

## **USO DE INTELIGENCIA ARTIFICIAL EN LA OPTIMIZACION DE LA PRODUCCION DE CONCENTRADOS DE COBRE – SOCIEDAD MINERA CERRO VERDE**

Aldo Aliaga Quiliano  
Hugo Escóbar Alvarez  
Sociedad Minera Cerro Verde

---

### **1 RESUMEN**

Los planes de producción en una concentradora de cobre comprometen las libras producidas contenidas en los concentrados para su posterior comercialización.

La operación diaria de las Concentradoras es gobernada por dos variables a optimizar: el tonelaje y la recuperación; ambas con una relación inversa. Alcanzar el equilibrio óptimo entre estas dos variables constituye el reto principal para maximizar las libras de cobre en los concentrados.

Una herramienta que ha brindado buenos resultados en las concentradoras de Sociedad Minera Cerro Verde ha sido la implementación de la Inteligencia Artificial (IA). El uso del Machine Learning para modelar el tonelaje y recuperación, y así optimizar la producción de libras de Cu.

Las recomendaciones obtenidas con la herramienta, el proceso sistemático de revisión de variables claves para la operación, la detección de anomalías de instrumentos y la interacción entre profesionales de las concentradoras durante la revisión de las recomendaciones, han servido para mejorar y unificar las decisiones operativas, rompiendo muchos paradigmas en el camino.

Producto de la implementación de esta herramienta y proceso, se lograron identificar oportunidades de mejora en las Plantas que derivaron en proyectos de optimización de

los circuitos de flotación y a la fecha con más de un año de implementación, se obtuvieron incrementos en la producción de libras de Cu de hasta 6.5%, sin perder la calidad del concentrado y en muchas oportunidades mejorándola.

### **2 INTRODUCCION**

Sociedad Minera Cerro Verde cuenta con dos Concentradoras y una planta SX/EW que operan de manera integrada en su única concesión de beneficio. El rendimiento de ambas concentradoras ha estado basado principalmente en el expertise de los profesionales que la operan y la capacidad de los equipos instalados.

Con herramientas de analítica de avanzada se pudo determinar nuevas oportunidades de mejora; utilizando modelos de Machine Learning se encontraron nuevos puntos óptimos de operación que normalmente eran considerados paradigmas operativos y que al ojo del mejor Metalurgista resultaba complicado alcanzar.

En este trabajo se presentará la metodología de implementación, los retos afrontados y los beneficios obtenidos durante la etapa de implementación y sostenibilidad de la herramienta.

### **3 OBJETIVOS**

Incrementar la producción de libras de Cu balanceando continuamente entre incrementar tonelaje o la recuperación.

Utilizar la Inteligencia Artificial como herramienta de optimización operativa.

### **4 METODOLOGIA**

La magnitud del trabajo involucrado en la implementación de la IA hace notar que los modelos de Machine Learning no podrían quedar solos como una herramienta de

optimización; por el contrario, se requiere una serie de otras herramientas y actividades que acompañen y ayuden en el sostenimiento de esta herramienta de optimización.

El proceso completo de implementación contempló: diagnóstico de situación actual, definición de alcances y recursos, determinación de primeros principios, implementación de primeros modelos de Machine Learning, implementación de módulo de “Detección de Anomalías de Instrumentos”, iteración de modelos de Machine Learning, definición de Interfaz de Usuario, alineamiento de APC’s (Sistemas Experto) con Primeros Principios Metalúrgicos, ajuste de restricciones y sostenibilidad de la herramienta.

#### a. Determinación de Prueba de Concepto

En esta etapa se identificó que el mayor potencial estaba en la optimización de la Recuperación y el Tonelaje con 6 palancas que ayudarían a alcanzar y sostener el máximo potencial [ver gráfica 1].

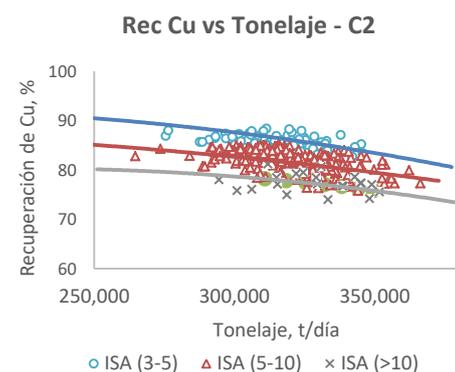
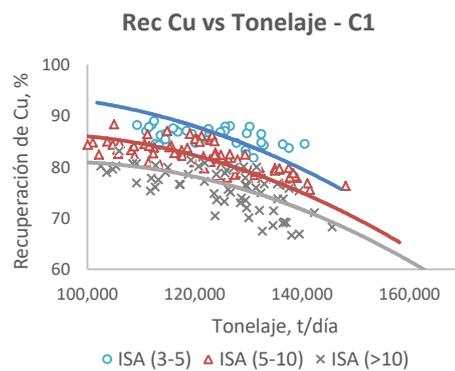


Gráfica 1 Variables de Alto Potencial y palancas para optimizarlas

Referente a la **Recuperación**, el análisis indicaba el potencial de mejora que se podría tener de acuerdo a conceptos teóricos y a análisis operativos de la recuperación. Considerando otras

variables más a las de modelos metalúrgicos de recuperación, que correlacionan variables relacionadas al mineral como el contenido de Cu y Fe en la alimentación, la dureza, el nivel de oxidación y variables relacionadas al proceso como el P80. [ver Anexo 1, tabla 1].

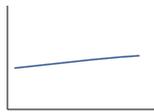
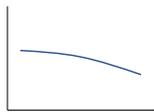
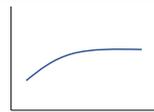
Referente al **Tonelaje**, la relación es inversa con la Recuperación; es decir cuando incrementamos el tonelaje hay un impacto negativo en recuperación. Para la Concentradora 1 (C1), la sensibilidad de la recuperación al tonelaje es mayor que en la Concentradora C2 (C2). [Gráfica 2]



Gráfica 2 Sensibilidad de recuperación al incremento de Tonelaje en las Concentradoras C1 y C2 considerando las variaciones en los niveles de oxidación del mineral (ISA).

#### b. Determinación de Primeros Principios

Definir los Primeros Principios permite dar coherencia a los modelos de Machine Learning y evitar errores de interpretación; es así como estos modelos deben cumplir con estos principios que obedecen al comportamiento metalúrgico de los tipos de mineral y factores operativos inherentes a cada Planta Concentradora. [Gráfica 3].

Parámetros	Tendencia Básica	Rango óptimo
Tonelaje		(120 - 145) KTPD
%Sólidos descarga molinos		(76 - 78) %
Presión de Ciclones		(120 - 140) Kpa
%Sólidos Alim a Flotación		(28 - 30) %
Grado Rougher		(8 - 12) %
Grado Scavenger		(1.2 - 4) %
Dosis Colector Primario		(1.5 - 4.4) g/Kg Cu
Dosis Colector Secundario		(1.5 - 5) g/KgCu
Mass Pull		(4 - 7) %
Cola Circuito Limpieza		(0.08 - 0.18) %

Gráfica 3 Primeros Principios definidos en coordinación con las áreas de Metalurgia y Operaciones. Relaciona en el eje Y la recuperación de Cu y en el eje X los parámetros.

### c. Implementación de modelos Machine Learning de línea base

El primer paso para la implementación de la Inteligencia Artificial (IA), fue definir modelos de línea base que puedan predecir resultados en condiciones estables de planta y que se actualicen con la información en línea disponible del proceso. Además, son muy necesarios para comparar los incrementos de recuperación y tonelaje con los modelos de optimización y generar las mejores recomendaciones a la operación.

Estos modelos fueron definidos para los parámetros optimizables: Recuperación, Tonelaje, y para el modelo de restricción de Concentrado Bulk Cu-Mo. La dificultad de la implementación consistía en: la complejidad de la interacción de las variables en la Concentradora y que no había datos en tiempo real sobre el rendimiento de planta sin que la IA tuviera lugar.

*Un punto importante para considerar es que el modelo metalúrgico de recuperación de Cu inspiró el modelo de línea base de recuperación de la IA; sin embargo, la principal diferencia residía en que el modelo metalúrgico se centraba en la recuperación final de cada turno de operación y el modelo de línea base de la IA se centraba en estimar la recuperación con una cadencia de 3 horas (4 veces por cada turno de operación de la planta).*

Las técnicas utilizadas para establecer los modelos de línea base consistían en los “árboles de decisión” y “gradient boosting”.

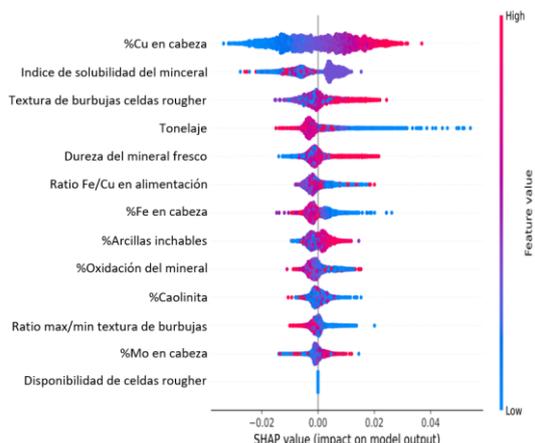
En caso de los “árboles de decisión”, permite: agrupar datos para asignar casos a grupos que son similares con respecto al resultado, tolerar diversidad de datos (se desempeña bien con mezclas de datos continuos y categóricos), relaciones no lineales y ayuda a encontrar patrones que no

pueden ser graficados en un diagrama XY y no pueden ser extrapolados porque las predicciones que entrega son promedios del resultado observado; esto lo convierte en una línea base natural.

En caso del “gradient boosting”, permite: garantizar la diversidad de modelos al considerar las entradas de múltiples árboles de decisión, cada uno creado con un subconjunto de variables disponibles, incorporar los beneficios de los árboles de decisión tolerando la diversidad y modelando relaciones no lineales; y contener miles de árboles para considerar una amplia variedad de rutas únicas para la predicción de resultados antes de tomar un promedio ponderado de árboles para la regresión final.

*Tabla 2 Modelo línea base para recuperación. ~2% de MAPE (Error Porcentual Absoluto Medio)*

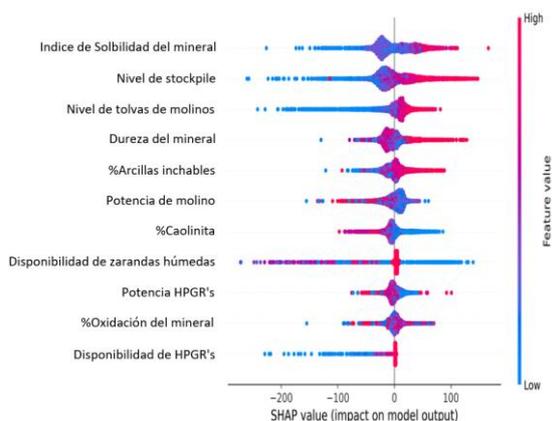
	MAPE		R2	
	Train	Test	Train	Test
<b>Line 1</b>	1.58	2.31	0.78	0.56
<b>Line 2</b>	1.23	2.01	0.85	0.63
<b>Line 3</b>	1.24	1.98	0.84	0.61
<b>Line 4</b>	1.40	2.18	0.82	0.59
<b>Promedio lineal</b>	1.36	2.12	0.82	0.60
<b>Agregado</b>	1.71	2.09	0.72	0.57



Gráfica 4 Parámetros del modelo línea base de Recuperación.

Tabla 3 Modelo línea base para tonelaje. ~6% de MAPE

	MAPE		R2	
	Train	Test	Train	Test
<b>Line 1</b>	4.1	5.5	0.72	0.44
<b>Line 2</b>	4.4	6.0	0.67	0.42
<b>Line 3</b>	5.3	6.6	0.60	0.38
<b>Line 4</b>	4.1	5.4	0.78	0.61
<b>Promedio lineal</b>	4.5	5.9	0.69	0.46
<b>Agregado</b>	6.2	7.4	0.50	0.29



Gráfica 5 Parámetros del modelo línea base de Tonelaje.

#### d. Implementación de modelos de Machine Learning de optimización

Una vez definidos los modelos de línea base, el siguiente paso fue la construcción de modelos de optimización que generen recomendaciones de los mejores puntos de operación que maximicen la producción de libras de Cu balanceando entre maximizar el tonelaje molido y la recuperación.

El método de construcción es muy similar al de los modelos de línea base; la diferencia consiste en que estos modelos estiman los valores óptimos para los parámetros optimizables que en este estudio consisten en los siguientes:

Tabla 4 Parámetros optimizables por la IA

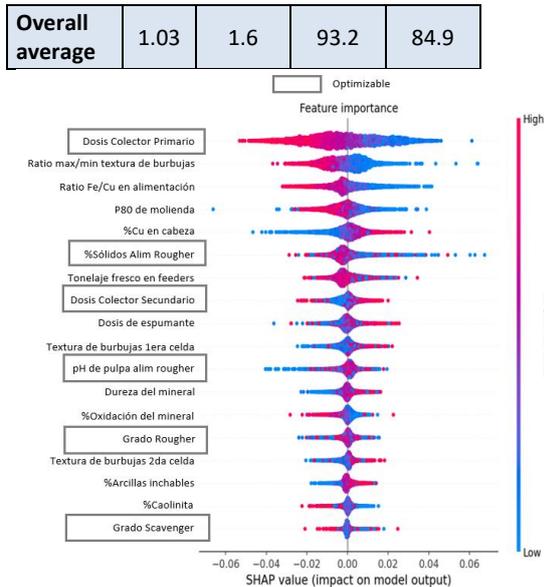
Palancas	Parámetros Optimizables
<b>Relacionados a P80</b>	Tonelaje
	Presión de ciclones
	%Sólidos a la descarga de molinos
<b>Relacionados a Recuperación</b>	%sólidos alimentación Rougher
	Grado Concentrado Rougher
	Grado Concentrado Scavenger
	Dosis de Colector Primario
	Dosis de Colector Secundario
	pH

#### Modelo de Optimización de Recuperación

El modelo campeón luego de las iteraciones presentó ~1.6% MAPE:

Tabla 5 Modelo campeón para optimización de Recuperación

	MAPE		R2	
	Train	Test	Train	Test
<b>Line 1</b>	1.36	1.95	90.3	80.8
<b>Line 2</b>	0.94	1.46	93.9	87.2
<b>Line 3</b>	0.79	1.47	95.3	85.9
<b>Line 4</b>	1.03	1.54	93.4	85.7



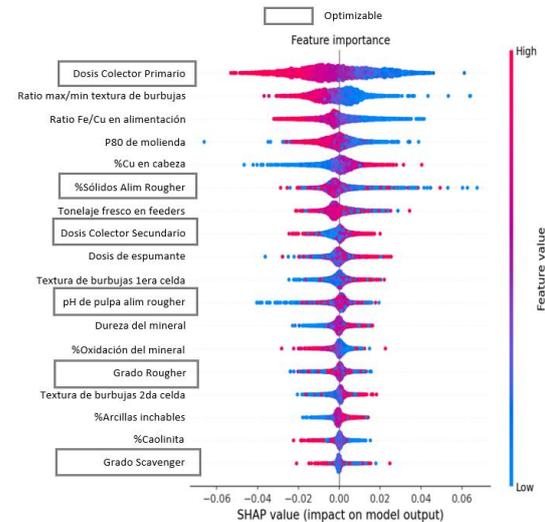
Gráfica 6 Parámetros del modelo de optimización de Recuperación

### Modelo de Optimización de P80

El modelo campeón luego de la iteración presentó ~3.48% MAPE:

Tabla 6 Modelo campeón para optimización de P80

	MAPE		R2	
	Train	Test	Train	Test
Line 1	2.96	3.19	0.8	0.76
Line 2	2.96	3.3	0.83	0.8
Line 3	3.24	3.78	0.83	0.78
Line 4	3.43	3.64	0.78	0.72
<b>Overall average</b>	3.15	3.48	0.81	0.76



Gráfica 7 Parámetros del modelo de optimización de P80

### e. Implementación de módulo de Detección de Anomalías de Instrumentos

Los modelos de Machine Learning deben correr con una frecuencia mayor a los resultados oficiales de cada turno de operación. Para estas corridas la información que se alimenta a los modelos provienen de los sensores de planta. Estos instrumentos deben ser monitoreados permanentemente y se debe asegurar su confiabilidad. Para esta tarea se implementó un módulo de "Detección de anomalías" de todos los instrumentos que alimentan información a los modelos de Machine Learning. Este módulo continuamente evalúa la coherencia de los datos y al detectar una desviación, clasifica la falla en intensidades: moderada, alto, muy alto y crítico. Este ranking permite al equipo de Instrumentación definir la prioridad de atención. [Ver anexo, Gráfica 12]

### f. Iteración de modelos

Los modelos iniciales deben ser entrenados en todos los escenarios posibles para disminuir el error de

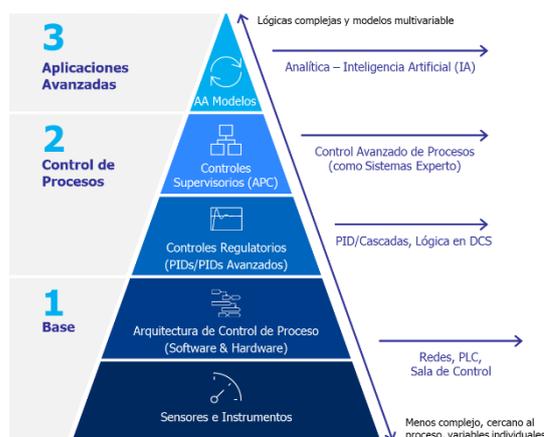
predicción. Esta tarea se lleva a cabo de manera frecuente (cada 3 meses) y en función a los cambios de mineral, mejoras en los procesos, cambios de equipos, etc.

### g. Definición de Interfaz de Usuario

La interfaz de usuario es el ambiente web que permite la interacción de los operadores con la Inteligencia Artificial. Es aquí donde se presentan los mejores puntos de operación estimados con los modelos de Machine Learning; y el operador puede hacer la revisión de estas recomendaciones. Esta interfaz de usuario brinda toda la información necesaria que debe conocer el Operador para tomar la decisión de alcanzar los puntos de operación recomendados o no. Es decir, tiene la facultad de Aceptar, Rechazar o Poner en Revisión cada recomendación. [Ver anexo, gráfica 13].

### h. Alineamiento de APC's con Primeros Principios

De acuerdo con la arquitectura de control, la IA ocupa el lugar más alto, sobre los Controles Avanzados de Procesos (APC's por sus siglas en inglés). Entonces, podemos deducir que las recomendaciones generadas por la IA podrían ser alcanzados de manera estable utilizando los APC's.



Gráfica 8 Jerarquía de Control y Optimización de Procesos

### i. Ajuste de restricciones

Es importante definir las restricciones a los parámetros optimizables que considera la IA. Sin la definición de estas restricciones, podríamos generar desconfianza en los operadores cuando evalúen recomendaciones que no podrían ser alcanzados operativamente o que los equipos tienen como restricción física de diseño.

Tabla 7 Restricciones a parámetros optimizables.

Variable	Min Rec	Max Rec
Presión de ciclones	120	145
Dosis de Colector Secundario	0	7
Concentrado Rougher	9	14
Concentrado Scavenger	1	4
Tonelaje	1500	3250
Dosis de Colector Primario	2	6
%Sólidos alim rougher	25	32
%Sólidos descarga molinos	65	80

Tabla 8 Restricciones adicionales

Tonelaje	El mismo valor	Velocidad de bomba de ciclones > 95%
		BM Gear Box Temp > 80 Deg C
		Disponibilidad de espesadores de relaves < 2
		Si disponibilidad de zarandas húmedas <= 1 entonces tonelaje <= 2000 TPH

<b>Presión de ciclones</b>	El mismo valor	BM Gear Box Temp > 80 Deg C
	Especial	Si velocidad de bomba de alim ciclones >95% solo permite incrementar 15 Kpa Si corriente de bomba de alimentación a ciclones >289 A solo permite incrementar 15 Kpa
<b>%Sólidos alim rougher</b>	El mismo valor	flujo de agua en Overflow >1200 m3/h
<b>%sólidos descarga de molino</b>	El mismo valor	Flujo de agua a molino >599 m3/h Flujo de agua al Underflow de ciclones >599 m3/h
	Especial	Si tonelaje > 2700 entonces mínima densidad en descarga del molino >= 75%
<b>Concentrado Rougher</b>	El mismo valor	Nivel de tanque de Concentrado Rougher >92% Flujo alimentación a remolienda rougher >1700 m3/h
	Especial	Si Concentrado Bulk > 21% entonces Concentrado Rougher <= valor actual
<b>Dosis Colector Secundario</b>	Especial	Si ratio Fe/Cu en columnas > 3 entonces Dosis de Colector Secundario <= valor actual

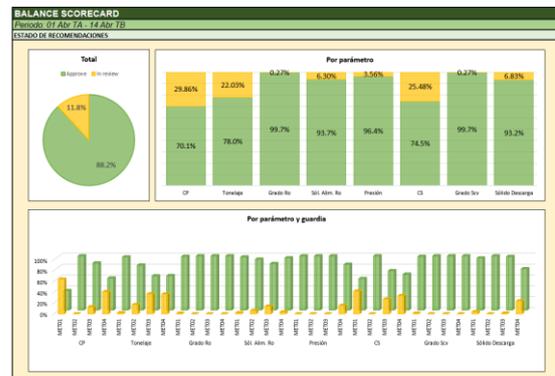
## j. Sostenibilidad de la herramienta

El proceso de sostenibilidad de la herramienta contempló:

- Charlas de introducción de IA y su utilización en la optimización del Proceso.
- Entrenamiento en la utilización de la herramienta interactuando a través de la Interfaz de Usuario con los usuarios directos.
- Charlas de difusión de la herramienta a las áreas de soporte de la operación como Electricidad, Instrumentación, Mantenimiento Mecánico, Control de Procesos, Metalurgia, etc.
- Difusión de la importancia de la confiabilidad de información de sensores y disponibilidad.
- La socialización e involucramiento de los líderes cumple un papel muy importante para el éxito de todo el proceso de implementación.

Durante el inicio del despliegue de la herramienta, el 100% del personal de Concentradora tenía conocimiento del proyecto de implementación y sabía cómo su trabajo impactaría en el éxito y sostenimiento de esta herramienta.

Parte del sostenimiento, se hicieron seguimientos mensuales al performance de las revisiones de recomendaciones, la comparación entre guardias y las estadísticas de aceptación, puestas en revisión o rechazo de las recomendaciones:



Gráfica 9 Reporte de seguimiento a revisión de recomendaciones.

Este seguimiento permite identificar los parámetros que menos nivel de aceptación tienen y evaluar si existe una restricción física de Planta que puede ser levantada a través de una iniciativa de mejora o si es simplemente un paradigma operativo.

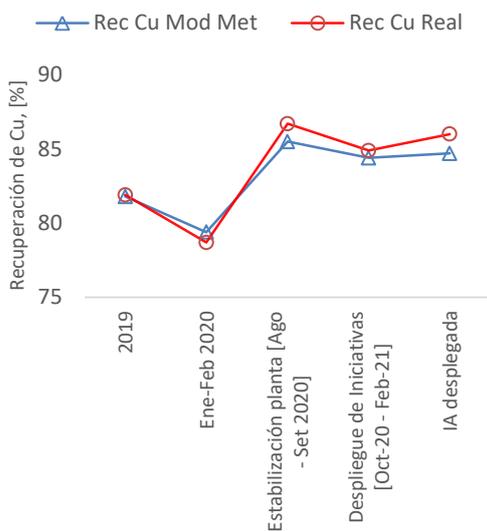
## 5 RESULTADOS

De acuerdo con las mejores estimaciones de la IA implementada, incrementar el tonelaje favorece la mayor producción de libras de Cu; sin embargo, la relación de la recuperación con el tonelaje es inversa según las curvas revisadas en la prueba de concepto. Es así, al incrementar el tonelaje se impacta negativamente en la recuperación, sin embargo, existe un punto máximo de tonelaje y recuperación que maximiza la producción de libras y las recomendaciones

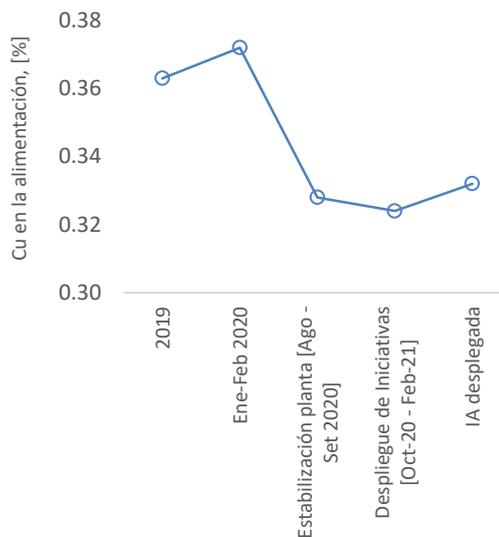
generadas por la IA nos permite mover la operación hacia esos puntos de operación.

Agosto del 2020 en que inició el Proyecto de implementación de IA con los primeros análisis y levantamiento de restricciones, se logró incrementar la recuperación a promedios de ~ 85% aún cuando la ley de cabeza se redujo por debajo de 0.34% de Cu.

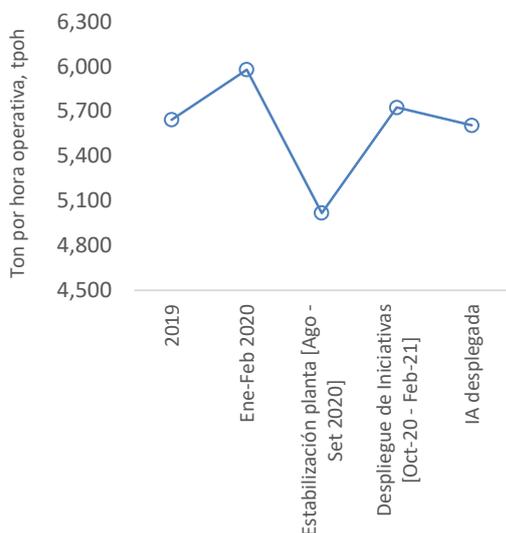
### Recuperación de Cu



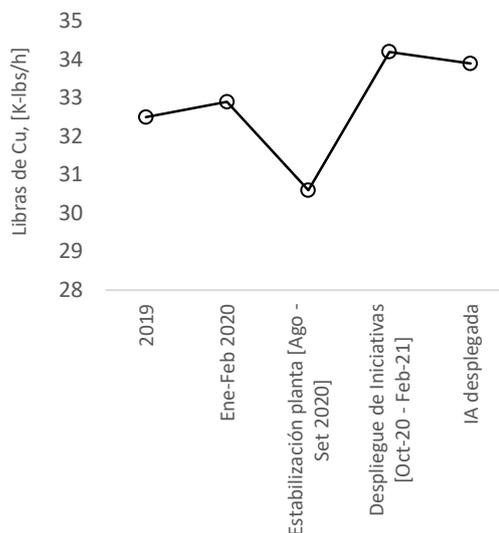
### Ley de cabeza de Cu



### Toneladas molidas



### Libras de Cu producidas



Gráfica 10 Recuperación de Cu y Toneladas molidas

Desde el 2019 hasta Febrero del 2020, operativamente se buscaba un mayor tonelaje, pero el impacto en recuperación era alto. Aún cuando la ley de cabeza era mayor a 0.36% de Cu la producción de libras de Cu por día alcanzaba a las 32,000 lb/h. A partir de

Gráfica 11 Gráfica de contenido de Cu en alimentación y libras de Cu producidas

A partir del despliegue de iniciativas durante la implementación de la IA y su despliegue, se logró incrementar la producción de libras de



Cu a promedios de ~ 34,000 lb/h incrementos de hasta 6.5%.

## 6 CONCLUSIONES

- a. Desarrollar un sistema de optimización de procesos utilizando Inteligencia Artificial conlleva una serie de implementaciones paralelas a los modelos de Machine Learning que ayuden a maximizar las libras de Cu. Estas labores paralelas son tan importantes como los modelos en sí mismos.
- b. Los trabajos de sostenibilidad de la herramienta que involucran conversaciones uno a uno con operadores de campo, con grupos de colaboradores de áreas de soporte y líderes de la Concentradora son primordiales para el éxito de la herramienta. Al final se puede tener una muy buena herramienta de optimización, pero si no lo han interiorizado los usuarios directos o los involucrados en las áreas de soporte, la herramienta simplemente no se utilizaría.
- c. De acuerdo con la jerarquía de control y optimización, es importante que todos los sistemas que están bajo la IA estén operando de manera confiable por dos razones principales: 1) la información que generen servirá como inputs a los modelos de optimización y 2) porque para alcanzar los puntos de operación recomendados se necesita que la operación esté estable y movamos la operación de manera estable hacia esos nuevos puntos de operación recomendados.
- d. Con la implementación de la IA se ha logrado incrementar las libras de Cu producidas maximizando el tonelaje y la recuperación.

## 7 BIBLIOGRAFIA

- Marco Vaccari, Ricardo Bacci. (2020). Implementation of fan Industry 4.0 system to optimally manage chemical plant operation.
- Ilesanmi Daniyan,. (2022). Implementation of Artificial Intelligence for maintenance operation in the rail industry.
- Varanon Uraikul, Christine W. Chan, Paitoon Tontiwachwuthikul. (2006). Artificial intelligence for monitoring and supervisory control of process systems.
- <https://shap.readthedocs.io/en/latest/index.html>
- <https://scikit-learn.org/stable/index.html>
- <https://scikit-learn.org/stable/modules/sgd.html>

## 8 ANEXOS

*Tabla 1 Potencial incremento en recuperación*

		C1	C2	¿Cómo capturar valor?	Dificultad
<b>Potencial de incremento teórico</b>	Reducción de colas	5%	4%		
	Recuperación por tamaños	3%	2 - 5 %		
	Pruebas de laboratorio	3.50%	2.50%		
	<b>Total de incremento teórico</b>	<b>3 - 5 %</b>	<b>2 - 5 %</b>		
<b>Mejora Operativa más allá del modelo de Recuperación</b>	Densidad de flotación	1.4%	1.4%	IA / Proyectos	D
	pH de flotación	0.7%	1.7%	IA / Proyectos	M
	Dosis Colector Primario	2.6%	1.6%	IA	F
	Dosis de Colector Secundario	4%	4%	IA	F
	Mass Pull	1.7%	1.5%	APC/IA/Proyectos	F
	Circuito Limpieza	0.7%	0.7%	APC/Proyectos	M
<b>Optimización del P80</b>	Mejora en Molienda	-	-	IA	F
<b>Entrega de mineral de fases (blending)</b>		<b>2.5 - 3.5 %</b>	<b>2.0 - 3.0 %</b>	-	-



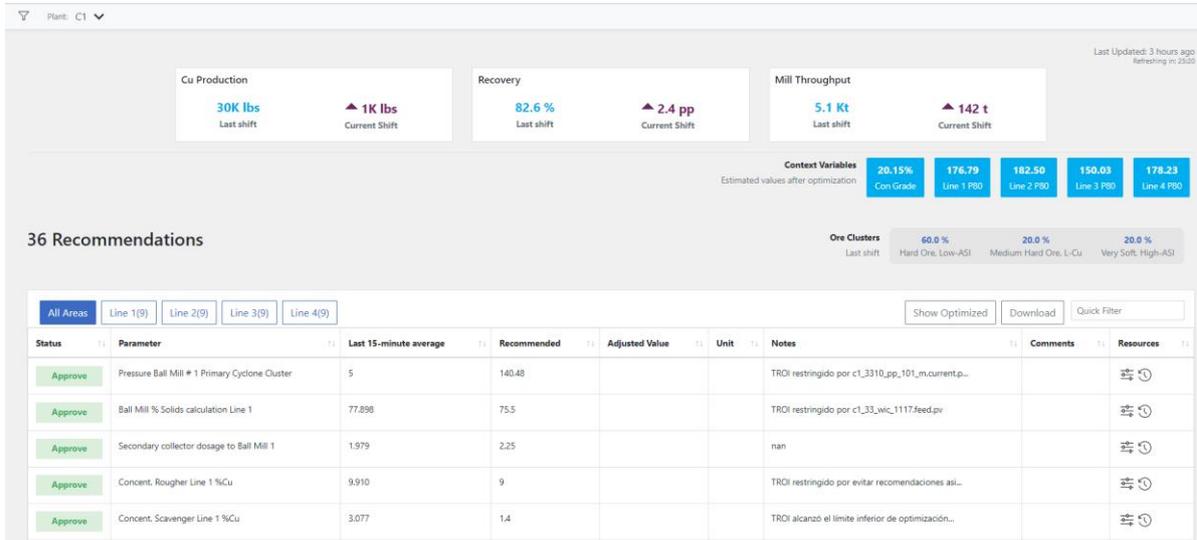
## Interfaz del módulo de detección de anomalías.

Criticality Rating	Sensor Name	PI Tag	Mean Increased	Mean Decreased	Variance Increased	Variance Decreased	Flatline	Missing	Out of Span	Nelson Rules
Critical	% Solids Ball Mill 1 Primary Cyclone Feed	c1_33_di_2116.daca.pv								2, 3
Critical	Primary Collector Dosage to Ball Mill 4	c1_39_fic_0124.dosif.pv						2		1, 2, 3
Critical	Primary Collector Dosage to Ball Mill 2	c1_39_fic_0122.dosif.pv						2	1	1, 2, 3
Critical	% Solids mill virtual discharge L3	c1_33_sol_l3_v.descmill.pv								2, 3
Critical	Total Line3 Fresh Feed	c1_33_wic_1317.feed.pv								2, 3
Critical	Total Line4 Fresh Feed	c1_33_wic_1417.feed.pv								2, 3
Critical	Primary Collector Dosage to Ball Mill 3	c1_39_fic_0123.dosif.pv						3		1, 2, 3
Critical	% Solids mill virtual discharge L4	c1_33_sol_l4_v.descmill.pv								2, 3
Critical	pH Ball Mill # 2 Cyclone Overflow Sampler	c1_33_aic_2402.daca.pv								2, 3
Critical	Total Line2 Fresh Feed	c1_33_wic_1217.feed.pv								2, 3
Very High	Primary Collector Dosage to Ball Mill 1	c1_39_fic_0121.dosif.pv						3		1, 2, 3
Very High	Ball Mill # 1 Power	c1_33_jic_2363.numerica.pv								2, 3
Very High	pH Ball Mill # 1 Cyclone Overflow Sampler	c1_33_aic_2401.daca.pv								2, 3
High	Pressure Ball Mill # 2 Primary Cyclone Cluster	c1_33_pic_2709.daca.pv								2, 3
High	Ball Mill # 2 Power	c1_33_jic_2863.numerica.pv								2, 3
High	% Solids mill virtual discharge L2	c1_33_sol_l2_v.descmill.pv								2, 3
High	Flow Slurry Feed to Primary Cyclone Cluster CS-401	c1_33_fl_3621.daca.pv								2, 3
High	Feed Rougher Line 4 P80	c1_3330_az_301_rfeed_l4_p80.pv							90	2
High	Ball Mill # 4 Power	c1_33_jic_3863.numerica.pv								2, 4
High	Pressure Ball Mill # 4 Primary Cyclone Cluster	c1_33_pic_3709.daca.pv							3	2, 3
Moderate	Concent. Scavenger Line 3 %Cu	c1_3410_az_304_scvconc_l3_cu								2
Moderate	Concent. Rougher Line 3 %Cu	c1_3410_az_304_roconc_l3_cu								2

Gráfica 2 Interfaz del módulo de detección de anomalías.



### Interfaz de usuario para la revisión de recomendaciones generadas por la IA.



Gráfica 13 Interfaz de usuario