudio

- Comparando los modelos ML y los oráculos, se obtiene el porcentaje de mejora relativo

Modelo directo  
% Mejora MAE:  
**18,28% - 11,66%**

Modelo simulación  
% Mejora MAE:  
**11,73% - 4,57%**



1. Se desarrolló una metodología para el modelamiento de recuperación de oro.
2. Se implementó un modelo de ML para la predicción de la recuperación en planta, con un buen desempeño.
3. Se construyó un modelo de bloques con la recuperación y las leyes de oro estimadas.
4. Se diseñó un esquema para la predicción de la recuperación en el próximo periodo.
5. El esquema de predicción del próximo periodo mejoró respecto los esquemas de oráculo analizados (Al menos 10% para modelación directa).

# Modelamiento de recursos y recuperación de metales en un yacimiento polimetálico

Aplicación de inteligencia artificial en la estimación de recursos y reservas minerales

*Fabián Soto Fernández*

*fsofo@alges.cl*