


UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
DEPARTAMENTO DE INGENIERÍA QUÍMICA Y AMBIENTAL
SANTIAGO – CHILE



**SISTEMA DE CONTROL SUPERVISOR DE OPTIMIZACIÓN
DINÁMICA EN TIEMPO REAL PARA UN MOLINO SAG
CONTROLADO POR UN SISTEMA EXPERTO**

*SUPERVISORY CONTROL SYSTEM VIA DYNAMIC REAL TIME OPTIMIZATION FOR A SAG MILL
CONTROLLED BY AN EXPERT SYSTEM*

CRISTÓBAL IGNACIO MANCILLA DÁVILA

**MEMORIA PARA OPTAR AL TÍTULO DE
INGENIERO CIVIL QUÍMICO**

**DIRECTOR DE TESIS
DR. DANIEL NAVIA LÓPEZ**

**CO-DIRECTOR DE TESIS
DRA. PAULINA QUINTANILLA PÉREZ
MG. CS. RODRIGO BRUNA DURÁN**

9 DE ENERO DE 2024

A Gabriela, Francisco, Ma. Teresa y Marcel

Este trabajo es dedicado a mi familia, por su apoyo y plena confianza.

*También a las personas con quienes tengo lindos recuerdos de mi paso por la
universidad.*

Agradecimientos

Agradecimientos a los profesores y profesoras del Departamento de Ingeniería Química y Ambiental. En especial, al Dr. Daniel N. por su confianza, su guía y apoyo en este proceso, a la Dra. Andrea C. y Dra. Carolyn P. por su disposición y ejemplo.

A los apoyos académicos del departamento.

A mis amigos y amigas, en la universidad y fuera. He coleccionado una gran cantidad de lindos recuerdos en este período.

A mis jefes, Mauricio E. y Rodrigo B. por la confianza y apoyo en el proceso, además de su guía en el desarrollo profesional. También a mis colegas, por su excelente compañía y ejemplo.

Y por sobre todo: a mi familia. Por el impulso constante y la confianza en el proceso.

Contenido

1. Resumen	6
2. Abstract	8
3. Introducción	10
4. Descripción del sistema	11
5. Descripción del sistema de control supervisor	15
5.1. Módulo de optimización	15
5.2. Módulo de estimación de perturbación	16
5.3. Modelo de predicción $\mathcal{H}$	18
5.3.1. Modelo APC $\mathcal{H}_{SAG}^{APC}$	19
5.3.2. Modelo de lazos de control PID $\mathcal{H}_{SAG}^{PID}$	20
5.3.3. Modelo SAG $\mathcal{H}_{SAG}^{NN}$	23
5.3.4. Modelo de perturbación $\mathcal{H}_{dist}$	25
5.4. Sistema de control supervisor de optimización dinámica en tiempo real.....	27
5.5. Procedimiento de optimización	29
6. Resultados y discusión	34
6.1. Casos de estudio.....	35
6.1.1. Escenario 1.....	36
6.1.2. Escenario 2.....	41
6.1.3. Escenario 3.....	46
6.2. Discusión.....	51
7. Conclusiones	53
8. Referencias	54

Índice de figuras

Figura 1: Diagrama de proceso y esquema control de molino SAG clásico.	12
Figura 2: Diagrama del control supervisor.	15
Figura 3: Diagrama de los componentes del modelo de predicción $\mathcal{H}$	18
Figura 4: (A) Gráfico de la respuesta obtenida para el modelo de espacio de estados del lazo PID de tonelaje de alimentación (t/h). (B) Gráfico del error de predicción del lazo.	21
Figura 5: (A) Gráfico de la respuesta obtenida para el modelo de espacio de estados del lazo PID de la velocidad de rotación del molino (%). (B) Gráfico del error de predicción del lazo.	22
Figura 6: (A) Gráfico de la respuesta obtenida para el modelo de espacio de estados del lazo PID de densidad (% sólidos). (B) Gráfico del error de predicción del lazo.	22
Figura 7: Gráfico de la red neuronal recursiva del modelo de presión (psi) del molino. (A) Presenta los resultados obtenidos para los conjuntos de datos de entrenamiento, validación y prueba. (B) Presenta el error de predicción obtenido para cada punto del conjunto de datos.	24
Figura 8: Gráfico del modelo de red neuronal recursiva del consumo de potencia (kW) del molino. (A) Presenta los resultados obtenidos para los conjuntos de datos de entrenamiento, validación y prueba. (B) Presenta el error de predicción obtenido para cada punto del conjunto de datos.	25
Figura 9: Diagrama que representa el horizonte móvil del modelo de predicción.	28
Figura 10: Diagrama del algoritmo para la búsqueda del valor óptimo de y_1^{LIM} para cada iteración de tiempo discreto k	32
Figura 11: Gráfica de los valores de Presión simulados para el Escenario 1.	37
Figura 12: Gráfica de los valores de consumo de Potencia simulados para el Escenario 1.	37
Figura 13: Gráfica de las MVs simuladas: tonelaje, velocidad y densidad para el Escenario 1.	38
Figura 14: Gráfico de los valores de presión simulados para el Escenario 2.	42
Figura 15: Gráfico de los valores de consumo de Potencia simulados para el Escenario 2.	42
Figura 16: Gráfica de las MVs simuladas: tonelaje, velocidad y densidad para el Escenario 2.	43
Figura 17: Gráfico de los valores de presión simulados para el escenario 3.	47
Figura 18: Gráfico de los valores de consumo de energía simulados para el escenario 3.	47
Figura 19: Gráfica de las MVs simuladas: tonelaje, velocidad y densidad.	48

1. Resumen

Los molinos semi-autógenos (SAG) son un tipo de molino comúnmente utilizados, especialmente en la minería del cobre del norte de Chile. Sin embargo, su operación presenta importantes desafíos debido a la imposibilidad de determinar ciertas propiedades de la operación como dureza del mineral o características reológicas de la pulpa en el interior del molino.

Los controladores avanzados de proceso (APC) son herramientas utilizadas para mejoramiento de la operación mediante la selección correcta de *setpoints* a aplicar en las capas de control regulatorio PID. Un ejemplo de estos APC ampliamente utilizado en circuitos de molienda de mineral es el Sistema Experto basado en reglas y lógica difusa.

Un clásico Sistema Experto en un molino SAG manipula los correspondientes *setpoint* de tonelaje de alimentación, de velocidad de giro del molino y de densidad, calculada como % de sólidos de alimentación. La manipulación de *setpoints* responde al objetivo de controlar dos variables: la presión en los descansos y la potencia utilizada por el motor. El APC recopila información actual y pasada de estas variables para determinar estados operacionales, los cuales son categorizados de acuerdo con su grado de criticidad y un conjunto de reglas determina los cambios de *setpoint* a realizar.

El sistema experto tiene por objetivo maximizar el tonelaje de alimentación junto con mantener operación estable y evitar estados críticos de operación. Como el sistema experto no posee capacidad predictiva, su operación depende en gran medida de la correcta definición del límite de las variables controladas (y^{LIM}). Dicho límite es establecido por los operadores y es importante para determinar el área deseada de operación.

El presente trabajo propone sistema de control supervisor que permita detectar cambios en las condiciones de operación de la molienda SAG y predecir la respuesta del proceso y sus sistemas de control regulatorio y avanzado. Con ello, un algoritmo de optimización adecuado redefine el valor del límite de presión y^{LIM} , para mejorar la performance de la operación maximizando el tonelaje alimentado, evitando estados críticos de operación y disminuyendo la duración de estos.

El sistema propuesto consta de un modelo predictivo del proceso de molienda SAG y sus sistemas de control, un módulo de optimización y un módulo de estimación de perturbaciones. El modelo predictivo esta compuesto por: un modelo de simulación del sistema experto, un modelo en el espacio de los estados de los lazos PID, una red neuronal recursiva que es modelo del proceso de molienda SAG y un modelo de perturbación aditiva para enfrentar el error planta-modelo.

El módulo de estimación de perturbaciones utiliza el modelo predictivo para estimar las perturbaciones que minimicen el error de simulación en un horizonte reciente de operación. El módulo de optimización utiliza dicha perturbación y el modelo predictivo para evaluar la operación en un horizonte de predicción.

El sistema fue evaluado mediante la simulación de la operación en 3 Escenarios que utilizan el modelo predictivo como simulación del proceso real y comparando los resultados de simulación cuando el sistema de control supervisor esta activo y no. La diferencia entre los Escenarios evaluados es la forma de la perturbación aditiva utilizada y las características de inicialización de la simulación. La inicialización de la simulación fue realizada utilizando datos de operación reales.

La función objetivo del sistema de control supervisor fue definida en base a conocimiento de los sistemas de control y del proceso en estudio, de manera de buscar el valor mas alto

de límite de presión que permita alimentar el proceso con máximo tonelaje en el horizonte de predicción. Se utilizó el modelo predictivo en instantes de simulación discretos equivalentes a 30 seg de operación y un horizonte de predicción del sistema de control supervisor de 6 instantes discretos.

La configuración de estados operacionales, lógica difusa y reglas dentro del sistema experto, junto con la utilización de la red neuronal para modelamiento del proceso de molienda SAG, hacen necesario utilizar un algoritmo no basado en gradientes para la búsqueda del óptimo dada las no linealidades que entregan estos elementos. El algoritmo evalúa diferentes valores del límite de presión para obtener la mejor respuesta del sistema de acuerdo a la función objetivo. Cuando la búsqueda es exitosa, se aplica el nuevo valor de límite de presión en el sistema experto y se espera hasta el siguiente instante discreto de simulación para repetir la rutina de optimización.

El sistema de control supervisor demostró ser capaz de cumplir con el objetivo de incrementar el tonelaje alimentado, obteniendo mejoras en el promedio de tonelaje alimentado de 3.5% , 0.7% y 0.6% en cada Escenario, cuando el sistema de control supervisor esta activo. Adicionalmente, en todos los Escenarios, se presenta una reducción en el período en que el APC evalúa estados críticos de operación, incluso llegando a reducir el número de eventos críticos ocurridos.

La rutina de optimización propuesta en conjunto con la utilización de un modelo de predicción dinámico para estimar las perturbaciones del proceso, demostró ser una herramienta adecuada para predecir eventos críticos y realizar acciones preventivas. Las acciones preventivas, se traducen en cambios en el límite de presión que llevan al APC a operar con diferentes valores de *setpoint*, reduciendo la variabilidad de la presión y del tonelaje alimentado. Esto esta en línea con los resultados esperados de sistemas de control por modelos en circuitos similares.

La reducción de la variabilidad de la presión tiene potencial efecto secundario de estabilizar la operación general de una planta concentradora al mantener una alimentación de mineral mas estable, reduciendo los efectos adversos en el tamaño de partícula entregado por la etapa de molienda y, por lo tanto, posiblemente afectando positivamente la recuperación en las etapas posteriores de procesamiento de mineral.

2. Abstract

Semi-autogenous (SAG) mills are a commonly used type of mill, especially in copper mining in the North of Chile. However, their operation poses significant challenges due to the impossibility of determining certain operational properties, such as ore hardness or the rheological characteristics of the pulp inside the mill.

Advanced process controllers (APC) are tools used for operational improvement by selection of correct setpoints to apply in the PID regulatory control layer. An example of these APCs, widely used in grinding circuits for mineral processing, is the Expert System based on rules and fuzzy logic.

A classic Expert System in a SAG mill manipulates the corresponding setpoints for ore feed tonnage, the speed of rotation of the mill, and density, calculated as % of solids feed. The manipulation of setpoints is done with the objective of controlling two variables: the pressure of the mill and the power drawn by the motor. The APC uses current and past values of these variables to determine operational states, which are categorized according to their degree of criticality. Then, a set of rules determines the setpoint changes to be applied.

The expert system aims to maximize fresh feed tonnage while maintaining stable operation and avoiding critical operational states. As the expert system lacks predictive capabilities, its operation largely depends on the correct definition of the limit of the controlled variables (y^{LIM}). This limit is set by the operators and is vital to determine the desired area of operation.

This work proposes a supervisory control system that is able to detect changes in the operating conditions of the SAG grinding circuit and predict the response of the process and its regulatory and advanced control systems. With this in mind, an appropriate optimization algorithm redefines the value of the pressure limit y^{LIM} , to improve the operation performance of the APC by maximizing the ore feed tonnage, avoiding critical operational states, and decreasing the duration of these states.

The proposed system is composed of a predictive model of the SAG grinding process and its control systems, an optimization module, and a disturbance estimation module. The predictive model comprises a simulation model of the expert system, a state-space model of the PID loops, a recursive neural network that is a model of the SAG grinding process, and an additive disturbance model to address the plant-model mismatch.

The disturbance estimation module uses the predictive model mentioned to estimate the disturbances that minimize the error when simulating the more recent operation. The optimization module uses such estimated disturbances and the predictive model to evaluate the operation in a prediction horizon.

The proposed supervisory control system is evaluated by simulating the operation in 3 scenarios using the predictive model to represent the real process and comparing the simulation results when the supervisory control system is active and when it is not. The difference between the evaluated scenarios is the form of the additive disturbance used and the characteristics of initialization data for the simulation. The initialization of each simulation was performed using actual operational data.

The objective function of the supervisory control system was defined based on knowledge of the control systems and the process in study. The function aims to find the highest value of the pressure limit that allows feeding the process with maximum tonnage within the prediction horizon. The predictive model was used at discrete simulation instants equivalent

to 30 seconds of operation and the prediction horizon of the supervisory control system is six discrete instants.

The configuration of operational states, fuzzy logic and rules within the expert system, along with the use of the neural network for modeling the SAG grinding process, make it necessary to use a non gradient-based algorithm for the search for the optimal value of the limit, given the nonlinearities provided by these elements. The algorithm evaluates different pressure limit values to obtain the best response of the process according to the objective function. When the search is successful, the new value of the pressure limit is applied in the expert system and the supervisory control system waits until the next discrete instant of simulation to repeat the optimization routine.

The supervisory control system proved capable of meeting the objective of improving tonnage feed, obtaining an average fed tonnage setpoint improvement of 3.5%, 0.7%, and 0.6% in each scenario when the supervisory control system is active. Additionally, in all scenarios, there is a reduction in the total period in which the APC evaluates critical operational states, and the supervisory control can even reduce the number of critical events that occur.

The optimization routine proposed, in conjunction with using a dynamic prediction model to estimate process disturbances, proved to be adequate for predicting critical events and promoting preventive actions. These actions can be changes in the pressure limit that lead the APC to operate with different setpoint values, reducing the variability of the pressure and the fed tonnage. This aligns with the expected results of model-based control systems in similar circuits.

Reducing pressure variability has the potential side effect of stabilizing the overall operation of a mineral concentrator plant. By maintaining a more stable mineral feed, the adverse effects on the particle size delivered by the grinding stage are reduced and, therefore, a positive impact might be seen in the recovery in later stages of mineral processing.

3. Introducción

El procesamiento de minerales depende en gran medida de la molienda para reducir las rocas del chancado a tamaños más pequeños. Es un proceso de alto consumo de energía y, en la mayoría de los casos, el principal ingreso de mineral a la planta de procesamiento. Los circuitos de molienda han sido objeto de estudio debido a su impacto en la potencial ganancia de tonelaje procesado, la reducción del consumo de energía y la alimentación estable o continua a la planta. Wei y Craig (2009) analizan circuitos de molienda y sus características, como las variables medidas, la configuración del circuito, los tipos de molino y otras. En su estudio, los molinos de molienda semiautógena (SAG) demostraron ser uno de los equipos más comúnmente utilizados. Estos son un gran recipiente cilíndrico que gira alrededor de su eje con paredes internas inclinadas, parcialmente lleno de roca mineral y bolas de acero.

Los molinos SAG representan una parte significativa del consumo total de energía en las operaciones de procesamiento de minerales y optimizar su rendimiento es crucial para una operación eficiente y rentable en la industria minera. Los sistemas de control de los molinos SAG deben adaptarse rápidamente a los cambios en las condiciones de operación como se describe en las observaciones realizadas en “la necesidad de un control avanzado de molienda de nivel superior” en Zhou et al., (2016) , especialmente debido a las características constantemente cambiantes del mineral y las posibles condiciones operativas críticas que ocurran. Las estrategias de optimización del *setpoint* (Hodouin, 2011; Zhou et al., 2016) , también llamadas *setpoint control* (Tatjewski, 2006), son un medio eficaz para brindar un mejor rendimiento del proceso. Bouffard (Bouffard, 2015) amplía el estudio de Wei y Craig (2009) , al estudiar los beneficios de este tipo de sistemas de control en los circuitos de molienda, centrándose en el rendimiento de tonelaje ganado, la mejora de la recuperación y otras ganancias operativas como la variabilidad y el consumo de medios de molienda (bolas).

Los sistemas de control avanzado de procesos (APC, por sus siglas en inglés), como detallan Zhou et al. (2016), se pueden clasificar como basados en modelos, como el control predictivo de modelos (MPC) o el control de matriz dinámica (DMC), y basados en inteligencia, como son los sistemas expertos o el control difuso.

Los sistemas de control SAG deben brindar buenas respuestas a los cambios en las condiciones operativas, sobre todo en condiciones críticas como la sobrecarga y el vaciado del molino SAG. Varios factores pueden afectar estas respuestas, lo que puede provocar demoras en las acciones correctivas que pueden dar lugar a situaciones operativas críticas y pérdida de productividad.

Si bien los sistemas expertos carecen de capacidades predictivas dentro de su estrategia, estos pueden manejar situaciones críticas de manera efectiva (Van Zyl et al., 2013) . El conocimiento experto y el control difuso han demostrado ser una solución adecuada, rentable y de rápida implementación para el control en condiciones de alta variabilidad (Bouffard, 2015).

Los sistemas de control experto en molienda SAG suelen controlar la presión o el peso del molino, el consumo de energía del motor y el nivel de ruido (cuando la tecnología de medición está disponible). Manipulan la alimentación de mineral, la adición de agua y la velocidad de rotación del molino para mantener las variables controladas dentro de los límites (Zhou et al., 2016).

El rango permitido de las variables manipuladas lo definen los expertos metalúrgicos, las condiciones de operación y el rendimiento esperado, pero el operador es quien en última

instancia, determina si obedece estos principios. La presión y la potencia máximas de operación se utilizan a menudo como límites altos para el APC, definidos por los principios de protección de los equipos, cumplimiento de los estándares operativos y, en última instancia, mantener de una producción estable en función de la experiencia del operador.

Los operadores a menudo ajustan los límites para las variables controladas, ya sea en respuesta a las condiciones operativas actuales (incluyendo procesos aguas arriba o aguas abajo) o después de evaluar el resultado de operación del sistema de control avanzado automatizado. En el caso de sistemas expertos basados en reglas y control difuso, estos límites afectarán los cálculos y evaluaciones realizados. Por lo tanto, dichos cambios implicarán una modificación en las acciones de control realizadas por el APC. Esto implica que límites mal definidos pueden resultar en una operación subóptima, condiciones cercanas a críticas, activación de sistemas de protección debido a sobrecarga o vaciado y pérdida de rendimiento.

En el presente trabajo se propone un sistema de control supervisor para simular la operación del molino y sus sistemas de control, brindando capacidades de predicción que serán utilizadas para evaluar Escenarios donde varía el límite superior de la presión, cambiando así la respuesta del APC. El sistema supervisor busca maximizar el tonelaje de producción y evitar estados críticos dentro del horizonte de predicción. Como el sistema de control experto ha demostrado ser preciso para la detección de condiciones críticas cuando los límites están correctamente definidos, podemos considerar que la definición de estos límites sea un grado de libertad para optimizar el control del proceso en busca de una operación cercana a la óptima. Al emplear un sistema de control supervisor con capacidades predictivas para detectar cambios en las condiciones operativas, los límites de las variables de control se pueden ajustar en función de las condiciones predichas. Esto puede potencialmente aumentar la producción. En la Sección 4 se describe el molino SAG y su sistema de control. La Sección 5 describe la propuesta de sistema de control supervisor mediante optimización dinámica en tiempo real. La Sección 6 presenta los resultados del sistema probado mediante simulación numérica.

4. Descripción del sistema

El sistema en estudio corresponde a un Molino SAG con una capa de control regulatorio compuesta por controladores PID, y un Sistema Experto como capa de control avanzado de procesos (APC). Las variables controladas (CVs) del APC son:

1. Presión hidráulica en los descansos del molino (y_1). Puede considerarse proporcional al inventario dentro del molino.
2. Consumo de potencia del motor (y_2).

Las variables manipuladas (MVs) del APC son:

1. El valor de referencia (*setpoint*) de la alimentación de mineral al molino (u_1^{SP}).
2. El *setpoint* de la velocidad de rotación del molino (u_2^{SP}), expresado como porcentaje de su valor crítico.
3. El *setpoint* del porcentaje de sólidos (u_3^{SP}), que calcula la adición de agua de acuerdo con el *setpoint* actual de alimentación de mineral.

Estos *setpoint* de las MVs $\mathbf{u}^{SP} = [u_1^{SP}, u_2^{SP}, u_3^{SP}]$ son definidos por el APC y entregados a los controladores PID de la capa de control regulatorio. Estos controladores PID son responsables de llevar el correspondiente valor de proceso (PV) $\mathbf{u} = [u_1, u_2, u_3]$ lo más cerca posible del valor del *setpoint* $\mathbf{u}^{SP}$.




Figura 1: Diagrama de proceso y esquema control de molino SAG clásico. El molino SAG se alimenta con agua y mineral fresco a través de controladores dedicados. PIT corresponde al transmisor de presión del molino y JIT al transmisor de potencia del motor. Estos valores se entregan al APC con sus respectivos límites deseados, el cual entrega los setpoint u^{SP} de las MV. El setpoint del flujo másico de alimentación de mineral fresco u_1^{SP} se entrega al controlador de tonelaje WIC, el setpoint de la velocidad de rotación del molino u_2^{SP} al controlador de velocidad del motor SIC, y el setpoint de la densidad u_3^{SP} , calculado como % de sólidos alimentados, se entrega al controlador de densidad DIC. El controlador de densidad trabaja en cascada con el controlador de flujo de agua FIC y el transmisor FT, y utiliza los valores actuales del WIC para su cálculo.

El APC busca maximizar el rendimiento de tonelaje (*setpoint* de la alimentación de mineral) al proceso de molienda mientras mantiene una operación estable y evita condiciones críticas como mediciones de presión o potencia altas. El operador o supervisor metalúrgico determinará los valores máximos y mínimos permitidos para los *setpoint* de las MV $u^{SP}_{min}^{max}$. Esto generalmente se hace en función de un objetivo económico de rendimiento de mineral procesado, disponibilidad de mineral, agua y reactivos aguas arriba o aguas abajo, límites físicos de los equipos y estabilidad de la operación, entre otros factores.

Los límites altos de las CVs (y^{LIM}) también son definidos por los operadores o el supervisor metalúrgico. Usualmente para mantener la estabilidad del proceso cuando el APC está en control y para protección del equipo y personal de operación, ya que consideran limitaciones mecánicas y/o eléctricas.

El APC está diseñado para detectar cambios en las condiciones operativas, como variaciones en las características del mineral o el comportamiento de la pulpa mezcla de mineral y agua. Utiliza información de las lecturas de presión y potencia para identificar estos cambios. Si la eficiencia de molienda disminuye debido a estos cambios, esto podría provocar un aumento de la presión a medida que el material se acumula dentro del molino

y, eventualmente, una disminución del consumo de energía debido a la ineficacia en la elevación de la carga (Cleary y Owen, 2018; McClure et al., 2014). Cuando se detectan cambios, el APC realiza los ajustes necesarios para prevenir o escapar de cualquier condición crítica. Sin embargo, el APC carece de la capacidad de predicción para responder de manera preventiva cuando las condiciones operativas están cambiando, ya que la tasa de cambio de los valores es el único estimador de posibles valores futuros de las CVs.

Mientras está en control, el APC evalúa los valores actuales y pasados para definir los *setpoint* u^{SP} . El APC tiende a priorizar el uso del *setpoint* de porcentaje sólido (u_3^{SP}) como la variable manipulada principal para promover una respuesta en las variables controladas y , seguido por el uso del *setpoint* de la velocidad de rotación del molino (u_2^{SP}). Como último recurso suele estar el *setpoint* de tonelaje de alimentación (u_1^{SP}). Aunque la disminución de u_1^{SP} suele generar una respuesta más rápida en los valores de las CVs, es contrario al objetivo económico de la planta concentradora, ya que un menor tonelaje ingresado al molino SAG reducirá el rendimiento general de tonelaje en la planta (Festa et al., 2009; METZNER et al., 2009; Van Zyl et al., 2013).

El APC Sistema Experto se basa en lógica difusa y reglas, de manera similar a la implementación de METZNER et al., (2009) y Van Zyl et al., (2013). Las variables principales son 6: los valores de las dos CVs mencionadas anteriormente $y := [y_1, y_2]$, la tasa de cambio calculadas para cada una y la correspondiente aceleración calculada. Estas variables proporcionan al APC información para determinar un valor difuso para los estados "Muy alto", "Alto", "Ok" y "Bajo" de las CVs, al comparar la proximidad del valor medido de y con su límite alto $y^{LIM} := [y_1^{LIM}, y_2^{LIM}]$. Luego, utilizando uno o más de los valores difusos, el APC determina los Estados Operacionales, categorizados como "Crítico", "Alto", "Ok" o "Bajo" (Van Zyl et al., 2013). Cada Estado tiene un conjunto de reglas y lógica difusa para calcular los cambios propuestos en los *setpoint* u^{SP} de las MVs, para mantener la estabilidad y el mejor rendimiento del proceso.

Los estados Críticos darán lugar a cambios más agresivos en los *setpoint*, mientras que los estados operacionales de "Presión Alta" realizan cambios agresivos pero evitan la manipulación del *setpoint* de tonelaje si es posible. Este comportamiento se detalla con más detalle en la Sección 5.3.1. Como y^{LIM} se utiliza para comparar con los valores medidos al determinar los estados de las CVs y los estados operacionales, los cambios en los límites y^{LIM} afectan el funcionamiento general del APC y la activación de los estados.

Debido a lo anterior, límites mal definidos pueden hacer que el APC responda más lento de lo deseado en casos cuando aumenta la presión y ocurre una condición de sobrecarga, pero es detectada después de que sea posible realizar acciones preventivas. En tales situaciones críticas, el APC recurre a ajustes agresivos en el *setpoint* de alimentación de tonelaje, ya que entrega la respuesta más rápida en y . Límites bien definidos, modificados según la dureza del mineral o la eficiencia de molienda, pueden permitir al APC priorizar las acciones en otras MVs antes de recurrir a la reducción de tonelaje debido a la sobrecarga, acción que es contraria al objetivo económico del proceso. Sin embargo, la reducción agresiva del *setpoint* de tonelaje podría ser la única acción que evite una parada de emergencia, al menos hasta que se controle la situación.

Actualmente, sólo después de que los operadores o supervisores detecten dichos cambios en las características del mineral o la eficiencia de molienda se pueden cambiar los límites y^{LIM} , ya que ellos son los responsables de realizar el cambio. Por lo tanto, si un sistema de control supervisor predice con precisión las condiciones de operación en el corto plazo, y es capaz de detectar cuándo se alcanzará un estado crítico o ha cambiado la eficiencia de molienda, entonces se puede modificar el límite alto de la presión y potencia para ajustar la

respuesta del APC. Utilizando los límites como un grado de libertad para una optimización de la operación futura. Este ajuste proactivo puede potencialmente evitar o minimizar los efectos adversos en las CVs, la potencial reducción en el tonelaje alimentado y la ocurrencia de estados críticos.

5. Descripción del sistema de control supervisor

El sistema de control supervisor propuesto se compone de dos módulos y un modelo de predicción, como se muestra en la Figura 2:

- Un módulo de optimización que evalúa estimaciones a corto plazo del modelo de predicción para proponer el mejor límite alto posible para la presión. (Sección 5.1)
- Un módulo de estimación de perturbaciones para garantizar la precisión de las predicciones del modelo (Sección 5.2).
- Un modelo de predicción que considera el APC, la capa de control básica, el proceso de molienda SAG y un modelo de perturbación (Sección 5.3). Todos estos proporcionan estimaciones de valores futuros cercanos de y utilizando valores anteriores de y, u^{SP}, u y un valor dado de y^{LIM} .




Figura 2: Diagrama del control supervisor. En cada iteración k , se estima una perturbación utilizando datos históricos y los modelos de predicción, de modo que el módulo de optimización pueda determinar y^{LIM} óptimos para aplicar en el proceso.

5.1. Módulo de optimización

El módulo de optimización (MO) utiliza el modelo de predicción para simular una serie de instantes futuros, como se describe en el trabajo de Navia et al., (2021), cada instante discreto equivale a 30 segundos de operación en tiempo real. Considera el resultado del módulo de estimación de perturbaciones para tener en cuenta el desajuste planta-modelo.

Si la predicción no proporciona el máximo rendimiento de tonelaje (*setpoint* de tonelaje igual a su límite alto) en todos los instantes futuros estimados, entonces el MO realiza una búsqueda de un valor del límite alto de presión que garantice el máximo rendimiento de tonelaje posible y no sobrecargue el molino en el futuro cercano.

Para ello, un algoritmo busca un valor óptimo del límite superior de la presión (y_1^{LIM}) que proporcione la mejor operación del molino SAG considerando el resultado determinado por el modelo de predicción. Estima en el instante discreto k , los valores medidos futuros de las CV ($\hat{y}_{k+i|k}^{MEAS}$) y MV ($\hat{u}_{k+i|k}$) utilizando los modelos de predicción para $\hat{y}$ y $\hat{u}$. Esto se hace para cada instante en el futuro $i := 1, \dots, N$, donde N es el horizonte de predicción.

La optimización buscará el valor de y^{LIM} para minimizar una función objetivo $\mathcal{F}$ adecuada, que considere las estimaciones futuras mas próximas de $\hat{u}$, $\hat{u}^{SP}$ y $\hat{y}^{MEAS}$ como se presenta en la Ecuación (1), donde $(\hat{\cdot})$ indica que la variable se estima utilizando el modelo de predicción $\mathcal{H}$ y m es el número de datos previos necesarios para el modelo.

$$\min_{\mathbf{y}^{LIM} \in \mathcal{Y}^{LIM}} \mathcal{F}(\hat{\mathbf{y}}_{k,N}^{MEAS}, \hat{\mathbf{u}}_{k,N}^{SP}, \hat{\mathbf{u}}_{k,N})$$

(1)

s. t:

$$\mathcal{H}(\mathbf{y}_{k,N+m}^{MEAS}, \mathbf{u}_{k,N+m}^{SP}, \mathbf{u}_{k,N+m}, \mathbf{y}_{k,N}^{LIM}, \xi_{k,N}) = 0$$

where:

$$\hat{\mathbf{y}}_{k,N}^{MEAS} := [\hat{\mathbf{y}}_{k+N|k}^{MEAS}, \dots, \hat{\mathbf{y}}_{k+1|k}^{MEAS}] \in \mathbb{R}^{n_y \times N}$$

$$\mathbf{y}_{k,N+m}^{MEAS} := [\mathbf{y}_{k+N|k}^{MEAS}, \dots, \mathbf{y}_{k+1|k}^{MEAS}, \mathbf{y}_k^{MEAS}, \dots, \mathbf{y}_{k-(m-1)}^{MEAS}] \in \mathbb{R}^{n_y \times (N+m)}$$

$$\hat{\mathbf{u}}_{k,N}^{SP} = [\hat{\mathbf{u}}_{k+N|k}^{SP}, \dots, \hat{\mathbf{u}}_{k+1|k}^{SP}] \in \mathbb{R}^{n_u \times N}$$

$$\mathbf{u}_{k,N+m}^{SP} := [\hat{\mathbf{u}}_{k+N|k}^{SP}, \dots, \hat{\mathbf{u}}_{k+1|k}^{SP}, \mathbf{u}_k^{SP}, \dots, \mathbf{u}_{k-(m-1)}^{SP}] \in \mathbb{R}^{n_u \times (N+m)}$$

$$\mathbf{u}_{k,N} = [\mathbf{u}_{k+N|k}, \dots, \mathbf{u}_{k+1|k}] \in \mathbb{R}^{n_u \times N}$$

$$\mathbf{u}_{k,N+m} := [\hat{\mathbf{u}}_{k+N|k}, \dots, \hat{\mathbf{u}}_{k+1|k}, \mathbf{u}_k, \dots, \mathbf{u}_{k-(m-1)}] \in \mathbb{R}^{n_u \times (N+m)}$$

$$\xi_{k,N} := [\xi_{k+1|k}, \dots, \xi_{k+N|k}] \in \mathbb{R}^{n_y \times N}$$

$\mathcal{Y}^{LIM}$ is the allowed search space of $\mathbf{y}^{LIM}$

$$\mathbf{y}_{k,N}^{LIM} := [\mathbf{y}_{k+N|k}^{LIM}, \dots, \mathbf{y}_{k|k}^{LIM}] \in \mathbb{R}^{n_y \times N}$$

$\mathbf{y}_{k+i+1|k}^{LIM}$ se considera constante en el horizonte de predicción, como se describe en la Ecuación (2):

$$\forall i = 0, \dots, (N-1) := \mathbf{y}_{k+i+1|k}^{LIM} = \mathbf{y}_{k+1|k}^{LIM} = \mathbf{y}^{LIM} \quad (2)$$

La idea es encontrar la presión máxima permitida (límite superior), la cual proporcione el máximo rendimiento de tonelaje y evite condiciones críticas, como la sobrecarga, en el molino SAG dentro de los siguientes instantes simulados. El límite superior se cambia si se encuentra con éxito un nuevo límite superior que satisfaga las condiciones o, en caso contrario, no se realizan cambios. Esto se basa en el hecho de que el límite superior se utiliza como valor límite del área de operación permitida y de la condición casi-crítica donde el molino SAG no puede procesar de manera eficiente la carga contenida en su interior.

5.2. Módulo de estimación de perturbación

Para proporcionar una estimación precisa de las variables, se utiliza un módulo de estimación de perturbaciones (MEP) que toma en cuenta el desajuste entre las estimaciones del modelo de predicción y las mediciones reales del proceso. Para ello, se utiliza el MEP utilizando valores pasados conocidos $\mathbf{y}_{k-t}^{MEAS}$, $\mathbf{u}_{k-t}^{SP}$, $\mathbf{u}_{k-t}$ para estimar el valor de las perturbaciones $\xi_{k,n_e} := [\xi_{k-n_e+1|k}, \dots, \xi_{k-1|k}, \xi_{k|k}]$ que minimizan el error de predicción del modelo, resolviendo el Problema (3), donde n_e es el número de instantes previos a k utilizados para la minimización:

$$\min_{\xi_{k,n_e}} \sum_{t=0}^{n_e-1} (\hat{y}_{k-t|k}^{MEAS} - y_{k-t|k}^{MEAS})^2 \quad (3)$$

s. t.:

$$\mathcal{H}(Y_{k-t,n_e+m}^{MEAS}, U_{k-t,n_e+m}^{SP}, U_{k-t,n_e+m}, Y_{k-t,n_e}^{LIM}, \xi_{k,n_e}) = 0$$

t indica los instantes de tiempo discretos anteriores a k , y $\hat{y}_{k-t|k}^{MEAS}$ es el valor de las CVs en el instante $k - t$ estimado utilizando toda la información disponible en el instante k . Se utiliza un estimador con horizonte móvil para realizar n_e predicciones hasta el instante k , y se compararan con los valores medidos.

La perturbación se considera como un modelo aditivo según se muestra en la Ecuación (4), que relaciona una medida $\hat{y}_{k-t|k}^{MEAS}$ con la perturbación ξ y los valores $\hat{y}$ utilizado por el modelo del proceso:

$$\hat{y}_{k-t|k}^{MEAS} = \hat{y}_{k-t|k} + \xi_{k-t} \quad (4)$$

$\mathcal{H}$ estima valores de $\hat{y}_{k-t|k}^{MEAS}$ con la perturbación siendo el desajuste respecto de un valor modelado $\hat{y}_{k-t|k}$. Esta perturbación se considera constante a lo largo del horizonte de estimación n_e como se expresa en la Ecuación (5):

$$\forall t = 0, \dots, n_e - 1 := \xi_{k-t} = \xi_k \quad (5)$$

En cada instante de tiempo discreto k , se utiliza una ventana de n_e datos de instantes anteriores para determinar la perturbación ξ_k que mejor estima los valores de las mediciones del modelo de predicción $\hat{y}_{k-t|k}^{MEAS}$ en los instantes $k - t$, con $t = 0, \dots, (n_e - 1)$, comparado con valores históricos reales medidos y_{k-t}^{MEAS} usando la Ecuación (4) y la Ecuación (5) del Problema (3). El problema de identificación resuelto en el MEP se expresa ahora como Problema (6):

$$\min_{\hat{\xi}_k} \sum_{t=0}^{n_e-1} (\hat{y}_{k-t|k}^{MEAS} - y_{k-t}^{MEAS})^2 \quad (6)$$

s. t.:

$$\mathcal{H}(Y_{k-t,n_e+m}^{MEAS}, U_{k,n_e+m}^{SP}, U_{k,n_e+m}, Y_{k-t,n_e}^{LIM}, \hat{\xi}_k) = 0$$

donde:

$$Y_{k-t,n_e+m}^{MEAS} := [\hat{y}_{k|k}^{MEAS}, \dots, \hat{y}_{k-(n_e-1)|k}^{MEAS}, y_{k-n_e}^{MEAS}, y_{k-n_e-1}^{MEAS}, \dots, y_{k-n_e-(m-1)}^{MEAS}] \in \mathbb{R}^{n_y \times (n_e+m)}$$

$$U_{k,n_e+m}^{SP} := [u_k^{SP}, \dots, u_{k-(n_e-1)}^{SP}, u_{k-n_e}^{SP}, u_{k-n_e-1}^{SP}, \dots, u_{k-n_e-(m-1)}^{SP}] \in \mathbb{R}^{n_u \times (n_e+m)}$$

$$U_{k,n_e+m} := [u_k, \dots, u_{k-(n_e-1)}, u_{k-n_e}, u_{k-n_e-1}, \dots, u_{k-n_e-(m-1)}] \in \mathbb{R}^{n_u \times (n_e+m)}$$

5.3.1. Modelo APC $\mathcal{H}_{SAG}^{APC}$

El APC modelado es un Sistema Experto basado en lógica difusa y reglas operacionales. Está modelado utilizando Python 3.7, representando con precisión el proceso de toma de decisiones del APC en estudio. Se utilizan los valores actuales y pasados de las CVs, su tasa de cambio se calcula como la diferencia de valores en una cierta cantidad de tiempo y la aceleración se calcula como la diferencia de la tasa de cambio correspondiente en un cierto período. En el modelo discreto utilizado, la cantidad de tiempo necesaria para estos cálculos está representada por un número p_y de instantes para las CVs, p_{SP} instantes para los *setpoint* de las MV y p_u para los PV de las MV. Estas variables pasan por un sistema de inferencia difuso con funciones de pertenencia que definen “valores difusos”. Estos se utilizan luego con un conjunto definido de lógicas discreta y difusa más un conjunto de reglas basadas en eventos para asignar un cierto “estado operacional” del molino SAG.

Los estados operacionales se clasifican como “Crítico”, “Presión Alta”, “Presión Ok” o “Presión baja” y se colocan en un orden jerárquico. Cada estado tiene acciones asociadas que se deben aplicar en las variables manipuladas (MV). Luego, utilizando el cálculo de Sugeno (Sugeno, 1985), el APC determinará un cambio de *setpoint* que se implementará.

Cada categoría incluye varios estados operacionales que dependen de las condiciones de las CVs evaluadas. Los estados Críticos y de Presión Alta se resumen en la Tabla 1, ya que son responsables de las acciones para evitar o escapar de las condiciones críticas. Esto se hace mediante cambios agresivos del *setpoint* y la inclusión de cambios de *setpoint* de tonelaje cuando sea necesario.

Categoría	Nombre del Estado operacional	Posibles cambios de <i>setpoint</i>					
		u_3^{SP}		u_2^{SP}		u_1^{SP}	
		<i>dism</i>	<i>aum</i>	<i>dism</i>	<i>aum</i>	<i>dism</i>	<i>aum</i>
Crítico	Sobrecarga	✓				✓	✓
	Potencia Crítica		✓			✓	✓
	Presión Crítica	✓				✓	✓
Presión Alta							
	Presión Alta y Aumentando, Potencia Alta	✓					✓
	Presión Alta y Aumentando, Potencia no Alta	✓		✓		✓	✓
	Presión Alta y no Aumentando, Potencia Alta	✓	✓			✓	✓
	Presión Alta y no Aumentando, Potencia no Alta	✓				✓	✓

Tabla 1: Estados operacionales categorizados como Crítico o Presión Alta. Sus nombres describen otras variables analizadas. Dependiendo de reglas específicas y lógica difusa, cada estado determinará un cambio de *setpoint* para una o más de las MVs. Los cambios de aumento y disminución del *setpoint* no se pueden realizar simultáneamente, el que se aplique dependerá de evaluaciones específicas para cada caso.

La Ecuación (7) representa el modelo del APC que calcula los *setpoint* u_{k+1}^{SP} para el instante $k + 1$ siguiente:

$$\hat{u}_{k+1}^{SP} = \mathcal{H}_{SAG}^{APC} \left(\mathbf{y}_{k,p_y}^{MEAS}, \mathbf{u}_{k,p_{SP}}^{SP}, \mathbf{u}_{k,p_u}, \mathbf{y}^{LIM}, \mathbf{u}_k^{SP|_{min}^{max}} \right) \quad (7)$$

y^{LIM} son los límites de las CVs tal como se definen en la Ecuación (2). u_{k+1}^{SP} es el *setpoint* que se implementará en el siguiente instante, si el máximo y el mínimo de los *setpoint* $u_k^{SP|_{min}^{max}}$ lo permiten.

Se puede observar que el APC utilizará los valores actuales y pasados de las CVs y MVs para determinar el siguiente valor u^{SP} que se implementará. En la simulación en lazo cerrado, se utiliza un contador i para el instante de tiempo discreto en evaluación. El contador determinará el número de estimaciones o datos históricos reales a utilizar. El modelo en lazo cerrado se representa mediante la Ecuación (8):

$$\hat{u}_{k+i+1}^{SP} = \mathcal{H}_{SAG}^{APC} \left(Y_{k,p_y,i}^{MEAS}, U_{k,p_{SP},i}^{SP}, U_{k,p_u,i}, y_{k+i}^{LIM}, u_{k+i}^{SP|_{min}^{max}} \right) \quad (8)$$

donde:

$$Y_{k,p_y,i}^{MEAS} := [\hat{y}_{k+i|k}^{MEAS}, \dots, \hat{y}_{k+1|k}^{MEAS}, y_k^{MEAS}, \dots, y_{k-(p_y-i-1)}^{MEAS}] \in \mathbb{R}^{n_y \times (p_y+1)}$$

$$U_{k,p_{SP},i}^{SP} := [\hat{u}_{k+i|k}^{SP}, \dots, \hat{u}_{k+1|k}^{SP}, u_k^{SP}, \dots, u_{k-(p_{SP}-i-1)}^{SP}] \in \mathbb{R}^{n_u \times (p_{SP}+1)}$$

$$U_{k,p_u,i} := [\hat{u}_{k+i|k}, \dots, \hat{u}_{k+1|k}, u_k, \dots, u_{k-(p_u-i-1)}] \in \mathbb{R}^{n_u \times (p_u+1)}$$

En la Ecuación (8), para cada estimación $\hat{u}^{SP}$ de los *setpoint*, se necesitan los valores anteriores de u e y^{MEAS} , ya sea como datos históricos reales (en $i = 0$) ó como estimaciones (para $i > 0$). y_{k+i}^{LIM} y $u_{k+i}^{SP|_{min}^{max}}$ se consideran constantes a lo largo del horizonte de predicción.

5.3.2. Modelo de lazos de control PID $\mathcal{H}_{SAG}^{PID}$

El desempeño de los lazos PID puede afectar el funcionamiento del modelo predictivo del molino SAG porque la respuesta del modelo del molino SAG dependerá de la respuesta dinámica de cada lazo PID. Esto implica que, dependiendo de la dinámica de la capa de control regulatorio, $\hat{u}_{k+i|k}^{SP}$ puede ser diferente a $\hat{u}_{k+i|k}$ para cada tiempo discreto i simulado. Para tener esto en consideración, se utiliza un modelo de representación en el espacio de estados para cada lazo PID. Estos modelos son ajustados utilizando datos históricos de planta y se estiman los estados para cada instante discreto de simulación, de manera que puedan representar correctamente los valores iniciales del lazo.

Utilizando la herramienta *System Identification Tool* de MATLAB®, se ajusta el modelo de lazos PID de tonelaje de alimentación, la velocidad de giro del molino y el cálculo del porcentaje de sólidos. Se utilizaron *setpoint* y valores de proceso para los conjuntos de datos de entrenamiento y validación, mientras se itera para obtener los mejores valores para el orden de la función de espacio de estados para cada variable. El tiempo de muestreo utilizado para el entrenamiento es el original de 5 s en el conjunto de datos; luego, se utilizó las funcionalidades de las herramientas de MATLAB para volver a muestrear el modelo resultante a un tiempo discreto equivalente de 30 s.

La Ecuación (9) representa una función de espacio de estados generalizada para un sistema discreto:

$$\begin{aligned} x_{ss\delta+1} &= A \cdot x_{ss\delta} + B \cdot u_{ss\delta+1}^{SP} + K \cdot \varepsilon_{ss} \\ u_{ss\delta+1} &= C \cdot x_{ss\delta} + D \cdot u_{ss\delta+1}^{SP} + \varepsilon_{ss} \end{aligned} \quad (9)$$

$$x_{ss\delta=-\ell} = x_0$$

Donde x_{ssk} es la variable de estado en el instante δ . u^{sp} y u son la entrada y la salida del modelo, en este caso el *setpoint* y el valor de proceso (PV) del lazo de control, respectivamente. El orden ℓ de un modelo de espacio de estados específico determinará, en este caso, el número de estados previos necesarios para representar con precisión la dinámica del modelo.

Cuando se entrena con el conjunto de datos disponible, tanto con los datos de entrenamiento como con los de prueba, el lazo de tonelaje de alimentación (u_1) es de orden 4 y los resultados se muestran en la Figura 4, la velocidad de rotación del molino (u_2) es de orden 3 y los resultados se muestran en la Figura 5. Por último, el porcentaje de sólidos (u_3) es de orden 2 y utiliza el *setpoint* y el valor de proceso del porcentaje de sólidos, junto al valor de proceso del tonelaje de alimentación, que se requiere para el cálculo de porcentaje de sólidos. Los resultados para el lazo de porcentaje de sólidos se muestran en la Figura 6.

El error obtenido para cada lazo se presenta en la Tabla 2:

Modelo	Error promedio	RMSE	Valor R
Tonelaje	$8.4 \times 10^{-3} \pm 0.7 \%$	18.3 t/h	0.97466
Velocidad	$-1.6 \times 10^{-5} \pm 0.08 \%$	0.1 %	0.99955
Densidad	$2.0 \times 10^{-4} \pm 0.2 \%$	0.1 %	0.99512

Tabla 2: Resultados de precisión y descripción de errores de los modelos de espacio de estados entrenados para tonelaje, velocidad y densidad. El error promedio, el error cuadrático medio (RMSE) y el coeficiente de correlación (valor R) se calculan utilizando el conjunto de datos completo.




Figura 4: (A) Gráfico de la respuesta obtenida para el modelo de espacio de estados del lazo PID de tonelaje de alimentación (t/h). (B) Gráfico del error de predicción del lazo.




Figura 5: (A) Gráfico de la respuesta obtenida para el modelo de espacio de estados del lazo PID de la velocidad de rotación del molino (%). (B) Gráfico del error de predicción del lazo.




Figura 6: (A) Gráfico de la respuesta obtenida para el modelo de espacio de estados del lazo PID de densidad (% sólidos). (B) Gráfico del error de predicción del lazo.

La función de transferencia del modelo de espacio de estados para el tonelaje de alimentación $\hat{u}_{1k+1}$ se presenta en la Ecuación (10), la Ecuación (11) representa la velocidad de rotación y la Ecuación (12) representa el lazo de porcentaje de sólidos:

$$\hat{u}_{1k+1} = \mathcal{H}_{SAG}^{PID_1} \left(u_{1k,\ell_1}, u_{1k,\ell_1}^{SP}, \varepsilon_1, x_{1k=-\ell_1} \right) \quad (10)$$

$$\hat{u}_{2k+1} = \mathcal{H}_{SAG}^{PID_2} \left(u_{2k,\ell_2}, u_{2k,\ell_2}^{SP}, \varepsilon_2, x_{2k=-\ell_2} \right) \quad (11)$$

$$\hat{u}_{3k+1} = \mathcal{H}_{SAG}^{PID_3} \left(u_{3k,\ell_3}, u_{3k,\ell_3}^{SP}, \varepsilon_3, x_{3k=-\ell_3}, u_{1k,\ell_1} \right) \quad (12)$$

donde ε es un error aditivo constante calculado para el modelo, ℓ es el orden del modelo y el vector $\mathbf{u}_{k,\ell} := [\mathbf{u}_k, \mathbf{u}_{k-1}, \dots, \mathbf{u}_{k-\ell}]$ representa los valores anteriores de $\mathbf{u}$ utilizados para determinar $\mathbf{u}_{k+1}$.

En el presente trabajo, debido a la dinámica lenta de la respuesta de tonelaje del sistema en general y la dinámica rápida de las rpm y el porcentaje de sólidos, solo se utiliza la función de tonelaje. Mientras tanto, las rpm y los sólidos se consideran como lazos PID de respuesta rápida que siempre harán que el valor del proceso $\mathbf{u}$ alcance el *setpoint* $\mathbf{u}^{SP}$ en el siguiente instante de tiempo discreto $k + 1$.

El sistema APC determina en cada instante de tiempo discreto k , a partir de la Ecuación (8), los *setpoint* $\hat{\mathbf{u}}_{k+1}^{SP}$ para implementar en el siguiente instante, $k + 1$. La Ecuación (13) representa el modelo de los lazos PID que estimarán el valor de la PV $\hat{\mathbf{u}}_{k+i+1}$, donde $i + 1$ es el número de instantes predichos. Para $i = 0$, se utilizan solo datos históricos reales de $\mathbf{u}_{k,\ell}$ y $\mathbf{u}_{k,\ell}^{SP}$, y a medida que aumenta i , se utilizan los valores estimados de $\hat{\mathbf{u}}_{k+i}$ hasta el horizonte de predicción N .

$$\hat{\mathbf{u}}_{k+i+1|k} = \mathcal{H}_{SAG}^{PID} \left(\mathbf{u}_{k,\ell,i}, \mathbf{u}_{k,\ell,i}^{SP}, \varepsilon, \mathbf{x}_{k=-\ell} \right) \quad (13)$$

donde $i = 0, \dots, (N - 1)$.

5.3.3. Modelo SAG $\mathcal{H}_{SAG}^{NN}$

La dinámica compleja del molino SAG es un desafío para ser modelada, ya que múltiples factores afectan el movimiento del material dentro del molino, incluyendo la distribución de tamaño, la reología de pulpa y la composición de los minerales. Es por esta razón que un modelo de red neuronal recursiva (RNN) nos permite simular valores utilizando la información disponible. La RNN puede ser entrenada para capturar la dinámica compleja del proceso como un modelo de caja negra, donde se entrega la información conocida y se obtiene el mejor ajuste del modelo. Se entrenaron y validaron dos redes neuronales recursivas con el la herramienta *Neural Net Time Series* en MATLAB®, para proporcionar una relación precisa de los efectos de las entradas $\mathbf{u}$ en las salidas $\mathbf{y}$, con una RNN para cada salida.

El modelo del molino SAG se desarrolló utilizando datos de un período de 6 meses de funcionamiento de un molino con APC en el norte de Chile. Los datos se adquirieron en intervalos de 5 segundos y luego se filtraron para reducir la cantidad de puntos de datos utilizando un intervalo de 30 segundos y con las siguientes condiciones:

- Señal de funcionamiento del molino SAG activa (i.e. SAG ON)
- Tonelaje de alimentación superior a 1,800 t/h
- Porcentaje de sólidos superior al 72%
- Sistema experto ON

Este conjunto de condiciones representa una operación a considerar como normal y evita utilizar datos de etapas de arranque o apagado. Con esto, se obtuvo un conjunto de datos

de operación continua de 68 h que se utilizó para entrenar la RNN. El conjunto de 8,156 datos resultante se dividió en conjuntos de entrenamiento, validación y prueba.

Se probaron diferentes configuraciones de la RNN y se evaluaron hasta obtener la mejor respuesta: esto considera una capa oculta, 2 neuronas en cada red neuronal y una ventana de datos de 12 puntos. Utilizando el algoritmo “Levenberg-Marquart” por defecto en MATLAB, se probaron varios pesos y estructura de la RNN hasta obtener la mejor respuesta. Esto es, cuando el jacobiano del valor de rendimiento ya no aumenta a medida que aumenta un valor adaptativo.

Las Figura 7 y Figura 8 muestran los resultados de la mejor respuesta encontrada de la red neuronal para la Presión y la Potencia, respectivamente. Utilizando el conjunto de datos de entrenamiento, validación y prueba, se analiza el error y sus principales resultados se presentan en la Tabla 3. Con estos resultados se observa que las redes neuronales presentadas describen con precisión el modelo de Presión y Potencia, con un error cercano a cero y el coeficiente de correlación demuestra una alta precisión en la predicción del modelo.

Modelo	Error promedio	RMSE	Valor R
Presión	$-1.3 \times 10^{-5} \pm 0.1 \%$	0.4 <i>psi</i>	0.99988
Potencia	$5.5 \times 10^{-4} \pm 0.2 \%$	15.5 <i>kW</i>	0.99987

Tabla 3: Resultados de precisión y descripción de errores de la RNN entrenada para la presión del molino y el consumo de potencia del motor. El error promedio, el error cuadrático medio (RMSE) y el coeficiente de correlación (valor R) se calculan utilizando el conjunto de datos completo.




Figura 7: Gráfico de la red neuronal recursiva del modelo de Presión (psi) del molino. (A) Presenta los resultados obtenidos (Output) vs esperados (Target) para los conjuntos de datos de entrenamiento (Training), validación (Validation) y prueba (Test). (B) Presenta el error de predicción obtenido para cada punto del conjunto de datos.




Figura 8: Gráfico del modelo de red neuronal recursiva del consumo de Potencia (kW) del molino. (A) Presenta los resultados (Output) vs esperados (Target) para los conjuntos de datos de entrenamiento (Training), validación (Validation) y prueba (Test). (B) Presenta el error de predicción obtenido para cada punto del conjunto de datos.

El modelo de la red neuronal recursiva resultante del molino SAG está representado por la Ecuación (14):

$$\hat{y}_{k+i+1|k} = \mathcal{H}_{SAG}^{NN}(\mathbf{y}_{k,m,i}, \mathbf{u}_{k,m,i}), \quad i = 0 \dots (N - 1) \quad (14)$$

donde:

$$\mathbf{Y}_{k,m,i} := [\hat{y}_{k+i|k}, \dots, \hat{y}_{k+1|k}, \mathbf{y}_k, \dots, \mathbf{y}_{k-(m-i-1)}] \in \mathbb{R}^{n_y \times (m+1)}$$

$$\mathbf{U}_{k,m,i} := [\hat{u}_{k+i|k}, \dots, \hat{u}_{k+1|k}, \mathbf{u}_k, \dots, \mathbf{u}_{k-(m-i-1)}] \in \mathbb{R}^{n_u \times (m+1)}$$

El modelo RNN utiliza los $m = 12$ valores anteriores de las CVs para estimar su valor en el instante siguiente. En el instante $i = 0$ sólo se utilizan valores históricos de $\mathbf{y}$ y $\mathbf{u}$ para estimar $\hat{y}_{k+1|k}$. Luego se utilizan las estimaciones de $\hat{\mathbf{y}}$ retroalimentadas en lazo cerrado hasta que se completa el horizonte de predicción, lo que dependerá de los valores conocidos de $\mathbf{u}_k$ y la estimación de $\hat{\mathbf{u}}_{k+i|k}$ dada por el modelo de dinámica de los lazos de control PID de la Ecuación (13).

5.3.4. Modelo de perturbación $\mathcal{H}_{dist}$

Al entrenar el modelo, los valores de $\mathbf{y}_k$ son iguales a sus mediciones $\mathbf{y}_k^{MEAS}$, ya que las redes neuronales entrenadas capturarán la dinámica del proceso, incluida la perturbación, y esto minimizará el error. Luego, cuando el modelo se utiliza en línea para controlar un sistema que representa la realidad, se debe tener en cuenta las desviaciones debido al desajuste entre la planta y el modelo. Como se mencionó anteriormente, se utiliza un estimador de perturbaciones en el sistema supervisor, también considerado en el modelo de predicción. Así, el modelo de perturbación aditivo de la Ecuación (4) se puede reescribir como la Ecuación (15) a continuación, para la perturbación en el modelo de predicción:

$$\hat{y}_{k+i+1|k}^{MEAS} = \mathcal{H}_{dist}(\hat{y}_{k+i+1|k}, \xi_k) = \hat{y}_{k+i+1|k} + \xi_k \quad (15)$$

donde $\hat{y}_{k+i|k}$ está dado por la Ecuación (14).

La Ecuación (15) utiliza la perturbación aditiva constante ξ_k , como se muestra en el MEP de la Sección 5.2. La perturbación afectará la relación entre los valores pasados y futuros de $\hat{y}^{MEAS}$. Sin embargo, se puede ver en la Ecuación (13) que $\mathcal{H}_{SAG}^{NN}$ calcula valores $\hat{y}_{k+i|k}$ que no se ven afectados por ella directamente, ya que utiliza solo valores sin perturbación $Y_{k,m,i}$. Mientras que $\hat{y}^{MEAS}$ afectará la respuesta de APC de acuerdo a la Ecuación (8), pues define *setpoint* que serían diferentes si la perturbación fuera inexistente.

5.4. Sistema de control supervisor de optimización dinámica en tiempo real

En cada iteración, el sistema de control supervisor realizará una estimación de perturbación de acuerdo con el Problema (6), donde el proceso del molino SAG y sus sistemas de control están contenidos en el módulo de predicción descrito por las Ecuaciones (8), (13), (14) y (15), que ahora se pueden expresar como un modelo del proceso y control del molino SAG $\mathcal{H}$ en la Ecuación (16):

$$\hat{\mathbf{y}}_{k+i+1|k}^{MEAS} = \mathcal{H}(\mathbf{Y}_{k,m,i}^{MEAS}, \mathbf{U}_{k,m,i}^{SP}, \mathbf{U}_{k,m,i}, \mathbf{y}^{LIM}, \boldsymbol{\xi}_k), \quad i = 0 \dots (N - 1) \quad (16)$$

dónde m es el número de instantes previos de tiempo discreto que necesita el modelo (14) del proceso del molino SAG para simular el siguiente valor, y es mayor que el número de valores previos que necesitan los modelos PID y APC, (13) y (8) respectivamente, por lo que $m \geq \max(\ell, p_y, p_{SP}, p_u)$.

Luego, utilizando la perturbación $\boldsymbol{\xi}_k$ calculada a partir del Problema (6), el módulo de optimización realizará una búsqueda de $\mathbf{y}^{LIM}$ para resolver el Problema de Optimización (1), ahora especificado como Problema (17):

$$\begin{aligned} \min_{\mathbf{y}^{LIM} \in \mathbf{y}^{LIM}} \mathcal{F}(\hat{\mathbf{Y}}_{k,N}^{MEAS}, \hat{\mathbf{U}}_{k,n}^{SP}, \hat{\mathbf{U}}_{k,N}) \\ \text{s. t:} \\ \hat{\mathbf{y}}_{k+i+1|k}^{MEAS} \text{ de Ecuación (16)} \\ \boldsymbol{\xi}_k \text{ de Ecuación (6)} \end{aligned} \quad (17)$$

Se puede ver de (16) y (17) que $\mathbf{Y}_{k,m,i}^{MEAS}$, $\mathbf{U}_{k,m,i}^{SP}$ y $\mathbf{U}_{k,m,i}$ son datos adquiridos del proceso cuando $i = 1$ y posteriormente incluyen predicciones hechas en el instante k . $\hat{\mathbf{Y}}_{k,N}^{MEAS}$, $\hat{\mathbf{U}}_{k,N}^{SP}$ y $\hat{\mathbf{U}}_{k,N}$ son los valores en el horizonte de predicción completo y $\mathbf{y}^{LIM}$ son los grados de libertad para mejorar la respuesta $\hat{\mathbf{y}}_{k+i|k}^{MEAS}$ del proceso en el horizonte de predicción.

La Figura 9 muestra cómo el procedimiento de horizonte móvil simula cada valor de $i = 0$ a $N - 1$. Aplicable a los vectores $\mathbf{Y}_{k,m,i}^{MEAS}$, $\mathbf{U}_{k,m,i}^{SP}$ y $\mathbf{U}_{k,m,i}$, cuando se simula un nuevo valor, se reemplaza el más antiguo del vector. Para la primera simulación, solo se utilizan datos o valores históricos para la predicción de valores para el tiempo $i + 1$. Luego, los valores de los datos se reemplazan por valores predichos a medida que i aumenta.




Figura 9: Diagrama que representa el horizonte móvil del modelo de predicción. El modelo predictivo utiliza el valor simulado $(k + i + 1)$ para completar el vector de m valores anteriores necesarios para el siguiente instante de simulación, reemplazando el más distante.

5.5. Procedimiento de optimización

La optimización realizada en el MO tiene discontinuidades como consecuencia del modelo del APC, porque los cambios en y^{LIM} pueden producir respuestas que son calculadas por diferentes estados discretos del Sistema Experto simulado. Esto implica que para resolver el Problema (17) un algoritmo basado en gradientes no es. Por lo tanto, en este trabajo se ha implementado una rutina de búsqueda ad-hoc basada en conocimiento operacional, del proceso y de sus sistemas de control. La inicialización del procedimiento se describe a continuación y el Algoritmo se detalla en el Algoritmo 1 y la Figura 10.

En cada instante discreto k , el procedimiento de optimización comienza realizando una predicción con horizonte $N = 6$, perturbación constante ξ_k estimada a partir de la Ecuación (6) y utilizando límites en las CVs y MVs constantes.

Si, dentro del horizonte de predicción, el *setpoint* del tonelaje de alimentación no está en su máximo permitido, entonces se realiza la búsqueda de optimización de acuerdo con la Ecuación (17), donde $\mathcal{F}$ es la función objetivo, definida en la Ecuación (18):

$$\mathcal{F} = \alpha_1 \cdot \frac{y_1^{LIM}}{y_{max-allowed}^{LIM}} + \alpha_2 \cdot \sum_{i=0}^5 \left(\frac{\hat{u}_{1k+i|k}^{SP}}{6 \cdot u_1^{SP|max}} \right) \quad (18)$$

donde:

$\alpha_1 = 0.5$ es el peso ajustado para la presión

$\alpha_2 = 1.0$ es el peso ajustado de tonelaje de alimentación

y_1^{LIM} es el límite máximo de presión actual

$u_1^{SP|max}$ es el límite máximo de u_1^{SP}

$y_{max-allowed}^{LIM}$ es el límite alto máximo permitido, una condición de borde para la optimización, que puede ser diferente del límite alto actual de presión y_1^{LIM} .

La Ecuación (18) se compone de dos partes, la primera se encarga de determinar un límite de presión lo más alto posible dentro del máximo permitido. Esto se debe en parte a la respuesta dada por el APC, ya que compara los valores actuales de presión (PV) con el límite. Esta parte castiga la disminución del valor del límite alto ya que, generalmente, eso implica una menor “carga” en el molino y, por lo tanto, posiblemente reduzca el tratamiento de tonelaje junto con realizar acciones mas agresivas en las MVs disponibles. La segunda parte de la función tiene como objetivo maximizar el tonelaje alimentado dentro del horizonte de predicción, le da el mismo peso a cada instante en el futuro, ya que eso también proporciona la máxima estabilidad del proceso. Los pesos de la función objetivo se ajustaron para que la iteración pudiera proporcionar un resultado acorde con la respuesta esperada del APC y el proceso, dando mayor importancia a que el tonelaje alimentado sea el máximo posible permitido.

Dado que iterar sobre los valores del límite superior de presión dará como resultado una evaluación diferente de los estados operacionales por parte del APC, el valor óptimo siempre es uno que no evalúa un estado de sobrecarga dentro del horizonte de predicción, ya que produciría inmediatamente una reducción agresiva del *setpoint* de tonelaje. Por lo tanto, la búsqueda se restringe a los valores del límite superior que no activan inmediatamente un estado de sobrecarga dentro de la jerarquía del sistema APC debido a

la comparación entre y_1^{LIM} y y_1 . Una vez que se detecta una sobrecarga, cualquier valor inferior de y_1^{LIM} también producirá una evaluación de estado de sobrecarga y, posiblemente, una reducción de tonelaje aún más agresiva.

La Ecuación (19) muestra la definición inicial del límite superior del espacio de búsqueda como el máximo permitido $y_{max-allowed}^{LIM}$, que sirve como punto de partida para cada ciclo de búsqueda en la optimización. Para asegurar una definición correcta de los límites, el límite inferior se restringe al valor más alto entre el 95,0% del valor actual de $y_{max-allowed}^{LIM}$, ó una reducción del 1,0% en el valor actual de y_1^{LIM} como se describe en la Ecuación (20). Para mantener un registro de los valores que producen una sobrecarga, se utiliza un mínimo interno en la búsqueda y se actualiza cuando se evalúa dicha condición, este se establece inicialmente igual al límite inferior, de acuerdo a la Ecuación (21).

$$Bound^{UP} = y_{max-allowed}^{LIM} \quad (19)$$

$$Bound^{LO} = \max(0.95 \times y_{max-allowed}^{LIM}, y_{k_{Pres}}^{LIM} \cdot 0.99) \quad (20)$$

$$low_{internal} = Bound^{LO} \quad (21)$$

Para realizar la búsqueda, el paso mínimo del límite superior de presión se establece de manera tal que su valor no aumente excesivamente las evaluaciones a realizar, y proporcione una buena resolución de los posibles cambios de los estados operacionales y de los *setpoint*. Se determina que un paso mínimo de $step_{min} = 0.2 \text{ psi}$ es adecuado. Además, dado que el espacio de búsqueda se actualiza de acuerdo con $y_{max-allowed}^{LIM}$ y y_1^{LIM} , el paso inicial se establece como uno que proporcione un máximo de 20 intervalos espaciados uniformemente al inicio del ciclo, así $num_{test} = 20$. El algoritmo de búsqueda se describe en detalle en el Algoritmo 1:

Algoritmo 1: Rutina de búsqueda del MO

Set:

$num_{test} \leftarrow 20$

$step_{min} \leftarrow 0.2$

Simular el modelo predictivo en el horizonte de predicción N . Utilizar ξ_k de MEP, datos disponibles de $\mathbf{Y}_{k,m,i}^{MEAS}$, $\mathbf{U}_{k,m,i}^{SP}$, $\mathbf{U}_{k,m,i}$ y el valor actual $\mathbf{y}^{LIM}$.

SI al menos uno de los *setpoints* de tonelaje $u_1^{SP}|_{k+i}$, $\forall i = 1, \dots, N$ es menor que $u_1^{SP|max}$
do:

Calcular $\mathcal{F}_{value}$

Set:

$\mathcal{F}_{best} \leftarrow \mathcal{F}_{value}$

$y_1^{LIM} \leftarrow y_1^{LIM}$

$Bound^{UP}, Bound_{LO}, low_{internal}$

$step_{prev} \leftarrow 0$

Calcular $step_{initial}$

$step_{initial} \leftarrow (Bound^{UP} - Bound_{LO})/num_{test}$

Start outer-loop

Primer loop: Set $step \leftarrow step_{initial}$

Siguiente: Actualizar $step \leftarrow step \times 0,6$

SI $step \leq step_{min}$ **hacer:**

$step \leftarrow step_{min}$

SI $step = step_{prev}$ **hacer:**

Detener outer loop

Set $y_1^{LIM}|_{k+1} \leftarrow y_{best}^{LIM}$

Salir e Ir a esperar siguiente instante k

$step_{prev} \leftarrow step$

Start inner-loop

Primer loop: Set $y_1^{LIM} \leftarrow Bound^{UP}$

Siguiente: Actualizar $y_1^{LIM} \leftarrow y_1^{LIM} - step$

SI $y_{lim} \leq low_{internal}$ **hacer:**

Detener inner-loop and **Ir a** start outer-loop

SI NO **hacer:**

Simular el modelo predictivo en el horizonte de predicción N con y_1^{LIM}

Calcular valor actual de la function objetivo $\mathcal{F}_{value}$

SI el estado de Sobrecarga esta activo en los instantes simulados $i = [1,2]$

hacer:

Actualizar $low_{internal} = \max(Bound_{LO}, floor(y_1^{LIM}))$

Detener inner-loop e **Ir a** start outer-loop

SI NO **hacer:**

SI valor actual $\mathcal{F}_{value} < \mathcal{F}_{best}$ **hacer:**

$\mathcal{F}_{best} \leftarrow \mathcal{F}_{value}$

$y_1^{LIM} \leftarrow y_1^{LIM}$

Ir a start inner-loop

SI NO **hacer:**

Salir e Ir a esperar siguiente instante k




Figura 10: Diagrama del algoritmo para la búsqueda del valor óptimo de y_1^{LIM} para cada iteración de tiempo discreto k . Comienza simulando el horizonte de predicción N y evaluando si hay tonelaje máximo dentro de él. Si no, se establecen las condiciones iniciales del loop-externo y se inicia. Este loop es responsable de calcular un tamaño de paso adecuado para una búsqueda lineal. Una vez calculado, el loop-interno utiliza el tamaño de paso para iterar los valores de y_1^{LIM} en una búsqueda lineal desde los valores permitidos más altos a los más bajos, deteniéndose al evaluar un estado de sobrecarga.

Consta de dos ciclos (*loop*), como se muestra en la Figura 10. El loop-externo se ejecutará después de que los resultados de la simulación con horizonte de predicción $N = 6$ predigan que el *setpoint* para el tonelaje de alimentación u_{ton}^{SP} no sea igual a su máximo permitido en al menos uno de los valores de predicción. Cuando esto sucede, se almacenan el valor inicial de la función objetivo y el límite alto de la presión. Luego, se definen un paso inicial, un paso mínimo y las condiciones de borde.

El loop-externo es responsable de la reducción del tamaño del paso, considerando que el número inicial de iteraciones es 20, luego el paso se reduce por un factor de 0,6 que demostró mantener la resolución de los cambios en el valor de la función objetivo, así como no aumentar rápidamente el número de iteraciones. En cada ejecución del loop-externo es posible que se detecte una condición de sobrecarga. Cuando esto sucede, el límite interno inferior se actualiza a un valor mayor que el anterior, reduciendo el espacio de búsqueda.

Luego de establecer el tamaño del paso, se inicia el loop-interno, el cual se encarga de calcular el valor de la función objetivo $\mathcal{F}_{value}$ considerando un horizonte de predicción de $N = 6$ y la perturbación estimada ξ_k , y modificando en cada ejecución el valor de y^{LIM} utilizado por el modelo de predicción según el tamaño del paso establecido anteriormente.

La búsqueda del mejor valor de la función objetivo se realiza iterando el límite superior de la presión (y_1^{LIM}), comenzando desde el valor del límite superior y disminuyendo en cada iteración según paso calculado, hasta que se alcanza el límite inferior interno o se activan restricciones. Cuando esto sucede, el límite inferior interno se actualiza, ya que la presión no puede bajar más de este valor sin activar restricciones en el espacio de búsqueda. El nuevo límite interno se establecerá en el valor más alto entre el límite inferior actual o el valor entero que sea menor o igual al último y_1^{LIM} evaluado.

Luego, se calcula un nuevo paso que debe ser menor que el paso anterior. Si se alcanza el paso mínimo permitido, se considera que la rutina de optimización está completa. Cuando se encuentra un mejor valor de función objetivo $\mathcal{F}_{value}$, se almacena como $\mathcal{F}_{best}$, y el límite superior y_1^{LIM} utilizado para ese valor es la mejor solución actual $y_{1\ best}^{LIM}$.

Si el valor de la función objetivo no ha disminuido con respecto al valor inicial, significa que el sistema de control supervisor no puede encontrar un límite de presión mejor y no se aplican cambios al sistema real. Si se ha encontrado un mejor valor, se aplica $y_{1\ best}^{LIM}$ al sistema real hasta la siguiente iteración en tiempo discreto.

6. Resultados y discusión

Para probar el control supervisor propuesto en la Sección 5, se utiliza un proceso simulado para el Molino SAG con su capa de control regulatorio y APC. Esto se hace utilizando Python 3.7 para implementar el modelo del proceso según lo definido por la Ecuación (16).

La perturbación utilizada en este caso es aditiva y externa al modelo del Molino SAG tal como se expresa en la Ecuación (15). Se considera que el modelo del Molino SAG es la verdad fundamental y la perturbación está afectando las mediciones de los lazos de control PID y la capa APC. Esto implica que el Sistema Experto observa una medición y^{MEAS} que se es inexacta con el valor y del modelo SAG por ξ_k , y se utiliza la medición para determinar los estados operacionales y acciones a emprender.

La perturbación se utilizó como una respuesta observable a un cambio en las condiciones operativas dentro del molino o las características del mineral, que dan como resultado estados Críticos o de Presión Alta que son detectados por el Sistema Experto cuando las acciones de control tomadas por el mismo no son suficientes para evitar estos estados. Un estado de sobrecarga puede deberse a la reducción en la capacidad de molienda dentro del molino SAG, un aumento en la dureza del mineral o cambios en las características de la pulpa y dinámica interna que afectan negativamente la capacidad de disminuir el tamaño del mineral y evacuar los sólidos. En los datos medidos, esto se ve como un aumento en la presión del sistema hidráulico del molino SAG y, en un punto determinado, una disminución en el consumo de potencia del motor del molino (McClure et al., 2014).

Se espera que antes de que se activen estados de Presión Crítica o Alta, el sistema de control supervisor realice la rutina de optimización descrita en la Sección 0. Esto proporcionará al APC un límite alto para la Presión que cambia y se adapta a las condiciones de operación del momento, utilizando un modelo de simulación del proceso con mediciones realizadas y el modelo de perturbación estimado por el MEP.

El rendimiento total de tonelaje ($Total_{ton}$), calculado como la suma acumulada del *setpoint* de tonelaje u_1^{SP} en un período de simulación determinado, se espera que sea mayor cuando el límite de presión se modifica en presencia del control supervisor que cuando no lo está. De manera análoga, la pérdida de tonelaje tratado $Total_{loss}$ se calcula como la suma acumulada de la diferencia entre el *setpoint* u_1^{SP} y el máximo *setpoint* $u_1^{SP|max}$ permitido en cada instante discreto del horizonte de simulación. Esto lo podemos expresar como la disminución en el *setpoint* del tonelaje u_{1loss}^{SP} , el cual debe disminuir cuando el sistema de control supervisor está activo. Las Ecuaciones (22), (23) y (24) presentan la relación entre estos cálculos. Dado que cada instante de tiempo discreto en el modelo de simulación y en el procedimiento de optimización es equivalente a 30 s, el cálculo es sencillo y Δt se expresa en hr.

$$u_{1k}^{SP} + u_{1loss}^{SP} = u_1^{SP|max} \quad (22)$$

$$Total_{ton} = \sum_{k=a}^b u_{1k}^{SP} \times \Delta t \quad (23)$$

$$Total_{loss} = \sum_{k=a}^b u_{1loss}^{SP} \times \Delta t \quad (24)$$

El cambio dinámico del límite de presión también tiene como objetivo evitar o escapar rápidamente de estados Críticos y de Presión Alta cuando sea posible. Esto significa que el sistema de control supervisor debe ser capaz de disminuir la cantidad total de tiempo en el que el APC evalúa dicha condición Crítica o, incluso, reducir la cantidad de ocurrencias de esto.

6.1. Casos de estudio

El sistema de control supervisor se estudia en tres Escenarios diferentes en cuales el APC observa una condición crítica al aplicar una perturbación simulada. Para determinar los casos, se buscaron e implementaron las siguientes condiciones dentro del conjunto de datos de entrenamiento:

- Encontrar un punto de partida en el conjunto de datos donde las CVs no estén cerca de la condición crítica (presión no alta, potencia no alta)
- Comprobar que el *setpoint* de velocidad no esté al máximo y el *setpoint* de densidad no esté al mínimo.
- Simular una perturbación en la que la Presión aumenta a una velocidad determinada y la Potencia disminuye. Esto debe inducir a un estado de Presión Alta o un estado de Sobrecarga que sea detectado por el APC.
- Simular el proceso utilizando el modelo descrito en la Sección 0 y el control supervisor descrito en la Sección 0.

	y_1^{LIM} [psi]	y_2^{LIM} [kW]	u_1^{LIM} [t/h]	u_2^{LIM} [%]	u_3^{LIM} [%Solids]
Escenario 1	980.0	14,500	1,500 – 3,000	90.0 – 100.0	73.0 – 77.0
Escenario 2	980.0	14,500	1,500 – 3,000	90.0 – 100.0	73.0 – 77.0
Escenario 3	980.0	14,500	1,500 – 2,500	86.0 – 100.0	73.0 – 76.0

Tabla 4: Condiciones iniciales de los Escenarios a evaluar. La simulación considerará estos límites como constantes en todo momento, a excepción del límite superior de presión que podrá ser modificado por el sistema de control supervisor.

La RNN descrita en la Sección 0 requiere 12 valores previos para simular el siguiente valor. Por lo tanto, es relevante para la simulación del proceso utilizar 12 puntos de datos históricos reales para la inicialización de la RNN y proporcionar así a la simulación condiciones iniciales para las variables relevantes que afectan las predicciones futuras. En cada instante de tiempo discreto, después de los 12 puntos de datos iniciales, el modelo de proceso simula los datos para el siguiente instante de tiempo discreto como se muestra en la Figura 9, y el sistema de control supervisor predice los instantes de tiempo discretos futuros con $N = 6$ como se describe en la Sección 0.

Los Escenarios 1 y 2 comparten las mismas condiciones iniciales y el mismo punto de partida dentro del conjunto de datos, pero se aplica una perturbación diferente. En el Escenario 1 se utiliza una rampa constante que representa un cambio gradual en las características del mineral, mientras que para el Escenario 2 también se agrega una perturbación sinusoidal, para tener en cuenta cambios más inesperados en las propiedades del mineral de alimentación y, por lo tanto, en el proceso de molienda. El segundo Escenario considera la respuesta esperada cuando el origen de la alimentación al molino SAG no es

constante y puede ser muy variable según el plan de la mina y la pila de almacenamiento de mineral.

La perturbación simulada es tal que el modelo de proceso y los datos medidos tendrán una diferencia. El modelo APC y el sistema de control supervisor realizan sus cálculos utilizando únicamente información de los datos medidos. El sistema de control supervisor utiliza el MEP descrito en la Sección 5.2 para estimar la perturbación del proceso y así, predecir valores de proceso y mediciones más precisos.

Con la perturbación utilizada para cada Escenario, el proceso simulado es llevado a una condición Crítica según lo evaluado por el APC, impulsado principalmente por el aumento en la medición de Presión. La respuesta esperada del APC en estos casos es realizar cambios agresivos en los *setpoint*, incluida una disminución en el *setpoint* de tonelaje de alimentación. Esto sucedería después de que varias otras acciones sean aplicadas y posiblemente no produzcan el efecto deseado en las CVs.

6.1.1. Escenario 1

La perturbación aplicada a la Presión es una rampa con tasa de cambio constante durante 80 instantes de tiempo discretos y luego una tasa de cambio ligeramente menor durante 100 instantes de tiempo posteriores. Para la Potencia, una rampa de pendiente negativa constante durante 100 instantes. Ambas perturbaciones permanecen constantes en su último valor durante el resto de la simulación, la representación gráfica se ve en las Figura 11 y y se describen a cotinuación:

- La Presión aumenta constantemente comenzando con $\xi_1 = 0$ en $k = 8$ (línea azul 1a) hasta $\xi_1 = 140$ en $k = 88$ (línea azul 2a).
- La Presión aumenta constantemente comenzando con $\xi_1 = 140$ en $k = 88$ (línea azul 2a) hasta $\xi_1 = 200$ en $k = 188$ (línea azul 3a).
- La Presión entonces mantiene una perturbación constante $\xi_1 = 200$ desde $k = 200$ hasta el fin de la simulación.
- La Potencia disminuye constantemente comenzando con $\xi_2 = 0$ en $k = 108$ (línea azul 1b) y se deja de disminuir con $\xi_2 = -2500$ en $k = 208$ (línea azul 2b)
- La Potencia entonces mantiene una perturbación constante $\xi_2 = -2,500$ desde $k = 208$ hasta el fin de la simulación.

Simulación




Figura 11: Gráfica de los valores de Presión simulados para el Escenario 1. Las líneas negras son los valores medidos con perturbación y las líneas grises son los valores modelados sin perturbación en gris. La línea verde es el límite superior de Presión, las líneas discontinuas de color rojo oscuro indican el momento en el que el tonelaje no está en su máximo y las líneas verticales azules indican la perturbación aplicada. Las áreas sombreadas son estados Críticos evaluados: el rojo es para Sobrecarga y el amarillo para otros estados Críticos o de Presión Alta.





Figura 12: Gráfica de los valores de consumo de Potencia simulados para el Escenario 1. Las líneas negras son los valores medidos con perturbación y las líneas grises son los valores modelados sin perturbación. La línea verde es el límite superior de Potencia, las líneas discontinuas de color rojo oscuro indican el momento en el que el tonelaje no está en su máximo y las líneas verticales azules indican la perturbación aplicada.



(a) Sistema de control supervisor inactivo

(b) Sistema de control supervisor activo

Figura 13: Gráfica de las MVs simuladas: tonelaje, velocidad y densidad para el Escenario 1. Las líneas discontinuas negras son los *setpoint*, los valores de PV son las líneas punteadas negras. Las líneas verdes indican el máximo y mínimo del *setpoint*. Las líneas discontinuas rojas oscuras indican el momento en el que el tonelaje no está en su máximo, las líneas verticales azules indican la perturbación aplicada para la Presión (1a, 2a, 3a) y la Potencia (1b, 2b). Las áreas sombreadas son estados Críticos evaluados: el rojo es para Sobrecarga y el amarillo para otros estados Críticos o de Presión Alta.

El APC detecta condiciones Críticas en cuatro momentos diferentes a lo largo de la simulación. La Figura 11a y Figura 11b, muestra la tasa de cambio de la presión y la diferencia entre el modelo del proceso simulado sin perturbación (gris) y la medición con perturbación (negro).

El primer estado Crítico se obtiene en el tiempo discreto $k = 150$, cuando se produce una Sobrecarga y el estado permanece activo hasta $k = 160$. Esto ocurre en el mismo tiempo discreto para el caso en que el sistema de control supervisor está activo y cuando está inactivo. En ambos casos, el APC reduce *setpoint* de tonelaje de alimentación a $u_1^{SP} = 2,828 \text{ tph}$.

Durante la primera condición de sobrecarga ocurrida no existen diferencias en los casos simulados del Escenario 1. Aunque la optimización se ejecuta constantemente, el sistema de control supervisor no proporciona al APC de un mejor valor para y_1^{LIM} a aplicar. La Sobrecarga en este caso, es mas probable que sea causada por la tasa de cambio de la presión que por la cercanía entre el valor medido y_1 y su límite y_1^{LIM} . El rápido aumento de la Presión está dado por la perturbación y el APC realiza las acciones esperadas en la velocidad de rotación y la densidad del molino pero no son suficientes para reducir la tasa de cambio de la presión.

Posteriormente, una vez que la Sobrecarga ya no está activa, el *setpoint* de tonelaje se incrementa, en ambos casos simulados, a $u_1^{SP} = 2,880 \text{ tph}$ al tiempo discreto $k = 162$ y luego a $u_1^{SP} = 2,930 \text{ tph}$ en $k = 165$.

El sistema de control supervisor encuentra un nuevo valor para el límite alto de presión $y_1^{LIM} = 970.1 \text{ psi}$ en el instante $k = 170$ y este es aplicado al APC. Es esperable que al aplicar el nuevo límite disminuya la pérdida de rendimiento de tonelaje, dado que el sistema de control supervisor ha predicho una reducción en el *setpoint* de tonelaje de alimentación

en horizonte. El efecto de este cambio se ve inmediatamente después, en $k = 171$ cuando se activa un estado de Presión Alta y el *setpoint* de tonelaje se reduce a $u_1^{SP} = 2,871 \text{ tph}$.

En ambos casos simulados, se produce una Sobrecarga en instante $k = 172$ que permanece activa hasta $k = 189$. Tal y como previno el sistema de control supervisor, el *setpoint* de tonelaje disminuye hasta $u_1^{SP} = 2,805 \text{ tph}$ tan pronto como el estado se activa cuando el límite de presión no se adapta a esta nueva condición de operación. Por el contrario, con el sistema de control de supervisión activo, el *setpoint* se mantiene en $u_1^{SP} = 2,870 \text{ tph}$. Esto se debe al cambio preventivo realizado un instante antes (en el estado de Presión Alta) y al hecho de que el APC tiene configurado internamente tiempos de espera entre cambios consecutivos de *setpoint* en la misma MV.

Estos *setpoint* y límites de presión son consistentes con la optimización y la función objetivo, que buscan maximizar el rendimiento de tonelaje en los instantes simulados. El sistema supervisor ha previsto, en este punto, una futura disminución en u_1^{SP} y consecuentemente redujo y_1^{LIM} para mejorar el tonelaje total en el horizonte de predicción.

Además, en tiempo discreto $k = 198$ el APC realiza un cambio en el *setpoint* de velocidad de giro del molino a $u_2^{SP} = 99.73 \%$ cuando el sistema de control supervisor está activo. Se trata de un cambio ligeramente superior al que se realiza en ausencia del control supervisor, cuando el *setpoint* está en $u_2^{SP} = 99.66\%$ y es, además, la primera vez en la simulación donde el *setpoint* de velocidad es diferente entre ambos casos.

Es probable que esta diferencia en el cambio del *setpoint* de velocidad se deba a una diferencia observada en la tasa de cambio de la presión medida, ya que esta se ve afectada por el *setpoint* más alto en el tonelaje de alimentación producto del uso del control supervisor. Adicionalmente, la diferencia en y_1^{LIM} produce que el APC establezca una mayor criticidad del estado cuando y_1 está más cerca de su límite y, por lo tanto, los cambios son más agresivos.

En el tiempo discreto $k = 191$, el control supervisor aplica un nuevo límite de presión $y_1^{LIM} = 980.0 \text{ psi}$. Durante los siguientes 5 instantes de simulación se aplican cambios consecutivos. Se trata de cambios pequeños que no provocan ningún efecto aparente en los *setpoint* y fijan el límite entre $y_1^{LIM} = 978.9$ y 979.1 psi . Esto continúa hasta el instante $k = 195$, cuando el cambio en y_1^{LIM} va acompañado de un cambio de *setpoint* $u_1^{SP} = 2915 \text{ tph}$. Mientras tanto, en ausencia del sistema de control supervisor, en el tiempo discreto $k = 195$ se aplican los siguientes cambios: $u_1^{SP} = 2,850 \text{ tph}$ y $u_2^{SP} = 100\%$.

El siguiente estado Crítico evaluado es en $k = 198$, cuando el sistema de control supervisor ha bajado el límite de presión a $y_1^{LIM} = 965.0 \text{ psi}$ y el tonelaje se ha elevado a $u_1^{SP} = 2,976 \text{ t/h}$. Se puede ver en la Figura 13a que en ausencia del sistema de control supervisor el *setpoint* de tonelaje de alimentación disminuye a $u_1^{SP} = 2,701 \text{ tph}$, y la sobrecarga dura el equivalente a 8 min de operación. Mientras que en el caso en que el sistema de control de supervisión está activo, como se ve en la Figura 13b, se produce una sobrecarga durante el equivalente a solo un minuto y luego se activa un estado de "Presión Crítica". Como se presenta en Tabla 1, este sigue siendo un estado de categoría Crítica, pero sus acciones son menos agresivas que en el estado de Sobrecarga,

En el instante $k = 200$ los *setpoint* de velocidad y porcentaje de sólidos ya están en su máximo y mínimo, respectivamente, por lo que no es posible realizar más acciones en estas MVs. La acción preventiva realizada de disminuir el tonelaje en el instante $k = 171$ y otros ajustes en y_1^{LIM} tienen el efecto deseado de provocar estados Críticos más cortos en duración y reducir la pérdida de rendimiento de tonelaje.

Por último, sin el sistema de control supervisor, se produce nuevamente un estado Crítico en $k = 221$ que permanece activo durante 10 instantes discretos de la simulación, equivalentes a 5 min de operación, con un *setpoint* de tonelaje de $u_1^{SP} = 2,733 \text{ tph}$. Comparativamente, el sistema de control de supervisión encuentra un mejor límite de presión de $y_1^{LIM} = 977.0 \text{ psi}$ en $k = 209$ y luego de $y_1^{LIM} = 980.0 \text{ psi}$ en $k = 214$. Este último cambio hace que el *setpoint* de tonelaje pase de $u_1^{SP} = 2,984 \text{ tph}$ en $k = 214$ a $u_1^{SP} = 2.911 \text{ tph}$ en $k = 217$ cuando está activo un estado de Presión Alta. No se produce ninguna sobrecarga con el sistema de control supervisor y el *setpoint* de alimentación de mineral vuelve a su máximo en $k = 250$. Mientras que, en comparación, sin el sistema de control supervisor, el *setpoint* de tonelaje de alimentación vuelve a su máximo solo en el tiempo discreto $k = 276$, como se ve en Figura 13a.

Al comparar las simulaciones, se puede observar en la Figura 13a y la Figura 13b el efecto positivo del sistema de control supervisor en el tonelaje de alimentación. El sistema realiza la rutina de optimización desde el tiempo discreto $k = 149$ hasta $k = 250$, cuando el *setpoint* de tonelaje está nuevamente en su máximo. Esto equivale a 50,5 min de operación, de los cuales 49,5 min corresponden a operación con un *setpoint* de tonelaje inferior al máximo permitido. Esto es una notable reducción del 21% al compararlo con el tiempo total de 62,5 min de operación por debajo del *setpoint* de tonelaje máximo cuando se opera en ausencia del sistema supervisor.

Los cambios en el límite y_1^{LIM} producen una pérdida de tonelaje de alimentación en promedio 90 *tph* por debajo del máximo, en el período en que se realizan las optimizaciones. Esto significa un promedio de tonelaje de alimentación de 2,909 *tph*. En el mismo período, la pérdida promedio sin un sistema de control supervisor es de 188 *tph* y el promedio de alimentación es 2,811 *tph*. Estos resultados representan una reducción del 52,1% en la pérdida de alimentación y una mejora del 3,5% en el promedio del *setpoint* de tonelaje de alimentación.

La evaluación de la mejora presentada cambia ligeramente si se tiene en cuenta que el período de operación con tonelaje inferior al máximo es mayor cuando no hay un sistema de control supervisor. Es en este caso que el tonelaje vuelve al máximo permitido en $k = 275$, en cambio cuando se optimiza el valor del límite, se alcanza nuevamente el máximo en $k = 250$. No obstante, la pérdida total de alimentación de tonelaje es de 176 *ton* en la simulación y este valor se reduce en un 57 % a 76 *ton* cuando el sistema de control supervisor está activo.

Con todo esto, cabe destacar que el sistema supervisor ha realizado la optimización según los criterios esperados: reducir la pérdida de alimentación, aumentar la alimentación promedio y también reducir la duración de los estados críticos evaluados. En total, el sistema de control supervisor realizó 102 iteraciones y realizó 10 cambios en el límite superior de presión y_1^{LIM} , lo que redujo la activación de los estados críticos desde 28,5 min sin el control supervisor a 22,0 min cuando está activo, lo que representa una reducción de 23% del largo del periodo.

La importancia de los resultados obtenidos con el sistema de control supervisor no se debe únicamente a la reducción de la disminución del *setpoint* de tonelaje de alimentación en un 45% de su valor, sino también a que esta reducción se presenta durante un período de tiempo más corto, lo que amplía aún más la importancia del límite de presión dinámico y adaptativo. Esta mejora también se puede atribuir a una estabilización en el *setpoint* de tonelaje de alimentación, ya que al realizar cambios de *setpoint* más pequeños y menos frecuentes, se espera que consecuentemente se estabilice la dinámica de la presión.

Lo anterior es de suma importancia para el sistema de control propuesto, ya que se ha mencionado en la literatura que la estabilización es una mejora común de diferentes sistemas de control para procesos de molienda (Bouffard, 2015; Zhou et al., 2016), lo que demuestra que este sistema está en línea con las expectativas de sistemas de control similares y puede mejorar aún más los resultados de la implementación de Sistemas Experto de control. Al mismo tiempo, la mejora en el *setpoint* de tonelaje promedio en general, y aún siendo inferior a su máximo, está en línea con la optimización económica de los sistemas de control en general (Bouffard, 2015).

6.1.2. Escenario 2

En este Escenario se aplica la misma perturbación que en el caso 1 y se le agrega una onda sinusoidal para simular una pendiente que no constante para las variables medidas. La perturbación sinusoidal tiene una amplitud de 4,0 y un período de 50. Este comportamiento simula un caso operacional en el que se observa una mezcla minerales con diferentes características o que existe un cambio lento en la composición del material alimentado, ya que la pila de acopio de alimentación a la planta tiene un comportamiento indefinido al alimentar mineral al molino.

La Figura 14 presenta la lectura de presión resultante, con los estados críticos evaluados. Se puede observar que esta perturbación sinusoidal agregada está relacionada con los estados críticos evaluados, ya que los períodos de tiempo donde la presión tiene una tasa de cambio positiva, son coincidentes con la evaluación de los estados críticos.

Simulación




Figura 14: Gráfico de los valores de presión simulados para el Escenario 2. Las líneas negras son los valores medidos con perturbación y las líneas grises son los valores modelados sin perturbación. La línea verde es el límite superior de presión, las líneas discontinuas de color rojo oscuro indican el momento en el que el tonelaje no está en su máximo y las líneas verticales azules indican la perturbación aplicada. Las áreas sombreadas son estados Críticos evaluados: el rojo es para Sobrecarga y el amarillo para otros estados críticos o de Presión Alta.




Figura 15: Gráfico de los valores de consumo de energía simulados para el Escenario 2. Las líneas negras son los valores medidos con perturbación y las líneas grises son los valores modelados sin perturbación. La línea verde es el límite superior de potencia, las líneas discontinuas de color rojo oscuro indican el momento en el que el tonelaje no está en su máximo y las líneas verticales azules indican la perturbación aplicada.




Figura 16: Gráfico de MV simulados: tonelaje, velocidad y densidad para el Escenario 2. Las líneas discontinuas negras son los setpoint, los valores de PV son las líneas punteadas negras. Las líneas verdes indican el setpoint alto y bajo de cada MV. Las líneas discontinuas rojas oscuras indican el momento en que el tonelaje no está en su máximo, las líneas verticales azules indican la perturbación aplicada para la presión (1a, 2a, 3a) y la potencia (1b, 2b). Las áreas sombreadas son estados críticos evaluados: el rojo es para Sobrecarga y el amarillo para otros estados críticos o de Presión Alta.

En esta simulación, el APC detecta condiciones críticas en 5 instancias, como se muestra en la Figura 14a y la Figura 14b anteriores: se detecta una Sobrecarga en los tiempos discretos $k = 151$, $k = 171$ y en $k = 225$. Posteriormente en la simulación se detecta un estado de Presión Alta, en los tiempos discretos $k = 284$ y $k = 332$. Las acciones de control realizadas por el APC en la simulación son idénticas en ambos casos, con y sin sistema supervisor, hasta el tiempo $k = 203$, cuando la optimización del sistema de control supervisor encuentra y aplica un nuevo valor de límite alto de Presión $y_1^{LIM} = 970.4 \text{ psi}$, implementado como se puede ver en la Figura 14b.

Este cambio en y_1^{LIM} hace que el APC en $k = 205$ realice un cambio en el *setpoint* de tonelaje de alimentación a $u_1^{sp} = 2,823 \text{ tph}$, que es una alimentación 25 tph más alta que la resultante en ausencia del sistema de control supervisor. En ese caso, se reduce el *setpoint* de tonelaje de alimentación a $u_1^{sp} = 2,798 \text{ tph}$. El nuevo límite y_1^{LIM} se mantiene con cambios muy insignificantes hasta el momento $k = 206$, cuando se aumenta nuevamente a $y_1^{LIM} = 980.0 \text{ psi}$.

El *setpoint* de tonelaje de alimentación se incrementa en ambos casos cuando un estado de "Presión Alta y no Aumentando" está activo en el instante $k = 209$. La optimización del sistema de control supervisor implementa un nuevo límite de presión $y_1^{LIM} = 978.8 \text{ psi}$ en $k = 212$. Estas diferencias en la operación hacen que el APC con sistema supervisor aumente el *setpoint* de tonelaje de alimentación a su máximo $u_1^{sp} = 3,000 \text{ tph}$ en $k = 212$, mientras que en ausencia del sistema de control supervisor, el APC aumenta el *setpoint* de alimentación de mineral a $u_1^{sp} = 2,929 \text{ tph}$ en dicho instante, y llegará al tonelaje máximo más tarde, en $k = 223$.

Sin el sistema de control supervisor, en el tiempo discreto $k = 226$, solo 3 instantes de tiempo discreto después de alcanzar el tonelaje máximo, se activa un estado de Sobrecarga por el equivalente a 14.5 min de operación. Tan pronto como se activa el estado Crítico, el APC disminuye el *setpoint* de tonelaje de alimentación a $u_1^{sp} = 2,883 \text{ tph}$. El estado se

supera en el tiempo discreto $k = 254$ y luego en $k = 258$ el *setpoint* de tonelaje se aumenta a $u_1^{SP} = 2,949 \text{ tph}$. 3 instantes de tiempo discreto después, el *setpoint* de tonelaje de alimentación está en su máximo nuevamente.

Por otro lado, con el sistema de control supervisor activo, tras fijar un límite de presión $y_1^{LIM} = 978.8 \text{ psi}$ en el instante $k = 212$, el límite se mantiene sin cambios hasta el instante discreto $k = 258$. A su vez, en el instante $k = 226$ el APC realiza una reducción del *setpoint* de tonelaje hasta $u_1^{SP} = 2,898 \text{ tph}$, cuando ocurre una sobrecarga. Esta reducción es 15.0 tph menos agresiva que la reducción realizada en la simulación sin control supervisor. Esto se puede explicar por una operación más estable, ya que se observa una menor razón de cambio en la presión. Dicha menor razón de cambio podría estar causada por la estabilidad en el tonelaje alimentado en instantes anteriores, ya que el tonelaje ha estado en su máximo durante un período más largo.

En la simulación con el sistema de control supervisor activo, el aumento de la tasa de cambio de la presión en el período cercano al instante $k = 226$ hace que el APC detecte una sobrecarga. Esta Sobrecarga se atribuye principalmente a la perturbación y no a los cambios en el *setpoint* de alimentación de tonelaje según se explicó anteriormente. Mientras que en el caso sin sistema de control supervisor, el aumento de la tasa de cambio también se ve afectado e intensificado por el aumento reciente en el *setpoint* de tonelaje realizado en el tiempo discreto $k = 223$.

El estado Crítico detectado en $k = 226$ está activo durante un período de tiempo más largo cuando el sistema de control supervisor está activo que cuando no está, hasta el instante $k = 259$ cuando la optimización cambia el límite de presión a $y_1^{LIM} = 980.0 \text{ psi}$. Este período más largo es esperable, dado que el límite de presión y_1^{LIM} permanece sin cambios en $y_1^{LIM} = 978.8 \text{ psi}$ lo que significa que la Presión medida se mantiene mas cerca del límite establecido durante el período. Es por esto, que el APC evalúa un estado de criticidad más alto. Al mismo tiempo, cuando cambia el límite de Presión, el estado Crítico ya no está activo y, en consecuencia, el APC aumenta el *setpoint* de tonelaje a $u_1^{SP} = 2.962 \text{ tph}$. Luego, solo 3 instantes de tiempo después, el *setpoint* de tonelaje se establece nuevamente en su máximo.

En $k = 285$ se evalúa un estado de Presión Alta y el APC reduce el tonelaje a $u_1^{SP} = 2,928 \text{ tph}$ en ambos casos simulados. Poco después, en $k = 288$ el sistema de supervisor reduce el límite de presión a $y_1^{LIM} = 970.6 \text{ psi}$, lo que hace que el *setpoint* de tonelaje se mantenga constante mientras el estado crítico está activo, hasta $k = 291$. El límite es alterado ligeramente en aumentos de menos de 0.5 psi en los instantes de tiempo posteriores $k = 289$ y $k = 290$, sin cambios en las otras variables. Finalmente, en el tiempo discreto $k = 291$ el límite de Presión se establece nuevamente en $y_1^{LIM} = 980.0 \text{ psi}$.

En el caso simulado donde no se modifica el límite de presión, en el mismo instante $k = 288$ el APC reduce de manera más agresiva el *setpoint* de tonelaje a $u_{ton}^{SP} = 2.852 \text{ tph}$. Esto demuestra de que aunque el control supervisor realiza una disminución del límite superior de Presión, el tonelaje alimentado se mantiene más alto durante el período. Es decir, la predicción realizada es precisa para encontrar un mejor valor de tonelaje acumulado y por lo tanto con el control supervisor se induce un mejor rendimiento en este caso.

Sin el sistema de control supervisor, el *setpoint* del tonelaje se incrementa en los instantes $k = 308, 317$ y finalmente en $k = 320$, cuando se alcanza nuevamente el tonelaje máximo. Esto ocurre mucho antes cuando el sistema de control supervisor esta activo y cambia el límite de Presión. Esto hace que el APC aumente el tonelaje a $u_{ton}^{SP} = 2,991 \text{ tph}$ en el

instante de tiempo $k = 308$ y luego lo aumente hasta su máximo $u_1^{SP} = 3,000 \text{ tph}$ en el momento $k = 311$, es decir, casi 5 minutos antes que en el otro caso.

Las mismas acciones realizadas por el APC en el momento $k = 285$ y después, descritas anteriormente, se vuelven a realizar instantes después en $k = 335$, disminuyendo el tonelaje a $u_1^{SP} = 2,927 \text{ tph}$ en ambos casos. El sistema de control supervisor reduce el límite de Presión a $y_1^{LIM} = 971.0 \text{ psi}$ en el momento $k = 337$ y se mantiene constante el *setpoint* del tonelaje. Este es el mismo comportamiento observado en el momento $k = 285$ y descrito anteriormente.

Es probable, que este comportamiento similar se deba a la perturbación sinusoidal aplicada, ya que esta produce una tasa de cambio casi idéntica en ambos casos. Las diferencias en los valores de presión entre la simulación con control supervisor y sin él, son menores que 2.0 psi . Por lo tanto, al producirse tasas de cambio similares entre ambos casos, es posible que se produzcan cambios similares en los *setpoint*.

A lo largo de la simulación, el sistema de control supervisor realiza 188 iteraciones de la rutina de optimización, comenzando en $k = 150$. Después de este instante, la simulación continúa durante 93,0 min, de los cuales durante 70,5 min el tonelaje de alimentación es inferior a su máximo cuando no hay sistema de control supervisor presente. La pérdida del *setpoint* de alimentación es 123 tph en promedio en este período y la pérdida total de tonelaje es 144.6 ton durante la simulación.

El sistema de supervisión aumenta significativamente el tiempo en el que el tonelaje se encuentra en su valor máximo. Con 10 cambios realizados en el límite superior en el mismo período descrito anteriormente, el tiempo con el tonelaje establecido por debajo del máximo se reduce a 60 min con un promedio de 112 tph de pérdida, que es una reducción de un 9% en la pérdida de tph . En total, la pérdida de tonelaje es 112 ton cuando el sistema de control supervisor está activo, una reducción del 23% en comparación con el caso sin optimización.

Estos resultados están en línea con estudios previos (Wei & Craig, 2009) sobre un aumento esperado en el rendimiento de tonelaje cuando se implementan sistemas de control, particularmente cuando se considera el uso de capas de control avanzadas. En este caso, el *setpoint* de alimentación promedio con el sistema de control supervisor es 2928 tph , que es un 0,7% más alto que el *setpoint* de alimentación promedio de $2,908 \text{ tph}$ obtenido sin optimización.

Es importante destacar cómo los resultados respaldan la definición de la función objetivo, tanto por el aumento del *setpoint* del tonelaje total como por la reducción del número de estados de sobrecarga evaluados. Además, el aumento del tonelaje promedio se acompaña de una reducción en la extensión del período de tiempo en el que el tonelaje está por debajo del máximo. El sistema de control supervisor reduce este período de 70,5 a 60,0 cuando está activo, una reducción del 15% que también puede estar afectando positivamente la estabilidad general de la operación.

La estabilidad de la alimentación, el aumento del tratamiento y la estabilidad en la carga del molino (representada en este estudio por la presión) son factores importantes a tener en cuenta dentro de las capas del APC. Como señala (Bouffard, 2015), estos son beneficios comunes de los diferentes tipos de sistemas de control. En este estudio, agregamos el beneficio de mejorar la estabilidad y el rendimiento con foco en los períodos de estados críticos de operación.

Es esperable alcanzar una mejora adicional si se refina el método de estimación de la perturbación. Esto se puede ver por el hecho de que el MEP asume una perturbación

constante en cada instante de simulación, como se describe en la Ecuación (5). Esto no representa con precisión la perturbación real aplicada en este Escenario, una onda sinusoidal es no constante por definición. Por lo tanto, muchas iteraciones se hacen rápidamente inexactas en los futuros instantes de predicción. Esto puede que no permita al sistema supervisor estimar adecuadamente la perturbación del modelo y, como resultado, sea difícil predecir adecuadamente los valores futuros de Presión o Potencia. En este Escenario, esto produce el efecto de que se evalúan estados críticos durante 95,0 min de operación sin un control supervisor, que disminuye solo a 94,0 min cuando la optimización está activa.

6.1.3. Escenario 3

La perturbación aplicada a la Presión es una rampa con una tasa de cambio constante durante 80 instantes de tiempo y una tasa de cambio ligeramente menor durante 100 instantes de tiempo posteriores. Para la Potencia, se utiliza una rampa de pendiente negativa constante durante 100 instantes. Ambas perturbaciones permanecen constantes en su último valor durante el resto de la simulación:

- La presión aumenta constantemente a partir $\xi_1 = 0$ en $k = 8$ hasta $\xi_1 = 130$ en $k = 88$.
- Luego, la presión aumenta a una razón de cambio constante comenzando con $\xi_1 = 130$ en $k = 88$ hasta $\xi_1 = 190$ en $k = 188$.
- Finalmente se aplica una perturbación constante a la presión con $\xi_1 = 190$ en $k = 188$ hasta el final de la simulación.
- La potencia disminuye a una razón de cambio constante comenzando con $\xi_2 = 0$ en $k = 108$ y se detiene en $\xi_2 = -2000$ en $k = 208$.
- Luego, la potencia tiene una perturbación constante $\xi_2 = -2,000$ desde $k = 208$ hasta el final de la simulación.

Simulation




Figura 17: Gráfico de los valores de presión simulados para el escenario 3. Las líneas negras son los valores medidos con perturbación y las líneas grises son los valores modelados sin perturbación. La línea verde es el límite superior de presión, las líneas discontinuas de color rojo oscuro indican el momento en el que el tonelaje no está en su máximo y las líneas verticales azules indican la perturbación aplicada. Las áreas sombreadas son estados críticos evaluados: el rojo es para Sobrecarga y el amarillo para otros estados Críticos o de Presión Alta.





Figura 18: Gráfico de los valores de consumo de energía simulados para el escenario 3. Las líneas negras son los valores medidos con perturbación y las líneas grises son los valores modelados sin perturbación. La línea verde es el límite superior de potencia, las líneas discontinuas de color rojo oscuro indican el momento en el que el tonelaje no está en su máximo y las líneas verticales azules indican la perturbación aplicada.



(a) Sistema de control supervisor inactivo

(b) Sistema de control supervisor activo

Figura 19: Gráfico de los valores de referencia simulados: tonelaje, velocidad y densidad para el Escenario 3. Las líneas discontinuas negras son los setpoint, los valores de PV son las líneas punteadas negras. Las líneas verdes indican el setpoint alto y bajo de cada MV. Las líneas discontinuas rojas oscuras indican el momento en el que el tonelaje no está en su máximo, las líneas verticales azules indican la perturbación aplicada para la presión (1a, 2a, 3a) y la potencia (1b, 2b). Las áreas sombreadas son estados críticos evaluados: el rojo es para Sobrecarga y el amarillo para otros estados Críticos o de Presión Alta.

La Figura 17a anterior muestra 3 momentos en los que el APC evalúa un estado crítico cuando no hay sistema de control supervisor presente. Cuando el sistema de control supervisor está activo, el APC también detecta el primer y segundo estado de Sobrecarga. Estos se producen debido al rápido aumento de la presión y que la rutina de optimización no puede encontrar un mejor límite alto para la presión. Encontrar un mejor valor para el límite permitiría al APC responder más rápidamente a la condición operacional, como se puede ver en Figura 19 donde el *setpoint* de velocidad aumenta lentamente cuando hay estados de sobrecarga activos, pero no está cerca de su límite.

En el instante $k = 187$ se obtiene el valor más bajo del *setpoint* de tonelaje para ambos casos $u_1^{SP} = 2,387 \text{ tph}$. En este punto, el *setpoint* de velocidad es $u_2^{SP} = 93.81 \%$, que es alrededor de un 8% inferior al máximo permitido. A medida que continúa la simulación, el *setpoint* de velocidad seguirá aumentando a diferentes tasa de cambio dependiendo de los cambios en el límite de presión. En el instante $k = 195$, el *setpoint* de velocidad se incrementa a $u_2^{SP} = 94.91 \%$ y el tonelaje a $u_1^{SP} = 2,436 \text{ tph}$. Posteriormente, en $k = 198$ la rutina de optimización define un nuevo límite de presión de $y_1^{LIM} = 972.2 \text{ psi}$, lo que hace que el APC aumente el *setpoint* de tonelaje a $u_1^{SP} = 2,482 \text{ tph}$. Esto es ligeramente inferior al $u_1^{SP} = 2,485 \text{ tph}$ establecido cuando el límite de presión se mantiene en $y_1^{LIM} = 980.0 \text{ psi}$ en ausencia del sistema de control supervisor.

Aunque el *setpoint* de tonelaje es menor, la presión se mantiene más estable cuando el sistema de control supervisor está activo. Esto es evidente por el hecho de que 5 instantes de tiempo después, equivalentes a 2,5 min de funcionamiento, en $k = 204$ el sistema supervisor ha evitado la ocurrencia de una Sobrecarga. La Sobrecarga se produce en ausencia del sistema de supervisión, disminuyendo el *setpoint* de tonelaje a $u_1^{SP} = 2,368 \text{ tph}$.

El control supervisor predice la Sobrecarga y actúa de manera preventiva modificando el límite de presión en cada instante de tiempo desde $k = 199$ a $k = 201$. En estos instantes, el límite cambia a $y_1^{LIM} = 980.0 \text{ psi}$, $y_1^{LIM} = 971.8 \text{ psi}$ y $y_1^{LIM} = 970.4 \text{ psi}$, respectivamente.

Estos cambios hacen que el APC aumente el *setpoint* de velocidad a $u_2^{SP} = 95.42\%$ y mantenga el *setpoint* de tonelaje sin cambios en su máximo.

En el instante de tiempo $k = 204$, como se ha evitado la sobrecarga, el sistema de control supervisor aumenta el límite nuevamente a $y_1^{LIM} = 980.0\text{ psi}$ y el *setpoint* de velocidad se incrementa a $u_2^{SP} = 96.54\%$. Este valor es mayor que el *setpoint* de velocidad definido por el APC en ausencia de control supervisor $u_2^{SP} = 95.53\%$.

Una diferencia del 1,0 % en el *setpoint* de velocidad hace que la potencia medida sea mayor, ya que esta aumenta con el esfuerzo que realiza el motor para aumentar la velocidad de rotación del molino. La mayor velocidad también reduce la tasa de cambio de presión, ya que aumenta la capacidad de molienda dentro del molino y, por lo tanto, promueve la evacuación de minerales cuyo tamaño ya ha sido reducido. Ambas condiciones: mayor potencia y menor tasa de cambio de presión, son comportamientos en cuya tasa de cambio es opuesta a un estado de Sobrecarga o de Presión Alta.

En ausencia del sistema de control supervisor, la tercera y última Sobrecarga está activa durante el equivalente a 5 min de funcionamiento del molino, desde tiempo discreto $k = 204$ hasta $k = 213$ cuando el *setpoint* de tonelaje se incrementa a $u_1^{SP} = 2,417\text{ tph}$. Mientras tanto, en el caso en que no se produce esta Sobrecarga, el *setpoint* de tonelaje está en su máximo desde el instante de tiempo $k = 205$.

Como se puede ver en la Figura 19a, en ausencia de control supervisor, el *setpoint* de tonelaje volverá a su máximo recién al instante $k = 219$, mientras que el *setpoint* de velocidad aumentará sólo hasta un valor de $u_{rpm}^{SP} = 96.74\%$ en la simulación. Por otro lado, como se muestra en Figura 17b, la rutina de optimización realiza cambios en el límite alto de presión a $y_1^{LIM} = 974.0\text{ psi}$ en $k = 225$ y $y_1^{LIM} = 970.0\text{ psi}$ en $k = 258$ el cual se mantiene hasta el final de la simulación. Esto produce en la simulación que el tonelaje se mantenga en su máximo y el *setpoint* de velocidad aumente continuamente hasta el máximo $u_2^{SP} = 100.00\%$ en el instante $k = 262$.

Entre los tiempos discretos $k = 205$, cuando el tonelaje de alimentación está en su máximo, y el tiempo $k = 262$, el control supervisor continúa realizando la rutina de optimización. Esto debe ser causado por algún valor de tonelaje menor al máximo dentro del horizonte de predicción para cada instante evaluado. Sin embargo, no es el caso en la realidad, y el APC logra el objetivo de mantener el proceso bajo control y el tonelaje en su máximo.

El sistema de control supervisor mantiene al final de la simulación el límite alto de presión en $y_1^{LIM} = 970.0\text{ psi}$, y esto se puede explicar por el efecto probable que tienen las acciones previas en la operación del molino. La simulación con control supervisor ha mantenido un mayor tratamiento de tonelaje, por lo que aumentar el límite de presión mas allá de 970.0 psi podría provocar que el APC mantenga constante el *setpoint* de velocidad en lugar de aumentarlo constantemente como lo hace y se aprecia en la Figura 19b. Dicho aumento de límite y la estabilización de la velocidad provocaría un aumento en los valores de presión y tal vez se produzca un estado Crítico, de Sobrecarga o de Presión Alta .

Cabe destacar que la rutina de optimización no se vuelve a realizar después $k = 262$ porque esta requiere detección de un *setpoint* del tonelaje de alimentación bajo el máximo para realizar la búsqueda, cosa que no sucede para ninguno de los casos de simulación en este Escenario. Esto implica que con el *setpoint* más alto de velocidad de simulación con control supervisor, la sobrecarga que podría haber ocurrido como se ve en Figura 17a en el momento $k = 204$, se ha evitado con éxito en ese instante y también para instantes futuros.

En este escenario, se pueden tener en cuenta otras consideraciones, como el consumo de energía debido al aumento de la velocidad de rotación del molino o un enfoque diferente para estimar los cambios en las características del mineral, a fin de determinar cuándo se necesita un nuevo límite de presión hacia el final de la simulación. Tanto la estabilidad del tratamiento como las restricciones económicas se pueden incluir en la función de optimización para tener en cuenta estas otras consideraciones.

Hodouin (2011) y Owusu et al., (2022) han mencionado un parámetro de “moliendabilidad” del mineral, incluyendo en sus estudios un enfoque sobre cómo estimarlo. Estos podrían resultar un buen elemento para incluir en el presente sistema de control supervisor, como una estimación incorporada en el modelo o como datos de medición. Esta perspectiva puede ir en la dirección de mejorar las condiciones bajo las cuales se realiza la rutina de optimización, de modo que no se realice solo evaluando los *setpoint* de tonelaje en el horizonte de predicción.

En este Escenario, el sistema de control supervisor realiza 107 iteraciones de la rutina de optimización en busca de un mejor límite de la presión, comenzando en $k = 154$. Después de $k = 156$, cuando el *setpoint* de tonelaje se reduce por primera vez, el APC tarda 25,0 min en recuperar un *setpoint* constante de tonelaje máximo en presencia de la rutina de optimización. En contraste, el APC requiere 32,0 min para esta tarea cuando no se realiza ninguna optimización del límite y_1^{LIM} .

La rutina de optimización se repite desde el instante $k = 154$ hasta $k = 262$ y da como resultado un promedio de *setpoint* de tonelaje de alimentación de 2,452 *tph* en 54,0 min de funcionamiento. La pérdida total de *setpoint* de alimentación es de 42.7 *ton* en ese período, debido a un total de 24,5 min de funcionamiento con un *setpoint* inferior al máximo.

Los resultados son indicativos de la misma tendencia observada anteriormente, un aumento del *setpoint* de alimentación del 0,6% en comparación con la 2,439 *tph* alimentación promedio en la simulación sin sistema de control supervisor. También, en esta simulación la pérdida total se reduce en un 22%, obtenida a partir de 30,0 min de funcionamiento por debajo del máximo.

Como se mencionó anteriormente, los resultados siguen mostrando un buen desempeño de la rutina de optimización y la función objetivo. Esto se confirma adicionalmente por la reducción del tiempo cuando los estados Críticos están activos, que es de 13,5 minutos sin un control supervisor y de 9,0 minutos en el caso contrario.

6.2. Discusión

El sistema de control supervisor propuesto tiene una rutina de optimización basada principalmente en heurística. Esta optimización tiene como objetivo encontrar un mejor valor para una función objetivo que depende de los tres modelos descritos: APC, lazos PID y proceso de molienda SAG. El modelo del molino SAG es una red neuronal entrenada con datos históricos. Su estructura no deja claro si podría ser una función continua o diferenciable. Cuando se estudia a través de sus principios fundamentales, el proceso muestra ser altamente no-lineal (Coetzee et al., 2010; Yuwen et al., 2019) lo que también sería un desafío para el uso de algoritmos basados en gradientes.

En el caso del modelo APC, las no linealidades presentes serían un problema seguro para un algoritmo de búsqueda basado en gradientes. Los estados jerárquicos definidos en su estructura principal, junto con la lógica difusa utilizada para el cálculo y la lógica booleana utilizada en su sistema basado en reglas, hacen difícil abordarlo con funciones diferenciables.

Como el Sistema Experto considera el conocimiento del proceso bajo control como uno de sus principales requisitos para el ajuste fino del sistema (Bouffard, 2015), se hace posible comprender la complejidad de la sintonía del sistema de control cuando el límite alto es fijo y no se adapta a las condiciones operacionales. El conocimiento experto se utiliza entonces en la rutina de optimización presentada en este trabajo, para definir un algoritmo de búsqueda que busque con precisión el límite máximo permitido para la presión, lo que mejorará la estabilidad del proceso y el máximo rendimiento de tonelaje tratado. El algoritmo de búsqueda toma en consideración las características específicas del APC y del proceso en estudio, tal como el efecto que tienen los cambios del límite de presión en la operación del APC y las restricciones esperables dada la jerarquía de los estados operacionales dentro del mismo.

Es importante comprender la definición de los estados jerárquicos, ya que en este caso, siempre que la presión (PV) se acerque al límite superior, es imposible alcanzar estados que se encuentren más abajo en la jerarquía. Por lo tanto, los estados de Sobrecarga y Críticos siempre estarán activos cuando la diferencia entre la PV y el límite superior esté por debajo de un cierto umbral. Es en estos casos que la búsqueda heurística debe dejar de buscar posibles candidatos más bajos para el límite superior de presión.

El control supervisor en todos los escenarios evaluados es capaz de realizar una mejor operación del sistema, reduciendo las toneladas totales perdidas por disminución del *setpoint* de alimentación entre un 22 y un 57% cuando el sistema supervisor está activo que cuando no lo está. En la Tabla 5 se muestra la comparación para cada Escenario, considerando que la pérdida total de tonelaje se evalúa durante toda la simulación y el periodo de optimización corresponde al período entre el primer y último instante donde se realiza la rutina de optimización cuando el sistema supervisor está activo. En tales condiciones, el *setpoint* promedio de tonelaje de alimentación aumenta entre 0,6% a 3,5 dependiendo del Escenario evaluado.

Por último, en la Tabla 5 se muestra también la diferencia porcentual de la extensión del periodo en que se evalúan estados críticos y la suma acumulada de tiempo que permanecen activos. Esto muestra mejores valores para los casos donde el sistema supervisor está activo, excepto en el tiempo total de activación de estados críticos para el Escenario 2. En este caso, estados críticos son evaluados activamente por un tiempo 3% mayor dentro del periodo de optimización, sin embargo esto no afecta negativamente la operación en términos de alimentación o pérdida de tonelaje.

Comparación		Escenario 1	Escenario 2	Escenario 3
Pérdida total tonelaje	% diferencia ton	-57%	-23%	-22%
Período de optimización				
SP TPH promedio	% diferencia tph	3,5%	0,7%	0,6%
Pérdida SP TPH promedio		-52,1%	-22,6%	-22,1%
Tiempo total de SP < máx.		-21%	15%	-18%
Estados Críticos				
Extensión Período		-16%	-1%	-51%
Tiempo total activo		-23%	3%	-33%

Tabla 5: Diferencias obtenidas en los 3 Escenarios para las principales evaluaciones de desempeño: pérdida total de tonelaje alimentado en la simulación. Setpoint promedio de tonelaje alimentado y pérdida de setpoint promedio durante el período en que la optimización está activa para cada Escenario. Tiempo total con setpoint de tonelaje por debajo de su máximo. Y tiempo en que se evalúan estados críticos (primera a última evaluación, no necesariamente continua) y tiempo total en que está activa dentro de dicho período.

7. Conclusiones

Se ha introducido un sistema de control supervisor que ha demostrado ser eficaz para añadir capacidad de predicción a un Sistema Experto para el control de un molino SAG, mejorando el rendimiento del APC en condiciones de funcionamiento Críticas o de Presión Alta mediante la optimización dinámica en tiempo real de una función objetivo adecuada. La capacidad de predicción se obtiene mediante modelos basados en datos de los lazos PID y del proceso, un modelo del sistema APC y un método de estimación de perturbaciones.

El modelo del APC es notablemente no lineal debido a la jerarquía de estados operacionales basados en reglas y lógica difusa, lo que generalmente es un aspecto fundamental en un Sistema Experto. Por lo tanto, en lugar de algoritmos de búsqueda basados en gradientes, el sistema de control supervisor utiliza un algoritmo basado en heurística. El algoritmo se basa en el conocimiento de los fundamentos de la operación del proceso del molino SAG y la base de conocimientos de la operación del APC. El aspecto principal del método es que el límite superior de presión es una variable de entrada del APC que afecta negativamente su rendimiento cuando no está definido de acuerdo con las condiciones y características de operación del momento.

La función objetivo a optimizar también se basa en estas consideraciones e incluye el objetivo económico de maximizar el tonelaje de alimentación. El sistema de control supervisor es capaz de predecir dinámicamente el comportamiento tanto del proceso como de los sistemas de control, y evaluar el resultado de cambiar el límite de presión para mejorar el rendimiento del APC en estados operativos Críticos o de Presión Alta.

Los resultados de la optimización demostraron que el sistema es capaz de aumentar el *setpoint* de tonelaje promedio en los 3 Escenarios evaluados y, en algunos casos, reducir la ocurrencia y/o duración de los estados Críticos y Presión Alta evaluados. Esto tiene el beneficio adicional de reducir la variabilidad del tonelaje y la presión, ya que el APC realiza acciones menos agresivas. En las plantas concentradoras de minerales, un efecto esperado de reducir la variabilidad del proceso de molienda es la estabilidad del tamaño de molienda entregado a etapas posteriores y la mejora de la recuperación de flotación.

A partir de las tendencias actuales en materia de gestión de datos, se podrán entrenar modelos más robustos basados en datos y las capacidades de procesamiento en la nube podrán mejorar el número de variables consideradas, así como reducir el tiempo discreto de simulación para proporcionar una respuesta más rápida. También es esperable que se pueda incluir la utilización de *soft-sensors* u otros tipos de modelos para proporcionar métodos alternativos de detección de cambios en las condiciones operacionales que puedan activar la rutina de optimización del sistema de control supervisor propuesto.

8. Referencias

- Bouffard, S. C. (2015). Benefits of process control systems in mineral processing grinding circuits. *Minerals Engineering*, 79, 139–142. <https://doi.org/10.1016/j.mineng.2015.06.006>
- Cleary, P. W., & Owen, P. (2018). Development of models relating charge shape and power draw to SAG mill operating parameters and their use in devising mill operating strategies to account for liner wear. *Minerals Engineering*, 117, 42–62. <https://doi.org/10.1016/j.mineng.2017.12.007>
- Coetzee, L. C., Craig, I. K., & Kerrigan, E. C. (2010). Robust nonlinear model predictive control of a run-of-mine ore milling circuit. *IEEE Transactions on Control Systems Technology*, 18(1), 222–229. <https://doi.org/10.1109/TCST.2009.2014641>
- Festa, A., Cornejo, F., Orrante, F., Alanis, R., & Gutiérrez, B. (2009). *Expert Systems implementation at peñoles group concentrators*.
- Hodouin, D. (2011). Methods for automatic control, observation, and optimization in mineral processing plants. *Journal of Process Control*, 21(2), 211–225. <https://doi.org/10.1016/j.jprocont.2010.10.016>
- McClure, K. S., Gopaluni, R. B., Chmelyk, T., Marshman, D., & Shah, S. L. (2014). Nonlinear process monitoring using supervised locally linear embedding projection. *Industrial and Engineering Chemistry Research*, 53(13), 5205–5216. <https://doi.org/10.1021/ie401556r>
- METZNER, G., CORNEJO, F., STEYN, J., WESTCOTT, M., FESTA, A., BARNARD, E., & BRITS, C. (2009). Implementation of a SAG grinding expert system at Barrick North Mara, Tanzania. *World Gold Conference 2009*, 19–26.
- Navia, D., Bruna, R., Fernández, F., Mancilla, C., Rojas, M., & Estrada, M. (2021). Gemelo digital con aprendizaje automático para la optimización en tiempo real de un SAG. *Minería Digital 2021*. <https://www.gecaminpublications.com/mineria-digital-2021/?noload=1#close>
- Owusu, K. B., Skinner, W., & Asamoah, R. (2022). Feed hardness and acoustic emissions of autogenous/semi-autogenous (AG/SAG) mills. *Minerals Engineering*, 187(August), 107781. <https://doi.org/10.1016/j.mineng.2022.107781>
- Sugeno, M. (1985). *Industrial Applications of Fuzzy Control*. Elsevier Science Inc.
- Van Zyl, F., Paquot, F., Metzner, Fouche, F., & Gomez, A. (2013). Implementation of a SAG grinding expert system at kansanshi mine - Zambia. In *IFAC Proceedings Volumes (IFAC-PapersOnline)* (Vol. 46, Issue 16 PART 1). IFAC. <https://doi.org/10.3182/20130825-4-US-2038.00071>
- Wei, D., & Craig, I. K. (2009). Grinding mill circuits - A survey of control and economic concerns. *International Journal of Mineral Processing*, 90(1–4), 56–66. <https://doi.org/10.1016/j.minpro.2008.10.009>
- Yuwen, C., Liu, S., & Sun, B. (2019). Dynamic Model of Semi-autogenous (SAG) Mill System. *IEEE International Conference on Control and Automation, ICCA, 2019-July*, 1195–1200. <https://doi.org/10.1109/ICCA.2019.8899651>
- Zhou, P., Lu, S., Yuan, M., & Chai, T. (2016). Survey on higher-level advanced control for grinding circuits operation. *Powder Technology*, 288, 324–338. <https://doi.org/10.1016/j.powtec.2015.11.010>

