

## MODELIZACIÓN DE LÍNEAS DE PRODUCCIÓN INDUSTRIAL Y DETECCIÓN DE PATRONES DE RESPUESTA MEDIANTE REDES NEURONALES ARTIFICIALES

**Javier Fornari<sup>a</sup>, Sebastián Grieco<sup>a</sup>, Eduardo Luccini<sup>a,b</sup>, Miguel Parodi<sup>a,b</sup> y Esteban Vidali<sup>a</sup>**

<sup>a</sup> *Facultad de Química e Ingeniería “Fray Roger Bacon”, Pontificia Universidad Católica Argentina.  
Av. Pellegrini 3314, CP 2000, Rosario, Argentina, javier.fornari@uca.edu.ar,  
sebastian\_grieco@uca.edu.ar, vidaliesteban@hotmail.com,  
<http://www.uca.edu.ar/uca/index.php/home/index/es/universidad/facultades/rosario/quimica-ingenieria>*

<sup>b</sup> *Grupo de Energía Solar, Instituto de Física de Rosario (CONICET-UNRosario). Bv. 27 de Febrero  
210bis, CP 2000, Rosario, Argentina, luccini@ifir-conicet.gov.ar, parodi@ifir-conicet.gov.ar,  
<http://new.ifir-conicet.gov.ar/grupos>*

**Palabras Clave:** Procesos Industriales, optimización, Redes Neuronales Artificiales.

**Resumen.** Las estrategias utilizadas en los diferentes procesos de producción requieren de una concepción integrada para la coordinación de las tareas operativas en una planta industrial. La integración de estas funciones en una arquitectura de un sistema inteligente representaría una mejora en el rendimiento de la planta, en la seguridad y en el incremento de su producción. Sin embargo, lograr un sistema integrado adecuado y dinámico para realizar las tareas operacionales es complejo, ya que las mayores limitaciones se basan en el hecho de la obtención de las variables y datos de producción tales como el tiempo de operación, la secuencia de operaciones, el tamaño del lote de las partes, etc. En este trabajo se trata de modelar el comportamiento de líneas de producción a través de la identificación de las variables principales y el uso de un sistema de redes neuronales artificiales para la detección de patrones de respuesta. El sistema se entrena para detectar y reconocer familias de procesos basados en sus similitudes dentro de los atributos de diseño y fabricación utilizados en un conjunto de empresas metalúrgicas de la región centro y sur de Santa Fe.

## 1 INTRODUCCIÓN

La modelización de un sistema de producción con fines de mejorar el proceso se enmarca dentro de la Teoría de Optimización (e.g. [Forst y Hoffmann, 2010](#)). Es una disciplina que ha ganado enorme desarrollo en las últimas décadas, aplicada a la planificación y el estudio del desenvolvimiento de líneas de producción industrial (e.g. [Rao, 2009](#)). A ello han contribuido los progresos informáticos, que brindan herramientas de análisis cada vez más sofisticadas, y la globalización económica, que requiere procedimientos estándar de producción independientemente del lugar donde la industria se radique. En el área productiva, un pequeño incremento en la exactitud de la predicción del proceso implica un significativo impacto en el resultado económico-productivo de la empresa.

Entre otros aspectos, la optimización implica el estudio de eventos críticos, o interrupciones en el sistema de producción por diversas causas, y sus consecuencias. Para ello se han desarrollado diversos modelos que simulan las etapas de la línea de producción y los efectos de un evento crítico ([Fornari et al., 2010](#)).

Más generalmente, la simulación numérica permite integrar las distintas etapas de un sistema de producción a fin de optimizar su funcionamiento. Para lograrlo, se deben determinar las variables que rigen el comportamiento del sistema y las leyes que las gobiernan. Los algoritmos y las técnicas de análisis disponibles son muy variados, y su elección depende fuertemente de las características del problema a resolver (e.g. [Rao, 2009](#)).

En el caso de la industria metalúrgica, algunas de las variables incluyen el tiempo de operación, la secuencia de operaciones, el tamaño del lote de las partes, la tipología del equipamiento utilizado, el nivel de demora de las partes, el scrap o material residual del proceso productivo, entre otras.

Uno de los algoritmos de análisis que ha cobrado más desarrollo y número de aplicaciones en las últimas décadas es el de redes neuronales artificiales (RNA). Una RNA es una arquitectura de procesamiento en paralelo distribuido, integrada por unidades de procesamiento masivamente interconectadas, también denominadas neuronas o nodos. La RNA se compone de neuronas organizadas en capas. Usualmente existen tres capas: de entrada, oculta y de salida. El número de neuronas se determina según el problema a resolver.

Los modelos más populares de RNA pueden clasificarse basándose en el paradigma de aprendizaje, su topología de conexión básica y sus funciones de procesamiento y capacidades. Entre los paradigmas de aprendizaje podemos destacar al aprendizaje supervisado, en este enfoque se le presenta un problema a la RNA y realiza una predicción o clasificación y el algoritmo de aprendizaje realiza la diferencia entre la salida deseada y la predicción actual, y utiliza dicha información para ajustar los pesos de la RNA. El otro modelo utilizado es el de aprendizaje no supervisado, que es el caso en el cual disponemos de mucha información de entrada, pero no conocemos la salida o respuesta, y generalmente la pregunta a resolver está referida a la interrelación o correlación existente de los datos de entrada. En efecto, lo que realiza la RNA en este caso es una agrupación en diferentes conjuntos de los diferentes patrones o información de la que disponemos. En el caso de las topologías de conexión, tenemos las redes de alimentación hacia adelante, donde la información fluye a través de la red en una sola dirección, y la respuesta se basa en el conjunto actual de entradas; redes recurrentes limitadas, en este caso la información acerca de entradas pasadas es retroalimentada y mezclada con las entradas recurrentes de la retroalimentación y las redes totalmente recurrentes, que proveen conexiones de dos vías entre todos los procesadores en la RNA. La información de la entrada circula hacia adelante y hacia atrás hasta que la activación de las unidades o procesadores se estabiliza. Entre los diferentes estándares de RNA podemos destacar a los modelos de backpropagation, mapa de características autoorganizativas (SOM)

y el modelo de resonancia adaptiva. Las RNA han demostrado su potencial en control, optimización y detección de errores en procesos industriales (Zarenezhad y Aminian, 2011; Govindhasamy et al., 2005; Alves and Nascimento, 2007).

En el presente trabajo se establecen las bases para el análisis de una serie de datos de producción obtenidos de industrias metalúrgicas de la provincia de Santa Fe, Argentina, con el propósito de optimizar los procesos productivos aplicando la técnica de RNA.

## 2 CARACTERIZACIÓN DE LOS PROCESOS INDUSTRIALES

Un proceso industrial es una secuencia, u orden definido de actividades químicas, físicas o biológicas que se llevan a cabo para la conversión, transporte o almacenamiento de material o energía. La automatización es una forma de ordenación a partir de la secuenciación automática de tareas y regulación de variables para que sigan las consignas impuestas. El objetivo de la supervisión es asegurar este orden aun cuando haya desviaciones no previstas en la automatización. En este caso, la automatización de procesos industriales debe proveer una infraestructura que permita cubrir todas las fases y aspectos del proceso productivo. No solamente está relacionada con el proceso mismo, sino también con la distribución de los productos fabricados o con la prestación de servicios.

Para el modelado de procesos industriales se realizan representaciones conceptuales de la automatización y se definen los requerimientos comunes para todas las implementaciones independientemente de los requisitos específicos del proceso particular (Pérez Rivas, 2006).

Cuando las personas interactúan entre sí o con el ambiente circundante se hace uso de información situacional implícita, que produce valor agregado y es especialmente importante en un ambiente móvil, donde la interacción, ejecución y uso necesita ser rápidamente adaptado. A este tipo de aplicaciones se las denomina sensibles al contexto y se puede extender el concepto a los procesos industriales automatizados.

En el proceso productivo es importante disponer de información actualizada del estado del mismo para la toma de decisiones del personal afectado a éste, desde el nivel gerencial hasta el personal de planta. Además es importante la obtención de dicha información en forma automática o a pedido en relación con el lugar físico de la fábrica o planta industrial en donde se encuentra la persona que la solicita o con relación a la etapa en que se encuentra el proceso. Tratar con información de contexto es difícil, ya que debe ser adquirida a través de dispositivos no tradicionales, en general sensores, de distintas fuentes e interpretada para ser usada por las aplicaciones.

El modelo de automatización CIM (Computer Integrated Manufacturing) (García Moreno, 1999) responde a una estructura piramidal jerarquizada compuesta por cinco niveles:

- El primer nivel o nivel 0 comprende el conjunto de dispositivos, subprocesos, maquinaria con que se realizan las operaciones elementales de producción. Además se sitúan los sensores, actuadores, transductores, y otros elementos.
- En el siguiente nivel o nivel 1 están los dispositivos lógicos de control.
- En el nivel 2 conviven los niveles de supervisión y control, que realizan las tareas de adquisición y tratamiento de datos, monitorización, gestión de alarmas, mantenimiento correctivo y preventivo, control de calidad, programación a corto plazo, control de producción en curso, sincronización de células de trabajo, coordinación de transporte, seguimiento de lotes y seguimiento de órdenes de trabajo.
- En el nivel 3 se realizan las tareas de programación de la producción, gestión de materiales, gestión de compras, análisis de costos de fabricación, control de inventarios, gestión de recursos de fabricación, gestión de calidad y gestión de mantenimiento.
- En el último nivel o nivel 4, las tareas que se realizan están relacionadas con la gestión

comercial y de marketing, la planificación estratégica, planificación financiera y administrativa, gestión de recursos humanos, ingeniería de producto y de proceso, gestión de tecnología, gestión de sistemas de información, investigación y desarrollo.

Este enfoque integrador de la producción requiere de las comunicaciones, al crearse una enorme demanda de información que afecta a todas las unidades funcionales de la empresa. Según estableció [Simon \(1977\)](#), los modelos jerárquicos disuelven el vínculo entre el tamaño y la complejidad, en virtud de la jerarquía. La complejidad de una organización, tal como se evalúa desde cualquier posición dentro de ella es casi independiente de su tamaño total y reduce la necesidad de transmisión de información entre los diferentes elementos que conforman la organización. Un nivel sólo necesita información detallada sobre las actividades correspondientes a su nivel e información sumaria adicional sobre el comportamiento medio en otras unidades. Es suficiente saber cuáles son las salidas que el subsistema debe proporcionar a otras entidades, sin importar a qué procesos serán sometidas por este último.

### 3 DATOS DE PROCESOS INDUSTRIALES

La Cámara de Industriales Metalúrgicos de Rafaela es una entidad que, entre sus funciones, brinda a sus asociados soporte de servicios en tecnologías de alto valor agregado a través de la asistencia y soporte técnico con incorporación de técnicas innovadoras. La mayoría de las empresas asociadas han implementado un sistema de gestión integrado orientado a los procesos de producción. Si bien es conocido que este tipo de sistemas brinda información adecuada y permite la detección de cuellos de botella en los diferentes procesos productivos, el resultado no indica cómo resolver las problemáticas que se presentan a fin de optimizar los recursos empresariales. Y más aún cuando el empresario debe tomar decisiones importantes y de alto riesgo, enfrentándose a situaciones cada vez más complejas y que cambian a velocidad vertiginosa, exigiendo reacciones que combinan conocimiento, racionalidad, manejo del riesgo y mucha intuición. Por ello, surge la necesidad de utilizar herramientas que permitan analizar diferentes escenarios y situaciones. Entre ellas, la simulación permite estudiar el comportamiento y las relaciones de un determinado proceso productivo planteando diversas alternativas y evaluando posibles soluciones. El uso combinado de la simulación junto con modelos analíticos, conocidos como metamodelos, genera funciones matemáticas características de cada uno de los eventos críticos que ocurren en cualquier proceso productivo. Su uso implica grandes beneficios para la gestión operativa del proceso, como la predicción del impacto del evento crítico sobre la productividad, el diseño de esquemas operativos y planificación de capacidad que proporcionen flexibilidad y robustez al proceso desde la perspectiva performance/productividad, y la evaluación de acciones correctivas en línea. Es decir, permite flexibilizar y agilizar el desarrollo de protocolos de producción y optimización del rendimiento del proceso productivo.

En este contexto, se relevaron los datos de 38 empresas y se definió un modelo de clasificación convencional de los equipos, utilizado en tecnología mecánica de las máquinas y herramientas, que se representa en la [figura 1](#).

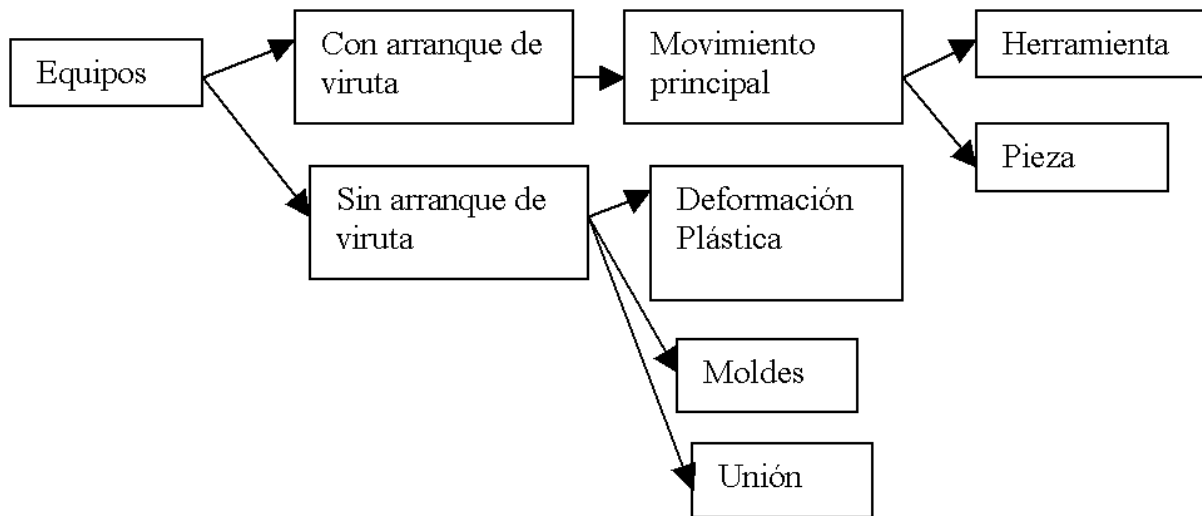


Figura 1. Esquema básico empleado de clasificación de equipos industriales.

También se realizó un proceso de clasificación del equipamiento industrial en función del principio de funcionamiento, donde se pueden mencionar:

- inyección de material,
- deformación plástica del material,
- utilización de moldes en lo que refiere a fundición, unión o ensamblado de distintas piezas que conforman un conjunto,
- por procesos químicos,
- por esfuerzo de corte de una herramienta sobre la pieza o materia prima,
- por utilización de temperatura para el mecanizado,
- erosión con partículas o micropartículas de la materia prima.

Realizada esta clasificación se procedió a caracterizar los tipos de materiales, en este caso, los metales y las características de diseño, entre las que podemos mencionar:

- la tolerancia,
- la geometría,
- la superficie y
- los esfuerzos.

Obtenidas estas clases, se procedió a clasificar los procesos industriales y agruparlos en función de las actividades de:

- fundición,
- formado en frío y caliente,
- metalurgia de polvos,
- moldeo de plástico,
- erosionado y
- recubrimiento.

A partir de la clasificación adecuada de equipamiento, material y proceso, se relevaron los datos de las 38 empresas asociadas, para proceder al análisis y aplicación de la simulación. Las variables relevadas son una función del tiempo e incluyen entre otras:

- el tiempo de operación de cada equipo,
- la secuencia de operaciones del proceso,
- el tamaño del lote de las partes,

- la tipología del equipamiento utilizado,
- el nivel de demora de las partes a utilizar,
- el material residual del proceso productivo.

En general, los datos se obtuvieron tanto a través de la entrega de formularios por parte de las empresas, como de la captura en forma manual e individual que se realizó en cada circuito productivo de cada organización, conformándose una serie temporal como base de datos.

El equipo de trabajo conformado para relevar los diferentes modelos productivos reflejó la complejidad y dinámica de las empresas, y la simulación de diversos escenarios para luego diseñar planes de trabajo concretos basados en los análisis de los contextos evaluados. Se priorizó trabajar con aquellas empresas cuyos sistemas productivos están organizados por lotes, ya que las características comunes de los sistemas de producción permiten mejorar el enfoque en las variables a utilizar y realizar un intercambio de experiencias entre las propias empresas participantes. Por lo tanto se separó a las empresas en dos grupos: el primero agrupa las empresas que trabajan con un esquema push o pull y con líneas de ensamble, mientras que el segundo grupo está compuesto por organizaciones que trabajan por proyecto, aunque los procesos productivos son similares, pero los resultados varían en función de la asignación de recursos y tiempos utilizados.

#### 4 REDES NEURONALES ARTIFICIALES Y MODELO UTILIZADO

Las fluctuaciones diarias observadas en los tiempos de producción de los diferentes procesos industriales alentaron la posibilidad de analizarlas en el marco de ciertos índices productivos utilizados actualmente. El tiempo del ciclo productivo (WIP) y la cantidad de material residual generado (SCRAP) son los más utilizados a escala mundial en los estudios de procesos productivos.

Para nuestro ejemplo de predicción, hemos seleccionado como variables:

- el tiempo de operación de cada equipo en función del tipo de pieza a producir,
- la secuencia de operaciones del proceso industrial asociado a un tipo de producto final,
- el tamaño del lote de las partes ya sea materia prima, insumo o producto intermedio,
- la tipología y caracterización del equipamiento utilizado en cada operación,
- el nivel de demora de cada una de las partes,
- el material residual del proceso productivo

Los valores numéricos de cada variable utilizada, a través de la adquisición de datos conformando una serie de tiempo, son:

- alto (el más alto de la jornada),
- bajo (el más bajo de la jornada), y
- un promedio de la diferencia de ambos (alto y bajo) del último proceso productivo realizado.

Los valores salida ( $Q$ , como se verá a continuación) son:

- +100 si el proceso es satisfactorio,
- -100 si el proceso indica una falla o demora en la producción, u
- otro valor, indicando en qué nivel de eficiencia se encuentra el proceso industrial.

De esta manera, intentaremos predecir el comportamiento correcto de la línea de producción, indicando en qué lugar se encuentra la obstrucción y proponiendo una estimación de la solución en función de otros escenarios o contextos en los cuales la RNA haya sido entrenada.

Existen ciertos elementos claves para la selección del modelo de RNA a utilizar en esta aplicación particular. Primero se debe seleccionar el tipo de función que se desee aplicar

(clasificación, clustering, modelado, aproximación de series de tiempo). En este caso *aproximación de series de tiempo*. Segundo, seleccionar dentro de la serie temporal de datos disponibles de cada variable, la fracción de datos para realizar el entrenamiento de la RNA (la gran mayoría dentro de la serie), y los breves intervalos de validación del entrenamiento (permite realizar los ajustes en cada iteración del aprendizaje) y de predicción pura (permite evaluar la capacidad predictiva de la RNA). Tercero, seleccionar la mejor arquitectura de la RNA para el problema a abordar (cantidad de neuronas en la capa de entrada, en la capa oculta y en la capa de salida). El tipo de RNA elegido es el *perceptrón multicapa*, entrenado mediante el método de *backpropagation estándar*.

En este estudio inicial, los valores de cada una de las variables en estudio provienen de 38 empresas del rubro metalúrgico de la zona de Rafaela y comprenden dos meses del año 2011. En cada tarea dentro del proceso productivo se aplica una RNA, como se ilustra en la [figura 2](#), donde  $s_i$  representa el vector o conjunto de variables de entrada estáticas (es decir que no cambian con el tiempo, como tipo de máquina, proceso industrial referenciado, etc.) y  $a_i$  representa el vector o conjunto de variables de entrada dinámicas (es decir que cambian con el tiempo, como cantidad de operarios, tiempo de proceso del recurso utilizado, etc.) en la etapa  $i$ -ésima, y  $Q$  representa la función de salida de la RNA cuyos valores pueden ser, como se mencionó, +100, -100, o un valor intermedio.




Figura 2. Esquema del análisis mediante RNA de un proceso industrial, como por ejemplo clasificación de equipos por arranque de viruta.

En cada RNA, el número de neuronas  $n$  de la capa de entrada es igual la suma de los parámetros de los vectores  $s_i$  y  $a_i$ . A la capa intermedia se le asignan  $(n/2)+1$  neuronas. Finalmente, la capa de salida posee sólo una neurona, con los valores definidos previamente.

La cantidad de patrones de datos disponibles (número de secuencias temporales de entrada en pasos de 1) depende de cada tarea en particular, ya que al estar asociados a un proceso productivo existen tareas que son más rápidas que otras, generando mayor cantidad de patrones. Entre los datos obtenidos, la cantidad mínima de patrones para una tarea es de 75 (tareas que se realizan un máximo de 2 veces al día) y la máxima es de 1850 (tareas que se realizan hasta 50 veces por día). A los fines de evitar el sobre-entrenamiento, todas las RNA se entrenan sobre un total de 2600 *épocas* (o iteraciones). La cantidad de patrones utilizados como intervalo de validación es del 10% del total de patrones para cada RNA, aplicando siempre la técnica de *bootstrapping* (Efron and Tibshirani, 1993) para la selección de los patrones que quedan en el intervalo de validación. Por cada época realizada el vector de datos



que se utiliza para validación varía en forma aleatoria, seleccionando hasta un máximo del 10% de la cantidad de patrones a entrenar.

La cantidad de patrones utilizados como intervalo de predicción pura es de sólo 1 patrón o vector, seleccionado aleatoriamente para cada RNA. También se utilizan patrones para la predicción de otras tareas realizadas en procesos productivos de otras empresas y que no fueron utilizadas en los patrones de entrenamiento o en el intervalo de validación.

## 5 CONCLUSIONES

En esta primera etapa de recolección, organización y depuración de datos de procesos industriales de empresas radicadas en la Provincia de Santa Fe, Argentina, de selección del modelo a implementar y de las RNA a aplicar, los indicios obtenidos hasta el momento han demostrado que el estudio de optimización de parámetros en procesos productivos mediante RNA es posible en nuestra región. La posibilidad de incorporar nuevos datos de empresas de la zona de Rosario aportaría aun más información a las RNA, permitiendo mejorar su predicción (Bigus, 1996). La validación de los datos a futuro se realizará con el mismo conjunto de datos de los patrones de entrenamiento, pero realizando la experiencia con un grupo de validación de datos de procesos productivos posteriores a los relevados en los dos meses de 2011.

Diferentes números de neuronas en la capa intermedia de las RNA permitirán optimizar su estructura en función del problema estudiado. Otra idea para trabajar a futuro consiste en incorporar otra neurona de salida en cada RNA, con un valor cualitativo que establezca el grado de optimización en función de la calidad del producto obtenido. La selección de la serie de tiempo en consideración también es arbitraria, ya que podría haberse elegido otro sector o proceso productivo. Existen además combinaciones de componentes, como RNA con sistemas expertos, algoritmos genéticos y lógica difusa, que aun no hemos explorado.

La interacción con las mencionadas empresas confirma que valoran seriamente la importancia de una buena gestión del proceso industrial y la optimización de sus recursos productivos, que participan en la cadena de valor agregado de la empresa acrecentando su competitividad.

## REFERENCIAS

- Alves, R.M.B., and Nascimento, C.A.O., Analysis and detection of outliers and systematic errors in industrial plant data. *Chemical Engineering Communications*, 194:382-397, DOI:10.1080/00986440600899955, 2007.
- Bigus, J., *Data Mining with Neural Networks*, McGraw-Hill, 1996.
- Efron, B., and Tibshirani R.J., *An Introduction to the Bootstrap*, Chapman & Hall, New York, 1993.
- Fornari, J., Grieco, S., Parodi M., y Luccini E., Análisis de líneas de producción utilizando técnicas tradicionales. *Energeia*, 8:41-52, 2010. <http://www.uca.edu.ar/index.php/site/index/es/universidad/facultades/rosario/quimica-ingenieria/investigacion/revista-energeia/>
- Forst, W., y Hoffmann, D., *Optimization-Theory and Practice*. DOI: 10.1007/978-0-387-78977-4\_8. Springer, 2010.
- García Moreno, E., *Automatización de Procesos Industriales*, Editorial Universidad Politécnica de Valencia, España, 1999.
- Govindhasamy, J.J., McLoone, S.F., Irwin, G.W., French, J.J., and Doyle, R.P., Neural modelling, control and optimisation of an industrial grinding process. *Control Engineering Practice*, 13:1243-1258, 2005.



- Pérez Rivas, L.C., *Técnicas emergentes para la automatización integrada de procesos industriales: Modelos de automatización*, Reporte Técnico #1, Proyecto 2005000170, Fonacit, Mérida, 2006.
- Rao, S.S., *Engineering Optimization: Theory and Practice*, Fourth Edition, John Wiley & Sons, 2009.
- Simon, H.A., *The new science of management decision*, Prentice Hall, 1977.
- Zarenezhad, B., y Aminian, A., Application of the neural network-based model predictive controllers in nonlinear industrial systems. Case study. *Journal of the University of Chemical Technology and Metallurgy*, 46:67-74, 2011.