

**César Moscoso<sup>1</sup>, Álvaro Rendón<sup>2</sup>, Ariel Medina<sup>3</sup>**

<sup>1</sup> ME Elecmetal, Andrés Bello 2233, Santiago, Chile (cmoscoso@elecmetal.cl)

<sup>2</sup> ECN Automation, Boulevard Paseo Rio Sonora Sur No. 69 Hermosillo, México (arendon@ecn.com.mx)

<sup>3</sup> ME Elecmetal, Andrés Bello 2233, Santiago, Chile (amedina@elecmetal.cl)

---

## RESUMEN

En la actualidad, gran parte del desarrollo de herramientas tecnológicas para molienda SAG tienen como fin la optimización del rendimiento de molinos, maximizando la producción y estabilidad del proceso. Para lograr lo anterior, es requerido un monitoreo completo de los inputs del molino junto con el estado operacional del mismo que es representado por las variables operacionales.

Este panorama ha promovido la sensorización de los principales equipos de molienda y el gran auge de tecnologías no invasivas basadas en inteligencia artificial y analítica avanzada como son los sensores virtuales, visión por computadora y, entre otros, los llamados modelos híbridos. Estos últimos aparecen como una solución capaz de entregar información oportuna (tiempo real) sobre variables que hoy en día siguen presentando grandes desafíos, pues su medición generalmente implica detención prolongada del proceso además de una logística costosa. Este es el caso del monitoreo de la carga interna del molino, cuyas variables principales son el nivel de llenado de bolas (Jb) y llenado total del molino (Jc). Estas para ser medidas actualmente requieren detención, lavado y escaneo del molino, por lo que es común no encontrar más de 3 o 4 mediciones puntuales durante toda una campaña o ciclo de revestimientos.

Los modelos determinísticos clásicos, como el de potencia de C-Morrell, han demostrado la importancia del conocimiento de Jb y Jc para predicción de parámetros operaciones, además su desarrollo aplicado al proceso permite estimar en forma precisa ambas variables, sin embargo, esto solo se lleva a cabo en forma discreta, generando análisis con data histórica y que no responden a la condición presente del proceso. La situación anterior mejora considerablemente al aplicar un enfoque híbrido, en donde el modelo clásico puede ser utilizado en conjunto a técnicas computacionales, como son algunos modelos de optimización, cuya rápida velocidad de computo es compatible con la aplicación en tiempo real, volviendo al modelo híbrido una

potente herramienta de análisis en línea que sirve de base para plataformas de inteligencia operacional como por ejemplo los gemelos digitales.

El presente trabajo tiene como finalidad explicar la importancia de adoptar un enfoque híbrido en los modelos clásicos de molienda, abriendo paso a nuevos modelos híbridos que habilitan la determinación de información clave para la optimización del proceso y de la forma más oportuna posible: en tiempo real. Luego, se expone la metodología utilizada para el desarrollo y validación de un modelo híbrido particular capaz de predecir en tiempo real, con alta efectividad y precisión el nivel de llenado de bolas (Jb), nivel de llenado total (Jc) y potencia consumida de un Molino SAG en operación.

La estructura de la modelación híbrida se describe en las siguientes etapas. La primera implica el planteamiento del modelo híbrido, el cual está compuesto por una adaptación del modelo de potencia de C-Morrell en conjunto con un modelo de optimización no lineal con restricciones. La segunda etapa considera experimentos de calibración a través del ajuste de las ganancias propias de cada modelo para minimizar los errores de predicción. Finalmente, la tercera etapa comprende la validación de los resultados obtenidos, respecto a la data operacional histórica real de un molino SAG.

El modelo híbrido desarrollado fue capaz de predecir el nivel de llenado de bolas (Jb) con un error promedio menor al 0.5% respecto a información de escaneos láser en condición Grind Out. Por otro lado, el error promedio de predicción de nivel de llenado total (Jc) fue menor 1.5% respecto a información de escaneos láser en condición Crash Stop.

En conclusión, los resultados demuestran que los modelos híbridos son habilitadores de información importante de proceso, los cuales bien calibrados son capaces de generar predicciones de alta precisión. Lo anterior, sumado a su compatibilidad con el despliegue en tiempo real, los convierte en herramientas de inteligencia operacional.

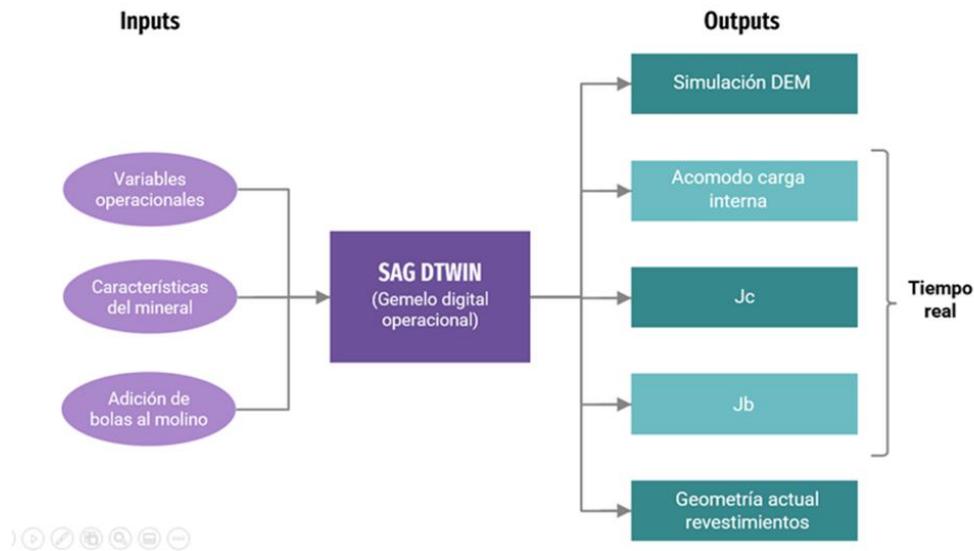


Figura 1: Esquema de Inputs y Outputs del SAG DTWIN.

## 1. Introducción

### 1.1. Contexto: Desafíos Molienda SAG

En la actualidad, gran parte del desarrollo de herramientas tecnológicas para molienda SAG tienen como fin la optimización del rendimiento de molinos, maximizando la producción y estabilidad del proceso. Para lograr lo anterior, es requerido un monitoreo completo de los inputs del molino junto con el estado operacional del mismo que es representado por las variables operacionales.

Este panorama ha promovido la sensorización de los principales equipos de molienda y el gran auge de tecnologías no invasivas basadas en inteligencia artificial y analítica avanzada como son los sensores virtuales, visión por computadora y, entre otros, los llamados modelos híbridos. Estos últimos aparecen como una solución capaz de entregar información oportuna (tiempo real) sobre variables que hoy en día siguen presentando grandes desafíos, pues su medición generalmente implica detención prolongada del proceso además de una logística costosa. Este es el caso del monitoreo de la carga interna del molino, cuyas variables principales son el nivel de llenado de bolas ( $J_b$ ) y llenado total del molino ( $J_c$ ). Estas para ser medidas actualmente requieren detención, lavado y escaneo del molino, por lo que es común no encontrar más de 3 o 4 mediciones puntuales durante toda una campaña o ciclo de revestimientos.

### 1.2. Modelos Clásicos vs. Modelos Híbridos

La modelación híbrida corresponde a la integración de 2 o más modelos/relaciones basadas en diferentes enfoques tales como: Modelos físicos, experimentales,

basados en datos (machine learning), de optimización, simulaciones, etc; cuyos resultados permitan converger los mejores atributos de cada uno.

Los modelos determinísticos clásicos, como el modelo de potencia consumida de C-Morrell, han demostrado la importancia del conocimiento de  $J_b$  y  $J_c$  para predicción de parámetros operaciones, además su desarrollo aplicado al proceso permite estimar en forma precisa ambas variables, sin embargo, esto solo se lleva a cabo en forma discreta, generando análisis con data histórica y que no responden a la condición presente del proceso. La situación anterior mejora considerablemente al aplicar un enfoque híbrido, en donde el modelo clásico puede ser utilizado en conjunto a técnicas computacionales, como son algunos modelos de optimización o machine learning, cuya rápida velocidad de cómputo es compatible con la aplicación en tiempo real, volviendo al modelo híbrido una potente herramienta de análisis en línea que sirve de base para plataformas de inteligencia operacional como por ejemplo los gemelos digitales (Medina & Rendón, 2021).

### 1.3. Gemelo Digital Operacional de Molienda SAG: SAG DTWIN

El Gemelo Digital Operacional de Molienda SAG (SAG DTWIN) consiste en una plataforma digital que agrupa diferentes herramientas de predicción, simulación y análisis operacional, varias de ellas basadas en modelación híbrida. El SAG DTWIN recibe como inputs variables de proceso, características de mineral y datos de diseño del molino para retornar predicciones de importantes variables para toma de decisiones como son el  $J_c$  [%],  $J_b$  [%], ángulos de pie [°], hombro [°] y de impacto [°]. Además, cuenta con 2

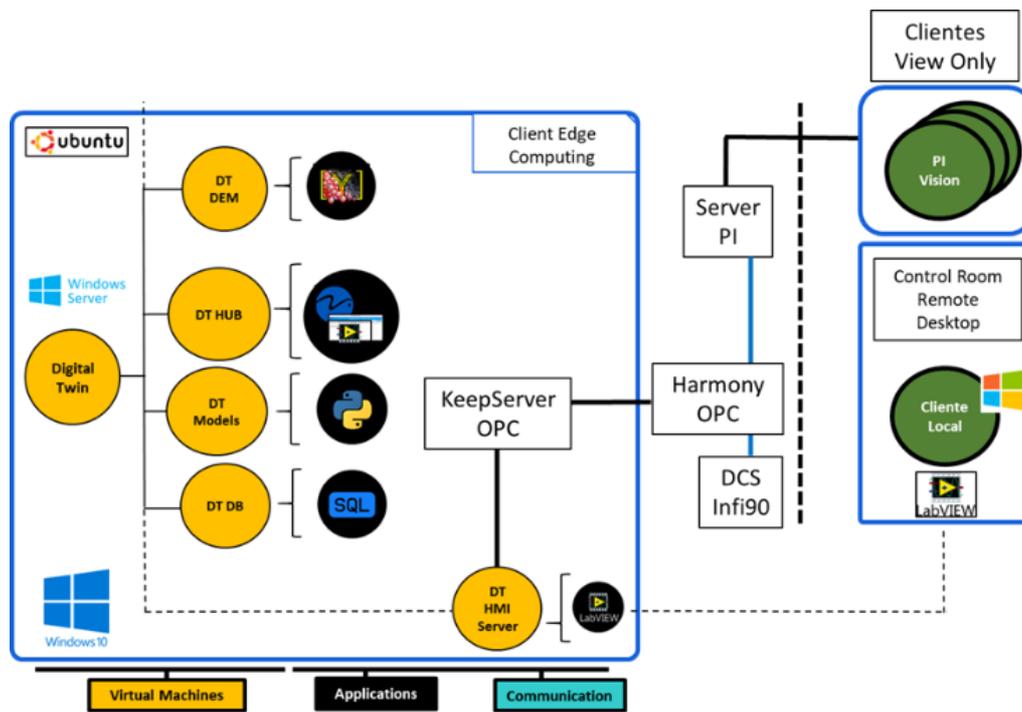


Figura 2: Esquema de arquitectura utilizada por SAG DTWIN (y Modelo Híbrido Jb/Jc).

módulos de parametrización y diagnóstico: (1) Simulador DEM optimizado denominado “One click DEM”, capaz de disparar simulaciones con un solo click, alimentándose directamente de variables operacionales, y (2) Módulo de predicción de perfil de revestimientos, el cual es capaz de determinar la geometría instantánea de la sección transversal del lifter y placa del molino. La figura 1, muestra un esquema completo de inputs y outputs del SAG DTWIN.

Todo lo anterior, convierte a esta plataforma en una herramienta capaz de generar una réplica virtual del molino, siendo utilizada para diagnosticar, generar alertas tempranas para valores fuera de rango, y asistir estrategias de control en favor de la estabilidad operacional y maximización de tratamiento (Rendón, 2020).

#### 1.4. Modelo Híbrido para Jb/Jc en línea

Volviendo al tema principal y que convoca este trabajo, que son los modelos híbridos, las siguientes secciones del documento tienen como fin exponer el trabajo de desarrollo, calibración, implementación y resultados del modelo híbrido para predicción de nivel de llenado de bolas (Jb) y carga total (Jc) en tiempo real, el cual, debido a sus resultados y robustez, es uno de los habilitadores principales de las herramientas entregadas por el SAG DTWIN.

## 2. Metodología

### 2.1. Arquitectura de Implementación

Como se ha mencionado anteriormente, el modelo híbrido de Jb/Jc se encuentra integrado al SAG DTWIN, por lo que ambos comparten la misma arquitectura para poder operar en tiempo real.

Por lo anterior, el modelo híbrido de Jc/Jb requiere data operacional del molino SAG como input para poder operar. La arquitectura del SAG DTWIN está compuesta de 5 máquinas virtuales donde cada una se encarga de realizar una función en específico y esencial para su funcionamiento:

- **DT DEM:** Aloja y ejecuta el simulador DEM optimizado.
- **DT HUB:** Se encarga de la gestión y flujo de datos entre las 5 máquinas virtuales.
- **DT MODELS:** Aloja y ejecuta todos los modelos calibrados que componen el gemelo digital. En él se encuentra, entre otros, el modelo híbrido de Jc/Jb.
- **DT DB:** Base de datos SQL. Almacena información proveniente del DCS (variables molino SAG) como también la data generada por el mismo gemelo digital (Jc, Jb, resultados DEM, predicciones de perfil revestimientos, etc.).
- **DT HMI:** Aloja la interfaz Usuario-Máquina del gemelo digital y también se encarga de instancias de comunicación con el DCS u otra fuente de información operacional del cliente.

El SAG DTWIN se puede conectar al DCS (u otra fuente de información de operación) directamente a través de algún módulo o protocolo industrial de

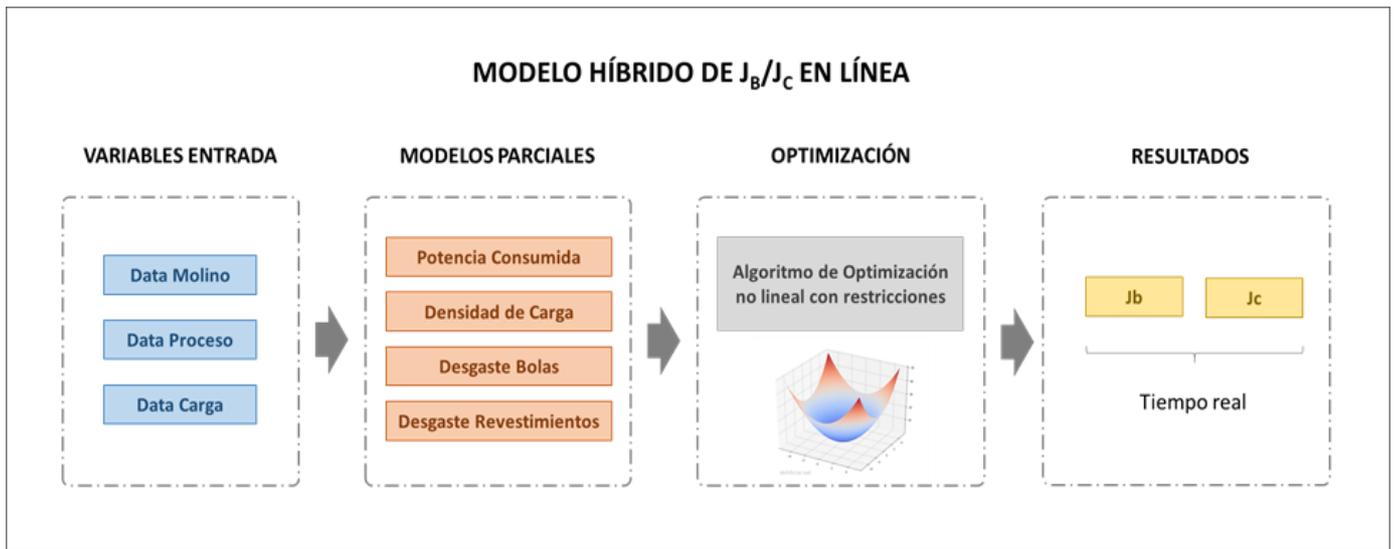


Figura 3: Esquema secuencial de ejecución Modelo Híbrido de Jb y Jc.

comunicación, como también a través de un servidor OPC, donde esta última opción es la que se presenta en la figura 2. La data operacional proveniente del DCS se almacena en el DT DB para luego, a través de consultas, ser utilizada por DT MODELS para resolver los modelos híbridos calibrados, entre ellos de modelo de Jb/Jc. Finalmente, las variables determinadas por los modelos se almacenan nuevamente en DT DB y simultáneamente se envían vía protocolo MQTT al DT HMI para ser desplegadas en la interfaz de visualización avanzada. La figura 2 presenta un diagrama de la arquitectura mencionada (Medina & Rendón, 2021).

## 2.2. Desarrollo Modelo Híbrido Jb/Jc

Tabla 1: Variables importantes de entrada Modelo Híbrido Jc/Jb.

Tipo Dato	Variables importantes	Frecuencia actualización
Diseño de molino SAG	<ul style="list-style-type: none"> <li>• Diámetro efectivo</li> <li>• Largo efectivo</li> <li>• Velocidad crítica</li> <li>• Diseño revestimientos (factor forma, altura, ángulo ataque, etc.)</li> </ul>	NA
Variables operacionales	<ul style="list-style-type: none"> <li>• Potencia</li> <li>• Velocidad giro</li> <li>• Celda de carga o presión de descansos.</li> <li>• Adición de bolas</li> </ul>	1 a 10 [s]
Características carga	<ul style="list-style-type: none"> <li>• Densidad mineral</li> <li>• Densidad Bola</li> <li>• Cp nominal</li> </ul>	Mayor disponible. Normalmente disponible en orden de horas.

El modelo híbrido de Jb y Jc, consta de un conjunto de relaciones fenomenológicas, basadas en datos y de métodos numéricos, que al ser resueltas en una secuencia lógica permiten lograr una estimación en línea y muy acertada (con un error porcentual inferior

al 1.5%), del nivel de llenado de bolas [%] (Jb) y nivel de llenado total [%] (Jc) de un molino SAG en operación.

El modelo híbrido se alimenta de variables operacionales de molienda, datos del molino SAG y características del mineral de entrada, las cuales permiten el desarrollo secuencial de las relaciones mencionadas, denominadas “modelos parciales”. Estos son resueltos a través de un algoritmo de optimización no lineal con restricciones, cuyo bajo coste de recursos de cómputo permite su ejecución casi al instante, y con ello una obtención de resultados de Jb y Jc en la misma frecuencia de actualización que la data operacional de entrada. El funcionamiento descrito anteriormente se muestra esquemáticamente en la figura 3, donde cada etapa se detalla a continuación:

### 2.2.1. Variables de entrada

Data operacional y de diseño del proceso de molienda, la cual se detalla en la tabla 1.

### 2.2.2. Modelos parciales

Corresponden al conjunto de modelos o relaciones que conforman el modelo híbrido de Jb/Jc. Estos son:

- **Potencia consumida C-Morrell:** considera el modelo clásico modificado de potencia consumida por un molino de bolas, AG o SAG desarrollado por S. Morrell (Morrell, 1992). Este considera que la potencia total  $P_{gross} = No - load Power + (k(P_{net} + P_c))$ , donde:

$$P_{net} = \frac{\pi g L N_m r_m}{3(r_m - z r_i)} \left( 2r_m^3 - 3z r_m^2 r_i + r_i^3 (3z - 2) \right) (\rho_c (\sin \theta_s - \sin \theta_T))$$

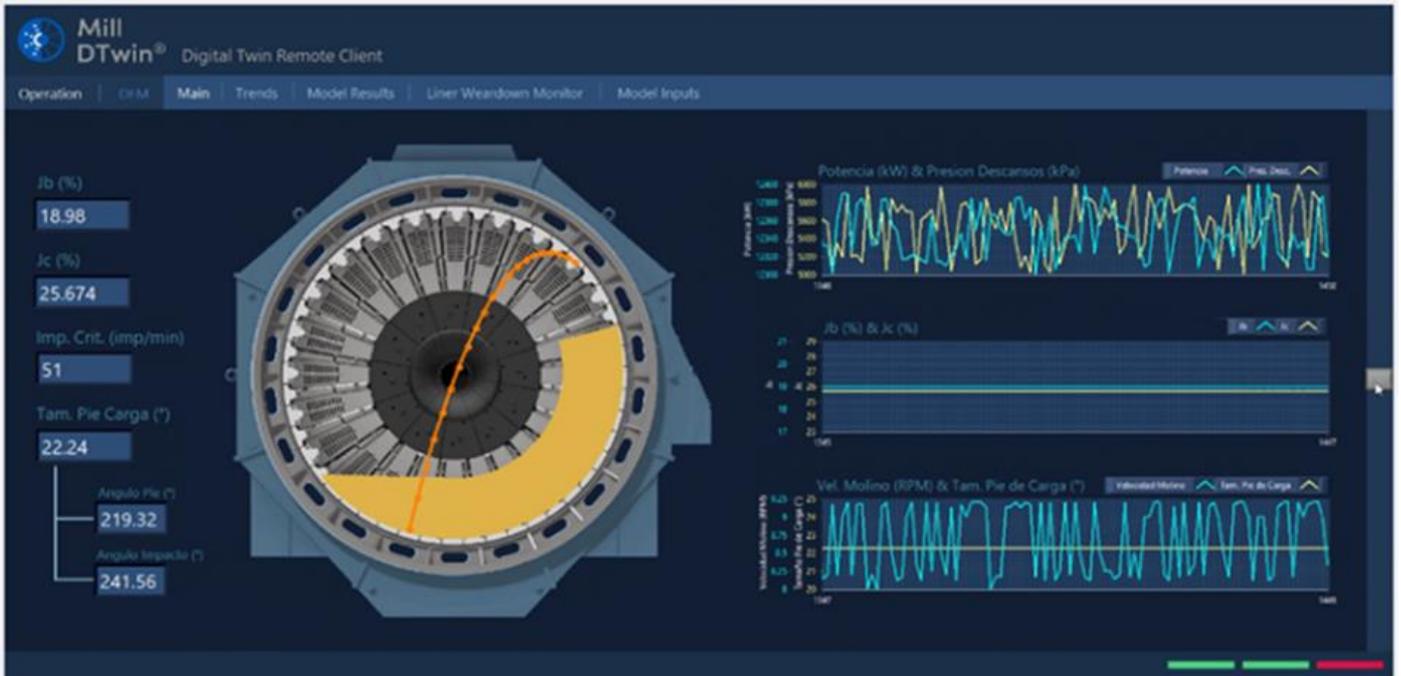


Figura 4: Interfaz de visualización avanzada del SAG DTWIN.

$$P_c = \frac{\pi L_d g N_m}{3(r_m - r_t)} \left( (r_m^4 - 4r_m r_i^3 + 3r_i^4) (\rho_c (\sin \theta_s - \sin \theta_T) + \rho_p (\sin \theta_T - \sin \theta_{TO})) \right) + \frac{2\pi^3 N_m^3 L_d \rho_c}{5(r_m - r_t)} (r_m^5 - 5r_m r_i^4 + 4r_i^5)$$

$$No - load Power = 2.62(D^{2.5}L\phi)^{0.804}$$

- **Densidad de carga:** considera el modelo de densidad de carga de un molino de bolas desarrollado por S. Morrell (Morrell, Valery, Banini, & Latchireddi, 2001). Está dada por:

$$\rho_c = \frac{J_t \rho_o (1 - E + EUS) + J_B (\rho_B - \rho_o) (1 - E) + J_t EU (1 - S)}{J_t}$$

- **Modelo de desgaste de bolas:** modelo de carácter lineal de desgaste de bolas, calibrado a través de mediciones experimentales en condición Grind-Out y data continua de adición de bolas.
- **Modelos de desgaste de revestimientos:** considera 2 modelos de predicción de forma de lifters del molino SAG. El primero, corresponde a un modelo basado en datos (machine learning) entrenado con data histórica para predecir la altura de perfil del lifter en un momento dado de la campaña. El segundo, corresponde a un modelo de interpolación calibrado con data histórica, capaz de predecir el ángulo de ataque del lifter. Este último, ajusta la predicción considerando el sentido de giro del molino SAG.

### 2.2.3. Algoritmo de optimización

El algoritmo de optimización resuelve una función de costo generada a partir de los modelos descritos anteriormente. Específicamente, esta función de costo relaciona el error de potencias (diferencia entre potencia experimental del molino SAG y la potencia predicha por el modelo de Morrell), con el Jb y las variables operacionales.

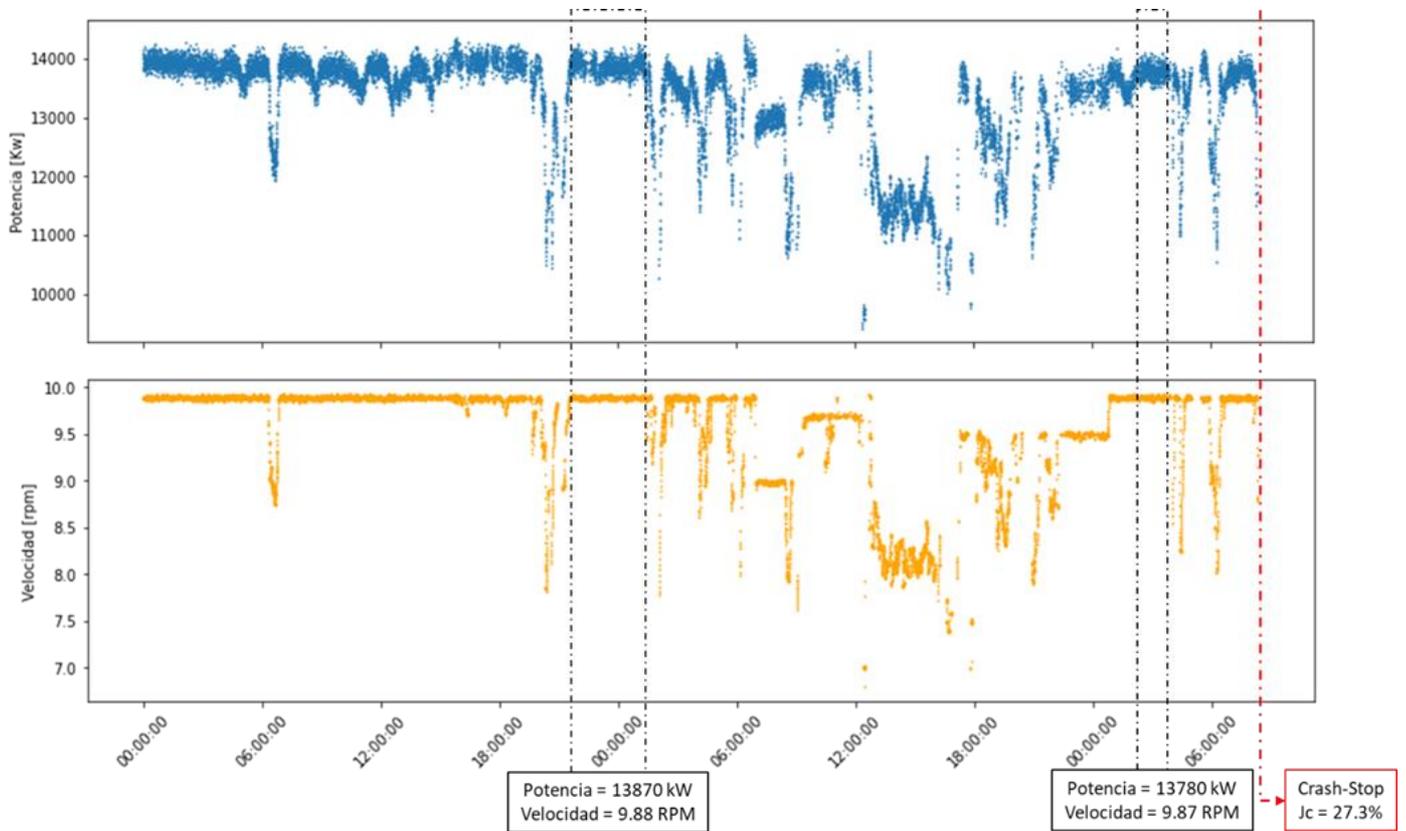
El algoritmo de optimización utilizado corresponde a un método numérico de bajo costo computacional, lo que permite su ejecución iterativa para mantener el mejor resultado en tiempo real.

### 2.2.4. Resultados

El modelo híbrido entrega como resultado estimaciones de Jb y Jc en tiempo real. Estos valores son almacenados en la base de datos DT DB y de forma simultánea son enviados por protocolo MQTT al DT HMI para ser reportados al usuario a través de la interfaz de visualización avanzada del SAG DTWIN, con una frecuencia de actualización igual a la de las variables operacionales de entrada. La figura 4 presenta una captura de la interfaz avanzada de visualización del SAG DTWIN.

## 2.3. Calibración

Al igual que los modelos experimentales en los que está basado, el modelo híbrido presenta parámetros de calibración o "ganancias" que deben ser ajustadas de forma experimental, estas son la ganancia del modelo de potencia consumida de C-Morrell y las



ponderaciones de la función de costo. Para ser calibradas, se utilizan valores conocidos de  $J_b$  y  $J_c$ , determinados de forma experimental mediante

régimen estacionario más cercanos a la detención. En base a estos periodos y las mediciones de  $J_b$  y  $J_c$ , se realiza el ajuste de ganancias en base a método de

Figura 6: Ejemplo de data de calibración modelo híbrido  $J_b$  y  $J_c$ .

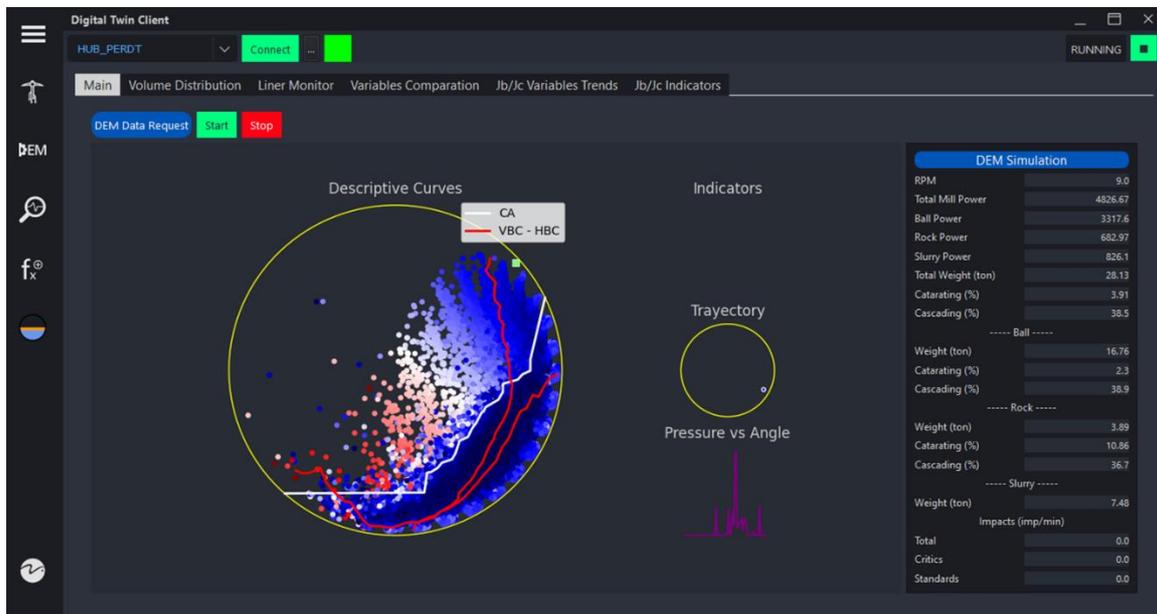


Figura 5: Módulo de Simulación DEM del SAG DTWIN. También utilizado para la auto-calibración del modelo híbrido.

medición láser durante detenciones del molino SAG en condiciones Grind-Out (para  $J_b$ ) y Crash-Stop (para  $J_c$ ).

El procedimiento de calibración, considera un periodo de 2 días de operación del molino antes de la detención para realizar las mediciones. Durante este periodo, se realiza un seguimiento de las principales variables operaciones y se identifican los periodos en

mínimos cuadrados. Un ejemplo de lo anterior se muestra en la figura 5, donde la gráfica explica el proceso de un molino SAG, 48 horas antes de su detención (línea roja segmentada) para la realización de una medición láser en condición Crash-Stop. Dentro del tiempo definido, se buscan intervalos de tiempo relativamente estables o en estado estacionario

(cuadros negros) y con estos valores de realiza la calibración.

## **2.4. Auto-check y auto-calibración**

Como se ha mencionado anteriormente, el SAG DTWIN entre sus herramientas cuenta con un simulador DEM optimizado, capaz de disparar simulaciones utilizando como inputs las variables operacionales instantáneas del molino. Esta característica es utilizada para aumentar la robustez del modelo híbrido de Jb y Jc, permitiéndole re-parametrizar escenarios y auto-calibrarse.

El proceso de auto-calibración comienza con el auto-chequeo de las predicciones realizadas por el modelo híbrido, esto es, una evaluación de la magnitud del error entre la potencia experimental del molino y la potencia predicha por el modelo en función de las predicciones de Jc y Jb. Cuando el error sobrepasa el umbral definido, se dispara una simulación DEM en condiciones operacionales instantáneas del molino, luego, con los resultados se estima una nueva potencia consumida. Si se verifica que esta última es similar a la experimental, el modelo se re-calibra automáticamente a través del ajuste de sus ganancias. La figura 6 muestra una captura de pantalla del módulo de simulación DEM del SAG DTWIN.

## **3. Resultados experimentales**

Para la validación del modelo híbrido, el desarrollo y calibración antes descritos se aplicó en un molino SAG de la gran minería chilena. Una vez calibrado el modelo se realizó validación de resultados en 2 etapas: (1) Validación off-line y (2) validación on-line. La primera considera la evaluación del desempeño del modelo, realizando predicciones sobre data operacional histórica del molino SAG, mientras que la segunda, considera la evaluación del desempeño recibiendo el flujo de data operacional en tiempo real, a través de integración del modelo con el DCS de la planta de molienda. A la fecha, la etapa de validación off-line fue concluida de forma exitosa y con resultados muy prometedores que se presentan a continuación, mientras que la etapa de validación on-line aún está proceso.

### **3.1. Validación off-line**

La primera validación de resultados del modelo híbrido de Jb y Jc (como parte del SAG DTWIN), se ha llevado a cabo en forma off-line donde se utilizó data de proceso histórica de un molino SAG de la gran minería chilena para el levantamiento y calibración de

todos los modelos descritos. La data operacional utilizada corresponde a los años 2020 y 2021, donde el primer año completo se utilizó para calibración, mientras que el segundo para validación y generalización de modelos.

A continuación, se muestran los principales resultados de Jb y Jc de la validación off-line:

#### **3.1.1. Nivel de llenado bolas: Jb**

Para la validación de resultados de Jb, se estableció como KPI el error porcentual existente entre la predicción realizada por el modelo híbrido versus las mediciones experimentales (mediciones láser) realizadas en detenciones del molino SAG durante el segundo semestre del año 2021. Una validación exitosa considera un error porcentual entre mediciones menor al 5%.

Durante el periodo seleccionado, existieron 2 paradas con mediciones en condición Grind-Out, lo que habilita 2 instancias de validación para los resultados de Jb. La figura 7 muestra 2 gráficas de predicciones continuas de Jb (superior) y Jc (inferior) para el día 13 de agosto del 2021. Ambas gráficas muestran la evolución de las predicciones del modelo híbrido en una ventana de tiempo que comienza 24 horas antes de la detención, hasta terminar en la misma (momento en que se realiza la medición experimental). Para el caso del Jb (gráfica superior) se observa claramente un efecto de “diente de sierra” el cual define el comportamiento esperado del Jb, donde la variable operacional de adición de bolas al molino aumenta el Jb en forma escalonada, mientras que el modelo de desgaste de bolas (modelo lineal) disminuye su valor en forma continua hasta la siguiente adición de bolas de molienda. Esta tendencia es cíclica hasta el momento de la detención (línea roja punteada) donde se compara con la medición experimental proveniente del escaneo láser en condición Grind-Out. Para este periodo, los resultados del modelo híbrido entregan una predicción de Jb de 19.53%, mientras que la medición experimental indicó que el valor real es 19.60%, esto resulta en un error porcentual de 0.37%, muy por debajo del error límite definido (5%) y que demuestra la robustez y precisión del modelo híbrido.

La figura 8 muestra el segundo punto de validación realizado durante la detención del día 21 de octubre del 2021, donde en general se observa un comportamiento muy similar al caso anterior. La predicción realizada por el modelo híbrido entregó un valor de Jb de 18.75%, mientras que la medición experimental indicó un valor real de 18.72%, lo que presenta nuevamente un error porcentual muy bajo de solo el 0.16%.



La tabla 2, muestra un resumen de los principales resultados de la validación off-line.

La figura 9 muestra la evolución de los valores Jb (superior) y Jc (inferior) determinados por el modelo

Figura 8: Resultados Jb para periodo detención 13-08-2021.



Figura 7: Resultados Jb para periodo detención 21-10-2021.

### 3.1.2. Nivel de llenado total: Jc

Los resultados de predicción de Jc se validaron bajo condiciones similares que las utilizadas Jb, se estableció el error porcentual entre valor predicho y valor real como KPI de evaluación y se definió el mismo periodo evaluación, correspondiente al segundo semestre de 2021. A diferencia del Jb, durante el periodo de evaluación solo se realizó solo una medición en condiciones Crash-Stop, lo que solo habilitó una instancia de validación de resultados.

híbrido. En el caso de Jc, se observa que al momento de la detención la predicción del modelo híbrido entrega un valor de 32.22% de llenado total, mientras que la medición laser correspondiente entrega un valor real de 32.70%, lo que corresponde a un error porcentual del 1.49%.

La tabla 2, muestra un resumen de los principales resultados de la validación off-line.

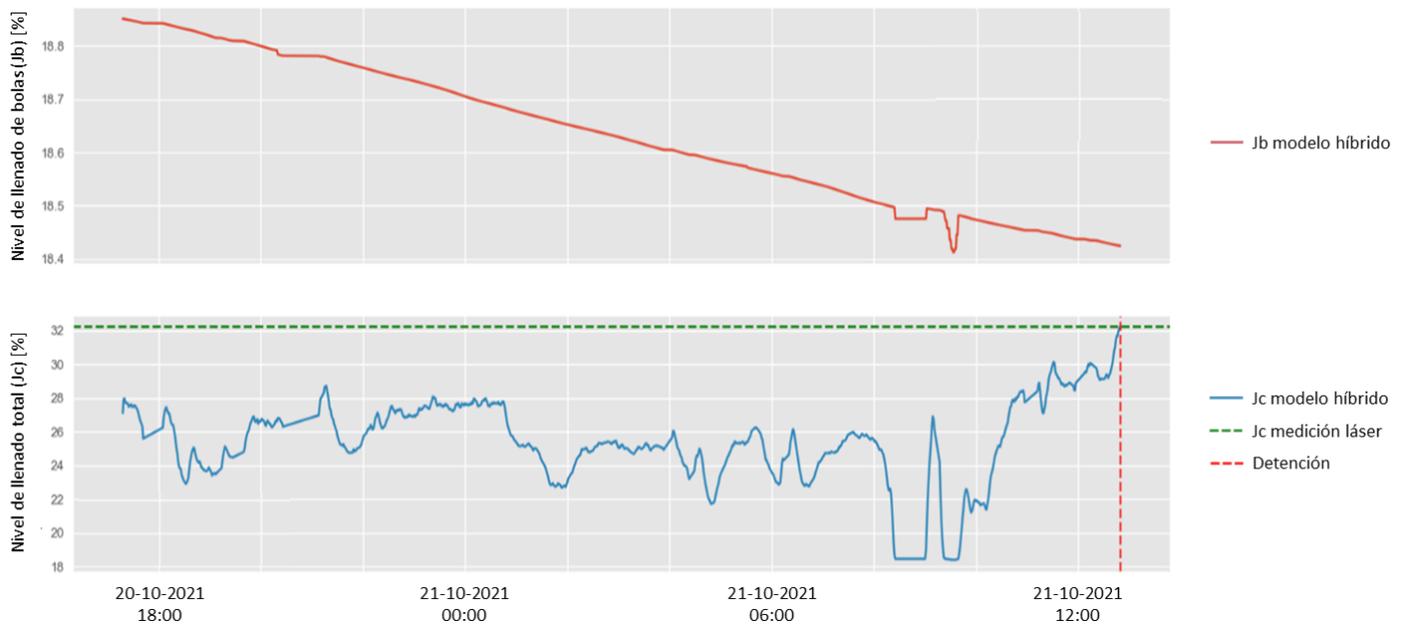


Figura 9: Resultados Jc para periodo 2da detención 21-10-2021.

Tabla 2: Resumen resultados validación off-line.

N°	Parámetro	Medición Modelo	Medición Experimental	Error porcentual
1	Jb	19.53%	19.60%	0.37%
2	Jb	18.75%	18.72%	0.16%
3	Jc	32.22%	32.70%	1.49%

### 3.2. Validación on-line

Como se comenta más arriba, a la fecha la etapa de validación on-line aún está en curso. Al igual que la validación anterior, se requieren mediciones experimentales (láser) para validar los resultados. Se espera que al término del primer semestre del 2022 se tengan los suficientes puntos de medición para realizar las validaciones entre predicciones y valores reales.

## 5. Conclusiones

A lo largo de este trabajo se demuestra que los modelos híbridos son habilitadores de información importante de proceso, los cuales bien calibrados son capaces de generar predicciones de alta precisión. Lo anterior, sumado a su compatibilidad con el despliegue en tiempo real, los convierte en herramientas muy valiosas de inteligencia operacional.

A continuación, se presentan las principales conclusiones del trabajo:

- El modelo híbrido para detección de Jb y Jc en línea presentó excelentes resultados, con errores porcentuales menores al 1.5% en todos los puntos de validación realizados.

- Utilizando herramientas adicionales, como la simulación DEM, es posible aumentar la robustez del modelo híbrido, permitiéndole auto-calibrarse ante cambios en factores externos y desviaciones en la predicción. Esta es la forma en la que el modelo opera integrado en el SAG DTWIN (Gemelos Digital Operacional Molino SAG).
- El desarrollo del modelo híbrido permite su implementación con una arquitectura cloud (en la nube), como también con una arquitectura on-premise (desplegada directamente en los servidores físicos del cliente).
- Finalmente, la precisión y robustez de las predicciones del modelo híbrido de Jb y Jc, permite que sus resultados puedan ser utilizados para determinar otros parámetros importantes como el desgaste de revestimientos, determinación de ángulos de carga, entre otras, tal como se utiliza actualmente en el SAG DTWIN.

### Glosario

- $D$  = Diámetro efectivo molino SAG (m).
- $E$  = Porosidad de carga (fracción).
- $g$  = Aceleración de gravedad ( $m/s^2$ )
- $J_B$  = Fracción volumétrica del SAG ocupada por bolas.
- $J_t$  = Fracción volumétrica del SAG ocupada por carga total.
- $L$  = Largo efectivo SAG (m).
- $L_d$  = Largo sección cónica SAG (m).
- $N_m$  = Velocidad rotación SAG (rev/min).
- $r_i$  = Posición radial superficie interna de carga (m).

- $r_m$  = Radio interno del SAG (sin liners) (m).
- $S$  = Fracción sólidos pulpa descarga.
- $U$  = Fracción intersticios medio de molienda.
- $\theta_S$  = Ángulo de hombro de carga (rad).
- $\theta_T$  = Ángulo de pie de carga (rad).
- $\theta_{TO}$  = Ángulo de superficie piscina pulpa (rad).
- $\rho_o$  = Densidad mineral ( $ton/m^3$ ).
- $\rho_B$  = Densidad bolas de molienda ( $ton/m^3$ ).
- $\emptyset$  = Fracción velocidad crítica.

## Referencias

- Baquedano, D., & Rendón, Á. (2021). On-line calibration of the power model incorporated in SAG mill operational digital twin. . *Procemin Geomet*.
- Baquedano, D., Rendón, Á., & Medina, A. (2021). Modelo híbrido basado en física – AI como habilitador en la predicción del desgaste de revestimientos en molinos SAG. *MAPLA MANTEMIN*.
- Kozicki, J., & Donzé, F. V. (2009). Yade-open DEM: an open-source software using a discrete element method to simulate granular material. *Engineering Computations (26)*.
- Morrell, S. (1992). Prediction of grinding-mill power. *IMM Transactions Section*.
- Morrell, S., Valery, W., Banini, G., & Latchireddi, S. (2001). Developments in AG/SAG mill modelling. *SAG2001 - International Conference on Autogenous and Semiautogenous Grinding Technology*. Vancouver.
- Rendón, Á. (s.f.). Operational Digital Twin: The Foundation for an Optimization as a Service (OaaS) Platform.

### Perfil profesional

Ingeniero de Proyectos Tecnológicos en ME Elecmetal. Aproximadamente 4 años de experiencia en desarrollo de proyectos mineros, análisis de datos y automatización.

César Moscoso

Ingeniero de Proyectos Tecnológicos

ME Elecmetal

cmoscoso@elecmetal.cl

+56953637519

Avenida Andrés Bello 2233, Providencia, Santiago de Chile

### Perfil profesional

Actual Director de ECN Scientific en ECN Automation. Con sobre 20 años de experiencia en proyecto de

automatización y desarrollos tecnológicos para el sector minero.

Álvaro Rendón

Director ECN Scientific

ECN Automation

arendon@ecn.com.mx

+526622156450

Boulevard Paseo Rio Sonora Sur No. 69 Hermosillo, Sonora, México

### Perfil profesional

Actual Director de ME Digital Lab de ME Elecmetal. Con sobre 20 años de experiencia en desarrollo de herramientas analíticas para la industria minera.

Ariel Medina

Director ME Digital Lab

ME Elecmetal

amedina@elecmetal.cl

+56 992230252

Avenida Andrés Bello 2233, Providencia, Santiago de Chile