

Incremento de Producción Metálica en Planta Concentradora Mediante la Implementación de Machine Learning en Antamina

Hernando Valdivia Lozada¹, Hector Paredes Chirinos², David Estrella³, Alexander Alvarez⁴

¹ Superintendente de Metalurgia - Compañía Minera Antamina, (hvaldivia@antamina.com), Perú.

² Superintendente de Control de Procesos - Compañía Minera Antamina, (heparedes@antamina.com), Perú.

³ Gerente de Concentradora - Compañía Minera Antamina, (destrella@antamina.com), Perú.

⁴ Ingeniero de Analítica Machine Learning - Compañía Minera Antamina, (aalvarezs@antamina.com), Perú.

Palabras clave: Machine Learning, yacimiento skarn polimetálico, agilidad, incremento de producción metálica.

Resumen

En Compañía Minera Antamina; como parte de la constante innovación tecnológica en su Concentradora de minerales polimetálicos, se ha hecho uso de Analítica Avanzada de Datos, mediante la aplicación de Machine Learning, con el objetivo de incrementar su producción metálica de cobre equivalente, generando modelos articulados que maximizan el tonelaje procesado en Molienda SAG, así como incrementan la recuperación metálica en Flotación de cobre y Flotación de zinc, sin afectar la capacidad del proceso ni las calidades de concentrados a producir.

El trabajo inicial de 04 meses se enfocó en el análisis y conocimiento del proceso, planeamiento de estrategias, gobernanza de información, talleres de ideación, aplicación de metodología “agile”, análisis exhaustivo de variables con directa influencia en la producción, determinando la real capacidad de los equipos en la operación, estableciendo cuellos de botella, oportunidades de mejora y en paralelo se generó la arquitectura de datos en la nube.

A partir de agosto del 2021, logramos desplegar los modelos de Machine Learning, con el involucramiento de áreas como Geología, Planeamiento y Operaciones Mina, Mantenimiento Concentradora, Operaciones Concentradora, Control de Procesos, Tecnología de la Información, Analistas Six Sigma y el equipo de Metalurgia, con el soporte de una consultora internacional y la formación del equipo de trabajo multidisciplinario “MAYTA” (palabra quechua que significa “UNO SOLO”).

El beneficio real obtenido alcanzó 3.7% de incremento de Cu equivalente, sobre la línea base planteada, gracias a la implementación de las recomendaciones planteadas por los modelos y evaluadas por el equipo operativo.

1 Introducción

1.1 Visión general de Antamina

Compañía Minera Antamina SA, opera el más grande yacimiento polimetálico a nivel mundial, la Figura 1 muestra su ubicación en la parte Central de la Cordillera de los Andes del Perú, en el departamento de Ancash, Provincia de Huarí, Distrito de San Marcos a 270 Km al norte de Lima.

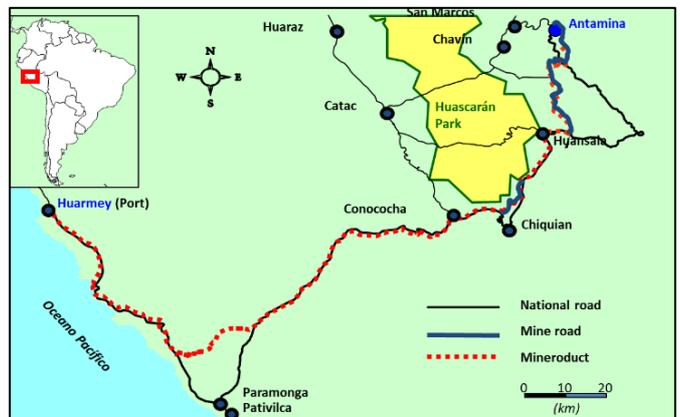


Figura 1: Ubicación del yacimiento de Antamina

La mineralización se encuentra emplazada en el complejo yacimiento tipo Skarn; de aproximadamente 3 Km de longitud, 1.5 Km de ancho y aproximadamente 2.0 Km de profundidad mostrado en la Figura 2.



Figura 2: Yacimiento Antamina

Antamina procesa diferentes tipos de mineral en campañas presupuestadas de acuerdo con nuestros compromisos de venta de concentrados; las cuales en principio se diferencian por los contenidos de Cu, Zn y los contenidos de Bi analizados en los concentrados de cobre obtenidos. La complejidad de nuestro skarn se manifiesta en alta variabilidad litológica y de mineralización, lo cual nos plantea oportunidades de mejora-optimización del procesamiento, para cada uno de los tres tipos de mineral procesados en el presente tiempo Tabla 01, los cuales están denominados como Mineral M1, Mineral M2A y Mineral M4B.

Tipo	Mineral	Característica	Concentrados
M1	Cu-Mo	Cu Bajo Bi	Cu y Mo
M2	Cu-Mo	Cu Alto Bi	Cu y Mo
M2A	Cu	Cu Muy Alto Bi	Cu
M4B	Cu-Zn-Pb	Cu Alto Bi	Cu, Zn, Pb/Bi
M5	Bornita Cu	Cu Muy Alto Bi	Cu
M6	Bornita Cu y Zn	Cu Muy Alto Bi	Cu y Zn

Tabla 1 : Tipos de mineral

El Skarn de Antamina se formó a partir de un pórfido complejo entre 11 a 10 millones de años intruído en las calizas y margas de las formaciones Jumasha y Celendin. De esta manera, en la Figuras 5 se muestra el yacimiento dividido en zonas definidas por su ubicación:

- Así tenemos la zona distal denominada exoskarn, caracterizada por la presencia de granates verdes (ganga) y mineralización de esfalerita (zinc) y calcopirita (cobre), con presencia de galena (plomo) y contenidos de plata; en esta zona se emplaza la mineralización M4B, de la cual recuperamos concentrados de cobre de moderado contenido de bismuto, zinc y plomo como subproducto. Figura 3
- Una zona definida como mineral de bornita M5 y bornita M6, resulta del emplazamiento de mineral de cobre bornita en gangas de

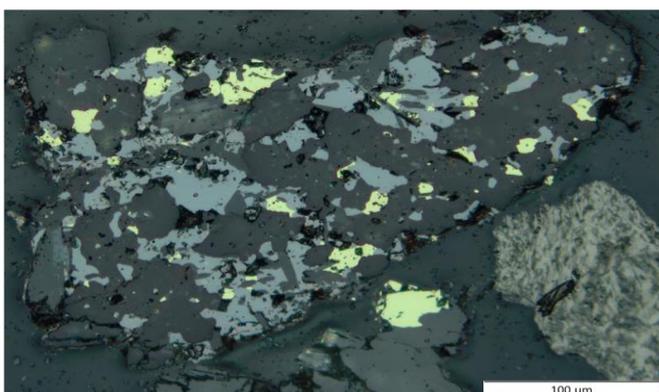


Figura 3: Exoskarn-M4B

wollastonita también en una zona focalizada de transición del exoskarn al endoskarn.

Los concentrados obtenidos son de cobre-bornita con muy alto bismuto, sin subproductos; mientras que el mineral tipo M6 en adición se obtiene concentrado de zinc.

- La otra zona contigua es una transición entre el exoskarn y el endoskarn denominada M2A, esta zona se emplaza en granates verdes, granates café-verde, así como en granates rosa, la mineralización principal es calcopirita (cobre) con muy bajos contenidos de galena (plomo) y molibdenita (molibdeno), de este tipo de mineral se recupera solo concentrados de cobre con elevados contenidos de bismuto.
- La zona central denominada Endoskarn esta influenciada por el cuerpo central donde predomina el intrusivo (ganga) además en sus periferias se tienen gangas como granates marrones y granates rosa, la mineralización es principalmente de calcopirita (cobre) y molibdenita (molibdeno), esta mineralización denominada M1 y M2 permite obtener concentrados de cobre de bajo contenido de bismuto y subproducto de concentrado de molibdeno. Figura 4
- La metodología de producción, considera campañas de procesamiento de minerales que obedecen a diferentes esquemas operativos tanto en el tamaño de partícula como en la dosificación de reactivos, los cuales no solo se orientan a maximizar el tonelaje y recuperación de valiosos; sino que también deben cumplir con restricciones de calidad de concentrados y tamaños de partícula máximo en concentrados para no afectar su transporte por el Concentraducto de 304 Km hasta nuestras instalaciones en Puerto Punta Lobitos, donde se filtran y embarcan; además se segregan por sus calidades para luego realizar blending adecuado y cumplir con las calidades comerciales presupuestadas el año previo.

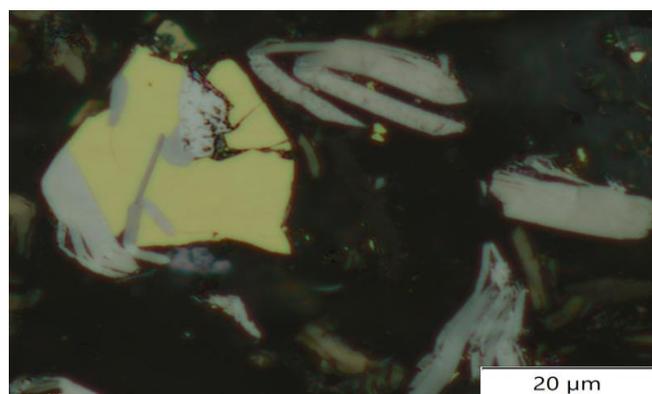


Figura 4 : Endoskarn-M1

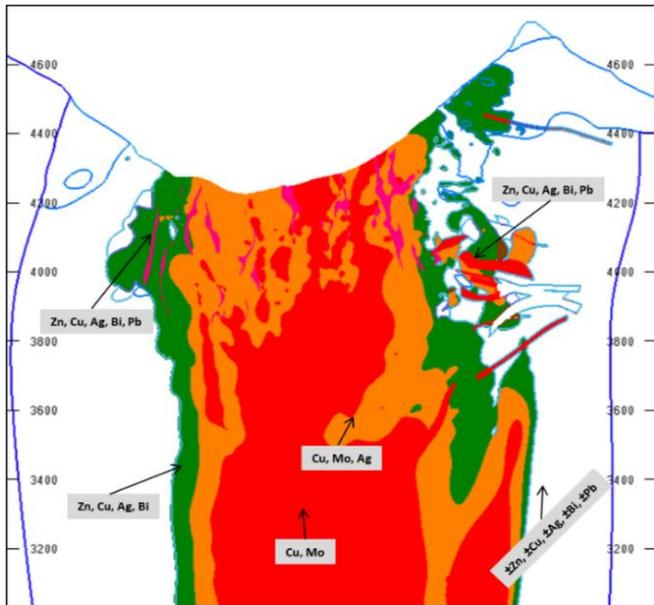


Figura 5 Skarn Antamina Corte Transversal

1.2 Definición de la Oportunidad de Mejora:

Antamina; desde que inició sus operaciones en el año 2001, está optimizando la concentración y calidad de sus concentrados, acorde a los requerimientos de sus clientes y las exigencias operativas; así, nombramos algunos parámetros de control en sus concentrados: el grado de cobre, adecuada predictibilidad de los contenidos de bismuto, límites máximos zinc en concentrado de cobre y cobre en concentrado de zinc, así como la granulometría de concentrados de cobre y zinc para asegurar un adecuado transporte.

Si bien los resultados metalúrgicos anuales presentan buen desempeño en cuanto a tonelaje procesado y recuperaciones de cobre y zinc, las exigencias y preparación para escenarios complejos en los años venideros nos plantea la necesidad de optimizar nuestra producción metálica y nada mejor que iniciar el proceso de transformación digital, haciendo uso de Analítica Avanzada de Datos en Planta Concentradora, como cimiento para mayores implementaciones en diferentes procesos de la compañía.

Aunque la definición de las zonas del yacimiento y el procesamiento en campañas de mineral podría considerarse eficaces; lo cierto es que día a día debemos enfrentarnos a la “variabilidad” puesta de manifiesto en variabilidad de leyes de cobre, zinc en el mineral alimentado en planta, pero por sobre todo variabilidad en la litología y contenidos de hierro, ya que el abastecimiento de planta requiere al menos de 2 o 3 frentes de minado, lo cual hace complejo el

procesamiento, tanto a nivel de tonelaje que pueden procesar los molinos, como recuperaciones en los circuitos de flotación, en las Figuras 6 y 7 se evidencia la gran variabilidad en las leyes de alimentación a planta.

Aquí radica la oportunidad de eliminar pérdidas potenciales y generar beneficios, realizando un adecuado análisis de oportunidades en capacidad de procesamiento máximo en planta, análisis estadísticos para predecir las principales variables influyentes en la máxima recuperación de metales equivalentes y la formulación de modelos matemáticos prescriptivos que brinden soporte a la operación, formulando recomendaciones de ejecución de variables en los rangos óptimos que permitirán aplacar la variabilidad del mineral procesado. Es importante considerar el enfoque geometalúrgico de interacción de variables litológicas, mineralización y procesamiento en Planta, bajo criterios y expertise adquirido por los procesistas en los años de operación del yacimiento skarn.

Para ello el planteamiento se enfoca a analizar cientos de variables operativas en planta, litologías y mineralización asociada, frentes de minado, velocidades de perforación en polígonos de mineral, conformación de stockpiles en mina y formular modelos de analítica avanzada que reproduzcan los mejores comportamientos alineados al tipo de mineral procesado, sin descuidar las restricciones propias del

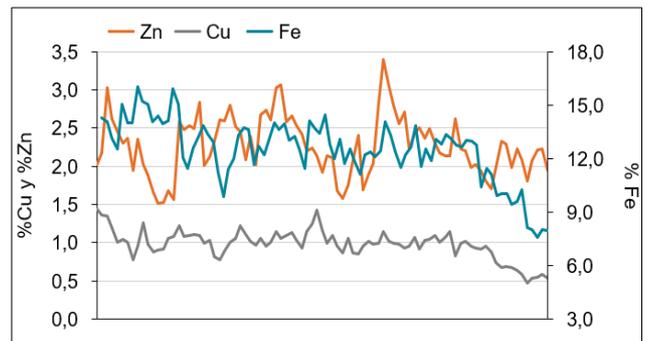


Figura 6: Variabilidad de leyes de alimentación Cu-Mo M1

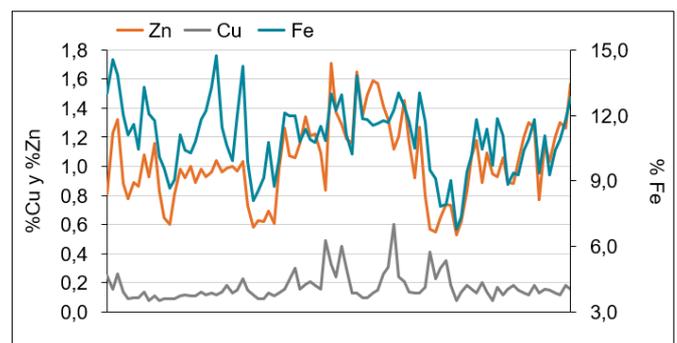


Figura 7: Variabilidad de leyes de alimentación Cu-Zn M4B proceso ni de los compromisos adquiridos.

Para tal efecto planteamos el uso de Machine Learning aplicado a Molienda SAG-Bolas (Figura 8) y Flotación de Cobre y Zinc, como la apuesta para optimizar y digitalizar nuestros procesos.



Figura 8: Circuito de molienda

2 Visión general de Analítica Avanzada de Datos

La Analítica Avanzada de Datos puede ser definida como el análisis autónomo o semiautónomo de datos, utilizando técnicas y herramientas sofisticadas, generalmente más allá de las tradicionales de inteligencia comercial (Business Intelligence), para descubrir información más profunda, hacer predicciones o generar recomendaciones.

Las principales técnicas de analítica avanzada incluyen aquellas como la minería de datos, aprendizaje automático (Machine Learning), pronósticos, análisis semántico, análisis clústeres, simulación y redes neuronales.

A continuación, se mencionan los tres principales tipos de analítica, considerando a las dos últimas dentro de analítica avanzada.

- a) Analítica Descriptiva: Es útil para entender qué sucedió en el pasado y tener una visión de los datos históricos.
- b) Analítica Predictiva: Con base en la data histórica se buscan patrones para predecir eventos futuros.
- c) Analítica Prescriptiva: Con base en el análisis de datos históricos y la identificación de patrones se busca recomendar acciones para optimizar los resultados futuros.

2.1 Oportunidades de la analítica avanzada en la minería

Una de las principales características de la industria minera es la alta inversión de capital; por esta razón generar mejoras en la productividad representa un alto impacto económico, atenuando los gastos incurridos. Bajo esa premisa, la analítica avanzada puede generar valor significativo al optimizar los procesos, reducir tiempos por detenciones y fortalecer la toma de decisiones, entre otros.

El uso de la analítica puede generar impacto a lo largo de la cadena de valor en minería, iniciando desde los procesos de exploración, pasando por planta de procesamiento, mantenibilidad y hasta el embarque y comercialización del concentrado. Así, podemos citar oportunidades en: optimización de la producción, predicción y reducción de costos, y seguridad.

2.1.1 Optimización de la producción

Algunos ejemplos aplicativos; durante la exploración, se busca mayor eficiencia mediante la elaboración de modelos geológicos basados en aprendizaje automático. En el proceso de perforación se genera valor al predecir la composición geológica y litológica, de igual manera, mediante análisis predictivo es posible la optimización de los parámetros de la malla de voladura.

Otro foco principal de la cadena de valor es la concentración de mineral en la planta de procesamiento, donde mediante modelos prescriptivos es posible optimizar los parámetros de molienda y flotación, reduciendo la variabilidad de procesos lo cual se logra materializar en mayor volumen y mejor calidad de los concentrados producidos.

2.1.2 Predicción y reducción de costos

Referenciando al combustible y neumáticos; como los principales costos operacionales en el minado, la analítica puede generar modelos de optimización del consumo de combustible, mediante la identificación de parámetros de conducción, análisis del consumo en tramos de las vías y efectivizar la rotación de neumáticos.

El mantenimiento predictivo y cuidado del equipo puede ser fortalecido, mediante un monitoreo de condiciones más exhaustivas basándonos en los datos históricos de sus parámetros.

2.2 Seguridad

Un pilar fundamental del trabajo en el sector minero es la seguridad industrial, la analítica también brinda oportunidades al formular modelos predictivos enfocados a evitar accidentes y lesiones. El uso de video analítica puede también contribuir a identificar posibles situaciones de riesgos y generar alertas.

Como pudimos apreciar, se puede generar distintas aplicaciones de la analítica avanzada a lo largo de la cadena de valor en minería, cada empresa minera tiene la facultad y necesidad de analizar sus cuellos de botella o principales restricciones para decidir la aplicación de analítica; de esta forma, en alguna de ellas se generará mayor beneficio por efecto del enfoque brindado a proyectos de optimización; tipo voladura o acarreo, mientras que en otras también podríamos mejorar los procesos de molienda y flotación.

3 Machine Learning en Antamina

El proyecto nace bajo el objetivo principal de incrementar la producción metálica de la Planta Concentradora mediante el uso de herramientas de Analítica Avanzada, en específico, la aplicación de Machine Learning. Proyectando un incremento sostenible de producción metálica de Cobre y Zinc, equivalente a 5% entre los minerales M4B, M2A y M1, sobre una línea base predefinida.

La tecnología implementada consiste en modelos de Machine Learning que generan recomendaciones a la

supervisión y a operadores para optimizar los resultados de su turno.

Un algoritmo predice el rendimiento de molienda y flotación con alta precisión para las siguientes cuatro horas, genera millones de escenarios posibles de parámetros operativos y recomienda valores óptimos para cada variable (por ejemplo, velocidad del SAG, dosificación de PAX, etc.) para maximizar la generación de cobre fino.

Las recomendaciones son implementadas por el equipo de operaciones quienes revisan y deciden las prioridades de acción. Si se da el caso que una recomendación no es aceptada, se envía el feedback al equipo de datos para realizar los ajustes en los modelos. De esta manera, la generación de recomendaciones, su aceptación o rechazo y ajuste a los modelos forman parte de un proceso iterativo y de mejora continua

El desarrollo de analítica avanzada en Antamina se ubica como el primer referente a nivel mundial en implementar exitosamente Machine Learning en un yacimiento polimetálico tipo skarn de grandes dimensiones, generando modelos de uso simultáneo en Molienda SAG, Flotación de Cobre y Flotación de Zinc, para incrementar la producción metálica en planta.

El desarrollo del proyecto se ha dado en cuatro fases principales que se pueden ver detalla en la figura 9.

En el avance del presente documento, se irá profundizando en cada una de las fases del desarrollo del proyecto de analítica en Antamina.



Figura 9 Fases de la Implementación de Machine

3.1 Preparación: Habilitadores para una implementación exitosa de Machine Learning

Los proyectos de Analítica Avanzada requieren que una organización esté preparada para generar un ambiente nuevo de trabajo que asegure una implementación exitosa, existen habilitadores necesarios para iniciar un proyecto de este tipo, en la experiencia de Antamina se pueden resaltar los dos siguientes:

3.1.1 La creación de células de trabajo ágil:

Para una implementación de Machine Learning es necesario adoptar una nueva forma de trabajo enfocada en iterar de manera constante durante el desarrollo del proyecto y generar un feedback continuo del área usuaria.

La mentalidad ágil del equipo debe asegurar un desarrollo adaptativo mediante Productos Mínimos Viables (MVPs) que puedan ir entregándose de manera constante con el objetivo de capturar valor de manera acumulativa.

Bajo este enfoque de nueva forma de trabajo, la célula ágil “Mayta” de Antamina tiene los roles detallados en la Figura 10, cada uno con un objetivo específico:

Agenda de trabajo

El equipo Mayta despliega su trabajo siguiendo las diferentes sesiones y ceremonias de trabajo bajo el enfoque de agilidad.

- Reuniones diarias de seguimiento de estatus al inicio del día (Check-in)
- Sesiones de Problem Solving – Equipo DS (2 veces por semana)
- Sesiones de Problem Solving de Modelos para Mejora Continua (3 veces por semana)
- Seguimiento diario de implementación de recomendaciones en Planta.
- Reuniones diarias con Operaciones (2 veces al día) para recopilar feedback del turno

3.1.2 Arquitectura cloud de datos

La arquitectura de datos y la analítica avanzada se comportan como dos caras de una misma moneda, dado que para generar modelos predictivos y generar recomendaciones se debe recibir y recopilar los datos con rapidez a lo largo de las distintas fuentes

La arquitectura brinda la capacidad de integrar sin problemas datos de diferentes fuentes, ya sea en archivos, bases de datos o servidores/nubes, pero también brinda la posibilidad de elaborar estos datos, ya que la preparación de datos (limpieza, ingeniería de características) representa entre el 70 % y el 80 % del tiempo en un proyecto de analítica avanzada.

En Antamina, se ha diseñado y desarrollado una nueva arquitectura cloud, logrando llevar la data de PI System al “data lake” y esto permite acceder a la información en tiempo real (incluyendo datos de geología y dispatch).



Figura 10: Célula ágil de Antamina

A nivel técnico, se utilizan las plataformas de Amazon Web Services(AWS) y DataBricks, las fuentes de datos se consumen por procesamiento en tiempo real y en batch

Características de la arquitectura implementada

- Escalabilidad: Aprovechando el computo en la nube, escala de forma automática.
- Mantenibilidad Infraestructura: El mantenimiento de los servicios es cargado por el Cloud Provider y sin sobrecarga en costos.
- Costo: Flexibilidad en costos desde pago por uso hasta servicios pagados mensualmente
- Configuración y aprovisionamiento: Flexible en habilitar servicios SaaS, IaaS, PaaS y alta integración entre servicios, permitiendo hacer frente a las crecientes necesidades de almacenamiento y computación.

4 Validación y Desarrollo:

4.1 Análisis de Máxima Capacidad del Proceso

Generar la oportunidad de maximizar la captura de valor se cimienta en un detallado análisis estadístico histórico-reciente de las variables operativas que influyen determinada etapa dentro del proceso productivo, bajo esta perspectiva analizamos los máximos obtenidos respecto a los promedios, generando rangos percentiles alcanzables bajo una adecuada operación y sinergia de variables.

Este análisis debe ir de la mano de talleres, con actores multidisciplinares que sustentan y/o restringen

los valores máximos inferidos. Este alineamiento es fundamental para proyectar metas realistas y a la vez, retadoras.

Con el objetivo de identificar el potencial de mejora en los procesos donde se maximizaría el impacto, se ha llevado a cabo diversos análisis y el enfoque ha sido en tres categorías:

- Throughput cobre:
 - Análisis de cuellos de botella
 - Análisis de frontera de TPH potencial
 - Análisis de Power Load
 - Análisis Weibull

Por ejemplo, en la Figura 11 muestra que el SAG 1 tiene una oportunidad teórica de ~11% llevando el promedio actual al percentil 65 (P65) de turnos pasados.

- Recuperación cobre
 - Prueba de flotación por granulometría en laboratorio
 - Liberación en colas de Cu.
 - Análisis de tiempo de residencia (TPH y recuperación Cu)
 - P80 – recuperación cobre
 - Ph y ORP
 - Colectores y reactivos, Mass pull
 - Circuito de limpieza, Sólidos
- Recuperación zinc
 - Análisis de liberación en colas Zinc
 - Análisis de tiempo de residencia (TPH y recuperación de Zn)
 - CuSO₄/ ley de cabeza

- S
IPX/ ley de cabeza

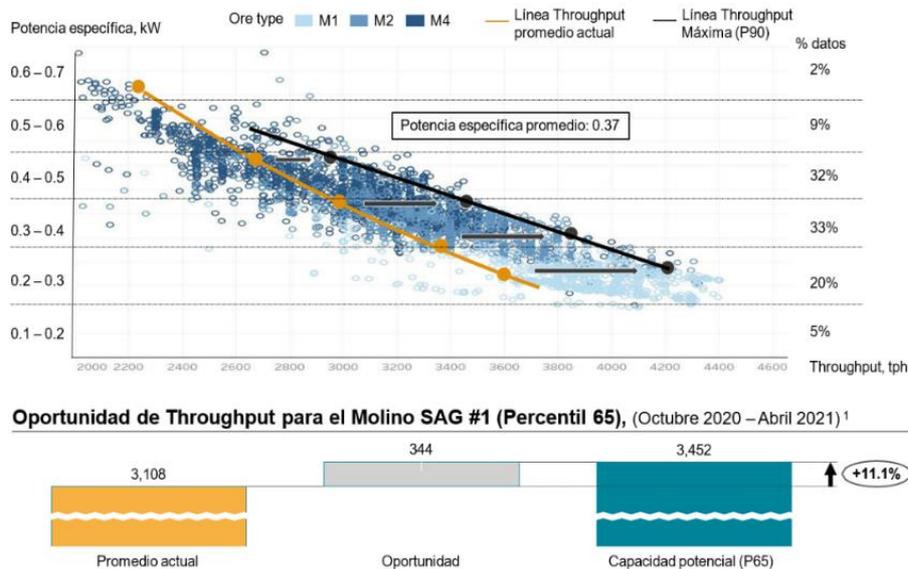


Figura 11: Análisis de frontera potencial SAG1

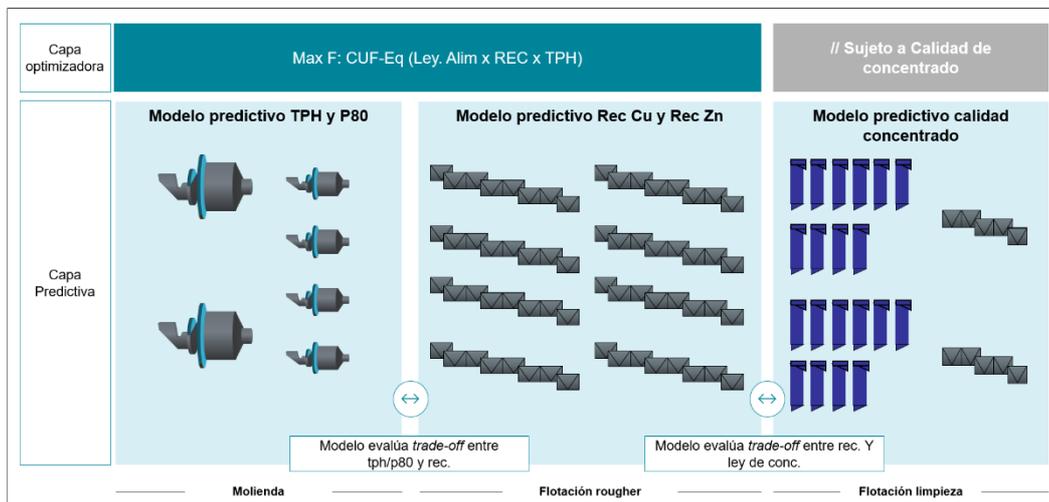


Figura 12: Modelos de predicción y optimización

Después de realizar diversos análisis teóricos y operacionales de los procesos, se han identificado un incremento potencial de 5% en la producción metálica de la planta considerando las tres campañas de mineral M1, M2A y M4B.

4.2 Modelamiento de la planta

Una vez definidos los rangos de máxima capacidad factibles de alcanzar, el planteamiento de modelos debe pasar por la interacción de cientos de variables influyentes; pero se genera la pregunta ¿quién define qué variables son las más pertinentes? Así, luego del trabajo de los científicos de datos que modelarán las variables de mayor significancia relacionadas con una alta productividad, es fundamental generar los talleres multidisciplinares que involucren a los principales actores del proceso en Planta, tales como mantenedores, instrumentistas, controladores de procesos, metalurgistas y supervisión de operaciones, con la finalidad de analizar los límites factibles de los modelos y que estos se desarrollen en un espectro realista, sin afectar los activos del proceso ni trasgredan las restricciones propias que nos plantea la comercialización y/o transporte de concentrados.

El proyecto de analítica está compuesto por modelos predictivos y una capa optimizadora de la producción de Cu fino equivalente Figura 12.

Se han desarrollado modelos de tonelaje y recuperación que interactúan entre sí para optimizar el metal producido en planta, así también, se tiene un condicionante que es la calidad de concentrado, para el cual se tiene un modelo predictivo que interactúa con los dos primeros.

En cada modelo existe una combinación de variables de contexto y control que serán las optimizadas.

4.2.1 Modelos de TPH:

Maximizar el tonelaje considerando la variabilidad litológica característica del yacimiento, resulta un reto complejo para mantener la sostenibilidad de los incrementos obtenidos, para ello en primer término es necesario “clusterizar” las litologías más representativas y/o agruparlas por características comunes; además es sumamente necesario considerar las restricciones de los equipos principales y los equipos o etapas posteriores.

Es importante considerar que maximizar el tonelaje tiene efectos en menores recuperaciones de metales aguas abajo, lo cual obliga a buscar un equilibrio.

Dadas las características del yacimiento de Antamina se realizó el modelamiento por cada molino SAG y tipo de campaña (M1, M2A y M4B)

Las principales variables de control que se han considerado son: velocidades de los molinos y el porcentaje de sólidos. Posteriormente se han agregado la velocidad media de molino de bolas y ratios de velocidad de los feeders.

Así mismo, se han incorporado en los modelos variables de mina, como la velocidad de perforación. Y por el lado de litología algunas variables como el contenido de Wollastonita y Exoskarn y otras litologías en el mineral alimentado a planta.

- Comparar dosificaciones de reactivos tanto en [g/t] como en [g/t%ley], permite que el modelo discrimine la dependencia más fuerte

Características importantes de la ingeniería de variables

- Dependiendo de la campaña de mineral es frecuente la producción de pebbles en planta, motivo por el cual es una característica importante para evaluar el estado de la producción de *pebbles* de ambos molinos y el porcentaje de recirculación hacia los SAGs
- Se desarrollan variables acumuladas de tiempo y toneladas desde el cambio de liner para dar importancia a los periodos de *ramp-up* de los modelos. Actualmente se ha dejado su uso por cambio de ángulo y comportamiento de liners

4.2.2 Modelos de flotación:

El desarrollo ha estado enfocado en los controles de las celdas Rougher de Cu y Zn, circuitos de limpieza y dosificación de reactivos.

Basados en una operación similar de las líneas de flotación, se consideró a una de ellas como representante del circuito.

Se han considerado variables de hidrociclones, otro como la velocidad, potencia, nivel de cajones y del mismo modo que en molienda se detectó la importancia de la litología en los modelos: Wollastonita, Hornfels, Exoskarn

Para construir la función objetivo de optimización, se utiliza un factor de conversión Zn->Cu, de manera de trabajar con Cu fino equivalente

Características importantes de la ingeniería de variables

- Las dosificaciones de un reactivo en distintos puntos de la planta pueden estar altamente correlacionadas lo cual genera la necesidad de crear variables agregadas.
- Para crear variables de aire de celdas es importante capturar el perfil por línea (deltas/promedio) para generar variables adicionales

Variables operativas en los modelos y la importancia de los controles

La importancia e impacto que las variables toman en los modelos; entre ellas controles, depende del entrenamiento, es por ello que diferentes versiones de un mismo modelo presentan comportamientos y desempeños diferentes. Una manera de caracterizar cada modelo y de entender el comportamiento que tendrá, es mediante los gráficos SHAP que muestran los posibles impactos en términos de target (tonelaje o recuperación) que posee cada variable.

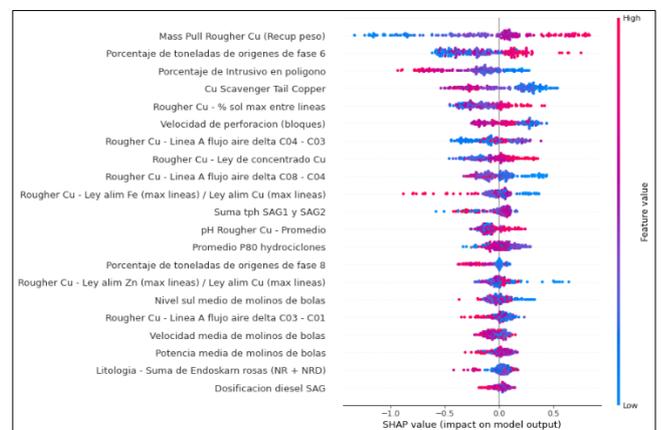


Figura 13: Shap Values para el modelo de recuperación M1

En la Figura 13, mientras más impacto tengan los controles (por lo tanto, mientras más alta su ubicación), mayor será el poder de optimización del modelo.

Otra información para complementar los SHAP, se encuentra en los gráficos PDP. Estos gráficos se evalúan para cada variable y muestran el valor en SHAP que tendrá dependiendo de los valores que tome, eso se puede visualizar en la Figura 14.

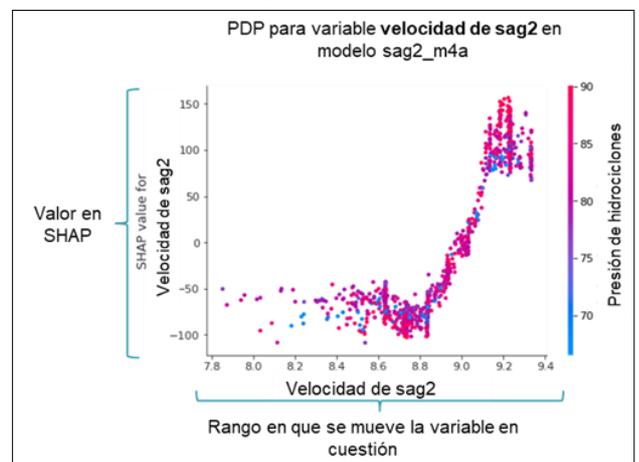


Figura 14 Gráficos PDP para SAG2

En conjunto la información de los SHAP y PDP permitirán entender para cada modelo en particular la importancia que tendrán los controles para las predicciones.

4.3 Generación de recomendaciones

Con los modelos entrenados mediante data histórica se captura el comportamiento de la planta y, mediante el uso de variables tanto del turno anterior como las actuales, se generará una predicción de los resultados de la operación de TPH y recuperación para cada periodo de 4 horas.

El siguiente paso es iterar, moviendo los controles de los modelos correspondientes de cada campaña y mediante las predicciones generadas logramos

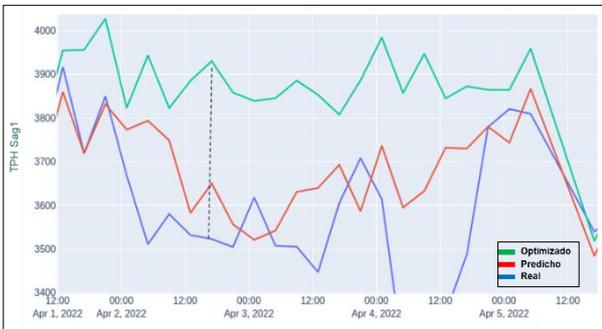


Figura 15 Comportamiento de las variables y modelos

encontrar el escenario que maximiza las toneladas de cobre fino. Los controles obtenidos de la optimización, corresponden a las recomendaciones realizadas. Se puede observar el detalle en la Figura 15

- El valor real corresponde al valor promedio de 4 horas que se obtiene a posteriori, cuando ya fue operado.
- El valor predicho corresponde al valor que el modelo predice para las próximas 4 horas de operación en base a las variables de entrada.
- E
- I

valor optimizado corresponde al valor predicho, pero con los controles en valores óptimos, por lo tanto, lo que se recomendará.

5 Implementación del proyecto

Las recomendaciones entregadas por el modelo de Machine Learning son mostradas en un Dashboard disponible en las pantallas de sala de control. En la Figura 16 y 17 se muestra la interfase.

El equipo de operaciones podrá aceptar y rechazar recomendaciones a través del Dashboard, posteriormente el equipo de datos realiza una revisión frecuente para establecer cambios que puedan incrementar el nivel de ajuste de los modelos.

Involucrando a cada uno de los actores principales del equipo se ha desarrollado un procedimiento operativo para la aceptación de las recomendaciones en la sala de control, detalle en la Figura 18.

5.1 Principales KPIs de implementación

Para asegurar un proceso exitoso se han definido KPIs de seguimiento que brinden información sobre el desempeño del proceso.

A continuación, se describen los principales indicadores que fueron utilizados.

- Disponibilidad de los modelos: porcentaje de tiempo que los modelos dan recomendaciones.
- Recomendación: El porcentaje de las recomendaciones generadas son realmente contestadas.

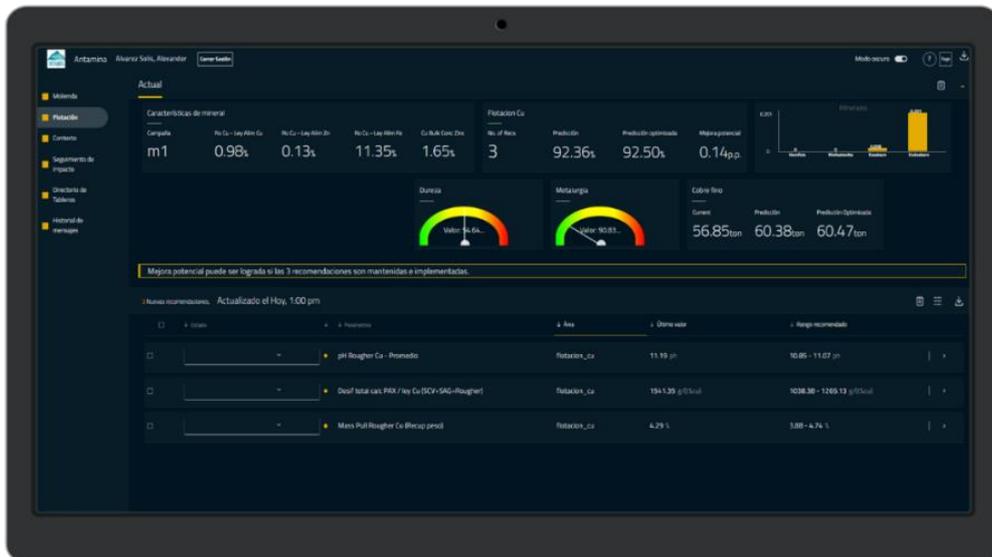


Figura 16: Dashboard de recomendaciones



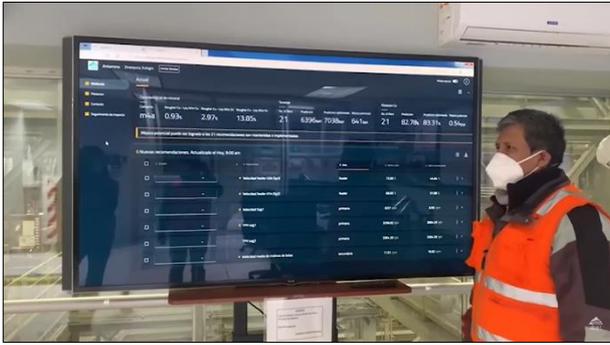


Figura 17: Dashboard implementado en Sala de Control

- Aceptación de recomendaciones: qué porcentaje de las recomendaciones vistas han sido aceptadas. Se mide a través del Dashboard automático con las respuestas enviadas.
- Implementación: qué porcentaje de las recomendaciones aceptadas / rechazadas finalmente han sido implementadas. Se realiza una medición con datos reales de variables en rango óptimo sugerido por modelos

6 Resultados:

La captura de valor en el despliegue de Machine Learning, fue validada estadísticamente al 95% de confianza, comparando los incrementos obtenidos sobre las líneas base, para los tiempos específicos de implementación de las recomendaciones planteadas por los modelos.

Consideremos el siguiente diagrama de proceso para estimar el impacto en dos rubros de incrementos en TPH y porcentajes de recuperación:

6.1 Impactos en TPH

Las variaciones en el tonelaje dependen de los siguientes factores:

- Características del equipo (capacidad y restricciones):
No lo controlamos, por lo que definimos líneas base (LB) por SAG (01 y 02).
- Características del mineral:
No lo controlamos, definimos LB por M2A/M4B y clasificación Duro/Blando (clusterización).
- Parámetros de operación:
Sí lo controlamos: RPM, % Sólidos, etc. los cuales son recomendadas por el Machine Learning (ML)

Se definieron 8 líneas base TPH (clusters) detallado en las Figuras 19 que nos permiten comparar antes y después de la implementación del Machine Learning tanto por molino SAG como por tipo de mineral y clasificación de dureza.

Porqué se utilizaron clusters

a) Tipo de yacimiento.

Antamina al ser skarn polimetálico, tiene alta variabilidad en sus características, incluso dentro de un mismo tipo de material.

b) Proporción de material duro/blando.

El material que alimenta a planta, dependiendo del periodo, puede tener mayor proporción de mineral duro o blando, lo que podría alterar los resultados.

c) Clasificación.

Para clusterizar el blending de mineral que llega a planta entre duro y blando, se tomaron datos de

M4B Duro	M2A Duro	M4B Blando	M2A Blando
		SAG 1	
		SAG 2	
M2A Duro	M4B Duro	M2A Blando	M4B Blando

Figura 19: Cluster de mineral para molienda

mina, geología, planta concentradora, etc. Cada Cluster representa rangos de parámetros característicos a una determinada respuesta en el tonelaje.

6.2 Impactos en recuperación

Los impactos en recuperación comparan la variación de resultados reales respecto al proyectado Figura 20

Para tener la proyección de recuperación, se utilizan modelos de regresión debido a la alta sensibilidad de resultados frente a leyes de cabeza y otras variables, por ejemplo:

- Rougher Cu - Promedio ORP líneas
- Rougher Cu - Ley alim Cu max entre líneas
- Rougher Cu - Ley alim Zn max entre líneas
- Suma tph SAG1 y SAG2
- Ratio Cu/Zn en la alimentación a planta

- Concentración Mo ponderado según toneladas por polígono
- Velocidad de perforación (dureza mineral)

a) Estimación del impacto en términos de cobre equivalente

En la Figura 21, se detalla la medición validada del impacto acumulado.

Figura 21: Impacto acumulado

La proporción de material considerada para el promedio ponderado es 45% de M4B, 15% de M2A y 40% de M1, con 55% de peso para SAG1 y 45% para el SAG2.

Así a detalle, se muestra un impacto sostenido en el SAG1, y con oportunidades de mejora en el SAG2, para campañas de M4B. Y se ha mantenido un impacto positivo para recuperación Cu, tanto para M4B y M2A con márgenes para optimizar.

Finalmente, el impacto en cobre equivalente (Cu Eq.) correspondiente al periodo agosto 2021 – febrero 2022 alcanzó 3.7% en incremento de producción, el cual

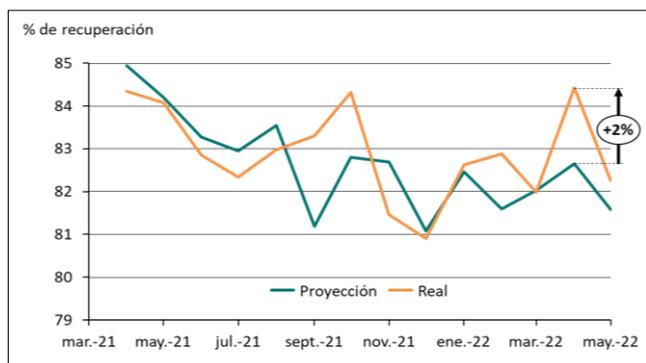


Figura 20: Impacto en la recuperación

detalla en la Figura 22.

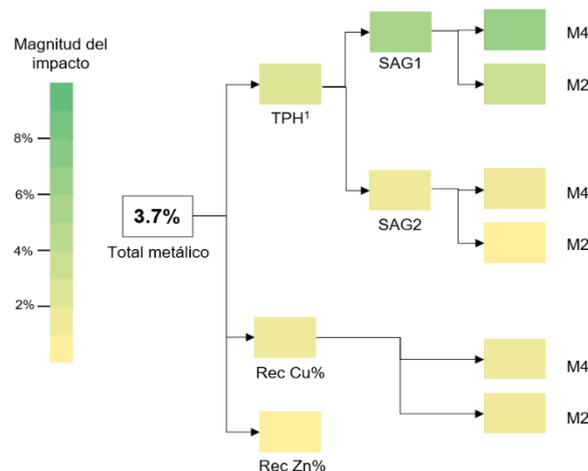
7 Conclusiones:

Luego de completar la implementación y puesta en productivo de los modelos de Molienda SAG y Flotación Cobre y Zinc; compartimos las siguientes conclusiones:

1. Si bien la gran variabilidad de un yacimiento skarn polimetálico como Antamina representa un gran reto para su optimización, el uso de Analítica Avanzada de Datos mediante técnicas de Machine Learning, con base en la data histórica, se logró segregarse e identificar las mejores prácticas realizadas por los operadores y supervisores para generar modelos prescriptivos que fueron el

soporte en la optimización de resultados metalúrgicos.

2. Con base en la experiencia de Antamina, un requerimiento fundamental para tener éxito en la implementación de un proyecto de analítica avanzada es realizar un diagnóstico sobre la calidad de datos y nivel de sensorización con el objetivo de



generar modelos robustos capaces de predecir, seguir y optimizar las condiciones operativas.

3. Se ha validado que la tecnología de analítica avanzada es una herramienta que potencia las capacidades de los operadores de planta, no busca reemplazar a los trabajadores, muy por el contrario, es un aliado que ayuda a desempeñar una labor más eficiente para maximizar sus resultados capturando lo mejor de sus múltiples experiencias en el procesamiento de minerales;

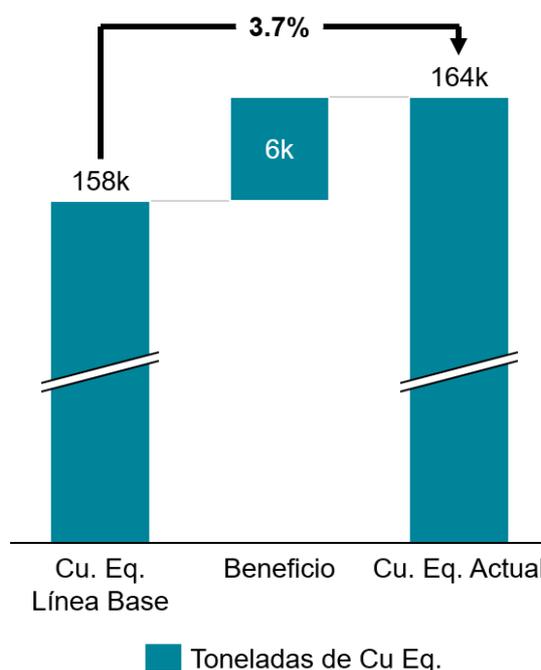


Figura 22 Impacto total en términos de Cu equivalente

sobre todo en los más complejos.

4. Demostramos la validez de la metodología Ágil para analizar, desarrollar e implementar modelos prescriptivos exitosos en molienda y flotación polimetálica compleja, bajo un calendario perfectamente acotado.
5. Producto de la implementación, Compañía Minera Antamina, logro incrementar sostenidamente 3.7% su producción de Cu metálico equivalente sobre la línea base planteada. Para nuestros volúmenes productivos este incremento representa aproximadamente 5,900 toneladas adicionales de metal de Cu equivalente. Este incremento fue adherido al presupuesto de producción del 2022 y recurrente para los siguientes años.
6. A partir de abril de este año, el equipo MAYTA se encuentra a plena capacidad y autonomía, soportando y optimizando los modelos de Machine Learning, en esta etapa post implementación, planteando nuevas estrategias orientadas a maximizar la captura de valor en Molienda y sobre todo en el enfoque hacia recuperación de cobre y zinc.
7. La Analítica Avanzada de Datos es una herramienta fundamental para la optimización de los procesos y Compañía Minera Antamina se posiciona en la línea de la digitalización de sus operaciones dando este primer y fundamental paso para luego decantarlo a toda la compañía.

8 Agradecimientos

Agradecimiento al equipo multidisciplinario MAYTA, por su profesionalismo, a los equipos de Geología, Planeamiento y Operaciones Mina, Mantenimiento Concentradora, Operaciones Concentradora, Control de Procesos, Tecnología de la Información, Analistas SixSigma y el equipo de Metalurgia, por el continuo soporte para la implementación, sostenimiento, continuidad y optimización continua, realizando además funciones de auditoría interna para el correcto desempeño de los modelos.

Finalmente agradecer a los Gerentes de Concentradora y Tecnología de la Información por el apoyo constante, así como a Vicepresidencia de Operaciones por el respaldo para hacer realidad este exitoso proyecto, que compartimos con el público interesado en la innovación tecnológica en minería

9 Referencias:

- Global Mining Guidelines Group (GMG Group)**, 2019, Foundations of a framework for AI in mining, <https://gmgroup.org/foundations-of-ai-a-framework-for-ai-in-mining-published/>
- Atlassian**, 2019, The Agile Coach. <https://www.atlassian.com/agile>
- Compañía Minera Antamina**, Reportes Mensuales de Producción Concentradora. 2020-2021-2022
- Compañía Minera Antamina**, Budget de Producción Concentradora. 2020-2021-2022
- Compañía Minera Antamina**, Master de Embarques. 2020-2021-2022
- Compañía Minera Antamina**, Test Metalúrgicos con Minerales Complejos. 2020-2021-2022
- Compañía Minera Antamina**, Reportes Mineralógicos-Metalúrgicos. 2020-2021-2022
- Compañía Minera Antamina**, Reporte de Arquitectura de Dato Antamina, Gerencia de Sistemas, Control y Telecomunicaciones .de Antamina 2022