



**REPUBLICA DE CUBA  
MINISTERIO DE EDUCACION SUPERIOR  
INSTITUTO SUPERIOR MINERO METALURGICO  
Dr. ANTONIO NUÑEZ JIMENEZ  
FACULTAD METALURGIA ELECTROMECAÁNICA  
DEPARTAMENTO DE INGENIERIA MECANICA**

**Tesis en Opción al Título de Máster en Electromecánica**

# **Identificación del proceso de enfriamiento del mineral en el proceso CARON, con ayuda de Redes Neuronales Artificiales.**

**AUTOR: Ing. Yudmila Spencer Rodríguez**

**TUTORES: Dr. C. Ing. Ángel Oscar Columbié Navarro**

Profesor Titular del Departamento de Eléctrica del ISMM

**M. Sc. Ever Góngora Leyva**

Profesor Asistente del Departamento de Mecánica del ISMM

**CONSULTANTES:**

**M. Sc. Reineris Montero Laurencio**

Profesor Asistente del CEETAM

**M. Sc. Marcos Medina Arce**

Profesor Asistente del Dpto de Contabilidad

**Moa- 2009**

## **RESUMEN**

En la presente investigación se aborda la temática de las Redes Neuronales Artificiales, aplicada a los procesos industriales en específico al proceso de enfriamiento del mineral reducido en la Planta de Hornos de Reducción de la empresa “Cmdte. Ernesto Che Guevara”.

En la misma se hace una exposición detallada de la bibliografía relacionada tanto con la temática de las Redes Neuronales como de la modelación físico matemática del proceso estudiado, demostrándose que no existe un modelo matemático validado que caracterice el proceso, hasta la fecha solo se han encontrado modelos teóricos que describen en cierto modo el comportamiento de los parámetros del dicho proceso.

Para el desarrollo de la investigación se identificaron las principales variables que caracterizan el proceso y se tomaron unas series de datos que comprenden un periodo de 4 meses de explotación de la instalación, a la cual se le realizó un análisis de regresión paso a paso hacia atrás, determinando que las principales variables que influyen en la temperatura del mineral a la salida son, el flujo y la temperatura del agua de enfriamiento. Este análisis también permitió determinar que el coeficiente de correlación lineal no alcanzó valores superiores al 57,19 % .

Las técnicas de inteligencia artificial permitieron la creación de una Red Neuronal del tipo Cascade – Forward Backpropagation de cuatro capas, capaz de identificar el proceso de enfriamiento con tal exactitud alcanzando valores de coeficiente de correlación de hasta un 92 % en su entrenamiento, de hasta un 93 % en su validación y hasta de un 74 % en su generalización.

## **ABSTRACT**

In this investigation the Neural Networks is applied to the industrial processes, specifically to the cooling process of reduced Ore in the Plant of Reduction Furnace in the company "Cmdte. Ernesto Che Guevara."

A detailed exposition about bibliography related to Neural Networks and Physic Mathematical Modelling is done. It is showed that a validated a Mathematical model characterization the process does not exist.

For the development of the investigation the main variables were identified that they characterize the process and they took some series of data that understand a period of 4 months of exploitation of the installation, to which was carried out a regression analysis step to step back, determining that the main variables that influence in the temperature from the mineral to the exit are, the flow and the temperature of the cooling water. This analysis also allowed to determine that the lineal correlation coefficient which didn't reach superior securities to 57,19 % .

The artificial intelligence techniques allowed the creation of Cascade-Forward Backpropagation Neural Networks of four layers. This model reproduce the cooling process with such an accuracy reaching correlation coefficient securities of until 92% in their training, of until 93% in their validation and until of 74% in their generalization.

## ÍNDICE

	<b>Pág.</b>
INTRODUCCIÓN	1
CAPÍTULO I: MARCO TEÓRICO	6
I.1. Introducción.	6
I.2. Estado del Arte.	6
I.3. Trabajos precedentes.	9
I.4. Redes Neuronales Artificiales.	12
I.4.1. Fundamentos de Redes Neuronales Artificiales.	13
I.4.2. Aplicaciones generales de las Redes Neuronales Artificiales.	18
I.4.3. Aplicaciones de la red Backpropagation.	19
I.5. Introducción al proceso de enfriamiento en la Planta de Hornos.	19
I.5.1. Proceso tecnológico de la Planta de Hornos de Reducción.	20
I.5.2. Descripción de la instalación de estudio.	22
I.6. Modelación termodinámica de los sistemas de intercambio de calor.	23
I.6.1. Análisis crítico de la modelación termodinámica del sistema de enfriamiento.	24
I.7. Conclusiones del Capítulo I	30
CAPÍTULO II: MATERIALES Y MÉTODOS	31
II.1. Introducción.	31
II.2. Aplicación de las herramientas estadísticas.	36
II.2.1. Análisis estadístico de los datos.	37
II.2.2. Análisis de regresión.	39
II.3. Redes Neuronales Artificiales.	46
II.4. Conclusiones del capítulo II	51
CAPÍTULO III: RESULTADOS EXPERIMENTALES	52
III.1. Introducción.	52
III.2. Análisis del Proceso de enfriamiento del mineral reducido.	53
III.3. Instalación experimental.	55
III.3.1. Estado de la automatización del proceso de enfriamiento del mineral.	56
III.3.2. Diseño experimental.	59
III.3.3. Técnica experimental.	59
III.4. Redes Neuronales Artificiales.	65
III.4.1. Arquitectura de la red.	66
III.4.2. Entrenamiento de la red.	69
III.4.3. Predicción.	71
III.4.4. Análisis de los resultados.	71
III.5. Conclusiones del capítulo III	78
CONCLUSIONES	79
RECOMENDACIONES	80
BIBLIOGRAFÍA	81
ANEXOS	85

## **INTRODUCCIÓN**

La industria cubana del níquel desempeña un papel importante dentro de la economía nacional, es por ello que el incremento de la eficiencia de los diferentes equipos e instalaciones que la componen incide considerablemente en la reducción del consumo de portadores energéticos.

Existen dos fábricas en funcionamiento para la obtención de concentrado de Níquel más Cobalto con tecnología carbonato amoniacal: la empresa “Cmdte. René Ramos Latour”, y la “Cmdte. Ernesto Che Guevara”, empresa estatal socialista que se desarrolló profundamente a partir de la década de los años 90, lo cual se refleja en los índices de producción logrados en ella, que sin lugar a dudas han contribuido exitosamente a la reanimación de la economía cubana, dando valiosos aportes económicos en aras del desarrollo social.

La fábrica “Cmdte. Ernesto Che Guevara” se encuentra ubicada al norte del yacimiento de mineral en Punta Gorda, provincia de Holguín entre los ríos Moa y Yagrumaje, a 4 km de la Ciudad de Moa y a 2 km del pueblo de Punta Gorda. El puerto marítimo encargado de facilitar las materias primas necesarias, así como la actividad mercantil, se halla a unos 3 km al noroeste de la fábrica. En esta región se ubica una de las mayores reservas minerales de Níquel del mundo, aspecto que ha funcionado como inductor de un gran desarrollo socioeconómico local y regional.

El proceso tecnológico de la fábrica de Níquel de Punta Gorda está basado en el esquema de lixiviación carbonato – amoniacal, o proceso CARON, según el cual el mineral oxidado de níquel es reducido selectivamente. Esta tecnología comienza con la extracción del mineral en las minas a cielo abierto de los yacimientos de níquel de Punta Gorda, incorporándose al flujo tecnológico, por la planta de Secaderos y Molinos, a partir de este momento el material circula por las diferentes plantas del proceso entre las que se encuentran: la planta de Hornos de Reducción, la planta de Lixiviación y Lavado, y la planta de Calcinación y Sínter, donde culmina el proceso CARON con la obtención del sínter de níquel más cobalto.

Esta tecnología puesta en práctica desde el año 1944 en Cuba, ha funcionado según dicho esquema en la fábrica de Nicaro, fundada en los años de la segunda guerra mundial.

El proceso de lixiviación carbonato – amoniacal en la fábrica “Cmdte. Ernesto Che Guevara” se caracteriza por ser un proceso donde el equipamiento tecnológico utilizado se distingue por su sencillez y utilización de equipos conocidos (hornos de soleras múltiples, espesadores, columnas de destilación, etc.), favoreciendo una producción con alto nivel de mecanización y automatización. El esquema amoniacal admite la elaboración de mezclas de minerales limoníticos y serpentínicos, mientras que el de lixiviación ácida solo permite la elaboración de la fracción limonítica.

Al mismo tiempo este proceso se realiza con un consumo de reactivos relativamente pequeño. El único que se utiliza en cantidades grandes es el amoníaco, su consumo es necesario solo para compensar las pérdidas mecánicas.

### ***Fundamento de la investigación***

Las nuevas tendencias relacionadas con el incremento de los niveles productivos y el vertiginoso desarrollo de la Unión del Níquel, demandan que cada día se perfeccionen los procesos tecnológicos y se eleve su eficiencia metalúrgica.

Dentro de una industria metalúrgica existen complejos sistemas que muestran diferentes comportamientos con dinámicas muy variadas, algunos de esos están ubicados en la planta de Hornos de Reducción y se pueden citar los enfriadores de mineral, quienes juegan un papel esencial dentro del proceso, pues en ellos se debe enfriar el mineral desde una temperatura entre  $650$  y  $700^{\circ}\text{C}$  a la salida del horno hasta una temperatura alrededor de los  $200^{\circ}\text{C}$  que sale del enfriador para pasar al proceso de Lixiviación y Lavado.

Los enfriadores cilíndricos rotatorios son muy utilizados en las industrias de procesos aunque pocos difundidos para el enfriamiento de mineral. Se han realizado diversos estudios sobre estos equipos de transferencia de calor, de los cuales este trabajo hace

mención, Góngora (2007), ha centrado su investigación a evaluar el proceso de intercambio de calor que se realiza en los mismos como objeto de modelación matemática y simulación del proceso, la cual ha presentado como inconveniente que la base de datos que suministra la industria en las condiciones actuales no es suficiente para la validación del modelo teórico, de ahí la importancia de la presente investigación.

Desde hace varios años los enfriadores han presentado problemas con el enfriamiento del mineral que llega a ellos proveniente de los hornos de reducción.

El proceso de enfriamiento en la planta de hornos de reducción de la empresa “Cmdte. Ernesto Che Guevara” se caracteriza por la siguiente *situación problémica*:

- Limitaciones de los métodos utilizados por diferentes autores para la selección y cálculo de los parámetros racionales del proceso de enfriamiento.
- En las condiciones actuales de explotación no se garantizan los parámetros adecuados para el desempeño eficiente del proceso posterior en lixiviación y lavado.
- La instrumentación disponible en la instalación no garantiza el monitoreo de ciertos parámetros que influyen en la caracterización exitosa del proceso de enfriamiento.

Esta problemática justifica la búsqueda de soluciones alternativas para una mejor aproximación a la identificación del sistema. El uso de las técnicas de inteligencia artificial facilitarían resolver una serie de incertidumbres en relación a una mejor estimación de la temperatura de salida del mineral en el proceso de enfriamiento. La variante del uso de las redes neuronales artificiales debidamente entrenada posibilitará la realización de cálculos del comportamiento del proceso para una mejor toma de decisiones.

*A partir de las deficiencias expresadas se declara como **problema de la investigación**:*

***La no existencia de una herramienta que permita identificar el proceso de enfriamiento del mineral reducido en los cilindros horizontales rotatorios de la empresa “Cmdte. Ernesto Che Guevara de Moa”, a partir de las variables medidas en el proceso.***

Como **objeto de estudio de la investigación** se plantea:

**El proceso de enfriamiento del mineral reducido.**

Sobre la base del problema a resolver se establece la siguiente **hipótesis científica**:

**Si se logran identificar los principales parámetros del proceso de enfriamiento del mineral reducido, entonces se podrá hacer una mejor predicción de la temperatura del mineral, garantizando la toma de decisiones a partir de un mejor conocimiento del sistema.**

En correspondencia con la hipótesis planteada, se define como **objetivo general del trabajo**:

**Identificar el proceso de enfriamiento del mineral reducido con el uso de Redes Neuronales Artificiales.**

Para dar solución al objetivo general del trabajo, se definen como **objetivos específicos**:

- **Seleccionar las principales variables que intervienen en el proceso de enfriamiento del mineral reducido a partir del uso de herramientas estadísticas.**
- **Proponer la estructura de la Red Neuronal Artificial que mejor identifique el proceso de enfriamiento del mineral reducido.**

Para lograr el cumplimiento del objetivo propuesto, se plantean las siguientes **tareas del trabajo**.

1. Estudio bibliográfico referente al tema.
2. Trabajo de campo para caracterizar el proceso y la selección de la bases de datos.
3. Aplicación de las herramientas estadísticas para la selección de las variables a utilizar en la creación de la Red Neuronal Artificial.
4. Entrenamiento y validación de la Red Neuronal Artificial seleccionada.
5. Análisis de los resultados obtenidos.

Los **resultados más relevantes esperados** de la investigación son:

1. El estado del arte sobre la temática tratada.
2. Obtención de una Red Neuronal que caracterice el proceso de enfriamiento del mineral reducido.

De acuerdo con la hipótesis y el objetivo propuesto, se establece como **aporte de la investigación**:

**Utilización de las técnicas de Inteligencia Artificial (Redes Neuronales Artificiales) en la caracterización del proceso de enfriamiento del mineral laterítico reducido en los cilindros rotatorios de la Planta de Hornos de Reducción de la empresa “Cmdte. Ernesto Che Guevara”.**

En el desarrollo de la investigación se aplican los siguientes **métodos**:

- ✓ Método de investigación documental y bibliográfica para la sistematización del conjunto de conocimientos y teorías relacionadas con el objeto de estudio.
- ✓ Método experimental para la selección de las variables que caracterizan el proceso de enfriamiento del mineral reducido.
- ✓ Técnicas computacionales existentes para la creación, entrenamiento e implementación de la Red Neuronal Artificial.

Para el desarrollo de la investigación se toman como base los estudios que sobre el tema de modelación matemática de procesos industriales se han efectuados por Columbié (2001); Guzmán (2001); Torres (2003), así como la información recopilada de trabajos de investigación y tesis de grado realizadas en la planta de Hornos de Reducción de la empresa “Cmdte. Ernesto Che Guevara” y “Cmdte. René Ramos Latour”.

## **CAPÍTULO I: MARCO TEÓRICO DE LA INVESTIGACIÓN**

### **I.1. Introducción**

En el presente capítulo se realiza un análisis de las diferentes publicaciones expuestas en la bibliografía especializada sobre la temática estudiada, con el fin de disponer de los elementos básicos esenciales para el desarrollo del trabajo. Se abordan además temas relacionados con el proceso de enfriamiento del mineral, el cual tiene una importancia vital dentro del proceso de obtención del Níquel y en particular los enfriadores de mineral.

La planta de Hornos de Reducción tiene una importancia vital dentro del proceso de obtención del Níquel, en ésta se crean las condiciones (reducción de los óxidos de Níquel y Cobalto) para la extracción del mineral en su forma metálica. Un eslabón importante de la planta lo constituyen los enfriadores de mineral (donde ocurre el proceso de enfriamiento), de los cuales depende en gran medida la realización óptima del proceso de Lixiviación y Lavado, en tal sentido el **objetivo** del capítulo es:

Establecer los fundamentos teóricos del proceso de enfriamiento del mineral como base para la modelación con Redes Neuronales Artificiales del mismo en la empresa “Cmdte. Ernesto Che Guevara”.

Además se presenta un resumen histórico sobre Redes Neuronales Artificiales, sus fundamentos y una breve descripción de algunos aspectos básicos.

### **I.2. Estado del Arte**

Debido a los vastos depósitos de minerales lateríticos en la costa noroeste de la actual provincia de Holguín, el Estado Cubano acordó en 1972 con el gobierno de la URSS, la colaboración técnica para la rehabilitación de las plantas Niquelíferas, “Cmdte. Pedro Sotto Alba” y “Cmdte. René Ramos Latour” y la posible construcción de una nueva planta de Níquel en Moa (Miranda, 2003), la que, fruto de esa colaboración, se encuentra al norte del yacimiento mineral de Punta Gorda, a 4 km de la ciudad de Moa y a 2 km del pueblo de Punta Gorda.

A pesar de los problemas técnicos presentados para el arranque, la “Cmdte. Ernesto Che Guevara”, hace su primera producción de Níquel, el 27 de enero de 1986. Para llegar a estos resultados, principalmente se realizaron diversas pruebas, con el mineral del yacimiento de Punta Gorda en la Planta Piloto de Nicaro (Chan, 1999). Consultando la literatura especializada se observa que ésta no aborda teoría alguna relacionada con los enfriadores de mineral. Los textos básicos que abordan los aparatos de tecnología química y de transferencia de calor como Kern (1999) y Perry's (1999) por solo mencionar dos, no muestran una metodología o procedimientos que permita evaluar los enfriadores, solo el último se limita a hacer una descripción teórica del equipo y su principio de funcionamiento. No siendo así en relación a otros equipos como son los secadores de mineral y los hornos cilíndricos rotatorios de los cuales si aparece una amplia variedad de criterios para su diseño y evaluación.

Debido a que en la empresa “Cmdte. Ernesto Che Guevara”, no existe bibliografía alguna sobre las modificaciones y aportes realizados a estos equipos, a modo de resumen se pueden referenciar algunos de los trabajos realizados por ingenieros e investigadores de la empresa “Cmdte. René Ramos Latour”.

Se consideran importantes los trabajos realizados por Gan (1970), quien realizó un análisis completo sobre los mecanismos de transferencia de calor que provocan el enfriamiento del mineral reducido cuando se introduce vapor de agua en la atmósfera del enfriador. Alonso (1973), construyó un modelo experimental de un enfriador teniendo en cuenta el coeficiente de llenado y la fuerza centrífuga, observando el movimiento de mineral dentro de los tambores rotatorios, determinando que el ángulo formado por la superficie del mineral con la horizontal oscila entre los 20 y 25°.

Presillas (1977), expone que en el periodo de 1943 a 1946 debido a la ineficiencia de los enfriadores se hicieron varias modificaciones, como la instalación de vibradores, el uso de cadenas en los extremos, se dividió el enfriador en varias secciones. Alepuz (1977), determinó la velocidad periférica de los enfriadores de la planta metalúrgica y la replicó con un tanque de paredes lisas, comprobando que la cama de mineral formaba un ángulo de 22 a 26° con respecto a la horizontal.

Gan (1978), analizó teóricamente los cambios que experimentan los mecanismos de transferencia de calor en el enfriador al inyectar vapor de agua. Gángara (1980), plantea experimentar en un enfriador de mineral de Planta Vieja la instalación de duchas en el interior del enfriador con agua atomizada para aprovechar el elevado calor latente de vaporización, y así, lograr disminuir la temperatura del mineral de salida. Chacón (1982) expone la importancia de los raspadores exteriores en la limpieza exterior que estaban constituido por cepillos de acero situados a nivel de su diámetro horizontal. Rosell, (1986) plantea la influencia del número de raspadores y levantadores en el proceso enfriamiento, según el fabricante se deben instalar 8 y 36 en planta vieja y 11 y 52 en planta nueva respectivamente.

Los trabajos relacionados se limitaron a la aplicación de los métodos que aparecen en las bibliografías básica y especializada de cada rama, no se impuso la búsqueda de nuevos conocimientos que dieran solución a los problemas que se manifestaban en su entorno. Esto estuvo condicionado a su vez por las limitaciones en la tecnología existente para entonces, los instrumentos de medición en los años 70 y 80 era bastante rudimentaria y los experimentos que se realizaban eran puntuales y solo permitían el estudio de comportamientos de parámetros medidos de forma aislada.

Haciendo un análisis de aquellos trabajos que se han dedicado a la modelación y simulación de procesos en la industria del níquel se pueden destacar Guzmán (2001), que modela matemáticamente y simula el sistema de los Tanques de Contacto de mineral reducido con licor carbonato-amoniaco, y Ramírez (2001), que desarrolla un modelo matemático, que refleja el comportamiento dinámico del subproceso de postcombustión de un horno de reducción de múltiples hogares, ambos emplearon como herramienta de cálculo el "Toolbox" de Identificación de MATLAB.

Por su parte Valle (2000 a, b), hace una evaluación de los enfriadores de mineral de la empresa "Cmdte. Ernesto Che Guevara" de Moa, mostrando los principales defectos que presentan en su funcionamiento.

Ha sido muy útil el trabajo presentado por Columbié (2001), quien estableció el modelo matemático para el control integral del proceso de calcinación del Carbonato Básico de Níquel en el horno tubular rotatorio, éste conformado por nueve (9) ecuaciones diferenciales en derivadas parciales que describen el comportamiento dinámico del objeto, este trabajo aportó ecuaciones nuevas muy importantes para el análisis de los procesos de transferencia de calor de mayor complejidad.

Tomando como partida el trabajo presentado por Columbié (2001), Góngora (2007), expone las ecuaciones que conforman el modelo matemático multivariable para un proceso de enfriamiento industrial de sólidos en cilindros rotatorios horizontales, estableciendo también las ecuaciones de enlace que permiten determinar los coeficientes de transferencia de calor por unidad de longitud y la fundamentación científica sobre la cual fueron obtenidas. Considerando que hasta la fecha esta es la primera aproximación que se encuentra en la bibliografía consultada sobre la modelación de los enfriadores de mineral reducido.

Como lo ha demostrado la bibliografía consultada los enfriadores de mineral presentan problemas desde 1943 según Presillas (1977), de los cuales algunos han sido solucionados pero aún persiste la baja eficiencia en los mismos.

### **I.3. Trabajos precedentes**

La búsqueda bibliográfica también permitió la consulta de un grupo de publicaciones que se ha realizado a nivel internacional y que en su mayoría abordan los cilindros horizontales rotatorios, entre los que se mencionan.

Peller (1984), experimenta con un fluido termodinámico calentado en un cilindro circular giratorio, teniendo en cuenta parámetros como la intensidad del fluido, y la carga de temperatura, empleando un número de Reynolds de  $8.3 \cdot 10^3 < Re_f < 7.1 \cdot 10^4$  y un número de Nusselt de 300. Iannetta (1992), experimenta en campos termales en cilindros excéntricos horizontales, para Rayleigh entre  $1.07 \cdot 10^4 \leq Ra_L \leq 8.27 \cdot 10^4$ . Chen (1997),

investigó sobre la convección de doble difusividad para un cilindro calentado sumergido en una capa fluida de sal estratificada.

Olivas (1997), realiza la simulación en un cilindro circular bajo convección forzada para un número de Reynolds de 10 y 200 empleando las soluciones numéricas de Navier-Stokes y las ecuaciones de transporte de masa. Peng (1998), analiza la película de condensación laminar en el interior de la pared de un cilindro giratorio con un raspador. Hossain (1998), estudia la interacción de la radiación-conducción en la convección mixta de un cilindro circular horizontal cuando la temperatura de la superficie es uniforme usando el método de diferencia finita. Mahfouz (1999), combina la convección (forzada y natural) de un cilindro horizontal que transmite oscilaciones rotatorias en dimensiones infinitas de fluidos. Naumenko (2001), determina numéricamente el comportamiento de un flujo viscoso bidimensional influenciado por los procesos de intercambio de calor en la superficie libre de un cilindro horizontal estacionario. Dorokhov y Kileeva (2001), presentan los resultados de un análisis de datos experimentales en el intercambio de calor en los cilindros horizontales rotatorios con un flujo en su interior de gas-líquido. Scurtu (2001), analiza la convección libre entre dos cilindros concéntricos horizontales y presenta las líneas e isothermas que corresponden a estos modos críticos. Gschwendtner (2004), investigó por medio de las técnicas de medición óptica y el traslado de calor de un cilindro giratorio en un flujo de aire-cruzado. Yapici (2004), investiga las temperaturas y la distribución de tensión termalmente inducidas en un cilindro calentado. Mahfouz (2003), investiga el problema de la convección libre de un cilindro isotérmico puesto horizontalmente en un fluido micropolar. Nazar (2004), hace un estudio teórico de la convección en un cilindro circular horizontal con un flujo de calor de superficie constante sumergido en un fluido viscoso e incompresible. Wang (2004), experimenta bajo diferentes condiciones con el transporte de gránulo y el tiempo de residencia medio en un tambor horizontal rotatorio. Shrager (2004), realiza la modelación de un flujo viscoso con una superficie libre dentro de un cilindro horizontal giratorio el flujo es un líquido de alta viscosidad que parcialmente llena un cilindro horizontal que gira a velocidad constante.

Ha quedado demostrado a través de la bibliografía consultada que hasta la fecha no se ha encontrado un criterio sólido, sustentado por un sistema de conocimiento que permita

modelar y simular el comportamiento del proceso de enfriamiento de mineral reducido en cilindros horizontales rotatorios.

Como se pudo observar en los trabajos consultados, no todos abordan el proceso relacionado con los cilindros horizontales rotatorios, solamente Valle (2000 a, b) y Góngora (2004), (2007) abordan el estudio de ese proceso de enfriamiento lo cual constituye objeto de estudio de esta investigación.

No obstante ellos abordan la temática relacionada con la teoría general de los sistemas y la metodología de las investigaciones sistémicas y conceptualizan con claridad los métodos sistémicos de análisis del conocimiento científico, permitiéndole al investigador su empleo para sustentar teóricamente la investigación. Muestran un correcto diseño de la metodología de la investigación, siendo esta muy necesaria en la realización de este trabajo.

También se registran algunos trabajos desarrollados por entidades especializadas, ellos se relacionan a continuación:

En el informe técnico de la Empresa “Cmdte. Ernesto Che Guevara” (1998) la firma BOLIDEN CONTECH, propone introducir para el mejoramiento del enfriador: adicionar 60 m<sup>2</sup> de superficie extendida, distribuida en el interior del shell en la primera mitad del equipo, además instalar una bomba de 100 m<sup>3</sup>/h, filtros y válvulas para recircular agua en la piscina controlando flujo y temperatura, instalar raspadores y agitadores mejorados para aumentar la capacidad de mezclado de mineral. Propone además el diseño y construcción de un enfriador paralelo al existente y dividir la descarga de cada horno a un enfriador para lo cual ofrece plena garantía. Prior Industries Australia está en desacuerdo con el concepto de un enfriador simple alimentado por dos hornos.

TUNRA (1998), encargada para la investigación de las propiedades del mineral concluyó que la conductividad térmica del mineral es deficiente y se reduce con la disminución de la temperatura, de modo que solamente el mineral más próximo al shell es enfriado. Sus recomendaciones son encaminadas a incrementar el área efectiva de los enfriadores o

asegurar un buen mezclado de mineral en su interior para obtener 150 °C a 38 t/h reducidas.

En general la literatura recoge pocos intentos de estudios experimentales de los cilindros rotatorios al parecer por la dificultad de realizar mediciones en dicho agregado, particularmente en condiciones industriales. Las más relevantes de éstas han involucrado a hornos tubulares rotatorios de amplia escala, pero debido a lo mencionado anteriormente carecen de una data de flujo de calor preciso y adecuado.

Una de las modelaciones con mayor tendencia en la actualidad, la ha estado asumiendo el método de redes neuronales, aplicada en el campo de la eléctrica, procesos sociales entre otros. Se han encontrado pocos estudios referentes a la aplicación de las redes neuronales en el campo de la Transferencia de Calor y masa.

La ciencia de las Redes Neuronales Artificiales, hace sus primeras apariciones significativas en la década de los cuarenta, cuando los investigadores (Mc Culloch, Pitts, Hebb, Rosenblatt, Widrow) desarrollaron modelos de hardware y software de las neuronas biológicas y de su sistema de conexiones intentando reproducir el comportamiento del cerebro. La investigación en este campo comenzó con dos grandes limitantes:

- Computadoras lentas y con poca memoria.
- Lenguajes de programación de muy bajo nivel.

Unas décadas después el desarrollo electrónico ya era otro y es a partir del año 1982 en que Hopfield utilizando propiedades matemáticas interesantes y un modelo no lineal salvó los problemas presentados anteriormente. A partir de entonces las Redes Neuronales Artificiales han despertado gran interés a nivel mundial y se han desarrollado más de 40 modelos (variantes de los pioneros) que exhiben características cada vez más atractivas.

#### **I.4. Redes Neuronales Artificiales.**

Se puede considerar una Red Neuronal Artificial como un modelo matemático de las "teóricas" actividades mentales y cerebrales. Estos sistemas explotan el procesamiento

local en paralelo y las propiedades de la representación distribuida, aspectos que al parecer existen en el cerebro. En la comunicación diaria se utilizan habitualmente información imprecisa, que generalmente el cerebro procesa muy bien, generando incluso nuevo conocimiento. Esto lleva a considerar la lógica difusa y los conjuntos difusos, de gran interés hoy día en Inteligencia Artificial y en los Sistemas Expertos, y sus relaciones con las Redes Neuronales Artificiales.

En 1943, McCulloch y Pitts simularon una neurona biológica mediante un dispositivo electroquímico con varias entradas y una salida activada como un autómata o umbral, permitiendo sólo valores binarios.

#### **I.4.1. Fundamentos de Redes Neuronales Artificiales.**

A las Redes Neuronales Artificiales también se las nombra como Sistemas Neuronales, Sistemas Adaptables o Adaptativos, Redes o Sistemas Conexionistas, Neurocomputadores o Procesadores Paralelos Distribuidos. Hay varias definiciones formales de una Red Neuronal Artificial (Hecht-Nielsen , Arbid, .. ).

Una definición no tan formal se debe a Simpson: Una Red Neuronal Artificial es "Un grafo dirigido y no lineal con arcos ponderados, capaz de almacenar patrones cambiando los pesos de los arcos, y capaz de recordar patrones a partir de entradas incompletas y desconocidas"

El planteamiento y análisis de los modelos matemáticos, propuesto por diferentes autores, permiten en toda investigación, realizar la identificación más apropiada de las variables de un proceso. Basado en el planteamiento anterior, se ha propuesto el tema de las redes neuronales, sus características básicas y sus diferentes aplicaciones con sus algoritmos de aprendizaje.

En el caso general de procesos dinámicos no lineales pueden distinguirse básicamente dos tipos de modelos de funcionamiento normal: los modelos físicos y los modelos de caja negra. Los primeros aplican leyes físicas para ligar las variables que intervienen en el proceso. Los parámetros que intervienen en dichas ecuaciones tienen un significado físico,

de tal forma que el conocimiento queda explícitamente reflejado en ellas. Sin embargo la obtención y utilización de estos modelos no siempre es posible. En primer lugar la complejidad de los procesos que hay que modelar hace que su modelado físico sea muy costoso e incluso una vez obtenido el modelo, el tiempo de cálculo necesario para su evaluación puede hacerlos inutilizables para una aplicación en tiempo real como es el diagnóstico. Por otro lado los modelos físicos requieren datos de diseño que conllevan dos problemas. En primer lugar resulta difícil y en ocasiones imposible extraer todos los datos necesarios de la documentación de diseño. En segundo lugar la experiencia demuestra que el comportamiento real de los componentes dista mucho de lo predicho por los datos de diseño.

Los modelos de caja negra están basados en criterios estadísticos capaces de modelar las relaciones existentes entre un conjunto de entradas y otro de salidas. Estas variables externas son variables físicas, pero el resto de variables y parámetros envueltos en el modelo pueden no tener significado físico. Los parámetros del modelo se ajustan a partir de un conjunto de medidas reales que caracterizan el comportamiento del proceso en condiciones de normalidad.

Los modelos de caja negra basados en criterios estadísticos clásicos ([Box-Jenkins, 1976]) presuponen un comportamiento lineal del proceso, y se limitan a ajustar los parámetros de modelos lineales para dar forma a la relación de entrada y salida. Esta limitación plantea la necesidad de establecer una metodología clara de modelado que permita generar de forma automática una relación funcional, en general no lineal, que se adapte al conjunto de medidas representativo del comportamiento normal del proceso.

El resurgimiento de las técnicas conexionistas, y en concreto el de las Redes Neuronales Artificiales supervisadas ([Rumelhart et al., 1986b]), trajo consigo el desarrollo de nuevos aproximadores funcionales no lineales con extraordinarias capacidades de representación y adaptación. Estas nuevas herramientas han servido como base para la extensión de la teoría clásica de identificación de sistemas ([Ljung, 1987]) al campo no lineal ([Ljung & Sjöberg, 1992], [Sjöberg, 1995]). Sin embargo, el desarrollo de las Redes Neuronales Artificiales tuvo la desgracia o la gran ventaja de tener su origen en la psicología. Este

origen, escabroso para algunos y apasionante para otros, ha motivado el que la comunidad científica relacionada con la identificación de sistemas haya retrasado su primera cita con estas “nuevas” herramientas hasta hace pocos años. La espera ha dado lugar al nacimiento de una nueva terminología conexionista, cuyos conceptos ya tenían nombre en el área de la identificación de sistemas. Así, el profesor L. Ljung propone en [Ljung & Sjöberg, 1992] el siguiente diccionario:

Estructura del modelo	Red
Orden del modelo	Número de unidades ocultas
Estimación	Aprendizaje, entrenamiento
Datos de estimación	Conjunto de entrenamiento
Iteración	Ciclo de entrenamiento
Validación	Generalización
Datos de validación	Conjunto de generalización
Algoritmo recursivo del gradiente	Retropropagación
Sobre-ajuste	Sobre-entrenamiento

En definitiva se puede concluir que las Redes Neuronales Artificiales se presentan como una herramienta de aproximación funcional a tener en cuenta en todo problema de identificación de sistemas con características no lineales. Estas características han multiplicado el número de aplicaciones de Redes Neuronales Artificiales a la detección y aislamiento de anomalías basados en modelos ([Sorsa et al., 1991], [Chow et al., 1993], [Los Arcos et al., 1993],[Ayoubi & Isermann, 1994], [Renders et al., 1995], [Polycarpou & Vemuri, 1995]).

#### **A) Elementos a considerar en el Diseño Estructural:**

- Neuronas (Procesadores Elementales).

Son los elementos donde se hace todo el procesamiento. Muchas veces se refiere también como Neurona Artificial a los nodos de entrada, aunque en ellos no se hace procesamiento ninguno. En las Neuronas Artificiales ellas hacen siempre un proceso de Agregación de las entradas, generalmente ponderadas, para obtener el nivel de Excitación

(S) de la Neurona Artificial, y después una Activación de la Neurona Artificial, que depende del nivel de Excitación, de acuerdo con una función de Activación  $F(S)$ . Entonces, las Neuronas Artificiales sólo manejan información local, que viene por las entradas, y producen un solo valor de salida, que puede ir como entrada de otras Neuronas Artificiales.

- Agregación de entradas.

En general, la excitación de la Neurona Artificial se obtiene como una suma ponderada de las entradas, ecuación 1.1. Cada entrada tiene un peso asignado (o aprendido) y S es la combinación lineal de las entradas y los pesos:

$$S_j = \sum X_i W_{ij} \quad (1.1)$$

En este caso, la salida es una función de las entradas y los pesos, ecuación 1.2.

$$Y_i = F(X, W_j) \quad (1.2)$$

No obstante, se han usado otras formas de agregación que básicamente se pueden resumir en las siguientes:

- Entradas con ponderación Media-Varianza.

Se considera que cada entrada a la Neurona Artificial tiene dos pesos, uno que indica la media de una clase (que se representa por esa entrada) y el otro la varianza. La salida se obtiene a través de la ecuación 1.3.

$$Y_j = g \left( \sum (W_{ij} - X_i)^2 / V_{ij} \right) \text{ con } g(x) = \exp(-x^2 / 2) \quad (1.3)$$

- Entradas Max-Min.

Las conexiones de entrada a la Neurona Artificial se ponderan con valores mínimos y máximos de la clase. Para cada valor de entrada, la cantidad que cae fuera de estas cotas

sirve para la activación de la neurona. De alguna forma se puede entender como un grado de pertenencia.

- Funciones de activación.

Las funciones de activación más usadas, son: Lineal; Salto; Salto lineal; Aplastamiento (Sigmoide, Tangente Hiperbólica o Razón Aumentada de Cuadrados) y Gaussiana (es más una función de ganancia que depende de ponderaciones de media y varianza, salvo que la varianza esté prefijada).

• Conexiones.

Las conexiones entre Neuronas Artificiales son generalmente dirigidas (de la Neurona Artificial origen a la destino). Cuando el flujo puede ir en las dos direcciones, se representa por un arco no dirigido, en vez de dos con direcciones opuestas. Si la Red Neuronal Artificial está organizada en capas, se pueden diferenciar las conexiones hacia adelante (feedforward) de las de retroalimentación (feedback) y, a veces, conexiones Intercapas de las Intracapas. Por otro lado, se distinguen también conexiones excitadoras (pesos positivos) e inhibitoras (pesos negativos) .El peso 0 indica ausencia de conexión. El umbral de las neuronas se representa en muchas ocasiones, porque además se facilita el proceso de cálculo, mediante una entrada de Tendencia (bias), que está siempre fijada a uno. Los pesos de las conexiones de esta entrada a las diferentes Neuronas Artificiales representan realmente un nivel de Umbral de la Neurona Artificial.

• Topología concreta de la Red.

Con los elementos anteriores, se puede concretar la estructura de la Red Neuronal Artificial, teniendo en cuenta, el tipo de neuronas (datos binarios o reales), si se consideran capas (y cuántas) de procesamiento de la información o conexión total, si todas las neuronas o capas usan la misma función de activación, el tipo de conexiones, etc. En general, se pueden resumir las estructuras en dos tipos: Red Neuronal Artificial de Propagación hacia delante (por capas) y Red Neuronal Artificial Recurrentes (no hay capas distinguibles), aunque también se usan modelos mixtos.

- Conjunto de Entrenamiento.

Las Redes Neuronales Artificiales no pueden ser usadas sin datos. Según el tipo de aprendizaje, se necesitan sólo ejemplos de entrada, o pares de ejemplos (entrada, salida esperada). La selección de un conjunto de datos adecuado, tanto para el entrenamiento como para la verificación del aprendizaje (prueba), es un punto importante y difícil al mismo tiempo. Volveremos a tratar este punto al estudiar los modelos concretos.

## **B) Aprendizaje**

Aprendizaje es el proceso de adaptación de los pesos de las conexiones de una Red Neuronal Artificial para conseguir que la respuesta de esta sea la deseada para ejemplos usados o no en el aprendizaje o entrenamiento. Muchas veces, este proceso depende de la topología de la red. No obstante, podemos clasificar todos estos procedimientos, por un lado, en Supervisado o No Supervisado, según que se utilicen (o no) salidas esperadas en los ejemplos de entrenamiento, y por otro lado, en fuera de línea o en línea, según que el proceso requiera un entrenamiento completo con todos los ejemplos, antes de ser usada, o que se pueda añadir nueva información sin necesitar un reentrenamiento de la información almacenada.

### **I.4.2. Aplicaciones generales de las Redes Neuronales Artificiales**

Como se dijo antes, en los últimos años ha crecido rápidamente el interés por las redes neuronales y debido al desarrollo teórico y las aplicaciones diversas que han tenido, profesionales de diversos campos solicitan aplicaciones en sus disciplinas.

Al utilizarlas es posible aplicar la computación a reinos restringidos hasta ese momento sólo a la inteligencia humana, hacer máquinas que aprendan y recuerden en forma notablemente semejante al proceso mental humano y dar un nuevo e importante significado al término "inteligencia artificial".

Por lo general no se trabajan de forma independiente sino que son integradas a un sistema, para ello el problema complejo de interés se descompone en tareas más simples y las Redes Neuronales Artificiales resuelven un subconjunto de ellas.

Las aplicaciones típicas son:

- Problemas del tipo de clasificación y/o reconocimiento de formas, imágenes, voces, etc.
- Sistemas de Diagnóstico.
- Sistemas de Identificación y Control.
- Robótica.
- Modelación etc.

El procedimiento convencional utilizado para construir Redes Neuronales Artificiales capaces de realizar una determinada tarea consiste en una elección adecuada de sus características más una estructura conveniente.

#### **1.4.3. Aplicaciones de la red Backpropagation**

Actualmente, este tipo de redes se están aplicando en distintas clases de problema debido a la naturaleza general del proceso de aprendizaje. Algunos de los campos generales de aplicación son:

- Codificación de Información.
- Traducción de texto a lenguaje hablado.
- Reconocimiento de lenguaje hablado.
- Reconocimiento óptico de caracteres (OCR).
- Software de Redes Neuronales.

#### **1.5. Introducción al proceso de enfriamiento en la Planta de Hornos**

En la industria, el mineral se incorpora al flujo tecnológico por la Planta de Secaderos y Molinos, donde es descargado en las tolvas de recepción, con dos sistemas paralelos, uno trabajando y el otro de reserva. Una vez homogenizado, el mineral es enviado al proceso de secado, reduciéndose en éste la humedad hasta 4,5 % y enviándose luego a la sección de molienda, mediante transportadores de bandas; en los cuales se le agrega al mineral alrededor de 2,9 % de petróleo tecnológico. El mineral seco y triturado es enviado a la Planta de Hornos de Reducción donde ocurre la reducción del óxido de níquel. Luego el

mineral es enviado a los enfriadores donde cede calor y se enfría para ser mezclado con licor amoniacal de retorno en la canal de prelixiviación de la cual pasa a los tanques de contacto. Ya en la Planta de Lixiviación y Lavado, el mineral pasa a través de tres sistemas paralelos de lixiviación de tres etapas a contracorriente, la lixiviación se lleva a cabo con licor carbonato amoniacal que contiene el 6 % de Amoníaco y 3 % de Ácido Carbónico mediante la formación de la pulpa. Este licor producto y la pulpa de colas se transportan a la Planta de Recuperación de Amoníaco donde se extrae el níquel en forma de carbonato básico y se recupera el amoníaco. Durante este proceso el amoníaco se elimina del licor y se precipita el Carbonato Básico de Níquel. La tecnología CARON culmina con los procesos de la Planta de calcinación y Sínter donde se obtiene el producto final. El carbonato básico de níquel húmedo se somete al proceso de calcinación, donde es transformado en óxido de níquel, el cual se sinteriza logrando finalmente el Sínter de Níquel con aproximadamente de 86 a 91 % de níquel, listo para ser exportado y comercializado.

### **I.5.1. Proceso tecnológico de la Planta de Hornos de Reducción**

El objetivo del proceso que se realiza en esta planta es reducir el óxido de níquel a níquel metálico, haciéndolo apto para la lixiviación amoniacal. Para ello la planta cuenta con la instalación de 24 hornos, 12 transportadores rotatorios e igual número de enfriadores.

El mineral, después de pasar por la sección de molienda, es enviado mediante transporte neumático a los silos como forma de almacenaje desde donde el mineral es bombeado hasta las tolvas de los hornos (12 en total), dispuestas una para cada dos hornos. Estas tolvas permiten realizar una operación de 8 horas a cada horno. Luego éste pasa a los dosificadores de pesaje automático que son los equipos encargados de garantizar una alimentación uniforme al horno a través del pesaje que este realiza de acuerdo al tonelaje fijado, estos equipos tienen una capacidad hasta de 22 t/h . Luego se produce la descarga del mismo al sinfín alimentador el cual lo transporta al horno hacia el hogar cero.

El mineral una vez dentro del horno es sometido al proceso de reducción, el que se logra estableciendo un perfil de temperatura dentro del mismo y una concentración determinada de gases reductores ( $\text{CO} - \text{H}_2$ ) para ello el horno dispone de 10 cámaras de combustión

dispuestas en los hogares 15, 12, 10, 8 y 6, con quemadores de petróleo a alta presión, que son los encargados de producir los gases para el calentamiento del mineral, lo cual permite además de lograr el perfil de temperatura enriquecer la atmósfera reductora del horno ya que trabaja con combustión incompleta. Este movimiento o traslado del mineral de un hogar a otro se realiza en forma de zigzag, ya que los hogares pares tienen su descarga por la periferia y los hogares impares por el centro. Así el mineral en su descenso es sometido a un perfil ascendente de temperatura que permite un calentamiento gradual, a la vez que penetra en un perfil gaseoso que garantiza un aumento en la concentración de reductores.

La atmósfera reductora es controlada mediante la relación CO<sub>2</sub> / CO en H-10 que debe ser de 1,2 % , según el perfil típico de temperatura que se muestra en la tabla 1.1.

**Tabla 1.1** Perfil típico de temperatura en el horno de reducción.

Hogar	T Gas	Hogar	T Gas
H0	350 °C	H9	710 °C
H4	720 °C	H11	720 °C
H6	690 °C	H13	740 °C
H7	695 °C	H15	760 °C

En estas condiciones, es posible el desarrollo de las reacciones de reducción a pesar del corto tiempo de retención del mineral en el horno (90 min).

1.  $\text{NiO}_{(s)} + \text{CO} (\text{H}_2) \rightarrow \text{Ni met} + \text{CO}_2 (\text{H}_2\text{O})_{(g)}$
2.  $3\text{Fe}_2\text{O}_3_{(s)} + \text{CO} (\text{H}_2) \rightarrow 2\text{Fe}_3\text{O}_4 + \text{CO}_2 (\text{H}_2\text{O})_{(g)}$
3.  $\text{Fe}_3\text{O}_4_{(s)} + \text{CO} (\text{H}_2) \rightarrow 3 \text{FeO} + \text{CO}_2 (\text{H}_2\text{O})_{(g)}$
4.  $\text{FeO}_{(s)} + \text{CO} (\text{H}_2) \rightarrow \text{Fe met} + \text{CO}_2 (\text{H}_2\text{O})_{(g)}$

Esta operación se complementa con la introducción de aire en los hogares 4 y 6 (2000 m<sup>3</sup>/h) para la postcombustión de los gases con un cierto contenido de CO y H<sub>2</sub> no

consumidos en la reacción química, para evitar un incremento de las concentraciones de los mismos en el sistema de limpieza de gases (precipitador electrostático), al mismo tiempo se aprovecha el calor de reacción exotérmica liberado en la combustión para facilitar el perfil de temperatura ideal en el horno.



### **I.5.2. Descripción de la instalación de estudio.**

Después que el mineral sale de los hornos es transportado por el tambor rotatorio hasta el enfriador.

El transportador rotatorio consta de un cuerpo tubular que rota en 6 rodillos de apoyo. Dentro del cuerpo está colocado un tornillo transportador. El cuerpo tiene 6 llantas, cada una se asienta en 2 rodillos de apoyo. La rotación del cuerpo se realiza por el accionamiento electromagnético. Los desplazamientos axiales posibles del cuerpo del transportador son asimilados por dos rodillos de apoyo, el cuerpo se enfría con agua.

El mineral después de pasar por el transportador rotatorio es descargado en el enfriador rotatorio, el cual tiene como función enfriar el mineral reducido que sale del horno hasta una temperatura por debajo de 200 °C para luego enviarlo al proceso de Lixiviación. Ellos están diseñados para enfriar el mineral reducido que contiene Níquel y una parte de hierro oxidado con vapor en el proceso de tratamiento del mineral niquelífero por el método amoniacal en las condiciones de trabajo que muestra la tabla 1.2.

**Tabla 1.2** Parámetros de explotación del enfriador de mineral.

<b>Parámetros de trabajo del enfriador</b>	<b>Valores Nominales</b>
Temperatura del mineral a la entrada	650 a 700 °C
Temperatura a la salida	200 °C
Temperatura del agua en la entrada	30 °C
Presión de trabajo	0,01 a 0,02 kPa
Consumo de agua para enfriar el tambor.	107 m <sup>3</sup> /h
Consumo de agua para enfriar los cojinetes.	1 m <sup>3</sup> /h
Presión excesiva del agua.	300 kPa
Temperatura del agua a la salida de la piscina.	70 °C
Coeficiente de llenado del tambor con el material.	9 %

El material enfriado es un mineral que contiene una granulometría de 200 mesh (0.074 mm) que pasa al tambor a través de un muñón de tope del enfriador. Con el paso del mineral, este se enfría con el contacto del cuerpo del tambor con el agua de la piscina.

El mineral que sale del enfriador cae a una de las canales de Lixiviación, por donde se introduce una corriente de una solución carbonato amoniacal formando una pulpa que va a los tanques de contacto, los cuales tienen una capacidad de 70 m<sup>3</sup>. Esta pulpa es bombeada a la planta de lixiviación y lavado mediante las bombas instaladas.

### **I.6. Modelación termodinámica de los sistemas de intercambio de calor.**

Tradicionalmente existen métodos de abordar problemas de modelación aplicando herramientas que están basadas fundamentalmente en la primera y la segunda ley de la termodinámica. Para la aplicación de estos modelos es necesario tener una vasta información de las características del equipamiento que interviene en el proceso termodinámico, coeficientes de traspaso de calor en los intercambiadores, así como las efectividades térmicas de los mismos.

En la etapa de diseño de un sistema resulta fácil determinar la efectividad térmica del intercambiador debido a que se cuenta con los detalles constructivos del intercambiador

de calor, además de las condiciones nominales de operación que se esperan del mismo y los datos del fabricante. Un aspecto diferente se presenta durante la operación del sistema, cuando por razones de tiempo de trabajo, de variaciones del clima, de variaciones en los regímenes de operación y flujo, así como el ensuciamiento y deterioro de las superficies de intercambio de calor, cambian los coeficientes de transmisión de calor, y por tanto, la efectividad del mismo. De modo que resulta necesario utilizar métodos de experimentación en los sistemas para caracterizar las nuevas condiciones de operación que son constantemente cambiantes, lo cual requiere prolongado tiempo e introduce ciertas incertidumbres.

En los modelos tradicionales para el estudio del comportamiento de un intercambiador de calor se parte de las relaciones termodinámicas fundamentales de cada componente del sistema en cuestión, tales como los que se describen a continuación:

### **1.6.1 Análisis crítico de la modelación termodinámica del sistema de enfriamiento del mineral reducido.**

El análisis crítico al modelo teórico del proceso de enfriamiento del mineral reducido se hace para el modelo físico – matemático planteado por Góngora (2007).

Tomando como punto de partida el principio fundamental de conservación de la energía, el cual plantea que: la energía ni se crea, ni se destruye; solo se transforma, se puede obtener la expresión matemática que servirá como ecuación de balance (1.1).

$$-\rho \cdot C \cdot A \, dx \frac{\delta\theta(x,t)}{\delta t} = -C \cdot \dot{m}[\theta(x,t) - \theta(x + dx,t)] + K_1 dx [\theta(x,t) - \theta_p(x,t)] \quad (1.1)$$

$$\dot{m}_{entrada} = \dot{m}_{salida} = \dot{m}$$

Donde:

- $\dot{m}_{entrada}$ ,  $\dot{m}_{salida}$  - Flujo de mineral que entra y que sale del enfriador; kg/s
- $\theta$ ,  $\theta_p$  - Temperatura del mineral y de la pared; K

- $C$  - Calor específico del mineral; kJ/kg K
- $\rho$  - Densidad del mineral; kg/m<sup>3</sup>
- $A$  - Sección transversal del sólido; m<sup>2</sup>
- $K_1$  - Coeficiente superficial de transferencia de calor del sólido a la pared por unidad de longitud; W/m K

En la expresión (1.1) el miembro izquierdo caracteriza la velocidad de variación de la temperatura en el tiempo  $\theta(t)$  del elemento de material  $dx$ ; el primer miembro de la derecha relaciona el calor que entra con el flujo de material al elemento  $dx$  y el calor que sale con el material; el tercer y cuarto término son el calor entregado por el material a los gases y a la pared del cilindro respectivamente según la ley de Newton.

Para la aplicación de la ecuación 1.1 es necesario conocer el área que ocupa el mineral en el interior del cilindro. Existen varios investigadores que se han dedicado a establecer la relación entre los parámetros que caracterizan el proceso y el área que ocupa el mineral.

El área de la sección transversal del sólido se calcula según la expresión (1.2), desarrollada por Columbié (2001).

$$A = \frac{2}{3} R_i^2 \cdot \beta^3 \quad (1.2)$$

Donde:

- $R_i$  - Radio interior del cilindro; m

Para ello es necesario determinar el ángulo ( $\beta$ ), mostrado en la Figura 1.2, según la ecuación (1.3).

$$\beta = \sqrt[3]{\frac{3\dot{m}}{2 \cdot R_i^2 \cdot \rho \cdot V_m}} \quad (1.3)$$

Donde:

$V_m$  - Velocidad del sólido; m/s



**Figura 1.2** Representación del ángulo  $\beta$ , con respecto al diámetro vertical y al área que ocupa el mineral dentro del cilindro.

La velocidad del sólido según expresión desarrollada por Diomidovskiy D.A. en el Instituto de Minas de Leningrado, referenciado por Chang (1997), se calcula mediante la ecuación (1.4).

$$V_m = 5,78D_i \cdot \varphi \cdot n \quad (1.4)$$

Donde:

- $\varphi$  - Ángulo de inclinación del cilindro; °
- $n$  - Velocidad de rotación; 1/s

Analizando las ecuaciones planteadas desde la 1.1 a la 1.4 se observa que las mismas se establecen con el objetivo de determinar la intensidad de la transferencia de calor del mineral al cilindro y para ello es necesario tener en cuenta las propiedades termo físicas del mineral, como son: conductividad térmica, calor específico, densidad y densidad aparente, todas en un rango de 100 a 700°C , para lo cual no se cuenta con la instrumentación requerida. Otro aspecto señalar es que para determinar el área de transferencia de calor del mineral en contacto con el cilindro es necesario obtener experimentalmente una ecuación matemática que describa el comportamiento del mineral dentro del cilindro, ya que la bibliografía recoge una serie de ecuaciones que fueron obtenidas para objetos de estudios similares como un horno de calcinación o un secador, donde el sistema de carros, levantadores o rastrillos que poseen en su interior no tienen semejanza alguna con los que usan los enfriadores y que aunque en cierta medida son

cilindros horizontales rotatorios se introducen errores que alejan los resultados obtenidos de los reales.

Otro aspecto a destacar es que para la validación de la ecuación 1.1 se necesita tener referencia de la temperatura del mineral en diferentes puntos en el interior del cilindro lo cual es muy complejo a escala industrial y de hacerlo a escala de laboratorio, habría que incursar en el escalado y las teorías de las semejanzas térmicas e hidromecánicas para el objeto de estudio, haciendo aún más compleja la investigación.

Del balance térmico para la pared, según la ecuación diferencial de la conducción se obtiene la expresión (1.5).

$$C_p M_p dx \frac{\partial \theta_p}{\partial t} + C_p M_p \cdot a \cdot \frac{\partial^2 \theta_p}{\partial x^2} = -K_1 (\theta - \theta_p) dx - K_2 (\theta_p - \theta_{agua}) dx \quad (1.5)$$

Donde:

- $C_p$  - Calor específico de la pared; kJ/kg K
- $M_p$  - Masa de la pared; kg/m
- $\theta_{ma}$  - Temperatura del medio; K
- $\theta_{agua}$  - Temperatura del agua en la piscina; K
- $a$  - Coeficiente de temperatura; m<sup>2</sup>/s
- $K_2$  - Coeficiente de transferencia de calor de la pared del enfriador por unidad de longitud al agua de la piscina; W/m K

Para determinar el coeficiente de transferencia de calor  $K_2$ , se tienen en cuenta los modos de transferencia de calor por conducción y convección, resolviéndose a través de la ecuación (1.6).

$$K_2 = \frac{1}{\frac{\ln \frac{R_i}{R_e}}{2 \cdot \pi \cdot \lambda_{carca}} + \frac{1}{\Pi_{pca} \pi \cdot \alpha_{c.agua} \cdot D_e} + \frac{1}{\Pi_{pca} \pi \cdot \alpha_{sat.} \cdot D_e}} \quad (1.6)$$

Para el caso de la transferencia de calor de la pared al agua, se puede afirmar que las propiedades del agua y su comportamiento en un rango entre 60 y 90°C se encuentran tabulados facilitando de esta manera la evolución del proceso, la situación se complica cuando luego de un periodo de explotación aparecen incrustaciones en la parte exterior del cilindro y como el área de transferencia de calor es considerable y las incrustaciones no son uniforme en toda su longitud, se introducen errores en la medición de la temperatura de la pared del cilindro y el coeficiente de conductividad térmica del material del cilindro varía. Todo esto trae aparejado que la estimación de los coeficientes de transferencia de calor por unidad e longitud no sea correcta.

Del balance térmico para el agua, según la ecuación diferencial de la conducción (1.7).

$$\rho_{agua} C_{agua} A_{agua} dx \frac{\partial \theta_{agua}(x,t)}{\partial t} = C_{agua} \dot{m}_{agua} \theta_{agua}(x,t) - C_{agua} \dot{m}_{agua} \theta_{agua}(x+dx,t) + K_2(\theta_p - \theta_{agua})dx - K_4(\theta_{agua} - \theta_{aire})dx \quad (1.7)$$

Donde:

- $\rho_{agua}$  - Densidad del agua; kg/m<sup>3</sup>
- $C_{agua}$  - Calor específico del agua; kJ/kg K
- $A_{agua}$  - Área ocupada por agua; m
- $\dot{m}_{agua}$  - Flujo de agua; kg/s
- $\theta_{agua}$ ,  $\theta_{aire}$  - Temperatura del agua y del aire; K
- $K_4$  - Coeficiente superficial de transferencia de calor del agua al medio por unidad de longitud; W/m K

Para determinar el coeficiente de transferencia de calor por convección del agua al medio es necesario tener en cuenta la cantidad de calor que se transfiere por evaporación del agua.

Para la evaluación de la transferencia de calor del agua al aire (medio circundante) se deben conocer una serie de parámetros que caracterizan a los números adimensionales (Sh, Re, Sc,) y describen los procesos de transferencia de calor por convección y evaporación del agua al aire. Actualmente en la industria no se registra la velocidad del aire, ni las temperaturas de bulbo seco y húmedo del aire ambiente, trayendo consigo que se asuman estos parámetros y los resultados que se obtengan no sean los esperados.

El análisis del estado del arte en la modelación de sistemas de intercambio de calor, tanto de los modelos físicos de los componentes de un sistema, como aquellos desarrollados por algunos autores con un propósito determinado, indica que para obtener un detallado comportamiento de un fenómeno con elevada precisión es necesario desarrollar investigaciones de un alto nivel de complejidad, sobre todo teniendo en cuenta la alta cantidad de parámetros y variables que intervienen en la modelación. Estos datos, desafortunadamente, no siempre están disponibles y muchos de ellos varían con las condiciones de operación.

En la etapa del diseño de un intercambiador de calor es más fácil desarrollar modelos de comportamiento a partir de la información disponible de los sistemas a instalar.

Un aspecto totalmente diferente se presenta cuando se trata de investigar sistemas en operación, donde la realidad es cambiante y afectada por parámetros que muchas veces no se conocen y la descripción de su comportamiento posee un nivel de incertidumbre determinado.

Por tanto, en sistemas en operación es necesario el desarrollo de herramientas y modelos que logren reproducir de la forma más cercana a la realidad posible y que se puedan prescindir de los datos y detalles que no son directamente obtenibles desde el sistema.

En la modelación moderna de sistemas termodinámicos, existe la necesidad de implementar otras herramientas que sean aplicables a estos sistemas y que reproduzcan los resultados con exactitud adecuada y con un menor número de datos de diseño del equipamiento. Precisamente en este principio se basan los modelos termodinámicos de cajas negras en los cuales sólo es necesario conocer las entradas y las salidas de las mismas, sin tener en consideración las transformaciones internas del sistema.

Es en este marco donde se justifica la implementación de modelos de sistemas a partir de parámetros conocidos y registrados directamente en el sistema. Este es el caso de los modelos neuronales, donde a partir del conocimiento de las entradas y salidas son capaces de reproducir con alto nivel de precisión el comportamiento de un proceso, sin necesidad de tener detallada información de las relaciones internas del proceso.

### **I.7. Conclusiones del Capítulo I**

- La literatura recoge pocos intentos de estudios experimentales de los cilindros rotatorios al parecer por la dificultad de realizar mediciones en dicho agregado, particularmente en condiciones industriales.
- Las publicaciones consultadas, en su gran mayoría, se limitan al estudio de los procesos de transferencia de calor y de los números adimensionales que lo caracterizan, como el  $Re$ ,  $Pr$  y el  $Nu$  en geometrías cilíndricas, pero ninguno de los casos se asemeja al proceso objeto de estudio.
- Las Redes Neuronales Artificiales se presentan como una herramienta de aproximación funcional a tener en cuenta en todo problema de identificación de sistemas con características no lineales.
- La bibliografía consultada muestra que se puede hacer una aproximación de la identificación del proceso con ayuda de las Redes Neuronales Artificiales.

➤ **CAPÍTULO II: MATERIALES Y MÉTODOS.**

**II.1. Introducción**

En este capítulo se presenta el método para el análisis de las variables presentes en el sistema de supervisión del proceso de enfriamiento del mineral reducido. Se describe todo el proceso de tratamiento de los datos, así como el método que da solución al problema planteado por la investigación. Se exponen además los pasos para llevar a cabo la creación, entrenamiento y la generalización de la red para proporcionar un ajuste adecuado.

El objetivo de este capítulo es: establecer el método para la selección de las variables más representativas y la creación de una red neuronal artificial.

En la práctica de las investigaciones ingenieriles existen dos procedimientos fundamentales de recolección del material estadístico inicial, para la obtención posterior del modelo matemático: el experimento pasivo y el experimento activo.

El experimento pasivo: Consiste en la observación y registro de las variables de entrada y salida del proceso en el régimen normal de trabajo del objeto investigado, en la observación de las variaciones arbitrarias naturales de todas las variables tecnológicas sin la intervención activa del investigador en el transcurso del proceso tecnológico, sin la introducción de perturbaciones preconcebidas, en este. El tratamiento de los datos experimentales se realiza por el método clásico de análisis de correlación-regresión.

Es necesario señalar que el aparato matemático para tal enfoque de la investigación, se aplica solo en la elaboración de los datos experimentales.

El experimento activo: Consiste en el registro de las variables del proceso después de introducirle perturbaciones premeditadas; este se lleva a cabo según un programa racionalmente establecido, llamado matriz de planificación, donde se prevén los diapasones de variación de las variables tecnológicas controladas, necesarias al investigador.

Los métodos matemáticos en este caso se emplean no solo durante la elaboración de los datos experimentales, sino también durante la selección de las condiciones de los experimentos. Estos métodos permiten elevar significativamente la efectividad de las investigaciones experimentales y llevan el nombre de métodos matemáticos estadísticos de planificación del experimento.

La planificación del experimento es un procedimiento de selección del número y las condiciones de realización de experimentos, necesarios y suficientes para la solución de la tarea planteada con la exactitud exigida.

El objetivo de la planificación de experimentos es obtener la mayor información con gastos mínimos.

Por lo general cada investigador prefiere utilizar el experimento activo, pues como se decía anteriormente, permite estudiar el objetivo en el diapasón de variación de las variables deseado por el investigador, y obtener en determinado sentido el comportamiento de las variables partiendo de los resultados de la estimación de los coeficientes del modelo matemático. Sin embargo, en las condiciones de la gran producción ininterrumpida con frecuencia se hace necesario aplicar el experimento pasivo por resultar imposible la aplicación del activo.

Las causas de ello son las siguientes:

1. En primer lugar, en las condiciones de producción de una gran empresa con frecuencia es imposible emplear un diapasón de variación de las variables controladas, suficientemente amplio como para que se pongan de manifiesto los efectos que se investigan, ya que surge el peligro de ruptura del régimen tecnológico y de obtención de una producción defectuosa.
2. En segundo lugar, durante el experimento activo los niveles de los factores de control deben estar dados en correspondencia con la matriz de planificación y todas las variables de entrega que no son de control (incluidas las controladas) es obligatorio considerarlas dentro del campo de ruido.

Pero entre las variables iniciales no controlables puede haber bastantes variables y en este caso será imposible encontrar el extremo general fundamental de la función respuesta.

3. En tercer lugar, el campo de ruido conjuntamente con todas las variables no controlables puede resultar tan grande que el modelo matemático, obtenido a través de experimento activo, será no adecuado, es decir, no tendrá valor práctico. Por esto han surgido propuestas de conjugación del experimento activo y pasivo.
4. En cuarto lugar, las perturbaciones casuales en condiciones reales pueden suponerse incluso a los factores de control, de tal modo que con frecuencia estos no pueden ser estabilizados con el tiempo necesario en los niveles previstos por el plan. Y esto conlleva al aumento de las desviaciones de los cálculos, o a la elaboración de los datos del experimento activo según la metodología general de análisis regresional, de igual modo que durante el experimento pasivo.

Una ventaja del experimento pasivo consiste además en que sus métodos en una serie de casos permiten utilizar la documentación tecnológica vigente si ésta es confiable.

La aplicación de los métodos de experimento pasivo puede ser totalmente exitosa si se cumplen determinadas condiciones durante la realización del experimento particular y durante la elaboración de los datos obtenidos.

Entre estas condiciones imprescindibles se encuentran:

1. La correcta determinación de los puntos de toma de datos y la consideración de las desviaciones de la medición para cada variable controlada.
2. La correcta consideración de la dinámica del objeto.
3. El logro de la independencia mutua de las variables de entrada.
4. El logro de la independencia entre mediciones vecinas por medio de la consideración del tiempo de correlación de cada variable de entrada.

5. El logro de un volumen suficiente de datos experimentales.

De manera que el experimento pasivo también es necesario planificarlo, organizarlo correctamente. Es cierto que el sentido de la planificación del experimento pasivo se diferencia de cierto modo del activo.

Se propone realizar las investigaciones de un objeto tecnológico complejo según las siguientes etapas principales:

1. Conocimiento de la tecnología y apertura del proceso productivo, estudio de la documentación técnica vigente y los resultados de experimentos realizados anteriormente, confección del plan de investigaciones preliminares y su realización.

Sobre la base de los datos obtenidos se valoran las características numéricas de las variables aleatorias, las funciones de auto e intercorrelación, se construyen los campos bidimensionales de correlación, etc., y sobre esta base se hacen las consideraciones para la organización del experimento fundamental.

A juzgar por las leyes de distribución se hace la suposición sobre el método necesario de elaboración de los datos y de valoración estadística de los resultados.

2. La planificación y realización del experimento fundamental, recolección y elaboración del grupo fundamental de datos empírico-estadísticos con el objetivo de obtener la descripción matemática. En esta etapa se corrigen los puntos de toma de datos, se incluyen con análisis nuevas variables, se escoge el centro del experimento fundamental se recoge la materia prima más conveniente, se define el intervalo de tiempo  $\Delta T$  para el logro de la independencia entre mediciones contiguas, se valora el tiempo imprescindible para el experimento para obtener el volumen de datos estadísticos. La realización del tratamiento de estas de lleva a cabo según reglas que serán analizadas posteriormente.

3. Análisis e interpretación del modelo matemático obtenido en este caso se ponen de manifiesto las variables substanciales, se eliminan las no substanciales, se valora la capacidad de trabajo de la ecuación de regresión, etc.

4. Perfeccionamiento de la descripción matemática con el fin de elevar su capacidad de trabajo, en caso de necesidad se introducen variables adicionales, se instalan nuevos sensores e instrumentos de medición más exactos, se cambia el punto base para acercarse, en la nueva serie de experimentos, a la región extrema, o se toman medidas para la ampliación del rango de variación de las variables de entrada con el fin de que la región del óptimo pueda ser encontrada según una ecuación de regresión nueva ya no lineal.
5. Empleo de la ecuación de regresión corregida y con la capacidad de trabajo necesaria, para el control directo del proceso con la ayuda de las cartas de régimen óptimo o para la creación de sistemas de control óptimos y automatizados del proceso tecnológico (SCAPT). Cuando se tienen máquinas computadoras electrónicas (MCE) por ejemplo una máquina computadora de control (MCC) y suficiente cantidad de sensores la descripción matemática se corrige continuamente, se ajusta, si el proceso resulta no estacionario.

De este modo, todo el proceso de investigaciones estadístico-experimentales resulta complejo, de un gran volumen de trabajo y con frecuencia solo realizable por un colectivo de investigadores.

#### “LA CAJA NEGRA” – MODELO DE UN OBJETO DE INVESTIGACIÓN

La construcción de la caja negra está basado en el principio que plantea que “el control óptimo es posible aún cuando no se tiene una información total”. En el primer estadio de la investigación ante el experimentador surge el problema de la formalización del objeto real de investigación de la presentación de esta a través del esquema “CAJA NEGRA” (fig .4.1), durante el análisis del cual se distinguen las entradas (factores, variables independientes)  $X_1, X_2, \dots, X_K$  y salidas (parámetros de optimización, criterios de optimización, respuestas)  $Y_1, Y_2, \dots, Y_e$ . A cada juego de valores de las entradas corresponden determinados valores de las salidas, es decir entre las entradas y las salidas de la Caja Negra existe determinada relación. El experimentador abstrayéndose de los fenómenos que ocurren en el objeto investigado, variando los valores de las entradas y fijando los valores de las salidas emite un juicio sobre su comportamiento.

## ESQUEMA

La independencia matemática entre los parámetros de salida (respuestas) y los parámetros de entradas (factores) se denomina función de respuesta y tiene la siguiente forma:

$$Y = f(X_1, \dots, X_k)$$

Desde el punto de vista de la cibernética por “modelo” se entiende una descripción no absolutamente exacta del fenómeno, sino una expresión aproximada de la ley desconocida, que caracteriza satisfactoriamente los fenómenos en determinada región local del campo factorial. Partiendo de esta definición, para la descripción aproximada de un mismo fenómeno, pueden ser propuestas varios modelos diferentes. Respecto a los modelos es legítima la utilización de tales definiciones como bueno, mala, etc.

Desde este punto de vista existe una diferencia de principios entre las nociones de modelo y ley.

La ley describe unívoca, clara y estrictamente el fenómeno. La ley es una categoría absoluta; puede ser cierta o incierta, no puede ocupar ninguna posición promedio, intermedia.

### **II.2. Aplicación de las herramientas estadísticas.**

La preparación del experimento de acuerdo con el plan seleccionado consiste fundamentalmente en la preparación del objeto, selección del equipo de control, medición y registro requerido, así como en la determinación de la duración del experimento.

En calidad de objeto de investigación durante la modelación en termo energética se utilizan ampliamente tantos equipos energéticos intercambiadores de calor como sus modelos físicos (instalaciones experimentales). Antes de comenzar el experimento el objeto debe ser dotado de los equipos de control y regulación requerida, que permitan medir y regular los parámetros dados.

La selección de los medios de mando y control de los parámetros se realiza individualmente, partiendo de la tarea concreta de investigación.

Después de seleccionar los equipos correspondientes se pasa a la definición del número de ensayos para la duración acordada del experimento.

Durante el experimento pasivo según la anotación previa en el tiempo de la magnitud variable  $X_i$  se determina las fronteras del diapasón de su variación.

### **II.2.1. Análisis estadístico de los datos**

Con el desarrollo de la ciencia y la técnica ha crecido la necesidad de utilizar la investigación en diferentes tipos de proyectos. Los investigadores realizan observaciones y sobre la base de estas se obtienen conclusiones; estas conclusiones, en la mayoría de los casos, rebasan los estrechos marcos en que se realiza la investigación, o sea, el investigador generaliza los resultados particulares a toda una clase de situaciones similar.

Existen pocas áreas donde el impacto del desarrollo reciente de la estadística se haya hecho sentir más que en la ingeniería; la estadística ha venido a ser una herramienta vital para los ingenieros, les permite comprender fenómenos sujetos a variaciones y predecirlos o controlarlos eficazmente.

La forma de recolectar los datos puede conducir a buenas decisiones o a errores graves, sin embargo la misma depende del tipo de variable o indicador seleccionado. Una variable es una magnitud aleatoria que puede tomar diferentes valores pero en un momento determinado toma uno y solo un valor.

### **Población y Muestra.**

Una población es el conjunto completo de individuos o elementos de interés que tienen una característica en común, que es objeto de estudio o sobre la cual se quiere sacar conclusiones.

Una muestra es el subconjunto de la población que permite sacar conclusiones sobre toda la población. Por tanto la misma debe ser lo más representativa posible de toda la población, es decir la muestra debe de contener toda la complejidad de la población.

Es muy importante resaltar que la representatividad de la misma no depende de su tamaño es decir de la cantidad de elementos que la forman (aunque si influye), sino de la forma en que la misma fue seleccionada; el proceso de selección de la muestra se conoce como muestreo.

### **Muestreo Aleatorio Simple (MAS).**

Este muestreo garantiza propiedades importantes en la muestra tomada, la independencia entre ellas, lo hace sumamente útil para aplicar numerosos métodos estadísticos, el cual tiene las siguientes características:

- Se aplica en poblaciones finitas y homogéneas.
- El investigador debe tener acceso a toda la población.
- La población debe estar enumerada.
- Se seleccionan los elementos con ayuda de una tabla de números aleatorios o por sorteo.

### **Presentación de los datos.**

La presentación de los datos le permite a cualquier investigador una fácil interpretación de los mismos, como se dijo anteriormente, la presentación de los datos se puede realizar de dos formas (mediante tablas y gráficos).

#### **1. Tablas de frecuencias.**

La forma más sencilla y común de presentar una base de dato es a través de una tabla de frecuencias o distribución de frecuencia como también se le conoce, la misma consiste en agrupar los datos en clases o categorías con sus respectivas frecuencias. Es aplicable a cualquier tipo de variable.

## **2. Gráficos.**

Existen diferentes tipos de gráficos para representar e interpretar una base de dato, entre ellos se pueden mencionar los siguientes:

- Diagrama de Pastel.
- Diagrama de barras.
- Histogramas.
- Polígonos.
- Diagramas de dispersión.

Histograma: Es la representación de los datos por rectángulos que tienen su base en un eje horizontal y su área proporcional a la frecuencia del intervalo de clase. Se utilizan fundamentalmente para variables continuas.

### **II.2.2. ANÁLISIS DE REGRESIÓN.**

El análisis de correlación desarrolla métodos que sirven “para investigar si dos o más variables están relacionadas”, y para medir “la intensidad de esta relación”.

El análisis de regresión, por su parte, ayudará a “determinar el modelo o ecuación matemática que mejor representa la relación existente entre las variables analizadas”.

En los modelos de regresión la variable dependiente (Y) es siempre una variable aleatoria, mientras que los factores o variables independientes son considerados como variables no aleatorias. Esto se argumenta en el hecho de que en las aplicaciones prácticas los valores de las  $X_i$  suelen ser controladas o elegidas de antemano por el investigador, estos factores también se les denomina variables explicativas, ya que ellos en definitiva son los que explican el comportamiento de la variable dependiente.

- **Requisitos o supuestos en la regresión. Análisis de los residuos.**

Se conoce que el método de los mínimos cuadrados minimiza la suma del cuadrado de los residuos; los cuales permiten estimar los errores aleatorios  $\varepsilon_i$ .

Aunque existen dójimas para comprobar los supuestos con respecto a la variable aleatoria  $Y_i$ , sin embargo el análisis de los supuestos a través de los residuos es de una forma sencilla y rápida, además permite determinar si el modelo proporciona un buen ajuste cuando no puede realizarse la dójima de la falta de ajuste, por falta de réplica, además permite investigar como mejorar el modelo:

1. La media de los errores debe ser cero.
2. Los errores deben ser independientes entre si. No autocorrelación.
3. La varianza de los errores debe ser constante e igual a  $\sigma^2$ . Homocedasticidad.
4. Los errores deben distribuirse normalmente con media cero y varianza  $\sigma^2$ .
5. No multicolinealidad. (Para casos de más de una variable).

Estos supuestos son equivalentes a los supuestos desde le punto de vista de la variable dependiente Y.

1. El valor promedio de Y coincida con el valor que ofrece la ecuación de regresión.
2. La varianza de las  $Y_i$  para cada valor fijo de X debe ser constante.
3. Para cada valor de X las  $Y_i$  deben ser estadísticamente independientes.
4. Las  $Y_i$  están normalmente distribuidas.

- **Incumplimiento de los supuestos**

Inconvenientes que proporcionan el incumplimiento:

Supuesto 2.

1. Aunque los estimadores mínimos cuadráticos de los parámetros ( $b_0, b_1$ ) son insesgado no serán óptimos pues sus varianzas pueden ser altas, sobrestimándose los parámetros ( $\beta_0, \beta_1$ ).
2. Las dójimas de la pendiente y la falta de ajuste no tienen validez.
3. Las estimaciones a partir de  $\hat{Y}$  son ineficientes.

Supuesto 3: Si se incumple este supuesto es decir que hay heterocedasticidad.

1. Se aumentan las varianzas de  $b_0$  y  $b_1$ .
2. Las estimaciones de  $\hat{Y}$  son ineficientes.
3. Las dójimas de la pendiente y la falta de ajuste no tienen validez.

• **Verificación de los supuestos y soluciones al incumplimiento de los mismos**

Supuesto 2. Para la comprobación de este supuesto se utiliza el método de Durbin-Watson se utiliza el Estadígrafo según la ecuación 2.1:

$$d = \frac{\sum_{i=1}^n (e_i - e_{i-1})^2}{\sum_{i=1}^n e_i^2} \quad (2.1)$$

Donde:

$$e_i = Y_i - \hat{Y}_i; \text{ Residuos}$$

Pasos a seguir:

1. Se obtiene  $\hat{Y}$ , utilizando el método de los mínimos cuadrados y se calculan los residuos  $e_i$ .
2. Conociendo los residuos se calcula  $d$ .
3. Se busca en la tabla de Durbin Watson, los valores críticos  $d_L$  y  $d_U$  para el tamaño de muestra analizado, el número de variables independientes y el valor del nivel de significación deseado.

Las hipótesis a probar en este método son las siguientes:

- $H_0$ : No hay autocorrelación.
- $H_1$ : Hay autocorrelación.

- Si  $d_U \leq d \leq 4 - d_U$  Aceptar  $H_0$

- Si  $d < d_L$  o  $d > 4 - d_L$  Rechazar  $H_0$

En otro caso la prueba no es concluyente y será necesario utilizar otro método o aumentar el tamaño de la muestra y aplicar nuevamente este método.

Se puede plantear esta dócima para determinar si hay autocorrelación positiva o negativa.

#### Eliminación de la autocorrelación.

Si se ha determinado que hay autocorrelación se utiliza para su eliminación métodos iterativos, pudiera ser el de Cochrane Orcutt o el de Theil Nogar, ya que la diferencia entre estos métodos radica en la estimación de  $\hat{e}$ .

#### **Método de Cochrane Orcutt.**

Pasos a seguir:

1. Se obtiene  $\hat{Y}$ , los residuos  $e_i$  y el estadístico de Durbin Watson.
2. Las variables originales se transforman en las ecuaciones 2.2 y 2.3:

$$X'_i = X_i - \hat{e}X_{i-1} \quad (2.2)$$

$$Y'_i = Y_i - \hat{e}Y_{i-1} \quad (2.3)$$

Donde:

$$\hat{e}_i = \frac{\sum_{i=1}^n e_i * e_{i-1}}{\sum_{i=1}^n e_{i-1}^2} ; \text{Residuos}$$

3. Se aplica el método de los mínimos cuadrados a las nuevas variables para determinar el nuevo modelo de regresión y los nuevos residuos y se busca el estadístico de Durbin

Watson para comprobar si aún hay autocorrelación, si se llega a que no hay, la recta de estimación estimada será a través de la ecuación 2.4.

$$\hat{Y} = \frac{b'_0}{1 - \hat{e}} + b'_1 X \quad (2.4)$$

Si por el contrario se repite la autocorrelación se repite el proceso hasta que se elimine.

Observaciones:

1. El estadígrafo de Durbin Watson se utiliza para muestras pequeñas, si las muestras son grandes debe utilizarse el estadígrafo de Von Neumann.
2. Si al eliminar la autocorrelación esta persiste pero (d) disminuye, puede pensarse que no se seleccionó el mejor modelo por lo que antes de continuar el proceso iterativo analice nuevamente el modelo utilizado para saber si es o no adecuado

Supuesto 3:

### **Método de Goldfied y Quandt.**

Este método se basa en una prueba paramétrica, donde se comparan las siguientes hipótesis:

- $H_0$ : Hay homocedasticidad.
- $H_1$ : Hay heterocedasticidad.

Pasos a seguir.

1. Se establece un orden creciente con respecto a los valores de las variables independientes.
2. Se omiten las observaciones centrales  $c$ , dividiéndose las observaciones en dos grupos iguales, donde cada uno posea  $(n-c)/2$  elementos. De forma que en un grupo estén los pares donde los valores de  $X_i$  sean más pequeños y en el otro los mayores.
3. Se determina  $\hat{Y}$  en cada grupo, ya que  $(n-c)/2 > p$ .

4. Se designa por  $S_1$  a  $\sum_{i=1}^n e_i^2$  de los valores de  $X$  más pequeños y por  $S_2$  la del subgrupo de valores de  $X$  mayores.

Estadígrafo:

$$\lambda = \frac{S_2}{S_1};$$

si se supone que los residuos están normalmente distribuidos y es válido el

supuesto de homocedasticidad, entonces se puede demostrar que

$$\lambda \sim F_{\alpha; \frac{n-c-2p}{2}; \frac{n-c-2p}{2}}$$

5. Criterio de decisión:

Si  $\lambda > F_{\alpha; \frac{n-c-2p}{2}; \frac{n-c-2p}{2}}$  se rechaza  $H_0$ , en caso contrario se aceptaría la hipótesis de homocedasticidad.

La potencia de la prueba depende del valor de  $c$ . Si  $c$  es grande la potencia es pequeña, si  $c$  es pequeña la potencia se equilibra.

Se recomienda: Si  $n = 30 \Rightarrow c = 8$   $n = 60 \Rightarrow c = 16$

#### Eliminación de la heterocedasticidad.

Se ha comprobado que si existe heterocedasticidad  $b_0$  y  $b_1$  no son los mejores estimadores lineales (de  $\beta_0$  y  $\beta_1$ ) insesgados y eficientes, y las dójimas de los coeficientes de regresión y de falta de ajuste no son válidas.

De ahí que, si se cumplen los demás supuestos excepto el de homocedasticidad, los mejores estimadores lineales e insesgados de  $\beta_0$  y  $\beta_1$  se determinan a través de las ecuaciones 2.5 y 2.6.

$$b_1^* = \frac{\left( \sum_{i=1}^n w_i \right) \left( \sum_{i=1}^n w_i X_i Y_i \right) - \left( \sum_{i=1}^n w_i X_i \right) \left( \sum_{i=1}^n w_i Y_i \right)}{\left( \sum_{i=1}^n w_i \right) \left( \sum_{i=1}^n w_i X_i^2 \right) - \left( \sum_{i=1}^n w_i X_i \right)^2} \quad (2.5)$$

$$b_0^* = \frac{\left( \sum_{i=1}^n w_i Y_i \right)}{\left( \sum_{i=1}^n w_i \right)} - b_1^* \frac{\left( \sum_{i=1}^n w_i X_i \right)}{\left( \sum_{i=1}^n w_i \right)} \quad w_i = \frac{1}{\sigma_i^2} \quad (2.6)$$

Estos estimadores son mínimos verosímiles de  $b_0$  y  $b_1$ .

Aunque existen varias formas de eliminar la heterocedasticidad, todas ellas dependen de que se conozca la forma de  $\sigma_i^2$  que permitiera hacer transformaciones en el modelo que irá sustituyendo  $w_i$  en las expresiones que planteamos por  $\frac{1}{\sigma_i^2 X_i}$ , de ahí que el nuevo

error aleatorio vendrá dado por  $\frac{\varepsilon_i}{\sqrt{X_i}}$  y será heterocedástico.

Sin embargo cuando existe heterocedasticidad en los errores aleatorios, se utiliza el modelo:  $\ln Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i$ , pues así se reduce la escala en que están medidas las variables, disminuyendo la posibilidad de la heterocedasticidad, lo que debe verificarse utilizando cualquier método.

Supuesto 4.

**Método para el chequeo de la normalidad. (Criterio de normalidad).**

Si se cumplen los requisitos de normalidad aproximadamente el  $(1-\alpha)\cdot 100\%$  de los residuos de la regresión estará en los límites  $\pm Z_{\frac{\alpha}{2}} S_{\hat{y}}$ , por lo que aproximadamente el

95% de los residuos de la regresión estará entre los límites  $\pm 2 S_{\hat{y}}$ .

Supuesto 1.

Es importante plantear que este supuesto siempre se cumple en cualquier modelo de regresión que posee un término constante  $\beta_0$ , por lo que no necesita ser comprobado.

Existen otros métodos para la comprobación de los supuestos, como el método gráfico el cual es poco preciso producto que depende de la apreciación de quién lo utiliza, es importante recalcar que mientras mayor sea el tamaño de la muestra, mejor podrá apreciarse el comportamiento de los residuos.

**II.3. Redes Neuronales Artificiales.**

Una red neuronal multicapa es una estructura paralela que procesa información en forma distribuida y está formada por elementos de procesamiento, llamados neuronas, interconectados con canales unidireccionales. Cada elemento de procesamiento tiene una conexión de salida, la cual se ramifica en tantas conexiones colaterales como se requiera (cada una lleva la misma señal, la salida del elemento procesador). Es una representación matemática que para su interpretación requiere de un entrenamiento previo, con base en patrones respectivos o de datos experimentales de entrada – salida, como en el caso de la aplicación en identificación de sistemas.

Uno de los problemas que ocurren durante el entrenamiento de la red neuronal, se llama sobre entrenamiento (overfitting). El error durante el entrenamiento se maneja a un valor muy pequeño, pero cuando los nuevos datos se presentan a la red el error es grande. La

red ha memorizado los ejemplos de entrenamiento, pero no ha aprendido a generalizar a las nuevas situaciones.

Un método para mejorar la generalización de la red es usar una red que simplemente sea bastante grande para proporcionar un ajuste adecuado. La red más grande utiliza funciones más complejas que la que puede crear. Si se usa una red bastante pequeña, no tendrá bastante poder al sobre entrenar los datos.

Para trabajar con redes neuronales, Matlab posee implementaciones de redes neuronales concretas como las perceptrón, backpropagation, Som, etc.

### **Estructura**

Matlab utiliza una estructura única que da acceso a todas las propiedades de la red neuronal, independientemente del tipo que ésta sea, de manera que utilizando esta propiedad se pueden modificar las entradas, capas, conexiones, pesos, etc. De esta manera una vez configurada la red neuronal según las necesidades se invocan las funciones de manipulación de redes neuronales disponibles en Matlab, (simulación, entrenamiento, inicialización, etc.), pasándole como parámetro la estructura de la red neuronal. *net = network;*

Si ejecuta el comando anterior y se visualiza el contenido de la variable *myNetwork* se observará la estructura mencionada, la cual se puede dividir en cinco secciones:

### **Arquitectura:**

Define las características básicas de la red neuronal, número de entradas, capas, conexiones de bias, etc.

```
architecture:  
numInputs: 0  
numLayers: 0  
biasConnect: []  
inputConnect: []
```

layerConnect: [ ]  
outputConnect: [ ]  
numOutputs: 0 (read-only)  
numInputDelays: 0 (read-only)  
numLayerDelays: 0 (read-only)

### **Subobjetos:**

Contiene referencias a las subestructuras de la red neuronal, que nos permitirán configurar las propiedades de los distintos componentes que forman la red (capas, entradas, salidas, etc.).

subobject structures:

inputs: {0x1 cell} of inputs  
layers: {0x1 cell} of layers  
outputs: {1x0 cell} containing no outputs  
biases: {0x1 cell} containing no biases  
inputWeights: {0x0 cell} containing no input weights  
layerWeights: {0x0 cell} containing no layer weights

### **Funciones:**

Funciones principales de la red neuronal, utilizadas para ejecutar las operaciones de inicialización, entrenamiento o simulación.

functions:  
adaptFcn: (none)  
divideFcn: (none)  
gradientFcn: (none)  
initFcn: (none)  
performFcn: (none)  
plotFcns: { }  
trainFcn: (none)

### **Parámetros:**

Configuración de los parámetros asociados a las funciones seleccionadas en el bloque de funciones.

```
parameters:  
  adaptParam: (none)  
  divideParam: (none)  
  gradientParam: (none)  
  initParam: (none)  
  performParam: (none)  
  trainParam: (none)
```

### **Valores:**

Aquí se definen las matrices con los valores de los pesos de entrada, conexiones entre capas y bias.

weight and bias values:

```
IW: {0x0 cell} containing no input weight matrices  
LW: {0x0 cell} containing no layer weight matrices  
b: {0x1 cell} containing no bias vectors
```

### **Funciones**

Una vez creada la red neuronal, para trabajar con la misma, se pueden utilizar las siguientes funciones para realizar las operaciones típicas:

Inicialización (net = init(net)):

Mediante la función de inicialización, se obtiene una red neuronal con los valores de los pesos y bias actualizados según las funciones de inicialización que le hayan asociado a la red, mediante su propiedad:

net.initFcn,                      net.layers{i}.initFcn                      net.biases{i}.initFcn.

**Entrenamiento:**

([net, tr, Y, E, Pf, Af] = train(net, P, T, Pi, Ai, VV, TV);)

Realiza el entrenamiento de la red neuronal, modificando los pesos asociados a las conexiones entre las diferentes capas y neuronas de la misma. Para esto, se deben indicar patrones de entrada a la red (P, matriz de dimensiones M x N siendo M la suma de los tamaños de las capas de entrada de la red neuronal, y N el número de patrones que desea aplicar en el entrenamiento). En caso de ser un entrenamiento supervisado también se indicaran los targets (T, matriz de M x N), con estos datos la matriz de patrones se aplica a la red neuronal, y el toolbox utilizando las funciones de entrenamiento que se le han indicado en las propiedades “*trainFcn*” se encargará de actualizar los pesos asociados a las conexiones de la red. Los resultados del entrenamiento se obtendrán en la variable de retorno Y y los errores para cada patrón de entrada respecto a la salida esperada en la variable de retorno E.

Demasiadas neuronas conllevan a un *sobre-ajuste*, la red memoriza el conjunto de datos de entrenamiento y para valores pertenecientes al mismo su precisión sería casi absoluta. Sin embargo si le presentan valores desconocidos fallaría estrepitosamente, dado que como consecuencia del sobre-ajuste sería incapaz de *generalizar*. Por otra parte si el número de neuronas en la capa oculta es reducido se podrá llegar a una situación de *sub-ajuste*, en la cual la red no sería capaz de aprender ciertas relaciones existentes entre las variables. Aprovechando las propiedades atribuidas a las Redes Neuronales Artificiales Unidireccionales (*Teorema de Hornik-Stinchcombe-White*, Hornik *et al.*, (1990)), el objetivo será aproximar la curva del comportamiento de la temperatura a la salida, dado el conjunto de datos disponible, para posteriormente poder realizar predicciones sobre valores futuros.

### **Simulación:**

$([Y, Pf, Af, E, perf] = \text{sim}(\text{net}, P, Pi, Ai, T))$

Función parecida a la anterior pero que no actualizará los pesos de la red neuronal. Una vez entrenada la red neuronal y ésta ofrezca resultado válidos, se utilizará esta función para analizar nuevos patrones de entrada.

### **Redes neuronales conocidas**

Normalmente a la hora de trabajar con redes neuronales, se quiere trabajar con un tipo de red neuronal determinado, el cual se ajuste mejor a las necesidades del proceso en estudio. En este caso en vez de utilizar la función “network” para la creación de la estructura base, se pueden utilizar funciones específicas para cada tipo de red neuronal, de manera que la estructura base que Matlab nos devuelva, tenga una configuración de capas de entrada, ocultas, conexiones etc. apropiada para el tipo de red neuronal deseado.

- Perceptron: `newp(P,S)`
- Backpropagation: `newff(P, [S1,....., Sn])`
- Radiales: `newgrnm(P,T)`
- Mapas Autoorganizados: `newsom(P,S)`

### **II.4. Conclusiones del capítulo II.**

- Se define que el tipo de experimento que se llevará a cabo es el pasivo.
- Que el aparato matemático se aplica solo en la elaboración y el tratamiento de los datos experimentales, además que se realiza por el método clásico de análisis de correlación-regresión.
- Se muestra la estructura que da acceso a todas las propiedades de la red neuronal y que permite a su vez modificar las entradas, capas, conexiones, pesos, etc.

## **CAPÍTULO III**

---

### **RESULTADOS EXPERIMENTALES Y CARACTERIZACIÓN PRELIMINAR DEL PROCESO DE ENFRIAMIENTO DE MINERAL CON AYUDA DE LAS TÉCNICAS DE INTELIGENCIA ARTIFICIAL**

#### **III.1. Introducción**

Toda modelación teórica desarrollada exige la ejecución de experimentos para lograr la adecuación del modelo elaborado al objeto industrial. La experimentación permitirá obtener los parámetros característicos del modelo teórico: la temperatura del mineral a la salida del enfriador, para lo cual se realizó una experimentación pasiva, o sea en el enfriador cilíndrico rotatorio en su proceso de producción continua.

La realización de experimentos en el objeto en producción impone dificultades inevitables a los mismos, pues es necesario, en la mayoría de las ocasiones, introducir perturbaciones que afecten en poca medida la estabilidad de las operaciones desde el punto de vista de la obtención del producto final dentro de las especificaciones comerciales establecidas, no obstante, la presencia en el enfriador de medios técnicos adecuados permitió llevar a cabo el seguimiento de los principales parámetros influyentes en el proceso de enfriamiento. En todos los casos los parámetros de medición continua y las acciones sobre el proceso introducidas fueron recogidas a través de un PLC y llevadas hasta una computadora que se encuentra en la oficina de los tecnólogos de la planta para controlar el proceso con ayuda del sistema de registro de almacenamiento de datos, CITECT.

El **objetivo** del capítulo es: caracterizar con ayuda de las Redes Neuronales Artificiales el comportamiento del proceso de enfriamiento de mineral a través de los resultados experimentales obtenidos de la instalación.

### **III.2. Análisis del Proceso de enfriamiento del mineral reducido como objeto de modelación físico-matemática**

El proceso de enfriamiento consiste en disminuir la temperatura del mineral hasta valores por debajo de 200°C . Para ello se utiliza el enfriador cilíndrico rotatorio.

El enfriador utilizado en el proceso es un equipo de transferencia de calor, el mismo está dispuesto horizontalmente como una instalación de transporte. El mineral llega a través del transportador rotatorio al enfriador, que está seccionado en tres partes en el cual al caer el mineral es pasado por cada sección del mismo con la ayuda de los carros raspadores y paletas los cuales se encargan también de remover el mineral y raspar la superficie interior del enfriador evitando que el mineral se adhiera e interfiera en el proceso de transferencia o intercambio de calor entre el mineral y el enfriador, cada sección del mismo posee un separador circular en todo el diámetro del equipo que posibilita el tiempo de retención necesario para que el mineral se enfríe adecuadamente.

Desde el punto de vista termo energético en este proceso están presentes los tres modos de transmisión del calor (Conducción, Convección y Radiación) y los mismos influyen de la forma siguiente:

El mineral es descargado en el enfriador a una temperatura entre 650 y 700°C , el mismo transfiere calor a la superficie interior del tambor por conducción, convección y radiación, predominando considerablemente la transferencia de calor por conducción debido al contacto sólido-sólido, en este caso mineral-enfriador, también se transfiere calor por convección debido a la presencia de gases productos de la combustión que acompañan el mineral hasta el interior del cilindro, pero este modo de transmisión del calor puede ser despreciado porque solo se manifiesta cuando se forman burbujas o poros dentro de la masa de mineral, hecho este que no es frecuente en este proceso.

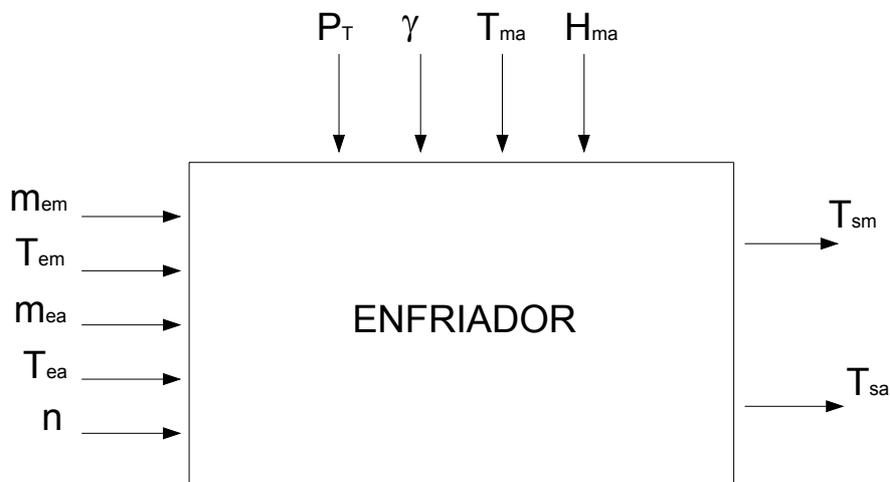
Desde la masa de mineral a la pared superior del equipo se transfiere el calor por radiación debido a la alta temperatura del mineral en el interior del enfriador. En el espesor del enfriador ( $\delta = 16$  mm), o sea desde la pared interior a la superficie exterior el flujo de calor se transfiere por conducción; teniendo en cuenta para el posterior análisis que es

mayor la influencia de la transferencia de calor por conducción en la parte que está en contacto el mineral con el tambor.

Una vez transferido el flujo de calor hasta la superficie exterior del enfriador, este intercambia calor con el agua de la piscina que se encuentra por encima de  $30^{\circ}\text{C}$ , dando lugar al calentamiento progresivo de la misma hasta valores entre  $70$  y  $76^{\circ}\text{C}$ , este proceso de intercambio de calor ocurre por convección y en el mismo se le comunica velocidad al fluido.

Como se puede apreciar el enfriador de mineral es un objeto de modelación físico-matemática complejo con gran número de parámetros de entrada y de salida los cuales se encuentran en una compleja interdependencia.

En la figura 3.1 se muestra el esquema estructural de la interacción de los parámetros principales del proceso de enfriamiento del mineral reducido.



**Figura 3.1** Esquema estructural del proceso de enfriamiento del mineral.

Los parámetros de entrada del proceso son:

- $m_{em} \Rightarrow$  Flujo de mineral a la entrada del enfriador.
- $T_{em} \Rightarrow$  Temperatura del mineral a la entrada del enfriador.

- $m_{ea} \Rightarrow$  Flujo de agua de entrada a la piscina.
- $T_{ea} \Rightarrow$  Temperatura del agua a la entrada de la piscina.
- $n \Rightarrow$  Número de revoluciones del tambor.

Como parámetros de salida se destacan los siguientes:

- $T_{sm} \Rightarrow$  Temperatura del mineral a la salida del enfriador.
- $T_{sa} \Rightarrow$  Temperatura del agua a la salida de la piscina.

Además de los parámetros de entrada y de salida, resulta importante destacar algunas perturbaciones propias de este proceso y que ejercen influencia sobre el mismo, ellas son:

- $P_T \Rightarrow$  Presión de trabajo en el interior del enfriador.
- $\gamma \Rightarrow$  Coeficiente de llenado del tambor.
- $T_{ma} \Rightarrow$  Temperatura del medio ambiente.
- $H_{ma} \Rightarrow$  Humedad relativa del medio ambiente.

### **III.3. Instalación experimental.**

En el epígrafe II.1 se expusieron los criterios que sustentan la decisión de realizar una experimentación pasiva basada en la observación y registro de las variables de entrada y salida, considerando el proceso de enfriamiento del mineral reducido en estado estacionario.

La instalación experimental en este caso fue el tambor utilizado para el enfriamiento del mineral en la planta de hornos de reducción y consta de los siguientes equipos y accesorios:

- 1- Enfriador cilíndrico
- 2- Estanque de agua
- 3- Motores eléctricos
- 4- Instrumentación y control de los parámetros

### ***Enfriador cilíndrico***

Utilizado como intercambiador de calor tiene la función de enfriar el mineral a través de los procesos de transferencia de calor, a la vez que ejerce como un transportador de mineral hasta la canal ubicada en el tanque de contacto donde inicia el proceso de lixiviación y lavado. El equipo tiene 30 m de longitud, está construido de acero A285A (ASTM), 15 GOST y su capacidad es de 30 t/h .

### ***Piscina de agua***

El enfriador se encuentra parcialmente sumergido en la piscina de agua, construida de hormigón. El fluido es renovado a razón de entre 20 y 37 m<sup>3</sup>/h y según el fabricante puede alcanzar los 107 m<sup>3</sup>/h , la temperatura del agua oscila entre los 30 y 76°C para la entrada y salida respectivamente, tiene como objetivo facilitar e incrementar el proceso de intercambio de calor entre el enfriador y el medio exterior.

### ***Motores eléctricos***

Transmiten el movimiento al enfriador para lo cual se emplean dos motores eléctricos con características técnicas diferentes:

*Motor eléctrico principal* tipo 315 M8, de corriente alterna, voltaje 440 V , potencia 75 kW , empleado para el trabajo estable del enfriador, presenta una amplia gama de números de revoluciones lo que posibilita el régimen de trabajo continuo al que está sometido.

*Motor eléctrico auxiliar* tipo M180L08 de corriente alterna, voltaje 440 V , potencia 11 kW , empleado para situaciones de emergencia (rotura del motor eléctrico principal, paradas imprevistas, etc.), se emplea también cuando se quiere variar el régimen de operación de la instalación.

### **III.3.1. Estado de la automatización del proceso de enfriamiento del mineral.**

El proceso de enfriamiento del mineral en la empresa “Cmdte. Ernesto Che Guevara” se encuentra desde el punto de vista de su automatización y control, en una etapa primaria,

pues sólo contempla la medición y registro de algunos parámetros del proceso por un autómatas programable.

A continuación se muestran los parámetros que se registran con sus correspondientes instrumentos de medición y las características técnicas de los mismos.

**PARÁMETRO:** Flujo de mineral alimentado al horno.

- EQUIPO: Banda transportadora CB-3 (pesa).
- CARACTERÍSTICAS TÉCNICAS:
- Construcción Goma sintética
- Diseño, 1.5 t/h
- Velocidad 0.032 m/s

**PARÁMETRO:** Temperatura del mineral a la entrada y salida del enfriador; y temperatura del agua en la piscina.

- EQUIPO: Termómetro de resistencia PT-100 con vaina y cabezal de conexión de roscado con convertidor de señal programable mediante PC alojado en el cabezal.
- CARACTERÍSTICAS TÉCNICAS:
- Temperatura de servicio hasta 873 K .
- Cabezal de conexión tipo B, construido de material ligero para alojar un convertidor.
- Convertidor de señal programable con rango ajustado.

**PARÁMETRO:** Velocidad de rotación del enfriador

- EQUIPO: Tacogenerador.
- CARACTERÍSTICAS TÉCNICAS:
- 0 a 8,0 rpm. y 0 a 10 V

**PARÁMETRO:** Flujo de agua que entra a la piscina.

- EQUIPOS: Elemento primario de caudal tipo PITOT delta.
- TUBE modelo 301 - AK - 10 - AD para agua.

- Transmisor de presión diferencial para la medida de caudal, inteligente, no smart, modelo SITRANS P serie HK.

En la instalación todos los instrumentos están normalizados y certificados por la NC 17025 de acreditación de instrumentación de laboratorio y presentan el sello “Apto para el uso”.

La instrumentación instalada en la planta permite registrar los valores de los parámetros del proceso de enfriamiento los cuales son censados por el instrumento correspondiente a cada uno de ellos y la señal se envía al ordenador ubicado en la oficina de control del proceso. Mediante el uso del programa “CYTET” se toma el valor de los parámetros antes mencionados.

Entre los parámetros que son registrados por el “CYTET” y que tiene relación con el proceso de enfriamiento se encuentran:

- Flujo de mineral alimentado al horno
- Temperatura de los gases en el hogar 15
- Temperatura del mineral a la descarga del enfriador
- Flujo de agua
- Temperatura del agua en la piscina
- Corriente del motor

De los parámetros mencionados se debe señalar que tienen incidencia directa en el proceso de enfriamiento el flujo de mineral y de agua, ya que de ellos dependen en gran medida los valores de la temperatura del mineral a la descarga. Es decir el flujo de agua permite establecer la temperatura del agua en la piscina, garantizando el menor consumo de corriente y a su vez el nivel de flotación del cilindro.

### **III.3.2. Diseño experimental.**

#### ***Selección de las variables***

De acuerdo con el análisis del proceso de enfriamiento como objeto de modelación, la temperatura del mineral a la salida del enfriador depende fundamentalmente de los siguientes parámetros:

- Flujo másico de mineral a la entrada del enfriador
- Temperatura del mineral a la entrada del enfriador
- Flujo másico de agua que entra a la piscina
- Temperatura del agua en la piscina
- Hora del día
- Consumo de corriente en el motor principal

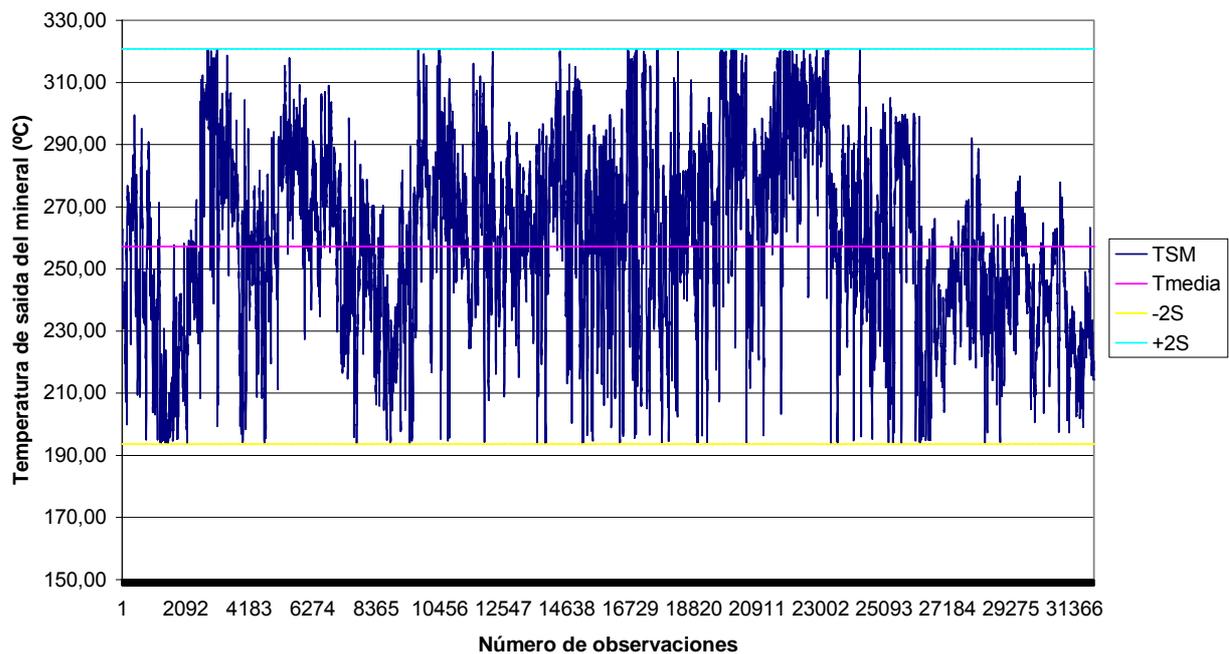
Se conoce del epígrafe 1.10 y de la figura 1.1 que existen otros parámetros que intervienen en el proceso de enfriamiento del mineral reducido y que a su vez influyen en la temperatura de salida del mineral, pero por cuestiones propias del proceso los parámetros antes mencionados son los únicos que se registran en la empresa y los demás permanecen constantes o son considerados perturbaciones.

### **III.3.3. Técnica experimental.**

Debido a la automatización existente en la planta los valores de los parámetros del proceso son censados por el instrumento correspondiente a cada uno de ellos y la señal se envía al ordenador ubicado en la oficina de control del proceso. Las series de datos obtenidos se registraron cada 180 s , y se tomaron los valores de 4 meses.

En las mediciones se observaron valores de variables fuera del rango de operación establecido para el proceso como por ejemplo: la temperatura del agua en la piscina menor que la temperatura del medio ambiente, flujo de agua igual a cero y en algunas ocasiones no se registraron valores algunos debido a deficiencias en los instrumentos de medición, por tales motivos se realizó la limpieza de datos.

Para la selección de la muestra que garantice un valor representativo de la población se tomó la media mas – menos dos (2) veces la desviación estándar, lográndose así que la muestra promedio fuera aproximadamente el 83 % de la población total. La figura 3.2 muestra el comportamiento de la temperatura de salida del mineral entre sus valores mínimos y máximos de 193,66 y 320,77°C respectivamente para los 4 meses de trabajo.



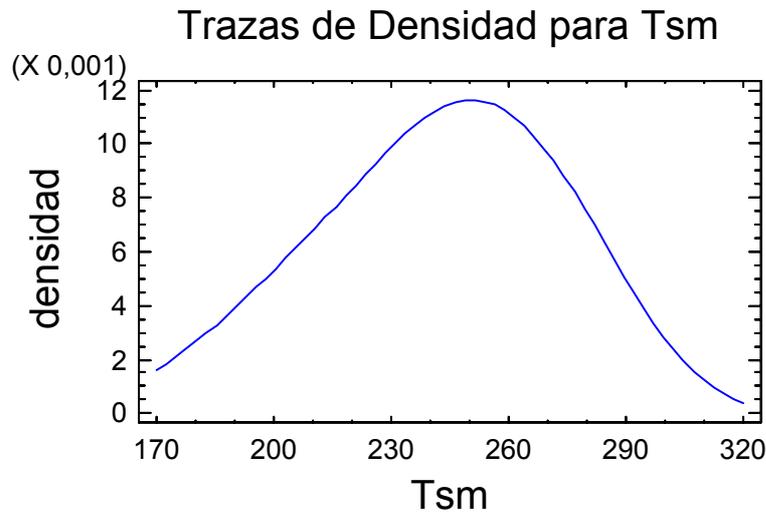
**Figura 3.2** Gráfico de control para la variable dependiente.

Una vez analizada la base de datos (Población) y a través de un análisis estadístico descriptivo se determinaron las funciones de muestra que evalúan las medidas de tendencia central y dispersión de la muestra.

**Tabla 3.1** Resumen del análisis estadístico descriptivo de la muestra para un mes.

	Temperatura (°C)		Flujo	
	Mineral	Agua	Mineral (t/h)	Agua (m <sup>3</sup> /h)
Media	240,23	82,89	40,08	30,00
Error típico	0,24	0,02	0,02	0,03
Mediana	239,73	83,15	41,00	30,68
Moda	230,00	84,49	41,00	30,74
Desviación estándar	22,30	1,70	1,52	2,91
Varianza de la muestra	497,23	2,88	2,30	8,46
Curtosis	-0,05	2,04	9,17	4,36
Coefficiente de asimetría	0,11	-0,80	-1,80	-1,73
Rango	118,92	15,32	18,00	17,81
Mínimo	198,76	72,86	25,00	18,87
Máximo	299,97	88,19	43,00	36,68
Suma	2087833,30	720433,18	348312,72	260756,24
Cuenta	8691,00	8691,00	8691,00	8691,00
Nivel de confianza (95,0%)	0,47	0,04	0,03	0,06

La tabla 3.1 expresa el comportamiento de las funciones de muestra que evalúan las medidas de tendencia central y dispersión de la muestra de las variables que intervienen en el proceso, para este caso se observa que los valores de Curtosis y del Coeficiente de asimetría, permiten afirmar que la variable dependiente (temperatura de salida del mineral) se comporta como una distribución normal. En la figura 3.3 se puede evaluar visualmente como se ajusta la distribución normal.



**Figura 3.2** Comportamiento de la distribución normal de la variable dependiente.

Los resultados de las pruebas ejecutadas para determinar si la temperatura del mineral a la descarga del enfriador puede ser modelada adecuadamente por una distribución normal muestran que:

- La prueba Chi-cuadrado que divide el rango de la temperatura de salida del mineral en intervalos no solapados y compara el número de observaciones en cada clase con el número esperado basado en la distribución ajustada, da un valor de Chi-cuadrado igual a 7,9897 con 6 grados de libertad para un valor de la probabilidad de 0,238859.
- La prueba de Kolmogorov-Smirnov que calcula la distancia máxima entre la distribución acumulada de la temperatura de salida del mineral y el CDF de la distribución normal ajustada, siendo la distancia máxima 0,0680449 el valor del estadístico Kolmogorov-Smirnov D toma el valor de 0,0680449 para un valor mayor o igual de 0.10.

Por la tanto, dado que el valor de la probabilidad más pequeño de las pruebas realizadas es superior o igual a 0.10, se puede afirmar que la temperatura del mineral a la descarga del enfriador procede de una distribución normal con un nivel de confianza de al menos un 90%. Los resultados mostrados se obtuvieron con ayuda del Software Statgraphics Plus 5.1.

La tabla 3.2 muestra el análisis de correlación entre las variables independientes identificadas en el proceso y la variable dependiente, destacándose que las que tienen mayor incidencia en la temperatura de salida del mineral alcanzan un coeficiente de correlación entre 0,16 y 0,48, siendo éstas las seleccionadas para la obtención del ajuste a un modelo de regresión lineal múltiple que describa la relación entre la temperatura a la que sale el mineral del enfriador y las tres (3) variables independientes.

**Tabla 3.2** Resumen del análisis de correlación.

VARIABLES	Temperatura de salida del mineral			
	Enero	Febrero	Marzo	Abril
Flujo de mineral	0,20	0,16	0,04	0,48
Flujo de agua	-0,18	0,45	-0,09	0,41
Temperatura del agua	0,36	0,22	0,16	0,16

Para la búsqueda de una ecuación que permita establecer la relación entre las variables de entrada del proceso y la variable dependiente se realizó un análisis de regresión paso a paso hacia atrás y los resultados se muestran en las tablas 3.3, 3.4 y 3.5.

En la tabla 3.3 el estadístico  $R^2$  indica que el modelo de la ecuación 3.1 explica un 0,3270 % de la variabilidad en la temperatura de salida del mineral. El estadístico  $R^2$  ajustado, que es más conveniente para comparar modelos con diferentes números de variables independientes, es 0,3268 % . El error estándar de la estimación muestra la desviación típica de los residuos que es 18,2957.

**Tabla 3.3** Resumen del análisis de regresión.

<b>ESTADÍSTICAS DE LA REGRESIÓN</b>	
Coeficiente de correlación múltiple	0,5719
Coeficiente de determinación R <sup>2</sup>	0,3270
R <sup>2</sup> ajustado	0,3268
Error típico	18,2957
Observaciones	8691,00

### **Análisis de los Componentes de la Varianza**

La tabla 3.4, muestra el análisis de la varianza donde divide la varianza de la temperatura de salida del mineral en tres (3) componentes, uno por cada factor. Cada factor después del primero se anida por encima de él. Este análisis permite estimar la cantidad con la que contribuyen a la varianza los diferentes factores, a los que se llaman componentes de la varianza. En este caso, el factor que contribuye con la máxima varianza es el flujo de mineral y su contribución representa 41,4401% del total de la variación en la temperatura de salida del mineral.

**Tabla 3.4** Resumen del análisis de varianza para la temperatura de salida del mineral.

<b>Fuente</b>	<b>Suma de Cuadrados</b>	<b>Grados de Libertad</b>	<b>Cuadrado Medio</b>	<b>Comp. Var.</b>	<b>Porcentaje</b>
Total (corregido)	4,32432E6	8694			
Flujo mineral	1,74776E6	36	48548,8	231,765	41,44
Flujo de agua	538272,0	86	6258,98	61,6698	11,03
Temperatura del agua	588008,0	213	2760,6	92,3422	16,51
Error	1,45028E6	8359	173,5	173,5	31,02

En la tabla 3.5 se observa el análisis de correlación que permitió determinar la ecuación matemática que mejor representa la relación existente entre las variables analizadas, ver ecuación 3.1.

**Tabla 3.5** Resumen del análisis de correlación.

	<b>Coeficientes</b>	<b>Error típico</b>	<b>Estadístico t</b>	<b>Probabilidad</b>	<b>&lt; 95%</b>	<b>&gt; 95%</b>
<b>Intercepción</b>	-213,6973	10,6135	-20,1344531	3,7023E-88	-234,50	-192,89
<b>Fm</b>	5,4011	0,13837	39,0311268	3,498E-307	5,12985	5,67236
<b>Fa</b>	2,3389	0,07223	32,3808002	2,883E-217	2,19735	2,48056
<b>Ta</b>	2,0181	0,11758	17,1628798	5,8859E-65	1,78761	2,24860

$$T_{sm} = - 213,6973 + 5.4011 \cdot F_m + 2,3389 \cdot F_a - 2,0181 \cdot T_a \quad (3.1)$$

Donde:

- Tsm: Temperatura del mineral a la salida; (°C)
- Fm: Flujo de mineral; (t/h)
- Fa: Flujo de agua; (m<sup>3</sup>/h)
- Ta: Temperatura del agua; (°C)

#### III.4. Redes Neuronales Artificiales.

La determinación del tipo de red neuronal, del número de capas y de la cantidad de neuronas en cada capa que mejor caracterice el proceso de enfriamiento del mineral reducido, se llevó a cabo mediante un proceso de ensayo y error en el que se juega con el número de neuronas y el máximo error admisible.

Para garantizar un uso eficiente del tiempo y un ahorro de los recursos disponibles, se confeccionó un programa que permite evaluar el comportamiento de los diferentes tipos de redes neuronales, para diferentes tipos de funciones de transferencia y diferentes tipos de entrenamientos, dando como resultado además el valor del coeficiente de correlación entre los valores reales y los obtenidos a través de la red. El mismo permite no hacer uso del Toolbox de Redes Neuronales (nntool) de Matlab, ver Anexo 1.

El objetivo fue dotar a la red de un número adecuado de neuronas en la capa oculta para que sea capaz de aprender las características de las posibles relaciones existentes entre los datos de la muestra.

El proceso de ensayo y error se inició con todas las variables posibles de entradas, probando diferentes estructuras de redes neuronales, comprobando de esa manera con cual estructura se obtienen los mejores resultados, para luego hacer énfasis en aquellas que según el análisis estadístico son las de mayor coeficiente de correlación, tabla 3.2. Luego se demostró que los tipos de redes neuronales para los cuales se obtienen mejores resultados son la feed-forward backpropagation y la cascade-forward backpropagation, seleccionando ésta última para la caracterización del proceso.

Una vez identificada la estructura de la red neuronal se procedió a determinar con que juego de variables de entrada se obtenían mejores resultados, concluyendo que coincidían las variables seleccionadas en la tabla 3.2. Luego en busca de mejores resultados se agruparon las series de datos en función del flujo de mineral que entra al enfriador y se asumieron solamente como variables de entrada el flujo de agua y temperatura del agua, observándose que los resultados obtenidos mejoraban considerablemente obteniéndose valores de un coeficiente de correlación de hasta 0,99 muy superior a los valores obtenidos con tres variables de entrada donde el mayor valor alcanzado fue de 0,85 y al obtenido con el análisis estadístico que fue 0,57. Ver Anexos 2 y 3.

#### **III.4.1. Arquitectura de la red**

La red propuesta está compuesta por cuatro capas: una de entrada, dos capas ocultas y una de salida. En lo referente a la capa de entrada, se ubicarán en la misma 2 unidades que representarán cada uno de los parámetros de entrada. La capa de salida solo contará con una unidad, la cual indicará el valor de la temperatura de descarga del mineral asociado a cada vector de entrada presentado a la red. Finalmente la capa oculta que contará con un número variable de neuronas. Esquemáticamente el modelo propuesto de red neuronal artificial para estimar la temperatura del mineral a la salida del enfriador tendría la forma que se muestra en la figura 3.3.

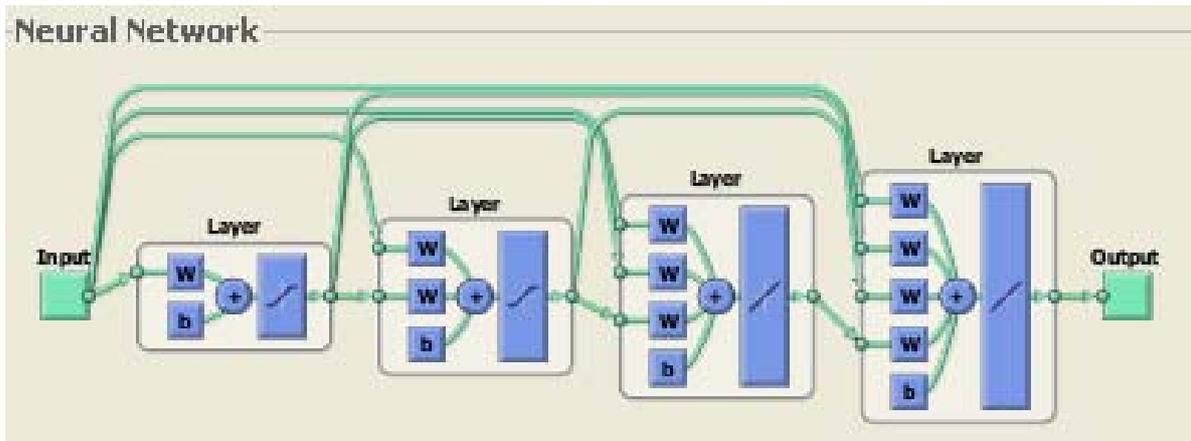


Figura 3.3. Representación esquemática de la Red Neuronal Artificial empleada.

### Datos de entrada

El modelo se alimenta con la información aportada por las siguientes variables:

- **Fm**: Flujo de mineral (se asume el flujo promedio de los dos hornos)
- **Ta**: Temperatura del agua en la piscina.
- **Fa**: Flujo de agua que entra a la piscina.

Es necesario destacar que existen otras variables de entrada a considerar y que tienen influencia en el proceso de enfriamiento, como son:

- Temperatura y humedad relativa del medioambiente.
- Velocidad y dirección de los vientos.

Pero al no estar éstas registradas por el sistema de adquisición de datos no fueron incluidas en el modelo neuronal.

La tabla 3.6 muestra las variables de entrada a la Red Neuronal Artificial las cuales serán utilizadas en ese orden en el entrenamiento, validación y generalización de la misma, en el Anexo 4 se muestra un resumen de los valores reales empleados en cada caso.

**Tabla 3.6** Resumen de datos para la red neuronal artificial.

No.	Fm	Ta	Fa
1	Fm <sub>1</sub>	Ta <sub>1</sub>	Fa <sub>1</sub>
2	Fm <sub>2</sub>	Ta <sub>2</sub>	Fa <sub>2</sub>
3	Fm <sub>3</sub>	Ta <sub>3</sub>	Fa <sub>3</sub>
n	Fm <sub>n</sub>	Ta <sub>n</sub>	Fa <sub>n</sub>

Quedando la variable dependiente (Tsm: temperatura de salida del mineral del enfriador) en función de las variable que aparecen en la tabla 3.2.

$$Tsm = f(Fm, Ta, Fa)$$

### **Preparación de la información de entrada: filtrado y cambio de escala**

Uno de los aspectos más relevantes en el éxito de cualquier modelo neuronal es el conjunto de datos empleado en su entrenamiento. Incluso el más simple de los modelos puede ofrecer buenos resultados si es alimentado con datos que, tras ser preprocesados adecuadamente, revelan de forma clara y precisa la información relevante, Beltratti *et al.* (1996). Asimismo, el mejor de los modelos fracasará si es entrenado con datos de baja calidad. Por tanto es necesario llevar a cabo un pre-procesado de la información muestral para de este modo aumentar la capacidad de aprendizaje de la red. El pre-procesado constará de las siguientes operaciones:

**Filtrado:** Se trataría de repasar las series de datos buscando posibles outliers. Se han encontrado datos atípicos, concretamente valores perdidos, tanto en las variables de entrada como la de salida. Estos se corresponden con fallas en el suministro eléctrico y en los instrumentos de medición respectivamente. En la serie de la temperatura de salida se han reemplazado los outliers con la media aritmética de los valores anterior y posterior al perdido, destacando que los días escogidos por meses son aquellos que tuvieron menos datos atípicos.

**Cambio de escala.** Todas las variables consideradas en el modelo serán linealmente escaladas entre 0 y 1. Este procedimiento consiste simplemente en modificar la escala de las variables atendiendo a su valor mínimo y máximo. Como resultado obtendrán nuevas series de datos más homogéneas, las cuales oscilarán entre 0 y 1.

La información en su estado original tendría el formato que se muestra en la tabla 3.7:

**Tabla 3.7** Información de entrada en su formato original.

Temperatura (°C)		Flujo	
Mineral	Agua	Mineral (t/h)	Agua (m <sup>3</sup> /h)
198,76	72,86	25,00	18,87
240,23	82,89	40,08	30,00
299,97	88,19	43,00	36,68

Una vez preparadas las series de datos adquieren el formato que aparece en la tabla 3.8.

**Tabla 3.8** Información de entrada en nueva escala [0,1].

Temperatura (°C)		Flujo	
Mineral	Agua	Mineral (t/h)	Agua (m <sup>3</sup> /h)
0,66	0,58	0,51	0,83
0,80	0,93	0,82	0,94
1,00	1,00	1,00	1,00

### III.4.2. Entrenamiento de la red

En la tabla únicamente se muestran tres valores (mínimo, medio y máximo) de la serie a modo de ejemplo. Estos valores se corresponden con los observados en 24 horas pertenecientes a un mes, dentro de los 4 meses de observación, un resumen de estos valores se observan en el Anexo 4.

## **Soporte informático para las Redes Neuronales Artificiales.**

Existen una serie de programas de carácter genérico que incorporan librerías o cajas de herramientas especializadas en las redes neuronales artificiales. Este es el caso de Matlab y su *Neural Networks Toolbox*. La potencia de motor del cálculo de Matlab permitió fijar el número máximo de iteraciones, determinado de manera arbitraria, establece el umbral para el error cuadrático medio marginal. Si este umbral no es alcanzado en el transcurso de un número de iteraciones establecido por él, asume que cada nueva iteración no aportaba nada al entrenamiento, con lo que él mismo se da por concluido. Este nuevo criterio de parada basado en el descenso por la función de error cuadrático medio, además de ser técnicamente más adecuado, evita la posibilidad de llegar a un sobre-entrenamiento de la red. En cuanto a las funciones de transferencia se observó que las que mostraron un mejor comportamiento del proceso fueron la función de la tangente hiperbólica sigmoideal (*tansig*) y la lineal (*purelin*).

### **Resultados del entrenamiento**

El entrenamiento se llevó a cabo utilizando una muestra superior a las 900 observaciones y para llegar a determinar el valor óptimo de los parámetros que definen la red, se recurrió al método de ensayo y error:

***Número óptimo de iteraciones:*** La aportación de cada nueva iteración en términos de reducción del error cuadrático medio es despreciable a partir de las 100 iteraciones.

***Número óptimo de neuronas en la capa oculta:*** Puede ser determinado mediante la aplicación de una serie de fórmulas heurísticas, ó alternativamente mediante un proceso de ensayo y error. Para llevar a cabo el experimento se fijó la tasa de aprendizaje y el valor del momento, de este modo se aísla el efecto que tiene el número de neuronas ocultas sobre el error cuadrático medio del entrenamiento. Si bien cada neurona adicional aportará mayor capacidad explicativa a la red, esta aportación será cada vez menor hasta llegar a un punto en que la capacidad explicativa del modelo no se ve afectada con la inclusión de nuevas neuronas. Los experimentos realizados revelaron que el número óptimo de neuronas de la capa oculta estaría en torno a las 48.

**Valor óptimo de la tasa de aprendizaje:** Fijando todos los parámetros que inciden en el entrenamiento de la red salvo la tasa de aprendizaje, se llegó a la conclusión de que el valor óptimo de este parámetro se situaría en torno a 0.8.

**Valor óptimo de momento:** Repitiendo una vez más el mismo proceso ya explicado, se obtuvo como valor óptimo del momento un valor situado en torno a 0.4, en resumen, los valores óptimos que definen el entrenamiento del modelo neuronal serían:

**Tabla 3.9** Valores óptimo de los parámetros del entrenamiento.

<b>Valores óptimos de los parámetros del entrenamiento</b>	
<b>Iteraciones</b>	100
<b>Neuronas Ocultas</b>	48
<b>Tasa de Aprendizaje</b>	0.6-0.8
<b>Momento</b>	0.4-0.6

Los Pesos (weights) y las Bias de la red neuronal se muestran en el Anexo 4.

### III.4.3. Predicción

Una vez concluido el entrenamiento, se asume que la red ha sido capaz de aprender las relaciones entre los datos presentados, con lo que la misma estará preparada para llevar a cabo tareas de predicción. La predicción se realiza sobre datos ya conocidos por la red, utilizados en su entrenamiento, ó alternativamente sobre datos nunca vistos. En el primer caso se contrasta la eficacia del aprendizaje, es decir, en que medida la red es capaz de replicar la serie objetivo al presentarle de nuevo los mismos datos con los que fue entrenada.

### III.4.4. Análisis de los resultados

A través del análisis estadístico se pudo comprobar que los valores del flujo de mineral que estaban presente en las series de datos correspondientes a los 4 meses que duró el experimento fueron 38, 40, 41 y 42 t/h, con los cuales se procedió entonces al entrenamiento, validación y generalización de la red neuronal.

Se debe destacar que este proceso se llevó a cabo con ayuda del programa que se muestra en el Anexo 1, que permitió determinar con mayor facilidad y menor tiempo que el método de aprendizaje con el cual se obtienen los mejores resultados es el de Levenberg-Marquart (*trainlm*), para las funciones de transferencia: tangente hiperbólica sigmoideal (*tansig*) y lineal (*purelin*). Estas estructuras se evaluaron para una red neuronal de cuatro capas con dos neuronas de entrada, 48 neuronas en la capa intermedia, una neurona en la penúltima y última capa, ver figura 3.3. Se debe destacar que con la versión del Matlab 7.7.0 (R2008b) por defecto se le agrega una capa a la salida de una neurona con una función de transferencia lineal (*purelin*). Se hizo énfasis en dos tipos de redes neuronales para las cuales se obtuvieron los mejores resultados en la primera etapa de la investigación, para luego seleccionar cual sería la que mejor caracteriza el proceso de enfriamiento del mineral reducido, ellas fueron la Feed – Forward Backpropagation y la Cascade – Forward Backpropagation.

Se debe destacar que la herramienta de Matlab que facilita el entrenamiento y la validación de la red neuronal, divide de manera aleatoria la base de datos de entrada, del cual toma el 60 % de los datos para el entrenamiento, un 20 % para la validación y el otro 20 % para la prueba de ajuste. De esta forma a través del programa del Anexo 1 se comprueba la generalización de la red con otra base de datos de otro mes de trabajo.

Los resultados obtenidos se muestran en la tabla 3.10, observándose las diferentes combinaciones de meses para lograr la generalización de la red, y que los mejores resultados están dados para un coeficiente de correlación entre 0,92 y 0,91 para el entrenamiento y la validación, y de 0,63 para la generalización, pero este valor se alcanza cuando el aprendizaje de la red no es lo suficientemente bueno.

Durante el proceso de evaluación de la red para flujos de mineral con valores entre 34, 35 y 37 t/h para los meses de Enero, Febrero y Marzo el entrenamiento se realizó con un coeficiente de regresión a 0.95 y a 0.90 para la validación. Pero la generalización de la red los resultados obtenidos no fueron satisfactorios, debido a que los valores de las variables de entrada para el entrenamiento no estaban dentro de los límites de las variables de entrada para la generalización. Luego según lo observado en la creación y el

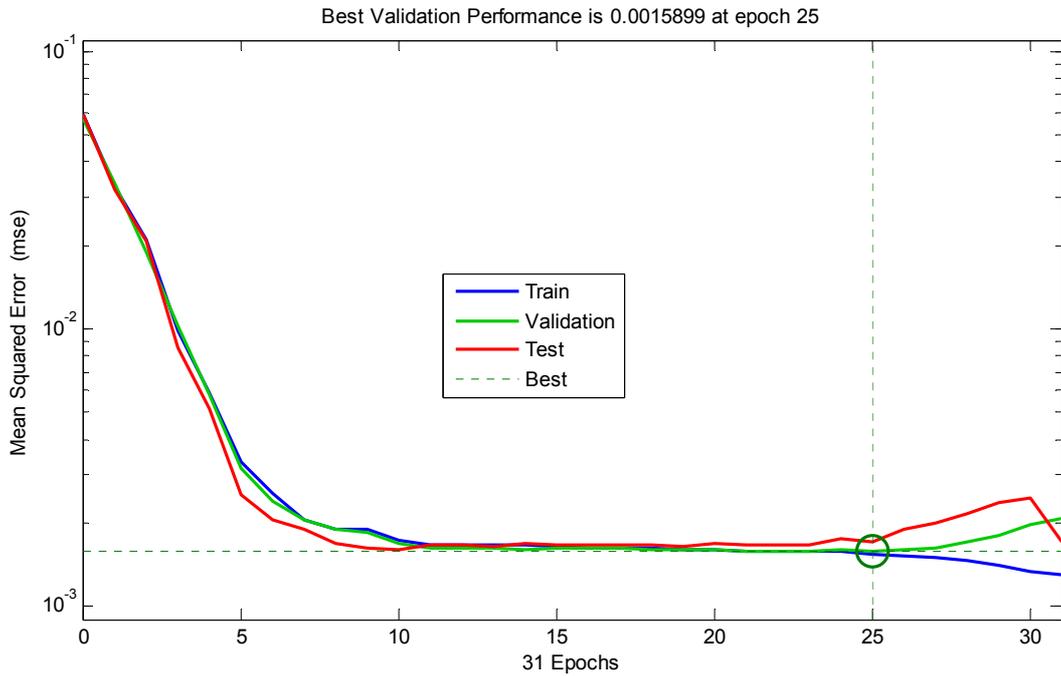
entrenamiento de la red para los meses de Marzo y Abril con 41 t/h del flujo de mineral el coeficiente de correlación es pequeño por debajo de 0.60 lo que indica que esa serie de datos no es recomendada para utilizarla como referencia para la caracterización del proceso en ese rango de explotación.

**Tabla 3.10** Resultados del entrenamiento, validación y generalización de la red neuronal Feed – Forward Backpropagation.

Meses		Flujo de mineral (t/h)	Regresión (R)		
			Entrenamiento	Validación	Generalización
Marzo	Enero	38	0.83	0.85	- 0.21
Enero	Marzo	39	0.91	0.91	0.29
Enero	Febrero	40	0.92	0.90	-0.12
Enero	Abril	40	0.86	0.74	-0.20
Febrero	Enero	40	0.68	0.70	0.63
Enero	Marzo	41	0.82	0.79	0.27
Febrero	Marzo	41	0.66	0.58	- 0.20
Abril	Enero	42	0.82	0.70	0.42
Abril	Marzo	42	0.78	0.64	- 0.16

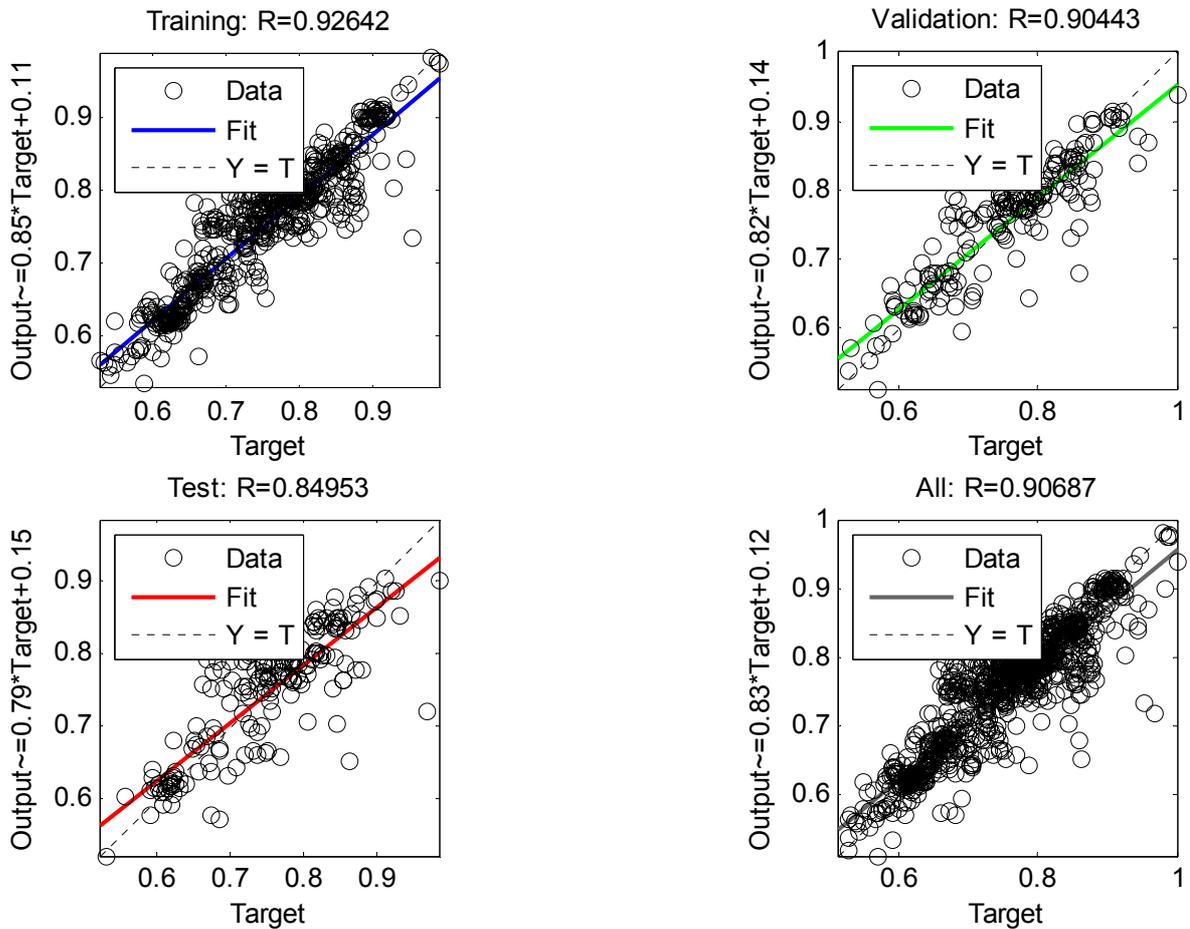
**red=newff(Data,Sal,[2 48 1],{'tansig' 'tansig' 'purelin'},'trainlm'**

La figura 3.4 muestra el comportamiento del entrenamiento de la red para uno de los procesos de aprendizajes relacionado con los resultados que aparecen en la tabla 3.10, observándose las curvas de entrenamiento, validación y de prueba, las cuales convergen a las 25 iteraciones para un error de 0,0016.



**Figura 3.4** Comportamiento del entrenamiento y la validación de la red neuronal Feed – Forward Backpropagation.

La figura 3.5 muestra el comportamiento de los coeficientes de correlación para el entrenamiento, validación, prueba y ajuste de la red neuronal.



**Figura 3.5** Comportamiento de los coeficientes de correlación del entrenamiento, validación y la prueba de la red neuronal Feed – Forward Backpropagation.

Luego se procedió a repetir el mismo proceso pero para una red neuronal de tipo Cascade – Forward Backpropagation, donde se utilizaron los mismos datos y estructuras que para la red neuronal anterior. La tabla 3.11 recoge los resultados del entrenamiento.

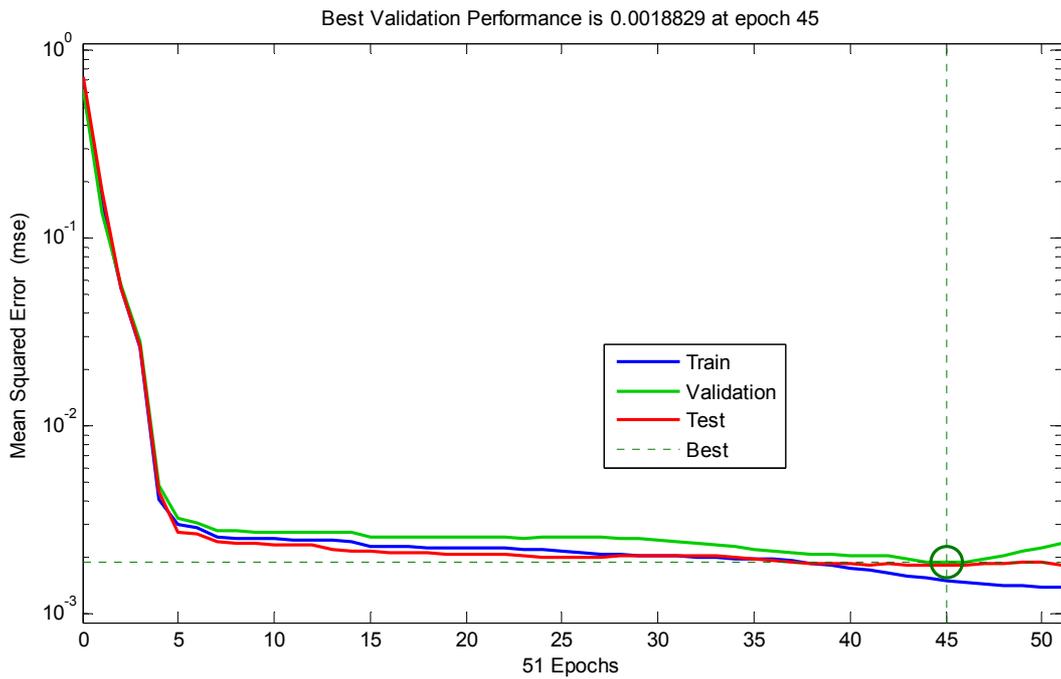
**Tabla 3.11** Resultados del entrenamiento, validación y generalización de la red neuronal Cascade – Forward Backpropagation.

Meses		Flujo de mineral (t/h)	Regresión (R)		
			Entrenamiento	Validación	Generalización
Enero	Marzo	38	0.91	0.92	- 0.17
Marzo	Enero	38	0.87	0.80	- 0.14
Enero	Febrero	39	0.92	0.89	-0.58
Enero	Marzo	39	0.91	0.85	0.67
Enero	Febrero	40	0.91	0.93	0.51
Febrero	Enero	40	0.80	0.78	0.74
Enero	Marzo	41	0.82	0.76	0.21
Enero	Abril	41	0.84	0.80	0.02
Enero	Abril	42	0.85	0.80	0.57
Febrero	Marzo	42	0.89	0.83	- 0.36

**red=newcf(Data,Sal,[2 48 1],{'tansig' 'tansig' 'purelin'},'trainlm'**

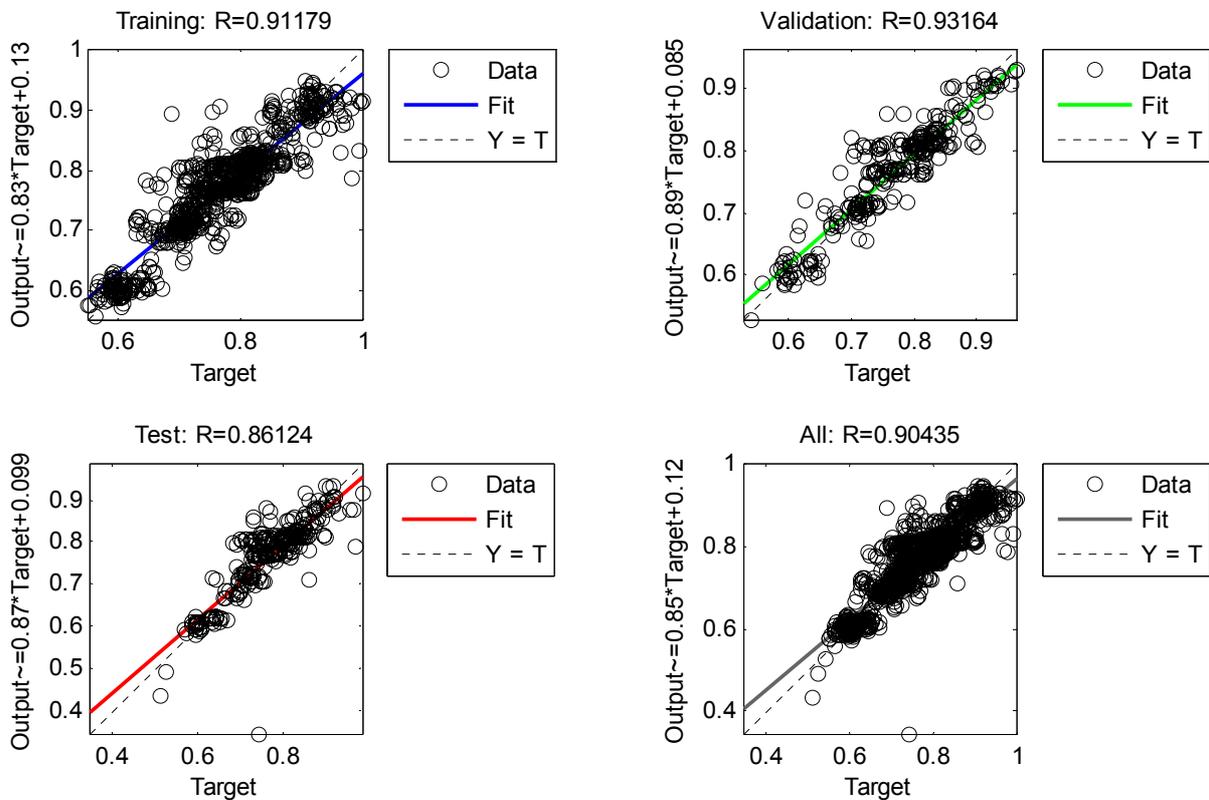
Según lo observado en la creación, entrenamiento y validación, el comportamiento es similar al obtenido con la red neuronal anterior, lo mismo está influenciado por las características propias del proceso que se reflejan en los datos obtenidos. No obstante se observa que se obtienen mejores coeficientes de correlación durante el entrenamiento y la validación de la red neuronal, haciéndose más notable en el proceso de generalización en el cual se alcanzan valores para el coeficiente de correlación superior al 0,63 obtenido con el tipo de red neuronal anterior.

La figura 3.6 muestra el comportamiento del entrenamiento de la red para uno de los procesos de aprendizaje relacionado con los resultados que aparecen en la tabla 3.11, observándose las curvas de entrenamiento, validación y la prueba las cuales convergen a las 45 iteraciones para un error de 0,0018.



**Figura 3.6** Comportamiento del entrenamiento y la validación de la red neuronal Cascade – Forward Backpropagation.

La figura 3.7 muestra el comportamiento de los coeficientes de correlación para el entrenamiento, validación, prueba y ajuste de la red neuronal.



**Figura 3.7** Comportamiento de los coeficientes de correlación del entrenamiento, validación y la prueba de la red neuronal Cascade – Forward Backpropagation.

### III.5. Conclusiones del capítulo III.

- Se identificaron las variables que intervienen en el proceso de enfriamiento de mineral (figura 3.1), así como las que son registradas por el son registrados por el “CYTET”.
- El proceso de ensayo y error permitió seleccionar los dos tipos de redes neuronales que mejor caracterizan el proceso de enfriamiento de mineral reducido.

## **CONCLUSIONES**

- La literatura especializada consultada no aborda teoría alguna relacionada con los enfriadores de mineral, y los trabajos realizados por investigadores e ingenieros de la industria solo se limitan al estudio de los mecanismos de transferencia de calor.
- El estado del arte indica que para la identificación de cualquier proceso de intercambio de calor es necesario desarrollar investigaciones de alta complejidad, teniendo en cuenta cantidad de variables que no siempre están disponibles; siendo en este caso donde se justifica la utilización de modelos neuronales, a partir de los conocimientos de las entradas y salidas.
- El trabajo de campo permitió identificar las variables que son registradas por el "CYTET son: Flujo de mineral alimentado al horno, Temperatura de los gases en el hogar 15, Temperatura del mineral a la descarga del enfriador, Flujo de agua, Temperatura del agua en la piscina, Corriente del motor y que los datos que ofrecen un mejor comportamiento son: Enero, Febrero, Marzo y Abril.
- Se demostró a través del análisis estadístico que las variables que más inciden en la temperatura del mineral a la descarga del enfriador son la temperatura y el flujo del agua, y el flujo de mineral que entra al enfriador.
- Quedó demostrada la capacidad de la redes Feed-Forward Backpropagation y Cascade – Forward Backpropagation para la simulación de procesos de transferencia de calor en la industria.
- La estructura que mejor caracteriza el comportamiento de la temperatura del mineral a la descarga del enfriador está caracterizada por 4 capas con 2 neuronas de entrada, 48 neuronas en la capa intermedia y 1 en la capa de salida, con método de aprendizaje Levenberg-Marquart (trainlm), y las funciones de transferencia: tangente hiperbólica sigmoideal (tansig) y lineal (purelin),
- El modelo neuronal propuesto ha sido capaz de predecir la temperatura de salida del mineral con una precisión del 99 % para flujos de mineral entre 34 y 37 t/h y con una precisión hasta de un 93 % para flujos de mineral entre 38 y 42 t/h .
- Se demostró la capacidad de las redes neuronales artificiales para la identificación del proceso de enfriamiento de mineral.

## **RECOMENDACIONES**

- Continuar la búsqueda bibliográfica y la vigilancia tecnológica para la aplicación de los nuevos conocimientos que se publiquen en la solución de la problemática en estudio.
- Proponer un diseño de experimentos que permita la inclusión de nuevas variables del proceso para obtención de datos confiables, ya sea a escala industrial o piloto, donde se refleje la menor cantidad de perturbaciones.
- Continuar con el estudio de las redes neuronales y su aplicación al proceso de enfriamiento sobre la base de redes neuronales dinámicas y la optimización de la temperatura del mineral a la salida del enfriador de mineral.
- Evaluar la posibilidad de aplicar otras técnicas de inteligencia artificial al enfriamiento del mineral reducido como son los algoritmos genéticos y lógica difusa.

## **BIBLIOGRAFÍA**

1. ALEPUZ, H. Mejora en el proceso de enfriamiento de mineral reducido con el enfriamiento actual. Nicaro: empresa "Cmdte. René Ramos Latour", 1977. 38p. Informe técnico.
2. ALONSO, C. Características del movimiento del mineral reducido caliente dentro de los enfriadores de mineral. Nicaro: empresa "Cmdte. René Ramos Latour", 1973. 27p. Informe técnico.
3. BARRON, A.R, "Complexity regularization with application to artificial neural networks" Nonparametric Functional Estimation and Related Topics (G. Roussas, ed.), pp.561-576, 1991
4. BARRON, A.R. "Neural net approximation" Proc. of the Seventh Yale Workshop on Adaptive and Learning Systems, pp.69-72. New Haven, CT: Yale University, 1992.
5. COLUMBIÉ, A. Modelación matemática del proceso de calcinación del carbonato básico de níquel en el horno tubular rotatorio. Tesis doctoral. ISMMANJ, Moa, 2001. 98p.
6. CHANG C. A., "Una visión sobre las reservas estratégicas de eficiencia metalúrgica en la tecnología carbonato-amoniaco", Revista Minería y Geología, Vol. XVI, No.1., 1999.
7. CHEN, M. Double-diffusive convection for a heated cylinder submerged in a salt-stratified fluid layer. Heat Mass Transfer 33, 1997: 17-26
8. DOROKHOV, A. R. Heat exchange with horizontal cylinders in a centrifugal-bubbling bed. Journal of Engineering Physics and Thermophysics, Vol. 74, No. 3, 2001: 800-805
9. GSCHWENDTNER, M. A. Optical investigation of the heat transfer from a rotating cylinder in a cross flow. Heat and Mass Transfer 40, 2004: 561-572
10. GÁNGARA, C. Enfriamiento del mineral reducido mediante la adición directa de agua atomizada en el enfriador rotatorio de Nicaro. Nicaro: empresa "Cmdte. René Ramos Latour", 1980. 32p. Informe técnico.
11. GEORGE E.P. Bo, Gwilym M. Jenkins "Time series analysis: forecasting and control", Holden-Day Inc., CA, (Revised Edition) 1976

12. GÓNGORA, E. Modelación físico-matemática del proceso de enfriamiento de mineral en cilindros rotatorios de la planta hornos de reducción de la empresa "Comandante Ernesto Che Guevara". Tesis de maestría. ISMMANJ, Moa, Cuba, 2004. 80p.
13. GÓNGORA, E. Modelo matemático multivariable para un proceso de enfriamiento industrial de sólidos en cilindros rotatorios horizontales. *Energética*, Vol. XXVIII, No. 2, 2007: 15 -25
14. GUZMÁN, D. Proceso de lixiviación carbonato-amoniaco: control multivariable a través del arreglo inverso de Nyquist para el mezclado de mineral y licor. *Minería y Geología*, Vol. XVII I, No. 2, 2001. 6p.
15. HOSSAIN, M. A. Radiation-conduction interaction on mixed convection from a horizontal circular cylinder. *Heat and Mass Transfer* 35, 1998: 307-314
16. IANNETTA, S. Experimental analysis of thermal fields in horizontally eccentric cylindrical annuli. *Experiments in Fluids* 12, 1992: 385-393
17. INCROPERA, F. *Fundamentals of Heat and Mass Transfer*. Tercera edición. La Habana: Editorial Pueblo y Educación, 2003 Tomo I, II. III.
18. Informe técnico de la empresa Ernesto Che Guevara. Resumen sobre los trabajos perspectivas de los Enfriadores de Mineral. 1998.
19. KERN, D., *Procesos de Transferencia de Calor*. Primera Edición. Trigésima primera reimpresión. Editorial Continental S.A. de CV , Inc.1999. pp 970.
20. LJUNG, L. "System identification: Theory for the user" Prentice Hall, Englewood Cliffs, NJ, 1987
21. LJUNG, L, Sjöberg, J.1992 IEEE Workshop on Neural Networks for Signal Processing. IEEE Service Center, 445 Hoes Lane, Piscataway, NJ 08854-4150. 1992
22. MAHFOUZ, F. M. Heat convection from a cylinder performing steady rotation or rotary oscillation. *Heat and Mass Transfer* 34, 1999: 375-380
23. MAHFOUZ, F. M. Transient free convection from a horizontal cylinder placed in a micropolar fluid. *Heat and Mass Transfer* 39, 2003: 455-462
24. Manual de Operaciones de la planta Hornos de Reducción de la empresa "Cmdte. Ernesto Che Guevara", 1985. 219p.

25. MIRANDA L. J., " Cronología de los antecedentes históricos de la explotación de los yacimientos lateríticos por la tecnología de Lixiviación Ácida a Presión", Revista Cubana de Química, No. 1, Vol. XV, 2003, Pág. 3 – 8.
26. MUÑOZ, A., CZERNICHOW, T. "Variable Selection through Statistical Sensibility Analysis: Application to Feedforward and Recurrent Neural Networks" Tech. Rep. 95-07-01 Institute National de Télécommunications (INT-SIM). Paris 1995
27. NAUMENKO, Y. V. Numerical calculation of the flow regimes of a fluid partially filling a horizontal rotating heat-exchange cylinder. Journal of Engineering Physics and Thermophysics, Vol. 74, No. 3, 2001: 736-744
28. NAZAR, R. Mixed convection boundary-layer flow from a horizontal circular cylinder with a constant surface heat flux. Heat and Mass Transfer 40, 2004: 219–227
29. OLIVAS, P. On unsteady electrochemical coating of a cylinder at moderately large Reynolds number. Journal of Applied Electrochemistry 27, 1997, pp. 1369-1379.
30. PELLET, H. Thermofluiddynamic experiments with a heated and rotating circular cylinder in crossflow. Experiments in Fluids 2, 1984, pp. 113-120.
31. PENG, S. W. Theoretical analysis of laminar film condensation in a rotating cylinder with a scraper. Heat and Mass Transfer 34, 1998: 279-285
32. PERRY J. H. Chemical Engineering Handbook. 6ta Edición. Mc Graw Hill, New York ./pág 7-20. 1979
33. PRESILLA, D. Mejora en el proceso de enfriamiento de mineral reducido con el enfriamiento actual. Nicaro: empresa "Cmdte. René Ramos Latour", 1977. 12p. Informe técnico.
34. RAMÍREZ, M. Identificación experimental del subproceso de postcombustión en un horno de reducción de níquel. Minería y Geología Vol. XVII I, No. 2, 2001: 61-66
35. ROSELL, R. Las posibles causas que están incidiendo sobre el enfriamiento deficiente del mineral dentro de los cooler. Nicaro: empresa "Cmdte. René Ramos Latour", 1986. 15p. Informe técnico.
36. ROHSENOW, W. M., M "A method of correlating heat transfer data for surface boiling liquids". Trans. ASME, 74, 969, 1952.
37. RUMELHART, D.E, HINTON, G.E. "Learning representations by back-propagating errors", 323, pp.533-536, 1986

38. SCURTU, N. D. Free convection between two horizontal concentric cylinders filled with a porous medium a perturbed solution. *Acta Mechanica* 151, 2001: 115- 125
39. SHRAGER, G. R. Modeling of the Viscous Flow with a Free Surface inside a Rotating Horizontal Cylinder. *Theoretical Foundations of Chemical Engineering*, Vol. 39, No. 3, 2004: 283–289
40. SJÖBERG, J. “Non-Linear System Identification with Neural Networks” Ph. D. Thesis, Linköping University, Sweden, 1995
41. TORRES, E. Modelación matemática y simulación del transporte neumático del mineral laterítico. Tesis doctoral. ISMMANJ, Moa. 2003. 105p.
42. TUNRA. Ore Cooler Evaluation. The University of New Castle Research Associates Limited, 1998. 18p.
43. a) VALLE, M. Evaluación de los enfriadores de mineral de la empresa Cmdte "Ernesto Che Guevara" de Moa (1). *Tecnología Química*, Vol. XX, No. 1, 2000: 70-77
44. b) VALLE, M. Evaluación de los enfriadores de mineral de la empresa Cmdte "Ernesto Che Guevara" de Moa (2). *Tecnología Química*, Vol. XX, No. 2, 2000: 10-15
45. WANG, T. Granule transport and mean residence time in horizontal drum with inclined flights. *Powder Technology* 162, 2004: 50 – 58
46. YAPICI, H. Transient temperature and thermally induced stress distributions in a partly-circumferentially heated cylindrical workpiece. *Heat Mass Transfer* 41, 2004:104–111

## ANEXO 1: Programa para el proceso de ensayo y error.

```
function Ever
clear,clc
[A1,TXT] = xlsread('E','39');
A = [A1(:,1) A1(:,3) A1(:,4)]; % Tsm(°C) Fm(t/h) FH2O (m3/h) TH2O(°C)
Data = [A1(:,3)/max(A1(:,3)) A1(:,4)/max(A1(:,4))];
Sal=A1(:,1)'/max(A1(:,1));
disp(' Método de aprendizaje ')
disp(' ')
disp(' (1) Levenberg-Marquart')
disp(' (2) Backpropagation con momento')
disp(' (3) Bacpropagation')
disp(' (4) Backpropagation adaptativo')
disp(' (5) Backpropagation extendido')
k = input('Seleccione una de ellas ? ');
if k==1
    mopt='trainlm';
elseif k==2
    mopt='traingdm';
elseif k==3
    mopt='traingd';
elseif k==4
    mopt='traingda';
elseif k==5
    mopt='traingdx';
end;
% logsig,hardlims,poslin,radbass,satlin,tribas, purelin y/o tansig
%red=newff(Data,Sal,[2 48 1],{'tansig' 'tansig' 'purelin'},'mopt');
red=newcf(Data,Sal,[2 48 1],{'tansig' 'tansig' 'purelin'},'mopt');
red = train(red,Data,Sal);% Se entrena la red.
Y = sim(red,Data);% Se simula la red.
figure(2)
plot(Sal*max(A(:,1)), 'b'),
hold on
plot (Y*max(A(:,1)), 'r'),grid
legend('Salida del proceso', 'Salida de la RNA')
title('Entrenamiento')
ylabel('Temperatura del mineral a la salida (oC)')
xlabel('Número de observaciones')
hold off
figure(3)
plot(Y*max(A(:,1)),Sal*max(A(:,1)), '*'),grid
title('Entrenamiento')
xlabel('Temperatura de salida del modelo (oC)')
ylabel('Temperatura de salida del proceso (oC)')
hold off
B1,TXT] = xlsread('M','39');
B = [B1(:,1) B1(:,3) B1(:,4)]; % Tsm(°C) Fm(t/h) FH2O (m3/h) TH2O(°C)
% INICIO LAZO
D = B; % D toma los datos de B
[Am,n] = max(A); % Referencia máximo Matriz A
[mA,k] = min(A); % Referencia mínimo Matriz A
[Bm,m] = max(D); % Máximo Matriz B
[mB,h] = min(D); % Mínimo Matriz B
[u,v] = size(D); % Filas y columnas Matriz B
```

```
% ELIMINAR ELEMENTOS DE [B] MAYORES QUE LOS MÁXIMOS DE [A] (COLUMNAS)
for J=1:u
    H(J,:) = D(J,:) <= Am; % [B] menores que máximo de [A]
    G(J,:) = D(J,:) >= mA; % [B] mayores que mínimo de [A]
    for k = 1:v
        if H(J,k) == 0, NK(J) = J; end % Cuenta mayores que máximo
        if G(J,k) == 0, NK(J) = J; end % Cuenta menores que mínimo
    end
end
nk = NK(NK~=0); % Número de filas a eliminar
D(nk,:)= []; % Matriz resultante
clear NK
% FIN DEL LAZO
% LA MATRIZ D ES DE 3 COLUMNAS PORQUE SOLO TIENE 2 ENTRADAS
Dat asim = [D(:,2)/max(D(:,2)) D(:,3)/max(D(:,3))]';
Salsim = D(:,1)'/max(D(:,1));
% VER COMO INFLUYE QUE AMBOS ASUMAN NUM(:,1)'/max(NUM(:,1));
Ysim = sim(red,Dat asim); % Se simula la red para los nuevos datos.
figure(4)
plot(Salsim*max(D(:,1)), 'b')
hold on
plot(Ysim*max(D(:,1)), 'r'), grid
legend('Salida del proceso', 'Salida de la RNA')
title('Generalización')
xlabel('Número de observaciones')
ylabel('Temperatura del mineral a la salida (oC)')
hold off
figure(5)
plot(Ysim*max(D(:,1)), Salsim*max(D(:,1)), '*'), grid
title('Generalización')
xlabel('Temperatura de salida del modelo (oC)')
ylabel('Temperatura de salida del proceso (oC)')
hold off
figure(6)
subplot(2,2,1),
plot(Sal, 'b'),
hold on
plot(Y, 'r'), grid
legend('Salida Sal', 'Salida Y')
hold off
subplot(2,2,2),
plot(Salsim, 'b')
hold on
plot(Ysim, 'r'), grid
legend('Salida Data', 'Salida Ysim')
hold off
subplot(2,2,3),
hold on
plot(Y, Sal, '*'), grid
hold off
subplot(2,2,4),
hold on
plot(Ysim, Salsim, '*'), grid
hold off
Rtrain = corrcoef(Y, Sal)
Rsimul = corrcoef(Ysim, Salsim)
```

**ANEXO 2: Resumen del proceso de ensayo y error.**

Resumen del proceso de ensayo y error para la selección de la estructura de la red para tres entradas y una salida.

Número de Neuronas por Capas					Función	Épocas	Time	Perform	Regresión		
1	2	3	4	5					Entrenamiento	Validación	Generalización
3	1				tansig	15	0:00:08	0.00350	0.58	0.52	0.43
6	1					54	0:03:07	0.00287	0.66	0.61	0.35
12	1					16	0:01:03	0.00269	0.70	0.68	-0.34
<b>24</b>	1					<b>78</b>	<b>0:04:16</b>	<b>0.00168</b>	<b>0.81</b>	<b>0.78</b>	<b>0.34</b>
30	1					55	0:03:34	0.00169	0.81	0.79	-0.25
36	1					30	0:02:16	0.00182	0.79	0.77	-0.09
42	1					29	0:02:05	0.00181	0.80	0.76	0.034
48	1					14	0:01:04	0.00197	0.80	0.71	-0.15
54	1					14	0:01:05	0.00195	0.80	0.74	-0.29
54	1					pirulin	3	0:00:17	0.00393	0.47	0.45
3	1	1			tansig - pirulin	36	0:02:37	0.00319	0.62	0.60	0.11
6	1	1				24	0:01:48	0.00307	0.62	0.63	0.28
12	1	1				41	0:02:41	0.00214	0.76	0.74	0.37
24	1	1				59	0:03:48	0.00174	0.80	0.77	-0.12
30	1	1				15	0:01:07	0.00210	0.77	0.70	-0.32
36	1	1				38	0:02:55	0.00184	0.80	0.74	-0.36
42	1	1				55	0:03:48	0.00144	0.84	0.78	0.43
48	1	1				17	0:01:15	0.00182	0.80	0.73	-0.41
3	3	1	1			46	0:03:00	0.00326	0.58	0.60	-34
6	6	1	1			26	0:01:50	0.00304	0.64	0.58	37
12	12	1	1			45	0:03:26	0.00240	0.73	0.67	-0.28
24	24	1	1			18	0:02:38	0.00212	0.77	0.70	-0.37
30	30	1	1			91	0:19:15	0.00160	0.82	0.75	-0.34
<b>34</b>	<b>34</b>	1	1			<b>29</b>	<b>0:06:37</b>	<b>0.00193</b>	<b>0.79</b>	<b>0.76</b>	<b>0.20</b>
3	3	1	1		tansig - tansig - pirulin	30	0:01:50	0.00292	0.66	0.60	-0.18
3	6	1	1			101	0:05:59	0.00219	0.75	0.72	-0.42
3	12	1	1			17	0:01:07	0.00232	0.75	0.73	-0.41
3	24	1	1			16	0:01:13	0.00204	0.79	0.72	-0.35
3	30	1	1			32	0:02:25	0.00176	0.81	0.76	0.17
3	36	1	1			36	0:02:41	0.00175	0.82	0.77	-0.38
3	42	1	1			21	0:01:42	0.00179	0.82	0.69	-0.20
<b>3</b>	<b>48</b>	<b>1</b>	<b>1</b>			<b>39</b>	<b>0:02:54</b>	<b>0.00157</b>	<b>0.83</b>	<b>0.77</b>	<b>0.34</b>
3	54	1	1			13	0:01:23	0.00223	0.78	0.66	0.27
3	3	3	1	1		logsig - tansig - tansig - pirulin	52	0:00:25	0.00246	0.74	0.68
3	6	6	1	1	17		0:00:15	0.00250	0.74	0.69	0.37
3	12	12	1	1	49		0:01:41	0.00161	0.83	0.79	-0.15
<b>3</b>	<b>24</b>	<b>24</b>	1	1	<b>26</b>		<b>0:03:04</b>	<b>0.00154</b>	<b>0.84</b>	<b>0.79</b>	<b>0.23</b>
<b>3</b>	<b>30</b>	<b>30</b>	1	1	<b>29</b>		<b>0:06:35</b>	<b>0.00164</b>	<b>0.85</b>	<b>0.76</b>	<b>-0.34</b>
3	34	34	1	1	20		0:06:52	0.00173	0.81	0.77	-0.40

### **ANEXO 3: Resumen del proceso de ensayo y error por Flujo de mineral.**

Se dividieron los datos por flujo de mineral y se procesaron identificarlos.

```
red=newff(Data,Sal,[2 48 1 1],{'tansig' 'tansig' 'purelin'},'trainlm');
red=newcf(Data,Sal,[2 48 1 1],{'tansig' 'tansig' 'purelin'},'trainlm');
```

#### **Enero - Abril**

Flujo Mineral (t/h)	Épocas	Time	Perform.	Regresión		
				Entrenamiento	Validación	Generalización
38	56	0:00:18	0.00289	0.90	0.89	-0.39
40	209	0:07:28	0.00120	0.93	0.92	-0.19
41	78	0:00:52	0.00208	0.83	0.76	0.14
42	26	0:00:18	0.00267	0.84	0.84	0.62

#### **Enero – Febrero**

Flujo Mineral (t/h)	Épocas	Time	Perform.	Regresión		
				Entrenamiento	Validación	Generalización
34	10	0:00:06	0.0006	0.99	0.36	-0.39
37	14	0:00:08	0.000897	0.94	0.91	0.059
38	17	0:00:10	0.0097	0.71	0.60	0.27
39	82	0:00:42	0.0013	0.91	0.91	0.29
40	36	0:00:18	0.00451	0.73	0.75	-0.27
41	123	0:01:26	0.00215	0.82	0.84	-0.32
42	74	0:00:43	0.00226	0.86	0.81	0.19

#### **Enero – Marzo**

Flujo Mineral (t/h)	Épocas	Time	Perform.	Regresión		
				Entrenamiento	Validación	Generalización
35	12	0:00:06	2.91e-05	0.99	0.98	0.75
38	114	0:00:35	0.00280	0.91	0.91	-0.09
39	334	0:02:41	0.00069	0.95	0.95	0.50
40	20	0:00:11	0.00498	0.71	0.74	0.22
41	106	0:01:13	0.00252	0.79	0.80	0.09
41.4	9	0:00:08	0.00206	0.70	0.59	-.005
42	68	0:00:35	0.0026	0.83	0.79	0.24
42.4	13	0:00:06	0.0044	0.49	0.52	0.08
43	42	0:00:19	0.00403	0.62	0.58	0.91

**ANEXO 4: Resumen de una muestra de las series de datos.**

Se muestra un resumen de una serie de datos empleados en el entrenamiento, validación y generalización de la red neuronal artificial.

$T_{SM}$	$F_m$	$F_{H2O}$	$T_{SH2O}$	$T_{SM}$	$F_m$	$F_{H2O}$	$T_{SH2O}$	$T_{SM}$	$F_m$	$F_{H2O}$	$T_{SH2O}$
248,89	38,00	82,09	63,30	256,01	40,00	82,22	65,09	185,90	42,00	22,62	77,58
266,59	38,00	22,68	83,81	258,59	40,00	82,19	65,05	184,74	42,00	22,71	77,82
267,03	38,00	22,76	83,89	257,89	40,00	82,28	65,10	183,37	42,00	22,61	78,07
266,86	38,00	22,75	83,86	257,50	40,00	82,21	65,11	180,78	42,00	22,48	78,24
267,31	38,00	22,63	83,89	252,87	40,00	82,38	65,08	177,34	42,00	22,46	78,40
268,86	38,00	22,75	83,89	252,28	40,00	82,16	64,85	173,42	42,00	22,70	78,48
269,95	38,00	22,59	83,78	247,71	40,00	82,21	64,88	166,64	42,00	22,67	75,87
269,48	38,00	22,81	83,77	244,55	40,00	82,31	64,83	169,19	42,00	22,82	76,01
269,64	38,00	22,74	83,77	241,16	40,00	82,40	64,79	172,09	42,00	22,67	76,30
271,49	38,00	22,68	83,84	238,80	40,00	82,43	64,73	175,16	42,00	22,58	76,64
274,75	38,00	22,66	83,75	235,50	40,00	82,13	64,61	178,51	42,00	22,56	76,89
274,26	38,00	22,66	83,70	233,71	40,00	82,38	64,45	182,57	42,00	22,58	77,27
273,00	38,00	22,59	83,70	232,71	40,00	82,37	64,33	187,36	42,00	22,58	77,62
270,44	38,00	22,37	83,67	234,25	40,00	81,89	64,34	193,13	42,00	22,69	78,12
268,28	38,00	22,54	83,61	237,90	40,00	82,19	64,30	199,95	42,00	22,61	78,56
267,68	38,00	22,56	83,70	239,89	40,00	82,10	64,16	207,16	42,00	22,66	78,92
267,88	38,00	22,48	83,79	166,70	40,00	22,69	74,82	215,69	42,00	22,68	79,41
267,10	38,00	22,41	83,71	171,48	40,00	22,56	75,21	224,68	42,00	22,63	79,99
246,89	38,00	30,57	79,11	179,25	40,00	22,68	76,06	240,16	42,00	22,56	80,53
257,74	38,00	30,64	79,29	182,33	40,00	22,64	76,81	251,95	42,00	22,68	81,25

$T_{SM}$ :	Temperatura del mineral a la salida del enfriador
$F_m$ :	Flujo másico de mineral a la entrada del enfriador
$F_{H2O}$ :	Flujo másico de agua que entra a la piscina
$T_{SH2O}$ :	Temperatura del agua en la piscina

#### ANEXO 4: Pesos y Bias de la red neuronal.

$iw\{1,1\}$  – Weight to layer 1 from input 1  
[2.0377 -2.3632; 0.39414 -3.743]

$iw\{2,1\}$  – Weight to layer 2 from input 1  
[-1.071 0.70114; -0.55594 2.3385; -1.6211 2.6983; -1.6906 3.1004; 1.5865 2.4069; 0.251 1.872; 3.2967 0.84062; -0.65985 3.4477; 0.88955 0.287; -0.72388 0.51929; 1.6053 1.3077; 1.7615 -1.8889; -1.5093 0.18329; -1.1095 1.7283; 2.9592 0.6512; 3.0263 1.8408; -2.0907 2.8452; 0.87435 0.89903; -0.78989 -0.74722; 4.1955 1.6049; 2.0564 -2.4542; -2.3469 0.87446; 2.6578 1.2679; 3.0896 1.6138; -0.67738 3.8373; 3.6297 2.2388; 0.72037 1.2428; -0.69288 -0.64638; -2.1396 3.1936; -0.76042 0.62505; -1.1583 -1.9081; 1.5845 -1.8278; 1.9722 4.4222; -1.3898 -0.074932; -0.93509 3.4435; -1.7966 -1.2465; -3.4753 -0.1293; -4.0027 0.59149; 1.3282 -2.5556; -0.49701 0.94837; -1.8944 -0.51486; -0.064849 -2.5269; -4.8445 2.4222; -2.0171 -1.8881; 1.6703 -1.8157; -1.5586 -0.16489; 2.1081 -1.877; 1.2701 -2.3666]

$iw\{3,1\}$  – Weight to layer 3 from input 1  
[-0.51926 -0.67566]

$iw\{4,1\}$  – Weight to layer 4 from input 1  
[0.99706 -0.20202]

$lw\{2,1\}$  – Weight to layer  
[-3.3095 0.60991; 0.992 2.6074; -1.5708 -1.0658; 0.26339 -0.12648; 0.92162 -2.1634; 2.2266 -3.8896; 0.33175 1.3846; -0.06234 -1.4645; -4.2228 4.7004; -1.1197 -2.6316; 1.8216 2.5431; 2.6029 0.26291; -2.6527 2.1595; -1.2618 2.674; 0.53495 -2.1254; 1.0541 -0.31821; -1.1524 -0.25181; -2.9238 2.0274; 2.0457 2.8387; -1.5415 -3.3422; -2.0242 -2.8735; -2.6129 -0.88482; -2.333 -3.17; 0.44899 0.46889; -0.96226 0.15879; -0.026152 -2.7612; 3.2002 -1.7335; 2.7631 3.5415; 2.9376 0.15007; -3.597 -0.16597; -0.79589 3.9994; 2.1261 -1.8727; 2.0948 2.2057; 2.8166 1.7791; 3.0848 0.27156; 0.27452 -2.5847; -1.5918 1.6066; 0.57707 -2.0393; -1.4809 -1.8688; -4.1392 -0.81363; 2.1834 2.0791; -1.1418 -2.4407; -3.1428 -5.5201; -0.45873 -1.8757; -1.0319 -0.40229; 1.2604 -6.1839; -2.16 1.6715; 3.8118 -2.7299]

$lw\{3,1\}$  – Weight to layer  
[-0.1126 -0.41975]

$lw\{4,1\}$  – Weight to layer  
[-0.2393 -0.030493]

$lw\{3,2\}$  – Weight to layer  
[1.1611 -0.36808 -0.37776 -0.24737 -0.22418 -1.0167 -0.089675 0.76339 1.1413 -0.44526 -1.0363 0.48858 0.65918 0.15342 -0.82525 0.98538 -0.22321 -0.54096 1.0236 0.80862 -1.0271 0.43635 2.1101 0.26665 0.10841 0.70375 0.43178 0.21966 0.20131 0.26405 -1.1491 -1.0091 -0.22358 -0.24403 -0.057084 0.69868 0.35387 -0.50487 0.25605 0.59173 0.58196 0.65287 0.42371 -0.50242 -0.51348 -2.1117 0.87218 0.28991]

lw{4,2} – Weight to layer

[-0.39602 -0.28074 -0.25256 0.92517 0.71993 -0.40989 0.47559 0.23373 2.0224 -0.42549  
0.094585 0.43015 -0.67115 -0.23308 0.32449 1.2576 -0.87138 -0.22975 0.052035 3.0274  
-2.0164 -0.87409 1.5477 1.0154 0.66055 3.1286 -0.045261 1.7639 -2.3438 -1.0858  
-1.3509 0.65341 -2.6076 -0.031037 -1.846 -1.5073 1.5407 2.387 0.38329 0.62812  
-0.15239 0.32031 1.9282 -0.89272 -0.17015 -2.9299 1.2777 0.80465]

lw{4,3} – Weight to layer

[2.4178]

b{1} – Bias to layer 1

[-0.10449; 1.3183]

b{2} – Bias to layer 2

[3.8631; 3.5347; 3.3899; 3.4409; -3.0817; 0.38542; -2.7399; 2.292; -0.24869; 3.2761;  
-2.0284; -1.9753; 1.6723; 1.9001; -1.2455; -1.5893; 1.3486; -0.80181; 1.5134; -0.93945;  
-1.3954; 0.49206; 0.3157; 0.35248; 1.7941; -1.2727; -0.37722; -1.3155; -2.2139; -0.78214;  
3.575; 1.1512; 1.8516; -1.5554; 0.93204; -2.0416; -2.8325; -3.5766; 2.0829; -1.4507;  
-2.653; -2.7242; -1.7832; -3.453; 4.0086; 3.6847; 3.5862; 1.9984]

b{3} – Bias to layer 3

[0.33331]

b{4} – Bias to layer 4

[0.64173]