

ESTIMADOR DE HORIZONTE MÓVIL NEURONAL EN MOLIENDA SEMIAUTÓGENA

Karina Carvajal, Gonzalo Acuña, Luis Magne, Francisco Cubillos

*Universidad de Santiago de Chile, USACH. Facultad de Ingeniería
Avda. Ecuador 3659. Santiago. Chile
{klcarvajal, gacuna} @ diinf.usach.cl*

Resumen: La carencia de sensores para medir en línea y tiempo real variables de estado y parámetros relevantes de un proceso, hacen difícil el desarrollo de métodos de control y optimización automático confiables para procesos no-lineales complejos. En este trabajo se presenta un método de Estimación de Estados de Horizonte Móvil (MHSE) acoplado a una red neuronal como modelo dinámico del sistema complejo. La aplicación del MHSE neuronal sobre un proceso de molienda semiautógena de minerales muestra resultados promisorios (índice adecuación > 0,9) que favorecerían su aplicación en procesos a escala industrial. *Copyright © 2004 IFAC*

Palabras claves: molienda semiautógena, estimador de horizonte móvil, redes neuronales, sistemas dinámicos.

1. INTRODUCCIÓN

En la molienda SemiAutógena (SAG) de minerales las condiciones de operación óptima de los molinos, estrechamente relacionadas con algunas variables de entrada relevantes como velocidad del molino, distribución de tamaños de las partículas de entrada, concentración de la pulpa y consumo de potencia, dependen fuertemente de la correcta determinación en línea de las variables de estado relevantes del proceso. Desafortunadamente, las condiciones que imperan dentro del molino SAG dificultan la obtención de estas medidas en línea y tiempo real, lo que es especialmente crítico para el caso de la variable “nivel de carga interna” o “nivel de llenado”.

Los sensores virtuales (software-sensors) han probado ser una herramienta poderosa en la determinación de variables de estado no medibles (Soroush, 1998). En general para este tipo de sensores es necesario contar con apropiados modelos dinámicos que den cuenta de la evolución de las variables de estado relevantes. En el caso de la molienda semiautógena, ha habido esfuerzos previos por desarrollar un modelo fenomenológico de balance de masas para en el molino (Magne *et al.*, 1995). Este modelo explica el transporte de masa a escala piloto. Aunque los resultados obtenidos son buenos, su complejidad hace difícil llevarlo a escala industrial a fin de abordar problemas de optimización y control.

En este trabajo se propone el desarrollo de un estimador de la variable de estado, “nivel de carga interna”. Este estimador corresponde a un Estimador de Horizonte Móvil, que ha probado ser muy efectivo y simple de operar en procesos industriales (Valdés-González *et al.*, 2003). En esta ocasión el modelo dinámico que sirve para el funcionamiento del estimador es una red neuronal de recurrencia externa, la que permite aproximar la evolución de ciertas variables de estado del proceso dinámico no-lineal de

molienda SAG. Se aprovecha así la capacidad de las redes neuronales de aproximar funciones no lineales complejas con una precisión arbitraria (Hornik et al. 1989).

Este trabajo se divide en las siguientes secciones: una breve descripción del proceso de molienda SAG, el modelo neuronal utilizado, una definición de lo que es un estimador de horizonte móvil, la metodología empleada junto a los resultados obtenidos y las conclusiones finales.

2. DESCRIPCIÓN DEL PROCESO DE MOLIENDA SEMIAUTÓGENA

El objetivo de los Procesos de Concentración en minería es recuperar las partículas de especies valiosas (cobre, oro, plata, etc.), que se encuentran en las rocas mineralizadas. El proceso de concentración se divide en tres fases: Chancado, Molienda y Flotación .

En el proceso de molienda se continúa reduciendo el tamaño de las partículas que provienen del chancado, 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.

En los molinos SAG, la molienda ocurre debido a la propia acción de caída de las colpas de minerales desde una altura cercana al diámetro del molino. La molienda SAG es una variación del proceso de molienda autógena y en ella se adicionan medios de molienda metálicos al molino, cuyo nivel volumétrico de llenado varía de 4 a 14% del volumen del molino. 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 (Magne et al., 1999).

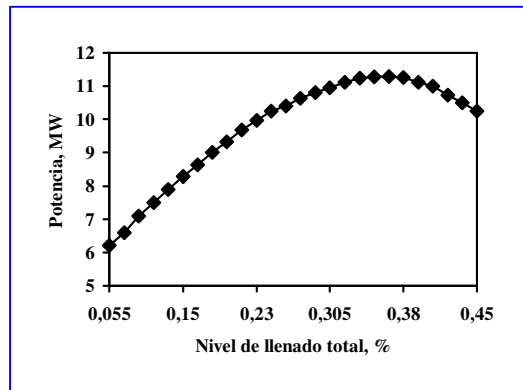


Fig. 1. Variación típica del consumo de potencia con el nivel volumétrico de llenado total del molino. (Magne et al., 1999)

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 (figura 1).

Adicionalmente, debe tenerse en cuenta que el valor de potencia máxima que puede consumir un molino SAG 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 SAG deben intentar conjugar estos factores para lograr, primero estabilizar la operación y posteriormente buscar su mejoramiento (Magne et al., 1999). De ahí la importancia de que ellos cuenten con información confiable y oportuna del nivel de llenado de la carga interna.

3. MODELAMIENTO MEDIANTE REDES NEURONALES

En el proceso de molienda SAG a modelar se consideran dos variables de estado: el nivel de carga interna -que es aquella variable que se desea estimar en línea y tiempo real- y la proporción de granulometría fina de entrada al molino. De esta última variable se dispone de mediciones en línea y tiempo real. Del nivel de carga interna se dispone de datos proporcionados indirectamente a través del torque que produce el movimiento de la carga en el molino. Estos datos, si bien sirven para el

entrenamiento de la red neuronal, no se considerarán disponibles a la hora de realizar las estimaciones.




Fig. 2. Esquema neuronal para la predicción de finos y nivel de llenado (utilizado en el entrenamiento de la red).

La presión en los descansos del eje del molino, estrechamente relacionada con el nivel de carga interna, se considera una variable solamente de entrada al modelo en conjunto con el flujo de alimentación fresca de mineral al molino. De ambas se cuenta con mediciones en línea y tiempo real.

Para realizar el modelamiento de este proceso dinámico se utiliza la forma canónica de una red neuronal recurrente, pues ha sido demostrado que cualquiera de estas redes puede ser transformada en su forma canónica consistente en una red neuronal estática con apropiadas recurrencias externas, factible por lo tanto de ser entrenada usando el conocido algoritmo de retropropagación del error (Nerrand et al., 1993). Al cabo de varios entrenamientos, en los cuales se cambió el número de capas ocultas y la cantidad de neuronas en la capa oculta y algoritmos y parámetros de aprendizaje, se optó por emplear una red con recurrencia externa, constituida por una capa de entrada, una capa oculta y una capa de salida con función de transferencia logarítmica sigmoideal en todas las capas.

Los datos usados en este trabajo provienen de varios días de operación de un molino SAG a nivel industrial. Luego de un preprocesamiento de los datos, se seleccionaron casi 6000 puntos para entrenar y validar el modelo neuronal, de los cuales 3500 se utilizaron para entrenamiento, 1500 como datos de prueba para evitar sobreentrenamiento y los restantes para validar el modelo. Se realizó una veintena de entrenamientos a partir de pesos iniciales aleatoriamente escogidos, de manera de escoger el mejor mínimo local. El algoritmo de optimización usado es el de quasi-Newton BFGS incluido en Matlab. Los datos fueron normalizados entre 0 y 1.

La arquitectura de la red neuronal utilizada, se muestra en la figura 2 .

*Para cada punto a lo largo del horizonte
 Obtener las variables de estado utilizando
 el modelo neuronal de la figura 4
 Avanzar en un paso.

FinPara

*Almacenar los estados estimados.

*Obtener las variables de estado utilizando
 el modelo neuronal de la figura 4 para
 buscar el próximo estado óptimo.

sh=sh+1

FinMientras

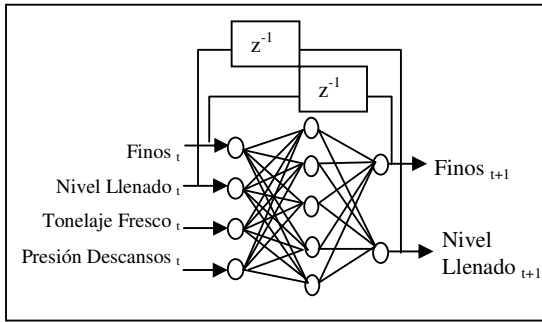


Fig. 4. Esquema neuronal en la predicción de las variables finos y nivel de llenado.

El método de optimización utilizado es el incluido en la función fmincon de Matlab, el cual encuentra el valor mínimo de una función no lineal multivariable, sujeta a restricciones.

La función a minimizar es la raíz cuadrada de la sumatoria de las diferencias entre los valores de finos predichos por la red neuronal y los valores deseados o experimentales. El método arroja los valores iniciales de las variables de estado que minimizan dicha función.

5.2 Análisis de Resultados

Para evaluar el funcionamiento del estimador se utilizaron datos del conjunto de validación, diferentes a los que se utilizaron para diseñarlo. Tal como se indicó anteriormente, se ocuparon 3500 datos de entrenamiento, 1500 datos de prueba y quedaron entonces disponibles alrededor de 900 datos para realizar validación.

Las salidas referentes a la estimación y al valor deseado son comparadas utilizando los índices de error correspondientes al Error Cuadrático Medio (RMS), el Error Residual Estándar (RSD) y el Índice de Adecuación (IA), los cuales se muestran a continuación (González et al., 2002):

$$RMS = \sqrt{\frac{\sum_{i=1}^n (o_i - p_i)^2}{\sum_{i=1}^n o_i^2}} \quad (4)$$

$$RSD = \sqrt{\frac{\sum_{i=1}^n (o_i - p_i)^2}{N}} \quad (5)$$

$$IA = 1 - \frac{\sum_{i=1}^n (o_i - p_i)^2}{\sum_{i=1}^n (|o_i| + |p_i|)^2} \quad (6)$$

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.




Fig. 5. Salidas deseada y reales del estimador con respecto a los finos.

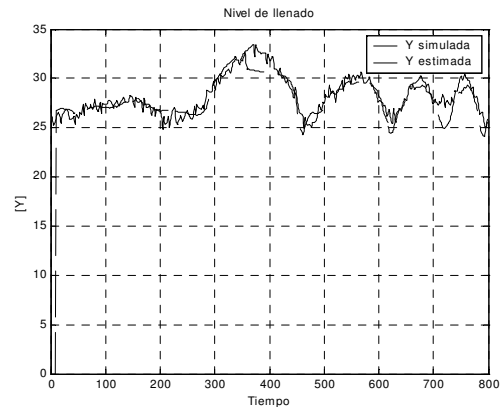


Fig. 6. Salidas deseada y real del estimador con respecto al nivel de llenado.

$o_i' = o_i - o_m$, siendo o_m el valor medio de las observaciones.

Las figuras 5 y 6 muestran los resultados obtenidos por el estimador y las salidas deseadas para las variables de finos y nivel de llenado, respectivamente, para los datos incluidos en el

conjunto de validación, es decir, no usados para el entrenamiento y prueba del modelo neuronal.

La tabla 1 muestra el resultado de los índices obtenidos por medio de las pruebas del método de estimación de horizonte móvil neuronal.

Tabla 1. Resumen de los índices de error del modelo

	Finos	Nivel de llenado
IA	0.9778	0.9398
RMS	0.1558	0.1221
RSD	0.0719	0.0738

De los resultados expuestos anteriormente se puede apreciar que el estimador logra predecir en un 98% la variable finos y en un 94% la variable nivel de llenado, que es la variable de estado que se desea estimar en línea y tiempo real.

6. CONCLUSIONES

A través de este trabajo se ha mostrado un Estimador de Estados de Horizonte Móvil Neuronal, aplicado a un proceso de molienda semiautógena, el que a través de una optimización local busca valores óptimos de las variables finos y nivel de llenado para propagarlos a través de una red neuronal durante un horizonte de tiempo determinado.

En el modelamiento del proceso se utilizó una red estática con recurrencias externas, lo que permite modelar un sistema dinámico. El algoritmo de entrenamiento utilizado es el clásico de retropropagación del gradiente con el método de minimización de segundo orden quasi-Newton y función de transferencia logarítmica sigmoide, requiriéndose de los datos en un tiempo anterior t para predecir la salida en un tiempo $t+1$. El modelo neuronal dinámico obtenido permite la evolución del sistema sólo a partir de condiciones iniciales.

Los resultados entregados por el estimador, son muy satisfactorios dados el índice de adecuación (ia) mayor a 0.9 y el error cuadrático menor a 0.1 obtenidos, lo que indica una predicción muy cercana al valor real.

Debe destacarse que en este trabajo se demuestra la posibilidad de complementar el método de Horizonte Móvil, de creciente utilización en procesos industriales, con las redes neuronales, establecidas como modelos dinámicos, lo que permite potenciar las ventajas de ambas metodologías en una aplicación de suma importancia económica en nuestro país.

Asimismo, una vez consolidada la fusión de redes neuronales con un estimador de horizonte móvil, el estudio de dicho estimador con un modelo de caja gris puede ofrecer interesantes perspectivas.

Agradecimientos. Proyectos FONDEF D02I1077 y FONDECYT 1010179, Chile.

REFERENCIAS

- Allgöwer F., Badgwell, T., Qin, J., Rawlings, J., Wright S., (1999). Nonlinear predictive control and moving horizon estimation – an introductory overview, in *Advances in Control Highlights of ECC'99*, Paul M. Frank (Ed.), Springer-Verlag, Chapter 12, pp. 391-449.
- Cherruault, Y., (1999). Optimisation: méthodes locales et globales, Presses Universitaires de France (PUF), Collections mathématiques, France.
- González E., Carvajal K, Acuña G, (2002), Modelamiento del Proceso de Molienda Semiautógena a Través de Redes Neuronales, Actas en CD del *Encuentro Chileno de Computación*, Copiapó, Chile, Noviembre 2002.
- Hornik, K., Stinchcombe, M. Y White, H., (1989), Multilayer feedforward networks are universal approximators, *Neural Networks*, **2**:359-366
- Magne L., Améstica R., Barría J. y Menacho J., (1995). Dynamic modelling of semiautogenous milling based on a simplified phenomenological model, *Rev. Metal. Madrid*, **31**(2):97-105 (in Spanish).
- Magne, Luis, Waldo Valderrama, Jorge Pontt, (1999). Visión Conceptual y Estado de la Tecnología en Molienda Semiautógena, *Workshop SAG'99*. Viña del Mar, Chile.
- Nerrand O., Roussel-Ragot P., Personnaz L., Dreyfuz G., Marcos S., (1993), Neural Networks and Non-linear Adaptive Filtering: Unifying Concepts and New Algorithms, *Neural Computation*, **5**(2):165-199.
- Soroush, M. (1998), State and parameter estimations and their applications in process control, *Comput. Chem. Engng.*, **23**:229-245.
- Valdés-González, H., J-M. Flaus, G. Acuña, (2003), Moving horizon state estimation with global convergence using interval techniques: application to biotechnological processes, *Journal of Process Control*, **13**(4):325-336.