

Eder Lagos Leon<sup>1</sup>, Engels Trejo Pantoja<sup>2</sup>

<sup>1</sup> Hudbay Peru SAC, Provincia de Chumbivilcas, Cusco, Perú (eder.lagos@hudsonminerals.com)

<sup>2</sup> Hudbay Peru SAC, Provincia de Chumbivilcas, Cusco, Perú (engels.trejo@hudsonminerals.com)

## RESUMEN

Una caída de producción en la planta impacta directamente en las ventas y el flujo de caja de la compañía. El rendimiento de los molinos está en función a su disponibilidad mecánica y a las características físicas del mineral (leyes, dureza y tamaño de partícula) que se descarga en la chancadora. Las leyes y dureza son intrínsecas al depósito pero el tamaño de partícula se puede gestionar en la etapa de Perforación y Voladura. Si se conoce el tamaño de partícula después de la Voladura, así como su distribución de finos, se puede planificar una mezcla de mineral adecuada que mantenga un ritmo constante de los molinos y así asegurar la producción de concentrado.

Mina Constancia opera principalmente con minerales tipo hipógeno y skarn pero con una gama diversa de alteraciones (propílico, potásica, fílica, argílica y skarn). Además, se identificó que un porcentaje de finos <sup>1</sup> mayor a 45% logra que los molinos trabajen adecuadamente. La generación de finos se produce después de cada voladura y para ello se debe optimizar el factor de potencia (FP)<sup>2</sup> ya que influye directamente a la generación de finos (a un mayor FP mayor será el porcentaje de finos). Por ello conocer el FP óptimo permitirá ajustar el uso de explosivos por taladro y generará un % de finos adecuado que permita mantener el ritmo de producción de los molinos. Usualmente este tipo de análisis se realiza con data histórica pero podríamos incurrir en errores debido a la heterogeneidad del depósito que hace que el mineral cambie a medida que profundizamos o nos encontramos en zonas distales del yacimiento.

En la actualidad, la técnica del machine learning (ML) está siendo utilizada con éxito en diversas industrias y

poder aplicarla al sector minero nos permitirá tener información en tiempo real para poder tomar decisiones basadas en números. En mina Constancia hemos dado el primer paso y logramos obtener un software, con desarrolladores peruanos, que nos permite predecir el comportamiento de los molinos basados en variables de la mina (leyes, durezas, ratios, etc) que se encuentran en nuestras bases de datos y que se retroalimenta de forma continua. Esto nos permite generar modelos avanzados, y en tiempo real, de predicción del rendimiento de los molinos los cuales alimentan y robustecen los planes de minado diarios y además permiten que la supervisión pueda tomar decisiones en tiempo real y así anticipar caídas en producción.

Además, este primer paso nos da pie a seguir integrando otros procesos de la cadena de valor y finalmente lograr el gemelo digital de la mina en donde podamos evaluar y tomar decisiones de forma virtual para luego aplicarlas en la operación.

## 1. Introducción

Hudbay es una empresa con larga tradición minera y con más de 90 años de experiencia, hemos descubierto, construido, desarrollado, operado y cerrado exitosamente 26 minas en todo este tiempo. Mina Constancia es una operación de Hudbay localizada en la provincia de Chumbivilcas en la región Cusco y su producción comercial inició en el año 2015. Cuenta con una planta concentradora para el tratamiento de minerales de sulfuros primarios a una tasa de 3,800 toneladas por hora y además la operación minera trabaja con: tres palas hidráulicas de 45 toneladas por pase, un cargador frontal de 30 toneladas por pase y 25 camiones mineros de 240 toneladas.

Cabe indicar que, al momento, se está minando la fase 04 del tajo Constancia y la fase 01 del tajo Pampacancha los cuales en términos de mineralización poseen diferentes características ya que el tajo Constancia es un pórfido de material hipógeno - skarn, cuerpo mineralizado masivo de mediana a baja ley, y Pampacancha es un skarn, pequeño cuerpo

<sup>1</sup> Para este estudio se define como “finos” a las partículas que tienen un tamaño menor a 1 pulgada y que se generan después de una voladura.

<sup>2</sup> El factor de potencia o “FP” son los kilogramos de explosivos cargados en un taladro y que luego fragmentara 1 tonelada de material. Sus unidades son kg de explosivo entre tonelada de material roto.

mineralizado de mediana a alta ley. Finalmente los materiales de ambos tajos son enviados a los mismos componentes. El destino del desmante es el depósito de desmante “WRF” y los minerales comparten los stockpiles así como la chancadora primaria y molienda ya que son enviados para su beneficio en mezcla y en función a los requerimientos del presupuesto.

## 2. Trazabilidad del proceso “Drill to Mill”

### 2.1. “Drill to Mill”

El concepto “Mine to Mill”, como se le conoce, es una filosofía que las empresas mineras adoptan cada vez más y están comprometidas con aumentar su rentabilidad a través de una mejor integración y optimización global de sus operaciones de extracción y procesamiento.

Tanto las operaciones de extracción como las de procesamiento involucran una variedad de pasos, cada uno con sus propios atributos y requisitos para una eficiencia óptima. Sin embargo, en algunos casos las condiciones que se requieren para optimizar uno de estos pasos son contraproducentes para lograr la optimización en otro. Como resultado, es posible que una estrategia de optimización local de cada paso no logre el mejor rendimiento general.

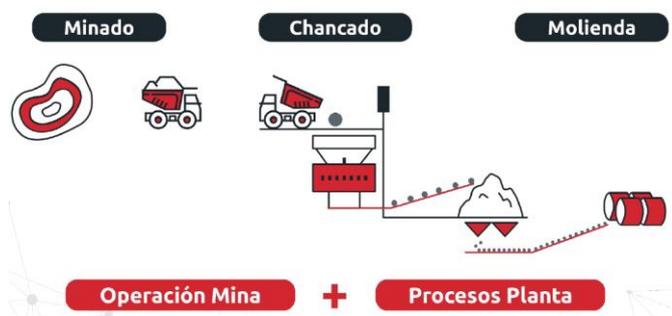


Figura 1. Mine to Mill

Entonces lo que se busca es optimizar la generación de finos después de cada voladura para que los molinos puedan trabajar a su máxima capacidad. Si bien esto puede significar un incremento en el costo de la perforación y voladura; finalmente se verá el beneficio cuando los molinos puedan trabajar a su máxima capacidad sin tener la necesidad de incrementar el consumo de energía. Es por esta razón que nosotros llamamos al proceso de optimización como “Drill to Mill”.

Otro factor importante, y lo que diferencia a esta optimización de trabajos anteriores, es el uso de Base de Datos. Debemos comprender que cada unidad de trabajo en la operación minera genera datos y comprender su comportamiento así como la generación de tendencias nos permitirá tomar

decisiones a tiempo y que impacten de forma positiva al negocio. Cabe mencionar que en este trabajo hemos logrado integrar las bases de datos, analizar y correlacionar variables en función al flujo de trabajo, para luego entrenar modelos a través de la metodología del “machine learning” y finalmente poder entender los resultados para maximizar el beneficio del proceso global.

### 2.2. Trazabilidad

#### 2.2.1. Configuración Actual

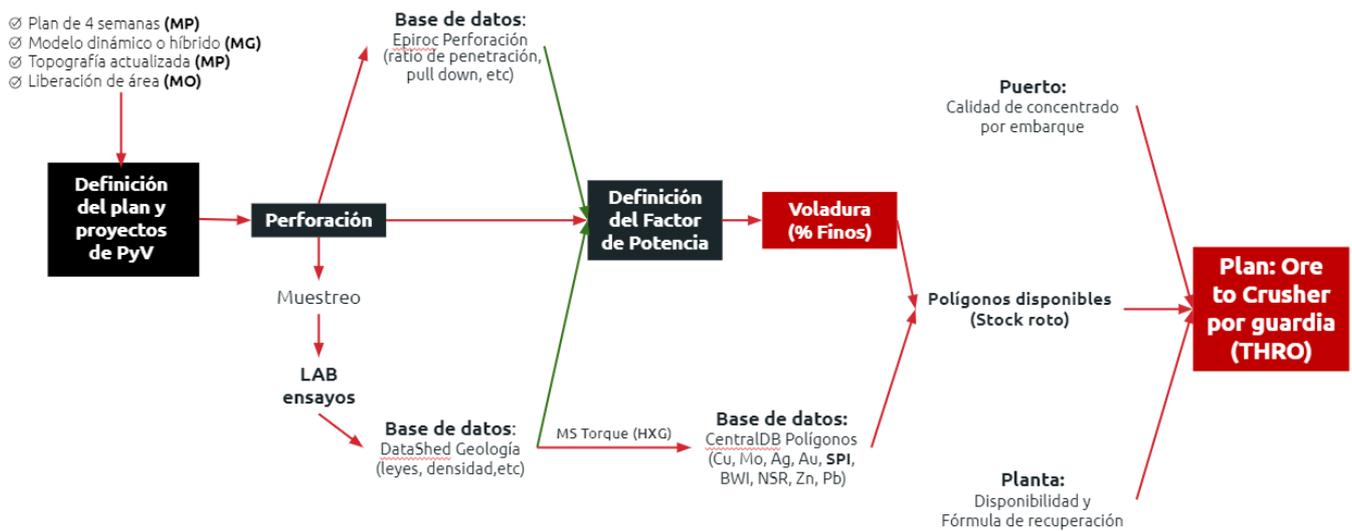
Los proyectos de perforación y voladura se generan para fragmentar el material in situ de manera adecuada para luego ser cargados y enviados a su destino final en la mina. Por ello la fragmentación debe permitir que tanto palas, chancadora y molinos trabajen de manera óptima según la configuración establecida pero a la vez su costo sea el mínimo. Según la teoría del “Mine to Mill” los gastos incurridos en esta primera etapa de la operación minera son recuperados con los ahorros generados por el menor consumo de energía o por los ingresos por una mayor producción de concentrado. Pero lo que se busca es balancear estos costos, ahorros e ingresos para estar dentro de la meseta de valor y así la cadena de producción sea óptima.

Cada vez que se genera un proyecto de perforación y voladura se define además el factor de potencia en función a las variables físicas y químicas del material a perforar. Para ello se extrapola información del banco superior y de taladros diamantinos cercanos. Una vez conocida mineralización, alteración y dureza se trabaja con una matriz de clasificación, basada en data histórica o estudios previos, para asignar un valor adecuado de factor de potencia por cada proyecto.

Esto resulta útil para la ejecución del proyecto pero puede generar un sesgo considerable en el resultado ya que los yacimientos mineralizados no son homogéneos y pueden cambiar sus propiedades en una corta distancia.

#### 2.2.2. Configuración propuesta

Lo que busca el planteamiento es reducir el sesgo y poder predecir con mayor exactitud la fragmentación de la roca según los parámetros de diseño establecidos pero incorporando en tiempo real los resultados de la perforación por cada taladro. Esto se logra gracias a la integración de bases de datos, la generación de un modelo predictivo que permite correlacionar variables entre la mina y planta y la generación de un modelo prescriptivo que permite ajustar el factor de potencia en cada taladro antes de la voladura.



**Figura 3. Configuración propuesta para la optimización del Drill to Mill**

El flujo de trabajo propuesto se puede ver en la Figura 3. Donde la principal propuesta es la conexión de las bases de datos de Perforación y Geología para poder anticipar la ejecución de la Voladura y ajustar el factor de potencia por taladro con información “fresca” tanto de variables físicas (perforación) así como de variables químicas (geología). Esto permitirá predecir de manera más eficiente el porcentaje de finos y por ende incrementar el cumplimiento del plan de minado.

### 3. Modelo Predictivo del Throughput

#### 3.1. Flujo de Trabajo

Un modelo predictivo busca anticipar los eventos que ocurrirán en un futuro cercano basados en la información disponible al momento de hacer la consulta. Para ello la aplicación del machine learning es fundamental ya que permite reconocer comportamientos en función a una gran escala y variabilidad de datos.

Como oportunidad de trabajo se encontró que la mayor parte de las áreas guardan su información. Pero como oportunidad de mejora es que esta información debería estar en Bases de Datos. Un manejo correcto y efectivo de la información nos permitirá generar modelos o réplicas de la realidad para luego estudiar procesos y finalmente optimizarlos sin la necesidad de que estos estudios afecten la producción o requieran gastos elevados.

La aplicación del Machine Learning requiere seguir los siguientes pasos:

1. Preparación de la Data

2. Analítica de la Data
3. Entrenamiento de los modelos
4. Interpretación de los modelos

##### 3.1.1. Preparación de la Data

Antes de analizar la Data se requiere que esta información se pueda leer, esté integrada y limpia. Para ello se trabajaron sobre las siguientes bases de datos: Modelo de Bloques, Planeamiento Mina, Perforación y Voladura, Geología, Sistema de Despacho y Procesos Planta. Si bien casi todas las bases de datos estaban generadas el reto fue madurar las que estaban pendientes y luego entender por donde integrarlas. El objetivo de esta parte del trabajo fue definir la trazabilidad de una partícula de roca, para además de conocer su recorrido desde el frente de minado hasta su llegada a los molinos (sincronización) poder saber sus características físicas y químicas (clasificación).

##### 3.1.2. Analítica de datos

Debido a que tenemos varias bases de datos integradas en un solo proceso y antes de iniciar con la analítica lo que se definió fue su emparejamiento. Además se tomaron asunciones, donde no se contaba con información.

Primero se emparejaron las Bases de datos del modelo de bloques y del sistema de despacho. Esto se logra gracias a la alta precisión de los equipos de carguío y alta resolución del modelo de bloques. Entonces cada vez que el material fragmentado se carga en el cucharón del equipo de carguío y es llevado a la tolva de un camión de acarreo podemos saber toda la información estática de este material: mineralización, alteración, ratio de penetración, factor de potencia, leyes, etc.

Asimismo podemos conocer su recorrido hasta su llegada a la chancadora en donde a través de

fotogrametría podemos conocer su P80 y F80<sup>3</sup>. Es aquí donde ocurre la primera asunción y son los dos minutos que transcurre desde que el mineral ingresa y sale de la chancadora.

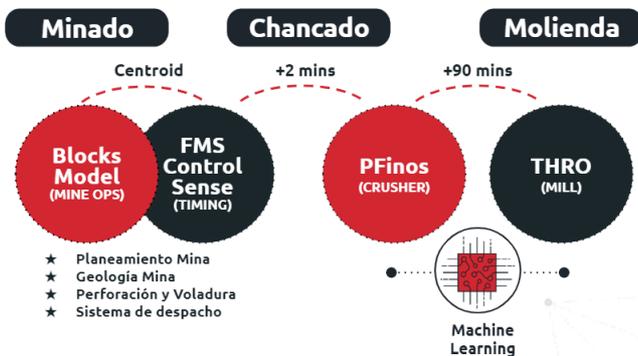


Figura 4. Emparejamiento de Bases de datos

La segunda asunción de tiempo es para definir el transcurso entre la salida de la chancadora y la llegada a los molinos. Esta corresponde a 90 minutos ya que entre ambos componentes se encuentra el stockpile de mineral chancado o “cono”. Posteriormente estas asunciones deberán ser reemplazadas por modelos que consideren la variabilidad de la operación tales como apertura de parrilla, altura de cono y segregación del mineral en el cono.

Finalmente se logró identificar, analizar y correlacionar variables de los últimos 12 meses (2021), tales como SPI<sup>4</sup>, BWI<sup>5</sup>, UCS, Na%, Al%, Agppm, Alteración, Porcentaje de Finos y Throughput. Los emparejamientos válidos fueron más de de 80,000.

### 3.1.3. Entrenamiento e Interpretación de los modelos

Se probaron distintos modelos de machine learning (generalizados y localizados) para buscar aquel que logre predecir mejor el throughput del molino. Utilizando un modelo “Random forest” se logró una predicción con un valor de R<sup>2</sup> cercano al 50%. Para mejorar esta predicción, se necesitaba dos cosas: mejorar la calidad de los *features* que ingresan al modelo; y aumentar las variables que influyen en el

<sup>3</sup> P80: tamaño correspondiente al 80% del pasante acumulado en los finos del último ciclo (µm). F80: tamaño correspondiente al 80% del pasante acumulado en la alimentación fresca (µm)

<sup>4</sup> SPI se refiere al tiempo que requiere una partícula dentro del molino para reducir su tamaño al solicitado en la configuración de la producción. Se utiliza operativamente para definir la dureza del mineral

<sup>5</sup> BWI se refiere a la energía que se consume en el molino para reducir una partícula al tamaño solicitado en la configuración de la producción. Se utiliza operativamente para definir la dureza del mineral

proceso que no se estaban considerando inicialmente (como las variables de la planta concentradora).



Figura 5. Modelos de predicción

Utilizando un análisis temporal, se encontró que era posible que el modelo reconozca patrones temporales en el comportamiento del throughput, que están influenciados por variables que no están disponibles para el modelo. Utilizando un modelo de predicción basado en series de tiempo, con un modelo de regresión Random forest; se logró mejorar la calidad de la predicción a un valor cercano al 90%. Esto se logró incorporando la base de datos del sistema de despacho al análisis, dando un orden de consumo de la data ya que se conoce el momento de la descarga del camión en la chancadora y se sabe de dónde provino y con ello todas las características del mineral cargado.

## 3.2. Resultados

### 3.2.1. Resultados del análisis de datos

El análisis de las variables consideradas y la prueba y entrenamiento de los modelos permitió identificar las que más se correlacionan con el throughput.

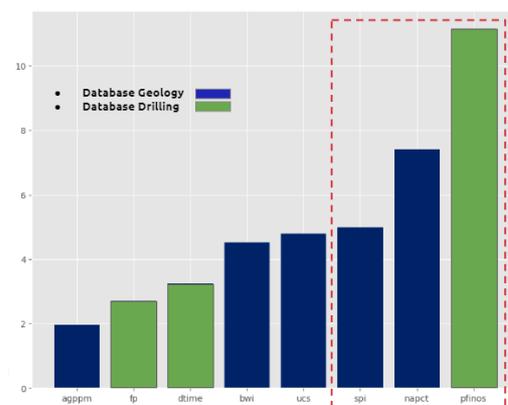


Figura 6. Correlación de variables con el throughput

Se encontró que el porcentaje de finos es la variable con mayor correlación con el throughput, seguido del porcentaje de sodio del mineral y el SPI. Al ser el porcentaje de finos una variable que es posible

modificar a través de la voladura, es evidente que se debía poner esfuerzos en mejorar este valor a un óptimo que proporcione el mejor throughput.

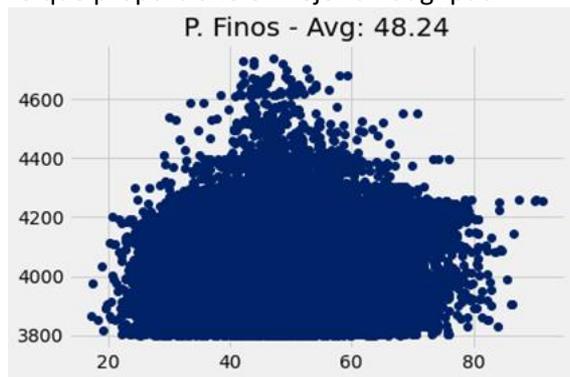


Figura 7. Valor de %Finos vs Throughput (casos de éxito)

A través del análisis fue posible encontrar el valor óptimo del porcentaje de finos, que se debía intentar alcanzar a través de la voladura. Además se conoció que este valor es distinto a cada tajo, mineralización y alteración siendo la litología monzónica y las alteraciones potásica y propílica los clusters que generan un menor éxito y estos mayormente se encuentran en el tajo Constancia. Este análisis abre las puertas a optimizar el proceso de minado desde la voladura, prediciendo el throughput en función a las leyes del mineral y un factor de potencia sugerido por software prescriptivo.

### 3.2.2. Aplicación del análisis para optimizar el minado

Todo el proceso de análisis, entrenamiento e interpretación se plasmó en un software web que permite predecir con una anticipación de 90 minutos los eventos de la planta en función a las variables de la mina y es utilizado por la supervisión de planeamiento mina para ajustar las mezclas de mineral que son enviados al proceso con el objetivo de mantener estable el throughput para evitar caídas que eleven el consumo de energía en la planta, se requiera de movimientos no planificados de los equipos mineros y/o no se cumpla con los KPIs de producción.

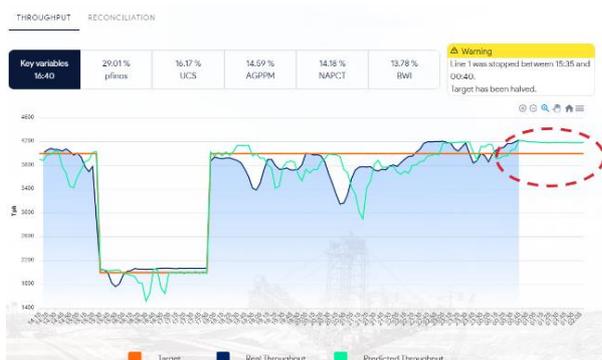


Figura 8. Software de predicción del throughput

Este software se encuentra integrado a los diferentes sistemas existentes en la mina que realizan recolección de datos: sistema de despacho, sistema de datos de planta, etc. De esta manera, es capaz de realizar la predicción en tiempo real continuamente y alertar cuando se detecte que el throughput está por caer y así tomar acciones correctivas para evitar dicha caída. Además muestra las variables que tienen mayor influencia en la predicción del throughput.

En un mediano plazo, se espera que el software clasifique cada bloque mineralizado y apoyado en el plan de minado se pueda definir el throughput estimado de cada plan.

## 4. Modelo Prescriptivo del Factor de Potencia

Lo que busca el modelo prescriptivo es definir una receta para generar casos de éxito. En nuestro estudio esta prescripción se dará para la definición del factor de potencia por taladro de perforación y el éxito será cuando se reduzcan los casos con un throughput menor a 3,200 tph.

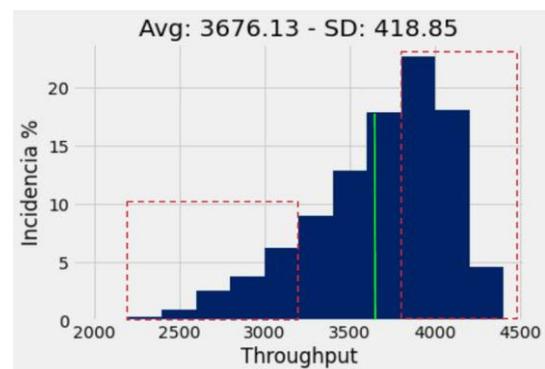


Figura 9. Casos de éxito y fracaso del Throughput

Para lograr ello se debe aislar la variable factor de potencia, generar su Analítica de Datos y conocer patrones que indiquen que bajo cierta alteración con un grado de SPI y valor de factor de potencia no se generó el throughput adecuado en la planta, es decir fue un caso de fracaso, para que en función a ello y a través del machine learning se pueda ajustar el factor de potencia en un siguiente proyecto de voladura que tenga las mismas características.

Esta mejora sólo funcionará si es que se logra ajustar el factor de potencia previo a la voladura. Por ello no solo la integración de las bases de datos es fundamental sino además lo es la disponibilidad de la información. Por ejemplo la base de datos de Geología se encuentra en función de los resultados del laboratorio y estos a la vez de la asignación de muestras después de la perforación. Entonces es importante que la operación minera tenga un

suficiente stock roto de material volado para que la planificación de los siguientes proyectos de voladura tenga un tiempo de espera prudencia y así pueda obtener un porcentaje de finos que genere éxito en el throughput.

## 5. Conclusiones

El porcentaje de finos influye fuertemente en el throughput y optimizarlo desde la voladura se traduce en una mejora del throughput y optimización de costos. Un porcentaje de finos adecuado se puede generar con una adecuada definición del factor de potencia, por taladro, basados en sus propiedades físicas y químicas después de la perforación..

Este modelo solo es alimentado con variables de Mina y utiliza como *espejo* el resultado de una sola variable de la Planta, el throughput. Alimentar el modelo predictivo con variables de geología y además con las de perforación como de la planta mejora la calidad de la predicción.

A continuación se muestra un tabla resumen con los casos de Éxito y Fracaso según porcentaje de finos por tajo.

Tajo	Casos	Tph	% Finos (Avg)
Constancia	Éxito	> 3800 tph	48%
	Fracaso	< 3200 tph	37%
Pampacancha	Éxito	> 3800 tph	38%
	Fracaso	< 3200 tph	31%

Figura 10. Casos de éxito y fracaso del Throughput

Con el software integrador se tiene el rastreo del mineral desde el frente de minado hasta la chancadora y se logró predecir con una efectividad mayor al 90% los eventos que ocurrirán en el molino desde que el mineral es descargado en la chancadora. La predicción es de 90 minutos y es el tiempo de arribo del mineral a los molinos desde su chancado, este tiempo puede ser modelado en función a la segregación del material y altura del stockpile.

El porcentaje de sodio y el SPI son las variables geológicas con mayor influencia en el throughput, intrínsecas al yacimiento. Siendo a su vez el SPI un modelo que representa la dureza del mineral, su valor se obtiene en un laboratorio y se utilizan las variables geológicas de la muestra para su definición y extrapolación.

## 6. Oportunidades

Contar con un software integrador de datos alimentado por modelos predictivos desarrollados gracias a los hallazgos del análisis de datos abre las puertas a optimizar el minado desde la voladura. Es posible utilizar el software para optimizar el porcentaje de finos de manera que se tenga un throughput óptimo, reduciendo así costos en voladura y maximizando la producción. Se viene trabajando en una siguiente versión del software que se conecte a los sistemas de voladura y geología para este fin.

## 7. Agradecimientos

Se agradece a la compañía minera Hudbay Perú por la predisposición a la innovación y fomentar la investigación dentro de la empresa. Además un agradecimiento especial a las áreas involucradas que tuvieron la apertura suficiente para compartir su información, trabajar en equipo y poder integrar las bases de datos en favor de la empresa y con el fin de encontrar oportunidades de mejora en beneficio de la operación. Gracias a esta investigación se abren las puertas para poder digitalizar la mina y así generar un gemelo digital minero en donde podamos hacer evaluaciones de forma virtual y sin afectar la producción o incurrir en gastos excesivos para probar nuevas tecnologías.

## Referencias

- Morrel, S. 1998. Increasing profitability through integration of blasting and comminution effort. Conference IIR, p. 2-3.
- Shah, D., 2021. Machine Learning: Tecnología en la Toma de Decisiones. MIT course, p. 1-10.
- Mahesh, B., 2020. Machine Learning Algorithms - A Review. International Journal of Science and Research (IJSR), p. 1-5.

## Perfil profesional

Eder Lagos Leon  
 Superintendente de Planeamiento Mina  
 Hudbay Peru SAC  
 eder.lagos@hudsonminerals.com  
 +51 951996873  
 Chumbivilcas, Cusco, Perú

Ingeniero de Minas egresado de la Universidad Nacional de Ingeniería y actual Superintendente de

Planeamiento Mina en Hudbay Peru SAC, con 16 años de experiencia en evaluación y optimización de operaciones mineras, tanto en el Perú como en el extranjero. Posee un Master en "Technical and Economic Analysis of Open-pit mining operation" por la Mines ParisTech. Cuenta con amplia experiencia en evaluación de proyectos mineros, diseño de minas a tajo abierto, planeamiento estratégico, LTP, MTP, STP y Machine Learning para procesos mineros.

### **Perfil profesional**

Engels Trejo Pantoja  
Gerente de Servicios Técnicos  
Hudbay Peru SAC  
engels.trejo@hudbayminerals.com  
+51 920168396  
Chumbivilcas, Cusco, Perú

Profesional en la especialidad de Ingeniería Geológica egresado de la Universidad Mayor de San Marcos, con un Master en Exploración Geológica por la Universidad Nacional de San Agustín y una especialidad en Gestión Minera por la Universidad ESAN. Experiencia internacional en Panamá, República Democrática del Congo y Zambia. Con una trayectoria de más de 22 años en operaciones a tajo abierto y planeamiento de mina, cuenta con amplia experiencia en procesos como: Geología de Mina (Ore Control) a tajo abierto, pórfidos de Cu-Mo, yacimientos epitermales, preparación de modelos geológicos, mine to mill, modelos geometalúrgicos, exploraciones de pórfidos de cobre y vetas.