



Universidad de Concepción
Dirección de Postgrado
Facultad de Ingeniería - Programa de Magíster en Ciencias de la Ingeniería con
mención en Ingeniería Eléctrica

Modelación neuro-difusa del desgaste de alzadores y nivel de llenado de molinos SAG

Tesis para optar al grado de Magíster en Ciencias de la Ingeniería con
mención en Ingeniería Eléctrica

OMAR ANDRÉS QUILODRÁN RODRÍGUEZ
CONCEPCIÓN-CHILE
2018

Profesor Guía: M. Aníbal Valenzuela Latorre
Dpto. de Ingeniería Eléctrica, Facultad de Ingeniería
Universidad de Concepción

Tesis de Grado

Programa

Magíster en Ciencias de la Ingeniería con mención en Ingeniería Eléctrica

Título

Modelación neuro-difusa del desgaste de alzadores y nivel de llenado de molinos SAG

Alumno

Omar Andrés Quilodrán Rodríguez

Profesor Supervisor

Manuel Aníbal Valenzuela Latorre

Comisión Evaluadora

Prof. Manuel Aníbal Valenzuela Latorre

Prof. Daniel Sbárbaro Hofer

Evaluador Externo

Prof. Guillermo Ramírez Arias

Resumen

Los molinos SAG son importantes equipos mineros utilizados en plantas concentradoras para la molienda de minerales. De la correcta operación de estos equipos, depende el mantener la tasa de producción diaria y el porcentaje de recuperación de cobre en el proceso que le sucede, la flotación.

Se estima que por detener dos horas un molino SAG, mínimo tiempo que tarda una inspección, las pérdidas económicas ascienden a cerca de 100,000 USD. La principal causa de detención corresponde a inspecciones para revisar el estado de los alzadores, los cuales cumplen una función de protección de la coraza interna del molino y también inciden en la eficiencia de molienda por medio del levante de la carga.

Por otro lado, el poder monitorear el nivel de llenado, tiene una gran relevancia en la producción y eficiencia del proceso, ya que permite utilizar el molino en su máxima capacidad de procesamiento sin caer en zonas de sobrellenado o vaciado del molino SAG.

Las dos variables, estado de alzadores y nivel de llenado, no son medibles directamente durante la operación del molino.

Este trabajo utiliza un enfoque neuro-difuso para generar modelos que permitan estimar en línea tanto el desgaste de los alzadores y el nivel de llenado, utilizando variables de proceso y eléctricas.

El modelo de desgaste de alzadores se desarrolla y evalúa a partir de registros de terreno, mientras que el modelo del nivel de llenado es desarrollado a partir de datos de simulaciones DEM, y posteriormente ajustado por medio de registros de terreno.

Las simulaciones DEM se llevan a cabo por medio del software Rocky DEM, cubriendo un amplio rango de variación de las condiciones de operación.

Agradecimientos

En especial agradecer a mi familia por su apoyo incondicional, en todo ámbito de mi vida.

Al profesor Aníbal Valenzuela por el continuo acompañamiento durante el desarrollo de este trabajo, así como también por creer en mis capacidades y potenciarlas en el día a día.

A los miembros del laboratorio de control de movimiento (Don Sergio, José, Matías, Diego, Benjamín y Germán) por contribuir a un grato ambiente de trabajo y brindar ayuda en temas técnicos y no tan técnicos.

No puedo dejar de agradecer al Sr. Eric Larenas por su gran y desinteresada ayuda, sin la cual este trabajo no hubiera sido posible.

Finalmente, agradecer a mi polola por su apoyo durante el desarrollo de la investigación y a mis amigos por los gratos momentos vividos.

Agradecimientos por Soporte a la Investigación

Se agradece el apoyo financiero recibido por parte del Programa de Becas para Estudios de Magíster en Chile de la agencia CONICYT del gobierno de Chile.



Tabla de contenidos

RESUMEN.....	III
LISTA DE TABLAS.....	VII
LISTA DE FIGURAS.....	VIII
NOMENCLATURA.....	X
ABREVIACIONES.....	XII
CAPÍTULO 1. INTRODUCCIÓN	1
1.1. INTRODUCCIÓN GENERAL	1
1.2. TRABAJOS PREVIOS	2
1.2.1 <i>Medición del desgaste de alzadores</i>	2
1.2.2 <i>Medición del nivel de llenado</i>	4
1.2.3 <i>Modelación neuro-difusa</i>	8
1.2.4 <i>Uso de software DEM en simulación de molinos rotatorios</i>	11
1.2.5 <i>Discusión</i>	13
1.3. HIPÓTESIS DE TRABAJO	14
1.4. OBJETIVOS.....	15
1.4.1 <i>Objetivo General</i>	15
1.4.2 <i>Objetivos Específicos</i>	15
1.5. ALCANCES Y LIMITACIONES.....	15
1.6. TEMARIO Y METODOLOGÍA.....	15
CAPÍTULO 2. MODELACIÓN NEURO-DIFUSA.....	17
2.1. INTRODUCCIÓN	17
2.2. SISTEMAS DIFUSOS.....	17
2.3. REDES NEURONALES ARTIFICIALES.....	21
2.4. ANFIS.....	24
2.5. DISCUSIÓN Y CONCLUSIONES	27
CAPÍTULO 3. MODELO DE DESGASTE DE ALZADORES	28
3.1. INTRODUCCIÓN	28
3.2. REGISTROS DE TERRENO Y MEDICIONES DEL DESGASTE.....	28
3.3. DESARROLLO DEL MODELO DE DESGASTE.....	33
3.3.1 <i>Etapa de entrenamiento</i>	33
3.3.2 <i>Reglas resultantes y funciones de pertenencia</i>	34
3.3.3 <i>Estructura y parámetros</i>	35
3.3.4 <i>Superficies de salida</i>	37
3.4. EVALUACIÓN DEL MODELO.....	38
3.5. DISCUSIÓN Y CONCLUSIONES	41
CAPÍTULO 4. ANÁLISIS DE SIMULACIONES DEM.....	42
4.1. INTRODUCCIÓN	42
4.2. DESCRIPCIÓN DEL MÉTODO DE ELEMENTOS DISCRETOS	42
4.3. POSICIÓN DE LA CARGA DEL MOLINO.	44
4.4. CURVAS DE POTENCIA VS VELOCIDAD.	46
4.5. CURVAS DE POTENCIA VS NIVEL DE LLENADO.....	48
4.6. OBTENCIÓN DE LA REACCIÓN EN LOS DESCANSOS.	50
4.7. CURVAS DE REACCIÓN VS NIVEL DE LLENADO.	56
4.8. DISCUSIÓN Y CONCLUSIONES	58
CAPÍTULO 5. MODELO DE NIVEL DE LLENADO	59
5.1. INTRODUCCIÓN	59
5.2. REGISTROS DE SIMULACIONES DEM.....	59

5.3.	DESARROLLO DEL MODELO DE NIVEL DE LLENADO	61
5.3.1	<i>Etapa de entrenamiento</i>	61
5.3.2	<i>Reglas resultantes y funciones de pertenencia</i>	61
5.3.3	<i>Estructura y parámetros</i>	62
5.3.4	<i>Superficies de salida</i>	64
5.4.	EVALUACIÓN DEL MODELO.....	66
5.5.	DISCUSIÓN Y CONCLUSIONES	70
CAPÍTULO 6. AJUSTE DEL MODELO DE NIVEL DE LLENADO CON DATOS DE TERRENO		71
6.1.	INTRODUCCIÓN	71
6.2.	MODELO DE NIVEL DE LLENADO IMPLEMENTADO EN SIMULINK	71
6.3.	ECUACIONES QUE REQUIEREN AJUSTE DE PARÁMETROS	74
6.4.	REGISTROS DE TERRENO Y VALORES DE PARÁMETROS AJUSTADOS.....	75
6.5.	RESULTADOS	76
6.6.	DISCUSIÓN Y CONCLUSIONES	78
CAPÍTULO 7. CONCLUSIONES		79
7.1.	SUMARIO	79
7.2.	CONCLUSIONES	80
7.3.	TRABAJO FUTURO	81
BIBLIOGRAFÍA.....		82
ANEXO A. MÉTODOS DE MEDICIÓN EN TERRENO		86
A.1.	MEDICIÓN DEL DESGASTE DE ALZADORES	86
A.2.	MEDICIÓN DEL NIVEL DE LLENADO.....	86
ANEXO B. GRANULOMETRÍA Y METODOLOGÍA DE LLENADO DEL MOLINO		88
B.1.	GRANULOMETRÍA DE MINERAL Y BOLAS.....	88
B.2.	METODOLOGÍA DE LLENADO DEL MOLINO	88
ANEXO C. METODOLOGÍA PARA REPLICAR EL DESGASTE DE ALZADORES EN ROCKY DEM.		92

Lista de Tablas

Tabla 3.1 Inspecciones de altura de alzadores – SAG 1 (Fuente: Elaboración propia).	31
Tabla 3.2 Número de datos de entrenamiento, validación y testeo (Fuente: Elaboración propia).	33
Tabla 3.3 RMSE finalizada la etapa de entrenamiento de modelos de desgaste (Fuente: Elaboración propia).	34
Tabla 3.4 Parámetros parciales de funciones de pertenencia modelo de desgaste – SAG 1 (Fuente: Elaboración propia).	35
Tabla 3.5 Parámetros parciales de consecuentes de reglas difusas de modelo de desgaste – SAG 1 (Fuente: Elaboración propia).	36
Tabla 3.6 Valores RMSE y MAPE obtenidos en la etapa de testeo (Fuente: Elaboración propia). ..	40
Tabla 4.1 Largo de secciones del molino (Fuente: Elaboración propia).	53
Tabla 5.1 Valores de normalización de variables (Fuente: Elaboración propia).	60
Tabla 5.2 Valores RMSE finalizado el entrenamiento (Fuente: Elaboración propia).	61
Tabla 5.3 Parámetros de las funciones de pertenencia (Fuente: Elaboración propia).	63
Tabla 5.4 Parámetros de los consecuentes de las reglas (Fuente: Elaboración propia).	63
Tabla 5.5 Primer grupo de simulaciones de evaluación (Fuente: Elaboración propia).	67
Tabla 5.6 Segundo grupo de simulaciones de evaluación (Fuente: Elaboración propia).	67
Tabla 5.7 Tercer grupo de simulaciones de evaluación (Fuente: Elaboración propia).	68
Tabla 5.8 RMSE y MAPE de simulaciones de evaluación (Fuente: Elaboración propia).	69
Tabla 6.1 Valores promedio de mediciones de terreno SAG 1 (Fuente: Elaboración propia).	75
Tabla 6.2 Valores promedio de mediciones de terreno SAG 2 (Fuente: Elaboración propia).	75
Tabla 6.3 Parámetros ajustados con datos de terreno (Fuente: Elaboración propia).	76
Tabla 6.4 Errores de estimación de modelo de nivel de llenado SAG 1 (Fuente: Elaboración propia).	77
Tabla 6.5 Errores de estimación de modelo de nivel de llenado SAG 2 (Fuente: Elaboración propia).	77
Tabla B.1 Granulometría de mineral (Fuente: Elaboración propia).	88
Tabla B.2 Granulometría de bolas (Fuente: Elaboración propia).	88
Tabla B.3 Volumen del molino para niveles de llenado del 25 al 45% (Fuente: Elaboración propia).	89
Tabla B.4 Volumen de la carga del molino para niveles de llenado experimentales (Fuente: Elaboración propia).	89
Tabla B.5 Volumen ocupado por mineral para niveles de llenado experimentales (Fuente: Elaboración propia).	90
Tabla B.6 Masa de mineral para niveles de llenado experimentales (Fuente: Elaboración propia). .	90
Tabla B.7 Niveles de llenado según método del conteo de alzadores – DEM y terreno (Fuente: Elaboración propia).	91

Lista de Figuras

Figura 2.1 Arquitectura de un Sistema de Inferencia Difuso (Fuente: Elaboración propia).....	18
Figura 2.2 Arquitectura de una neurona artificial (Fuente: Elaboración propia).....	21
Figura 2.3 RNA multilayer feedforward (Fuente: Elaboración propia).....	23
Figura 2.4 Arquitectura ANFIS (Fuente: Elaboración propia).....	24
Figura 3.1 Alimentación de mineral – primera campaña de SAG 1 (Fuente: Elaboración propia)...	29
Figura 3.2 Presión de descanso – primera campaña de SAG 1 (Fuente: Elaboración propia).....	29
Figura 3.3 Potencia – primera campaña de SAG 1 (Fuente: Elaboración propia).....	30
Figura 3.4 Velocidad – primera campaña de SAG 1 (Fuente: Elaboración propia).....	30
Figura 3.5 Curva de desgaste de alzadores, campaña 1ª (Fuente: Elaboración propia).....	32
Figura 3.6 Curva de desgaste de alzadores, campaña 1B (Fuente: Elaboración propia).....	32
Figura 3.7 Evolución del RMSE con datos de entrenamiento y validación – SAG 1 (Fuente: Elaboración propia).....	34
Figura 3.8 Funciones de pertenencia de cinco primeras reglas de modelo de desgaste – SAG 1 (Fuente: Elaboración propia).....	35
Figura 3.9 Estructura parcial de modelo de desgaste – SAG 1, 2 (Fuente: Elaboración propia).....	36
Figura 3.10 Altura de alzadores en función de mineral procesado y potencia – SAG 1 (Fuente: Elaboración propia).....	37
Figura 3.11 Altura de alzadores en función de mineral procesado y presión de descanso – SAG 1 (Fuente: Elaboración propia).....	37
Figura 3.12 Evaluación de modelo de desgaste SAG 1 – datos de campaña 1ª (Fuente: Elaboración propia).....	38
Figura 3.13 Curva de error al evaluar modelo de desgaste SAG 1 – datos de campaña 1ª (Fuente: Elaboración propia).....	39
Figura 3.14 Evaluación de modelo de desgaste SAG 1 – datos de campaña 1B (Fuente: Elaboración propia).....	39
Figura 3.15 Curva de error al evaluar modelo de desgaste SAG 1 – datos de campaña 1B (Fuente: Elaboración propia).....	40
Figura 4.1 Forma de la carga del molino – sentido de giro antihorario (Fuente: Elaboración propia).....	44
Figura 4.2 Matriz nivel de llenado–velocidad con altura de alzadores de 377 mm (Fuente: Elaboración propia).....	45
Figura 4.3 Matriz nivel de llenado – velocidad con altura de alzadores de 140 mm (Fuente: Elaboración propia).....	45
Figura 4.4 Curvas de potencia vs velocidad – altura 377 mm (Fuente: Elaboración propia).....	46
Figura 4.5 Curvas de potencia vs velocidad – nivel de llenado de 25 % (Fuente: Elaboración propia).....	47
Figura 4.6 Curvas de potencia vs nivel de llenado – altura de alzadores de 377 mm (Fuente: Elaboración propia).....	48
Figura 4.7 Curvas de potencia vs nivel de llenado – velocidad de 85% (Fuente: Elaboración propia).....	50
Figura 4.8 Estructura de molino SAG simulado en Rocky DEM (Fuente: Elaboración propia).....	51
Figura 4.9 Fuerza ejercida por las partículas sobre el molino (Fuente: Elaboración propia).....	52
Figura 4.10 Distribución de fuerzas sobre secciones del molino (Fuente: Elaboración propia).....	53
Figura 4.11 Correspondencia de masa nominal y fuerzas promedio – Altura de alzadores de 377 mm (Fuente: Elaboración propia).....	54

Figura 4.12 Esquema de fuerzas involucradas en el equilibrio del molino (Fuente: Elaboración propia).	54
Figura 4.13 Masa de revestimientos en función del desgaste de alzadores (Fuente: Elaboración propia).	56
Figura 4.14 Curvas de reacción vs nivel de llenado – Altura de alzadores de 377 mm (Fuente: Elaboración propia).	57
Figura 4.15 Curvas de reacción vs nivel de llenado – velocidad de 65 % (Fuente: Elaboración propia).	57
Figura 5.1 Datos de entrenamiento normalizados (Fuente: Elaboración propia).	60
Figura 5.2 Evolución del RMSE durante la etapa de entrenamiento del modelo (Fuente: Elaboración propia).	61
Figura 5.3 Funciones de pertenencia de las 2 reglas del modelo (Fuente: Elaboración propia).	62
Figura 5.4 Estructura ANFIS del modelo del nivel de llenado (Fuente: Elaboración propia).	63
Figura 5.5 Nivel de llenado en función de reacción de descanso y potencia, altura de alzadores de 300 mm y 75% de la velocidad crítica (Fuente: Elaboración propia).	64
Figura 5.6 Nivel de llenado en función de reacción de descanso y altura de alzadores, 75 % de la velocidad crítica (Fuente: Elaboración propia).	65
Figura 5.7 Nivel de llenado en función de potencia y velocidad, altura de alzadores de 300 mm (Fuente: Elaboración propia).	65
Figura 5.8 Evaluación de modelo de nivel de llenado (Fuente: Elaboración propia).	68
Figura 5.9 Errores de estimación obtenidos en la evaluación del modelo (Fuente: Elaboración propia).	69
Figura 6.1 Modelo de nivel de llenado implementado en Simulink (Fuente: Elaboración propia). ..	72
Figura 6.2 Subsistema 1 de modelo de nivel de llenado (Fuente: Elaboración propia).	72
Figura 6.3 Subsistema 2 de modelo de nivel de llenado (Fuente: Elaboración propia).	73
Figura 6.4 Subsistema 3 de modelo de nivel de llenado (Fuente: Elaboración propia).	73
Figura 6.5 Valores promedio de registros de terreno de molino SAG 1 (Fuente: Elaboración propia).	76
Figura 6.6 Estimaciones del nivel de llenado – molino SAG 1 (Fuente: Elaboración propia).	77
Figura A.1 Puntos de medición de altura de alzadores (Fuente: CODELCO).	86
Figura A.2 Esquema de corte transversal de molino SAG (Fuente: Elaboración propia).	86
Figura A.3 Vista interna de molino SAG durante inspección del nivel de llenado (Fuente: CODELCO).	87
Figura B.1 Niveles de llenado medidos en terreno simulados en DEM (Fuente: Elaboración propia).	91
Figura C.1 Geometría de alzadores tras 0 segundos transcurridos en simulación (Fuente: Elaboración propia).	92
Figura C.2 Geometría de alzadores tras 55 segundos transcurridos en simulación (Fuente: Elaboración propia).	92
Figura C.3 Datos de terreno de condición 5 (Fuente: Elaboración propia).	93
Figura C.4 Superposición de superficie rectangular sobre cara de ataque de alizador desgastado (Fuente: Elaboración propia).	93
Figura C.5 Ángulo entre la cara superior y de ataque de nueva geometría de alizador (Fuente: Elaboración propia).	93

Nomenclatura

Vectores

\vec{F}_{neta}	: Fuerza neta
\vec{F}_c	: Fuerza de contacto con partículas y bordes
\vec{F}_{ext}	: Fuerza externa
\vec{a}	: Aceleración de partícula
\vec{V}	: Velocidad
\vec{X}	: Posición

Escalares

x	: Variable lingüística
A_1	: Conjunto difuso
$\mu_{A_1}(x)$: Función de pertenencia de x con A_1
R^i	: i -ésima regla difusa
α_i	: Fuerza de disparo de i -ésima regla difusa
\wedge	: Operador mínimo
\vee	: Operador máximo
$\mu_{C_i}(w)$: Función de pertenencia del consecuente de i -ésima regla en modelo Mamdani
$f_i(x, y)$: Función de pertenencia del consecuente de i -ésima regla en modelo Sugeno
$\mu_{C_i}(w)$: Salida individual de i -ésima regla en modelo Mamdani
S_i	: Salida individual de i -ésima regla en modelo Sugeno
$\mu_C(w)$: Salida total del motor de inferencia en modelo Mamdani
z_0	: Salida total del motor de inferencia en modelo Sugeno
w_{ij}	: j -ésimo peso de ponderación de i -ésima neurona
x_j	: j -ésima entrada de la i -ésima neurona
θ_i	: Valor umbral de la i -ésima neurona
y_i	: Valor medido de la variable y
\hat{y}_i	: Valor estimado de la variable y
m	: Masa de partícula
dt	: Paso de tiempo
ω	: Velocidad angular de rotación
T	: Torque
M_c	: Masa de la carga de molino
g	: Valor de aceleración de gravedad
d	: Brazo de fuerza peso de la carga de molino

F_s	: Valor de fuerza ejercida por las partículas en contacto con sección S
d_s	: Distancia desde sección S hasta descanso de alimentación
$R.D$: Reacción en el descanso del lado de descarga
$R.A$: Reacción en el descanso del lado de alimentación
$\sum F_Y$: Fuerza neta ejercida por las partículas en la dirección del eje Y
m_R	: Masa de revestimientos de molino
D	: Desgaste de alzadores
p	: Presión en el descanso del lado de descarga
k	: Constante toneladas-presión
$offset$: Constante asociada a calibración de sensor de presión
J_c	: Nivel de llenado
Li_v	: Número de alzadores visibles en sección de anillo de alimentación
ES_v	: Número de espacios visibles en sección de anillo de alimentación
Li_t	: Total de alzadores en sección de anillo de alimentación
V_{carga}	: Volumen ocupado por la carga de molino
M_b	: Masa de bolas de la carga de molino
ε_b	: Porosidad equivalente de bolas de acero
ρ_b	: Densidad de bolas de acero
V_b	: Volumen ocupado por las bolas al interior de molino
M_m	: Masa de mineral de la carga de molino
ε_m	: Porosidad equivalente de mineral de acero
ρ_m	: Densidad de mineral
V_m	: Volumen ocupado por el mineral al interior de molino
R	: Reacción en el descanso del lado de descarga
P	: Potencia demandada por el molino
V	: Velocidad de operación
H	: Altura de alzadores

Abreviaciones

Mayúsculas

ANFIS	: Adaptive Network Based Fuzzy Inference System
CAD	: Computer Aided Design
COA	: Center of area
DEM	: Discrete Element Method
EKF	: Extended Kalman Filter
MAPE	: Mean Absolute Percentage Error
MHSE	: Moving Horizon State Estimation
MISO	: Multiple Input - Single Output
MOM	: Mean of maximum
NARMAX	: No-lineal autoregresivo, con entrada exógena y media móvil
NARX	: No-lineal autoregresivo, con entrada exógena
PCHIP	: Piecewise Cubic Hermite Interpolating Polynomial
PLS	: Partial Least Square
RMSE	: Root Mean Square Error
RNA	: Red neuronal artificial
SAG	: Semiautógeno
SSD	: Sistema sensor de desgaste
SVM	: Máquinas de Vectores de Soporte
TOF	: Time of flight



Capítulo 1. Introducción

1.1. Introducción general

La conminución se define como la acción de reducir un material a pequeñas partículas o fragmentos. En la industria minera, la ruptura es llevada a cabo a través de tronadura, chancado y molienda. El proceso de tronadura busca reducir el tamaño de las rocas, de manera de hacer abordable el transporte de ellas. Por su parte, el chancado y molienda, tienen como objetivo proporcionar partículas de un determinado tamaño, del orden de los 150 mm y 200 μm respectivamente, para una posterior separación del mineral valioso del material estéril.

Cerca del 55% de la energía eléctrica usada en operaciones mineras a nivel nacional es consumida en los procesos de conminución de mineral. Es por esta razón que tanto prácticas operacionales, desarrollos tecnológicos e innovaciones que permitan optimizar este proceso, tienen un gran impacto en el incremento de la productividad y eficiencia energética del negocio minero.

En lo que respecta a la molienda de mineral, esta se lleva a cabo en la mayoría de las plantas concentradoras por molinos rotatorios de grandes dimensiones tales como molinos SAG y molinos de bolas. Dado que la tendencia ha sido aumentar la capacidad de producción de los molinos SAG, llegando a diámetros de hasta 12 metros, los accionamientos de tipo piñón-corona convencionales han sido reemplazados por accionamientos *gearless*, en los cuales el estator del motor se encuentra instalado alrededor del manto del molino. De esta manera se logra una mayor eficiencia y disponibilidad del equipo, en el rango de potencias que fluctúan entre los 8 y 25 MW.

El estado de los alzadores de molinos SAG, así como el nivel de llenado de mineral al cual operan estos equipos, son variables que afectan en gran medida el movimiento de la carga al interior del molino, por lo que son de gran importancia en términos de eficiencia del proceso de conminución.

El desgaste de los alzadores tiene una gran influencia en la productividad y disponibilidad de un molino SAG, dado que es la principal causa de detenciones debido a inspecciones de la altura de estas piezas y también detenciones por recambio de éstas. Por su parte, el nivel de llenado es una variable que permite operar el molino en una zona óptima

desde el punto de vista de maximización del tonelaje a procesar, sin riesgo de una condición de sobrellenado perjudicial para la continuidad operacional.

Las dos variables de proceso mencionadas anteriormente no son medibles directamente durante la operación de un molino SAG, lo que provoca detenciones del molino y sub-operación de la capacidad de molienda de este equipo minero.

Lo anterior es de suma relevancia dado que el costo de detener por dos horas un molino SAG, tiempo mínimo que toma una inspección, es aproximadamente \$USD 100,000.

Este trabajo presenta un método de estimación en línea del desgaste de alzadores y nivel de llenado, utilizando variables de proceso y simulación DEM.

1.2. Trabajos previos

En la presente sección se realiza el análisis de trabajos previos que abordan alguno de los temas que abarca esta Tesis de Grado.

La revisión se basa principalmente en tres tópicos, siendo el primero de ellos la medición del desgaste de alzadores y nivel de llenado de molinos SAG, con énfasis en metodologías para la medición en línea de estas variables.

En segundo término, se revisa la metodología de modelación neuro-difusa, con foco en los fundamentos y ejemplos en aplicaciones industriales.

Finalmente, se revisan artículos relacionados al uso de software DEM como herramienta para identificar relaciones entre las condiciones de operación de molinos SAG con el estado de alzadores y el nivel de llenado.

1.2.1 Medición del desgaste de alzadores

- C. Stenström, “Ultrasonic for monitoring of mining mill linings: Pilots Experiments”, Center for Maintenance and Industrial Services, Division of Operation, Maintenance and Acoustics, Luleå University of Technology, Suecia, Reporte técnico, Abril 2016, [1].

Este trabajo estudia la factibilidad de usar ultrasonido para el monitoreo en línea del estado de desgaste de los revestimientos de un molino. Se propone una tecnología denominada “Waterflow ultrasonic” que usa una columna de agua para transmitir el ultrasonido hacia la coraza del molino y revestimientos. Luego, midiendo el tiempo de vuelo

(TOF) se puede inferir el grosor de los revestimientos sin necesidad de interrumpir la operación del molino.

La tecnología anterior se encuentra a nivel de pruebas piloto, e ilustra la necesidad de investigar metodologías para medir el desgaste de revestimientos sin afectar la disponibilidad del molino.

- Fundación Chile, “Casos de innovación de proveedores en la minería chilena”, *Santiago; Primera Edición (2016)*, [2].

El documento realiza una recopilación de cinco mejoras tecnológicas de alto impacto en la industria minera chilena, siendo de especial relevancia el tercer caso correspondiente al sistema sensor de desgaste, SSD, comercializado por la empresa HighService. Esta tecnología permite la transmisión inalámbrica de una señal proporcional al desgaste de los revestimientos, por medio del uso de un perno de sujeción que tiene incorporado dispositivos electrónicos.

El trabajo es de especial interés para el desarrollo de la Tesis debido a que sitúa el contexto en el cual la medición en línea del desgaste mejora la disponibilidad y labores de mantenimiento de un molino SAG. Si bien en la Tesis se busca lograr el mismo resultado, la metodología propuesta apunta a un sensor “virtual” del desgaste, que involucre menores costos de implementación y reemplazo del sensor SSD.

- R. Cartes and M. Valenzuela, “Empirical Determination of the Effect of Lifter Wear in Mill Power for Dry Grinding”, in *IEEE Trans. on Industry Applications*. vol. 53, no. 3, pp 2621-2627, 2017, [3].

Esta publicación presenta los resultados de un programa de pruebas experimentales para determinar el efecto del desgaste de alzadores en la potencia demandada por un molino. Se reportan curvas potencia-velocidad a partir de las cuales se propone un factor de desgaste en las expresiones de potencia de un molino. Los resultados indican que, para una cierta condición de carga y velocidad de operación, en molienda seca la potencia se incrementa a medida que los alzadores se desgastan.

La publicación permite verificar los resultados obtenidos en simulación DEM respecto al efecto de operar con alzadores desgastados.

- B. Castro and M. Valenzuela, “Experimental evaluation of power requirements for wet grinding and its comparison to dry grinding”, in *IEEE Industry Applications*

Society Annual Meeting. Cincinnati, OH, 2017, pp. 1-8 [4].

Esta publicación es la continuación de [3], dado que las curvas de potencia-velocidad son obtenidas en condición de molienda húmeda usando el mismo setup con las mismas condiciones de carga. Se evalúan tres diferentes razones agua-gravilla y se propone un factor de potencia húmedo-seco para estimar potencia en condición de molienda húmeda a partir de resultados de molienda seca bajo las mismas condiciones de carga.

- M. Rezaeizadeh *et al.*, “An experimental investigation of the effects of operating parameters on the wear of lifters in tumbling mills”, in *Minerals Engineering*, vol. 23, no. 7, pp. 558-562, 2009, [5].

En este trabajo se establecen relaciones entre las condiciones de operación de un molino y el perfil de desgaste de los alzadores. Se reportan resultados experimentales de un molino de laboratorio en condiciones de molienda seca y húmeda, al variar condiciones operacionales tales como velocidad, nivel de carga, tamaño de gravilla y material de alzadores.

La publicación permite verificar la fuerte influencia de la velocidad de operación y nivel de carga en la tasa de desgaste de los alzadores.

- F. Ahmadzadeh, J. Lundberg, “Remaining useful life prediction of grinding mill liners using an artificial neural network”, in *Minerals Engineering*, vol. 53, pp. 1–8, 2013, [6].

Esta publicación desarrolla un método que predice el tiempo de vida útil restante de los alzadores, sin necesidad de detener el molino. Se entrena una red neuronal artificial a partir de datos de proceso que afectan el desgaste de los alzadores y registros de altura de éstos.

El trabajo permite corroborar el patrón de la curva de desgaste a lo largo de una campaña, y resalta las ventajas de usar el tipo de interpolación PCHIP en los registros de altura.

1.2.2 Medición del nivel de llenado

- R.P King, *Modeling and simulation of mineral processing systems*. Englewood, Colorado: Society for Mining, Metallurgy, and Exploration, Inc. (SME), 2012, [7].

Libro que aborda técnicas y métodos de modelación fenomenológica de procesamiento de minerales. En lo que respecta a la molienda, se describe el movimiento de la carga de molinos rotatorios y se desarrollan expresiones para el torque y la potencia demandada por éstos.

Las descripciones cualitativas en base a leyes físicas de los procesos de molienda, son especialmente valiosas pues constituyen una sólida base para la interpretación de los resultados obtenidos por medio de simulación DEM.

- D. Sbarbaro and René del Villar, *Advanced control and supervision of mineral processing plants*. London, United Kingdom: Springer, 2010, [8].

Libro que aborda los tipos de variables de proceso medidas, métodos de medición, tecnologías de control industrial y objetivos de control de plantas de procesamiento de minerales. Dentro de la temática de simulación de procesos, se presenta una librería de módulos de simulación desarrollados en Matlab, que incluye circuitos de molienda.

Las respuestas dinámicas de simulaciones de nivel de llenado y potencia ilustran la sensibilidad de estas variables ante perturbaciones como la distribución de tamaños en la alimentación al molino y la dureza del mineral.

- J. Salazar *et al.*, “Dynamic modelling and simulation of semiautogenous mills”, in *Minerals Engineering*, vol. 22, no. 1, pp. 70–77, 2009 [9].

Esta publicación presenta un simulador dinámico de la operación de molinos SAG basado en ecuaciones de balance poblacional. El modelo es capaz de predecir la evolución de las principales variables de operación, como la tasa de descarga, nivel de llenado de carga, potencia y posición de la carga, en función de otras importantes variables como la velocidad de rotación y las características del mineral ingresado al molino.

Las constantes de tiempo de las respuestas de los modelos de nivel de llenado y potencia ante variaciones de la tasa de alimentación de mineral y velocidad rotacional, constituyen una valiosa referencia en la interpretación de los registros experimentales de proceso disponibles.

- J. Pontt, “MONSAG: A new monitoring system for measuring the load filling of a SAG mill”, in *Minerals Engineering*, vol. 17, no. 11-12, pp. 1143–1148, 2004, [10].

La publicación desarrolla un sistema de monitoreo para la medida indirecta del nivel

de llenado de molinos SAG. El principio de operación se basa en el procesamiento de variables eléctricas del control vectorial del motor y variables de proceso. La metodología no utiliza la presión de los descansos como una entrada.

Si bien no se reporta el porcentaje de error medio en las estimaciones, se indica que el método aplicado a un molino SAG de 15000 hp logró mejorar en un 3.2% el tonelaje medio procesado y en 3.8% el consumo específico de energía.

- M. Moys, “The control of autogenous and semi-autogenous mills: the relationship between measurements of bearing pressure and parameters describing the mill load” in *Journal of the Southern African Institute of Mining and Metallurgy*, vol. 72, no. 11, pp. 401-408, 1980, [11].

Esta publicación presenta un modelo matemático que relaciona la presión de los descansos con parámetros que definen la carga de un molino, como la masa, el volumen y el ángulo de reposo. Los valores obtenidos a partir de este modelo son comparados con valores experimentales y se concluye que se puede estimar la masa de la carga de un molino si las mediciones de la presión de los descansos son precisas.

La relación lineal entre la presión de los descansos y la masa de la carga presentada en este trabajo sustenta la utilización de la señal de presión del descanso de descarga en la estimación del nivel de llenado.

- H. Robles *et al.*, “New approach for load level estimation in SAG mills using a sensor system and optimization algorithm” in *Procemin 2015*, Chile, [12].

Esta presentación resalta los beneficios de la medición en línea del nivel de llenado, y presenta un método de inferencia del nivel de llenado a partir de mediciones de la presión de descansos, potencia y posición de la carga. Se resalta que se obtuvieron estimaciones satisfactorias del nivel de llenado de un molino industrial de 38’x22’.

El trabajo respalda la elección de la potencia y presión de los descansos como variables claves en la estimación del nivel de llenado de un molino SAG.

- G. Acuña, M. Curilem and F. Cubillos, “Desarrollo de un Sensor Virtual basado en Modelo NARMAX y Máquina de Vectores de Soporte para Molienda Semiautógena” in *Revista Iberoamericana de Automática e Informática Industrial RIAI*, vol. 11, no 1, pp. 109-116, 2014, [13].

La publicación presenta una comparación del rendimiento de dos herramientas de modelamiento basadas en datos, las SVM y las RNA para implementar modelos dinámicos de tipo NARX y NARMAX que actúen como estimadores del nivel de llenado de un proceso de molienda semiautógena. Los modelos desarrollados estiman la salida a partir de la presión de los descansos y valores pasados del nivel de llenado.

El trabajo constituye una base para la utilización de la presión en los descansos para estimar el nivel de llenado, dado que la fuerte relación entre estas dos variables puede ser aprovechada al utilizar herramientas de modelación en base a ejemplos.

- K. Carvajal and G. Acuña, “Estimation of State Variables in Semiautogenous Mills by Means of a Neural Moving Horizon State Estimator” in *Advances in Neural Networks*, ISSN 2007, pp. 1255-1264, [14].

La publicación presenta un método de estimación de estados de horizonte móvil (MHSE) acoplado a una red neuronal como modelo dinámico de un molino SAG. El método estima el nivel de llenado y la proporción de granulometría fina de entrada al molino a través de una optimización local. Los datos de nivel de llenado utilizados para el entrenamiento de la RNA se obtuvieron indirectamente a través del torque demandado por el accionamiento.

En el desarrollo del estimador de horizonte móvil, se ratifica la importancia de la señal de presión de los descansos al momento de inferir el nivel de llenado de un molino.

- J.D. le Roux *et al.*, “An EKF observer to estimate semi-autogenous grinding mill hold-ups” in *Journal of Process Control*, vol. 51, pp. 27-41, 2017, [15].

La publicación presenta un observador no lineal de molienda semiautógena, para estimar el nivel de llenado de un molino, así como también el contenido de agua y material fino. El modelo del observador usa la tasa de acumulación de sólidos y la tasa de descarga del molino como parámetros. Un filtro EKF es aplicado en simulación para estimar los estados del modelo y valores de los parámetros.

El trabajo utiliza un observador de estados en una planta simulada, dado que en circuitos de molienda industriales no existe instrumentación en la descarga del molino. Lo anterior valida el enfoque de usar simuladores, como por ejemplo software DEM, para establecer metodologías que permitan estimar el nivel de llenado.

- J. Tang *et al.*, “Soft sensor for parameters of mill load based on multi-spectral segments PLS sub-models and on-line adaptive weighted fusion algorithm” in

Neurocomputing, vol. 78, no 1, pp. 38-47, 2012, [16].

La publicación presenta una metodología basada en un modelo de mínimos cuadrados parciales (PLS) y un algoritmo adaptivo para estimar la cantidad de mineral, agua y medios de molienda de un molino de bolas. Las estimaciones se obtienen a partir del procesamiento del espectro de vibraciones de la coraza del molino.

El trabajo resalta que el procesamiento de las vibraciones de un molino constituye una valiosa herramienta para inferir el nivel de llenado.

1.2.3 Modelación neuro-difusa

- Chin-Teng Lin and C. S. George Lee, *Neural Fuzzy Systems: A Neuro-Fuzzy Synergism to Intelligent Systems*. Upper Saddle River, New Jersey: Prentice Hall, 1996, [17].

Libro que revisa los fundamentos y aplicaciones de los sistemas difusos y redes neuronales artificiales, así como también se presentan las ventajas de la integración de estos tipos de sistemas. Se examinan sistemas de control neuro-difusos, redes neuronales difusas y sistemas híbridos. También se incluyen simulaciones de sistemas difusos y redes neuronales en Matlab.

El libro sustenta la elección de modelos neuro-difusos para la modelación del nivel de llenado y desgaste de alzadores de molinos SAG, dado el alto grado de no linealidad, interacciones entre variables y perturbaciones no medibles propias del proceso de molienda.

- M. Negnevitsky, *Artificial Intelligence: A Guide to Intelligent Systems*. London: Addison Wesley, 2005, [18].

Libro que aborda técnicas de construcción de sistemas inteligentes basados en sistemas expertos, redes neuronales, sistemas difusos y computación evolutiva. Se entregan los principios detrás de estas técnicas, procedimientos de construcción de los sistemas y campos de aplicación.

El libro es especialmente valioso en lo que respecta a la revisión de la estructura y algoritmos de aprendizaje de un sistema neuro-difuso ANFIS.

- L.A Zadeh, "Fuzzy Logic" in *IEEE Comput*, vol.1, no. 4, pp. 83-93, 1988, [19].

Publicación que presenta una exposición condensada de los principios básicos de la

lógica difusa y describe algunas aplicaciones representativas. También se abordan las formas de representación e inferencia, reglas básicas de inferencia, variables lingüísticas y su aplicación en control difuso.

El trabajo entrega sólidas bases del buen desempeño de sistemas difusos en escenarios de incerteza e imprecisión.

- M.J Willis *et al.*, “Artificial neural networks in process engineering” in *IEEE Proceedings D (Control Theory and Applications)*, vol.138, pp. 256-266, 1991, [20].

Publicación que presenta los conceptos involucrados en la formulación de redes neuronales artificiales. Se discute además la conveniencia de éstas para solucionar problemas de ingeniería de procesos, presentando resultados obtenidos tanto por medio de estudios de simulación como por aplicaciones a datos de procesos industriales.

El trabajo respalda las potencialidades de una RNA de representar, a partir de una etapa de aprendizaje, complejas dinámicas de procesos industriales.

- J.-S. Roger Jang, “ANFIS: Adaptive-network-based fuzzy inference system” in *IEEE Trans. Syst. Man Cybern.*, vol. 23, no. 3, pp. 665-685, 1993, [21].

La publicación presenta la arquitectura y procedimiento de aprendizaje de un sistema ANFIS, el cual corresponde un sistema de inferencia difuso implementado por medio de redes neuronales. Se ilustra a través de ejemplos de simulación que, usando un procedimiento de aprendizaje híbrido, ANFIS puede representar un mapeo entrada-salida basado en conocimiento humano (en la forma de reglas if-then) y conjuntos de datos de entrada-salida.

El trabajo es de gran relevancia para desarrollo de la presente Tesis, dado que corresponde al tipo de sistema neuro-difuso utilizado para modelar el desgaste de los alzadores y el nivel de llenado.

- S. Chiu, “Method and software for extracting fuzzy classification rules by subtractive clustering” in *1996 Biennial Conference of the North American*. Berkeley, USA [22].

Publicación que presenta un rápido y robusto método para extraer reglas difusas a partir de datos. Este método obtiene las reglas iniciales por medio de subtractive clustering y luego optimiza los parámetros de las funciones de pertenencia de éstas por medio de un algoritmo de descenso del gradiente.

En el desarrollo de la presenta Tesis se utiliza subtractive clustering para obtener un

mínimo conjunto de reglas que representen el comportamiento dinámico del sistema, para luego optimizar los parámetros de las reglas por medio del aprendizaje híbrido de ANFIS.

- B. Li *et al* “Approach to complex hydrogen reactor optimization modeling based on ANFIS” *2012 IEEE 2nd International Conference on Cloud Computing and Intelligent Systems (CCIS)*. Hangzhou, China, 2012, [23].

Publicación que presenta la modelación de un reactor de hidrógeno basado en ANFIS combinado con el método subtractive clustering. Se obtienen estimaciones satisfactorias de la salida de voltaje de un reactor por medio del modelo neuro-difuso desarrollado.

El trabajo demuestra que ANFIS complementado con subtractive clustering para la determinación de las reglas iniciales, representa exitosamente las dinámicas de complejos sistemas industriales con gran precisión.

- A. Jahic *et al.*, "Photovoltaic power output forecasting with ANFIS" in *Mediterranean Conference on Power Generation, Transmission, Distribution and Energy Conversion (MedPower 2016)*, Belgrade, 2016, pp. 1-8, [24].

Esta publicación presenta un modelo basado en ANFIS capaz de predecir con precisión la potencia de salida de una planta fotovoltaica de 7.5 kW de capacidad nominal, en intervalos de tiempo de una hora. Las entradas del modelo corresponden a la radiación solar, temperatura de los módulos y temperatura ambiente.

El trabajo demuestra la idoneidad de la técnica ANFIS en escenarios de alta incertidumbre, como es la relación de las condiciones meteorológicas con la producción de energía de plantas fotovoltaicas.

- L. Minchala *et al.*, “A comparative study of black-box models for cement quality prediction using input-output measurements of a closed circuit grinding” in *2016 Annual IEEE Conference on Systems Conference (SysCon)*. Orlando, FL, USA, [25].

La publicación presenta una comparación de tres metodologías de diseño de un modelo capaz de predecir la calidad del producto en un circuito de molienda de una planta de cemento. Los enfoques de modelación comparados corresponden a modelos estadísticos, redes neuronales artificiales y ANFIS. La data utilizada para generar y evaluar los modelos se obtuvo de la base de datos de una planta de cemento industrial.

Los resultados de este trabajo reportan que los errores de estimación más bajos se

obtuvieron por medio de ANFIS. Además, se reporta que la exactitud de las estimaciones depende de la exactitud de la data de terreno, y que esta debe cubrir diferentes condiciones de operación.

1.2.4 Uso de software DEM en simulación de molinos rotatorios

- C.O Sullivan. *Particulate discrete element modelling, a geomechanics perspective* Taylor & Francis e-Library, Londres (UK) y Nueva York (USA), 2011, [26].

Libro que aborda temas relacionados a los tiempos de integración y estabilidad de las simulaciones, tipos de partículas, modelos de contacto y condiciones de borde. También se presenta, en el capítulo 11, una guía para realizar simulaciones DEM que cubre aspectos como diferencias entre realizar simulaciones en dos y tres dimensiones, selección de parámetros de contacto y el efecto del número y forma de partículas en los tiempos de simulación.

Los aspectos cubiertos por el libro proporcionan una sólida base al momento de configurar simulaciones DEM, así como también para la interpretación de resultados.

- X. Quiu *et al.*, “Prediction of Wear of Mill Lifters Using Discrete Element Method” in Mular A(ed) SAG 2001, Vancouver, B.C. Canada, [27].

Esta publicación introduce una modificación a los códigos DEM convencionales, la cual consiste en la implementación de la ley de desgaste de Archad. Se reporta que el código DEM modificado es capaz de predecir satisfactoriamente los perfiles y la tasa de desgaste de los alzadores de un molino.

El trabajo es de especial relevancia debido a que ley de desgaste presentada corresponde a la que utiliza el software Rocky DEM para simular el desgaste acelerado de los alzadores.

- M. Rezaeizadeh *et al.*, “A new predictive model of lifter bar wear in mills”, *Minerals Engineering*, vol. 23(15), pp. 1174-1181, 2014, [28].

En esta publicación se desarrolla un modelo para predecir el desgaste de alzadores basado en la presión ejercida en éstos, velocidad de operación y condiciones de fricción. El modelo se desarrolla a partir de relaciones fenomenológicas y simulaciones DEM. Los resultados de estimación se contrastan con inspecciones de un molino SAG industrial.

El trabajo respalda la utilización de software DEM para el desarrollo de un modelo que permita estimar el desgaste de alzadores y que sea implementable en tiempo real.

- J. T. Kalala, M. M. Bwalya and M. H. Moys, “Discrete element method (DEM) modelling of evolving mill liner profiles due to wear. Part II. Industrial case study” in *Minerals Engineering*, vol. 18, 2005, pp. 1392–1397, [29].

La publicación presenta una expresión empírica para estimar la altura de alzadores validada con registros correspondientes a un molino de bolas en condición de molienda seca. La expresión se obtuvo por medio de resultados de simulaciones DEM y utiliza como entradas el ángulo de ataque del alizador y valores pasados de altura.

El trabajo ilustra la importancia de contar con un modelo que sea capaz de predecir la altura de los alzadores en tiempo real, y resalta la validez de las simulaciones DEM para replicar la evolución del desgaste de los alzadores de un molino.

- N. Djordjevic, “Discrete element modelling of the influence of lifters on power draw of tumbling mill”, in *Minerals Engineering*, vol. 16, pp. 331-336, 2003, [30].

Publicación que estudia el efecto de la condición de desgaste de los alzadores en la potencia demandada por un molino. Los resultados se obtuvieron por medio de simulación DEM y muestran que a medida que los alzadores se desgastan la potencia demanda por el molino aumenta.

La publicación respalda la elección de la potencia como una variable fundamental en la estimación del desgaste de alzadores, así como también sustenta los resultados de simulación DEM obtenidos en la presente Tesis.

- P. Owen and P. Cleary “The relationship between charge shape characteristics and fill level and lifter height for a SAG mill” in *Minerals Engineering*, vol. 83, pp. 19-32, 2015, [31].

La publicación presenta un modelo que permite estimar el nivel de llenado y la altura de los alzadores de un molino SAG a partir de mediciones de la posición del pie y el hombro de la carga. El modelo se desarrolló a partir del ajuste de los parámetros de expresiones lineales con datos obtenidos por medio de simulación DEM.

La distribución de tamaños de mineral y bolas usada en la presente Tesis se basa en la utilizada en este trabajo.

- P. Cleary and P. Owen “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” in *Minerals Engineering*, vol. 117, pp. 42-62, 2018, [32].

La publicación es la continuación de [31] y presenta los resultados de un conjunto de 22 simulaciones DEM, a partir de los cuales se ajustan los parámetros de ecuaciones lineales para estimar el nivel de llenado y la altura de alzadores. Los modelos desarrollados estiman las variables anteriores en base a la posición de la carga del molino, la velocidad de operación y la potencia demandada.

Es importante consignar que la inclusión de la variable potencia, respecto a [31], ratifica la importancia de esta variable eléctrica en la estimación tanto del nivel de llenado como de la altura de alzadores. Además, la relación entre desgaste de alzadores y potencia sustenta los resultados de las simulaciones DEM obtenidos en la presente Tesis.

- *Manual – Workshop 04 - SAG Mill (Wear and Particle Energy Spectra)*, Rocky, 2017 [33].

El presente manual define el procedimiento para habilitar y configurar el desgaste de alzadores en el software Rocky DEM. Además, se presenta un set parámetros de contacto en la simulación de un molino SAG industrial. Estos parámetros de contacto se utilizan en las simulaciones DEM de la presente Tesis.

1.2.5 Discusión

La literatura muestra que para la estimación del desgaste de alzadores se han desarrollado tecnologías basadas en mediciones efectuadas en la coraza del molino [1] o incluso desde el interior [2]. El costo de mantenimiento de este tipo de sensores constituye una importante limitante, que ha propiciado el desarrollo de sensores que de manera no invasiva logren inferir la altura de los alzadores.

En este ámbito, se revisaron trabajos que de forma experimental o mediante simulación DEM relacionan la altura de los alzadores con las condiciones de operación [3], [5], [30]; y enfoques que desarrollan expresiones a partir de este tipo de relaciones para la estimación del desgaste en tiempo real [28], [29], [31], [32].

Cabe destacar que en los trabajos anteriores no se incluye el tiempo de operación del

molino como una variable relevante en el desgaste de los alzadores, lo que sí se desarrolla en [6] mediante un ajuste por medio de redes neuronales y datos de variables de proceso.

Este trabajo, incluye el tonelaje procesado, relacionado con el tiempo de campaña, como entrada del modelo de desgaste, además de incluir variables operacionales como la presión del descanso de descarga, potencia y velocidad. El modelo se desarrolla íntegramente a partir de datos de terreno utilizando modelación neuro-difusa, dado que un sistema difuso es idóneo para un proceso que presenta incertidumbre en sus condiciones de operación como lo es el proceso de molienda SAG [17].

Por otra parte, la revisión muestra que se han desarrollado métodos para estimar el nivel de llenado en línea, basados en resultados de simulaciones DEM que replican un amplio rango de variación de las condiciones de operación [31], [32]. Sin embargo, la forma de abordar la problemática ha sido por medio del ajuste de parámetros de expresiones lineales que relacionan las variables de interés. En este trabajo, se presenta un modelo no lineal neuro-difuso que relaciona las variables de operación, incluyendo la altura de los alzadores, con el nivel de llenado. Este tipo de modelo ha demostrado ser robusto en sistemas no lineales, con acoplamiento entre las distintas variables y que presentan incertidumbre [23], [24], [25].

Por otro lado, se revisaron trabajos en que los modelos del nivel de llenado se desarrollan a partir de datos extraídos directamente de molinos industriales [13], [14], molinos de laboratorio [16] y simuladores de molienda SAG distintos a DEM [9], [15].

Si bien los enfoques anteriores utilizan técnicas avanzadas de modelación, los datos no siempre cubren todas las condiciones posibles de operación, lo que merma la robustez de las estimaciones. En este trabajo, se cubre un amplio rango de operación por medio de simulación DEM, y posteriormente se realiza un ajuste de parámetros del modelo en base a datos de terreno.

1.3. Hipótesis de Trabajo

Las técnicas de identificación neuro-difusas permiten la modelación de procesos no-lineales y que presentan incertidumbre en sus parámetros. Dada la robustez de estas técnicas, es posible estimar en línea el estado de los alzadores y el nivel de llenado de molinos SAG, a partir de la construcción de un modelo en base a datos de entrada-salida del proceso.

1.4. Objetivos

1.4.1 Objetivo General

El objetivo general de este trabajo consiste en plantear un modelo neuro-difuso basado en datos entrada-salida de proceso para estimar el estado de los alzadores y nivel de llenado de molinos SAG, y generar algoritmos para su implementación.

1.4.2 Objetivos Específicos

- Construcción de un estimador del desgaste de alzadores a partir de data de terreno.
- Calibración DEM de un modelo de molino SAG, a partir de datos y planillas de inspección obtenidos desde una planta concentradora del norte de Chile.
- Construcción de un estimador del nivel de llenado a partir de resultados de simulación DEM.
- Generación algoritmos de estimación del desgaste de alzadores y nivel de llenado para implementación en tiempo real.

1.5. Alcances y limitaciones

- Las simulaciones DEM del modelo de molino SAG se realizarán utilizando dos computadores con procesador i7 y 16 GB de memoria RAM cada uno, disponibles en el laboratorio de Control de Movimiento de la Universidad de Concepción.
- Las planillas de inspecciones, tanto de desgaste de alzadores como de nivel de llenado, se asumirán representativas de las reales condiciones de operación del proceso.
- Se generarán algoritmos para la implementación en tiempo real del modelo de molienda SAG, sin contemplar una etapa de implementación durante el desarrollo de la Tesis.

1.6. Temario y Metodología

En el capítulo 2 se describe la modelación neuro-difusa, abordando los fundamentos de sistemas difusos y redes neuronales. Se presenta el modelo ANFIS utilizado en el desarrollo de la presente Tesis.

En el capítulo 3 se desarrolla el modelo de desgaste de alzadores. Se presentan los

registros de terreno, estructura del modelo y resultados de las estimaciones.

En el capítulo 4 se desarrolla un análisis de las simulaciones DEM. Se reportan curvas potencia-velocidad, potencia-nivel de llenado y curvas de reacción-nivel de llenado.

En el capítulo 5 se desarrolla el modelo de nivel de llenado. Se presentan los registros de terreno, estructura del modelo y resultados de las estimaciones.

En el capítulo 6 se presenta el ajuste del modelo de nivel de llenado con datos de terreno.

Finalmente, en el capítulo 7 se entregan las conclusiones del trabajo.



Capítulo 2. Modelación Neuro-difusa

2.1. Introducción

Un sistema neuro-difuso integra dos poderosas tecnologías complementarias entre sí, como lo son la lógica difusa y las redes neuronales. Este tipo de sistema retiene los beneficios de un sistema basado en lógica difusa y le proporciona ventajas de las redes neuronales, como lo son la capacidad de aprendizaje, optimización y tolerancia a fallas.

Dado que un modelo del tipo neuro-difuso es inherentemente un sistema basado en lógica difusa, este permite manejar incerteza e imprecisión en la modelación de complejos sistemas no lineales dinámicos como lo son los procesos mineros.

En este capítulo se presenta el marco conceptual de los sistemas difusos y las redes neuronales, para luego presentar la estructura y algoritmo de aprendizaje del modelo neuro-difuso ANFIS [21], el cual ha sido ampliamente utilizado en la modelación y control de complejos procesos industriales [23], [24], [25].

2.2. Sistemas difusos

Los conjuntos difusos y la lógica difusa se desarrollaron como medios para representar, manipular y utilizar información incierta y proporcionar un marco de referencia para manejar la incerteza e imprecisión en aplicaciones del mundo real [17].

En la teoría clásica de conjuntos, un elemento del universo puede pertenecer o no pertenecer a un conjunto, lo que admite solo dos grados de pertenencia: total o nulo.

Por su parte, los conjuntos difusos pueden ser considerados una generalización de la teoría clásica de conjuntos, dado que permiten un cierto *grado de pertenencia* de los elementos, en el rango $[0,1]$.

La función matemática que mapea al intervalo $[0,1]$ los elementos comprendidos dentro de un cierto rango conocido como *universo de discurso*, se conoce como *función de pertenencia* de un conjunto difuso.

Así como la teoría de conjuntos difusos es una extensión de la teoría clásica de conjuntos, la lógica difusa también lo es respecto a la lógica bivalente.

Es en este contexto que, una *variable lingüística* se entiende como una variable cuyos valores son palabras o sentencias en un lenguaje natural o artificial [19]. Por ejemplo,

velocidad es una variable lingüística si asume valores como *lento*, *rápido*, *muy rápido*, etc.

Por otro lado, la lógica difusa utiliza sentencias condicionales o *reglas difusas*. La forma general de una regla difusa se muestra en la ecuación (2.1) para el caso de un sistema MISO.

$$R^i : \text{IF } x \text{ is } A_i, \dots, \text{AND } y \text{ is } B_i, \text{THEN } z = C_i, \quad i = 1, 2, \dots, n, \quad (2.1)$$

donde,

x, y, z : Variables lingüísticas.

A_i, B_i, C_i : Conjuntos difusos.

Tanto “ x is A_i ” como “ y is B_i ” constituyen el *antecedente* de la regla R^i , mientras que “ $z = C_i$ ” corresponde a la parte del *consecuente* de la regla.

Una variante del tipo de regla mostrado en la ecuación (2.1) se obtiene cuando el consecuente de la regla se representa como una función de las variables x e y , tal como se muestra en la ecuación (2.2).

$$R^i : \text{IF } x \text{ is } A_i, \dots, \text{AND } y \text{ is } B_i, \text{THEN } z = f_i(x, \dots, y), \quad i = 1, 2, \dots, n, \quad (2.2)$$

donde,

x, y : Variables lingüísticas.

z : Valor no-difuso.

Es importante consignar que una regla difusa dispone de valores lingüísticos como entradas, mientras que su salida(s) pueden ser valores lingüísticos o valores no-difusos, como se observa en las ecuaciones (2.1) y (2.2), respectivamente.

Por otro lado, un sistema de inferencia difuso se puede definir como el proceso de mapeo desde determinadas entradas a una salida, usando la teoría de conjuntos difusos. La Figura 2.1 muestra la estructura de un sistema de inferencia difuso.




Figura 2.1 Arquitectura de un Sistema de Inferencia Difuso (Fuente: Elaboración propia).

En la interfaz de fusificación se determina el grado de pertenencia de cada entrada no-difusa a los respectivos conjuntos difusos. Lo anterior se lleva a cabo por medio de la evaluación de cada variable de entrada en las respectivas funciones de pertenencia de los conjuntos difusos.

La base de reglas consiste en una colección de reglas difusas del tipo IF-THEN en las que los antecedentes y consecuentes involucran variables lingüísticas.

El motor de inferencia, por su parte, constituye el núcleo del sistema de inferencia difuso, dado que modela la inferencia humana por medio del marco conceptual de la lógica difusa. Las técnicas de inferencia difusas más utilizadas corresponden al método de Mamdani y al método de Sugeno [18].

En un sistema de inferencia del tipo Mamdani, las reglas difusas presentan valores lingüísticos en la parte del consecuente, tal como se muestra en la ecuación (2.1). Si un sistema de este tipo se compone de las reglas R^1 y R^2 , las *fuerzas de disparo* de estas últimas se calculan por medio del operador mínimo (\wedge) de acuerdo con las ecuaciones (2.3) y (2.4), respectivamente.

$$\alpha_1 = \mu_{A_1}(x) \wedge \mu_{B_1}(y) \quad (2.3)$$

donde,

$\mu_{A_1}(x)$: Grado de pertenencia de x con el conjunto difuso A_1 .

$\mu_{B_1}(x)$: Grado de pertenencia de y con el conjunto difuso B_1 .

$$\alpha_2 = \mu_{A_2}(x) \wedge \mu_{B_2}(y) \quad (2.4)$$

donde,

$\mu_{A_2}(x)$: Grado de pertenencia de x con el conjunto difuso A_2 .

$\mu_{B_2}(x)$: Grado de pertenencia de y con el conjunto difuso B_2 .

El cálculo de la salida individual de la i -ésima regla difusa se muestra en la ecuación (2.5), mientras que la salida total del motor de inferencia se muestra en la ecuación (2.6).

$$\mu_{C_i}(w) = \alpha_i \wedge \mu_{C_i}(w) \quad (2.5)$$

donde,

α_i : Fuerza de disparo de i -ésima regla.

$\mu_{c_i}(w)$: Función de pertenencia del consecuente de i-ésima regla.

$$\mu_c(w) = \mu_{c_1}(w) \vee \mu_{c_2}(w) \quad (2.6)$$

donde,

$\mu_{c_1}(w)$: Salida individual de la regla R¹.

$\mu_{c_2}(w)$: Salida individual de la regla R².

\vee : Operador máximo.

Por su parte, en un sistema de inferencia del tipo Sugeno las reglas presentan funciones de las variables de entrada en la parte del consecuente, tal como se muestra en la ecuación (2.2). Debido a que las evaluaciones de estas funciones presentan valores específicos según las variables de entrada, las funciones de pertenencia utilizadas en los consecuentes son del tipo singleton. Una función de pertenencia del tipo singleton presenta un valor unitario en solo un punto del universo de discurso.

En un sistema Sugeno formado por dos reglas con los mismos antecedentes que el sistema de tipo Mamdani anterior, la salida individual de la i-ésima regla se calcula de acuerdo con la ecuación (2.7).

$$S_i = \alpha_i \cdot f_i(x, y) \quad (2.7)$$

donde,

α_i : Fuerza de disparo de i-ésima regla.

$f_i(x, y)$: Función del consecuente de la i-ésima regla.

Luego, la salida total del motor de inferencia se calcula según la ecuación (2.8).

$$z_0 = \frac{S_1 + S_2}{\alpha_1 + \alpha_2} \quad (2.8)$$

donde,

S_1, S_2 : Salidas individuales de reglas 1 y 2.

α_1, α_2 : Fuerzas de disparo de reglas 1 y 2.

Finalmente, la interfaz de defusificación de la Figura 2.1 mapea los resultados difusos obtenidos desde el motor de inferencia a resultados no-difusos. Los métodos de defusificación más comunes son el método COA (center of area) y el método MOM (mean

of maximum) [17]. En el caso de un sistema del tipo Sugeno, no es necesario defusificar la salida del motor de inferencia dado que ésta corresponde a un valor no-difuso.

2.3. Redes neuronales artificiales

El cerebro humano es un sofisticado procesador de información. Se estima que posee aproximadamente 10^{11} neuronas y entre 10^{14} - 10^{15} sinapsis (conexiones entre neuronas) [20]. Las redes neuronales artificiales, RNA's, emulan la arquitectura y capacidades de sistemas neuronales biológicos, para así modelar complejos sistemas.

La Figura 2.2 muestra el modelo matemático de una neurona artificial. Las entradas x_1, x_2, \dots, x_m representan las m-ésimas dendritas de una neurona, mientras que la salida y_i representa el axón de la misma. Para emular la reacción química de excitación de una neurona, se utiliza una función de activación cuyo argumento corresponde a la suma ponderada de las entradas por medio de una función de integración. En la neurona de la Figura 2.2 la función de activación se denota por $a(\cdot)$ y la función de integración por $f(\cdot)$. La ponderación de las distintas entradas se realiza por medio de los pesos, denotados por $w_{i1}, w_{i2}, \dots, w_{im}$, los cuales representan las sinapsis entre distintas neuronas.

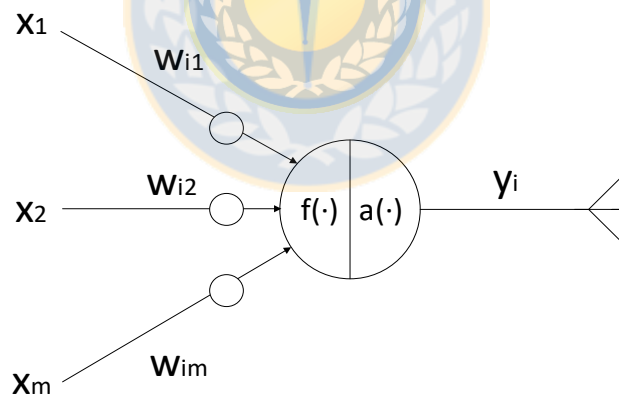


Figura 2.2 Arquitectura de una neurona artificial (Fuente: Elaboración propia).

La función de integración es usualmente una función lineal de las entradas, tal como se muestra en la ecuación (2.9).

$$f_i = \sum_{j=1}^m w_{ij} \cdot x_j - \theta_i \quad (2.9)$$

donde,

w_{ij} : j-ésimo peso de ponderación de la i-ésima neurona.

x_j : j-ésima entrada de la i-ésima neurona.

θ_i : Valor umbral de la i-ésima neurona.

Por otro lado, una típica función de activación corresponde a la función sigmoide, cuya ecuación se muestra en la ecuación (2.10).

$$a(x) = \frac{1}{1 + e^{-x}} \quad (2.10)$$

donde,

x : Resultado de la función de integración.

Diferentes funciones de integración y de activación se pueden encontrar en [17]. Cabe mencionar que la función de activación permite que una RNA pueda representar relaciones no lineales [20].

Entre las diversas topologías de RNA's, se encuentran las *single-layer feedforward*, *multilayer feedforward* y *recurrent*. Estas topologías se diferencian en la forma de conexión entre las distintas neuronas [17].

En este trabajo se estudia con mayor detalle la topología *multilayer feedforward*, dado que es la utilizada en el algoritmo neuro-difuso ANFIS para modelar tanto el desgaste de alzadores como el nivel de llenado. Las RNA's *multilayer feedforward*, a diferencia de las *single-layer feedforward*, se componen de varias capas de neuronas interconectadas.

Por otro lado, las neuronas de esta topología solo admiten como entradas las salidas de las neuronas de la capa anterior, lo que las diferencia de las *recurrent networks* que presentan lazos de retroalimentación entre neuronas.

En la Figura 2.3 se muestra un ejemplo de una red *multilayer feedforward*.




Figura 2.3 RNA multilayer feedforward (Fuente: Elaboración propia).

Se distinguen tres tipos de capa:

- *Capa de entrada:* Está formada por n unidades (siendo n el número de entradas externas) que distribuyen las señales de entrada a la capa siguiente.
- *Capas ocultas:* Están formadas por neuronas que no tienen contacto físico con el exterior. No existe una restricción para el número de capas ocultas.
- *Capa de salida:* Está formado por m neuronas (siendo m el número de salidas externas) cuyas salidas constituyen el vector de salidas externas de la red.

Las neuronas en la capa de entrada no llevan a cabo funciones de procesamiento de señal, sino que solo proporcionan un medio por el cual los datos son introducidos a la RNA. Luego, estas señales son traspasadas por medio de las conexiones entre las capas ocultas, hasta llegar a la capa de salida.

Por otra parte, la capacidad de aprendizaje de una RNA se encuentra relacionada con la actualización de los valores de los pesos que interconectan las distintas neuronas.

En general, los algoritmos de aprendizaje se clasifican en algoritmos de aprendizaje supervisado, aprendizaje reforzado y aprendizaje no-supervisado.

En el aprendizaje supervisado, que es el utilizado en este trabajo, una red neuronal es alimentada con una secuencia de ejemplos de pares de entrada-salida. El error generado entre la salida de la red neuronal y la salida deseada se utiliza para corregir los valores de los pesos de forma tal que la salida de la red se ajuste a la salida de referencia.

Los tipos de aprendizaje reforzado y no-supervisado se presentan en detalle en [17].

2.4. ANFIS

Un modelo ANFIS, desde el punto de vista estructural, es equivalente a un sistema difuso del tipo Sugeno. La metodología ANFIS se creó originalmente en 1993 por Jang [21] y ha sido utilizada satisfactoriamente en la modelación de diversos procesos.

La arquitectura ANFIS es descrita a partir de la Figura 2.4, en la cual se muestra un sistema de dos entradas, dos conjuntos difusos por entrada, cuatro reglas difusas y una salida.

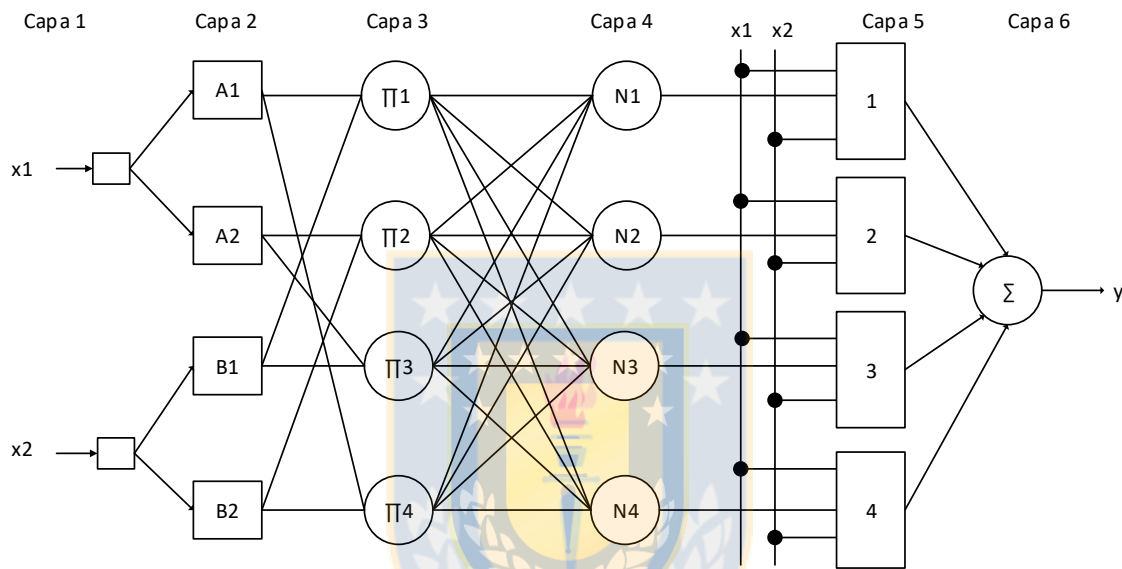


Figura 2.4 Arquitectura ANFIS (Fuente: Elaboración propia).

La descripción genérica de una de las cuatro reglas se muestra en la ecuación (2.11).

$$\text{if } x_1 \text{ is } A_m \text{ and } x_2 \text{ is } B_n, \text{ then } f_i = p_i \cdot x_1 + q_i \cdot x_2 + r_i \quad (2.11)$$

donde,

x_1, x_2 : Entradas del sistema.

A_m : m-ésimo conjunto difuso de la entrada x_1 .

B_n : n-ésimo conjunto difuso de la entrada x_2 .

f_i : Salida individual de i-ésima regla.

p_i, q_i, r_i : Parámetros de salida de i-ésima regla.

ANFIS posee 6 capas, cada una con una cierta función, las cuales se explican a continuación.

Capa 1:

Cada neurona de esta capa traspasa una determinada variable de entrada hacia la capa 2, de acuerdo con la ecuación (2.12).

$$O_j^{(1)} = x_j, j = 1, 2. \quad (2.12)$$

donde,

$O_j^{(1)}$: Salida de la j-ésima neurona de la capa 1.

x_j : j-ésima entrada del sistema.

Capa 2:

Las neuronas de esta capa llevan a cabo la fusificación de las entradas, por medio de funciones de pertenencia del tipo gaussiana simétrica. La ecuación (2.13) muestra, a modo de ejemplo, la fusificación de la entrada x_1 .

$$\mu_{A_m}(x_1) = e^{-\frac{(x_1 - c_{A_m})^2}{\sigma_{A_m}}} \quad (2.13)$$

donde,

$\mu_{A_m}(x_1)$: Función de pertenencia de A_m .

c_{A_m} : Centro de la función de pertenencia de A_m .

σ_{A_m} : Dispersión de la función de pertenencia de A_m .

Capa 3:

Cada neurona en esta capa calcula la fuerza de disparo de cada una de las reglas difusas, de acuerdo con la ecuación (2.14).

$$w_i = \mu_{A_m}(x_1) \cdot \mu_{B_n}(x_2) \quad (2.14)$$

donde,

w_i : Fuerza de disparo de i-ésima regla.

Capa 4:

Las neuronas de esta capa normalizan cada una de las fuerzas de disparo de las reglas difusas respecto a la suma de todas las fuerzas de disparo, como se muestra en la ecuación (2.15).

$$\bar{w}_i = \frac{w_i}{w_1 + w_2 + w_3 + w_4}, i = 1, 2, 3, 4. \quad (2.15)$$

Capa 5:

Cada neurona en esta capa calcula el producto entre la salida individual de la i -ésima regla por su respectiva fuerza de disparo normalizada, como se indica en la ecuación (2.16).

$$O_i^{(5)} = \bar{w}_i \cdot f_i = \bar{w}_i \cdot (p_i \cdot x_1 + q_i \cdot x_2 + r_i) \quad (2.16)$$

donde,

$O_i^{(5)}$: Salida de la i -ésima neurona de la capa 5.

Capa 6:

La neurona en esta capa suma las salidas de cada neurona de la capa 5, para así obtener la salida del sistema, tal como se muestra en la ecuación (2.17).

$$O_i^{(6)} = \sum_{i=1}^4 O_i^{(5)} = \sum_{i=1}^4 \bar{w}_i \cdot f_i = \frac{\sum_{i=1}^4 (w_i \cdot f_i)}{\sum_{i=1}^4 w_i} \quad (2.17)$$

Por otra parte, un modelo ANFIS usa un algoritmo de aprendizaje híbrido para la identificación de los parámetros. Este algoritmo combina un estimador de mínimos cuadrados y el método de descenso de gradiente [21].

En este proceso de aprendizaje, también conocido como entrenamiento, cada *época* o iteración se compone de un paso hacia adelante y uno hacia atrás. En el paso hacia adelante, un conjunto de datos de entrenamiento es presentado al sistema ANFIS, se calculan las salidas de las neuronas del sistema y los parámetros de los consecuentes de las reglas son identificados por medio de la técnica de mínimos cuadrados. En el paso hacia atrás, los errores de estimación del sistema son propagados hacia las primeras capas y los parámetros de los antecedentes de las reglas son actualizados por el método del descenso del gradiente.

El detalle de los algoritmos de aprendizaje se puede encontrar en [18] y [21].

Por último, la determinación de la estructura de un sistema difuso del tipo Sugeno que con un mínimo de reglas represente el comportamiento entrada-salida de un sistema, se puede lograr por medio de la técnica basada en clustering de datos *subtractive clustering* detallada en [22].

En este trabajo se utiliza este método para la determinación del número de funciones de pertenencia por entrada y número de reglas difusas del sistema a ser entrenado por medio de ANFIS.

2.5. Discusión y conclusiones

Los sistemas difusos han demostrado ser robustos en la modelación de sistemas no lineales, multivariados y que presentan incertidumbre. Estas condiciones son propias del proceso de molienda SAG, dado las perturbaciones no medibles que influyen en las condiciones de operación. Un sistema difuso requiere un set de reglas de un experto, el cual no siempre está disponible.

En este sentido, los sistemas neuro-difusos se valen de la capacidad de aprendizaje de las redes neuronales para definir las reglas de un sistema difuso a partir de datos de entrada-salida del proceso.

Este tipo de modelación se utiliza para generar estimadores del desgaste de alzadores y nivel de llenado, de implementación directa y robustos antes distintas condiciones de operación.



Capítulo 3. Modelo de desgaste de alzadores

3.1. Introducción

Las etapas de desarrollo de los modelos de desgaste de alzadores, de los molinos SAG 1 y SAG 2, se muestran a continuación. Se presentan los registros de terreno y se tabulan los valores de altura de alzadores disponibles. El procedimiento de medición de la altura de alzadores en terreno se presenta en el Anexo A.

Posteriormente, se muestran las reglas resultantes de la etapa de entrenamiento, la estructura del modelo y se analizan las superficies de salida.

Finalmente, se evalúa el desempeño de los modelos haciendo uso de los índices de error RMSE y MAPE.

3.2. Registros de terreno y mediciones del desgaste

Desde la Figura 3.1 a la Figura 3.2 se muestran las señales de proceso correspondientes a la campaña 1A del SAG 1, la cual tuvo una duración aproximada de 5 meses y medio. Los registros presentados en estas figuras poseen un tiempo de muestreo de 10 segundos.

Cabe mencionar que a los registros de terreno de cada campaña se les realiza un preprocesamiento de extracción de los tiempos de detención, de modo que se expresen en función de un tiempo efectivo de campaña.




Figura 3.1 Alimentación de mineral – primera campaña de SAG 1 (Fuente: Elaboración propia).




Figura 3.2 Presión de descanso – primera campaña de SAG 1 (Fuente: Elaboración propia).




Figura 3.3 Potencia – primera campaña de SAG 1 (Fuente: Elaboración propia).

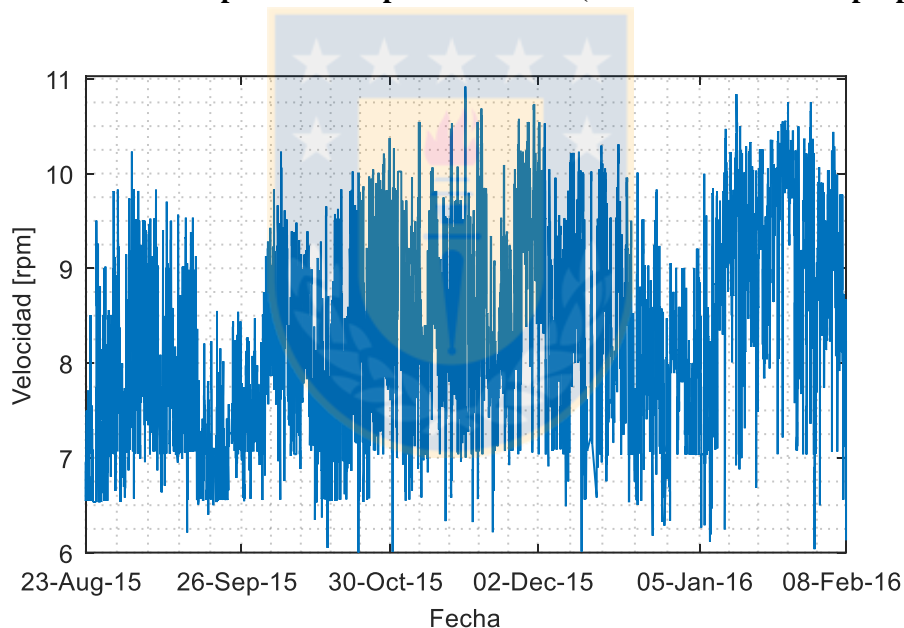


Figura 3.4 Velocidad – primera campaña de SAG 1 (Fuente: Elaboración propia).

El principal interés de los operadores de molinos SAG es procesar una tasa de alimentación de mineral constante a lo largo de las distintas campañas. En la Figura 3.1 se observa que, aunque la tendencia global muestra una tasa de alimentación de mineral relativamente constante, existen importantes variaciones durante la operación diaria.

En la Figura 3.2 se observa que la señal de presión de descanso, relacionada con el nivel de llenado, muestra mayormente un comportamiento constante. Esto se explica en que el nivel de llenado se busca mantener constante en la operación de un molino, y dado que

esta variable no se puede medir directamente, se busca mantener constante la presión del descanso.

Las señales que muestran las mayores variaciones son la potencia y la velocidad de operación (Figura 3.3 y Figura 3.4). Sin embargo, se observa que las señales de potencia y velocidad se encuentran correlacionadas.

En la Tabla 3.1 se presentan los valores promedio de las alturas de alzadores registradas durante las inspecciones correspondientes a las campañas del molino SAG 1. Las distintas alturas son asociadas a un tiempo efectivo de campaña, es decir sin considerar los tiempos de detención.

El procedimiento de medición se detalla en el Anexo A.

Tabla 3.1 Inspecciones de altura de alzadores – SAG 1 (Fuente: Elaboración propia).

Campaña	Tiempo efectivo de campaña [días]	Altura de alzadores [mm]
1A	0	377
	21	337
	36	329
	48	326
	66	314
	80	287
	99	256
	132	197
1B	0	377
	21	330
	59	305
	78	246
	98	214
	120	161

Es importante consignar que al final de cada campaña la altura de los alzadores no es registrada, por lo que los modelos son desarrollados con datos hasta la fecha de la última inspección.

La Figura 3.5 y Figura 3.6 muestran la interpolación de los valores de altura de alzadores correspondientes a las campañas 1A y 1B, respectivamente. Las curvas interpoladas se obtienen por medio de interpolación PCHIP. Este tipo de interpolación preserva la tendencia y monotonidad de los datos.




Figura 3.5 Curva de desgaste de alzadores, campaña 1^a (Fuente: Elaboración propia).

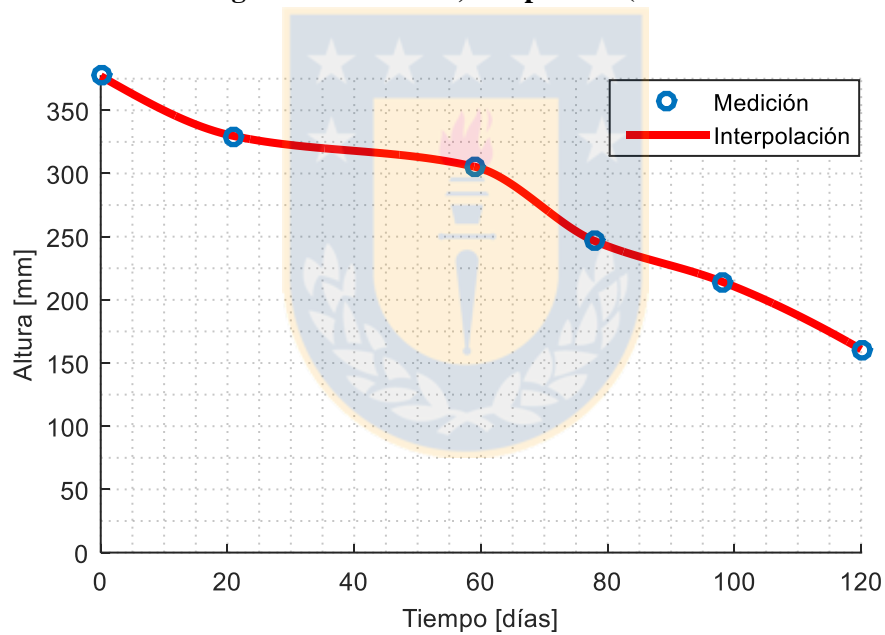


Figura 3.6 Curva de desgaste de alzadores, campaña 1B (Fuente: Elaboración propia).

Las curvas interpoladas de desgaste de la Figura 3.5 y Figura 3.6 junto con los registros de las variables de proceso, son utilizados para el desarrollo del modelo de desgaste de alzadores del molino SAG 1. Para el caso del molino SAG 2, el procedimiento es el mismo.

3.3. Desarrollo del modelo de desgaste

Para la construcción de cada modelo de desgaste se dispone de los registros de dos campañas de alzadores. El total de datos disponible para cada modelo se divide en tres conjuntos de datos que son usados para entrenamiento, validación y testeo.

La identificación de los parámetros de cada estimador es llevada a cabo durante la etapa de entrenamiento. El conjunto de validación es usado para mejorar la capacidad de generalización del modelo y evitar el sobreajuste de los datos cuando el entrenamiento se lleva a cabo. Finalmente, el conjunto de testeo es usado para evaluar el error en las estimaciones del modelo.

La división de los datos en los conjuntos de entrenamiento, validación y testeo se realiza de forma aleatoria en la proporción 0.7, 0.15 y 0.15, respectivamente. La cantidad de datos de cada conjunto, para ambos modelos, se presenta en la Tabla 3.2.

Tabla 3.2 Número de datos de entrenamiento, validación y testeo (Fuente: Elaboración propia).

Modelo de desgaste	Total	Entrenamiento	Validación	Testeo
SAG 1	36277	25395	5441	5441
SAG 2	38833	27183	5825	5825

3.3.1 Etapa de entrenamiento

En la etapa de entrenamiento, llevada a cabo por medio de la herramienta Fuzzy Logic Toolbox™ [35], se minimiza el índice RMSE™ en cada una de las épocas o iteraciones. La formulación del RMSE se presenta en la ecuación (3.1), donde y_i representa el valor medido, \hat{y}_i el valor estimado y N el total de datos.

$$RMSE = \sqrt{\frac{1}{N} \cdot \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (3.1)$$

En la Figura 3.7 se muestra la evolución de los índices RMSE durante la etapa de entrenamiento del modelo de desgaste del molino SAG 1, en color azul utilizando el conjunto de datos de entrenamiento y en color rojo usando el conjunto de datos de validación.

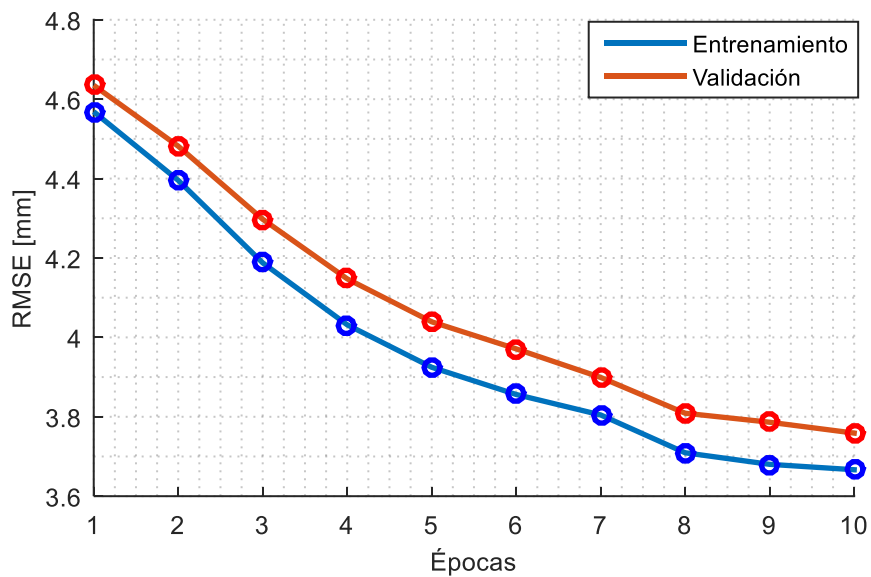


Figura 3.7 Evolución del RMSE con datos de entrenamiento y validación – SAG 1 (Fuente: Elaboración propia).

Se observa que el índice RMSE asociado al conjunto de validación es estrictamente decreciente, por lo que no se produce sobreajuste del modelo respecto a los datos del conjunto de entrenamiento.

El valor RMSE final obtenido con cada conjunto de datos se muestra en la Tabla 3.3, para los modelos de desgaste de alzadores los molinos SAG 1 y SAG 2.

Tabla 3.3 RMSE finalizada la etapa de entrenamiento de modelos de desgaste (Fuente: Elaboración propia).

Modelo de desgaste	Error con datos de entrenamiento [mm]	Error con datos de validación [mm]
SAG 1	3.67	3.76
SAG 2	4.03	4.09

3.3.2 Reglas resultantes y funciones de pertenencia

Por medio de la ejecución de los algoritmos subtractive clusterig y ANFIS por medio de la herramienta Fuzzy Logic ToolboxTM, se determinan dos modelos de desgaste, de 15 reglas difusas cada uno, para los molinos SAG 1 y SAG 2.

El número de reglas difusas determina la cantidad de funciones de pertenencia por variable de entrada del modelo. La Figura 3.8 muestra el sistema de inferencia difuso del modelo de desgaste de alzadores del molino SAG 1, considerando solo las primeras cinco reglas.




Figura 3.8 Funciones de pertenencia de cinco primeras reglas de modelo de desgaste – SAG 1 (Fuente: Elaboración propia).

Las primeras cuatro columnas muestran las funciones de pertenencia correspondientes a las partes if-then de cada regla, mientras que la quinta columna muestra las funciones de pertenencia de tipo singleton de cada regla, las cuales poseen un valor unitario en sólo un punto del universo de discurso. La posición de cada singleton varía según el valor que asuman las variables de entrada, y sus valores son ponderados por el grado de cumplimiento de cada regla normalizado.

3.3.3 Estructura y parámetros

La estructura parcial del modelo neuro-difuso de desgaste de alzadores se muestra en la Figura 3.9. Además, la Tabla 3.4 muestra los parámetros de las funciones de pertenencia de las dos primeras reglas del modelo correspondiente al SAG 1. Del mismo modo, la Tabla 3.5 presenta los parámetros de los consecuentes de las reglas del mismo modelo.

Tabla 3.4 Parámetros parciales de funciones de pertenencia modelo de desgaste – SAG 1 (Fuente: Elaboración propia).

Variable	Función de pertenencia	σ (desviación)	c (centro)
Mineral procesado	A ₁	0.0698	0.2316
	A ₂	0.0603	0.1170
Velocidad	B ₁	0.0443	0.6425
	B ₂	0.0473	0.5394
Potencia	C ₁	0.0756	0.7052
	C ₂	0.0746	0.5343
Presión de descanso	D ₁	0.0214	0.8264
	D ₂	0.0270	0.8048

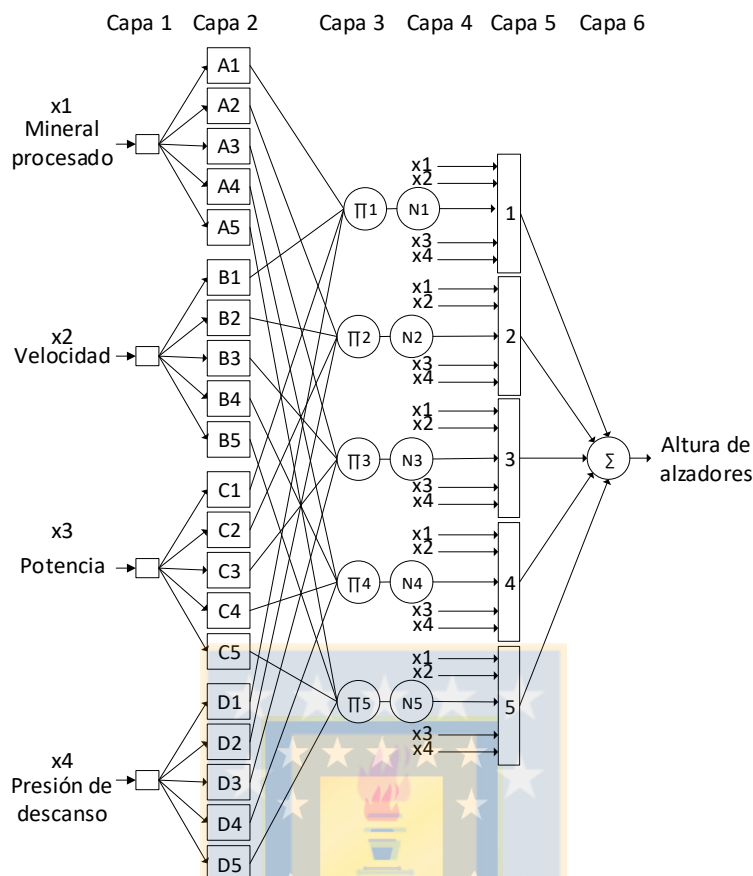


Figura 3.9 Estructura parcial de modelo de desgaste – SAG 1, 2 (Fuente: Elaboración propia).

Tabla 3.5 Parámetros parciales de consecuentes de reglas difusas de modelo de desgaste – SAG 1 (Fuente: Elaboración propia).

Regla	Parámetros	Valor
Regla 1	p_1	-0.7831
	q_1	0.1641
	r_1	-0.6119
	s_1	0.7078
	k_1	0.7822
Regla 2	p_2	-0.4695
	q_2	-0.0110
	r_2	-0.2061
	s_2	0.0669
	k_2	0.9978

3.3.4 Superficies de salida

La salida final del modelo de desgaste de alzadores corresponde a la ponderación de las salidas de cada regla y puede ser analizada en un espacio tridimensional conocido como superficie de salida. Las superficies de salida permiten analizar la sensibilidad del desgaste de los alzadores respecto a las variables de entrada.

En la Figura 3.10 y Figura 3.11 se muestran las superficies de salida mineral procesado-potencia y mineral procesado-presión de descanso, respectivamente.




Figura 3.10 Altura de alzadores en función de mineral procesado y potencia – SAG 1 (Fuente: Elaboración propia).




Figura 3.11 Altura de alzadores en función de mineral procesado y presión de descanso – SAG 1 (Fuente: Elaboración propia).

La Figura 3.10 muestra que el mayor desgaste de los alzadores, con altos valores de mineral procesado, se encuentra asociado a los mayores valores de potencia. La superficie de esta figura considera una velocidad de 10 rpm y una presión de descanso de 55 kg/cm².

Similarmente, si se considera una velocidad de 10 rpm y potencia de 8.21 MW, la Figura 3.11 muestra que, con altos valores de mineral procesado, el mayor desgaste de los alzadores se encuentra asociado a los menores valores de presión de descanso.

La tendencia anterior tiene su explicación en la pérdida de masa de los alzadores a medida que éstos se desgastan, la cual no es compensada por una mayor carga de mineral porque el nivel de llenado se mantiene relativamente constante a lo largo de una campaña.

3.4. Evaluación del modelo

La evaluación de los modelos neuro-difusos desarrollados se lleva a cabo utilizando los respectivos conjuntos de datos de testeo filtrados, de manera de equilibrar las dinámicas de la velocidad, potencia y presión con la del desgaste de alzadores. La Figura 3.12 muestra la comparación entre la curva de desgaste obtenida por medio de la interpolación de los valores registrados en terreno y los resultados de la estimación por medio del modelo neuro-difuso de desgaste, para el caso de los datos de testeo de la campaña 1A. En la Figura 3.13 se muestra el correspondiente error de estimación.

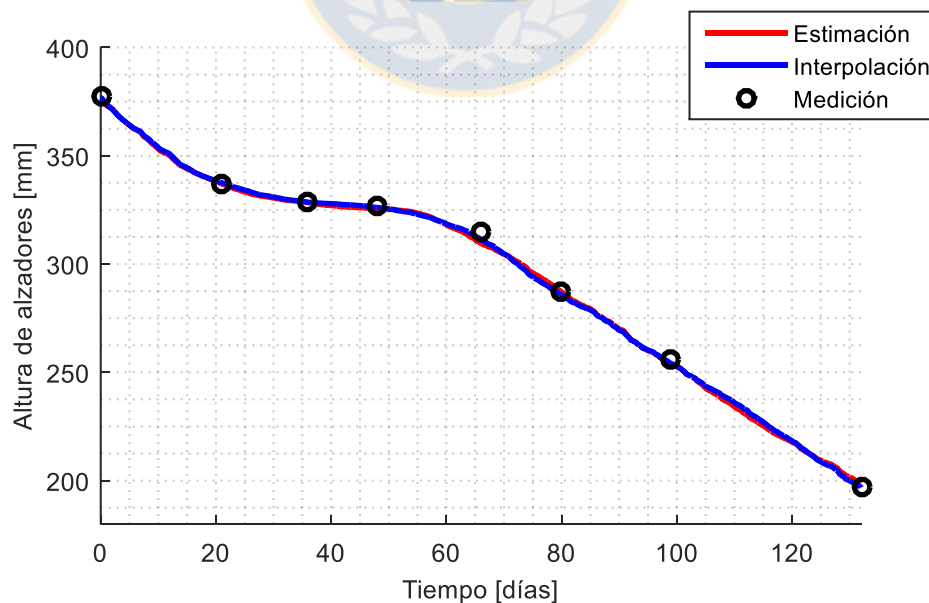


Figura 3.12 Evaluación de modelo de desgaste SAG 1 – datos de campaña 1^a (Fuente: Elaboración propia).




Figura 3.13 Curva de error al evaluar modelo de desgaste SAG 1 – datos de campaña 1ª (Fuente: Elaboración propia).

De manera similar, en la Figura 3.14 y Figura 3.15, se muestran los resultados de estimación con los datos de testeo de la campaña 1B y el correspondiente error de estimación, respectivamente.

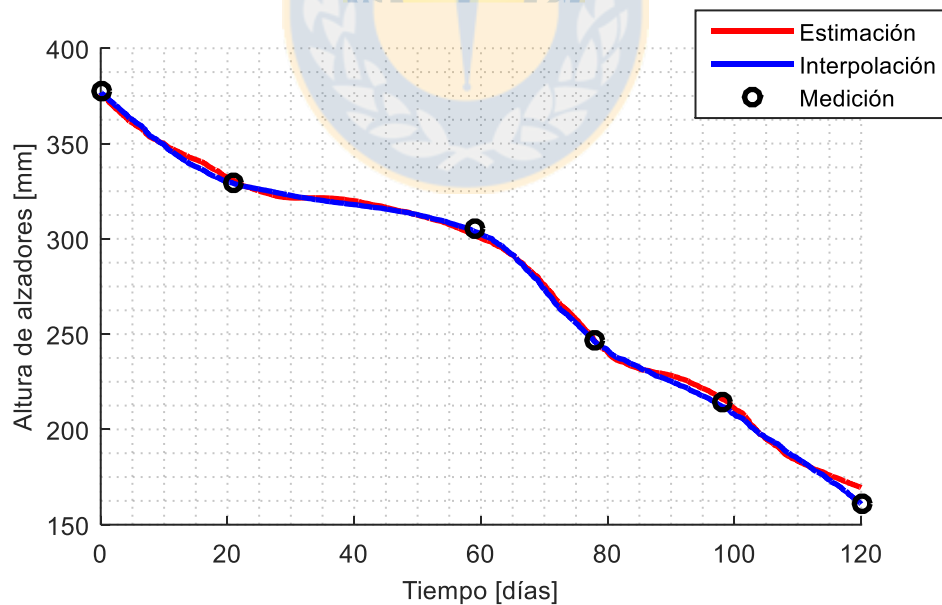


Figura 3.14 Evaluación de modelo de desgaste SAG 1 – datos de campaña 1B (Fuente: Elaboración propia).




Figura 3.15 Curva de error al evaluar modelo de desgaste SAG 1 – datos de campaña 1B (Fuente: Elaboración propia).

El error de estimación es cuantificado mediante los índices RMSE y MAPE. La formulación del índice MAPE se presenta en la ecuación (3.2), donde y_i representa el valor medido, \hat{y}_i el valor estimado y N el total de datos.

$$MAPE = \frac{\sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right|}{N} \cdot 100 \quad (3.2)$$

El índice de error MAPE, a diferencia del RMSE, se expresa en porcentaje. Un MAPE cercano a cero significa una buena estimación mientras que un valor cercano a 100 significa una estimación deficiente.

En la Tabla 3.6 se presentan los índices RMSE y MAPE obtenidos al evaluar los modelos de desgaste de ambos molinos con los datos de testeo de cada campaña.

Tabla 3.6 Valores RMSE y MAPE obtenidos en la etapa de testeo (Fuente: Elaboración propia).

Modelo de desgaste	Campaña	RMSE [mm]	MAPE [%]
SAG 1	1A	0.96	0.28
SAG 1	1B	2.21	0.71
SAG 2	2A	2.76	0.73
SAG 2	2B	2.15	0.68

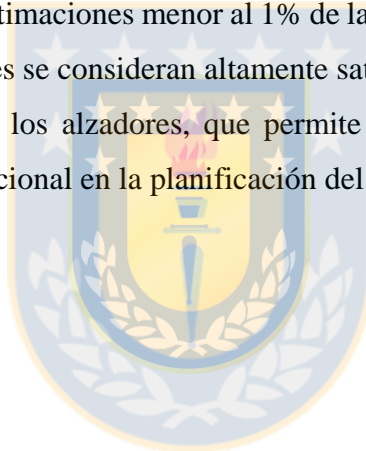
3.5. Discusión y conclusiones

Las curvas de desgaste obtenidas por medio del modelo neuro-difuso presentan características decrecientes que se ajustan a las mediciones de terreno de la misma forma que lo hacen las curvas obtenidas por la interpolación de los puntos experimentales, como puede observarse en la Figura 3.12 y Figura 3.14.

La exactitud de las estimaciones se confirma observando los respectivos errores de las campañas 1A y 1B (Figura 3.13 y Figura 3.15), donde las máximas desviaciones son de -2.1 mm y -8.6 mm, correspondientes al 0.56% y 2.28% de la altura nominal de los alzadores (377 mm).

Finalmente, de acuerdo con los valores presentados en la Tabla 3.6, ningún índice MAPE excede el 1%. Además, los índices RMSE son menores a 3 mm, lo cual indica un intervalo de confianza en las estimaciones menor al 1% de la altura nominal de los alzadores.

Los resultados anteriores se consideran altamente satisfactorios, dado el beneficio de conocer en línea el estado de los alzadores, que permite evitar detener la producción y constituye una herramienta adicional en la planificación del mantenimiento.



Capítulo 4. Análisis de simulaciones DEM

4.1. Introducción

En este capítulo se analizan los resultados del conjunto de 100 simulaciones DEM necesarias para desarrollar el modelo del nivel de llenado. Estas simulaciones son caracterizadas con parámetros de molienda seca.

En primera instancia, se desarrolla una breve descripción del método de elementos discretos y luego se desarrolla un análisis de las simulaciones desde la perspectiva de la posición de la carga al variar las condiciones de operación. Posteriormente se analizan las curvas estáticas potencia-velocidad y potencia-nivel de llenado.

También se presenta un desarrollo para obtener las reacciones de los descansos a partir del análisis de las fuerzas que son ejercidas por las partículas sobre la estructura del molino.

Una vez definida la metodología de obtención de las reacciones, se analizan distintas curvas de reacción-nivel de llenado.

4.2. Descripción del Método de Elementos Discretos

El Método de Elementos Discretos es una técnica numérica para predecir el comportamiento de sólidos granulados, los cuales se componen de una gran cantidad de partículas sólidas. Dado lo anterior, la técnica DEM ha sido utilizada para abordar la modelación de molinos rotatorios, tal como se muestra en [28], [39], [30], [31] y [32].

Las ecuaciones de movimiento, para cada una de las partículas, son integradas numéricamente en el tiempo. Para esto, se debe conocer la fuerza neta ejercida sobre cada partícula. La fuerza neta es la resultante entre las fuerzas de contacto (generadas por la interacción entre partículas y bordes) y fuerzas de tipo externa (fuerzas gravitacionales, electrostáticas o electromagnéticas).

Previo a la ejecución de un código DEM mediante software especializado, el usuario debe importar geometrías CAD que definen los bordes dentro de los cuales se mueven las partículas, luego se deben definir los distintos grupos de partículas y finalmente configurar los parámetros de contacto entre las distintas partículas y los bordes.

Luego, una vez iniciada una simulación, el programa DEM realiza un proceso

iterativo para cada una de las partículas, en el cual primero localiza las partículas y bordes en contacto.

Posteriormente, se calcula la suma de todas las fuerzas y momentos que actúan sobre cada partícula. Cabe mencionar que en la sumatoria de momentos se utilizan las ecuaciones rotacionales de Euler y en la sumatoria de fuerzas se utiliza la segunda ley de Newton. En la ecuación (4.1) se muestra la sumatoria de fuerzas sobre una determinada partícula.

$$\sum \vec{F}_{neta} = \sum (\vec{F}_c + \vec{F}_{ext}) = m \cdot \vec{a} \quad (4.1)$$

donde,

\vec{F}_{neta} : Fuerza neta.

\vec{F}_c : Fuerza de contacto con partículas y bordes.

\vec{F}_{ext} : Fuerza de carácter externo.

m : Masa de partícula.

\vec{a} : Aceleración de partícula.

Finalmente, se usa la posición actual de la partícula, velocidad y paso de tiempo para mover la partícula hacia una nueva posición en la simulación, de acuerdo con la ecuación (4.2) y ecuación (4.3).

$$\vec{V}_{k+1} = \vec{V}_k + \Delta \vec{V} = \vec{V}_k + \int \left(\frac{\sum \vec{F}_{neta}}{m} dt \right) \quad (4.2)$$

$$\vec{X}_{k+1} = \vec{X}_k + \Delta \vec{X} = \vec{X}_k + \int (\vec{V}_k dt) \quad (4.3)$$

donde,

\vec{V} : Velocidad.

\vec{X} : Posición.

dt : Paso de tiempo.

4.3. Posición de la carga del molino.

La forma de la carga con el molino en operación es similar a la de un riñón, en cuyo extremo inferior izquierdo puede reconocerse una zona conocida como pie de la carga y en el extremo superior derecho una zona llamada hombro de la carga. En la Figura 4.1 se indican estas zonas para un sentido de giro antihorario del molino. Las partículas de color azul corresponden a rocas mientras que las de color rojo corresponden a bolas de acero.

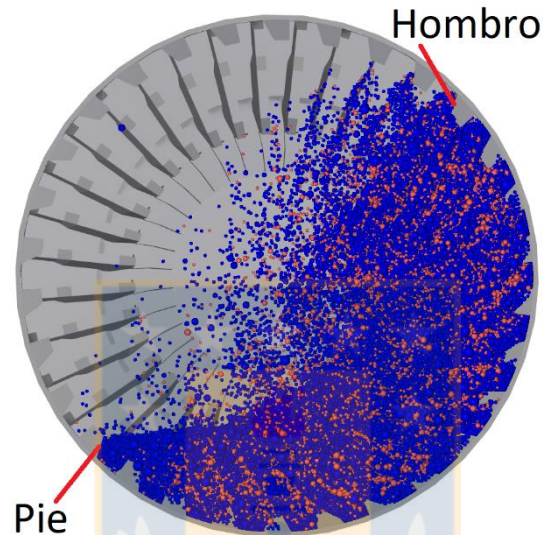


Figura 4.1 Forma de la carga del molino – sentido de giro antihorario (Fuente: Elaboración propia).

El efecto de distintas condiciones operacionales como el nivel de llenado, velocidad y altura de alzadores sobre la dinámica interna del molino se estudia por medio de arreglos matriciales de imágenes extraídas de simulaciones DEM.

Cada fila o columna de una matriz posee dos condiciones de operación fijas y una que cambia, lo que permite visualizar el efecto sobre la forma de la carga que tiene la condición operacional que varía.

En la Figura 4.2 se presenta una matriz de nivel de llenado-velocidad para una condición de alzadores de 377 mm, mientras que en la Figura 4.3 se presenta para alzadores de altura 140 mm.




Figura 4.2 Matriz nivel de llenado–velocidad con altura de alzadores de 377 mm (Fuente: Elaboración propia).

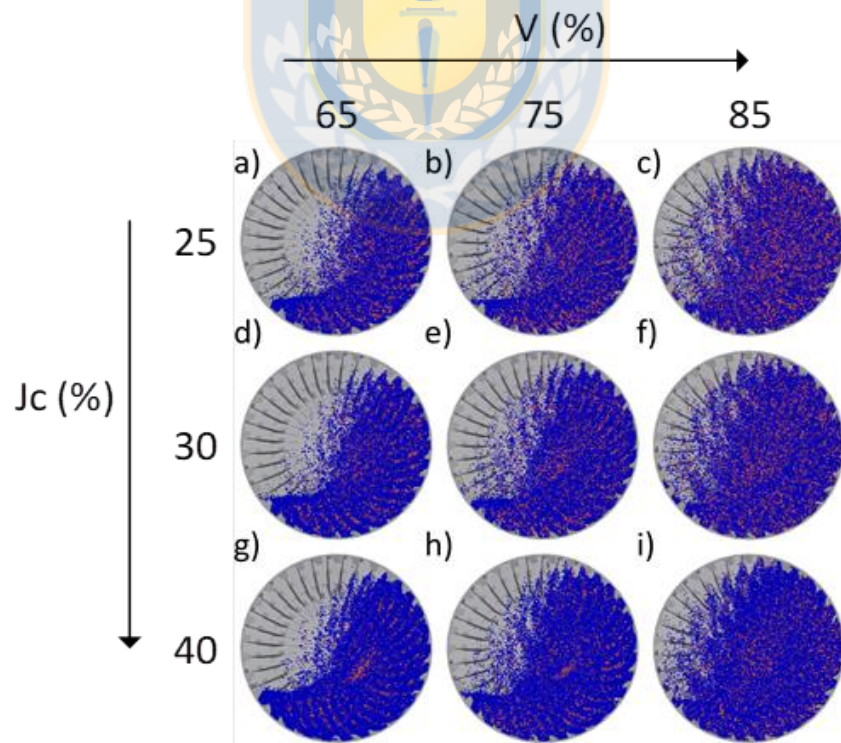


Figura 4.3 Matriz nivel de llenado – velocidad con altura de alzadores de 140 mm (Fuente: Elaboración propia).

En la Figura 4.2 se observa que, al aumentar la velocidad de operación, cualquiera sea el nivel de llenado, la acción de levante de la carga por parte de los alzadores se ve favorecida. Esto se traduce principalmente en que se amplía la zona donde impactan las partículas que son lanzadas por los alzadores, por sobre la posición del pie de la carga. También se observa que la posición del hombro de la carga se eleva al incrementarse la velocidad de operación.

Por otro lado, al aumentar el nivel de llenado se observa una elevación de la posición del pie de la carga. Si bien este comportamiento es válido para las 3 velocidades evaluadas, es más perceptible al 65 % de la velocidad crítica.

Finalmente, al comparar las columnas correspondientes al 65 % y 85% de la velocidad crítica de la Figura 4.2 con las respectivas columnas de la Figura 4.3, se observa que una mayor altura de alizador propicia una extensión de la zona de impacto de partículas por sobre del pie de la carga. Además, se logra identificar que este efecto es más significativo cuando la velocidad de operación es mayor.

4.4. Curvas de potencia vs velocidad.

En la Figura 4.4 se muestran las curvas de potencia vs velocidad para distintos niveles de llenado y una altura de alizador de 377 mm

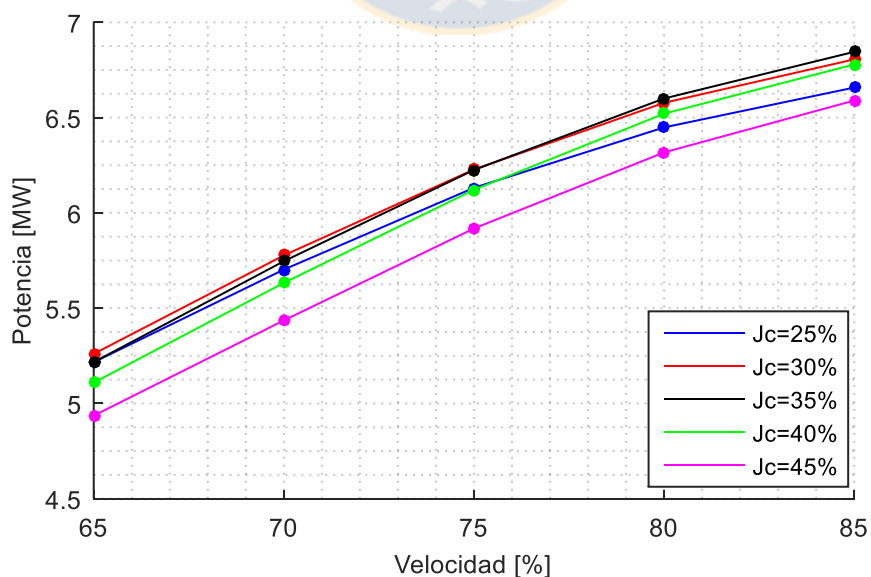


Figura 4.4 Curvas de potencia vs velocidad – altura 377 mm (Fuente: Elaboración propia).

Las curvas de potencia de la Figura 4.4 se incrementan a medida que la velocidad de operación aumenta desde el 65 al 85% de la velocidad crítica. Esto se debe a que la velocidad de rotación afecta a la potencia a través de la relación lineal de la ecuación (4.4).

$$P = \omega \cdot T \quad (4.4)$$

Donde,

ω : Velocidad de operación, en rad/s.

T : Torque requerido para el giro del molino.

A medida que la velocidad de operación se acerca a la velocidad crítica, la tasa de crecimiento de la potencia es menor debido a que el centro de gravedad de la carga comienza a desplazarse hacia el centro del molino, lo cual reduce el requerimiento de torque.

Además, se observa que la curva asociada al 45% del nivel de llenado es la que posee los menores valores de potencia, mientras que las curvas correspondientes al 30 y 35% son las que alcanzan los mayores valores. Los valores bajos de potencia de la curva asociada al 45% del nivel de llenado se debe a que el centro de masa de la carga se encuentra desplazado hacia el centro del molino, lo cual reduce la potencia requerida.

Por otro lado, en la Figura 4.5 se muestran las curvas de potencia vs velocidad para distintas alturas de alzadores y un nivel de llenado de 25 %.

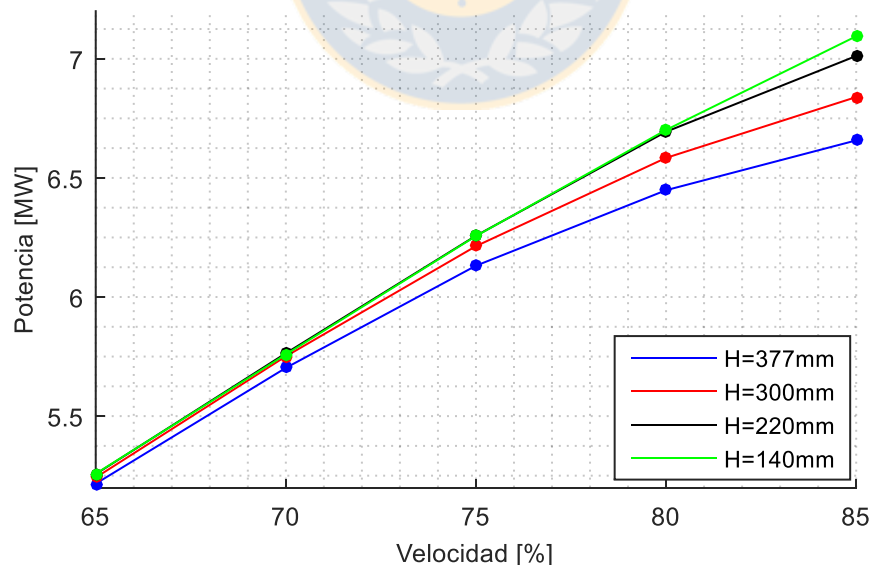


Figura 4.5 Curvas de potencia vs velocidad – nivel de llenado de 25 % (Fuente: Elaboración propia).

Las curvas de potencia de la Figura 4.5 muestran un comportamiento creciente en

función de la velocidad en el rango del 65 al 85% de la velocidad crítica. Se observa que a mayor altura de los alzadores menor es la potencia requerida. Esto tiene su explicación en que el flujo de partículas en catarata es superior a mayor altura de alzador. Luego, al elevarse la posición de las partículas el centro de masa de la carga se acerca al centro geométrico del molino, lo que finalmente reduce el requerimiento de potencia [30], [32].

4.5. Curvas de potencia vs nivel de llenado.

En la Figura 4.6 se muestran las curvas de potencia vs nivel de llenado para distintas velocidades de operación y una altura de alzador de 377 mm.

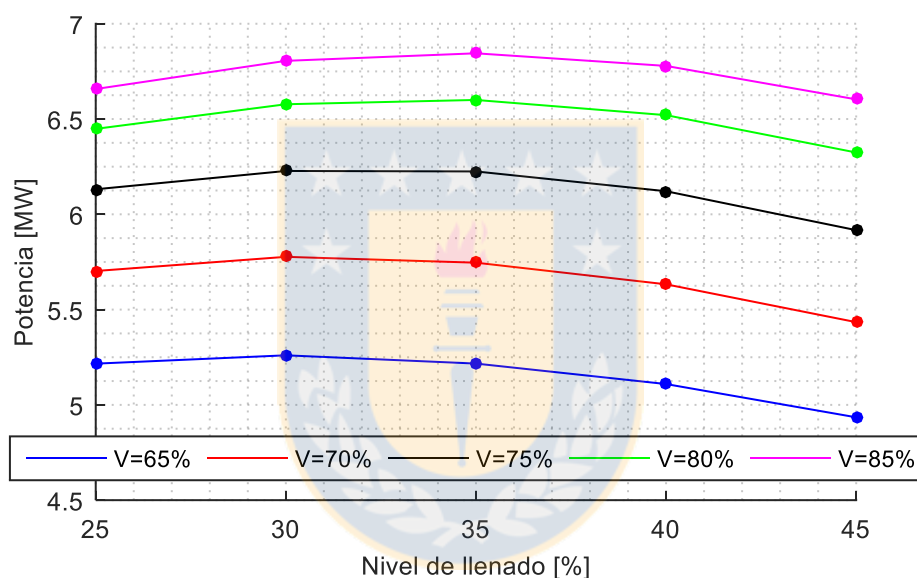


Figura 4.6 Curvas de potencia vs nivel de llenado – altura de alzadores de 377 mm (Fuente: Elaboración propia).

Las curvas de la Figura 4.6 muestran un comportamiento parabólico de la potencia respecto al nivel de llenado, alcanzando sus máximos, para niveles de llenado cercanos al 35%.

El comportamiento creciente de las curvas de potencia respecto al aumento del nivel de llenado se sustenta en que el torque requerido para girar un molino depende linealmente de la masa de la carga. Dado que la potencia se obtiene como el producto entre el torque y la velocidad, al aumentar linealmente el torque también lo hace la potencia.

En la figura 4.1 se muestra una simplificación de la forma de la carga de un molino en operación y en la ecuación (4.5) se describe el requerimiento de torque para producir el giro del molino.

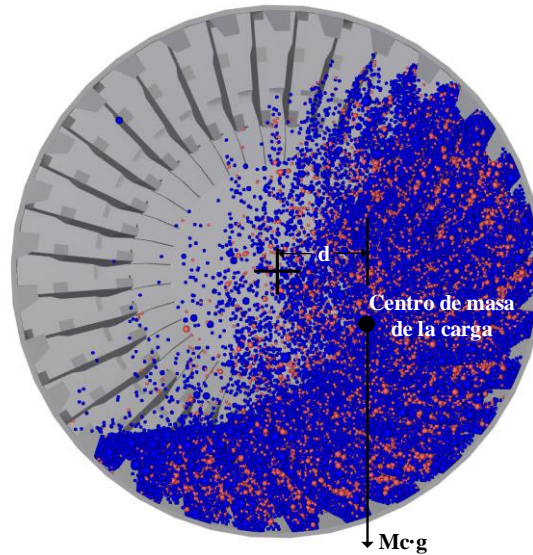


Figura 4.1 Simplificación del requerimiento de torque para el giro de un molino (Fuente: Elaboración propia).

$$T = M_c \cdot g \cdot d \quad (4.5)$$

Donde,

M_c : Masa total de la carga al interior del molino.

g : Aceleración de gravedad.

d : Brazo de la fuerza peso de la carga del molino.

Un segundo efecto del aumento de la carga, y que explica la parte decreciente de las curvas de potencia, es el desplazamiento del centro de masa de la carga hacia el centro del molino. Lo anterior genera una disminución en el requerimiento de torque, debido a que el aumento de la masa de la carga no logra compensar la disminución del brazo de la fuerza peso.

Por otra parte, en la Figura 4.7 se muestran las curvas de potencia vs nivel de llenado para distintas alturas de alzadores y una velocidad de 85 % de la velocidad crítica.

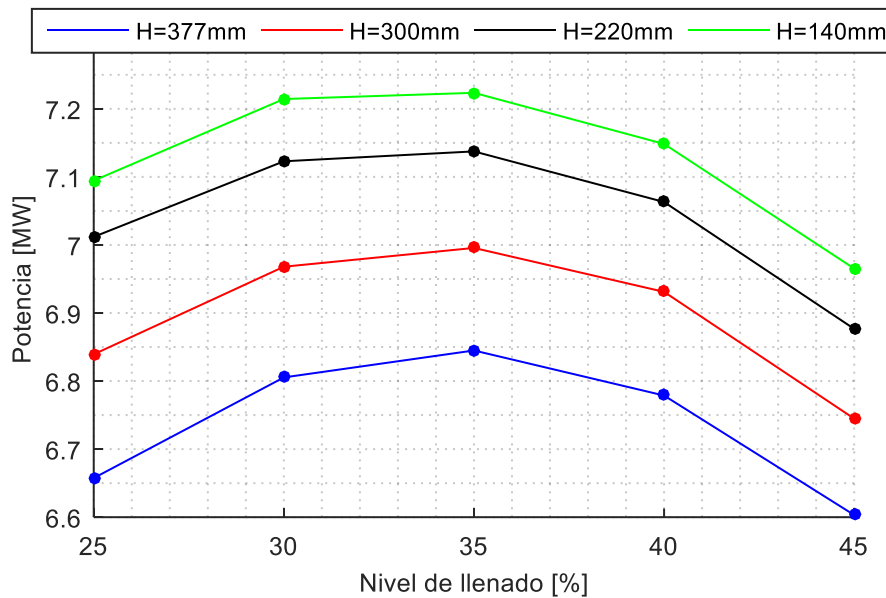


Figura 4.7 Curvas de potencia vs nivel de llenado – velocidad de 85% (Fuente: Elaboración propia).

Cada curva de la Figura 4.7 muestra un aumento de la potencia al incrementarse el nivel de llenado desde un 25 a un 35%, y una disminución desde el 35% en adelante. Se observa además que mientras menor es la altura de los alzadores mayor es la potencia requerida para girar el molino.

4.6. Obtención de la reacción en los descansos.

La reacción en los descansos depende de la masa de la carga y del estado de los revestimientos.

El cálculo de las componentes de las reacciones originadas por la carga de mineral y bolas se basa en el análisis de las fuerzas obtenidas por simulación DEM.

En primer lugar, se realiza un procesamiento para obtener las fuerzas promedio que ejercen las partículas sobre la estructura del molino en las direcciones de los 3 ejes coordenados.

La estructura simulada del molino se muestra en la Figura 4.8. Es importante consignar que el sentido del eje Z es hacia la descarga del molino y el sentido de rotación de éste es antihorario mirado desde el lado de descarga.




Figura 4.8 Estructura de molino SAG simulado en Rocky DEM (Fuente: Elaboración propia).

Por otra parte, en la Figura 4.9 se muestra la superposición del valor promedio (línea naranja), valor promedio más desviación estándar (línea morada) y valor promedio menos desviación estándar (línea amarilla) de las fuerzas.

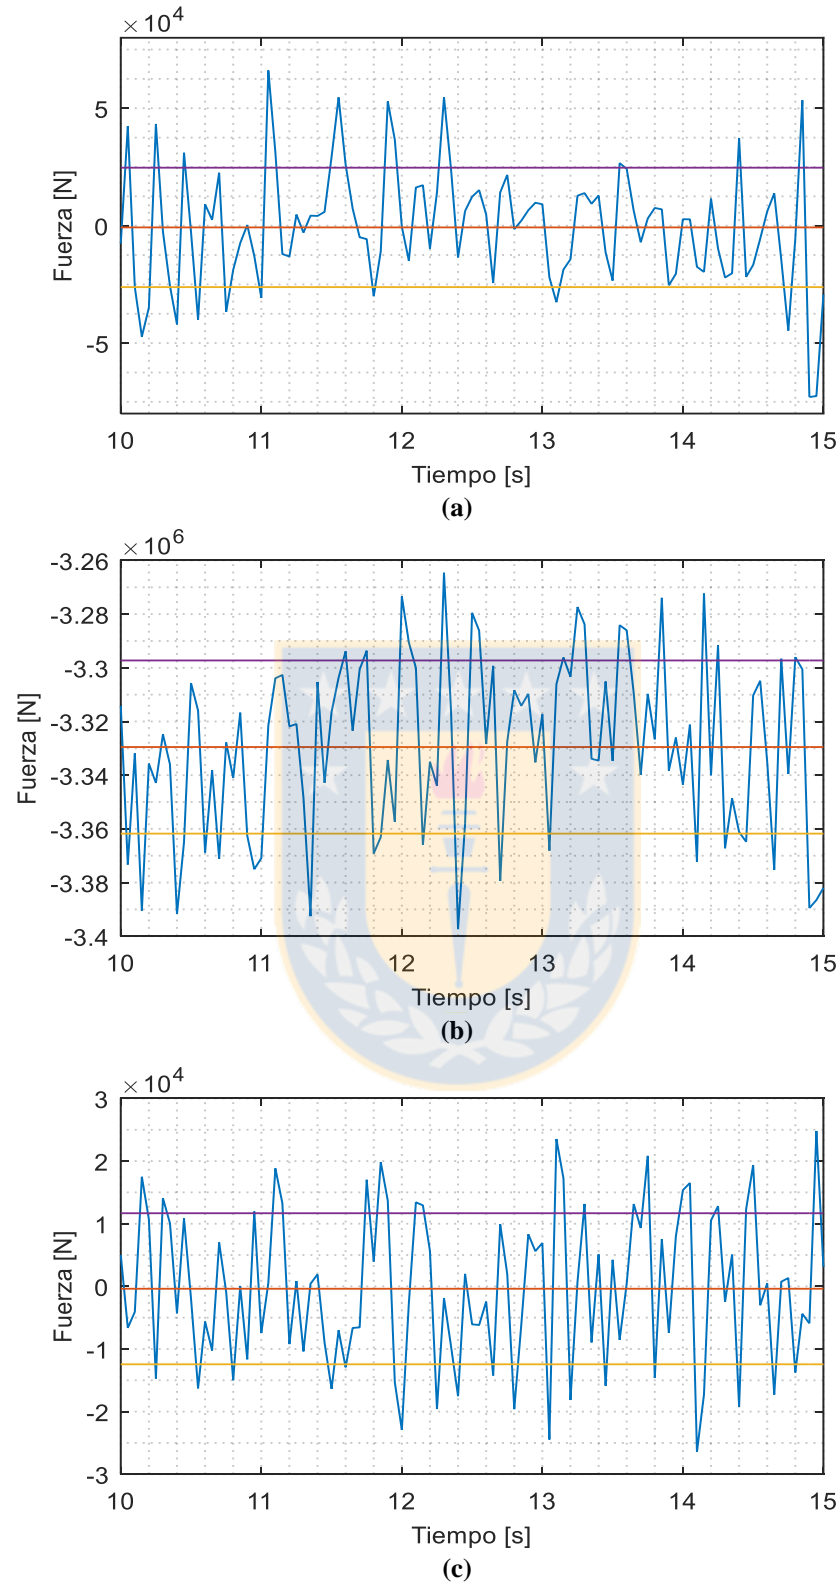


Figura 4.9 Fuerza ejercida por las partículas sobre el molino (Fuente: Elaboración propia).

(a) Fuerza en la dirección del eje X; (b) Fuerza en la dirección del eje Y; (c) Fuerza en la dirección del eje Z.

En la Figura 4.9 se observa que solo la fuerza en la dirección del eje Y presenta un promedio significativo respecto a la desviación estándar. Debido a lo anterior, en el análisis estático usado para determinar las reacciones de los descansos, solo se consideran las fuerzas promedio en la dirección del eje Y.

La estructura del molino se encuentra dividida en 13 secciones transversales. Específicamente, se tiene un extremo de alimentación (E.A), costado izquierdo (C.I), 9 anillos centrales, costado derecho (C.D) y finalmente extremo de descarga (E.D). Los largos de cada sección se detallan en la Tabla 4.1.

Tabla 4.1 Largo de secciones del molino (Fuente: Elaboración propia).

Segmento	Largo [mm]
E.A	1212
C.I	434
Anillo central	400
C.D	427
E.D	940

En la Figura 4.10 se muestra un ejemplo de distribución de fuerzas sobre las distintas secciones de la estructura del molino, para una condición de altura de alzadores de 377 mm, nivel de llenado de 30% y velocidad de operación de 70% de la velocidad crítica. Los resultados se presentan en unidades de fuerza por unidad de largo [N/mm].

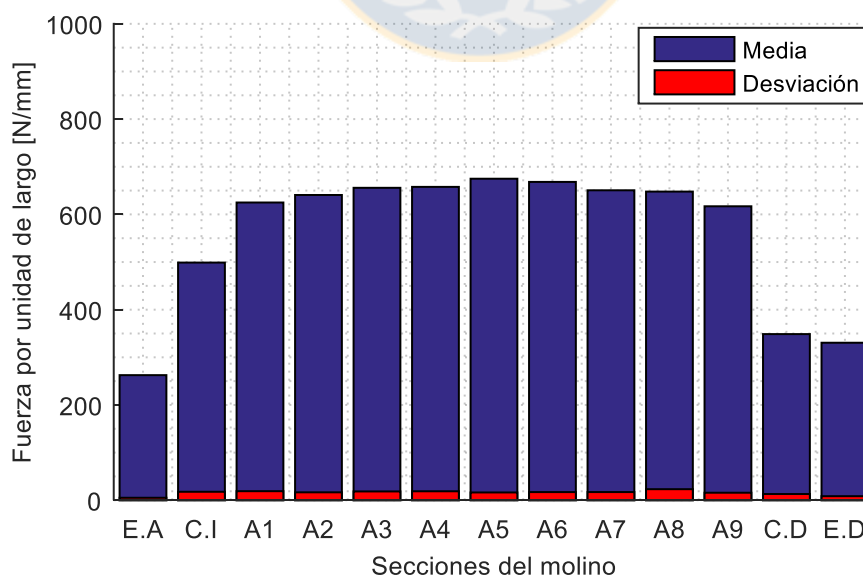


Figura 4.10 Distribución de fuerzas sobre secciones del molino (Fuente: Elaboración propia).

Al dividir la sumatoria de fuerzas promedio de las secciones del molino por la

aceleración de gravedad, se obtienen en todas las condiciones simuladas valores muy cercanos a la masa de bolas de acero y rocas al interior del molino, como queda de manifiesto en la Figura 4.11.




Figura 4.11 Correspondencia de masa nominal y fuerzas promedio – Altura de alzadores de 377 mm (Fuente: Elaboración propia).

El esquema de las fuerzas ejercidas por las partículas e involucradas en el equilibrio estático del molino se muestra en la Figura 4.12. Cabe destacar que las distancias son expresadas en milímetros.

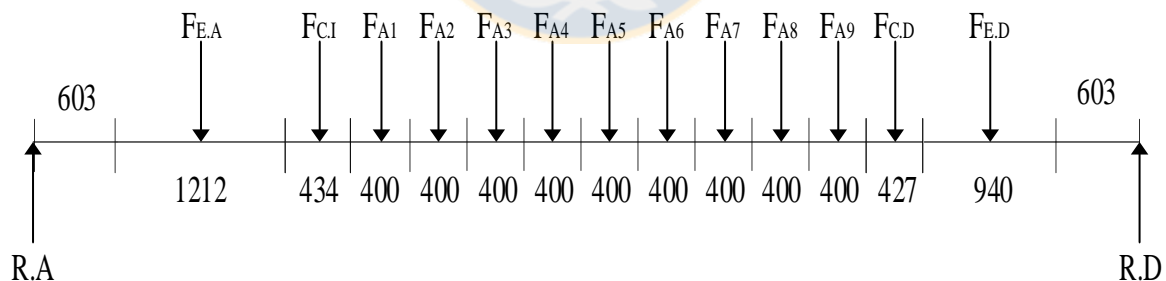


Figura 4.12 Esquema de fuerzas involucradas en el equilibrio del molino (Fuente: Elaboración propia).

Los centros geométricos de cada descanso se ubican a 603 mm de la estructura del molino, por lo que es posible obtener las distancias desde éstos a los puntos medios de cada sección, los cuales corresponden a los puntos de aplicación de las fuerzas. Dado lo anterior, se plantea una sumatoria de momentos en el centro geométrico del descanso de alimentación, según la ecuación (4.6).

$$\sum M_A = F_{EA} \cdot d_{EA} + F_{CI} \cdot d_{CI} + \sum_{K=1}^9 F_{A_K} \cdot d_{A_K} + F_{CD} \cdot d_{CD} + F_{ED} \cdot d_{ED} - R.D \cdot d_{RD} \quad (4.6)$$

donde,

- F_{EA} : Fuerza ejercida por las partículas en contacto con sección E.A.
 F_{CI} : Fuerza ejercida por las partículas en contacto con sección C.I.
 F_{A_K} : Fuerza ejercida por las partículas en contacto con sección A_K.
 F_{CD} : Fuerza ejercida por las partículas en contacto con sección C.D.
 F_{ED} : Fuerza ejercida por las partículas en contacto con sección E.D.
 $R.D$: Reacción en el descanso de descarga.
 d_{EA} : Distancia desde sección EA hasta descanso de alimentación.
 d_{CI} : Distancia desde sección CI hasta descanso de alimentación.
 d_{A_K} : Distancia desde sección A_K hasta descanso de alimentación.
 d_{CD} : Distancia desde sección CD hasta descanso de alimentación.
 d_{ED} : Distancia desde sección ED hasta descanso de alimentación.
 d_{RD} : Distancia desde descanso de descarga hasta descanso de alimentación.

Debido a que el descanso de alimentación se encuentra estático, la sumatoria de momentos en su centro geométrico es igual a cero. Lo anterior permite despejar el valor de R.D. desde la ecuación (4.6), resultando la expresión de la ecuación (4.7).

$$R.D = \frac{F_{EA} \cdot d_{EA} + F_{CI} \cdot d_{CI} + \sum_{K=1}^9 F_{A_K} \cdot d_{A_K} + F_{CD} \cdot d_{CD} + F_{ED} \cdot d_{ED}}{d_{RD}} \quad (4.7)$$

Por su parte, el valor de la reacción en el descanso de alimentación (R.A) puede ser obtenido mediante la ecuación (4.8).

$$R.A = \sum F_Y - R.D \quad (4.8)$$

donde,

- $R.A$: Reacción en el descanso de alimentación.
 $\sum F_Y$: Fuerza neta ejercida por las partículas en la dirección del eje Y.
 $R.D$: Reacción en el descanso de descarga.

Por otro lado, la expresión que relaciona el desgaste de los alzadores con la masa de los revestimientos se muestra en la ecuación (4.9).

$$m_R = 207.6666 - 0.1694 \cdot D - 1.26 \cdot 10^{-4} \cdot D^2 - 4.3 \cdot 10^{-7} \cdot D^3 \quad (4.9)$$

donde,

D : Desgaste de alzadores, expresado en mm.

La relación anterior se obtiene modificando la altura de los alzadores y calculando el volumen de las piezas, por medio del uso de software de dibujo asistido por computador. Dado que las piezas son de acero, la masa se puede calcular directamente a través de la densidad.

Al multiplicar la masa de los revestimientos por la constante de aceleración de gravedad, se obtiene la fuerza peso de estas piezas que es compensada por las reacciones en los descansos para mantener al molino en equilibrio.

En la Figura 4.13 se muestra la evolución de la masa de los revestimientos del molino conforme disminuye la altura de los alzadores.




Figura 4.13 Masa de revestimientos en función del desgaste de alzadores (Fuente: Elaboración propia).

4.7. Curvas de reacción vs nivel de llenado.

Se presentan los resultados de las reacciones en el descanso de descarga, expresadas en unidades de fuerza newton, para las distintas condiciones operacionales evaluadas. Solo son presentadas las reacciones en el descanso de descarga dado que es el único que es medido

en terreno en el molino de la planta concentradora de la cual se disponen datos de terreno.

En la Figura 4.14 se muestran las reacciones en función del nivel de llenado para distintas velocidades de operación y una altura de alzador de 377 mm, mientras que en la Figura 4.15 se muestra para distintas alturas de alzadores y una velocidad del 65% de la velocidad crítica.




Figura 4.14 Curvas de reacción vs nivel de llenado – Altura de alzadores de 377 mm (Fuente: Elaboración propia).

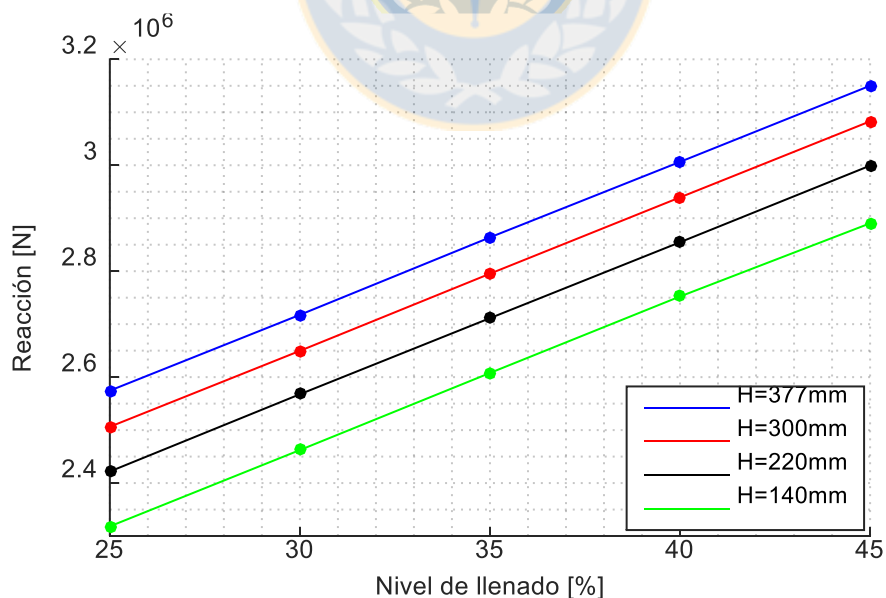


Figura 4.15 Curvas de reacción vs nivel de llenado – velocidad de 65 % (Fuente: Elaboración propia).

En la Figura 4.14 se observa una tendencia de crecimiento lineal de la reacción del descanso respecto al nivel de llenado. También se observa que los cambios en las reacciones debido a la velocidad de operación son despreciables respecto a los cambios producidos por incrementos del nivel de llenado.

Por otro lado, en la Figura 4.15 se observa que la altura de los alzadores influye considerablemente en el valor de reacción de los descansos, pudiéndose incluso lograr disminuciones en la reacción de los descansos al aumentar el nivel de llenado si es que los alzadores se encuentran desgastados.

4.8. Discusión y conclusiones.

Las simulaciones DEM resultan representativas de la dinámica de la carga al interior del molino, como se mostró en el análisis de la posición de la carga del molino al variar las condiciones de operación.

Las curvas estáticas generadas en este trabajo pueden ser explicadas cualitativamente por medio de relaciones físicas, lo que respalda la validez de las simulaciones DEM para relacionar cuantitativamente las distintas interacciones entre variables de operación como la velocidad, potencia, nivel de llenado y altura de alzadores.

La metodología para obtener la reacción de los descansos a partir de las fuerzas ejercidas por las partículas sobre la estructura del molino es consistente con la idea intuitiva de que ambos descansos deben soportar el peso del molino de manera equitativa.

Finalmente, se puede concluir que la potencia demanda por el molino presenta una gran interacción con las variables velocidad, nivel de llenado y altura de alzadores, mientras que las reacciones dependen principalmente del valor del nivel de llenado y la altura de los alzadores.

Capítulo 5. Modelo de nivel de llenado

5.1. Introducción

En este capítulo se desarrolla el modelo neuro-difuso del nivel de llenado basado en ANFIS. Las entradas del modelo son la reacción del descanso de descarga, potencia, velocidad de operación y altura de alzadores. Se presentan los valores de las distintas condiciones de operación junto con los respectivos niveles de llenado.

Es importante consignar que el procedimiento de medición del llenado del molino en terreno se detalla en el Anexo A.

Una vez desarrollado el modelo neuro-difuso, se muestran las reglas resultantes de la etapa de entrenamiento, la estructura del modelo y se analizan las superficies de salida.

Finalmente, se evalúa el desempeño del modelo por medio de los índices RMSE y MAPE en un set de 25 simulaciones adicionales al set de 100 simulaciones utilizadas para crear el modelo.

5.2. Registros de simulaciones DEM

Para la construcción del modelo neuro-difuso que permita estimar el nivel de llenado a partir de las variables reacción del descanso de descarga, potencia, velocidad de operación y altura de alzadores, se utilizan los datos generados a partir de las simulaciones DEM.

En la Figura 5.1 se presentan los valores de las distintas variables de entrada, normalizadas respecto a los valores de la Tabla 5.1.




Figura 5.1 Datos de entrenamiento normalizados (Fuente: Elaboración propia).

Tabla 5.1 Valores de normalización de variables (Fuente: Elaboración propia).

Variable	Valor de normalización
Reacción del descanso de descarga	$3.1604 \cdot 10^6$ [N]
Potencia	7.2235 [MW]
Velocidad	100 [%]
Altura de alzadores	377 [mm]
Nivel de llenado	100 [%]

Los datos normalizados son agrupados aleatoriamente en subconjuntos de entrenamiento y validación, en una proporción 80-20%, respectivamente.

Los datos del conjunto de validación son usados para mejorar la capacidad de generalización y evitar el sobreajuste del modelo a la data de entrenamiento.

5.3. Desarrollo del modelo de nivel de llenado

5.3.1 Etapa de entrenamiento

En la Figura 5.2 se muestra la evolución del índice de error RMSE expresado en % (con base el 100% del nivel de llenado) durante las distintas épocas de entrenamiento y el correspondiente RMSE obtenido con los datos de validación. Se observa que ambos índices de error se estabilizan a partir de la época N°10. Además, dado que la tendencia del error de validación es estrictamente decreciente, se asegura que no existe sobreajuste del modelo generado respecto a la data de entrenamiento.




Figura 5.2 Evolución del RMSE durante la etapa de entrenamiento del modelo (Fuente: Elaboración propia).

Los valores de RMSE obtenidos al final del proceso de entrenamiento se muestran en la Tabla 5.2.

Tabla 5.2 Valores RMSE finalizado el entrenamiento (Fuente: Elaboración propia).

Conjunto de datos	Valor RMSE final [%]
Entrenamiento	0.11
Validación	0.12

5.3.2 Reglas resultantes y funciones de pertenencia

El modelo generado al final de la etapa de entrenamiento posee 2 reglas y 2 funciones de pertenencia por cada variable de entrada. La Figura 5.3 muestra el sistema de inferencia

difuso del nivel de llenado a partir de las reglas que lo componen.




Figura 5.3 Funciones de pertenencia de las 2 reglas del modelo (Fuente: Elaboración propia).

Las primeras cuatro columnas muestran las funciones de pertenencia correspondientes a las partes if-then de cada regla, mientras que la quinta columna muestra las funciones de pertenencia de tipo singleton de cada regla, las cuales poseen un valor unitario en sólo un punto del universo de discurso. La posición de cada singleton varía según el valor que asuman las variables de entrada, y sus valores son ponderados por el grado de cumplimiento de cada regla normalizado.

Por ejemplo, si el singleton de la primera regla se ubicara en la posición 0.4 y el grado de cumplimiento normalizado de la misma fuera de 0.5, el valor ponderado sería de 0.2. De la misma forma, si el singleton de la segunda regla se ubicara en la posición 0.3, su valor ponderado sería de 0.15. Así, el valor estimado total del nivel de llenado sería de 0.35.

5.3.3 Estructura y parámetros

La estructura del modelo neuro-difuso es mostrada en la Figura 5.4. Además, la Tabla 5.3 muestra los parámetros de las funciones de pertenencia y la Tabla 5.4 los parámetros de los consecuentes de las reglas.

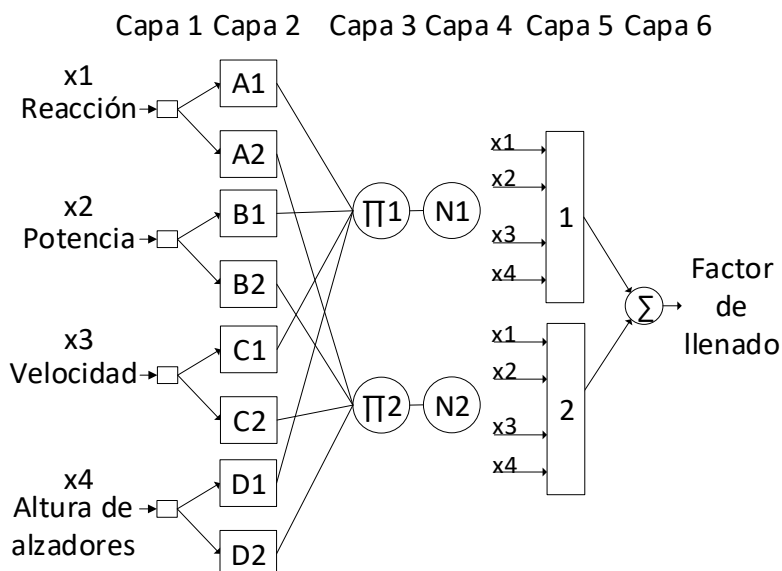


Figura 5.4 Estructura ANFIS del modelo del nivel de llenado (Fuente: Elaboración propia).

Tabla 5.3 Parámetros de las funciones de pertenencia (Fuente: Elaboración propia).

Variable	Función de pertenencia	σ (desviación)	c (centro)
Reacción descanso de descarga	A1	0.0908	0.8566
	A2	0.1119	0.7318
Potencia	B1	0.1006	0.8876
	B2	0.1238	0.9054
Velocidad	C1	0.0788	0.7639
	C2	0.0774	0.7867
Altura de alzadores	D1	0.1972	0.5855
	D2	0.2439	0.7950

Tabla 5.4 Parámetros de los consecuentes de las reglas (Fuente: Elaboración propia).

Regla	Parámetros	Valor
Regla 1	a1	1.2075
	b1	0.1366
	c1	-0.2252
	d1	-0.1883
	e1	-0.5365
Regla 2	a2	1.1763
	b2	-0.0068
	c2	-0.0355
	d2	-0.1719
	e2	-0.4956

5.3.4 Superficies de salida

La salida final del modelo del nivel de llenado corresponde a la ponderación de las salidas de cada regla y puede ser analizada en un espacio tridimensional conocido como superficie de salida. Las superficies de salida permiten analizar la sensibilidad del nivel de llenado respecto a las variables de entrada.

La Figura 5.5 muestra la sensibilidad de la variable estimada ante variaciones de reacción de descanso y potencia, mientras que la Figura 5.6 lo hace para variaciones de reacción de descanso y altura de alzadores. La Figura 5.7 muestra la superficie generada por variaciones de potencia a distintas velocidades, con altura de alzadores de 300 mm.




Figura 5.5 Nivel de llenado en función de reacción de descanso y potencia, altura de alzadores de 300 mm y 75% de la velocidad crítica (Fuente: Elaboración propia).

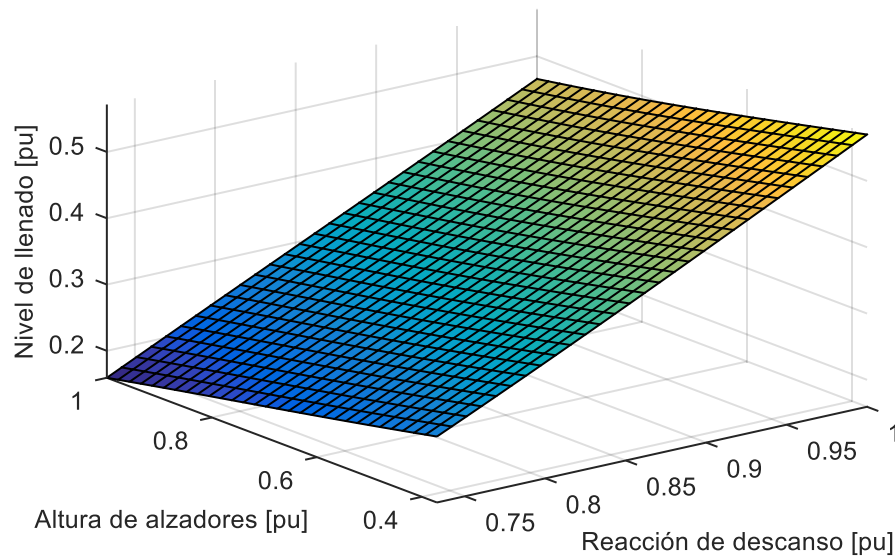


Figura 5.6 Nivel de llenado en función de reacción de descanso y altura de alzadores, 75 % de la velocidad crítica (Fuente: Elaboración propia).

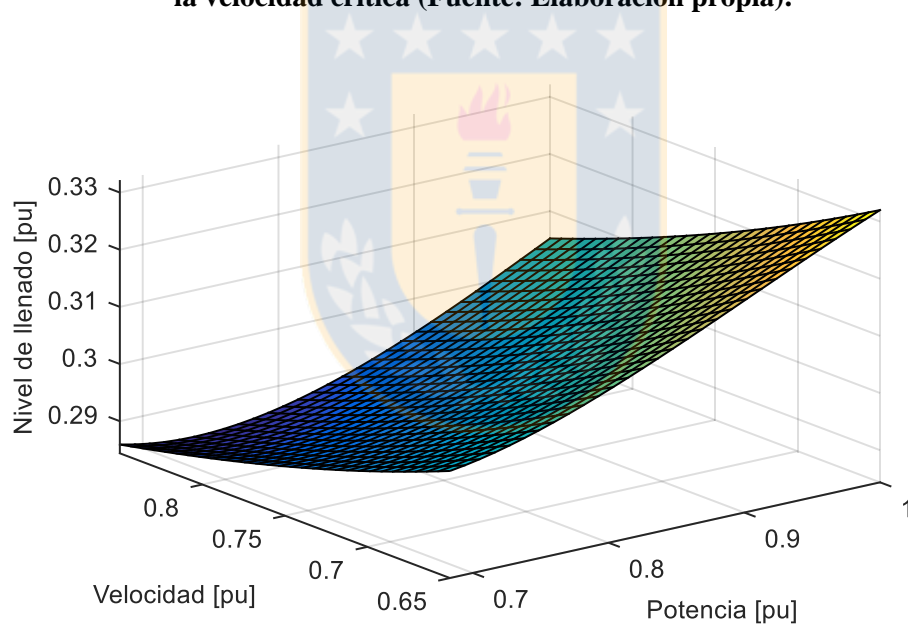


Figura 5.7 Nivel de llenado en función de potencia y velocidad, altura de alzadores de 300 mm (Fuente: Elaboración propia).

En la Figura 5.5 se observa que el nivel de llenado es más sensible a variaciones de la reacción en el descanso que a variaciones en la potencia. Lo anterior se explica en que un cambio en la reacción en el descanso se debe exclusivamente a un cambio en el nivel de llenado, mientras que variaciones de la potencia no solo se deben a cambios en esta última variable, sino que también a variaciones de la velocidad de operación y nivel de desgaste de los alzadores.

Por otra parte, la superficie presentada en la Figura 5.6 muestra que, para un mismo valor de reacción en el descanso, el nivel de llenado estimado es mayor en la medida que los alzadores se encuentran más desgastados. La explicación a esta tendencia radica en que la densidad media de la carga del molino es menor a la de los alzadores, por lo que la reducción de material de los alzadores debe ser compensada por un volumen mayor de mineral.

Finalmente, en la Figura 5.7 se observa que el nivel de llenado tiende a aumentar conforme se incrementa la potencia, cualquiera sea la velocidad de giro del molino y operando con una altura de alzadores de 300 mm. Lo anterior se debe a que, si la velocidad de rotación es fija, un incremento de potencia es reflejo de un aumento del torque, el cual depende directamente del llenado del molino.

Por otro lado, un mismo valor de potencia se encuentra asociado a un llenado mayor en la medida que la velocidad de operación es menor. Esto tiene su explicación en que, para una cierta altura de alizador, la potencia desarrollada depende tanto de la velocidad de operación como del nivel de llenado, por lo que si la potencia es fija las contribuciones de los efectos anteriores son inversamente proporcionales.

5.4. Evaluación del modelo

La evaluación del estimador se realiza mediante un set de 25 simulaciones DEM. Considerando que en la etapa de entrenamiento se utilizaron los resultados de 100 simulaciones, la proporción de simulaciones de evaluación corresponde al 20% del total.

El set se divide en tres grupos compuestos por 9, 12 y 4 simulaciones, respectivamente. El primer grupo evalúa si bajo condiciones de velocidad y altura de alzadores utilizadas en el entrenamiento, el estimador logra identificar con precisión un nivel de llenado distinto a los utilizados en la creación del modelo.

En cierta forma, la primera evaluación del estimador es análoga a la evaluación del seguimiento de una referencia en un sistema de control.

El primer grupo de simulaciones se muestra en la Tabla 5.5.

Tabla 5.5 Primer grupo de simulaciones de evaluación (Fuente: Elaboración propia).

N° simulación	Altura de alzadores [mm]	Velocidad de operación [% de velocidad crítica]	Nivel de llenado [%]
1	377	85	27.5
2	377	85	32.5
3	377	85	37.5
4	300	75	27.5
5	300	75	32.5
6	300	75	37.5
7	140	65	27.5
8	140	65	32.5
9	140	65	37.5

El segundo evalúa la robustez de la estimación de un nivel de llenado utilizado en la etapa de entrenamiento, ante condiciones de velocidad de operación y altura de alzadores distintas a las utilizadas en la creación del modelo.

En cierta forma, la evaluación del estimador por medio de este grupo de simulaciones es análoga a la evaluación del rechazo de perturbaciones en un sistema de control.

El segundo grupo de simulaciones se muestra en la Tabla 5.6.

Tabla 5.6 Segundo grupo de simulaciones de evaluación (Fuente: Elaboración propia).

N° simulación	Altura de alzadores [mm]	Velocidad de operación [% de velocidad crítica]	Nivel de llenado [%]
10	340	82.5	25
11	340	67.5	25
12	180	82.5	25
13	180	67.5	25
14	340	82.5	30
15	340	67.5	30
16	180	82.5	30
17	180	67.5	30
18	340	82.5	35
19	340	67.5	35
20	180	82.5	35
21	180	67.5	35

Finalmente, el tercer grupo consiste en simulaciones en las cuales la velocidad de operación, la altura de los alzadores y el nivel de llenado son diferentes respecto a los valores

utilizados en la etapa de entrenamiento del modelo. Este grupo se presenta en la Tabla 5.7.

Tabla 5.7 Tercer grupo de simulaciones de evaluación (Fuente: Elaboración propia).

N° simulación	Altura de alzadores [mm]	Velocidad de operación [% de velocidad crítica]	Nivel de llenado [%]
22	340	82.5	27.5
23	340	82.5	37.5
24	180	67.5	27.5
25	180	67.5	37.5

Cabe mencionar que en todos los grupos se incluyen simulaciones que combinan alturas de alzadores altas (≥ 340 mm) con velocidades altas (≥ 82.5 %), así como alturas de alzadores bajas (≤ 180 mm) con velocidades bajas (≤ 67.5 %). De esta manera se evalúa que el estimador sea robusto ante variaciones del flujo en catarata de las partículas.

El resultado de la evaluación del modelo del nivel de llenado se muestra en la Figura 5.8, donde los niveles de llenado utilizados en las simulaciones junto con los correspondientes valores estimados se encuentran ordenados por índice de simulación.

En la Figura 5.9 se muestran los correspondientes errores de estimación, también ordenados por índice de simulación. Se observa que todos los errores de estimación son menores a 0.15% (con base el 100% del nivel de llenado).




Figura 5.8 Evaluación de modelo de nivel de llenado (Fuente: Elaboración propia).




Figura 5.9 Errores de estimación obtenidos en la evaluación del modelo (Fuente: Elaboración propia).

Por otro lado, en la Tabla 5.8 se presentan los índices de error RMSE y MAPE de cada grupo de simulaciones, así como aplicados al total de simulaciones. El índice RMSE se expresa en porcentaje respecto al 100% del nivel de llenado del molino, mientras que el índice MAPE se expresa en porcentaje respecto a los valores específicos de llenado usados en las simulaciones DEM.

Tabla 5.8 RMSE y MAPE de simulaciones de evaluación (Fuente: Elaboración propia).

Grupo de simulaciones	RMSE [%]	MAPE [%]
Grupo I	0.11	0.29
Grupo II	0.09	0.25
Grupo III	0.09	0.25
Total de simulaciones	0.09	0.27

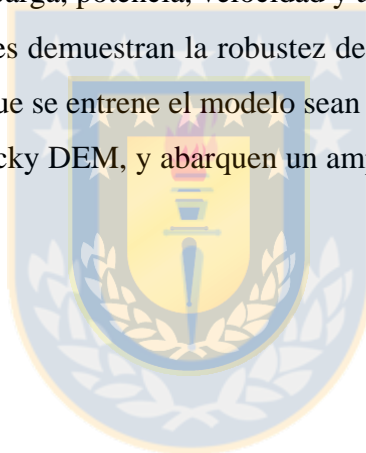
Los índices de error presentados en la Tabla 5.8 reflejan una buena estimación del nivel de llenado a partir de variables de proceso y eléctricas, dado que el MAPE obtenido considerando todas las simulaciones de evaluación es de un 0.27%. Además, la variación del error, expresado en porcentaje respecto al 100% de la variable estimada, no sobrepasó el 0.22%, con un índice RMSE del 0.09%.

5.5. Discusión y conclusiones

El modelo neuro-difuso del nivel de llenado, evaluado con un set de 25 simulaciones que no fueron utilizadas en el proceso de entrenamiento, presenta bajas desviaciones. Específicamente, los errores de estimación no superan el 0.22% del volumen total del molino y el índice MAPE fue de un 0.27%.

Es importante destacar que, dentro de las simulaciones de evaluación, se incluyeron simultáneamente condiciones de altura de alzadores, velocidad y nivel de llenado distintas a cualquiera de las usadas en el proceso de entrenamiento. No obstante, el modelo demostró ser robusto y estimar de forma precisa los llenados del molino a partir de los valores de reacción en el descanso de descarga, potencia, velocidad y altura de alzadores.

Los resultados anteriores demuestran la robustez de las técnicas neuro-difusas en la medida que los datos con los que se entrene el modelo sean consistentes, como es el caso de los resultados obtenidos en Rocky DEM, y abarquen un amplio rango de las condiciones de operación.



Capítulo 6. Ajuste del modelo de nivel de llenado con datos de terreno

6.1. Introducción

En este capítulo se modifica el modelo neuro-difuso del nivel de llenado generado en base a simulaciones en Rocky DEM, por medio de un conjunto de datos de terreno y la herramienta de optimización de Simulink “Parameter Estimation”. Esta herramienta determina por medio de un método de optimización, *Trust-Region-Reflective* [36], los valores de los parámetros de un modelo que minimizan el error entre la variable estimada y la variable medida.

Los datos de terreno utilizados como entradas corresponden a promedios de las variables de proceso sobre una ventana de tiempo de 50 minutos previos a la detención del molino, y se muestran en la Tabla 6.1 y Tabla 6.2 para los molinos SAG 1 y SAG 2, respectivamente.

Para el proceso de optimización de los parámetros, se desarrolla una implementación del modelo neuro-difuso en Simulink. Se agrega una etapa de transformación de una señal de presión a reacción de descanso. Esto dado que la presión no puede ser simulada en Rocky DEM, por lo que para utilizar el modelo neuro-difuso desarrollado en base a DEM es necesario establecer la relación en cuestión.

Es importante destacar que la relación presión-reacción desarrollada considera la altura de los alzadores, dada la pérdida de masa que los descansos deben soportar a medida que los alzadores se desgastan.

6.2. Modelo de nivel de llenado implementado en Simulink

En la Figura 6.1 se muestra la implementación en Simulink del modelo neuro-difuso de nivel de llenado. En color azul se destacan las entradas y la salida expresadas en sus respectivas unidades de medida.

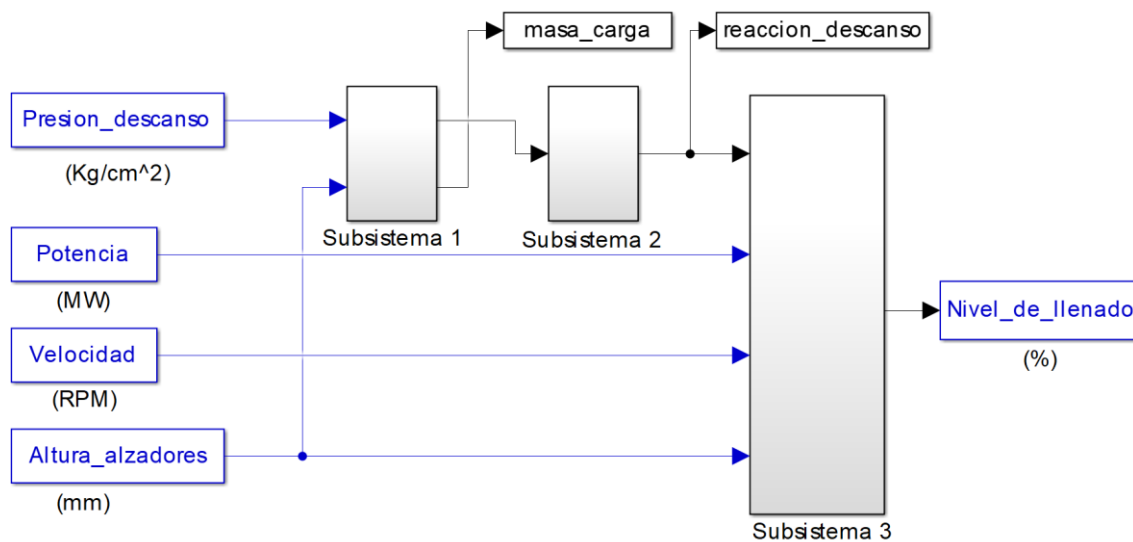


Figura 6.1 Modelo de nivel de llenado implementado en Simulink (Fuente: Elaboración propia).

En la Figura 6.2 se muestra el detalle del subsistema 1 de la Figura 6.1, el cual transforma valores de presión de descanso en valores de masa de carga del molino y masa de carga más revestimientos, siendo ésta última la entrada del subsistema 2 de la misma figura. Los bloques destacados en color verde corresponden a parámetros que son ajustados.

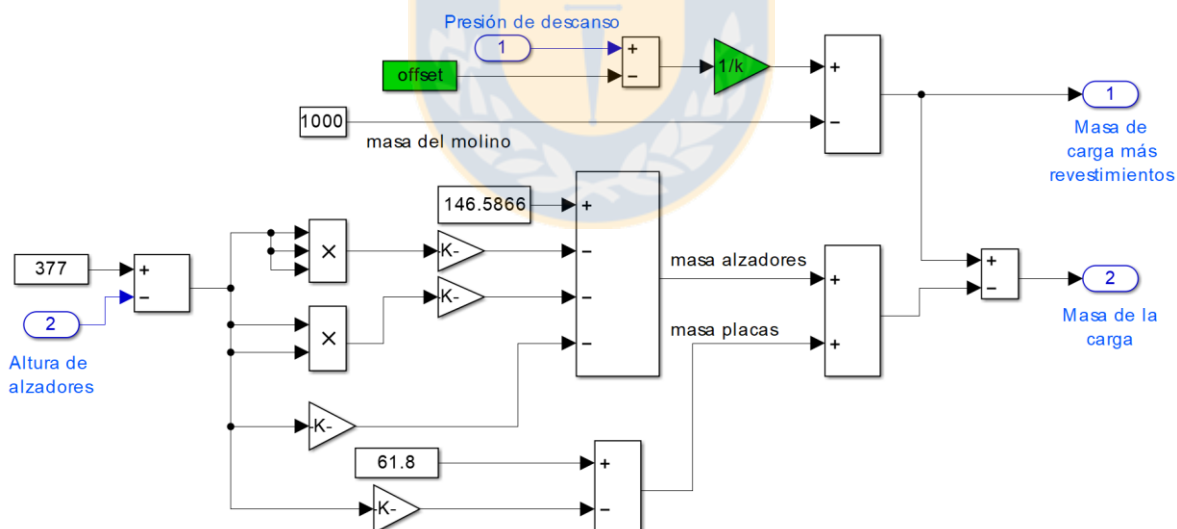


Figura 6.2 Subsistema 1 de modelo de nivel de llenado (Fuente: Elaboración propia).

En la Figura 6.3, se detalla el subsistema 2 del modelo de nivel de llenado, el cual realiza la transformación desde la masa de la carga más revestimientos, a un valor de reacción del descanso del lado de descarga. Para esto, la masa de la carga más revestimientos, expresada en toneladas, se multiplica por un factor 1000 para obtener su valor en kilogramos. Luego, se transforma a unidades de fuerza newton multiplicando por el factor 9.81

correspondiente a la constante de aceleración de gravedad. Por último, se multiplica por el factor 0.5 dado que mediante las simulaciones DEM se determinó que cada descanso produce una reacción que en promedio equivale a la mitad de la fuerza peso de la carga del molino.




Figura 6.3 Subsistema 2 de modelo de nivel de llenado (Fuente: Elaboración propia).

Finalmente, en la Figura 6.4, se muestra el subsistema 3 que corresponde a la estructura ANFIS desarrollada a partir de los datos generados en Rocky DEM para estimar el nivel de llenado a partir de la reacción del descanso de descarga, potencia, velocidad y altura de alzadores. En color verde se destaca la etapa de normalización de las entradas, en color azul y rojo los parámetros asociados a la primera y segunda regla del modelo, respectivamente; y en color negro los bloques asociados a la ponderación de las salidas de cada regla.

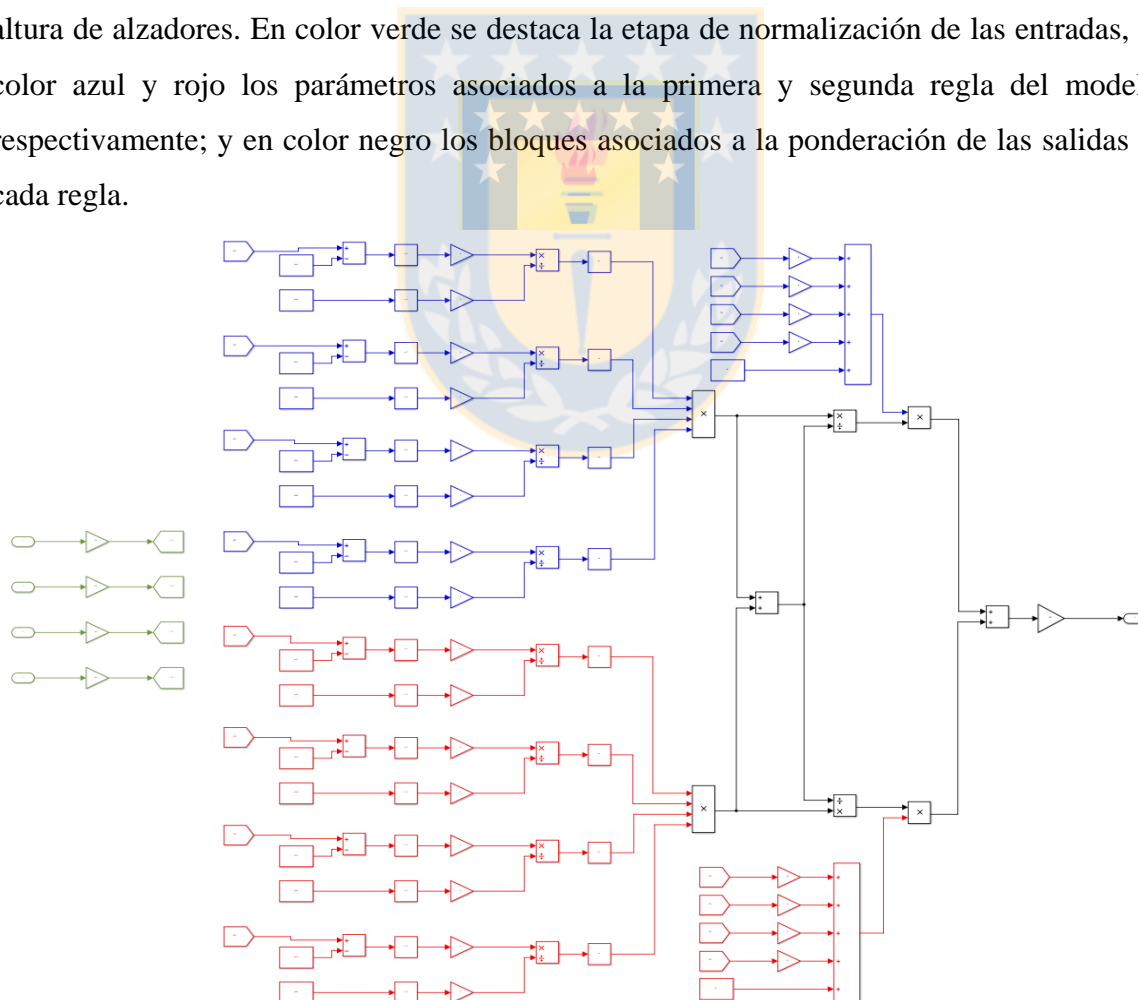


Figura 6.4 Subsistema 3 de modelo de nivel de llenado (Fuente: Elaboración propia).

6.3. Ecuaciones que requieren ajuste de parámetros

La relación que se utiliza para obtener la masa de la carga del molino a partir del valor de presión del descanso de descarga se muestra en la ecuación (6.1). La dependencia lineal de la presión del descanso con respecto a la masa de la carga se reporta experimentalmente en [11]. De esta ecuación los parámetros k y $offset$ son identificados dado que se desconocen sus valores.

$$p = k(M_c + 1000 + m_R) + offset \quad (6.1)$$

donde,

- p : Presión del descanso del lado de descarga, en kg/cm^2 .
- k : Ganancia toneladas-presión.
- M_c : Masa de la carga, en ton.
- m_R : Masa de los revestimientos, en ton.
- $offset$: Constante asociada a la calibración de sensor de presión, en kg/cm^2 .
- 1000 : Masa estimada de la estructura del molino, en ton.

Es importante consignar que la masa de los revestimientos, m_R , se obtiene a partir de la ecuación (4.9).

Por otro lado, en la ecuación (6.2) se muestra la salida del modelo de nivel de llenado correspondiente a la primera regla difusa, mientras que en la ecuación (6.3) se muestra para la segunda regla.

$$J_c = a_1 \cdot R + b_1 \cdot P + c_1 \cdot V + d_1 \cdot H + e_1 \quad (6.2)$$

$$J_c = a_2 \cdot R + b_2 \cdot P + c_2 \cdot V + d_2 \cdot H + e_2 \quad (6.3)$$

donde,

- J_c : Nivel de llenado.
- R : Reacción en el descanso del lado de descarga.
- P : Potencia demandada por el molino.
- V : Velocidad de operación.
- H : Altura de alzadores.
- a_1, a_2 : Parámetros de ponderación de reacción en el descanso.
- b_1, b_2 : Parámetros de ponderación de potencia.

c_1, c_2 : Parámetros de ponderación de velocidad.

d_1, d_2 : Parámetros de ponderación de altura de alzadores.

Los parámetros b_1 y b_2 se ajustan para compensar los efectos de molienda húmeda que no son posibles de replicar directamente en Rocky DEM. Por otro lado, los parámetros d_1 y d_2 se ajustan para compensar las diferencias entre la masa perdida por lo revestimientos en función del desgaste, en condiciones reales de proceso y simuladas en DEM.

6.4. Registros de terreno y valores de parámetros ajustados

En la Tabla 6.1 y Tabla 6.2 se presentan los valores promedio de los registros de terreno de los molinos SAG 1 y 2, respectivamente.

Tabla 6.1 Valores promedio de mediciones de terreno SAG 1 (Fuente: Elaboración propia).

Inspección	Nivel de llenado (%)	Presión de descanso (kg/cm^2)	Potencia (MW)	Velocidad (RPM)	Altura de alzadores (mm)
1	27	59.8	5.8	8.09	237
2	29.2	61.3	6.53	9.04	296
3	30.6	61.9	6.15	8.85	344
4	33.7	62.5	7.02	10.68	314
5	36.1	63.9	5.87	9.07	326
6	39.3	64.5	3.53	6.90	256

Tabla 6.2 Valores promedio de mediciones de terreno SAG 2 (Fuente: Elaboración propia).

Inspección	Nivel de llenado (%)	Presión de descanso (kg/cm^2)	Potencia (MW)	Velocidad (RPM)	Altura de alzadores (mm)
1	26.2	62.8	4.92	8.05	339
2	27.7	63.3	4.38	6.97	199
3	29.9	63.9	4.92	7.22	240
4	30.6	64.1	5.29	7.94	233
5	33.7	64.5	6.30	8.90	241

En la Figura 6.5 se muestra la gráfica de los valores promedio de los registros de terreno del molino SAG 1.




Figura 6.5 Valores promedio de registros de terreno de molino SAG 1 (Fuente: Elaboración propia).

Los valores obtenidos de los parámetros ajustados, para los modelos de cada molino SAG, se presentan en la Tabla 6.3.

Tabla 6.3 Parámetros ajustados con datos de terreno (Fuente: Elaboración propia).

Modelo	Parámetros					
	k	offset	b1	b2	d1	d2
SAG 1	0.049360	-12.251	0.47334	-0.078389	-0.46993	$-1.52 \cdot 10^{-8}$
SAG 2	0.046879	-5.0074	0.35836	-0.01171	-0.31784	-0.022033

6.5. Resultados

En la Figura 6.6 se muestra la comparación de los distintos niveles de llenado registrados en terreno y las estimaciones del modelo de nivel de llenado del molino SAG 1 a partir de variables de proceso.

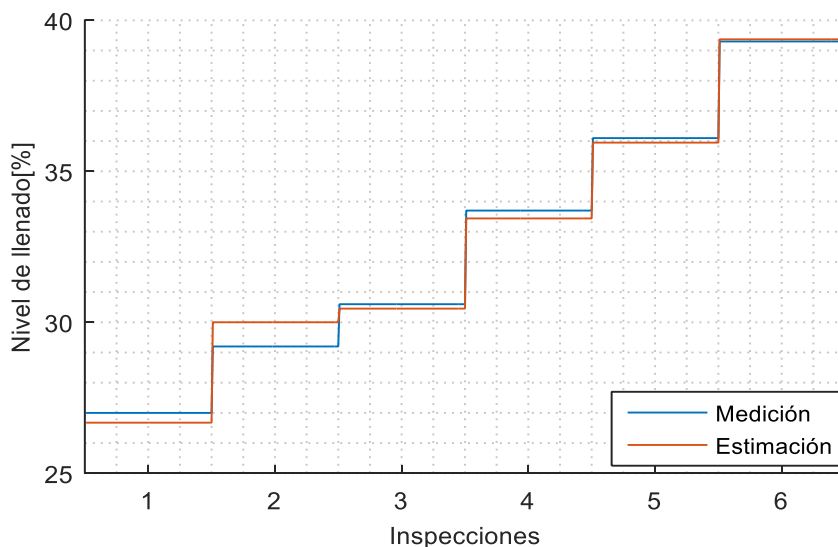


Figura 6.6 Estimaciones del nivel de llenado – molino SAG 1 (Fuente: Elaboración propia).

En la Tabla 6.4 se muestra los errores en la estimación del nivel de llenado para cada una de las inspecciones del modelo del molino SAG 1, mientras que en la Tabla 6.5 se muestra para el caso del molino SAG 2.

Tabla 6.4 Errores de estimación de modelo de nivel de llenado SAG 1 (Fuente: Elaboración propia).

Inspecciones	Masa estimada de la carga [ton]	Nivel de llenado estimado [%]	Nivel de llenado medido [%]	Error absoluto [%]
1	278.7	26.68	27	0.32
2	296.5	30	29.2	0.8
3	299.6	30.45	30.6	0.15
4	317.3	33.44	33.7	0.26
5	343.4	35.95	36.1	0.15
6	369.6	39.37	39.3	0.07
Error medio				0.29

Tabla 6.5 Errores de estimación de modelo de nivel de llenado SAG 2 (Fuente: Elaboración propia).

Inspecciones	Masa estimada [ton]	Nivel de llenado estimado [%]	Nivel de llenado medido [%]	Error absoluto [%]
1	244.7	25.87	26.2	0.33
2	285.3	28.45	27.7	0.75
3	288.2	29.64	29.9	0.26
4	294.1	30.72	30.6	0.12
5	300.8	33.44	33.7	0.26
Error medio				0.34

6.6. Discusión y conclusiones

Las estimaciones del nivel de llenado obtenidas por medio del modelo neuro-difuso del nivel de llenado ajustado con datos de terreno presentan bajos errores de estimación. Específicamente, se obtienen errores medios de 0.29% para el caso del modelo del SAG 1 y 0.34% para el caso del SAG 2. Ambos errores usan como base el 100% del volumen del molino.

Además, es importante consignar que tanto en las estimaciones de los niveles de llenado de terreno del SAG 1 como del SAG 2, los errores fueron siempre menores al 1%.

Finalmente, dados los bajos errores de estimación obtenidos, se concluye que un modelo neuro-difuso del nivel de llenado construido a partir de datos consistentes y representativos, y que además se ajusta por medio de datos de terreno, constituye una útil herramienta en la estimación en línea de un molino SAG industrial.



Capítulo 7. Conclusiones

7.1. Sumario

- Se realizó una extensa revisión bibliográfica para situar el presente trabajo respecto al estado del arte en la estimación en línea del desgaste de alzadores y nivel de llenado de molinos SAG.
- Se desarrolló un resumen de los conceptos asociados a la modelación neuro-difusa, presentando en primera instancia los sistemas difusos, luego las redes neuronales artificiales y finalmente el sistema híbrido ANFIS.
- Se desarrollaron dos modelos neuro-difusos de desgaste de alzadores a partir de registros de terreno de variables de proceso y valores de altura obtenidos por inspección visual. Para cada uno de los molinos se utilizaron datos de dos campañas de alzadores.
- Se analizaron los valores de potencia y reacción de descansos obtenidos a partir de las simulaciones DEM, el análisis se realizó desde una perspectiva física y comparando con trabajos de la bibliografía.
- Se desarrolló un modelo neuro-difuso del nivel de llenado a partir de los datos generados a partir de un conjunto de 100 simulaciones DEM en un amplio rango de variación de condiciones de operación. La evaluación se realizó con un set de 25 simulaciones adicionales.
- Se presentaron dos modelos de nivel de llenado, para los molinos SAG 1 y SAG 2, obtenidos por medio del ajuste del modelo neuro-difuso generado en base a DEM por medio de registros de terreno e inspecciones visuales del nivel de llenado. El ajuste de los parámetros de los modelos se llevó a cabo mediante herramientas de optimización de Simulink.

7.2. Conclusiones

1. La metodología de modelación neuro-difusa usada en la estimación en línea del desgaste de alzadores, constituye una valiosa herramienta para evitar detenciones del molino a causa de inspección de estas piezas y además es un apoyo en la planificación del mantenimiento. Lo anterior se respalda en que, utilizando variables de proceso y eléctricas, los modelos del SAG 1 y SAG 2 presentaron desviaciones máximas de 2.1 y 8.6 mm, respectivamente. Estas desviaciones representan el 0.56 y 2.28% de la altura nominal de los alzadores, respectivamente. Además, los índices MAPE obtenidos en la evaluación de cada uno de los modelos son inferiores a 1%.
2. Los datos obtenidos por medio de Rocky DEM permiten desarrollar satisfactoriamente un modelo neuro-difuso capaz de estimar el nivel de llenado en función de la reacción del descanso de descarga, potencia, velocidad y altura de alzadores. Lo anterior se debe a que las simulaciones cubren un amplio rango de variación de las condiciones operacionales y son consistentes entre sí. Los errores de estimación no superaron en ningún caso el 0.22% del volumen total del molino.
3. El ajuste por medio de datos de terreno del modelo neuro-difuso del nivel de llenado fue satisfactorio en el caso de los molinos SAG 1 y SAG 2, lo cual se respalda en que en ninguna condición de terreno el error de estimación superó el 0.8% del volumen total del molino. Además, los índices de errores promedio obtenidos en la evaluación de cada uno de los modelos son inferiores a 0.35%.
4. La metodología neuro-difusa de estimación del nivel de llenado constituye una valiosa herramienta para los sistemas de control avanzado de una planta de molienda, dado que la formulación del control podría incorporar el nivel de llenado y no solo la presión de los descansos. Lo anterior contribuye a estabilizar el proceso de molienda en una condición óptima respecto al aprovechamiento de la capacidad de diseño de un molino SAG, sin el riesgo de caer en condiciones de sobrellenado o vaciado del molino que merman la producción de mineral y la eficiencia del proceso.

7.3. Trabajo futuro

- **Estudio del nivel de llenado de bolas y distribución de tamaños en molinos SAG:**
Se propone realizar un estudio de la influencia del nivel de llenado de bolas y su distribución de tamaños en variables de operación como la potencia y reacción de descansos, bajo distintas condiciones de nivel de llenado total, velocidad y altura de alzadores.
- **Estudio del desgaste de alzadores en molinos SAG de descarga continua:**
Se propone realizar un estudio del desgaste de alzadores en molinos SAG a partir de simulaciones DEM en que se emula la entrada y descarga de mineral, evaluando campañas bajo distintas condiciones de operación.



Bibliografía

- [1] C. Stenström, “Ultrasonic for monitoring of mining mill linings: Pilots Experiments”, Center for Maintenance and Industrial Services, Division of Operation, Maintenance and Acoustics, Luleå University of Technology, Suecia, Reporte técnico, Abril 2016.
- [2] Fundación Chile, “Casos de innovación de proveedores en la minería chilena”, Santiago; *Primera Edición (2016)*.
- [3] R. Cartes, M. Valenzuela, “Empirical Determination of the Effect of Lifter Wear in Mill Power for Dry Grinding”, *IEEE Trans. on Industry Applications*, Vol. 53, N° 3, p.p 2621 - 2627.
- [4] B. Castro, M. Valenzuela, “Experimental evaluation of power requirements for wet grinding and its comparison to dry grinding” IEEE Industry Applications Society Annual Meeting. Cincinnati, USA, 2017.
- [5] M. Rezaeizadeh, M. Fooladi, and M.S Powell, “An experimental investigation of the effects of operating parameters on the wear of lifters in tumbling mills”, *Minerals Engineering*, vol. 23, pp. 558-562, Diciembre 2009.
- [6] Ahmadzadeh, F, Lundberg, J, 2013. Remaining useful life prediction of grinding mill liners using an artificial neural network. *Miner. Eng.* 53, 1–8.
- [7] R.P King, “Modeling and simulation of mineral processing systems” Society for Mining, Metallurgy, and Exploration, Inc. (SME); Second edition (2012).
- [8] Daniel Sbárbaro, René del Villar, “Advanced control and supervision of mineral processing plants” Springer; First edition (2010).
- [9] Salazar, J., Magne, L., et al., 2009. Dynamic modelling and simulation of semiautogenous mills. *Miner. Eng.* 22 (1), 70–77.
- [10] Pontt, J, 2004. MONSAG: A new monitoring system for measuring the load filling of a SAG mill. *Miner. Eng.* 17, 1143–1148.
- [11] M. H. Moys, “The control of autogenous and semi-autogenous mills: the relationship between measurements of bearing pressure and parameters describing the mill load” *Journal of the Southern African Institute of Mining and Metallurgy*, vol. 72, No 11,

- pp. 401-408, 1980.
- [12] H. Robles, T. Ledezma, J. Inostroza, L. Vinnett, W. Valderrama, J. Pontt, “New approach for load level estimation in SAG mills using a sensor system and optimization algorithm” *Procemin 2015*, Chile.
- [13] G. Acuña, M. Curilem, F. Cubillos, “Desarrollo de un Sensor Virtual basado en Modelo NARMAX y Máquina de Vectores de Soporte para Molienda Semiautógena” *Revista Iberoamericana de Automática e Informática Industrial RIAI*, vol. 11, No 1, pp. 109-116, 2014.
- [14] K. Carvajal, G. Acuña, “Estimation of State Variables in Semiautogenous Mills by Means of a Neural Moving Horizon State Estimator” *Advances in Neural Networks*, ISSN 2007, pp. 1255-1264.
- [15] J.D. le Roux, A. Steinboeck, A. Kugi, I.K. Craig, “An EKF observer to estimate semi-autogenous grinding mill hold-ups” *Journal of Process Control*, vol. 51, pp. 27-41, March 2017.
- [16] Jian Tang, Tianyou Chai, Lijie Zhao, Wen Yu, Heng Yue, “Soft sensor for parameters of mill load based on multi-spectral segments PLS sub-models and on-line adaptive weighted fusion algorithm” *Neurocomputing*, vol. 78, No 1, pp. 38-47, February 2012.
- [17] Chin-Teng Lin (Author), C. S. George Lee (Author), “Neural Fuzzy Systems: A Neuro-Fuzzy Synergism to Intelligent Systems” Prentice Hall; Har/Dskt edition (May 1996).
- [18] Michael Negnevitsky, “Artificial Intelligence: A Guide to Intelligent Systems” Addison Wesley Second edition (2005).
- [19] Zadeh, L.A, “Fuzzy Logic” *IEEE Comput.*, vol.1 pp. 83 - 93, 1988.
- [20] M.J Willis, et al, “Artificial neural networks in process engineering” *IEEE Proceedings D (Control Theory and Applications)*, vol.138 pp. 256 - 266, 1991.
- [21] J.-S. Roger Jang. “ANFIS: Adaptive-network-based fuzzy inference system”, *IEEE Trans. Syst. Man Cybern*, 23(03):665-685, May 1993.

- [22] S. Chiu, "Method and software for extracting fuzzy classification rules by subtractive clustering" *1996 Biennial Conference of the North American*. Berkeley, USA.
- [23] B. Li, Z. Cao, M. Liu, J. Hao, "Approach to complex hydrogen reactor optimization modeling based on ANFIS" *2012 IEEE 2nd International Conference on Cloud Computing and Intelligent Systems (CCIS)*. Hangzhou, China, 2012.
- [24] A. Jahic, T. Konjic, J. Pihler and A. Jahic, "Photovoltaic power output forecasting with ANFIS," *Mediterranean Conference on Power Generation, Transmission, Distribution and Energy Conversion (MedPower 2016)*, Belgrade, 2016, pp. 1-8.
- [25] L. Minchala, et al., "A comparative study of black-box models for cement quality prediction using input-output measurements of a closed circuit grinding" *2016 Annual IEEE Conference on Systems Conference (SysCon)*. Orlando, FL, USA.
- [26] C.O' Sullivan (2011) *Particulate discrete element modelling, a geomechanics perspective* Taylor & Francis e-Library, Londres (UK) y Nueva York (USA).
- [27] X. Quiu, A. Potatov, M. Song, L. Nordell, "Prediction of Wear of Mill Lifters Using Discrete Element Method" Mular A(ed) SAG 2001, Vancouver, B.C. Canada.
- [28] M. Rezaeizadeh, M. Fooladi, M.S Powell, N. Weerasekara "A new predictive model of lifter bar wear in mills", *Minerals Engineering*, vol. 23(15), pp. 1174-1181, 2014.
- [29] J. T. Kalala, M. M. Bwalya, M. H. Moys, "Discrete element method (DEM) modelling of evolving mill liner profiles due to wear. Part II. Industrial case study", *Minerals Engineering* vol. 18, 2005, pp. 1392–1397.
- [30] N. Djordjevic, "Discrete element modelling of the influence of lifters on power draw of tumbling mill", *Minerals Engineering*, vol. 16, pp. 331-336, 2003.
- [31] P. Owen, P. Cleary "The relationship between charge shape characteristics and fill level and lifter height for a SAG mill", *Minerals Engineering*, vol. 83, pp. 19-32, 2015.
- [32] P. Cleary, P. Owen "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*, vol. 117, pp. 42-62, 2018.

- [33] *Manual – Workshop 04 - SAG Mill (Wear and Particle Energy Spectra)*, Rocky, 2017.
- [34] *Manual – A Brief Introduction to DEM and an overview of contact force models in Rocky*, Rocky, 2017.
- [35] *Manual – Fuzzy Logic Toolbox™*, Matlab, 2017.
- [36] Rao, “Engineering Optimization” Wiley; Fourth edition (2009).



Anexo A. Métodos de medición en terreno

A.1. Medición del desgaste de alzadores

El método convencional de medición del estado de los alzadores consiste en la medición directa de la altura respecto a la placa adyacente. Este procedimiento requiere necesariamente la detención del molino para su medición. La Figura A.1 muestra la distancia que es registrada (h) y los puntos de medición.

El procedimiento considera el registro de nueve puntos repartidos equidistantemente en dos filas de dos alzadores cada una. Cada fila se compone de un alzador del lado de carga y otro de descarga.

Según criterios operacionales, el valor representativo de desgaste se obtiene como la menor altura registrada.

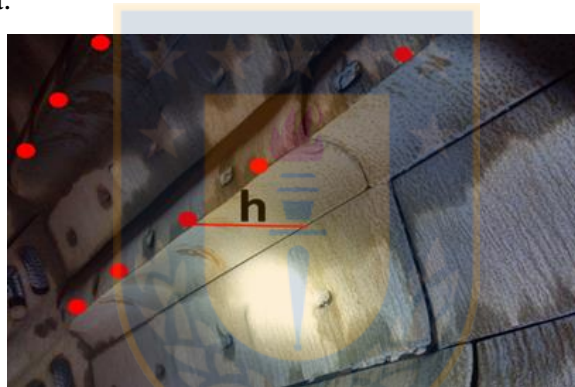


Figura A.1 Puntos de medición de altura de alzadores (Fuente: CODELCO).

A.2. Medición del nivel de llenado

El procedimiento se basa en la medición del ángulo θ , mostrado en la Figura A.2. Este procedimiento se realiza con el molino detenido.




Figura A.2 Esquema de corte transversal de molino SAG (Fuente: Elaboración propia).

En la Figura A.2, R corresponde al radio del molino; H_c a la distancia entre la superficie de la carga y el techo del molino; y h corresponde a la distancia entre la superficie de la carga y el centro del molino.

Geoméricamente, se puede demostrar que el nivel de llenado puede ser calculado según la ecuación (A.1).

$$J_c = \frac{\theta - \sin(\theta)}{2\pi} \quad (\text{A.1})$$

Para determinar el ángulo θ se realiza un conteo de alzadores y espacios entre alzadores para obtener una estimación del ángulo, según la ecuación (4.6).

$$\theta = 2\pi - \frac{Li_v + Es_v}{2 \cdot Li_t} \cdot 2\pi \quad (\text{A.2})$$

donde,

Li_v : Número de alzadores visibles en sección de anillo de alimentación.

Es_v : Número de espacios visibles en sección de anillo de alimentación.

Li_t : Número total de alzadores de sección de anillo de alimentación, 30 en el caso del molino de este trabajo.

En la Figura A.3 se muestra la vista del interior de un molino SAG durante una inspección del nivel de llenado.



Figura A.3 Vista interna de molino SAG durante inspección del nivel de llenado (Fuente: CODELCO).

Anexo B. Granulometría y metodología de llenado del molino

B.1. Granulometría de mineral y bolas

Las distribuciones granulométricas de mineral y de bolas utilizadas en este trabajo se muestran en la Tabla B.1 y Tabla B.2, respectivamente. Estas granulometrías se referencian del trabajo desarrollado en [31].

Tabla B.1 Granulometría de mineral (Fuente: Elaboración propia).

Tamaño [mm]	Acumulado pasante [%]	Porcentaje específico
200	100	8
140	92	12
100	80	15
70	65	65

Tabla B.2 Granulometría de bolas (Fuente: Elaboración propia).

Tamaño [mm]	Acumulado pasante [%]	Porcentaje específico
127	100	30
100	70	35
60	35	35

B.2. Metodología de llenado del molino

Para llenar el molino de manera de replicar las distintas condiciones de terreno, se debe tener en cuenta que cada inspección del nivel de llenado se realiza mediante el conteo de alzadores y espacios vacíos. Esto implica que el nivel de llenado reportado es solo con respecto a la parte cilíndrica del molino.

La especificación de la masa de rocas y bolas para llenar el molino se realiza asumiendo una porosidad equivalente de la carga de 0.4. El procedimiento se detalla a continuación.

En primer lugar, se calcula en el software Inventor el volumen total de la parte cilíndrica del molino, el cual es de 379.83 m³.

Luego, se tabula el volumen del molino con y sin incluir los extremos cónicos, para niveles de llenado del 25 al 45% con incrementos de 5%, lo cual se muestra en la Tabla B.3.

Tabla B.3 Volumen del molino para niveles de llenado del 25 al 45% (Fuente: Elaboración propia).

Nivel de llenado [p.u]	Volumen de parte cilíndrica [m ³]	Volumen de parte cilíndrica + extremos cónicos [m ³]
0.25	0.25 · 379.83 = 94.958	105.040
0.30	0.30 · 379.83 = 113.949	123.264
0.35	0.35 · 379.83 = 132.941	141.765
0.40	0.40 · 379.83 = 151.932	160.248
0.45	0.45 · 379.83 = 170.924	178.880

A partir de los datos de la Tabla B.3, es posible establecer una relación entre el volumen del molino con extremos cónicos y el nivel de llenado, la cual se muestra en la ecuación (B.1).

$$V_{carga} = 369.328 \cdot J_c + 12.5746 \quad (\text{B.1})$$

Posteriormente, se determina el volumen ocupado por la carga, utilizando la ecuación (B.1), para los distintos niveles de llenado experimentales. Lo anterior se muestra en la Tabla B.4.

Tabla B.4 Volumen de la carga del molino para niveles de llenado experimentales (Fuente: Elaboración propia).

Nivel de llenado [p.u]	Volumen ocupado por la carga [m ³]
0.262	109.339
0.337	137.038
0.361	145.902

A continuación, se calcula el volumen de bolas, como el 12% del volumen de la parte cilíndrica del molino (379.83 m³), resultando 45.5796 m³.

En seguida, se calcula la masa de bolas, reemplazando el resultado anterior en la ecuación (B.2), usando una porosidad equivalente de 0.4.

$$M_b = (1 - \varepsilon_b) \cdot \rho_b \cdot V_b \cdot 1000 \quad (\text{B.2})$$

$$M_b = (1 - 0.4) \cdot 7.8 \cdot 45.5796 \cdot 1000 = 213.312 \text{ [kg]}$$

donde,

M_b : Masa de bolas, en kg.

ε_b : Porosidad equivalente de las bolas, 0.4.

ρ_b : Densidad de las bolas de acero, 7.8 [ton/m³].

V_b : Volumen ocupado por las bolas, en m³.

Luego, se calcula el volumen ocupado por mineral para los distintos niveles de llenado experimentales, a partir de la resta del volumen de bolas al volumen ocupado por la carga. Los resultados se muestran en la Tabla B.5.

Tabla B.5 Volumen ocupado por mineral para niveles de llenado experimentales (Fuente: Elaboración propia).

Nivel de llenado [p.u]	Volumen ocupado por la carga [m ³]	Volumen ocupado por bolas [m ³]	Volumen ocupado por mineral [m ³]
0.262	109.339	45.5796	63.759
0.337	137.038	45.5796	91.459
0.361	145.902	45.5796	100.322

Finalmente, se calcula la masa de mineral, usando una porosidad equivalente de 0.4 en la ecuación (B.3). Los resultados se muestran en la Tabla B.6.

$$M_m = (1 - \varepsilon_m) \cdot \rho_m \cdot V_m \cdot 1000 \quad (\text{B.3})$$

donde,

- M_m : Masa de mineral, en kg.
- ε_m : Porosidad equivalente de mineral, 0.4.
- ρ_m : Densidad de mineral, 2.7 [ton/m³].
- V_b : Volumen ocupado por mineral, en m³.

Tabla B.6 Masa de mineral para niveles de llenado experimentales (Fuente: Elaboración propia).

Nivel de llenado [p.u]	Masa de mineral [kg]
0.262	103289
0.337	148163
0.361	162522

Mediante el procedimiento de llenado presentado, se replican tres niveles de llenado experimentales, 26.2, 33.7 y 36.1% presentados en la Figura B.1.

Cada vista permite contar el número de alzadores y espacios que no se encuentran en contacto con la carga del molino. Luego, mediante la ecuación (A.1) y ecuación (A.2), se determinan valores de nivel de llenado comparables con los valores registrados en terreno.




Figura B.1 Niveles de llenado medidos en terreno simulados en DEM (Fuente: Elaboración propia).

(a) Llenado 26.2 %; (b) Llenado 33.7 %; (c) Llenado 36.1 %.

La Tabla B.7 contrasta los niveles de llenado obtenidos mediante el conteo de alzadores en DEM y en terreno.

Tabla B.7 Niveles de llenado según método del conteo de alzadores – DEM y terreno (Fuente: Elaboración propia).

Condición	N° alzadores vacíos	N° espacios vacíos	Nivel de llenado [p.u]
DEM	18.5	18.5	27.6
Terreno	19	18.5	26.2
DEM	17	17.5	35.2
Terreno	17	18	33.7
DEM	17	17	36.8
Terreno	17	17.25	36.1

Anexo C. Metodología para replicar el desgaste de alzadores en Rocky DEM

Para realizar simulaciones en Rocky DEM emulando condiciones en que los alzadores se encuentran desgastados, se debe definir tanto la altura como el ángulo de ataque de éstos.

El procedimiento usado en este trabajo consiste en ejecutar una simulación habilitando la opción de desgaste en Rocky DEM, de modo de poder importar las geometrías desgastadas a un software de diseño asistido por computador y así medir el ángulo de ataque.

El desgaste de los alzadores es llevado a cabo en la simulación por medio del modelo de desgaste de Archad [27]. En la Figura C.1 se muestra la geometría de alzadores sin desgastar (altura 377 mm y ángulo de ataque 30°), mientras que en la Figura C.2 se muestra una geometría desgastada luego de 55 segundos simulados en el software.




Figura C.1 Geometría de alzadores tras 0 segundos transcurridos en simulación (Fuente: Elaboración propia).



Figura C.2 Geometría de alzadores tras 55 segundos transcurridos en simulación (Fuente: Elaboración propia).

La convención usada para medir el ángulo se muestra en la Figura C.3.




Figura C.3 Datos de terreno de condición 5 (Fuente: Elaboración propia).

Una vez que la geometría desgastada alcanza una cierta altura para la cual se desea medir el ángulo de ataque correspondiente, se realiza por medio del software Inventor una superposición de una superficie rectangular sobre la cara de ataque del alizador desgastado, tal como se muestra en la Figura C.4.




Figura C.4 Superposición de superficie rectangular sobre cara de ataque de alizador desgastado (Fuente: Elaboración propia).

De esta manera, es posible definir una nueva geometría de alizador cuyo ángulo de ataque sea representativo del nivel de desgaste. En la Figura C.5 se muestra la medición del ángulo entre la cara superior y la cara de ataque del nuevo alizador. Al restar 90° a este ángulo se obtiene el valor del ángulo de ataque.




Figura C.5 Ángulo entre la cara superior y de ataque de nueva geometría de alizador (Fuente: Elaboración propia).