

Estimador de Tamaño de Colpas en Molienda Semiautógena Utilizando Horizonte Móvil Neuronal

Karina Carvajal, Gonzalo Acuña, Francisco Cubillos, Luis Magne
Universidad de Santiago de Chile, Facultad de Ingeniería, Santiago, Chile
{klcarvajal;gacuna}@diinf.usach.cl

Abstract

The development of a moving horizon estimator coupled with an external neural network acting as a dynamic model of a semiautogenous grinding process is presented. A phenomenological model describing the evolution of size particles was simulated using Matlab Simulink in order to have enough data for training the neural network and validate the estimator performance. A gaussian noise was added to the variables in order to better simulate real conditions. Good results for the estimation of the relevant variables are shown (adequation index over 0,9).

Keywords: Dynamic Neural Networks, Moving Horizon State Estimator, Local Optimisation , Semiautogenous Grinding

Resumen

En el presente trabajo se presenta el desarrollo de un estimador de horizonte móvil acoplado a una red neuronal de recurrencia externa que hace las veces de modelo dinámico de un proceso de molienda semiautógena. Para el entrenamiento de la red neuronal y posterior utilización del estimador 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. Las variables fueron contaminadas con ruido aditivo gaussiano para simular mejor el comportamiento real del proceso. Los resultados de la estimación de las variables relevantes (tamaño de colpas) son satisfactorios con índices de adecuación superiores a 0,9.

Palabras claves: Redes Neuronales Dinámicas, Estimación de Horizonte Móvil, Optimización Local, Molienda Semiautógena

1 Introducción

Los sensores virtuales (software-sensors) han probado ser una herramienta poderosa en la determinación de variables de estado no medibles [10]. En general para este tipo de sensores es necesario contar con modelos dinámicos apropiados, que den cuenta de la evolución de las variables de estado relevantes. Muchas de las técnicas utilizadas en la implementación de sensores requieren modelos descriptivos bastante precisos del proceso, los que, para el caso industrial, son difíciles de obtener. Adicionalmente ellas son exigentes en tiempo de desarrollo, delicadas en cuanto a su calibración y puesta a punto y no consideran, en muchas ocasiones, modelos realistas de las perturbaciones, propias de un medio industrial. Una buena alternativa para desarrollar modelos a partir de la información de entrada-salida del proceso son las redes neuronales, entendidas como aproximadores universales de funciones no-lineales [6].

El estimador de estado de horizonte móvil (MHSE-del inglés Moving Horizon State Estimation) es un enfoque en donde se transforma un problema de estimación dinámica en otro de optimización no-lineal sobre un horizonte temporal y se presenta como una alternativa para desarrollar técnicas de estimación que cumpla con las condiciones en los procesos a escala industrial. Un aspecto central en este método lo constituye la minimización de una función objetivo o criterio consistente en la suma de los errores de predicción de la salida sobre un cierto horizonte de tiempo. Es decir, MHSE busca el vector de estado, al inicio del horizonte, que minimiza el criterio escogido.

En molienda semiautógena (SAG), ha habido esfuerzos previos por desarrollar un modelo fenomenológico de balance de masas [8]. Este modelo explica el transporte de masa a escala piloto dentro de un molino semiautógeno. Aunque los resultados obtenidos son buenos, su complejidad hace difícil llevarlo a escala industrial a fin de abordar problemas de optimización y control. Por lo que se propone el desarrollo de un estimador correspondiente a un Estimador de Horizonte Móvil, que ha probado ser muy efectivo y simple de operar en procesos industriales [11]. 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 [4]. A partir del modelo fenomenológico apropiadamente implementado utilizando el software Simulink de Matlab se generaron datos que sirvieron para el entrenamiento de la red neuronal.

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 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 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 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, como se muestra en la figura 1.

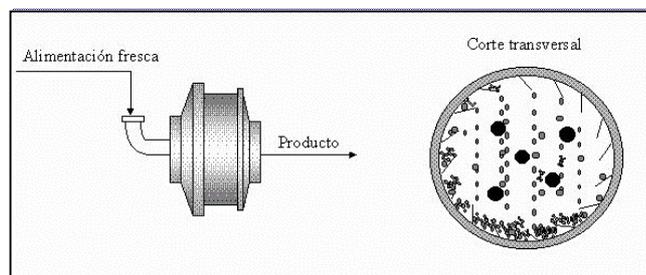


Figura 1. Esquema del molino SAG – Vista externa e interna.

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).

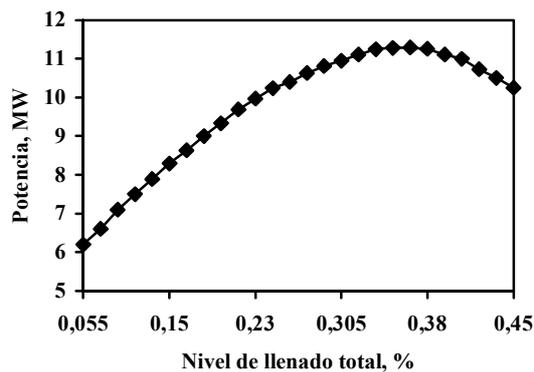


Figura 2. Variación típica del consumo de potencia con el nivel volumétrico de llenado total del molino.

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 [9].

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

- a. Cámara de molienda: Aquí, se identifica y modela la ocurrencia del proceso de molienda y transporte de masa.
- b. 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 alimentadas al molino ingresan a la cámara de molienda, cuyo producto enfrenta a la parrilla interna, donde, de acuerdo a una probabilidad de clasificación, 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 [7].

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.
- (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.

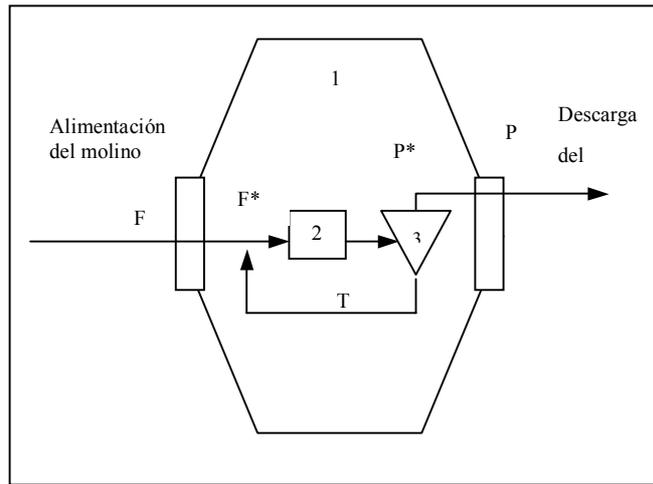


Figura 3. Representación esquemática de modelo de molienda semiautógena.

En base a este enfoque se describe el modelo fenomenológico para el molino semiautógeno, el cual plantea una ecuación diferencial respecto de la variable peso (ω), obteniéndose un modelo para la dinámica de cada uno de los tamaños de partículas determinadas dentro del molino [8], el cual se muestra en la ecuación (1).

$$\frac{d\omega_i}{dt} = -\left(\frac{P^*}{W}\right)\left(1 - c_i\right)\omega_i - K_i^* \omega_i - (K_{i-1} - K_i)^* \sum_{k=1}^{i-1} \omega_k + f_i \quad (1)$$

Donde : ω_i : Carga interna en ton.

f_i : Flujo de alimentación en ton/h.

K_i : Velocidad efectiva de molienda.

c_i : Factor de eficiencia de clasificación.

W : Peso total del mineral en la carga interna.

El modelo anterior describe una ecuación parcial que se encuentra completamente definida con los datos de entrada y de realimentación de los pesos internos del mineral dentro del molino.

3 Modelamiento mediante Redes Neuronales

A partir del modelo fenomenológico de ‘balance de masas’, apropiadamente implementado utilizando el software Simulink de Matlab, 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) [5].

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, es decir, colpas medianas, pequeñas y muy pequeñas.

La arquitectura del modelo neuronal mostrada en la figura 4 contempla como variables de entrada a los cinco tamaños diferentes de la alimentación del molino (variables de control) y como variables de estado a los tres 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.

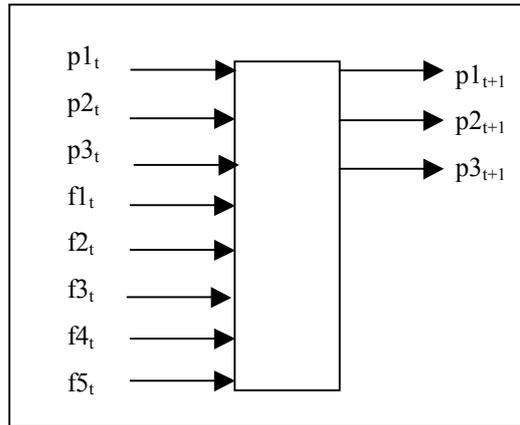


Figura 4. Arquitectura de la red.

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.

4 Estimador de Horizonte Móvil

En general los estimadores clásicos suponen un modelo preciso del sistema, supuesto que, al no poder ser satisfecho en la mayor parte de las aplicaciones reales, se traduce en un error de la estimación que suele incrementarse con el tiempo. Adicionalmente y debido a la dificultad de incorporar en los métodos anteriores algunas restricciones típicas de ambientes industriales, como muestreo poco frecuente, respeto a leyes de conservación e inigualdades y necesidad de recalibrar cada cierto tiempo la estimación a partir de mediciones adecuadas, es que surgió una técnica de estimación adaptada de conceptos provenientes de métodos de control predictivo. Es el llamado Estimador de Horizonte Móvil, MHSE [1].

En síntesis, MHSE transforma un problema de estimación dinámica de estados en un problema de optimización estática, en el cual se busca el valor de un vector inicial al inicio de un horizonte de manera de minimizar la diferencia entre la salida real del sistema y la evolución de él dada por el modelo y sus condiciones iniciales. Este principio es ilustrado en la figura siguiente (Figura 5).

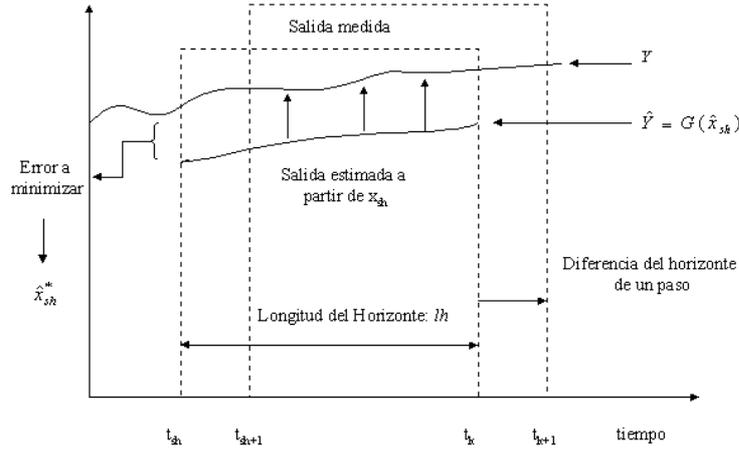


Figura 5. Representación esquemática del principio de estimación utilizado por MHSE.

Un aspecto central en este método lo constituye la minimización de una función objetivo o criterio consistente en la suma de los errores de predicción de la salida sobre un cierto horizonte de tiempo. Es decir, MHSE busca el vector de estado, al inicio del horizonte, que minimiza el criterio escogido.

Formalmente, si se tiene el modelo no lineal de un sistema dado por:

$$\dot{x}(t) = f(x(t), u(t)) \quad (2)$$

$$y(t) = g(x(t)) \quad (3)$$

MHSE busca determinar el vector, al inicio del horizonte, que minimice un criterio, por ejemplo del tipo:

$$J = \frac{1}{2} \sum_{i=t_{sh}}^{t_k} [Y_i - \hat{Y}_i]^2 \quad (4)$$

Siendo $Y = [y_{sh}, \dots, y_k]^T$ la salida sobre el horizonte considerado, e $\hat{Y} = [\hat{y}_{sh}, \dots, \hat{y}_k]^T$ las estimaciones de la salida sobre dicho horizonte.

El algoritmo MHSE puede resumirse en las siguientes sentencias:

1. Inicialización del vector de estados : \hat{x}_{sh}
2. Búsqueda del vector de estados inicial óptimo: \hat{x}_{sh}^* (mediante algún método de optimización)
3. Cálculo de la solución al final del horizonte (instante actual t_k): \hat{x}_k
4. Retorno a la etapa 2 para efectuar el cálculo de \hat{x}_{k+1} , desplazando el horizonte en un paso.

En el caso de sistemas complejos no-lineales el problema de la optimización para determinar el vector de estados óptimo al inicio del horizonte no puede ser resuelto de manera analítica y es por esta razón que se debe utilizar técnicas numéricas. Estas pueden agruparse, *grosso modo* en técnicas clásicas o heurísticas, dentro de las que se puede destacar aquellas local o globalmente convergentes [2]. En este trabajo se utilizó una técnica local de optimización.

5 Estimador de Horizonte Móvil Neuronal

Para desarrollar un estimador de horizonte móvil neuronal, en vez de utilizar el modelo fenomenológico del proceso, se utilizó la red neuronal previamente entrenada como modelo dinámico del proceso (figura 4) en la cual se realimenta el valor de las variables de estado (figura 6). Esta red permite entonces estimar el valor de

dichas variables de estado al final del horizonte, a partir del valor óptimo inicial de ellas, otorgado por el método de horizonte móvil.

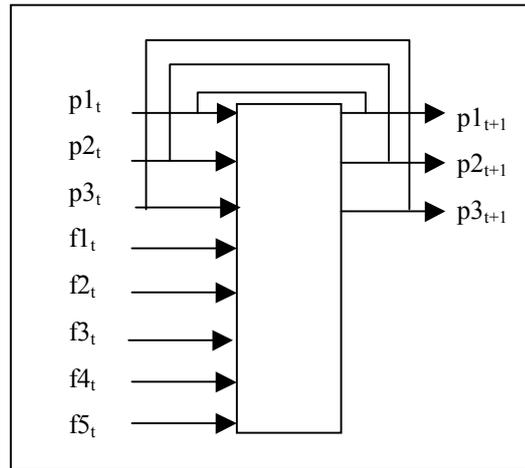


Figura 6. Esquema neuronal en la predicción de las variables finas y nivel de llenado.

A continuación se muestra la metodología utilizada en el desarrollo del estimador y los resultados obtenidos.

5.1 Descripción de la Metodología

El algoritmo de horizonte móvil utilizado es el siguiente:

1.- Inicializar: $MaxT, sh, lh$

2.- Mientras $(sh+lh) \leq MaxT$

* Buscar el vector de estado inicial óptimo utilizando optimización local.

* Para cada punto a lo largo del horizonte

Obtener las variables de estado utilizando el modelo neuronal de la figura 6

Avanzar en un paso.

FinPara

* Almacenar los estados estimados.

* Obtener las variables de estado utilizando el modelo neuronal de la figura 6 para buscar el próximo estado óptimo.

$sh=sh+1$

FinMientras

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 colpas medianas y pequeñas 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 Resultados Obtenidos

Para evaluar el funcionamiento del estimador se utilizaron datos del conjunto de validación, correspondientes a aproximadamente 400 datos de señales sinusoidales. 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) [3].

Las figuras 7, 8 y 9 muestran los resultados obtenidos por el estimador y las salidas deseadas para las variables de salida colpas medianas, pequeñas y muy pequeñas, respectivamente. El horizonte utilizado por el estimador es de 30 unidades de tiempo.

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

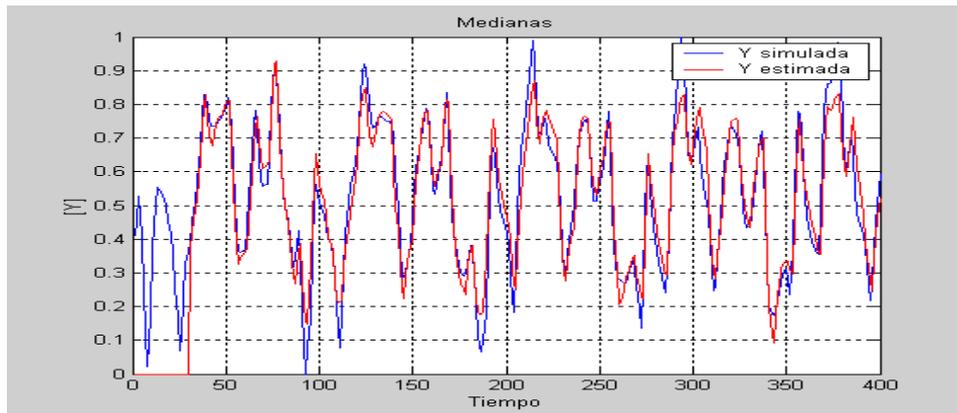


Figura 7. Salidas deseada y reales del estimador con respecto a las colpas medianas.

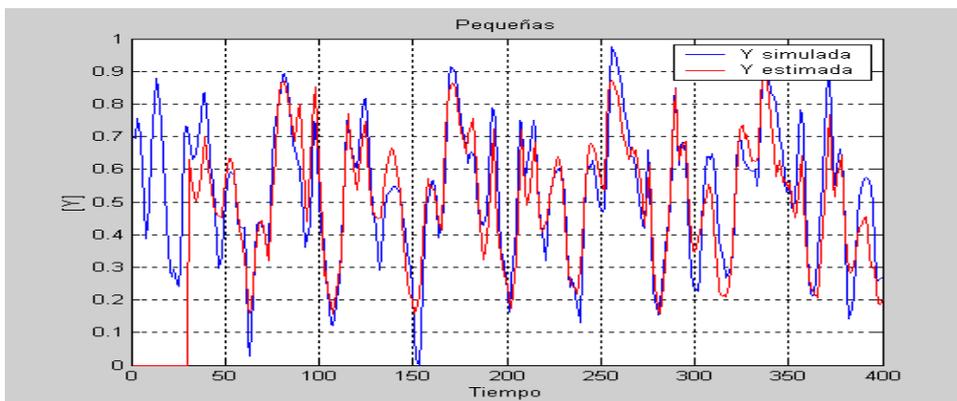


Figura 8. Salidas deseada y reales del estimador con respecto a las colpas pequeñas.

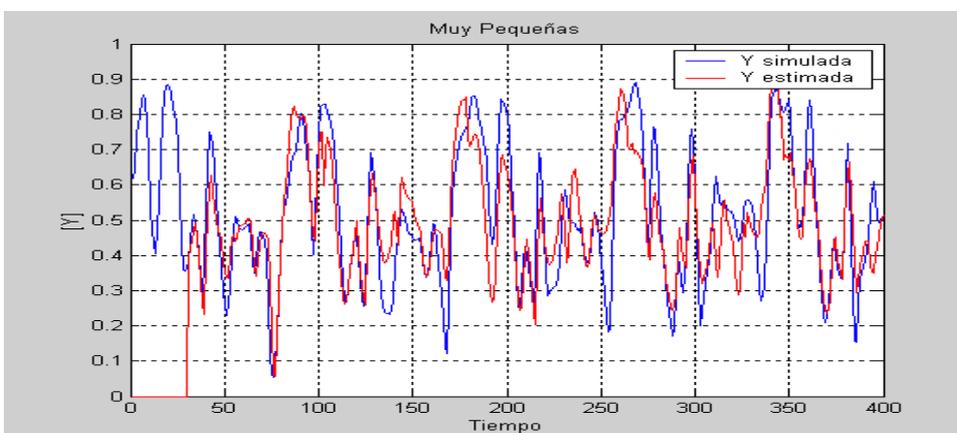


Figura 9. Salidas deseada y reales del estimador con respecto a las colpas muy pequeñas.

Tabla 1. Resumen de los índices de error del modelo

	Colpas medianas	Colpas pequeñas	Colpas Muy Pequeñas
IA	0.9766	0.9440	0.9018
RMS	0.1052	0.1584	0.1969
RSD	0.0612	0.0899	0.1057

De los resultados expuestos anteriormente se puede apreciar que el estimador logra predecir en un 98% las colpas medianas, en un 94% las colpas pequeñas y en un 90% las colpas muy pequeñas, que es la variable de estado que se desea estimar en línea y tiempo real. Resultados que muestran una buena estimación y que mejoran a medida que se aumenta el horizonte.

6 Conclusiones

En este trabajo se presenta 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 colpas medianas, pequeñas y muy pequeñas 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.

Agradecimientos

Se agradece financiamiento parcial de proyectos FONDEF D0211077 y FONDECYT 1040208, Chile

Referencias

- [1] Allgöwer F., Badgwell, T., Qin, J., Rawlings, J, Wright S. 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, 1999.
- [2] Cherruault, Y. *Optimisation: méthodes locales et globales*, Presses Universitaires de France (PUF), Collections mathématiques, France, 1999.
- [3] 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.
- [4] Hornik, K., Stinchcombe, M. Y White, H., (1989), Multilayer feedforward networks are universal approximators, *Neural Networks*, 2:359-366
- [5] Jamet 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.
- [6] Lennox, B., Montague, G., Frith, A., Gent, C., Bevan, V. Industrial application of neural networks – an investigation, *Journal of Process Control* 11, pp. 497-507, 2001.

- [7] 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.
- [8] 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).
- [9] Magne, L., Valderrama, W., “Operación y mantención en plantas de molienda semiautógena”, Tesis de Doctorado, Universidad de Santiago de Chile, 1997.
- [10] Soroush, M. (1998), State and parameter estimations and their applications in process control, *Comput. Chem. Engng.*, **23**:229-245.
- [11] Valdés-González, H., Flaus, J, Acuña G., Moving horizon state estimation with global convergence using interval techniques: application to biotechnological processes, *Journal of Process Control*, 13(4), pp. 325-336, 2003