

**TITULO:** Procedimiento para estimar el extractable del níquel con una red neuronal artificial, en sustitución de los modelos estadísticos tradicionales.

**TITLE:** Procedure to estimate the extractable of the nickel with a network artificial neuronal, in substitution of the traditional statistical models

**AUTORES:**

MsC. Francisco Viada Aguilera<sup>1</sup>

MsC. Juan Carlos Espinosa Franco<sup>2</sup>

**RESUMEN:**

Las Redes Neuronales Artificiales se aplican en la estimación o predicción de los sistemas de detección de fallas de equipos, logrando con ellas las mismas funciones que el modelo estadístico tradicional. Se argumentó un método para sustituir los algoritmos de selección y el conjunto de modelos que normalmente se utilizan en sistemas de control predictivo de procesos complejos, los que están determinados por un conjunto de variables, con un amplio rango de variación de cada una de ellas, como es el caso del extractable del níquel obtenido en los hornos de reducción de la fábrica, por una Red Neuronal.

**PALABRAS CLAVES:** REDES NEURONALES ARTIFICIALES, MODELOS ESTADÍSTICOS, NÍQUEL.

**ABSTRACT:**

The Artificial Neuronal Network they are applied in the estimate or prediction of the systems of detection of flaws of teams, achieving in them the same functions that the traditional statistical pattern. This work argues a method to substitute the selection algorithms and the group of models that are usually used in control systems predictive of complex processes, those that are determined by a group of variables, with a wide range of variation of each one of them, like it is the case of the extractable of the nickel obtained in the ovens of reduction of the factory, for a Network Neuronal.

**KEY WORDS:** NETWORK NEURONAL ARTIFICIAL, STATISTICAL MODELS, NICKEL.

**INTRODUCCIÓN**

El control automático utiliza modelos determinísticos para estimar de forma continua el comportamiento de los procesos industriales, se basa en realizar las predicciones en función de una variable calculada por el comportamiento de otras, que son medidas automáticamente durante la ejecución del proceso.

Como ejemplo se encuentran el tratamiento térmico, la cristalización del azúcar, el primero se logra con un modelo formado por la suma de tres rectas, una con pendiente positiva determinada por la rapidez del calentamiento, otra por una recta de pendiente cero, correspondiente al tiempo de retención y otra

recta con pendiente negativa correspondiente al tiempo de enfriamiento. Para controlar el proceso de cristalización del azúcar se utiliza una función que estima la sobresaturación (SS), variable calculada en función de tres variables medidas, la pureza de la meladura, presión de vacío y temperatura de la masa.

Este proceso se controla correctamente manteniendo la presión del vacío en el tacho de cristalización y la pureza de la meladura en valores constantes, determinado por la calidad de la materia prima y por las experiencias de los puntistas azucareros y controlando la temperatura de la masa de forma tal que la sobresaturación (SS) cambie de acuerdo a una función establecida previamente según un modelo (Viada, 1999).

En el control del proceso de reducción del níquel, se estima también una variable de cálculo llamada extractable del níquel (ext c), en función de 12 variables medidas y donde cada una tiene un amplio rango de variación, por esto es necesario dividir el rango total de la variable más significativa en no menos de 15 tramos, para obtener igual número de modelos, los cuales son aplicados al proceso por un algoritmo de selección, donde existe la posibilidad de que ocurran variaciones fuera de rango y el algoritmo no funcione correctamente, por esta razón después de investigaciones realizadas y comprobarse la calidad en la estimación del extractable, por la Red Neuronal Artificial (RNA) , se propone la sustitución de este conjunto de modelos por la red, porque durante su aplicación, ella va aprendiendo y estimando cada vez con más calidad.

## **MATERIALES Y METODOS.**

En este artículo se aplica la técnica del modelado inductivo de una data del proceso de reducción del níquel, obtenida durante 390 turnos de 8 horas, utilizando Redes Neuronales Artificiales (arquitectura Perceptrón Multicapa, con aprendizaje supervisado) para estimar el comportamiento de la variable fundamental de este proceso (extractable del níquel). Las redes neuronales artificiales (RNA) aventajan a los métodos de regresión u otro tradicional, por la posibilidad del aprendizaje continuo en la aplicación de la misma. En lo fundamental, se distingue de los enfoques estadísticos de modelación en que no asumen a priori ninguna distribución estadística u otra propiedad en los datos y ofrece resultados de notable precisión al modelar patrones complejos.

Se exponen además los resultados obtenidos en el proceso de estimación del extractable del níquel, demostrando la eficiencia en la estimación del rendimiento en un proceso industrial complejo.


La aplicación ventajosa de dicho método comparando sus resultados con los análogos obtenidos mediante el enfoque convencional, constituye un aporte práctico de este trabajo.

## RESULTADOS DEL TRABAJO:

### 2. Modelación de procesos industriales.

La estimación, constituye junto a la predicción, uno de los principales problemas ó tareas científicas que involucran el uso de modelos. Formalmente, la estimación es una de las manifestaciones de la inferencia estadística que se ocupa de cómo obtener información (inferir) sobre los parámetros de una población a partir de subconjuntos de valores (muestras) de variables escogidas.

La red neuronal artificial (RNA) o cualquier otro método de estimación, puede tener dos orientaciones totalmente distintas en sus usos, uno dirigido solamente a realizar la estimación de la salida de un proceso, para ser comparado con la salida real del mismo y por un esquema de pariedad conocer el error resultado de la diferencia entre ambos valores y con estos residuos determinar si se encuentran o no en los umbrales admisibles para estos casos (Sistema de detección de fallas), el otro uso al que se refiere este trabajo, los resultados de la estimación son los que determinan la conducción del proceso y solo se compara con límites preestablecidos de la variable calculada para producir los efectos de control y las alarmas necesarias cuando se produce una falla de dicho proceso.



Para comprender la función de la modelación en la detección de fallas de un equipo, se puede observar la Fig. 1, (Alcorta, 1997), donde la salida del modelo, se utiliza para compararla con la salida real del sistema y producir el error o diferencia entre ambas salidas y comprobar si estos errores se encuentran entre las tolerancias preestablecidas para el buen funcionamiento del equipo.

Fig. 1 Filtro de detección de errores

En el esquema de control de un proceso Fig. 2, la salida del modelo  $Y(t)$  se envía a un algoritmo, este calcula el valor de la variable de control  $U(t)$  y ejecuta las acciones sobre el proceso, además por otro lado se comparan sus valores con los establecidos para las alarmas, se produce el error y si este no está en los límites preestablecidos produce la alarma y acción correspondiente.

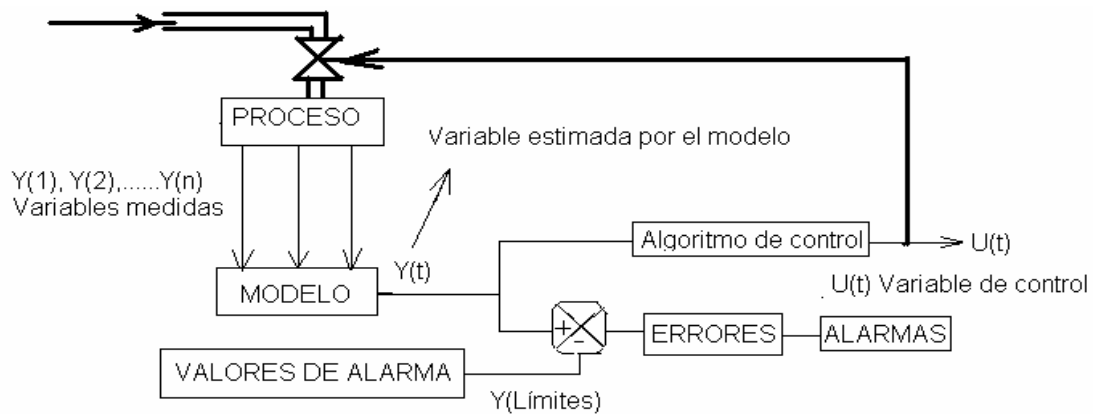


Fig. 2. Esquema de un sistema de control de procesos

Estos modelos pueden ser sustituidos por las redes neuronales artificiales, las cuales tienen una elevada capacidad de adaptación y representación y son ampliamente utilizadas para implementar la identificación no lineal de sistemas complejos.

Una vez demostrada según (Hornick, 1989) la notable capacidad de aproximación universal de las redes neuronales, cobran fuerte impulso las investigaciones en este nuevo campo de la identificación de sistemas. Por esta razón la inteligencia artificial hoy es un área donde se alcanzan resultados de éxito.

Para implementar un sistema de control solo es necesaria una adecuada representación de las relaciones complejas de sus entradas y salidas.

## 2.2 Las Redes Neuronales Artificiales.

Las redes neuronales artificiales (**RNA**) son estructuras computacionales basadas en unidades de procesamiento en paralelo (las neuronas), organizadas como grafos dirigidos hacia adelante con un algoritmo de aprendizaje. Estas acumulan el conocimiento (contenido en los pesos de las conexiones) a partir de un juego de datos. Por tanto, son modelos inductivos de procesamiento de información, es decir, construyen reglas y patrones partiendo de ejemplos y de la experiencia. En la literatura (Lefebvre, 2005) se les refiere como modelos conexionistas, procesadores en paralelo y neuro-computadores.

En ellas las neuronas se organizan como grafos cuya estructura define la arquitectura de la red neuronal. Hay tres tipos de arquitecturas: redes de capa simple alimentadas hacia adelante, redes multicapas alimentadas hacia adelante, y redes recurrentes.

En este trabajo se desarrolla la que realiza la aproximación funcional basada en una red multicapa alimentada hacia adelante, estas procesan información desde las entradas hacia las salidas (Fig. 3), y todas las neuronas y capas, se conectan a todas las neuronas de las capas precedentes y siguientes, por lo que integra la modalidad de redes completamente conectadas.

Procedimiento para estimar el extractable del níquel con una red neuronal artificial, en sustitución de los modelos estadísticos tradicionales.




Fig. 3. Red multicapa alimentada hacia adelante (“feedforward”).

### 2.2.1 Aprendizaje de las Redes Neuronales Artificiales.

La lista de algoritmos de entrenamiento para las RNA es extensa, este trabajo aborda los empleados para la optimización estructural y paramétrica del modelo neuronal desarrollado. Se entiende por aprendizaje (entrenamiento) de la red, la propia estimación del modelo neuronal, ó al proceso de búsqueda de los parámetros (pesos) de la función de aproximación que minimice una función de costo (error cuadrático entre las salidas reales del sistema modelado y las salidas de la RNA. La esencia del proceso de aprendizaje de una red se representa en la Fig. 4, este modelo neuronal se coloca en paralelo con el sistema y el error entre las salidas del sistema ( $y^p$ ) y de la RNA ( $y^m$ ) (error de predicción) es utilizado como señal para el entrenamiento de la red. Esta estructura implementa el aprendizaje supervisado, donde el maestro (sistema), proporciona los valores deseados (salidas), directamente en el sistema coordinado del aprendiz (modelo neuronal), (Herrera, 2001).




Fig. 4. Esquema simplificado del aprendizaje supervisado.

El entrenamiento de redes neuronales multicapa se basa en el empleo de técnicas de optimización numérica no lineales, entre las que ocupa un lugar primordial el algoritmo de propagación de los errores hacia atrás (“back propagation” ó BP), este constituye un proceso iterativo de actualización de los parámetros de la RNA, según el gradiente de la función de error a partir de una muestra representativa de vectores de entrada y sus correspondientes salidas y de su algoritmo básico, del que se derivan las técnicas de optimización, el gradiente descendente con momento, los métodos de Newton y el algoritmo Levenberg-Marquardt (L-M).

### **2.3 Perceptrón Multicapa (PM), como un aproximador universal.**

En un trabajo medular (Cybenko, 1989) da a conocer la primera demostración rigurosa de la capacidad de representación funcional del PM, en la que se probaba que con una única capa oculta era capaz de aproximar uniformemente cualquier función continua, de soporte al hipercubo unitario. Corresponde a (Hornik, 1989) un artículo donde expuso la capacidad de aproximación funcional del perceptrón multicapa.

Este teorema, no explica cómo escoger la estructura, ni los pesos de la red, pero justifica teóricamente el uso de las redes neuronales en la identificación de sistemas, aunque solo hace mención a una única capa oculta, puede ser conveniente el aumentar el número de capas.

#### **2.3.1 Validación del modelo neuronal.**

Validar un modelo significa contrastarlo con la realidad que representa, de manera que se compruebe si posee un rango satisfactorio de precisión consistente con la aplicación para la que está concebido. Conforme a (Norgaard, 1997) el análisis de los residuos (errores de predicción) mediante técnicas de validación cruzada a partir un conjunto de datos designado para tal comprobación, es el método más comúnmente empleado. Además se ha establecido la necesidad de verificar la independencia entre los residuos, también entre estos y las entradas del modelo (análisis de correlación residual y covarianza cruzada entre los errores y las entradas), como un buen criterio de calidad de los modelos.

#### **2.3.2 Análisis estadístico de sensibilidades.**

Una vez ajustado el aproximador funcional, es necesario analizar la influencia que cada una de las variables de entrada tiene en la salida, con el fin de identificar aquellas variables no relevantes, que no aportan ninguna información (Muñoz, 1996). La eliminación de estas variables disminuye la complejidad del aproximador y aumenta su capacidad de generalización.

### **2.4 Software utilizado, para sustituir modelos estadísticos por una Red Neuronal.**

El software utilizado es el “NeuroSolution for Excel”, (Lefebvre, 2005), este permite el acceso a todos los rasgos esenciales del Neuro Solutions, con la ventaja y facilidad del uso de la hoja de cálculo. Permite etiquetar los datos visualmente como entrenamiento, validación cruzada, prueba o producción, crear, entrenar una red y probar el nivel de representación de la misma directamente desde una hoja de cálculo de Microsoft Excel, además genera los informes automáticamente donde se muestran los resultados.

#### **Procedimiento para utilizar el “Neuro Solution for Excel”.**

Ejecutar el NeuroSolution para EXCELL.

Desde tabla de datos en EXCELL se ejecutan los siguientes pasos:

- a) Se marcan las columnas de las variables de entrada en EXCELL.
  - \* Se seleccionan las columnas anteriores con la opción tag data del Neuro Solution
  - \* Se marcan las columnas de las variables de salida en EXCELL con Neuro Solution.
  - \* Se seleccionan las columnas anteriores con la opción tag data del Neuro Solution
- b) El total de filas de la tabla de datos se divide en cuatro grupos:
  - \* Grupo de filas para el aprendizaje de red
  - \* Grupo de filas para la prueba de la red.
  - \* Grupo de filas para la validación de la red.
  - \* Grupo de filas para la Producción o Estimación.

Estos cuatro grupos anteriores se incluyen marcando en la tabla el número de filas seleccionadas y definiéndolas con la opción tag data.

- c) Ahora se manda a construir la red, esta acción se ejecuta con la opción tag data.
  - \* Después se procede a salvar la red que el software ha creado.
- d) Se retorna al Neuro Solution para realizar las acciones siguientes:
  - \* Entrenamiento de la red con la opción “Train Network”.
  - \* Prueba de la red con “Test Network”
  - \* Validación con “Test Valition”

Ahora la red está preparada para realizar las estimaciones necesarias, lo que constituye el objeto de este trabajo

## **2.5 Características principales del proceso de reducción del níquel.**

Este proceso está determinado por el paso del mineral por medio de 15 hornos de reducción en serie y en cada horno se controlan diversas variables, pero el resultado final es el extractable de níquel (Ext) , por lo tanto todas las variables se controlan y fijan en valores predeterminados por la experiencia en la conducción de este proceso y se actúa solamente variando la más significativa, conduciendo el extractable (variable de salida), por los valores deseados para este proceso y estimados por los modelos o la red neuronal que los sustituye.

La fuente de datos para la elaboración de la red se obtuvo de los registros de una industria, en más de 390 turnos de 8 horas cada uno, lo que permite comprender que en estos, se produjeron el mayor número de alternativas de variación del mismo.

Estos datos son los valores de variables medidas automáticamente, que corresponden a esa misma cantidad de procesos, realizados cada uno independiente de los demás, con condiciones imposibles de repetirse para un proceso, que aún no ha sido automatizado.

## **2.6 Variables del proceso de reducción del níquel.**

En la aplicación de las RNA, el total de variables a escoger para la identificación del sistema, debe ser lo bastante grande para cubrir las diferentes

facetas del problema en cuestión y suficientemente pequeño para no sobrecargar excesivamente la cantidad de información (Pacheco, 1995).

Las variables que determinan el extractable de níquel en los hornos de reducción, medidas automáticamente y controladas manualmente, en este proceso son:

- \* El perfil de temperatura, determinado por la temperatura medida en los hogares  $H_4$ ,  $H_6$ ,  $H_9$ ,  $H_{11}$ ,  $H_{13}$  y  $H_{15}$ .
- \* El tonelaje por hora de entrada de mineral al horno (T).
- \* El petróleo consumido (P).
- \* El monóxido de carbono (CO).
- \* Contenido de níquel en el mineral (Ni).
- \* Contenido de hierro en el mineral (Fe).
- \* El número de mineral (Na).

Las variables contenido de níquel (Ni), contenido de hierro (Fe) en el mineral y el extractable de níquel más cobalto (Ext), son obtenidos a través del análisis del laboratorio con una periodicidad de 8 horas, el número de mineral (Na) es una variable que se calcula por la siguiente expresión:

$$Na = \frac{\%Ni * \%Fe}{\%SiO_2 * \%MgO}$$

(Ec. 2-1)

Esta variable tiene una gran influencia en la estimación del modelo, porque incluye la fuerte influencia que tienen el  $SiO_2$  y  $MgO$  en el proceso y que no aparecen incluidas como variables dentro de la data de cálculo de la red.

## 2.7 Datos reales de la muestra.

Respecto a la cantidad de observaciones necesarias para conseguir buenos resultados en el entrenamiento de las redes neuronales, no existe una regla para determinarla. Lo más conveniente es disponer de un conjunto de datos lo más extenso posible, como para cubrir cada estado del sistema a modelar. Se tomó un total de 390 líneas de mediciones (con un período de muestreo 8 horas).



1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
No.	h4	h6	h9	h11	h13	h15	ni	fe	na	Caa	t	p	ext		
1	560	638	700	767	765	774	1,13	44,8	1,03	2,52	13,6	62,9	71,7		
2	653	673	656	710	729	802	1,18	43,4	1,07	2,13	14,9	65,4	73,1		
3	501	728	675	717	754	789	1,19	44,2	1,50	1,13	15,0	66,2	73,1		
4	694	723	728	762	774	790	1,18	45,7	1,55	1,91	15,2	55,9	74,5		
.	.	.	.	.	.	.	.	.	.	.	.	.	.		
.	.	.	.	.	.	.	.	.	.	.	.	.	.		
.	.	.	.	.	.	.	.	.	.	.	.	.	.	ext c	E(t)
375	722	787	709	729	733	788	1,05	40,7	0,80	2,31	22,3	47,7	84,03	84,81	0.78
376	801	752	640	712	665	782	1,10	36,8	0,62	3,44	22,1	58,2	84,56	84,30	0.26
377	826	735	649	729	691	791	1,10	33,0	0,43	3,54	21,9	68,2	84,11	84,02	0.09
378	741	793	684	733	792	783	1,14	42,0	0,76	2,32	21,7	55,1	83,84	83,33	0.51
379	787	727	633	712	663	791	1,09	34,7	0,44	2,80	21,2	59,4	83,19	82,50	0.69
380	675,1	668	666	717	681	796	1,17	35,4	0,48	3,01	20,9	68,7	83,36	81,92	1.44
381	712	927	675	769	731	749	1,11	43,5	0,90	2,00	20,6	68,4	82,44	81,10	1.34
382	795	866	696	739	733	760	1,14	41,8	0,52	2,10	20,9	52,8	82,82	81,87	0.95
383	749	733	731	753	760	810	1,15	45,0	1,69	2,54	20,3	61,8	81,80	80,51	0.29
384	572	853	672	773	755	732	1,13	43,9	1,27	1,82	20,0	60,9	80,69	79,76	0.93
385	814	793	714	727	697	753	1,06	40,5	1,01	2,59	19,7	48,5	79,59	79,49	0.10
386	714	723	707	755	741	746	1,07	44,3	1,25	1,49	19,3	67,0	78,13	78,73	0.60
387	658	736	683	747	777	792	1,13	45,8	1,58	2,08	18,7	61,5	77,07	77,47	0.40
388	742	701	706	731	764	773	1,15	41,4	0,75	2,30	17,8	55,9	75,48	76,11	0.63
389	842	757	708	742	756	760	1,11	40,6	0,93	1,57	13,5	49,8	71,69	71,81	0.12
390	687	817	673	741	771	756	1,19	45,5	1,41	2,10	19,9	57,4	80,29	79,53	0.76

*Tabla 2.1 Valores utilizados en las corridas de la RNA y sus salidas calculadas.*

Los datos de la columna 14, línea 1 hasta la línea 390, Tabla 2.1, reporta los valores del extractable medido (ext) por el laboratorio de la industria, para un período de mediciones correspondientes a 390 turnos de producción en jornadas de 8 horas cada uno. La columna 15 reporta los valores estimados (ext c) por la **RNA**, desde la línea 370 hasta la 390, la columna 16 corresponde a los errores E(t) resultante de la comparación entre ambas columnas, llamados errores de estimación. Puede observarse que aún hay errores significativos para algunos estados de trabajo.

## 2.8 Construcción de la Red Neuronal Artificial del proceso de reducción

El análisis del problema y la literatura especializada, sobre las RNA como aproximador funcional, justifica la topología de red Perceptrón Multicapa (MLP) por su adaptabilidad y capacidad de representación. Para optimizar la estructura y los parámetros se utilizó el aprendizaje supervisado Backpropagation, mediante la técnica estadística conocida bajo el nombre de validación cruzada ("crossvalidation), esta permitió estimar la capacidad de generalización del aproximador funcional, utilizando un conjunto de diferentes datos, para entrenamiento, prueba y validación del modelo. Con tal fin los datos

se dividieron para formar tres conjuntos de muestras independientes de las observaciones de entrada/salida. El primero corresponde al conjunto del entrenamiento, utilizado para el ajuste del vector de parámetros (pesos) del aproximador, con minimización de la función de costo en el entrenamiento: distancia euclidiana entre la salida de la red y la salida real del sistema (Ec. 2-2):

$$J(t) = \frac{1}{2} \sum_i (d_i(t) - y_i(t))^2 \quad (\text{Ec.2-2})$$

El segundo es el conjunto de prueba, utilizado para estimar la capacidad de la generalización del modelo, se utilizan estos datos “frescos” para estimar el comportamiento frente a datos no conocidos y que permitan estimar el riesgo del error global. El tercero es utilizado para la validación, para dar el visto bueno al óptimo del aproximador hallado. Basado en estos criterios, se eligieron 265 líneas de datos de la muestra para el entrenamiento, 50 para la prueba, 50 para la validación y 25 para la producción. El software desarrolló la red neuronal mediante su modulo asociado al Excel de Windows. La RNA se sometió a tres corridas de entrenamiento, cada una con 1000 épocas, permitiendo alcanzar la convergencia con mínimo error.

## 2.9 Análisis de los resultados.

La optimización del modelo se aprecia en la Fig. 2.5 (estas curvas son aportadas por el software, al correr con los datos reales del proceso en cuestión), donde las curvas de error medio cuadrático (MSE) para los datos de prueba, entrenamiento y validación son similares, en ellas se observa la rapidez de convergencia de la red, desde un alto valor de error hasta un mínimo. En todos los casos las rutas de convergencias se confinan entre las fronteras de desviación estándar +1 y -1.




Fig. 2.5. Error (MSE) para los datos de entrenamiento y validación.

Los valores mínimos de error y medios, de entrenamiento y validación y sus desviaciones estándar se pueden apreciar en las Tablas 2.2 y 2.3. Todos muestran errores bajos y confiables para el modelo obtenido.

<b>Todas las corridas</b>	<b>Valor mínimo en el entrenamiento</b>	<b>Desviación estándar en el entrenamiento</b>	<b>Valor mínimo en la validación cruzada</b>	<b>Desviación estándar en la Validación cruzada</b>
MSE mínimo	0,001633078	0,000124714	0,008089606	0,001239185
MSE final	0,001633078	0,000124714	0,008089606	0,001239185

Tabla 2.2. Parámetros de la red resultado de su entrenamiento y validación.

<b>Mejores redes</b>	<b>Entrenamiento</b>	<b>Cross Validación</b>
Corrida	1	1
Época	1000	1000
MSE mínimo	0,001516132	0,006668177
MSE final	0,001516132	0,006668177

Tabla 2.3 Parámetros de la mejor red, resultado de su entrenamiento y validación.

Estos resultados muestran el comportamiento de los errores del modelo durante el proceso de optimización (para las muestras de prueba y validación). Una vez ajustada la RNA, se realizaron simulaciones para analizar su salida respecto a los valores reportados de la variable extractable calculada (**ext c**), Tabla 2.1, en dicha tabla los valores obtenidos de esta variable, fueron muy próximos a los valores reportados por el laboratorio de la industria, para estas mismas líneas de datos, lo que permite considerar que la RNA es un buen estimador para este tipo de proceso.

Un criterio adicional sugerido en la literatura (Ljung, 1987) para evaluar la calidad del modelo es el coeficiente de correlación ( $r$ ) entre la serie de datos de salida real ( $d_i$ ) del sistema modelado y la serie de datos de la salida de red ( $y_i$ ). Para un total de  $N$  observaciones, está definido en la ecuación (Ec. 2. 2).

$$r = \frac{\sum_i (y_i - \bar{y})(d_i - \bar{d})}{\sqrt{\frac{\sum_i (d_i - \bar{d})^2}{N}} \sqrt{\frac{\sum_i (y_i - \bar{y})^2}{N}}} \quad (\text{Ec. 2. 2})$$

En el caso investigado este coeficiente toma el valor de 0,88 según se reporta en la Tabla 2.4, para ambos conjuntos de datos (prueba y validación), esto indica que las series de salida de la red y el sistema están linealmente asociadas y se mueven en la misma dirección.

<b>Performance</b>	<b>ext</b>	<b>ext Output</b>
Min Abs Error	0,360093272	85,49420178
Max Abs Error	1,314891989	87,11855111
<b>R</b>	<b>0,881089002</b>	

Tabla 2.4

### 2.9.1 Comparación entre los modelos determinísticos y los neuronales.

Al confrontar los modelos clásicos y neuronales se toman como elementos de análisis los principales estadísticos que permiten caracterizar la bondad de ajuste de las series de datos de los parámetros de la investigación. Estos son los valores medios y desviaciones estándar de los datos medidos y estimados, el coeficiente de correlación entre ambas series de datos y el valor medio del error.

Del análisis de los resultados presentados en la Tabla 2.5 (Viada, 2005), se puede observar la calidad del modelo estadístico convencional para estimar el extractable del níquel (ext c).

Dependent Variable: EXT

Method: Least Squares

Date: 05/21/01 Time: 02:25

Sample: 1 100 Included observations: 100

$$\text{EXT} = C(1) + C(2) \cdot \text{FE} + C(3) \cdot \text{FE}^2 + C(4) \cdot \text{FE}^3 + C(5) \cdot \text{NI} + C(6) \cdot \text{NI}^2 + C(7) \cdot \text{CAA}^2 + C(8) \cdot \text{CAA} \\ + C(9) \cdot \text{NNA} + C(10) \cdot \text{NNA}^2 + C(11) \cdot \text{H6} + C(12) \cdot \text{H15} + C(13) \cdot \text{H13} + C(14) \cdot \text{P}$$

**R-squared**                    **0.990936**                    Mean dependent        81.92800

**Adjusted R-S.**            **0.989565**                    S.D. dependent        3.379082

Sum squared resid 10.24644                    Schwarz criterion        1.204361

Log likelihood            -27.98185                    F-statistic                723.2031

Durbin-Watson            2.015807                    Prob(F-statistic)        0.000000

Tabla 2.5. Salida del Eviews en la obtención y validación del modelo:

Al comparar los resultados obtenidos por la RNA y los resultados anteriores obtenidos por la evaluación de un modelo, se observa que los estadígrafos del modelo (Tabla 2.4), tienen más calidad que los estadígrafos de la red (Tabla 2.3).

<b>Para el modelo:</b>	<b>R-squared</b>	<b>0.990936</b>
<b>Para la RNA:</b>	<b>R-squared</b>	<b>0.881089002</b>

Estos resultados permiten realizar las siguientes consideraciones:

\* Las estimaciones de la RNA son de menos calidad que las obtenidas por el modelo, pero la RNA se va ajustando automáticamente (o sea va aprendiendo) durante la aplicación, constituyendo una perspectiva de mejoramiento de su calidad.

\* El modelo fue estimado para un rango muy pequeño de variación de sus variables, no cubre todo su espectro, problema resuelto en la RNA, la que estima para todo el rango del proceso.

## CONCLUSIONES:

1. La aplicación de biomateriales que puedan ser degradados en condiciones fisiológicas para ser utilizados en biomedicina, está experimentando un crecimiento incesante.
2. En los últimos años se han experimentando nuevos materiales con carácter biocompatible y adecuadas propiedades mecánicas. En este sentido las poliamidas, poliesteramidas y sus derivados, poseen un amplio campo de aplicación como materiales biomédicos.

## BIBLIOGRAFÍA:

1. Laminates composed of polypeptides and elastomers as a burn wound covering - physicochemical properties. Aiba, S.... [et al.]. **Biomaterials**, 6 (5): 290-296, 1985.
2. Alla, Abdellilah. Síntesis y degradación de poliesteramidas derivadas del ácido tartárico. Barcelona; Departamento de Ingeniería Química. Universidad Politécnica de Cataluña, 1997. 236 h. (Tesis Doctoral).
3. Bou, Jordi. Síntesis y caracterización de poliamidas derivadas del ácido tartárico. Barcelona; Departamento de Ingeniería Química. Universidad Politécnica de Cataluña, 1994. 357 h. (Tesis Doctoral).
4. Synthesis, characterization, and degradation of block polyesteramides containing poly(l-lactide) segments. Desimone, V.... [et al.]. **Journal of Applied Polymer Science**, 46 (10):1813-1820, 1992.
5. Ducreux, Ann Severine. Influencia de la degradación hidrolítica sobre las propiedades de polímeros derivados del ácido tartárico. Barcelona; Departamento de Ingeniería Química. Universidad Politécnica de Cataluña, 1997. 74 h. (Trabajo Final de Carrera. Ingeniería Europea de Materiales).
6. Degradation of nonalternating Poly(ester-amides). Gonsalves, K. E..... [et al.]. **Macromolecules**, 25: 3309-3312, 1992.
7. Enzymatic-hydrolysis of water-soluble random copolypeptides. Hayashi, T..... [et al.]. **Journal of Applied Polymer Science**, 43 (12): 2223-2230, 1991.
8. Iribarren Laco, Ignacio. Estudio estructural de poliesteramidas quirales. Barcelona; Departamento de Ingeniería Química. Universidad Politécnica de Cataluña, 1996. 364 h. (Tesis Doctoral).
9. Molecular-weight control in polycondensation of hydroxyl diesters with hexamethylenediamine by polymer matrices. Ogata, N.... [et al.]. **Journal of Polymer Science: Part A- Polymer Chemistry**, 19 (10): 2609-2617, 1981.

10. Synthesis of polyamides from active bis(pentafluorophenyl) esters of dicarboxylic-acids and diamines. Katsarava, R. ... [et al.]. **Makromolekulare Chemie** -Rapid Communications, 5 (9): 585-591, 1984.
11. Synthesis and structural study of a new biodegradable copolymer of a nylon-11 and L-alanine. Paredes, N..... [et al.]. **Polymer**, 37 (18): 4175-4186, 1996.
12. Studies on the Biodegradation and Biocompatibility of a new Poly (ester amide) derived from L-alanine. Paredes, N..... [et al.]. **Journal of applied Polymer Science**, 69: 1537-1549, 1998.
13. Ogata, N.; Hosoda, Y. Synthesis of hydrophilic polyamide by active polycondensation. **Journal of Polymer Science: Part C - Polymer Letters**, 12 (6): 355-358, 1974.
14. Polycondensation reaction of dimethyl tartrate with hexamethylenediamine in the presence of various matrices. Ogata, N.... [et al.]. **Journal of Polymer Science: Part A- Polymer Chemistry**, 18 (3): 939-948, 1980.
15. Synthesis and characterization of a family of biodegradable Poly(ester amide)s derived from glycine. Paredes, N.... [et al.]. **Journal of Polymer Science: Part A- Polymer Chemistry**, 36: 1271-1282, 1998.
16. Pérez Rodríguez, Ángel. Propiedades de poliamidas, poliesteramidas y sus mezclas. Barcelona; Departamento de Ingeniería Química. Universidad Politécnica de Cataluña, 1999. 198 h. (Tesis Doctoral).
17. Stereocopolyamides derived from 2,3-Di-O-methyl-D- and -L-Tartaric Acids and Hexamethylenediamine. 1. Synthesis, characterization and compared properties. Regaño, C.... [et al.]. **Macromolecules** 29: 8404-8412, 1996.
18. Stereocopolyamides derived from 2,3-Di-O-methyl-D- and -L-Tartaric Acids and Hexamethylenediamine. 2. Influence of the configurational composition on the crystal structure of optically compensated systems. Regaño, C.... [et al.]. **Macromolecules** 29: 8413-8424, 1996.
19. San Román, J. Polímeros biodegradables de interés en cirugía. I. Síntesis, propiedades y mecanismos biodegradativos. **Revista de Plásticos Modernos** (España) 413: 689-704, 1990.
20. San Román, J. Polímeros biodegradables de interés en cirugía. II. Comportamiento biodegradativo y aplicaciones biomédicas. **Revista de Plásticos Modernos** (España) 414: 857-877, 1990.
21. Synthesis of polyamides and a polyester containing 2,6-dichlorobenzaldehyde. Schacht, D.... [et al.]. **Makromolekulare Chemie** - Macromolecular Chemistry and Physics, 179 (3): 837-840, 1978.
22. Polyether-segmented polyamides as a new designed antithrombogenic material - microstructure of poly(propylene oxide)-segmented nylon-610. Yui, N....[et al.]. **Makromolekulare Chemie**- Macromolecular Chemistry and Physics, 185 (11): 2259-2267, 1984.
23. Villuendas, María Isabel. Poliesteramidas derivadas del ácido tartárico y aminoalcoholes. Barcelona; Departamento de Ingeniería Química. Universidad Politécnica de Cataluña, 1998. 357 h. (Tesis Doctoral).

## DATOS DE LOS AUTORES

### Nombres:

Dra. Marisol L. Pérez Ferrás. Profesora Asistente. Dpto. Metodológico.

Dr. C. Ángel T. Pérez Rodríguez. Profesor Titular. Grupo de Investigación de  
Materiales y Ambiente. Dpto. de Física-Química-Electrónica. FACING.

### Correos:

[marisalp@ucm.hlg.sld.cu](mailto:marisalp@ucm.hlg.sld.cu)

[aperez@facing.uho.edu.cu](mailto:aperez@facing.uho.edu.cu)

### Centro de trabajo:

Universidad de Ciencias Médicas “Mariana Grajales Coello”. Holguín.

Universidad de Holguín. Ave XX Aniversario, s/n. Holguín. CP 80100. Cuba.

**Fecha de recepción:** 26 mar. 2010

**Fecha de aprobación:** 22 jul. 2010

**Fecha de Publicación:** 30 sep. 2010