

Modelamiento del Proceso de Molienda Semiautógena a través de Redes Neuronales

Eugenia González Jiménez, Karina Carvajal Cuello, Gonzalo Acuña Leiva
Departamento de Ingeniería Informática
Facultad de Ingeniería
Universidad de Santiago de Chile
Av. Ecuador N° 3659 – Estación Central
Santiago, Chile
E-mail: gacuna@diinf.usach.cl

Resumen

En el presente trabajo se presenta el modelamiento y posterior simulación del proceso de molienda en los molinos semiautógenos, mediante el uso de redes neuronales dinámicas. Para dicho efecto se hizo uso de datos simulados por un programa realizado con la herramienta *Simulink* de Matlab confeccionado sobre la base de un modelo fenomenológico existente que describe el proceso de fractura de las colpas de mineral en dichos molinos.

Palabras Claves: Redes Neuronales, Modelamiento Dinámico de Sistemas, Redes Dinámicas.

I. Introducción

Las redes neuronales artificiales son una rama de la Inteligencia Artificial, específicamente del área conexionista, pues simulan el funcionamiento de las neuronas biológicas, en particular de la interconexión que existe entre ellas.

Las redes neuronales artificiales son modelos matemáticos que simulan ciertas capacidades del cerebro humano y debido a que ellas pueden "adquirir conocimiento", son aplicables en tareas donde no hay reglas bien definidas como es el caso del análisis financiero, mercadotecnia, procesamiento de señales, automatización y robótica, reconocimiento de patrones o clasificación [10].

En el presente trabajo, las redes neuronales son aplicadas al modelamiento del proceso de molienda semiautógeno, utilizado en los procesos mineros para reducir el tamaño de mineral que sale de la mina. Dicho modelo permitirá observar y controlar algunas variables del proceso.

En la actualidad se encuentra disponible un modelo fenomenológico que describe la dinámica del proceso de molienda semiautógeno basado en un balance de masas que involucra la variable peso (ω) según cada tamaño de las partículas de mineral dentro del molino.

Este modelo sirvió para generar datos que alimentan al modelo neuronal, el que posteriormente será ampliado para su uso en el proceso real.

El presente trabajo se divide en las siguientes secciones: descripción del proceso de molienda semiautógeno, modelamiento del proceso de molienda semiautógeno, modelamiento neuronal del proceso, resultados obtenidos y conclusiones del trabajo.

II. Descripción del proceso de Molienda

El objetivo del Proceso de Concentración en minería es liberar y concentrar las partículas de cobre que se encuentran en forma de sulfuros en las rocas mineralizadas, de manera que pueda continuar a otras etapas del proceso productivo. El proceso de concentración se divide en tres fases: Chancado, Molienda y Flotación [1].

En el chancado el mineral proveniente de la mina presenta una granulometría variada, por lo que se requiere reducir su tamaño hasta obtener un tamaño máximo de $\frac{1}{2}$ pulgada. Para esto se utiliza la combinación de tres equipos en línea, los que se conocen como chancado primario, secundario y terciario.

En la molienda se continúa reduciendo el tamaño de las partículas, para obtener una granulometría máxima de 180 micrones (0,18 mm). El proceso de la molienda se realiza utilizando grandes equipos giratorios o molinos de forma cilíndrica, en dos formas diferentes: molienda convencional o molienda SAG.

La molienda convencional se realiza en dos etapas, utilizando molino de barras y de bolas, respectivamente, y el material que ingresa a estos molinos proviene del chancado terciario. En los molinos de barras el elemento de molienda son barras de acero de 3,5 pulgadas de diámetro y en los molinos de bolas son bolas de acero de 3,5 pulgadas de diámetro.

Los molinos SAG (SemiAutóGenos) son equipos de mayores dimensiones y más eficientes que los anteriores. El mineral se recibe directamente desde el chancado primario con un tamaño cercano a 8 pulgadas. Este material es reducido gracias a la acción del mismo material mineralizado presente en partículas de variados tamaños y por la acción de numerosas bolas de acero, de 5 pulgadas de diámetro.

La selección de una u otra configuración en la mayoría de los casos depende de consideraciones más bien económicas que técnicas, ya que el crecimiento experimentado por los molinos semiautógenos se debe principalmente a los bajos costos totales de estos. El costo de capital de un circuito semiautógeno es aproximadamente un 80% del costo de capital de un circuito convencional en el rango de capacidades de 50.000 t/d. Por otra parte, el costo de operación del circuito semiautógeno es alrededor del 85% del convencional [2].

En el futuro próximo la molienda semiautógena seguirá aumentando en cantidad y variedad de aplicaciones, por lo que la modelación computacional será utilizada intensamente para fines de mejorar el diseño, optimizar y controlar la operación.

III. Molienda Semiautógena

En la molienda autógena actual (AG), rocas de hasta 8 pulgadas o más son alimentadas a un molino cilíndrico, cuyo diámetro es 2 a 3 veces su largo. La palabra autógena indica que la molienda ocurre debido a la propia acción de caída de las colpas minerales desde una altura cercana al diámetro del molino. La molienda semiautógena (SAG) es una variación del proceso de molienda autógena y en ella se adicionan medios de molienda metálicos al molino, cuyo volumétrico de llenado varía de 4 a 14% del volumen del molino(ver figura 1).




Figura 1. Esquema del molino SAG – Vista externa e interna.

En la operación de estos molinos se busca trabajar en condiciones que impliquen el máximo consumo de potencia instalada. Pero esto implica trabajar en un punto de operación inestable ya que un aumento en el nivel de llenado del molino más allá del punto de consumo máximo conduce a una condición de sobrellenado de éste (ver figura 2).




Figura 2. Variación típica del consumo de potencia con el nivel volumétrico de llenado total del molino.

Además, debe tenerse en cuenta que el valor de potencia máxima que puede consumir un molino semiautógeno no es constante y depende principalmente de la densidad de la carga interna, la distribución de tamaños de la alimentación y del estado del revestimiento. El nivel de llenado de la carga interna que corresponde al máximo consumo de potencia está relacionado con el nivel de llenado de medios de molienda y el movimiento de la carga interna. Por ello, los operadores de circuito de molienda semiautógena deben intentar conjugar estos factores para lograr, primero estabilizar la operación y posteriormente buscar su mejoramiento.

Para la operación estable de un molino semiautógeno se requiere tres condiciones: una adecuada proporción de las fracturas gruesas, intermedias y fina en la alimentación fresca, que permita al molino reponer los medios moledores; un flujo de alimentación fresca al molino que permita balancear la tasa de ingreso del mineral grueso con su tasa de molienda hacia tamaños más pequeños; y una tasa de descarga a través de la parrilla del molino que permita evacuar el mineral fino a la misma tasa que ingresa y que se genera por la fractura de los tamaños superiores [3].

Para modelar la molienda SAG y dadas las características físicas de este tipo de equipos, el molino se ha dividido en las siguientes partes.

- Cámara de molienda: Aquí, se identifica y modela la ocurrencia del proceso de molienda y transporte de masa.
- Cámara de descarga: Aquí, se verifica la clasificación por la parrilla interna y la posterior evacuación del material como producto final mediante los alzadores de pulpa.

Las partículas de mineral que alimentan al molino ingresan a la cámara de molienda, cuyo producto enfrenta a la parrilla interna, donde, de acuerdo a una probabilidad de clasificación (c_i), las partículas pueden permanecer en la cámara de molienda o formar parte del flujo de descarga, ya sea que éstas hayan o no atravesado la parrilla de descarga del molino [4].

En la figura 3 se muestra la representación esquemática del molino semiautógeno en donde: (1) representa el molino real, (2) representa la cámara de molienda y (3) representa la parrilla interna, y:

- F y P : son la alimentación y el producto del molino.
- F* y P* : son los flujos de alimentación y producto del molino imaginario interno.
- T : es el flujo de recirculación.

V. Modelamiento del Proceso

A partir del modelo fenomenológico apropiadamente implementado utilizando el software Simulink de Matlab 6.1 se generaron datos que sirvieron para el entrenamiento de la red neuronal. Se añadió ruido gaussiano a las salidas de amplitud igual a un 5% de la amplitud de la señal sin ruido. Como señales de entradas se utilizaron señales binarias pseudoaleatorias que simulan la cantidad de mineral que ingresa al molino. Las salidas corresponden al mineral que es evacuado del molino (ver figura 3) [8].

El criterio utilizado para formar grupos de datos está referido a los tramos lineales que se encuentran en la curva de eficiencia de clasificación resultando cinco grupos correspondientes a distintos tamaños en la alimentación del molino, los cuales son: colpas de mineral muy grande, grandes, medianas, pequeñas y colpas de mineral muy pequeñas. El mineral evacuado del molino corresponde a los tres tamaños inferiores descritos anteriormente.

La arquitectura del modelo neuronal utilizada contempla como variables de entrada a los cinco tamaños diferentes de la alimentación del molino (variables de control). Las variables de estado corresponden al producto de salida del molino. En las variables de estado se consideran sólo 3 tamaños menores, pues se supone que al entrar al molino, y luego del proceso, el mineral más grande se muele y sólo se obtiene el mineral que tiene un diámetro menor a la parrilla de descarga.

De esta forma el modelo más cercano a las salida deseada es el descrito en la figura 4.




Figura 4. Arquitectura de la red,
p: descarga del molino para las distintas granulometrías de salida y
f: alimentación al molino para las distintas granulometrías.

Inicialmente se diseñó una red multicapa con recurrencia externa, a la cual se le fueron modificando los parámetros para obtener mejores resultados. Se trabajó modificando la cantidad de capas ocultas (1 y 2 capas), neuronas por capas (entre 5 y 20 neuronas en la capa oculta), funciones de transferencia, tipo y tamaño de señales de entrada y algoritmos de entrenamiento.

Los resultados de los parámetros que simulaban de mejor manera el proceso son:

Número de capas ocultas	= 1
Neuronas capa oculta	= 10
Función de transferencia	= logarítmica sigmoide en ambas capas
Algoritmo de entrenamiento	= algoritmo de retropropagación quasi-Newton (trainbfg)
Número de épocas	= 1000
Número de entradas	= 8

De 1000 datos aproximadamente generados por el modelo fenomenológico, del tipo señales binarias pseudoaleatorias, se consideraron 500 datos para entrenamiento y el resto para validar el modelo. En la prueba de la red se utilizaron señales sinusoidales, las cuales se ocuparon para comprobar la buena generalización que estaba realizando ésta. A las entradas ocupadas tanto en el entrenamiento y en las pruebas se les incorporó ruido.

VI. Análisis de Resultados

Para evaluar la red neuronal se utilizaron dos tipos de predicciones, uno que genera toda la serie de datos a partir de condiciones iniciales dadas (MPO) y otro que predice la salida sólo en el tiempo siguiente (OSA).

Los resultados son comparados utilizando los índices de error correspondientes al Error Cuadrático Medio (RMS), la Desviación Estándar Residual (RSD) y el Índice de Adecuación (IA), los cuales se indican a continuación [9]:

$$RMS = \sqrt{\frac{\sum_{i=1}^n (o_i - p_i)^2}{\sum_{i=1}^n o_i^2}} \quad RSD = \sqrt{\frac{\sum_{i=1}^n (o_i - p_i)^2}{N}} \quad IA = 1 - \frac{\sum_{i=1}^n (o_i - p_i)^2}{\sum_{i=1}^n (|o_i| + |p_i|)^2}$$

Donde o_i y p_i son los valores predichos y observados, respectivamente, en el tiempo i , y N es el número total de datos. $p_i' = p_i - o_m$ y $o_i' = o_i - o_m$, siendo o_m el valor medio de las observaciones.

Para comprobar el comportamiento del modelo se realizó su validación con el resto de las entradas binarias aleatorias generadas. Como este comportamiento fue bueno se procedió a verificar su generalización con entradas sinusoidales aleatorias. Los resultados obtenidos por el modelo para los tres tipos de tamaño se muestran en las tablas 1 y 2.

Tabla 1. Resumen de los índices de error del modelo neuronal con predicción MPO.

	Entradas sinusoidales pseudoaleatorias		
	Colpas medianas	Colpas pequeñas	Colpas más pequeñas
IA	0.9647	0.9533	0.9297
RMS	0.0831	0.0734	0.0778
RSD	0.0569	0.0744	0.0985

Las figuras 5, 6 y 7 muestran los resultados obtenidos por el modelo con entradas sinusoidales aleatorias para predicción tipo MPO.




Figura 5. Salidas de la red y del modelo fenomenológico, colpas medianas.




Figura 6. Salidas de la red y del modelo fenomenológico, colpas pequeñas.




Figura 7. Salidas de la red y del modelo fenomenológico, colpas muy pequeñas.

Tabla 2. Resumen de los índices de error del modelo neuronal con predicción OSA.

	Entradas sinusoidales pseudoaleatorias		
	Colpas medianas	Colpas pequeñas	Colpas más pequeñas
IA	0.9932	0.9926	0.9922
RMS	0.0370	0.0296	0.0269
RSD	0.0258	0.0306	0.0345

Las figuras 8, 9 y 10 muestran los resultados obtenidos por el modelo con entradas sinusoidales aleatorias para predicción tipo OSA.




Figura 8. Salidas de la red y del modelo fenomenológico, colpas medianas.




Figura 9. Salidas de la red y del modelo fenomenológico, colpas pequeñas.




Figura 10. Salidas de la red y del modelo fenomenológico, colpas muy pequeñas.

Dados los resultados expuestos anteriormente se puede apreciar que el modelo neuronal logra generalizar satisfactoriamente, dado que se entrenó la red con datos binarios y se probó con datos sinusoidales, entregando índices aceptables, para cada uno de los tamaños de colpa. En el caso del índice de adaptación un valor aceptable es mayor al 90%; en el error cuadrático medio un valor aceptable es menor a 0.1 y en el caso la desviación residual es inferior a 0.1.

VII. Conclusiones

Este trabajo ha permitido comprobar la eficiencia de las redes neuronales recurrentes en la tarea de modelar complejos sistemas dinámicos no lineales. En este caso la recurrencia es externa, utilizando cómo algoritmo de entrenamiento el algoritmo de retropropagación.

Si bien es cierto los datos utilizados para la construcción del modelo provienen de la simulación de un modelo fenomenológico, este proyecto servirá de base para probar la red con otras variables de estado propias del proceso real que no se han incorporado hasta ahora, como lo son el nivel de llenado del molino, la presión en los descansos, velocidad de rotación, etc.

El fin último de este proyecto es lograr realizar un modelo utilizando las variables mencionadas anteriormente y con ello poder aportar a la investigación de nuevas tecnologías que permitan a la minería llevar a cabo procesos más eficientes y basados en toma de decisiones oportunas. En este caso aportar en el proceso de molienda SAG para determinar interrogantes como: ¿el porcentaje de medios de molienda es adecuado?, ¿cuánta potencia aplicar al molino? o ¿está bien el nivel de carga del molino?, etc., con el fin de optimizar la operación de este complejo proceso.

Agradecimiento: Proyecto Fondecyt 1010179 y Ecos-Conicyt C99-B04.

Referencias

- [1] <http://www.codelcochile.com/.../procesos.html>. Sitio Web de la empresa CODELCO sobre los procesos de molienda de minerales.
- [2] Magne, L., Valderrama, W., Pontt, J., “Visión conceptual y estado de la tecnología en molienda semiautógena”, Centro Tecnológico en Molienda SAG y Sistemas Eléctricos, 1997.
- [3] Magne, L., Valderrama, W., “Operación y mantención en plantas de molienda semiautógena”, Tesis de Doctorado, Universidad de Santiago de Chile, 1997.
- [4] Magne Luis, “Estudio del transporte de masa en molinos semiautógenos”, Tesis de Doctorado en Ciencias de la Ingeniería con mención en Metalurgia, Universidad de Concepción, 1999.
- [5] Nerrand O., Roussel-Ragot P., Personnaz L., Dreyfuz G., Marcos S., “Neural networks and non-linear adaptative filtering: Unifying concepts and new algorithms”, *Neural Computation*, 1993, vol. 5, n°2, pp. 165-199.
- [6] Billings S.A., Jamaluddin H. B. y Chen S., “Properties of neural network with applications to modeling non-linear dynamical system, *Int. J. Control*, 1992, vol. 55, n° 1, 193-224.
- [7] Acuña G, Latrille E, Béal C, Corrieu G, 1998 “Static and dynamic neural network models for the estimation of biomass concentration in thermophilic lactic acid bacteria fermentations”, *J. Ferment Bioeng.*,85(6):615-622.
- [8] Jamett Marcela, San Juan Enrique, “Identificación de un Sistema Multivariable que modela el proceso de molienda SAG”, Trabajo de Doctorado en ciencias de la ingeniería mención automática, Universidad de Santiago de Chile.
- [9] J. Aguilera, G. Acuña, N. Moraga, “Modelamiento predictivo del congelamiento de cilindros de zanahoria utilizando redes neuronales”, XII Congreso Chileno de Ingeniería Eléctrica, Temuco, Chile, 1997, anales vol II, pp 596-599.
- [10] Díaz Muñoz Jorge Andrés, “Modelo predictivo para la transferencia de materia y calor en un proceso de congelamiento de alimentos utilizando redes neuronales”, Tesis de Ingeniería Civil en Informática, Universidad de Santiago de Chile, 1999.