



REPUBLICA DE CUBA

MINISTERIO DE EDUCACION SUPERIOR  
INSTITUTO SUPERIOR MINERO METALÚRGICO

Dr. ANTONIO NÚÑEZ JIMÉNEZ

FACULTAD DE METALURGIA Y ELECTROMECAÁNICA

DEPARTAMENTO DE INGENIERIA MECÁNICA

# **TRABAJO DE DIPLOMA**

TESIS EN OPCION AL TÍTULO DE INGENIERO MECÁNICO

**TÍTULO: Método para la corrección de la característica de carga de bombas centrífugas con la utilización de Redes Neuronales**

**DIPLOMANTE: *Luís Afonso Fernandes Neves***

**TUTOR: *Ms.C. Héctor Luís Laurencio Alfonso***

*MOA - 2008*

*“Aniversario 50 de la Revolución”*

---

## DECLARACIÓN DE AUTORIDAD

El autor de este trabajo de diploma titulado “Método para la corrección de la característica de bombas centrífugas con la utilización de Redes Neuronales”, Luis Afonso Fernandes Neves, certifica la propiedad intelectual a favor del Instituto Superior Minero Metalúrgico de Moa a hacer uso del mismo con la finalidad académica que estime conveniente.

---

Luis Afonso Fernandes Neves  
Autor

---

Ms.C. Héctor Luís Laurencio Alfonso  
Tutor

---

## PENSAMIENTO

“ ESTUDIAR MUCHA TORA NO ES MOTIVO DE ORGULLO, ES EL PROPOSITO POR  
EL QUE HAS SIDO CREADO ”

Luis Alfonso F. Neves

## DEDICATORIA

---

Dedico este trabajo con toda la gratitud del mundo a mi gran **ETERNO ADONAY**, como prueba del agradecimiento de todo lo que ha hecho por mí sin que lo merezca.

---

## AGRADECIMIENTOS

Sin ánimos de establecer prioridades, les agradezco a todas aquellas personas que permitieron y desearon la culminación de este trabajo. No se pueden dejar de mencionar a mi novia Julia Nela Estevez Girón y su familia en particular, los compañeros del cuarto Ngaggne Guewe y Samson Watulatsu que han sido mis compañeros de cuarto por más de 6 años. También agradezco a mí tutor Ms.C. Ing. Héctor Laurencio Alfonso, que ha estado contribuyendo fuertemente para la realización de este trabajo y a La Revolución Cubana de haberme dado la oportunidad de estudiarme en Cuba.

En realidad agradezco a tantas personas que aunque no encuentren sus nombres escritos en este documento, sí deben saber que les necesité mucho y les guardo en mí actuar diario. Algunos me dieron ánimos, otros me ofrecieron sus medios para que trabajara, quizás algunos simplemente confiaron en mí, otros me guiaron cuando estaba perdido, en fin... les agradezco mucho a todos. De una forma justa y agradecida quisiera agradecer a mi **ETERNO SEÑOR** que ha y estará siempre a mi lado apoyándome en los momentos difíciles mediante este trabajo lo prometo que un día lo seré justo delante de sus ojos.

---

## RESUMEN

En este trabajo de diploma, se presenta la aplicación de Redes Neuronales artificiales en la corrección de la curva característica de las bombas centrífugas para diferentes viscosidad. Esta tecnología, relativamente nueva, sirve para poder reemplazar eficientemente algunos de los métodos usados hasta el momento.

Se hace una revisión bibliográfica sobre el tema y sobre los factores más influyentes en la selección de bombas y una breve introducción sobre Redes Neuronales y sus fundamentos.

Como resultado del trabajo, se desarrolla una Red Neuronal backpropagation describiendo algunos tipos de funciones, estructuras y algunos métodos de implementación usado para la creación de la Red mediante el programa MATLAB lo que se simula con los datos dado por el fabricante y se hace una comparación entre las señales simuladas. Finalmente se da a conocer los parámetros de la Red creada.

## SUMMARY

This study consists of the application of artificial neural networks in the correction of the centrifugal pump characteristic curves for different viscosities. This technology, relatively new, helps to replace some methods used up to the moment efficiently.

A bibliographic revision about the subject and the most influential factors is done in the selection of pumps and a brief introduction about neural networks and its fundamentals.

As a result of this study, a feed-back neural network is developed describing some types of functions, structures and implementation methods used in the neural network development via MATLAB, which is simulated with data given by the manufacturer and the comparison between the simulated signals is done. Finally, the created network parameters are known.

<b>ÍNDICE</b>	<b>Página</b>
<b>Declaración de autoridad</b>	I
<b>Pensamiento</b>	II
<b>Dedicatoria</b>	III
<b>Agradecimientos</b>	IV
<b>Resumen</b>	V
<b>Introducción General</b>	1
<b>Capítulo I: Marco teórico de la investigación</b>	
1.1- Introducción	5
1.2- Revisión Bibliográfica	5
1.3- Criterios de Semejanza aplicado a las bombas centrífugas	11
1.4-Teoría de impulsión de las bombas centrífugas	15
1.5- Efecto de las propiedades físicas del fluido en el bombeo	19
1.6- Redes Neuronales Artificiales (RNA)	20
1.6.1- Fundamentos de Redes Neuronales Artificiales (RNA)	24
1.7- Aplicaciones generales de las RNA	28
1.7.1- Aplicaciones de la Red Backpropagation	30
<b>1.8-Conclusiones del capítulo</b>	30
<b>Capitulo II: Materiales y Métodos</b>	
2.1- Introducción	31
2.2-Procedimiento metodológico sobre las características operacionales de los quipos de bombeo	32
2.3- Identificación de las variables introducidas en la Red Neuronal	35
2.4- Parámetros de entrenamiento de la Red Neuronal	36
2.4.1- Regla Delta Generalizada para ajustar los pesos	38
2.4.2- Adición de un momento en la regla delta generalizada	39
2.4.3- Resumen del algoritmo Backpropagation	40
2.4.4- Estructura y aprendizaje de la Red backpropagation	41
2.4.5- Función de ativación de la Red	42
2.5.- Pasos para aplicar el algoritmo de entrenamiento	42
2.6.- Consideraciones sobre el algoritmo de aprendizaje	45
2.6.1- Control de Convergencia	46
2.7- Dimensionamiento de la Red. Número de neuronas ocultas	46
2.8- Procedimientos para la creación de la Red Neuronal Backpropagation	47
<b>2.9- conclusiones del capítulo</b>	50
	53
<b>Capitulo III: Materiales y Métodos</b>	
3.1- Introducción	51
3.2- Parámetros para la creación de la Red Neuronal Artificial	51
3.2.1- La arquitectura de la Red Creada	52

---

3.3- Resultados de entrenamiento de la Red neuronal Artificial	54
3.4- Correlación entre los coeficientes experimentados y los simulados	55
3.5- Impacto social de las nuevas técnicas y tecnologías	56
<b>3.6- Conclusiones del capítulo</b>	<b>58</b>
<b>Conclusiones Generales</b>	<b>59</b>
<b>Recomendaciones</b>	<b>60</b>
<b>Bibliografía</b>	<b>61</b>
<b>Anexos</b>	

## INTRODUCCIÓN GENERAL

El transporte de fluidos es una operación unitaria de gran importancia dentro de los procesos industriales, es necesario familiarizarse con el funcionamiento, selección, elementos constructivos y problemas operativos de los equipos de transporte. El empleo de técnicas modernas para la selección de equipos de transporte por parte de especialistas pertenecientes a entidades de proyecto e industrias de procesos nacionales, con un basamento científico-técnico, ineludiblemente tiene una repercusión económica significativa.

La problemática del uso racional de la energía en el contexto actual continúa ocupando un lugar prioritario en las investigaciones científicas a nivel mundial. Los sistemas de transporte de fluidos son consumidores de una parte importante de la energía utilizada con fines productivos en cualquier industria de procesos.

La cantidad de máquinas de flujo de distintos tipos fabricadas por la industria de los países técnicamente desarrollados, se expresa en millones de unidades al año; la energía eléctrica utilizada para el accionamiento de los mismos constituye una parte esencial del balance energético de los países. Por esta razón, las investigaciones teóricas y experimentales, dirigidas al perfeccionamiento de los procesos de transporte y al aumento del rendimiento de las máquinas de este tipo, tienen una gran importancia (Cherkasski 1986).

Las bombas centrífugas son el tipo de bombas que se utilizan con mayor frecuencia en la industria química para el transporte de líquidos, como son materias primas, subproductos, productos intermedios, servicios auxiliares, productos terminados etc. Se pueden utilizar para un intervalo muy amplio de gastos desde 5 a 8 l/min hasta 500,000 l/min; con cabezas o presiones de descarga de unos cuantos milímetros de mercurio hasta de cientos de atmósferas. Además de lo anterior, se tienen las ventajas de tener bajo costo de operación y de mantenimiento, ocupan poco espacio y generan bajos niveles de ruido.

Siendo los sistemas de transporte de fluidos un eslabón que media entre un sinnúmero de operaciones básicas en toda industria de procesos, resulta sin dudas limitado cualquier

análisis global que se desee efectuar del proceso industrial que no incluya las operaciones de transporte. Se le ha prestado atención al creciente papel de la elaboración de modelos matemáticos como vía de solución de los problemas planteados en la industria de procesos, entre los que se destacan por su importancia los problemas computacionales del cálculo de flujo de fluidos complejos.

Para el análisis de corrección de características de carga de bombas centrífugas, no se ha tenido como basamento el empleo de técnicas de modelación por Redes Neuronales Artificiales, método computacional empleado mundialmente en todas las áreas de la ciencia y la técnica en nuestros días. Dicho análisis se ha visto caracterizado por la utilización de métodos tradicionales de forma espontánea por parte de especialistas consagrados por vocación a esta importante y laboriosa tarea. Por otra parte, la literatura que ha sido consultada refiere procedimientos de corrección basado en la utilización de nomogramas y modelos estadísticos de difícil empleo y limitados para casos particulares de modelos de bombas centrífugas.

Para el desarrollo de la selección y la detección de sobre consumo energético de los sistemas de transporte industrial de fluidos por bombas centrífugas, es básica la obtención del punto de funcionamiento del sistema que está dado por la intersección entre las características de carga-capacidad de los equipos de bombeo y los de resistencia hidráulica capacidad del sistema de tuberías; de donde puede obtenerse el flujo, la potencia y la eficiencia de operación de los equipos de bombeo. Con tal propósito, tradicionalmente los especialistas encargados de estas tareas, desarrollan un método gráfico, con los consiguientes inconvenientes de poca precisión, elevado tiempo de ejecución de la tarea, que por demás exige un cúmulo de conocimientos de Mecánica de los Fluidos y experiencias prácticas en su realización, así como limitaciones importantes en cuanto al análisis de diversas alternativas y condiciones de operación variable cuando el sistema presenta diferentes viscosidades de fluidos a transportar, lo cual se agudiza en aquellos sistemas donde resulta necesaria la regulación de la operación.

## **SITUACIÓN PROBLEMÁTICA:**

La inexistencia en la literatura especializada de coeficientes experimentales para calcular y diseñar bombas centrífugas que manipulen fluidos viscosos han ocasionado que los cálculos sean elaborados para agua y posteriormente extrapolados a otro tipo de fluido (Turino 1994), lo que genera un proceso engorroso y poco preciso.

Esta problemática puede justificar el desarrollo de una metodología basada en la elaboración de modelos con la implementación de las Rede Neuronales Artificiales, con lo cual se facilita su aplicación e introducción en todas las dependencias y entidades de proyectos del país. La Red Neuronal entrenada posibilitará la realización de cálculos de corrección de las características de carga de las bombas centrífugas con alta precisión y rapidez, cuando transportan un fluido con viscosidad diferente a la del agua, lo cual constituye en la actualidad un paso imprescindible para el desarrollo acelerado de este campo.

Tomando en cuenta la situación nacional existente en la operación y diseño de sistemas de transporte de fluidos incompresibles, así como la necesidad de fomentar el auge científico-técnico en esa dirección, de importancia vital para la economía del país, y atendiendo además a la tendencia que se está desarrollando internacionalmente en países industrializados, es que se fundamenta la necesidad de realizar un trabajo que responda a la problemática de la corrección de las características de carga de las bombas centrífugas.

## **PROBLEMA:**

La inexistencia de un método computacional para la corrección de la curva de trabajo de una bomba centrífuga para el trasiego de fluidos, teniendo en cuenta diferentes viscosidades de fluidos y la característica de carga para el trabajo con agua.

## **HIPÓTESIS:**

Mediante la selección de los factores principales de las características de las curvas de trabajo de las bombas centrífugas, es posible obtener un método de corrección de la característica de carga con la implementación de las Redes Neuronales Artificiales.

**OBJETIVO:**

Predecir el comportamiento de las características de las curvas de carga de bombas centrífugas, mediante la utilización de Redes Neuronales Artificiales que tengan en cuenta las propiedades del fluido a transportar.

**OBJETIVOS ESPECÍFICOS:**

- Analizar las principales publicaciones relacionada con la corrección de características de carga de las bombas centrífugas.
- Determinar las principales variables que influyen en la curva característica de una bomba centrífuga.
- Obtener una Red Neuronal Artificial que simule los coeficientes de la curva de trabajo para diferentes viscosidades.
- Analizar los principales impactos del uso de estas técnicas.

Para lograr el cumplimiento del objetivo propuesto, se plantean las siguientes **TAREAS DEL TRABAJO:**

1. Estudio bibliográfico referente al tema.
2. Análisis de los modelos de corrección existentes.
3. Búsqueda de datos experimentales, donde se tenga en cuenta la influencia de la viscosidad en la característica de bombas centrífugas.
4. Selección y entrenamiento de la Red Neuronal para la corrección de las características de carga de las bombas centrífugas.
5. Simulación de los coeficientes de carga mediante la Red Neuronal creada.

## CAPÍTULO I: MARCO TEÓRICO DE LA INVESTIGACIÓN

📖 **Introducción**

📖 **Revisión Bibliográfica**

📖 **Criterios de Semejanza aplicado a las bombas centrífugas**

📖 **Teoría de impulsión de las bombas centrífugas**

📖 **Efecto de las propiedades físicas del fluido en el bombeo**

📖 **Redes Neuronales Artificiales (RNA)**

📖 **Fundamentos de Redes Neuronales Artificiales (RNA)**

📖 **Aplicaciones generales de las RNA**

📖 **Conclusiones del capítulo**

### 1.1 - Introducción

En este capítulo se realizará el análisis de los distintos aspectos relacionados con el tema en estudio, los que se abordan en la bibliografía consultada, con la finalidad de disponer de los elementos básicos invariantes y de las tendencias actuales que resulten esenciales para el correcto desarrollo del trabajo. Se presenta un resumen histórico sobre redes neuronales artificiales (ANN), sus fundamentos y una breve descripción de algunos aspectos básicos.

En tal sentido **el objetivo** del capítulo es:

Analizar las principales teorías existentes relacionadas con el comportamiento operacional de las bombas centrífugas y propiedades de fluidos.

### 1.2 - Revisión Bibliográfica

“La teoría de los fluidos deberá basarse necesariamente en la experimentación”  
D’Alambert 1744, demostró que no existe resistencia al movimiento de un cuerpo cuando éste se mueve a través de un fluido ideal (no viscoso o invíscido), pero es obvio que esta conclusión no puede aplicarse a los cuerpos que se mueven a través de fluidos reales.

Esta discrepancia entre la teoría y el experimento, que se denominó la paradoja de D'Alambert, ha sido ya resuelta. No obstante, demuestra con claridad las limitaciones de la teoría de esa época para la resolución de problema sobre fluidos.

En Cuba no comienza un desarrollo de los estudios hidráulicos sino hasta después de la revolución en que dichos estudios constituyen una de las bases principales del progreso científico técnico del país.

En el desarrollo de la investigación se han consultado diferentes trabajos y estudios, la revisión bibliográfica ha estado dirigida en dos líneas fundamentales:

- La información relacionada con el enfoque teórico – metodológico.
- Los trabajos sobre el tema de operación de la Bombas Centrifugas desde el punto de vista científico, técnico y práctico que se han efectuado en los últimos años.

El problema de los efectos viscosos de disipación de energía, se empezó a abordar experimentalmente con flujos a baja velocidad en tuberías, independientemente en 1839 por el médico francés Jean Poiseuille, que estaba interesado por las características del flujo de la sangre, y en 1840 por el ingeniero alemán Gotthif Hagen. El primer intento de incluir los efectos de la viscosidad en las ecuaciones de gobierno de la dinámica de fluidos se debió al ingeniero francés Claude Navier en 1827 e, independientemente, al matemático británico George Stokes, quien en 1845 perfeccionó las ecuaciones básicas para los fluidos viscosos incompresibles. Actualmente se las conoce como ecuaciones de Navier- Stokes.

Refiriéndose a la viscosidad, muchos han sido los autores que abordan esta temática; de vital importancia en el desarrollo de la investigación de fluidos; trabajos como (De la Paz et al., 2002), realiza un estudio reológico de la jalea dentífrica fluida; donde analizan las deformaciones sufridas por la formulación al aplicarle la fuerza de cizalla con un determinado gradiente de velocidad, describiéndose por medio de la curva viscosimétrica y de la de fluidez cómo se deforma el cuerpo al ser sometido a esfuerzos producidos por fuerzas externas, así como la determinación de sus propiedades mecánicas bajo las condiciones de deformación ensayadas. La formulación diseñada resultó estable

físicamente, al menos, bajo las condiciones y circunstancias experimentales en que se ensayo, se encuentra como deficiencia, que los autores no estudian el comportamiento reológico del fluido para variaciones de temperaturas; siendo esta perturbación, de gran influencia en la estructura y propiedades de los fluidos.

Se encuentra como dificultad de los trabajos anteriormente descritos, que los autores, no determinan las relaciones de las propiedades reológicas en sus investigaciones; lo cual dificultaría el ajuste de estas condiciones a otras condiciones de los fluidos estudiados.

Para el transporte de fluidos viscosos, los estudios existentes son limitados, diferentes factores han sido analizados. Las caídas de presión a través de una tubería en el manejo de pasta de pescado, fueron evaluadas por Nakayama et al. (1980); determinando valores bajos en las pérdidas de energía, atribuidos a la naturaleza del comportamiento no newtoniano de tipo plástico de Bingham.

Haoulo et al. (2005) evalúan el efecto de la densidad y de la viscosidad dinámica de la mezcla en la determinación del gradiente de presión longitudinal de flujo bifásico de gas y de líquido en tuberías horizontales considerando un fluido pseudo homogéneo. Se evalúan dieciocho ecuaciones de viscosidad de mezcla y cuatro ecuaciones de densidad de mezcla. La combinación de estas ecuaciones de propiedades de mezcla generan setenta y dos modelos, cuya única diferencia es la forma de calcular las propiedades de mezcla. La evaluación del desempeño de los diferentes modelos para determinar el gradiente de presión, se realiza comparando los resultados obtenido por cada modelo con noventa y tres datos experimentales que incluyen los patrones de flujo intermitente, anular, burbuja dispersa y estratificado ondulado.

Una de las modelaciones con mayor tendencia en la actualidad, la a 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 capo de los flujos de los fluidos.

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.

Lo que provocó que modelos propuestos por investigadores de mucho prestigio (Minsky y Papert) fueran muy limitados y se expresaron grandes dudas sobre las posibilidades de lograr resultados importantes siguiendo este camino, por lo que las investigaciones fueron relegadas al olvido durante casi veinte años.

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 RNA 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. Es, como se observa, una ciencia joven y muy estudiada actualmente y se piensa que en el próximo siglo tenga un significativo impacto en la sociedad. Las investigaciones actuales se dividen en dos grandes campos:

- Los neurofisiólogos, interesados en reproducir fielmente el comportamiento del cerebro humano. Debe decirse en este sentido que hoy las RNA constituyen una importante herramienta de investigación para la interpretación de los fenómenos neurobiológicos.
- Los computólogos, interesados en obtener aplicaciones prácticas y comercializables.

En este sentido, los investigadores mas renombrados hoy son, entre otros: Hopfield, Hoff, Widrow, Hamming, Boltzman, Grossberg, Kohonen, Rumelhart, Mohamed El Sharkawi, etc.

Actualmente en varias partes del mundo se están realizando inversiones de consideración en la investigación de las Redes Neuronales y comienzan a aparecer, con muy buenos resultados, trabajos que combinan la tecnología de las RNA con la de los Sistemas Expertos y la Lógica Difusa, siendo el objetivo de éstos el tomar lo mejor de cada

tecnología para obtener sistemas con más habilidades inteligentes. No obstante todo lo anteriormente dicho aún queda mucho para lograr construir realmente una arquitectura de microcomputadora que imite realmente el cerebro humano.

En el Artículo, Sánchez (2002), realiza un estudio numérico de mecánica de fluidos 2D en una contracción brusca para fluidos no newtonianos tipo ley de potencia de Ostwald-de-Waele. Se emplean dos métodos de resolución, el método de los volúmenes finitos y el método de los elementos finitos para la resolución de las ecuaciones de momentum lineal y de continuidad. En ambos métodos se estudia el comportamiento del fluido para diferentes índices de potencia.

Ortega (1995), presenta en su tesis doctoral, un estudio teórico de algunos sistemas de ecuaciones en derivadas parciales no lineales que describen el comportamiento de ciertas clases de fluidos viscosos; considera un modelo para fluidos de bingham, pseudoplásticos y dilatantes en densidad variable. Para estos modelos, se obtienen resultados de existencia de solución global en tiempo en varios sentidos: solución muy débil y medida-valuada. También se estudia la cuestión de la unicidad de solución. En la segunda parte se consideran tres problemas asociados al modelo de oldroyd para fluidos viscoelásticos: el problema de evolución, el problema estacionario y el flujo de poiseuille en dominios cilíndricos.

Dentro de los trabajos reportados sobre la influencia de las propiedades reológicas en el comportamiento de la característica operacional de bombas centrífugas se han reportado numerosos trabajos que han colaborado en el desarrollo de esta esfera de la ciencia. Según lo planteado por Turiño (1994) no existe una teoría que permita predecir el comportamiento exacto de una bomba centrífuga cuando manipula un fluido viscoso, pues teóricamente hasta el presente ha sido imposible tener en cuenta la influencia de la viscosidad en los parámetros de trabajo de la bomba y en la forma de sus características.

Santos y Martín (1999) a partir de un análisis estadístico de la forma de la característica de trabajo de un equipo de bombeo de tipo centrífugo, obtiene modelos que recalculan los coeficientes  $a$ ,  $b$  y  $c$  de la ecuación anterior con la velocidad específica con un nivel de confianza de un 95 %.

Para fluidos no newtonianos la literatura científico-técnica no reporta coeficientes de corrección, por lo que se ha generalizado erróneamente la aplicación del símil de viscosidad de estos fluidos con los newtonianos según lo refiere Turiño (1994), lo cual ocasiona errores de pronóstico de la curva de funcionamiento de la bomba centrífuga.

Roque (1989), desarrollo investigaciones experimentales en relación con el bombeo de soluciones azucaradas de naturaleza no newtonianas, en equipos centrífugos y propuso coeficientes de corrección que permiten pronosticar la curva característica de estos equipos de bombeo en función de las propiedades reológicas de los fluidos ensayados. Adhikari et al. (2000), incorporaron el concepto de las redes neuronales, como una nueva herramienta computacional, en el cálculo de las pérdidas de presión en tuberías, para lo cual manejaron fluidos de comportamiento no newtoniano, obteniendo errores de predicción menores a 5.4% con respecto a los valores experimentales.

Las redes neuronales son modelos que intentan reproducir el comportamiento del cerebro humano (Hilera y Martínez, 1995; Montana, 1995). Una red neuronal consiste en un conjunto de elementos de procesamiento, llamados neuronas, los cuales se conectan entre si. Un grupo de redes neuronales de interés son las redes “*feedforward*”, que se caracterizan por tener arquitecturas en niveles y conexiones estrictamente hacia adelante (Wang, et. al., 1998).

Prados, D.L. (1992) identifican una cantidad significativa de algoritmos de entrenamiento. La mayoría de éstos utilizan información del gradiente de una función de error para ajustar los pesos de las conexiones, y se los llaman algoritmos de gradiente descendente (Porto, 1998). Los algoritmos de gradiente descendente poseen dos problemas. Primero, suelen quedar atrapados en mínimos locales, generándose de esta manera estimaciones subóptimas de los pesos (Sutton, 1986). Segundo, suelen ser muy lentos por utilizar pasos infinitesimales para alcanzar la solución.

Los algoritmos evolutivos, dentro de los cuales los algoritmos genéticos son los más conocidos, son una familia de modelos computacionales inspirados en la evolución y la supervivencia del más apto (Bäch, et. al., 1991; Ömer, 1995; Whitley, 2001; 2002). Se utilizan fundamentalmente en la resolución de problemas de búsqueda y de optimización

(Holland, 1975). El verdadero poder de estos algoritmos radica en la búsqueda simultánea de la solución en un conjunto de posibles soluciones (individuos) (Whitley, 1994). Buscan una solución del problema reproduciendo genéticamente una población de individuos a lo largo de una serie de generaciones (Koza, 1997).

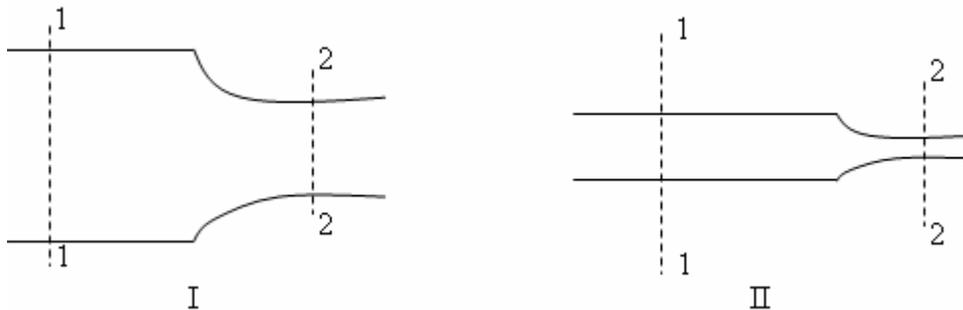
Dada una topología fija, el entrenamiento de una red neuronal puede ser visto como un proceso de optimización cuyo objetivo es encontrar un conjunto de pesos que minimice el error que produce la red sobre el conjunto de datos de entrenamiento (Branke, 1995).

### 1.3- Criterios de Semejanza aplicado a las bombas centrífugas

Las leyes de semejanza son de extraordinaria importancia para el estudio en hidráulica, estas deben tenerse en cuenta no solo para el flujo de líquidos, sino también para el diseño y explotación de las turbomáquinas.

Las semejanzas geométricas (Figura 1.1) en hidráulica se entienden por la semejanzas de las superficies que limitan los flujos de los líquidos: Semejanzas cinemáticas, es la semejanza de las líneas de corrientes y la proporcionalidad de las velocidades similares.

Semejanzas dinámicas, significan la proporcionalidad de las fueras que actúan sobre los elementos similares de los flujos cinemáticamente semejantes y la igualdad de los ángulos que caracterizan la dirección de estas fuerzas.



**Figura 1.1.** Semejanza geométrica de secciones.

**Fuente:** Streeter, 1984.

#### Criterio de Newton

$$Ne = \left[ \frac{F}{\rho \cdot v_{med}^2 \cdot A} \right]_I = \left[ \frac{F}{\rho \cdot v_{med}^2 \cdot A} \right]_{II} \quad (1.1)$$

El producto  $\rho v_{med}^2 A$  en los flujos semejantes le son proporcionales las fuerzas con las cuales el flujo actúa sobre los obstáculos.

Criterio de Euler

$$\left[ \frac{\Delta P}{\rho \cdot v^2} \right]_I = \left[ \frac{\Delta P}{\rho \cdot v^2} \right]_{II} = Eu \tag{1.2}$$

En el flujo de un líquido incomprensible se cumple que la diferencia de presión en flujos semejantes geoméricamente es proporcional a la energía dinámica.

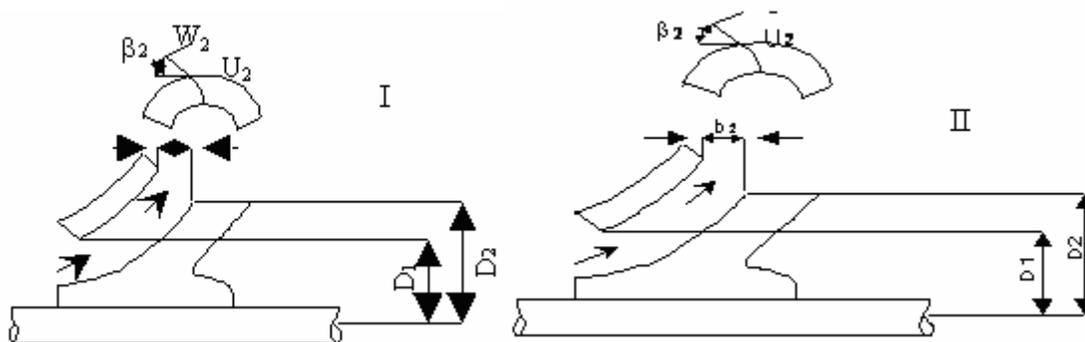
Si el flujo del líquido es real se tiene que cumplir además que  $\lambda_I = \lambda_{II}$ .

$$\left[ \frac{\tau_0}{\rho \cdot v^2} \right]_I = \left[ \frac{\tau_0}{\rho \cdot v^2} \right]_{II} \tag{1.3}$$

Un criterio de uso universal, es criterio de Reynolds donde  $Re_I = Re_{II}$ .

Para una corriente de líquido real.

En las construcciones de máquinas modernas se utilizan ampliamente el método de simulación (modelación), es decir, el ensayo de modelos, que permiten comprobar el proyecto e introducir en él las correcciones prácticas.



**Figura 1.2.** Observación de las leyes de semejanza en la maquina I y II.

**Fuente:** Streeter, 1984.

Los criterios de semejanza pueden agruparse igual que para el flujo de líquidos:

**-Semejanza Geométrica:**

Establece que debe existir una proporcionalidad entre las dimensiones de una máquina y su modelo.

Esta proporcionalidad debe de ser la misma entre todas las dimensiones.

$$\frac{D_2 I}{D_2 II} = \frac{b_2 I}{b_2 II} = \frac{D_1 I}{D_2 II} = \dots = \sigma_1(const) \quad (1.4)$$

Los ángulos deben de ser iguales: (1.5)

$$\beta_2 I = \beta_2 II$$

**-Semejanza Cinemática:**

Este criterio establece la proporcionalidad entre los valores de las velocidades correspondientes a los puntos en las máquinas geoméricamente semejantes y la igualdad entre los ángulos de los triángulos de velocidades respectivas.

$$\frac{U_2 I}{D_2 II} = \frac{C_1 I}{C_1 II} = \frac{W_2 I}{W_2 II} = \dots = \sigma_c(const). \quad (1.6)$$

**Semejanza Dinámica:**

Para que esta se cumpla entre máquinas geoméricamente semejantes es necesario que exista una proporcionalidad constante entre las fuerzas de igual naturaleza que actúan en puntos correspondientes de estas máquinas.

$$\frac{P_1 I}{P_1 II} = \frac{P_2 I}{P_2 II} = \dots = \sigma_d(const). \quad (1.7)$$

La demostración de la semejanza de las corrientes en las máquinas consiste en relevar la constancia de los coeficientes de semejanza para los puntos homólogos.

Si se conoce los coeficientes de semejanza de dos máquinas, entonces valiéndose de las características conocidas de una máquina se pueden obtener los valores de las características semejantes de la otra máquina.

Las fábricas que producen las Máquinas Centrífugas tienen generalmente en la producción no tipos de casuales de máquinas que se distinguen por sus dimensiones y formas geométricas, sino una serie de máquinas geoméricamente semejantes.

Comparemos dos máquinas (figura 1.2 I y II) semejantes y veamos las relaciones que existen entre sus características principales, gasto, altura y potencia en los parámetros geométricos y cinemáticas.

El gasto real que entrega una máquina puede expresarse en las siguientes ecuaciones:

$$Q = \pi \cdot D_2 \cdot b_2 \cdot Cr_2 \cdot \eta v \quad (1.8)$$

La relación entre los gastos de las máquinas (figura 1.2. I y II) será:

$$\frac{Q_I}{Q_{II}} = \frac{D_{2I}}{D_{2II}} \cdot \frac{b_{2I}}{b_{2II}} \cdot \frac{Cr_{2I}}{Cr_{2II}} \cdot \frac{\eta v_I}{\eta v_{II}} \quad (1.9)$$

Según los criterios de semejanza geométricas:

$$\frac{D_{2I}}{D_{2II}} = \frac{b_{2I}}{b_{2II}} \quad (1.10)$$

Y según la semejanza cinemática.

$$\frac{Cr_{2I}}{Cr_{2II}} = \frac{U_{2I}}{U_{2II}} \cdot \frac{n_i}{n_{II}} \cdot \frac{D_{2I}}{D_{2II}} \quad (1.11)$$

Por lo tanto:

$$\frac{Q_I}{Q_{II}} = \frac{D_{2I}^3}{D_{2II}^3} \cdot \frac{n_i}{n_{II}} \cdot \frac{\eta v_I}{\eta v_{II}} \quad (1.12)$$

Los caudales volumétricos de las máquinas que funcionan en régimen semejante son entre sí como los cubos de los diámetros exteriores de las ruedas de trabajo y las primeras potencias de las frecuencias de rotación de los árboles y los rendimientos volumétricos.

La carga real que entrega una máquina centrífuga puede expresarse por la ecuación de EULER modificada por el rendimiento hidráulico de la máquina.

$$H = \frac{Cu_2 U_2}{g} \cdot \eta h \quad (1.13)$$

La relación entre las cargas de ambas máquinas sería:

$$\frac{H_I}{H_{II}} = \frac{Cu_{2I}}{Cu_{2II}} = \frac{D_{2I}}{D_{2II}} \cdot \frac{n_I}{n_{II}} \quad (1.14)$$

Según la semejanza cinemática (ecuación 1.6)

$$\frac{Cu_{2I}}{Cu_{2II}} = \frac{U_{2I}}{U_{2II}} = \frac{D_{2I}}{D_{2II}} \frac{n_I}{n_{II}}; \quad U = \pi \cdot D \cdot \frac{n}{t} \quad (1.15)$$

Y por lo tanto:

$$\frac{H_I}{H_{II}} = \frac{D_{2I}^2}{D_{2II}^2} \cdot \frac{n_I^2}{n_{II}^2} \cdot \frac{\eta_{hI}}{\eta_{hII}} \quad (1.16)$$

La potencia al eje de una máquina centrífuga se calcula por la fórmula:

$$N = \frac{H \cdot Q \rho \cdot g}{\eta} \quad (1.17)$$

La relación de la potencia al eje de ambas máquinas será:

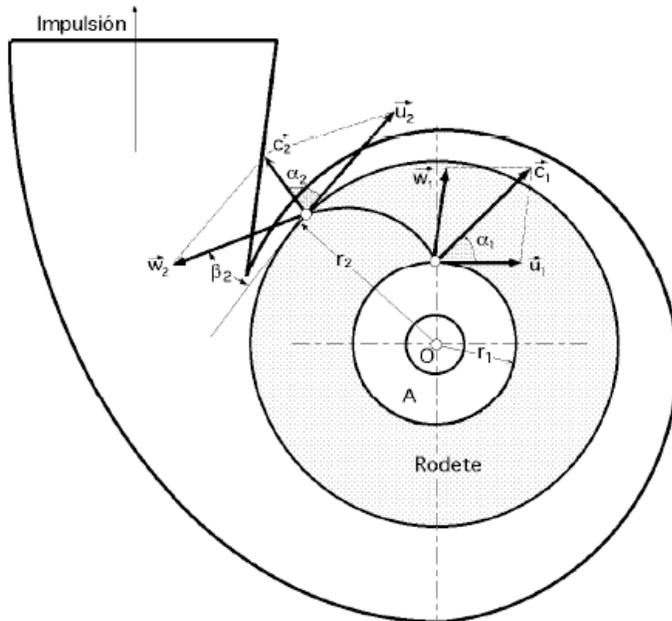
$$\frac{N_I}{N_{II}} = \frac{D_{2I}^5}{D_{2II}^5} \cdot \frac{n_I^3}{n_{II}^3} \cdot \frac{\rho_I}{\rho_{II}} \cdot \frac{\eta_I}{\eta_{II}} \quad (1.18)$$

Para variaciones del número de revoluciones menor de 20% el rendimiento varía muy poco y  $\eta_1 = \eta_2$ .

#### 1.4- Teoría de impulsión de las bombas centrífugas

El órgano principal de una bomba centrífuga es el rodete que, en figura 1.3, se puede ver con los álabes dispuestos según una sección perpendicular al eje de la bomba; el líquido llega a la entrada del rodete en dirección normal al plano de la figura, (dirección axial), y cambia a dirección radial recorriendo el espacio o canal delimitado entre los álabes. El líquido queda sometido a una velocidad relativa  $\bar{w}$  a su paso por el espacio entre álabes entre la entrada y la salida, y una velocidad de arrastre  $\bar{u}$  debida a la rotación del rodete

alrededor del eje. La suma vectorial de estas velocidades proporciona la velocidad absoluta  $\vec{c}$ .



**Figura I.3.** Triángulos de velocidades de una bomba centrífuga.

**Fuente:** Díez, 2001.

Si llamamos  $\vec{w}_1$  a la velocidad relativa del líquido a la entrada en la cámara delimitada por un par de álabes,  $\vec{u}_1$  a la velocidad tangencial, y  $\vec{c}_1$  a la velocidad absoluta, se obtiene el triángulo de velocidades a la entrada.

$$\left. \begin{array}{l} \text{Velocidad relativa, } \vec{w}_1 \\ \text{Velocidad tan gencial, } \vec{u}_1 \\ \text{Velocidad absoluta, } \vec{c}_1 \end{array} \right\} \Rightarrow \left\{ \begin{array}{l} \alpha_1 \text{ es el ángulo formado por } \vec{c}_1 \text{ y } \vec{u}_1 \\ \beta_1 \text{ es el ángulo formado por } \vec{w}_1 \text{ y } \vec{u}_1 \end{array} \right.$$

A la salida del rodete se tiene otro triángulo de velocidades determinado por las siguientes velocidades y ángulos:

$$\left. \begin{array}{l} \text{Velocidad relativa, } \vec{w}_2 \\ \text{Velocidad tan gencial, } \vec{u}_2 \\ \text{Velocidad absoluta, } \vec{c}_2 \end{array} \right\} \Rightarrow \left\{ \begin{array}{l} \alpha_2 \text{ es el ángulo formado por } \vec{c}_2 \text{ y } \vec{u}_2 \\ \beta_2 \text{ es el ángulo formado por } \vec{w}_2 \text{ y } \vec{u}_2 \end{array} \right.$$

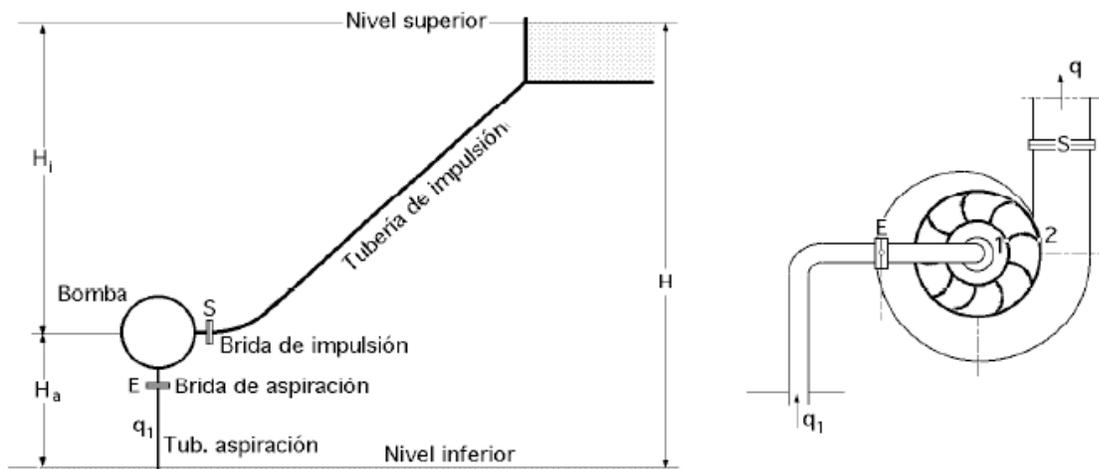
Si se designa por  $H$  el desnivel o altura geométrica existente entre los niveles mínimo y máximo del líquido, por  $H_a$  la altura o nivel de aspiración, (altura existente entre el eje de la bomba y el nivel inferior del líquido), y por  $H_i$  la altura de impulsión, (altura existente entre el eje del rodete y el nivel superior del líquido), se tiene que:

$$H = H_a + H_i \quad (1.19)$$

Para el caso del agua, la altura teórica de aspiración para un número infinito de álabes (teoría unidimensional), trabajando la bomba en condiciones ideales, sería la equivalente a la columna de agua correspondiente a la presión a que se encontrase el nivel inferior; si éste está sometido únicamente a la presión atmosférica, la altura teórica de aspiración sería de 10,33 metros; sin embargo, esta altura es siempre menor, pues hay que tener en cuenta:

- Las pérdidas de carga en la tubería
- El rozamiento a la entrada del rodete
- La temperatura del líquido a elevar
- El fenómeno de la cavitación

Por lo que el límite máximo para la altura de aspiración se puede fijar entre 5 y 7 metros.



**Figura I.4.** Alturas a considerar en una instalación con bomba centrífuga.

**Fuente:** Díez, 2001.

$$\text{El Bernoulli de impulsión es: } \frac{c_s^2}{2g} + \frac{p_s}{\gamma} + z_s \quad (1.20)$$

$$\text{El Bernoulli de aspiración: } \frac{c_E^2}{2g} + \frac{p_E}{\gamma} + z_E \quad (1.21)$$

Las alturas a considerar, aparte de la geométrica ya definida, son:

- $H_t$  = Altura total creada por la bomba.
- $H_m$  = Altura manométrica de la bomba.

Las pérdidas de carga que pueden aparecer en la instalación, (bomba y tuberías), son:

- $\Delta_i$  = Pérdidas de carga en las tuberías de aspiración e inspiración
- $\Delta_i = \Delta H_{roz} + \Delta H_{choque}$  = Pérdidas en el rodete ( $h_r$ ) + pérdidas en la directriz (si la tiene) ( $h_{cd}$  + pérdidas en la voluta ( $h_v$ )).
- $\Delta_e$  = Pérdidas de carga en las tuberías de aspiración e impulsión.

Por lo que:

$$H_t = \Delta_i + \Delta_e + H \Rightarrow \begin{cases} H_m = H + \Delta_e \text{ (Tubería)} \\ H_m = H_t - \Delta_i \text{ (Bomba)} \end{cases} \quad (1.22)$$

El rendimiento manométrico se define en la forma:

$$\eta_{man} = \frac{H_t}{H_m} \quad (1.23)$$

La altura manométrica creada por la bomba tiene por expresión:

$$H_{man} = \left( \frac{c_s^2}{2g} + \frac{p_s}{\gamma} + z_s \right) - \left( \frac{c_E^2}{2g} + \frac{p_E}{\gamma} + z_E \right) = H_t \eta_{man} = H_t - \Delta_i \eta_{man} = 1 - \frac{\Delta_i}{\Delta_t} \quad (1.24)$$

Es decir, la diferencia del Bernoulli entre las bridas de impulsión y de aspiración.

La altura manométrica de la bomba se puede poner también en función de los puntos 1 y 2, de entrada y salida del impulsor, en la forma:

$$H_{man} = H_t - \{\Delta_t - (h_{vol} + h_{cor.directriz}) - 0\} = H_t - h_r \quad (1.25)$$

### 1.5- Efecto de las propiedades físicas del fluido en el bombeo

Las propiedades físicas del fluido que influyen en el bombeo con bombas centrífugas son la densidad (o peso específico), presión de vapor y viscosidad.

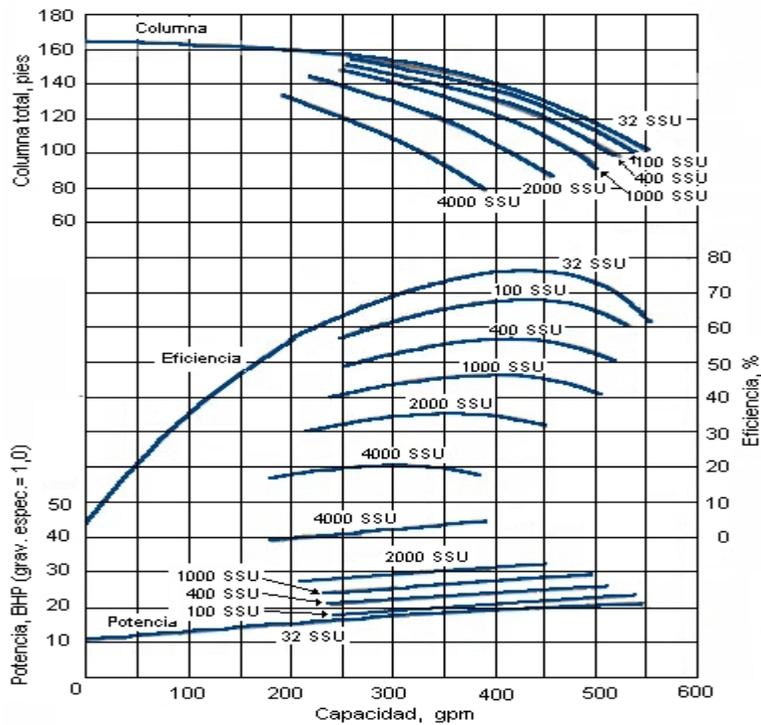
a) Densidad (peso específico, o densidad relativa). Influye sobre la potencia necesaria para el bombeo, a mayor densidad, mayor potencia necesaria para el bombeo.

b) Presión de vapor ( $P_v$ ).- Su influencia se acentúa si se trabaja con líquidos calientes y está en la CSPN<sub>A</sub> o del sistema la  $P_v$  debe ser baja para tener una CSPN<sub>A</sub> razonable y evitar la “cavitación”.

c) Viscosidad ( $\mu$ ).- Influye sobre el caudal que pueda manipular la bomba  $Q$ , la columna  $H$  que pueda desarrollar la bomba, y la eficiencia de la bomba  $\eta$ . Además influye sobre la columna o resistencia del sistema (aumentándolo).

Se han hecho considerables esfuerzos para determinar el efecto de la viscosidad sobre la operación de bombas centrífugas, y el “Hydraulic Institute Standards” proporciona cartas que pueden usarse para predecir la operación de bombas manipulando líquidos de diferentes viscosidades a partir del conocimiento de la operación de la bomba manipulando agua. La figura 1.5, muestra el efecto de diferentes rangos de viscosidades desde 32 SSU (que corresponde al agua) hasta 4000 SSU. Aún cuando la bomba tenga una eficiencia de 76 % (en el punto de máxima eficiencia, BEP) cuando manipula agua, la eficiencia de la bomba se reduce a cerca de 20 % cuando manipula líquidos con viscosidad de 4000 SSU.

Obviamente debe hacerse una evaluación entre bombas centrífugas y bombas de desplazamiento para tomar una decisión justificable desde el punto de vista de la economía. Pero como una regla general es que el límite superior para usar bombas centrífugas es 2000 SSU.



**Figura 1.5.** Influencia de la viscosidad.  
**Fuente:** Hydraulic Institute Standards, 2007.

### 1.6-Redes Neuronales Artificiales (RNA)

Las redes neuronales son modelos que intentan reproducir el comportamiento del cerebro humano (Hilera y Martínez, 1995; Montana, 1995). Una red neuronal consiste en un conjunto de elementos de procesamiento, llamados neuronas, los cuales se conectan entre si.

Podemos considerar una RNA 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 nuestra comunicación diaria utilizamos habitualmente información imprecisa, que generalmente el cerebro procesa muy bien, generando incluso nuevo conocimiento. Esto nos 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 RNA.

En 1943, McCulloch y Pitts simularon una neurona biológica mediante un dispositivo electroquímico con varias entradas y una salida activada como un autómat a umbral,

permitiendo sólo valores binarios. A partir de entonces, se han desarrollado asociaciones de neuronas para constituir Redes. Podemos considerar una RNA como una colección de procesadores elementales (neuronas), conectados a otras neuronas o entradas externas, y con una salida, que permite propagar las señales por múltiples caminos. Cada procesador pondera las entradas que recibe, y estos pesos pueden ser modificados en aras de conseguir el objetivo previsto. Es lo que llamaremos función de APRENDIZAJE. Es decir, una RNA puede "aprender" de sus propios errores. Es un Proceso INDUCTIVO a partir de un conjunto de ejemplos, frente al Proceso Deductivo, propio de los Sistemas Expertos.

Muchos procedimientos de entrenamiento se basan en las teorías de D. Hebb, que en su libro "Organization of Behavior" establece conjeturas sobre redes neuronales que podían aprender, construyendo representaciones internas de conceptos. Sugiere que las sinapsis de neuronas activadas se refuerzan, en forma proporcional a los niveles de activación de ambas neuronas (correlación). Hubo que esperar a que la I.A. diese caminos para concretar los conceptos simbólicos para desarrollar el modelo matemático de sus ideas, que conocido como ley de Hebb, es uno de los paradigmas claves del aprendizaje de RNA. Primero se fue a máquinas para realizar funciones concretas y después a máquinas que aprendieran, distinguiendo la memoria de los procedimientos complejos de abstracción, predicción y generalización de cosas nunca "vistas". Algunas se basaban en ideas del refuerzo de hechos del pasado. Las primeras RNA (Perceptron, MAdaline), estaban formadas por una capa de neuronas artificiales, sin conexión entre ellas, que reciben todas las mismas entradas (pero con distintas ponderaciones) y una salida propia. Rosenblatt introdujo el Perceptron, que usa información binaria, y demostró muchas propiedades del mismo, concluyendo que "El perceptron es capaz de aprender todo lo que puede representar", donde representar indica la capacidad de simular una función específica, y aprender significa el proceso sistemático de ajuste de los pesos para producir esa función. El ajuste de los pesos se basa en la diferencia entre las salidas que se esperan con cada ejemplo y las calculadas por la red (aprendizaje supervisado). Widrow-Hoff desarrollaron el MAdaline, con funcionamiento parecido, pero tomando el error

cuadrático para el ajuste de pesos. Permite entradas continuas, normalizando el vector de entradas para tener módulo 1.

Toda la teoría sobre RNA sufre un duro golpe al demostrarse (Minsky-Papert a finales de los 60), la imposibilidad de que los perceptrones puedan representar (y por tanto aprender), funciones no separables linealmente, como la XOR. Esto limitaba mucho el número de posibles funciones a representar. Con 4 entradas hay 65536 funciones posibles y sólo 1882 representables. El desarrollo de los ordenadores (procesamiento en serie) y los avances de la I.A. (Sistemas Expertos) contribuyen al "adormecimiento" las Redes Neuronales.

Como consecuencia, muchos investigadores abandonaron el estudio de las RNA, ya que, aunque se vio que este problema se podía salvar utilizando redes multicapas, no se encontraban algoritmos de entrenamiento apropiados. Después de casi 20 años de abandono, resurgen las redes multicapas, gracias a la perseverancia de algunos investigadores que desarrollaron otras formas de aprendizaje. Sin duda, el paradigma que da fuerza a la investigación en RNA es el algoritmo de retropropagación de errores (backpropagation), que permite entrenar RNA multicapa de propagación hacia adelante (feedforward). Introducido por Rumelhart-Hinton-Williams (1986), ya había sido estudiado por Parker y Werbos. Tiene unos fundamentos matemáticos fuertes, y ha demostrado ser uno de los más fructíferos algoritmos en RNA. Para evaluar el error de la capa escondida, no se puede comparar el valor computado con el esperado, pues éste no existe. Por ello lo que se hace es retropropagar el error de la capa de salida, a través de sus pesos. T. Sejnowski-G. Hinton (85) aplican la retropropagación para la representación fonética de textos, clasificación de señales de sonar y predicción de estructuras de proteínas globulares. Aparecen también Redes Recurrentes, con salidas feedback hacia la propia capa u otras anteriores. Esto implica respuestas dinámicas al poder recalcular salidas sin nuevas entradas, y permite una función importante de las RNA, la de MEMORIZAR. Cada salida o configuración posible de la red se considera un estado de la misma. Si las neuronas son binarias, habrá  $2^n$  estados para  $n$  neuronas de salida. Los ajustes de los

pesos se hacen para que los cambios de estado provocados, produzcan beneficios en el aprendizaje.

Hopfield describió una red recurrente, con entradas y salidas binarias, y con cambios de estado discretos. Si después de un cierto tiempo la salida no cambia, diremos que ésta se ha estabilizado, y que la red es estable. Cohen-Grossberg han demostrado que estas redes son estables, si la matriz de pesos es simétrica y la diagonal principal es toda de ceros. La memoria biológica está distribuida sobre las conexiones entre neuronas modificadas durante el aprendizaje. También es capaz de recordar el todo a partir de una parte. Estímulos incompletos o defectuosos pueden hacer recuperar la información completa almacenada. Es decir, es ASOCIATIVA. El cerebro biológico aprende cambiando las conexiones entre las neuronas. Tenemos memoria porque las conexiones son estables. Este aprendizaje parece No Supervisado, así que los cambios en los pesos de las conexiones deben basarse en Similitudes entre estímulos de entrada y en la coherencia de almacenamiento para patrones similares. Siguiendo esta idea, Coñeen desarrolla un modelo artificial de memoria asociativa como una RNA recurrente con entrenamiento no supervisado. Puede recuperar patrones a partir de entradas defectuosas o incompletas.

Es la capacidad de generalización y abstracción de lo esencial en un conjunto de ejemplos. Ackely, Hinton y Sejnowski desarrollan con fuerte base matemática y biológica el Algoritmo de la Máquina de Boltzmann. Las neuronas son binarias y la conexión puede ser total, señalando conexiones excitatorias e inhibitorias. Utiliza un entrenamiento estocástico, basado en el Annealing Simulado como optimizador subyacente. Hay otros modelos interesantes, pero sin duda hay que destacar los modelos que usan la campana de Gauss como función de transferencia en vez de función de activación, como las RN Probabilísticas, o las Redes de Función Base Radial, que se están utilizando mucho sobre todo por su rapidez en el entrenamiento (algunas ni siquiera necesitan aprender). Un grupo de redes neuronales de interés son las redes “*feedforward*”, que se caracterizan por tener arquitecturas en niveles y conexiones estrictamente hacia adelante (Wang, et. al., 1998).

### 1.6.1-Fundamentos de Redes Neuronales Artificiales (RNA)

A las RNA 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 RNA (Hecht-Nielsen , Arbid, .. ). Una definición no tan formal se debe a Simpson: Una RNA 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"

Aquí proponemos la siguiente: "Una RNA es un sistema o conjunto de procesadores elementales interconectados, no lineal ni estacionario, que realiza al menos alguna de las siguientes funciones: Aprendizaje, Memorización, Generalización o Abstracción de características esenciales, a partir de un conjunto de ejemplos". La red más simple posible, se obtiene conectando todas las entradas a cada neurona de una capa en paralelo, sin interconectarlas. Cada neurona de la red proporciona una salida. Los pesos son propios de cada neurona, y no se está obligado a tener todas las conexiones (alguna puede tener peso 0).

Las ecuaciones tienen ahora una forma matricial para calcular todas las salidas:

$$Y = F(S) \quad (1.26)$$

Podemos conectar todas las salidas  $y$  a una nueva capa de neuronas del mismo tipo, para obtener una red de 2 capas, y a su vez las salidas de esta capa a otra capa, etc... Para obtener en definitiva una Red multicapa, donde las capas pueden tener distintos números de neuronas, y cada neurona de cada capa pondera las entradas que le llegan .La función de activación suele ser la misma, pero puede ser diferente en cada capa. Cuando la activación es lineal  $F(S) = cS$  , no se obtiene mejora del poder computacional de la red al aumentar las capas, ya que sería equivalente a una red de una sola capa ( $y_i$  = salida de capa  $i$ -ésima):

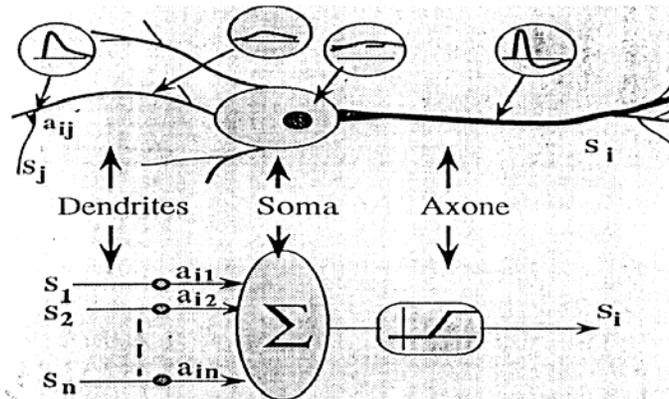
$$Y_1 = cS_1 = cXW_1; Y_2 = cXW_1W_2; Y_h = KxW_1...W_h = KXW \quad (1.27)$$

que corresponde a la salida de una red de una capa de matriz de pesos  $W$ . A las redes con conexiones de realimentación (feedback), se les dice RECURRENTES, y son

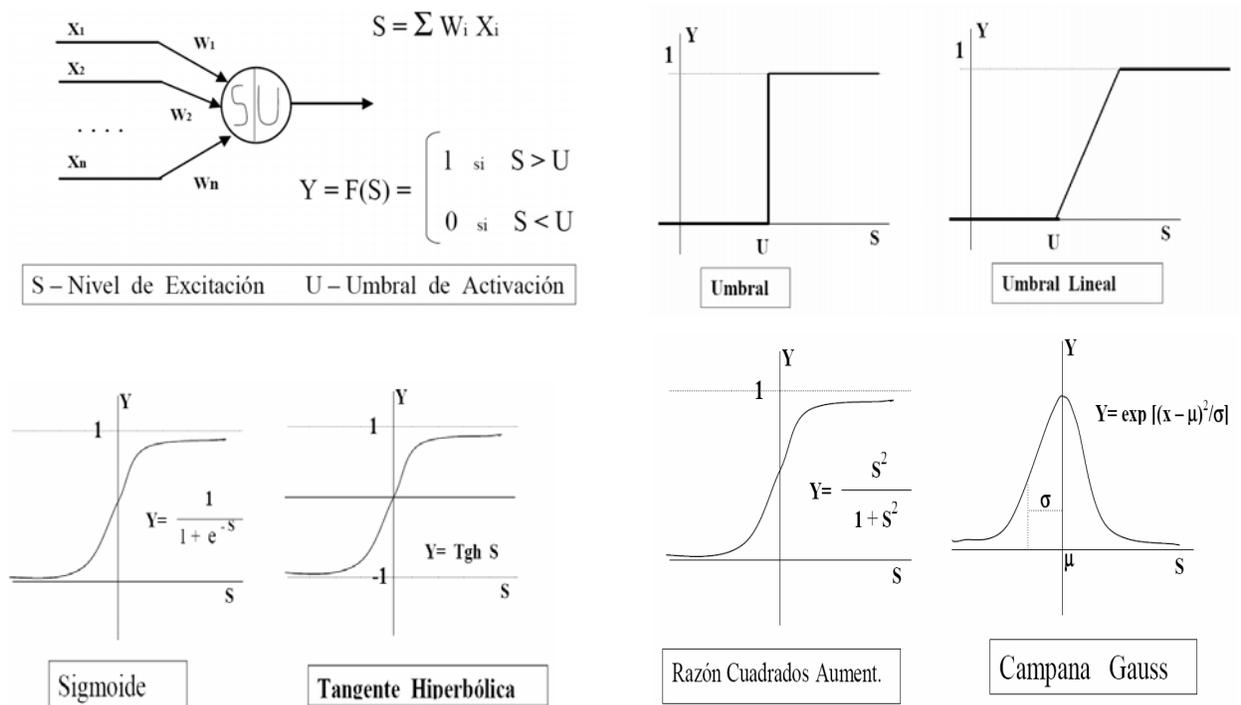
Sistemas Dinámicos. La salida se ve por etapas, y en la etapa t, la salida sirve de entrada para la etapa t+1.

$$S_{t+1} = (X_{t+1} + Y_t)W \tag{1.28}$$

Para casos continuos, hay que utilizar ecuaciones diferenciales



**Figura 1.4.** De la Neurona Biológica a Neurona Artificial.  
**Fuente:** Requena 2004.



**Figura 1.5.** Diversas Funciones de Ativación.  
**Fuente:** Requena 2004.

En las RNA hay que considerar básicamente tres aspectos: El Diseño Estructural (Topología Organizada), Los Procedimientos de Almacenamiento o Codificación de la Información (Aprendizaje o Entrenamiento) y Los Procedimientos de Recuperación de la Información (Uso de la RNA entrenada). Vamos a ver lo esencial de cada uno.

### **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 NA a los nodos de entrada, aunque en ellos no se hace procesamiento ninguno. En las NA se hace siempre un proceso de Agregación de las entradas, generalmente ponderadas, para obtener el nivel de Excitación ( $S$ ) de la NA, y después una Activación de la NA, que depende del nivel de Excitación, de acuerdo con una función de Activación  $F(S)$ . Entonces, las NA sólo manejan información local, que viene por las entradas, y producen un solo valor de salida, que puede ir como entrada de otras NA.

- Agregación de entradas.

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

$$S_j = \sum X_i W_{ij} \quad (1.29)$$

En este caso, la salida es una función de las entradas y los pesos:

$$Y_i = F(X, W_j) \quad (1.30)$$

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 NA 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 como:

$$Y_j = g \left( \sum (W_{ij} - X_i)^2 / V_{ij} \right) \text{ con } g(x) = \exp(-x^2 / 2) \quad (1.31)$$

### - Entradas Max-Min.

Las conexiones de entrada a la NA 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, que se reflejan en la figura 1.5, 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 NA son generalmente dirigidas (de la NA 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 RNA 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 NA representan realmente un nivel de Umbral de la NA.

### • Topología concreta de la Red.

Con los elementos anteriores, podemos concretar la estructura de la RNA, 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: RNA de Propagación hacia delante (por capas) y RNA Recurrentes (no hay capas distinguibles), aunque también se usan modelos mixtos.

- Conjunto de Entrenamiento.

Las RNA 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 RNA para conseguir que la respuesta de la RNA sea la deseada para ejemplos usados o no en el aprendizaje o entrenamiento. Muchas veces, este proceso depende de la topología de la red, pero en general todos los algoritmos se basan en alguno de los procesos que se resumen más adelante (algunos los describiremos con más detalle al estudiar modelos concretos). 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.

### **1.7- Aplicaciones generales de las RNA**

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 RNA 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 RNA capaces de realizar una determinada tarea consiste en una elección adecuada de sus características más una estructura conveniente.

Las redes neuronales más utilizadas hoy día son la Red de Hopfield, los mapas autoorganizativos de Kohonen y el Perceptrón multicapa con algoritmo de retropropagación. Más del 80 % de las aplicaciones realizadas en nuestro campo de Ingeniería Eléctrica así como de los artículos publicados hasta el año 1996 utilizan el perceptrón multicapa con algoritmo de retropropagación, al cual dedicaremos por tanto la mayor parte del tiempo de este curso.

Algunas aplicaciones en la Ingeniería Eléctrica:

- Análisis de seguridad (Red de Hopfield)
  - Determinación del tiempo crítico de despeje.
  - Estimación de la seguridad estática.
  - Estimación de la seguridad dinámica.
  - Estimación de la seguridad de voltaje.
- Plantas de generación (Perceptrón multicapa).

- Detección de cambios en modos de operación.
- Diagnóstico de condiciones anormales.
- Diagnóstico de transitorios.
- Predicción de la potencia térmica.

### **1.7.1- 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.

### **1.8- Conclusiones del capítulo**

- Quedan expuestos, los modelos matemáticos de la operación de sistemas de flujo en bombas centrífugas.
- Los procedimientos tradicionales reportados por la literatura especializada, utilizan métodos gráficos para la obtención de los parámetros operacionales del sistema en el punto de funcionamiento, y en comparación con los modelos matemáticos implementados computacionalmente ofrecen menor precisión, rapidez y confiabilidad.

## CAPITULO II: MATERIALES Y MÉTODOS

### Introducción

### Procedimientos metodológicos sobre las características operacionales de los equipos de bombeo

### Identificación de las variables introducidas en la Red Neuronal

### Parámetros de entrenamiento de la Red Neuronal

### Funcionamiento de la Red Backpropagation

### Pasos para aplicar el algoritmo de entrenamiento

### Consideraciones sobre el algoritmo de aprendizaje

### Dimensionamiento de la red. Número de neuronas ocultas

### Procedimientos para la creación de la Red Neuronal backpropagation

### Conclusiones del capítulo

## 2.1- Introducción

El planteamiento y análisis de los modelos matemáticos, propuesto por diferentes autores, nos permite en toda investigación, realizar la identificación más apropiada de las variables de un proceso. Basado en el planteamiento anterior, hemos propuesto el tema de las redes neuronales, sus características básicas y sus diferentes aplicaciones con sus algoritmos de aprendizaje. Este método ya implementado en otras ramas de la técnica, puede ser una vía eficiente en la utilización de un modelo de redes para la corrección de las características de trabajo de bombas centrífugas.

**El objetivo** del capítulo es:

Determinar las variables principales del proceso y parámetros de la Red a crear para la corrección de la característica de carga de la Bomba Centrífuga; a partir de las limitaciones del método tradicionales.

## 2.2- Procedimientos metodológicos sobre las características operacionales de los equipos de bombeo

Con tal propósito, tradicionalmente los especialistas encargados de estos diagnósticos desarrollan un método gráfico, con los consiguientes inconvenientes de poca precisión, elevado tiempo de ejecución de la tarea, que por demás exige un cúmulo de conocimientos de Mecánica de los Fluidos y experiencias prácticas en su realización, así como limitaciones importantes en cuanto al análisis de diversas alternativas y condiciones de operación variable cuando el sistema presenta diferentes elevaciones y complicadas disposiciones geométricas en el espacio, lo cual se agudiza en aquellos sistemas donde resulta necesaria la regulación de la operación, ya que el caudal entregado por las unidades de bombeo es variable con la demanda del proceso.

Las bombas centrífugas que operan a velocidad constante, pueden descargar cualquier capacidad desde cero hasta un valor máximo que depende del tamaño, diseño y condiciones de succión (Karassik y Carter, 1968). Diversos autores como Bienvenido (1973), Turiño (1994), León y Percy, (2000): y Turro (2002), coinciden en establecer el siguiente modelo para la característica de carga-flujo de las bombas centrífugas a velocidad de giro constante.

$$H = A + B \cdot Q - C \cdot Q^2 \quad (2.1)$$

Donde:

$A(m)$ ;  $B,(s/m^2)$ ;  $C,(s^2/m^3)$  - Coeficientes que se pueden obtener de análisis de la curva característica suministrada por el fabricante.

$Q$  - Caudal para un punto H de trabajo de la bomba;  $m^3/s$

Según Santos y Martín (1999) estos coeficientes son determinados por los modelos siguientes:

$$A = 0.875 \cdot H_D + 0.002396 \cdot H_D \cdot n_{(int)} \quad (2.2)$$

$$B = 0.748 \cdot \frac{N_D}{Q_D} + 0.00315 \cdot \frac{N_D}{Q_D} \cdot n_{(int)} \quad (2.3)$$

$$C = 0.2878 \cdot \frac{H_D}{Q_D^2} \quad (2.4)$$

Donde:

$n_{\text{int}}$  : Velocidad específica, SI

$Q_D$  : Caudal de diseño

$H_D$  : Altura de diseño

$N_D$  : Potencia de diseño de la bomba.

Las características de operación de carga que brindan los fabricantes relacionados a bombas centrifugas, generalmente es para agua limpia y a condiciones de presión y temperaturas normales, velocidad de giro y diámetro exterior constante (Turiño, 1994; Turro, 2002). Dicho modelo no contempla la operación a otras velocidades de giro, diámetro exterior del impelente, ni la aplicación de estos equipos en el bombeo de fluidos no newtonianos.

Mediante la sustitución de las leyes de semejanza (Lorenzo, 1990) en el modelo de la característica de la bomba, se a propuesto la siguiente relación (Turiño, 1994).

$$H = A \cdot \left(\frac{n}{n_1}\right)^2 \cdot \left(\frac{D_2}{D_{21}}\right)^2 + B \cdot \left(\frac{n}{n_1}\right) \cdot Q - C \cdot \left(\frac{D_{21}}{D_2}\right)^2 \cdot Q^2 \quad (2.5)$$

El coeficiente de corrección de carga para fluidos no newtonianos según Roque (1989), se puede ajustar al siguiente modelo:

$$C_H = \frac{(a_0 + c_0 \cdot R_1)}{(1 + b_0 \cdot R_1)} + \left(a_1 \cdot b_1 + \frac{c_1}{R_1}\right) \cdot \ln(\text{Re}^*) + \left(a_2 \cdot b_2 \cdot R_1 + \frac{c_2}{R_1}\right) \cdot (\ln(\text{Re}^*))^2 \quad (2.6)$$

$$R_1 = \frac{Q}{Q_d}$$

$Q$  - Capacidad para la que se desea obtener los coeficientes de corrección

$Q_d$  - Capacidad de diseño.

$$C_H = C_Q^{\frac{3}{2}} \quad (2.7)$$

Estos coeficientes de corrección se determinan en función del número generalizado de Reynolds, y el método de recalcu lo según plantea su autor. Es válido para el rango comprendido entre números de Reynolds de  $1,3 \times 10^{-4}$  a  $1,6 \times 10^{-4}$ .

$$\text{Re}^* = \frac{U_2^{(2-n)} \cdot D_2 \cdot \rho}{\frac{K}{8} \left[ \frac{6 \cdot n + 2}{n} \right]^n} \quad (2.8)$$

Donde:

$n$  - Índice de la ley de potencia (adimensional).

$K$  - Índice de consistencia másica ( $Pa \cdot s$ ).

Al obtener los coeficientes de corrección de carga y capacidad de las bombas centrífugas para fluidos viscosos, es posible corregir la característica operacional de estos equipos mediante las conocidas relaciones siguientes.

$$\frac{H_{\text{corregida}}}{H_{\text{agua}}} = C_H \quad (2.9)$$

$$\frac{Q_{\text{corregido}}}{Q_{\text{agua}}} = C_Q \quad (2.10)$$

Sustituyendo estas expresiones en la ecuación 2.1 se obtiene:

$$H = A \cdot \left( \frac{n}{n_1} \right)^2 \cdot \left( \frac{D_2}{D_{21}} \right)^2 \cdot C_H + B \cdot \left( \frac{n}{n_1} \right) \cdot \frac{C_H}{C_Q} \cdot Q - C \cdot \left( \frac{D_{21}}{D_2} \right)^2 \cdot \frac{C_H}{C_Q^2} \cdot Q^2 \quad (2.11)$$

Para las condiciones donde solo se cambia el tipo de fluido la expresión quedaría de la siguiente forma.

$$H = A \cdot C_H + B \cdot \frac{C_H}{C_Q} \cdot Q - C \cdot \frac{C_H}{C_Q^2} \cdot Q^2 \quad (2.12)$$

Estas ecuaciones constituyen el modelo matemático de la operación de bombas centrífugas, los cuales tienen en consideración los siguientes aspectos:

- 1- Los parámetros de diseño de la bomba a través de los coeficientes A, B y C, obtenidos por la información suministrada por el fabricante con agua.
- 2- Variación de la velocidad de giro.
- 3- Variación del diámetro exterior del impelente.
- 4- Cambio de las propiedades reológicas del fluido, tanto newtoniano como no newtoniano a través de las funciones CH y CQ.

Estos aspectos a tener en cuenta dificultan en cierta medida el trabajo de obtención de la nueva curva de operación de una bomba, debido a la obtención de los parámetros por puntos específicos, por los que se ha propuesto para este trabajo la implementación de las redes neuronales, lo que viabiliza los cálculos y la obtención de los coeficientes de forma más precisa y menos trabajosa.

### 2.3- Identificación de las variables introducidas en la Red Neuronal

Según los modelos tradicionales referidos anteriormente, se han podido identificar las variables principales que intervienen en la corrección de las curvas de las bombas centrífugas, las variables identificadas son:

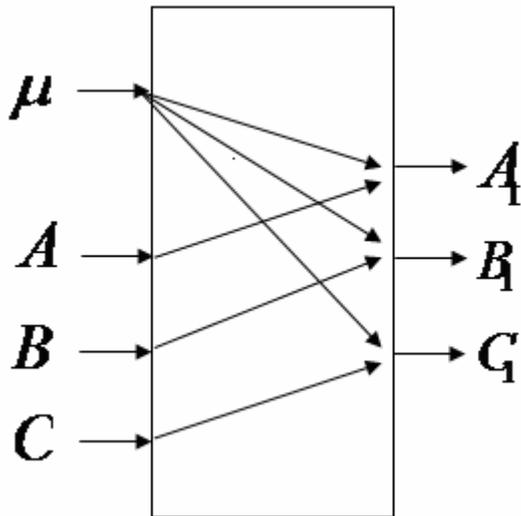
#### Variables de entrada:

- $\mu \rightarrow$  Viscosidad del fluido a transportar: La viscosidad del fluido a transportar influye sobre el caudal que pueda manipular la bomba, la altura que pueda desarrollar la bomba, y la eficiencia de la bomba.
- $A; B; C \rightarrow$  Coeficiente de la curva de carga de la bomba centrífuga para el trasiego del agua según ecuación 2.1.

**Variables de salida:**

- $A_1; B_1; C_1 \rightarrow$  Nuevos coeficientes para la ecuación 2.1, al bombear un fluido con viscosidad diferente a la del agua y según la viscosidad del fluido a transportar.

En la figura 2.1 se dispone de forma esquemática la disposición de la variable considerada como fundamental, distribuida en cuatro entradas y tres salidas.



**Figura 2.1.** Variables del proceso de corrección.

Según la literatura consultada, hemos asumido que introduciendo los coeficientes para el funcionamiento con agua de la bomba con la curva brindada por el fabricante y la viscosidad del fluido que se desea bombear ya sea aparente o absoluta, se pueden obtener los coeficientes del modelo que describe el comportamiento de altura de carga para viscosidades diferentes a la del agua.

#### **2.4- Parámetros de entrenamiento de la Red neuronal**

Para la determinación de los datos para entrenar la Red, se utilizaron datos experimentales que brinda el Hydraulic Institute Standards, tomados para el tipo de bomba centrífuga **SNH 660R46E6**.

Se usó el programa Excel 2003 para la determinación de los coeficientes de corrección dado por el fabricante de dicha bomba, el comportamiento de los datos se muestra en la figura 1 (ver anexo I).

Como se puede observar en la figura 1, el comportamiento de la curva característica de carga de una bomba centrífuga tiende a decrecer con el aumento de la viscosidad del fluido. Este comportamiento es similar en todas las bombas centrífugas, lo que facilita la extrapolación de los resultados y la aplicación de la red neuronal que crearemos a otros modelos de bombas centrífugas. Analizando las líneas de tendencias ajustadas a los datos y siguiendo los modelos de la ecuación 2.1, se han obtenido los coeficientes del modelo para diferentes viscosidades que nos servirá como datos para el entrenamiento de la Red, según se muestra en la tabla 1 (ver anexo I).

## 2.4- Funcionamiento de la Red Backpropagation

El funcionamiento de la red backpropagation (BPN) consiste en el aprendizaje de un conjunto predefinido de pares de entradas-salidas dados como ejemplo: primero se aplica un patrón de entrada como estímulo para la primera capa de las neuronas de la red, se va propagando a través de todas las capas superiores hasta generar una salida, se compara el resultado en las neuronas de salida con la salida que se desea obtener y se calcula un valor de error para cada neurona de salida. A continuación, estos errores se transmiten hacia atrás, partiendo de la capa de salida hacia todas las neuronas de la capa intermedia que contribuyan directamente a la salida, recibiendo de error aproximado a la neurona intermedia a la salida original. Este proceso se repite, capa por capa, hasta que todas las neuronas de la red hayan recibido un error que describa su aportación relativa al error total. Basándose en el valor del error recibido, se reajustan los pesos de conexión de cada neurona, de manera que en la siguiente vez que se presente el mismo patrón, la más salida esté cercana a la deseada.

La importancia de la red backpropagation consiste en su capacidad de autoadaptar los pesos de las neuronas de las capas intermedias para aprender la relación que existe entre un conjunto de patrones de entrada y sus salidas correspondientes. Es importante la capacidad de generalización, facilidad de dar salidas satisfactorias a entradas que el sistema no ha visto nunca en su fase de entrenamiento. La red debe encontrar una representación interna que le permita generar las salidas deseadas cuando se le dan

entradas de entrenamiento, y que pueda aplicar, además, a entradas no presentadas durante la etapa de aprendizaje para clasificarlas.

### 2.4.1- Regla Delta Generalizada para ajustar los pesos

La regla propuesta por Widrow en 1960 ha sido extendida a redes con capas intermedias con conexiones hacia delante (feedforward) y cuyas células tienen funciones de activación continuas (lineales o sigmoideas), dando lugar a la retropropagación. Estas funciones continuas son no decrecientes y derivables.

Este algoritmo utiliza una función de error asociada a la red, buscando el estado estable de mínima energía o de mínimo error a través del camino descendente de la superficie del error. Por ello realimenta el error del sistema para realizar la modificación de los pesos en un valor proporcional al gradiente decreciente de dicha función de error.

#### Funcionamiento del algoritmo

El método que sigue la regla delta generalizada para ajustar los pesos es exactamente el mismo que el de la regla utilizada en ADALINE; los pesos se actualizan de forma proporcional a la delta, o diferencia entre la salida deseada y la obtenida ( $\alpha = \text{salida deseada} - \text{salida obtenida}$ ).

Dada una neurona (unidad  $U_i$ ) y la salida que produce,  $Y_i$ , el cambio que se produce en el peso de la conexión que una salida de dicha neurona con la unidad  $U_j$  ( $w_{ji}$ ) para un patrón de aprendizaje  $p$  determinado es:

$$\Delta w_{ji}(t+1) = \alpha \delta_{pi} Y_{pi} \quad (2.13)$$

En donde el subíndice  $p$  se refiere al patrón de aprendizaje concreto, y  $\alpha$  es la constante o tasa de aprendizaje.

En redes multinivel en principio no se puede conocer la salida deseada de las neuronas ocultas para poder determinar los pesos en la función de error cometido. Inicialmente podemos conocer la salida deseada de las neuronas de salida. Según esto, si consideramos la unidad  $U_i$  de salida, entonces definimos:

$$\delta_{pi} = (d_{pi} - y_{pi}) \cdot f'(net_j) \quad (2.14)$$

Donde

$d_{pi}$  es la salida deseada de la neurona  $j$  para el patrón  $p$

$net_j$  es la entrada neta que recibe la neurona  $j$ .

Esta fórmula es como la de la regla delta, excepto a los se refiere a la derivada de la función de transferencia. Este término representa la modificación que hay que realizar en la entrada que recibe la neurona  $j$ . En caso de que dicha neurona no sea de salida, el error que se produce estará en función del error que se cometa en las neuronas que reciban como entrada la salida de dicha neurona. Esto es lo que se denomina como procedimiento de propagación de error hacia atrás.

Según esto, en el caso de que  $U_j$  no sea una neurona de salida, el error que se produce está en función del error que se comete en las neuronas que reciben como entrada la salida de  $U_j$ :

$$\delta_{pi} = \left( \sum_k \delta_{pk} w_{pi} \right) * f'(net_j) \quad (2.15)$$

Donde el rango de  $k$  cubre a todas las neuronas a las que está conectada la salida de  $U_j$ . De esta forma el error que se produce en una neurona oculta es la suma de los errores que se producen en las neuronas a las que está conectada la salida de ésta, multiplicado cada uno de ellos por el peso de la conexión.

#### 2.4.2- Adición de un momento en la regla delta generalizada

El método de retropropagación del error requiere un importante número de cálculos para lograr el ajuste de los pesos de la red. En la implementación del algoritmo, se toma una amplitud de paso que viene dada por la tasa de aprendizaje. A mayor tasa de aprendizaje, mayor es la modificación de los pesos en cada iteración, con lo que el aprendizaje será más rápido, pero por otro lado, puede dar lugar a oscilaciones. Rumelhart, Hinton y

Williams sugirieron que para filtrar estas oscilaciones se añada en la expresión de incremento de los pesos un término (momento),  $\beta$  de manera que dicha expresión quede:

$$\begin{aligned} w_{ji}(t+1) &= w_{ji}(t) + \alpha \delta_{pj} y_{pi} + \beta (w_{ji}(t) - w_{ji}(t+1)) = \\ \Delta w_{ji}(t+1) &= \alpha \delta_{pj} y_{pi} + \beta \Delta w_{ji}(t) \end{aligned} \quad (2.16)$$

Donde  $\beta$  es una constante que determina el efecto t+1 del cambio de los pesos en el instante t.

Con este momento se consigue la convergencia de la red en menor número de iteraciones, ya que si en t el incremento de un peso era positivo y en t+1 también, entonces el descenso por la superficie de error en t+1 es mayor. Sin embargo, si en t era positivo y en t+1 es negativo, el paso que se da en t+1 es más pequeño, lo cual es adecuado, ya que significa que se ha pasado por un mínimo y que los pesos deben ser menores para poder alcanzarlo.

### 2.4.3- Resumen del algoritmo Backpropagation

Resumiendo, el algoritmo Backpropagation queda finalmente:

$$w_{ji}(t+1) = w_{ji}(t) + [\Delta w_{ji}(t+1)] \quad (2.17)$$

$$w_{ji}(t+1) = w_{ji}(t) + [\alpha \delta_{pj} y_{pi} + \beta \Delta w_{ji}(t)] \quad (2.18)$$

donde:

$$\delta_{pj} = (d_{pj} - y_{pj}) f'(net_j) \quad (2.19)$$

si  $U_j$  es una neurona de salida.

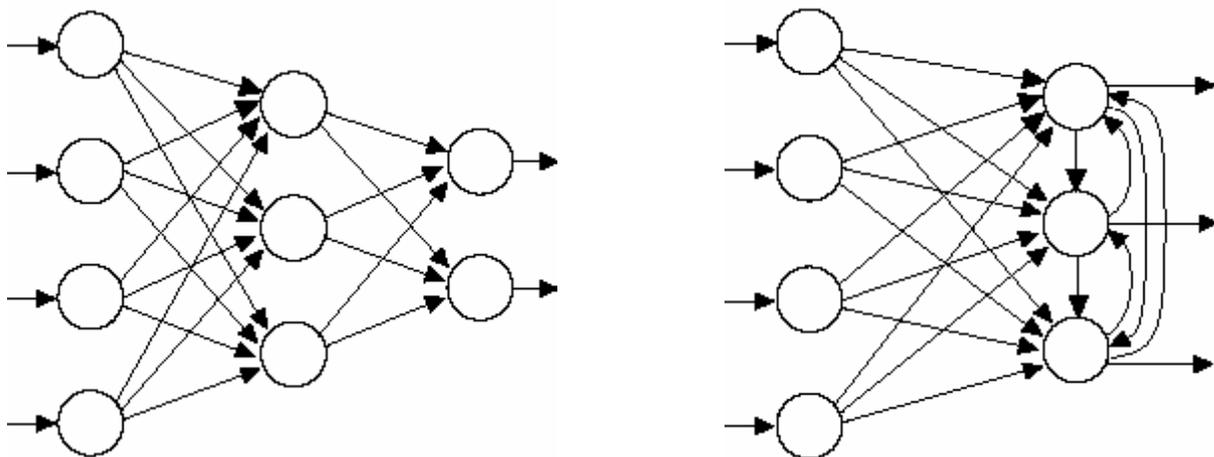
$$\delta_{pi} = \left( \sum_k \delta_{pk} w_{ki} \right) f'(net_j)$$

Si  $U_j$  no es una neurona de salida. (2.20)

### 2.4.4- Estructura y aprendizaje de la Red backpropagation

La red Backpropagation creada tendrá una capa de entrada con 4 neuronas y una capa de salida con 3 neuronas y otra capa oculta de 3 neuronas internas. Cada neurona de una capa (excepto las de entrada) recibe entradas de todas las neuronas de la capa anterior y envía su salida a todas las neuronas de la capa posterior (excepto las de salida). No hay conexiones hacia atrás feedback ni laterales entre las neuronas de la misma capa.

La aplicación del algoritmo tiene dos fases, una hacia delante y otra hacia atrás como muestra la figura 2.2.a y b. Durante la primera fase el patrón de entrada es presentado a la red y propagado a través de las capas hasta llegar a la capa de salida. Obtenidos los valores de salida de la red, se inicia la segunda fase, comparándose éstos valores con la salida esperada para obtener el error. Se ajustan los pesos de la última capa proporcionalmente al error. Se pasa a la capa anterior con una retropropagación del error, ajustando los pesos y continuando con este proceso hasta llegar al primer capa. De esta manera se han modificado los pesos de las conexiones de la red para cada patrón de aprendizaje del problema, del que conocíamos su valor de entrada y la salida deseada que debería generar la red ante dicho patrón.



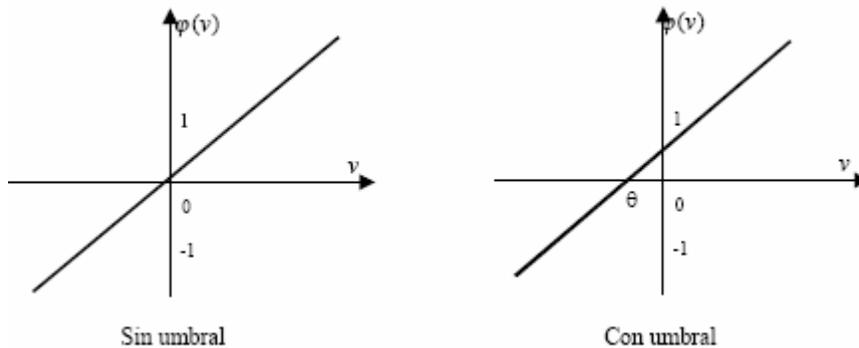
**Figura 2.2.a.** Red neuronal artificial de propagación hacia delante.

**b.** Red neuronal artificial de propagación hacia atrás.

### 2.4.5- Función de activación de la Red

La técnica Backpropagation requiere el uso de neuronas cuya función de activación sea continua, y por lo tanto, diferenciable. Generalmente, la función utilizada será del tipo lineal (purelin).

Esta función posee una característica tipo lineal como se observa en figura 2.3, la cual no tiene límites en su rango.



**Figura 2.3.** Función lineal.

### 2.5- Pasos para aplicar el algoritmo de entrenamiento

#### -Paso 1

Inicializar los pesos de la red con valores pequeños aleatorios.

La inicialización es el primer proceso del entrenamiento de la red neuronal. Una buena selección de los valores iniciales de los pesos sinápticos y de los umbrales pueden ayudar enormemente en el diseño satisfactorio de la red y su entrenamiento. La inicialización de los pesos sinápticos y los umbrales deben distribuirse uniformemente en un rango pequeño para reducir la probabilidad de saturación de las neuronas en la red. Sin embargo, el rango no debe ser muy pequeño ya que puede originar que los gradientes del error sean inicialmente muy bajos, y el aprendizaje muy reducido.

#### -Paso 2

Presentar un patrón de entrada y especificar la salida deseada que debe generar la red.

**-Paso 3**

Calcular la salida actual de la red. Para ello presentamos las entradas a la red y vamos calculando la salida que presenta cada capa hasta llegar a la capa de salida, ésta será la salida de la red. Los pasos son los siguientes:

Se calculan las entradas netas para las neuronas ocultas procedentes de las neuronas de entrada. Para una neurona  $j$  oculta:

$$net_{pj}^k = \sum_{i=1}^N w_{ji}^k x_{pi} + \theta_j^k \quad (2.21)$$

Donde el índice  $h$  se refiere a magnitudes de la capa oculta; el subíndice  $p$ , al  $p$ -ésimo vector de entrenamiento, y  $j$  a la  $j$ -ésima neurona oculta. El término  $\theta$  puede ser opcional, pues actúa como una entrada más.

Se calculan las salidas de las neuronas ocultas según la formula (2.22):

$$y_{pj} = f_j^k (net_{kj}^k) \quad (2.22)$$

Se realizan los mismos cálculos para obtener las salidas de las neuronas de salida:

$$net_{pk}^0 = \sum_{j=1}^L w_{kj}^0 y_{pj} + \theta_k^0 \quad (2.23)$$

$$y_{pk} = f_k^0 (net_{pk}^0) \quad (2.24)$$

**-Paso 4**

Calcular los términos de error para todas las neuronas.

Si la neurona  $k$  es una neurona de la capa de salida, el valor de la delta es:

$$\delta_{pk}^0 = (d_{pk} - y_{pk}) f_{pk}^0 (net_{pk}^0) \quad (2.25)$$

La función  $f$  debe ser derivable. En general disponemos de dos formas de función de salida:

$$\text{La función lineal: } f_k (net_{jk}) = net_{jk} \quad (2.26)$$

$$\text{La función sigmoïdal: } f_k(\text{net}_{jk}) = \frac{1}{1 + e^{-\text{net}_{jk}}} \quad (2.27)$$

La selección de la función depende de la forma que se decida representar la salida: si se desea que las neuronas de salida sean binarias, se utiliza la función sigmoïdal, en otros casos, la lineal.

Para una función lineal, tenemos:  $f_k^0 = 1$ , mientras que la derivada de una función sigmoïdal es:

$$f_k^0 = f_k^0(1 - f_k^0) = y_{pk}(1 - y_{pk}) \quad (2.28)$$

Por lo que los términos de error para las neuronas de salida quedan:

$$\delta_{pk}^0 = (d_{pk} - y_{pk}) \quad (2.29)$$

Para la salida lineal y

$$\delta_{pk}^0 = (d_{pk} - y_{pk})y_{pk}(1 - y_{pk}) \quad (2.30)$$

Para la salida sigmoïdal.

Si la neurona  $j$  no es de salida, entonces la derivada parcial del error no puede ser evaluada directamente, por tanto se obtiene el desarrollo a partir de valores que son conocidos y otros que pueden ser evaluados.

La expresión obtenida en este caso es:

$$\delta_{pj}^k = f_j^k(\text{net}_{pj}^k) \sum_k \delta_{pk}^0 w_{pj}^0 \quad (2.31)$$

donde observamos que el error en las capas ocultas depende de todos los términos de error de la capa de salida. De aquí surge el término propagación hacia atrás.

-Paso 5

Actualización de los pesos: para ello utilizamos un algoritmo recursivo, comenzando por las neuronas de salida y trabajando hacia atrás hasta llegar a la capa de entrada, ajustando los pesos de la siguiente forma:

Para los pesos de las neuronas de la capa de salida:

$$\Delta w_{ij} = y_i * y_j \quad (2.32)$$

$$\Delta w_{kj}^0(t+1) = \alpha \delta_{pk}^0 y_{pj} \quad (2.33)$$

Para los pesos de las neuronas de la capa oculta:

$$w_{ji}^k(t+1) = w_{ji}^k(t) \quad (2.34)$$

$$w_{ji}^k(t+1) = \alpha \delta_{kj}^k x_{pi} \quad (2.35)$$

En ambos casos, para acelerar el proceso de aprendizaje se puede añadir un término momento.

-Paso 6

El proceso se repite hasta que el término de error  $E_p = \frac{1}{2} \sum_{k=1}^M \delta_{pk}^2$  resulta aceptablemente pequeño para cada uno de los patrones aprendidos.

## 2.6- Consideraciones sobre el algoritmo de aprendizaje

El algoritmo encuentra un valor mínimo de error (local o global) mediante una aplicación de pasos (gradiente) descendentes. Cada punto de la superficie de la función corresponde a un conjunto de valores de los pesos de la red. Con el gradiente descendente, siempre que se realiza un cambio en todos los pesos de la red, se asegura el descenso por la superficie del error hasta encontrar el valle más cercano, lo que puede hacer que el proceso de aprendizaje se detenga en un mínimo local de error.

Uno de los problemas del algoritmo es que en busca de minimizar la función de error, puede caer en un mínimo local o en algún punto estacionario, con lo cual no se llega a encontrar el mínimo global de la función de error. Sin embargo, no tiene porqué alcanzarse el mínimo global en todas las aplicaciones, sino que puede ser suficiente con un error mínimo preestablecido.

### 2.6.1- Control de Convergencia

En las técnicas de gradiente decreciente es conveniente avanzar por la superficie del error con incrementos de pesos pequeños. Esto se debe a que tenemos una información local de la superficie y no se sabe lo lejos o cerca que se está del punto mínimo. Con incrementos grandes se corre el riesgo de pasar por encima del punto mínimo sin conseguir estacionarse en él. Con incrementos pequeños, aunque se tarda más en llegar, se evita que ocurra esto.

El incremento del paso adecuado influye en la velocidad de convergencia del algoritmo. La velocidad se controla con la tasa de aprendizaje  $\alpha$ . Normalmente  $\alpha$ , debe ser un número pequeño (del orden de 0,05 a 0,25), para asegurar que la red llegue a asentarse en una solución.

Lo habitual es aumentar el valor de  $\alpha$  a medida que disminuye el error de la red durante la fase de aprendizaje. Así aceleramos la convergencia aunque sin llegar nunca a valores de  $\alpha$  demasiado grandes, que hicieran que la red oscilase alejándose del mínimo.

En la práctica, si una red deja de aprender antes de llegar a una solución aceptable, se realiza un cambio en el número de neuronas ocultas o en los parámetros de aprendizaje, o simplemente, se vuelve a empezar con un conjunto distinto de pesos originales y se suele resolver el problema.

### 2.7- Dimensionamiento de la Red. Número de neuronas ocultas

No se pueden dar reglas concretas para determinar el número de neuronas o número de capas de una red para resolver un problema concreto.

Respecto al número de capas de la red, en general tres capas son suficientes (entrada - oculta-salida), y ese será el número de capas que usaremos para nuestra Red. Sin embargo, hay veces que un problema es más fácil de resolver con más de una capa oculta. El tamaño de las capas, tanto de entrada como de salida, suelen venir determinado por la naturaleza de la aplicación. En cambio, decidir cuántas neuronas debe tener una capa oculta no suele ser tan evidente.

El número de neuronas ocultas interviene en la eficiencia de aprendizaje y de generalización de la red. No hay ninguna regla que indique el número óptimo, en cada problema se debe ensayar.

## 2.8- Procedimientos para la creación de la Red Neuronal **backpropagation**

De acuerdo con las diferentes formas de implementar las redes neuronales artificiales ya discutido en el capítulo I, se utilizó en este trabajo el software MatLAB para crear, entrenar y simular la Red **backpropagation**. El entrenamiento por software requiere una computación matemáticamente comprensiva, muchas veces necesitando tiempo de entrenamiento excesivo en procesadores ordinarios. Matlab tiene un toolbox de redes neuronales artificiales que facilita este proceso de entrenamiento.

Definiendo el vector del patrón de entrada donde e (ver anexo I, tabla 1), es el vector de entrada:

```
e=datos(:,1:4)
```

```
e =
```

```
1.0e+003 *
```

```
0.0320  0.1641  0.0001  -0.0000
```

```
0.4000  0.1600  0.0001  -0.0000
```

```
1.0000  0.1581  0.0000  -0.0000
```

```
2.0000  0.1503  0.0000  -0.0000
```

```
4.0000  0.1508  0.0001  -0.0000
```

Trasponiendo el vector de entrada e:

```
>> e=e'
```

```
e =
```

```
1.0e+003 *
```

```
0.0320  0.4000  1.0000  2.0000  4.0000
0.1641  0.1600  0.1581  0.1503  0.1508
0.0001  0.0001  0.0000  0.0000  0.0001
-0.0000 -0.0000 -0.0000 -0.0000 -0.0000
```

Definiendo el vector del patrón de salida donde  $s$  es el vector de salida (ver anexo I tabla1):

```
>> s=datos(:,5:7)
```

```
s =
```

```
164.1300  0.0542 -0.0003
160.0100  0.0647 -0.0003
158.0600  0.0321 -0.0003
150.3200  0.0103 -0.0003
150.8500  0.0939 -0.0002
```

Trasponiendo el vector de entrada  $s$ :

```
>> s=s'
```

```
s =
```

```
164.1300 160.0100 158.0600 150.3200 150.8500
0.0542  0.0647  0.0321  0.0103  0.0939
-0.0003 -0.0003 -0.0003 -0.0003 -0.0002
```

Cargaremos la ventana Network/Data manager (ver anexo II, figura 2):

```
>> nntool
```

Después de cargar la ventana Network/Data manager crearemos la red deseada e introduciremos los parámetros de entrenamiento y lo entrenamos (ver figura 2; 3; 4 anexo II).

Después de entrenar la red vamos a simular todos los vectores de entrada dado por el fabricante para diferentes viscosidad con la red creada para comprobar el aprendizaje de la Red creada.

Al patrón de entrada lo llamaremos a (ver anexo III, tabla 2):

a =

1.0e+003 \*

0.0320 0.1641 0.0001 -0.0000

0.4000 0.1641 0.0001 -0.0000

1.0000 0.1641 0.0001 -0.0000

2.0000 0.1641 0.0001 -0.0000

4.0000 0.1641 0.0001 -0.0000

Trasponiendo el vector de entrada a

>> a=a'

a =

1.0e+003 \*

0.0320 0.4000 1.0000 2.0000 4.0000

0.1641 0.1641 0.1641 0.1641 0.1641

0.0001 0.0001 0.0001 0.0001 0.0001

-0.0000 -0.0000 -0.0000 -0.0000 -0.0000

Ahora simularemos con la red creada

```
>> u=sim(Bomba,a)
```

```
u =
```

```
164.1300 164.1300 164.1300 164.1300 164.1300
```

```
0.0542 0.0542 0.0542 0.0543 0.0543
```

```
-0.0003 -0.0003 -0.0003 -0.0002 -0.0002
```

## 2.9- Conclusiones del capítulo

- Quedaron establecidas las estrategias generales para entrenar la RED NEURONAL backpropagation.
- La arquitectura más adecuada de una Red Neuronal Artificial para la determinación de los coeficientes de corrección de carga de una bomba centrífuga es la de propagación hacia atrás y adelante.

## CAPÍTULO III: ANALISIS DE LOS RESULTADOS

 **Introducción**

 **Parámetros de entrenamiento de la Red Neuronal Artificial**

 **Resultados de entrenamiento de la Red Neuronal Artificial**

 **Correlación entre los coeficientes experimentados y los simulados**

 **Impacto social de las nuevas técnicas y tecnologías**

 **Conclusiones del capítulo**

### 3.1- Introducción

De acuerdo con las diferentes formas de implementar las Redes Neuronales artificiales ya discutido en el capítulo I y II, se utilizó en este trabajo el software MatLAB para crear, entrenar y simular la red. El entrenamiento por software requiere una computación matemáticamente comprensiva, muchas veces necesitando tiempo de entrenamiento excesivo en procesadores ordinarios. El correcto análisis, permite sentar las bases para futuros trabajos que se desarrollen sobre la temática impulsando a la sociedad.

**El objetivo** del capítulo es:

Simular la Red Neuronal Artificial creada, a partir de la utilización de la data experimental ofrecida por fabricantes de la bomba.

### 3.2- Parámetros para la creación de La Red Neuronal Artificial

En la tabla 3.2 se muestran los parámetros de la Red Neuronal Artificial creada en capítulo anterior.

**Tabla 3.1.** Parámetros de la Red creada.

<b>Parámetros</b>	<b>1ra Capa</b>	<b>Capa Oculta</b>	<b>Capa Salida</b>
<b>No. de entradas</b>	4	3	3
<b>No. De neuronas</b>	4	3	3

<b>Tabla 3.1. Continuación</b>			
<b>Función de activación</b>	Purelin	Purelin	Purelin
<b>No. de iteraciones</b>	50		
<b>Error</b>	0		
<b>Factor de aprendizaje</b>	0.03		
<b>Momento</b>	95		

### 3.2.1 - La arquitectura de la Red Creada

Bomba =

Neural Network object:

numInputs: 1

numLayers: 3

biasConnect: [1; 1; 1]

inputConnect: [1; 0; 0]

layerConnect: [0 0 0; 1 0 0; 0 1 0]

outputConnect: [0 0 1]

targetConnect: [0 0 1]

numOutputs: 1 (read-only)

numTargets: 1 (read-only)

numInputDelays: 0 (read-only)

numLayerDelays: 0 (read-only)

subobject structures:

inputs: {1x1 cell} of inputs

layers: {3x1 cell} of layers

outputs: {1x3 cell} containing 1 output

targets: {1x3 cell} containing 1 target

biases: {3x1 cell} containing 3 biases

inputWeights: {3x1 cell} containing 1 input weight

layerWeights: {3x3 cell} containing 2 layer weights

functions:

adaptFcn: 'trainlm'

initFcn: 'initlay'

performFcn: 'mse'

trainFcn: 'trainlm'

parameters:

adaptParam: .passes

initParam: (none)

performParam: (none)

trainParam: .epochs, .goal, .max\_fail, .mem\_reduc,

min\_grad, .mu, .mu\_dec, .mu\_inc,

mu\_max, .show, .time

weight and bias values:

IW: {3x1 cell} containing 1 input weight matrix

LW: {3x3 cell} containing 2 layer weight matrices

b: {3x1 cell} containing 3 bias vectors

other:

userdata: (user stuff)

A continuación podemos observar con más detalles la red creada mostrada en la figura 3.1.

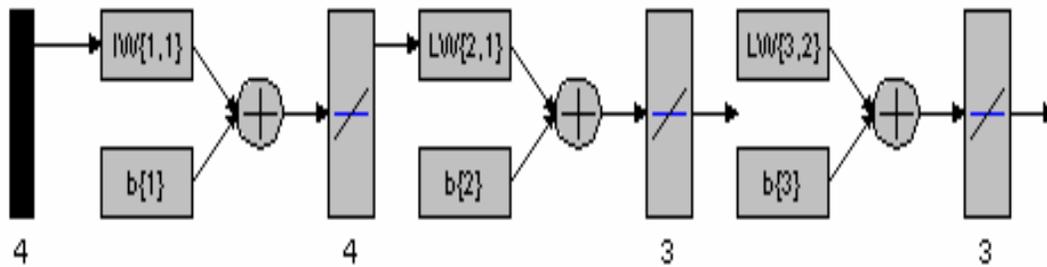


Figura 3.1. Estructura de la red Creada.

### 3.3- Resultados de entrenamiento de la Red Neuronal Artificial

Así, la Red esta adiestrada para disminuir el error al valor mínimo posible en 100 épocas. En otros tipos de redes comúnmente se entrenan para poner en el cero error y su error comúnmente encubre un rango muy mayor (figura 3.2).

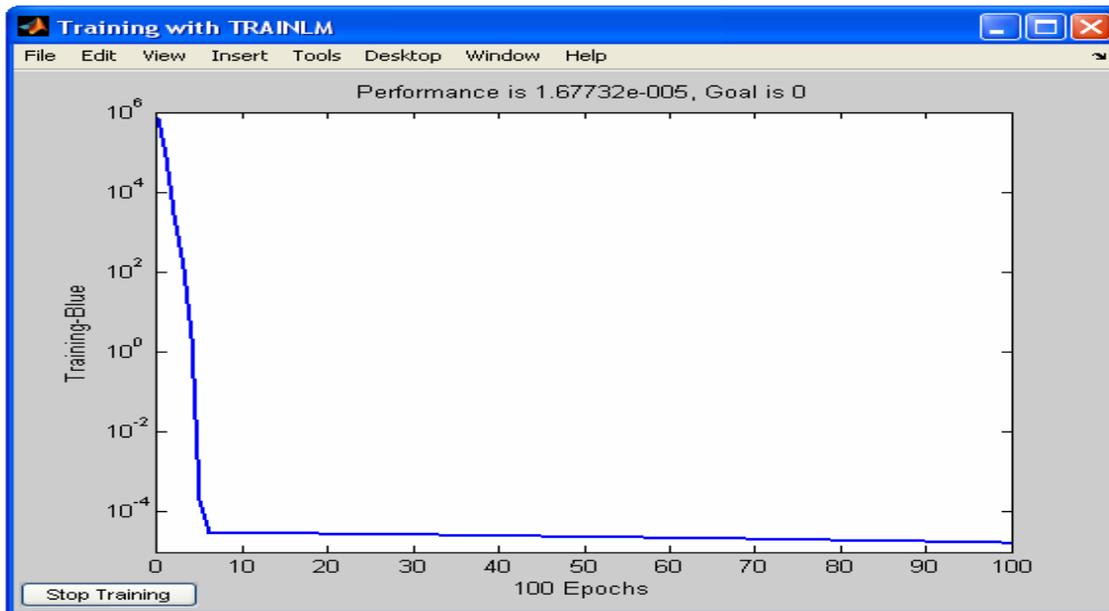


Figura 3.2. Resultados de entrenamiento.

### 3.4- Correlación entre los coeficientes experimentados y los simulados

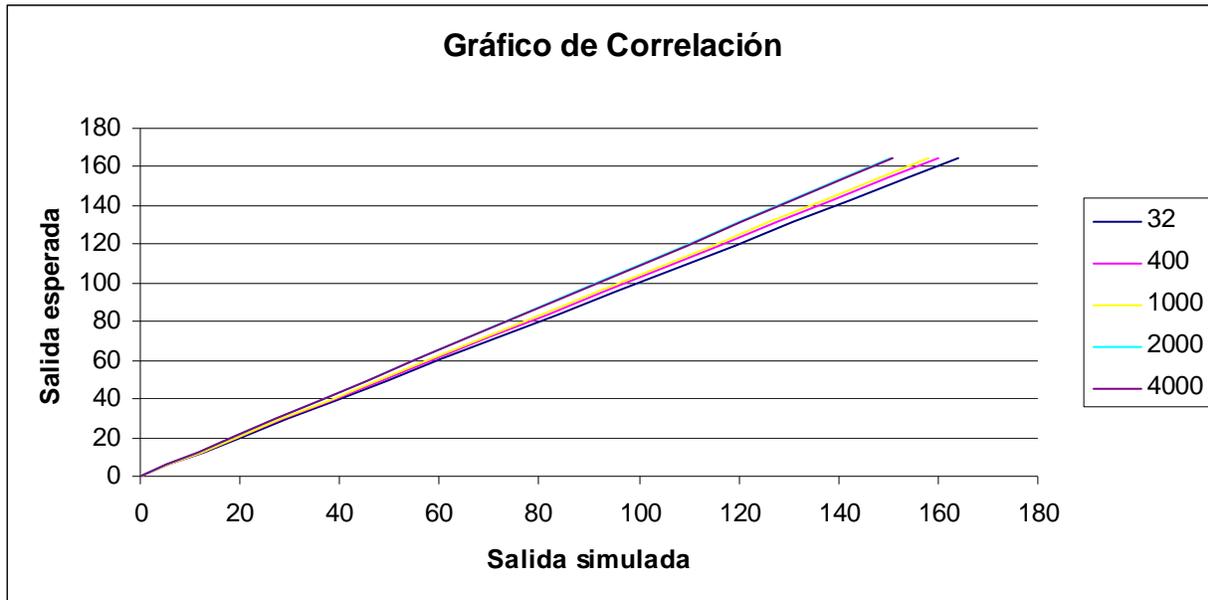
Podemos entonces concluir que la Rede fue exitosamente entrenada, porque el vector de salida fue casi la esperada, que en este caso sería el vector de salida correspondiente a la entrada para las viscosidades de entrenamiento.

A continuación mostraremos los valores esperados y simulados en la tabla 3.2.

**Tabla 3.2.** Resultados de valores esperados y simulado.

Entrada esperada				Salida esperada		
Viscosidad(ssu)	A	B	C	A <sub>1</sub>	B <sub>1</sub>	C <sub>1</sub>
32	164,13	0,0542	-0,0003	164,13	0,0542	-0,0003
400	160,01	0,0647	-0,0003	160,01	0,0647	-0,0003
1000	158,06	0,0321	-0,0003	158,06	0,0321	-0,0003
2000	150,32	0,0103	-0,0003	150,32	0,0103	-0,0003
4000	150,85	0,0939	-0,0002	150,85	0,0939	-0,0002
Entrada simulada (a)				Salida simulada (u)		
Viscosidad(ssu)	A <sub>agua</sub>	B <sub>agua</sub>	C <sub>agua</sub>	A <sub>sim</sub>	B <sub>sim</sub>	C <sub>sim</sub>
32	164,13	0,0542	-0,0003	164,13	0,05419898	-0,00030
400	164,13	0,0542	-0,0003	164,130003	0,05421073	-0,00028
1000	164,13	0,0542	-0,0003	164,130008	0,05422988	-0,00026
2000	164,13	0,0542	-0,0003	164,130017	0,05426181	-0,00023
4000	164,13	0,0542	-0,0003	164,130034	0,05432565	-0,00016

La correlación de los datos de entrada y datos de salida se muestran en la figura 3.3, con el propósito de obtener el grado de exactitud de la Red Neuronal.



**Figura 3.3.** Gráfico de correlación.

Como se muestra en el gráfico de la figura 3.3 y según los resultados de la correlación, se puede precisar que la red creada ha simulado con los datos introducidos con un error promedio de 0,021 según el coeficiente de correlación  $R^2$ ; el mismo devuelve el cuadrado del coeficiente de correlación de momento del producto Pearson mediante los puntos de datos de conocido y (salida esperada) y conocido x (salida simulada). Para obtener más información, consúltese PEARSON. El valor  $R$  cuadrado puede interpretarse como la proporción de la varianza de  $y$  que puede atribuirse a la varianza de  $x$ .

Lo anterior valida la utilización de la red creada para la corrección de la curva característica de bombas centrífugas.

### 3.5- Impacto social de las nuevas técnicas y tecnologías

En la sociedad contemporánea, el desarrollo científico y tecnológico constituye uno de los factores más influyentes, donde en los últimos años se han producido cambios en las interrelaciones Ciencia–Tecnología–Sociedad. Los poderes políticos y militares, la gestión empresarial, los medios de comunicación masiva, descansan sobre pilares científicos y

tecnológicos. También la vida del ciudadano común está notablemente influida por los avances tecnocientíficos (Núñez, 1999).

La interrelación entre Ciencia, Tecnología y Sociedad (CTS) está fundamentada en la existencia de problemas técnicos y la necesidad de encontrar, mediante las investigaciones científicas, respuestas a éstos. Las respuestas pueden quedar establecidas a partir de las innovaciones tecnológicas, las que permiten incrementar la eficiencia de los procesos productivos mediante el aumento de la productividad, la obtención de nuevos productos a partir de desechos industriales y la recirculación de los materiales residuales tratados, a los propios procesos industriales, disminuyendo así los contaminantes que se vierten al medio, pues uno de los temas más complejos que tiene que asumir hoy el pensamiento CTS es el de la relación entre innovación y desarrollo social. Es por tal motivo que al analizar el impacto social de la ciencia en cuestión, no puede desconocerse el hecho de que la ciencia es una actividad social en si misma, (Edge, 1995; Ziman, 1986) y al discutir sobre ciencia, tecnología y sociedad, la sociedad ha de ser colocada como elemento primordial respecto a los múltiples temas a tratar.

El desarrollo tecnológico se considera un fenómeno cultural y de transformación social. Para esto es necesaria la adquisición de una tecnología apropiada que responda como una alternativa a un fin determinado y se ajuste a determinada solución, cuyos usos se adecuan a los fines propuestos de un determinado contexto social en íntima o estrecha relación con los intereses económicos, políticos, culturales e ideológicos.

La teoría sobre RNA sufre un duro golpe al demostrarse (Minsky-Papert a finales de los 60), la imposibilidad de que los perceptrones puedan representar (y por tanto aprender), funciones no separables linealmente, como la XOR. Esto limitaba mucho el número de posibles funciones a representar. Con 4 entradas hay 65536 funciones posibles y sólo 1882 representables. El desarrollo de los ordenadores (procesamiento en serie) y los avances de la I.A. (Sistemas Expertos) contribuyen al "adormecimiento" las Redes Neuronales.

Como consecuencia, muchos investigadores abandonaron el estudio de las RNA, ya que, aunque se vio que este problema se podía salvar utilizando redes multicapas, no se

encontraban algoritmos de entrenamiento apropiados. Después de casi 20 años de abandono, resurgen las redes multicapas, gracias a la perseverancia de algunos investigadores que desarrollaron otras formas de aprendizaje. Sin duda, el paradigma que da fuerza a la investigación en RNA es el algoritmo de retropropagación de errores (backpropagation), que permite entrenar RNA multicapa de propagación hacia adelante (feedforward).

### 3.6- Conclusiones del capítulo

- Se entrenó una red neuronal artificial, capaz de corregir los coeficientes de las curvas características de las bombas centrífugas para diferente valor de viscosidad. La red neuronal artificial tiene 3 capas, la primera tiene 4 entradas, la oculta 3 entradas, y la salida 3 entradas también con una arquitectura de propagación hacia atrás y adelante y el aprendizaje fue supervisado usando el algoritmo de aprendizaje por corrección de error (regla delta) .
- La red se entrenó en 50 iteraciones con un error de 0, y factor de aprendizaje 0.03 y factor de momento 95.

## CONCLUSIONES GENERALES

- Los procedimientos tradicionales reportados por la literatura especializada, son superados por los modelos matemáticos implementados computacionalmente los que ofrecen menor precisión, rapidez y confiabilidad.
- Se ha demostrado que se puede aplicar un modelo de Red Neuronal artificial para la corrección de los coeficientes de la curva de carga, aportando de esta manera con una nueva herramienta para realizar la selección de Bombas Centrífugas.
- La red neuronal artificial entrenada, es capaz de corregir los coeficientes de las curvas características de las bombas centrífugas. La red neuronal artificial tiene 3 capas, la primera tiene 4 entradas, la oculta 3 entradas, y la salida 3 entradas también con una arquitectura de propagación hacia atrás y adelante.
- El modelo neuronal propuesto ha sido capaz de predecir los coeficientes de corrección de la carga de la bomba centrífuga, en estudio para diferentes valores de viscosidades con una elevada precisión y rapidez.

## RECOMENDACIONES

- La Red Neuronal Artificial creada, reconoce sólo conceptos previamente aprendidos y si queremos entrenar un nuevo patrón como la potencia y la eficiencia, deberíamos re-entrenar a la misma con todos los anteriores patrones y este último. En otras palabras, en este tipo de redes ocurre el dilema de la estabilidad y la plasticidad del aprendizaje, por eso se recomienda un algoritmo especial de aprendizaje que posibilita la modificación dinámica de la estructura de la red neuronal para lograr un "aprendizaje incremental constructivo". Esta técnica representa un enfoque evolutivo que realiza una RNA que se denomina, Red Neuronal de Topología Flexible (RNTF).
- Hacer un estudio más profundo sobre los factores más influyentes en la corrección de los coeficientes para así aumentar los patrones de entrenamiento de la Red Neuronal Artificial.
- Crear otra Red capaz de predecir la potencia y la eficiencia de las Bombas Centrífugas, como una continuación futura de este tema de importancia significativa en los trabajos de ingeniería.
- Visualizar la Red Neuronal creada.

## REFERENCIAS BIBLIOGRÁFICAS

1. Adhikari B., Jindal V.K. Artificial Neural: A New Tool for Prediction of Pressure Drop of Non-Newtonian Fluid Foods Through Tubes. *Journal of Food Engineering*: 46, 43-51, 2000.
2. Bäch, T., Hoffmeister F. y Schwefel H. (1991) A Survey of evolution strategies. En *Proceedings of the Fourth Int'l Conf. on Genetic Algorithms* R. K. Belew and L. B. Booker (eds). Morgan Kaufmann, San Mateo, CA.
3. Branke, J. (1995) *Evolutionary Algorithms for Neural Network Design and Training* . En *Proceedings of the First Nordic Workshop on Genetic Algorithms and its Applications* , Jarmo T. Alander (ed), Vaasa, Finland, January.
4. Cherkasski, V.M.: *Bombas, ventiladores y compresores*. Ed. MIR. Moscu, 1986
5. De la Paz N. Uso de la reología en la evaluación de la jalea dentífrica fluida. *Centro de Investigación y Desarrollo de Medicamentos, Rev Cubana Farm* 2002;36(1):21-7
6. Holland J. H. (1975) *Adaptation in Natural and Artificial Systems* . University of Michigan Press (Ann Arbor).
7. Hilera J. y Martínez V. (1995) *Redes Neuronales Artificiales. Fundamentos, modelos y aplicaciones*. RA-MA, Madrid.
8. Haoulo M., García F., SOTO J., *Gradiente de presión de flujo de gas y líquido en tuberías horizontales considerando El Efecto de las Propiedades de Mezcla*, *Revista de la Facultad de Ingeniería Universidad Central de Venezuela* v.20 n.4 ISSN 0798-4065 versión impresa Caracas oct. 2005.
9. Karassik, I., Carter, R., *Bombas centrifugas. Selección operación y mantenimiento*, Editorial Revolucionaria, La Habana, 1968.
10. Koza, J.R. (1997) *Genetic Programming* . En *Encyclopedia of Science and Technology* , Allen Kent y James G. Williams (eds).

11. León C. A., Percy V. F., Ahorro de energía por control de velocidad en el sistema de bombeo de Guarapo, Centroazucar, volumen1, 2000.
12. Nakayama T., E. Niwa y I. Hamada. Pipe Transportation of Minced Fish Paste. *Journal of Food Science*: 45 (4), 844-847 (1980). Om N., Loginapaulo V. y Cavado A., Composición de los petróleos pesados cubanos, CEINPET, *Oil & Gas Journal Latinoamérica*, Volumen 10, numero 1, enero / febrero, 2004.
13. Porto, V.W. (1998) Evolutionary computation approaches to solving problems in neural computation. En *The Handbook of Evolutionary Computation*, Bäck, T., Fogel, D., Michalewicz, Z. (eds.).
14. Prados, D.L. (1992) Training multilayered neural networks by replacing the least fit hidden neurons. En *Proc. of the IEEE SOUTHEASTCON '92*, vol. 2, pp 634-637. IEEE Press, New York.
15. Roque, D., Método de recalcu de la característica de funcionamiento de las bombas centrifugas que manipulan soluciones azucaradas, Memorias del VI encuentro Nacional de Jefes de Maquinarias. MINAZ. Santa Clara, 1989.
16. Sánchez M.G., Estudio de fluidos no newtonianos con los métodos de volúmenes y elementos finitos, *Revista facultad de ingeniería, U.T.A. (CHILE)*, VOL 10, 2002, pp. 23-34
17. Santos, F.: Martín, M., Modelos matemáticos para la determinación aproximada de la forma de la característica de trabajo de una bomba centrifuga; Centro azucar, N 1, 1999.
18. Sutton, R.S. (1986) Two problems with backpropagation and other steepest-descent learning procedures for networks. En *Proc. of 8 th Annual Conf. Of the Cognitive Science Society* , pp 823-831. Lawrence Erlbaum Associates, Hillsdale, NJ.
19. Turiño, I. M., Determinación aproximada de la característica de funcionamiento de una bomba centrifuga. Centro azúcar, No.1, 1994.
20. Turro B. A., Estudio del Hidrotransporte de las Colas en el Proceso Carbonato Amoniaco, Tesis en Opción al Grado Científico de Doctor en Ciencias Técnicas. ISMM, Moa, 2002. p.154

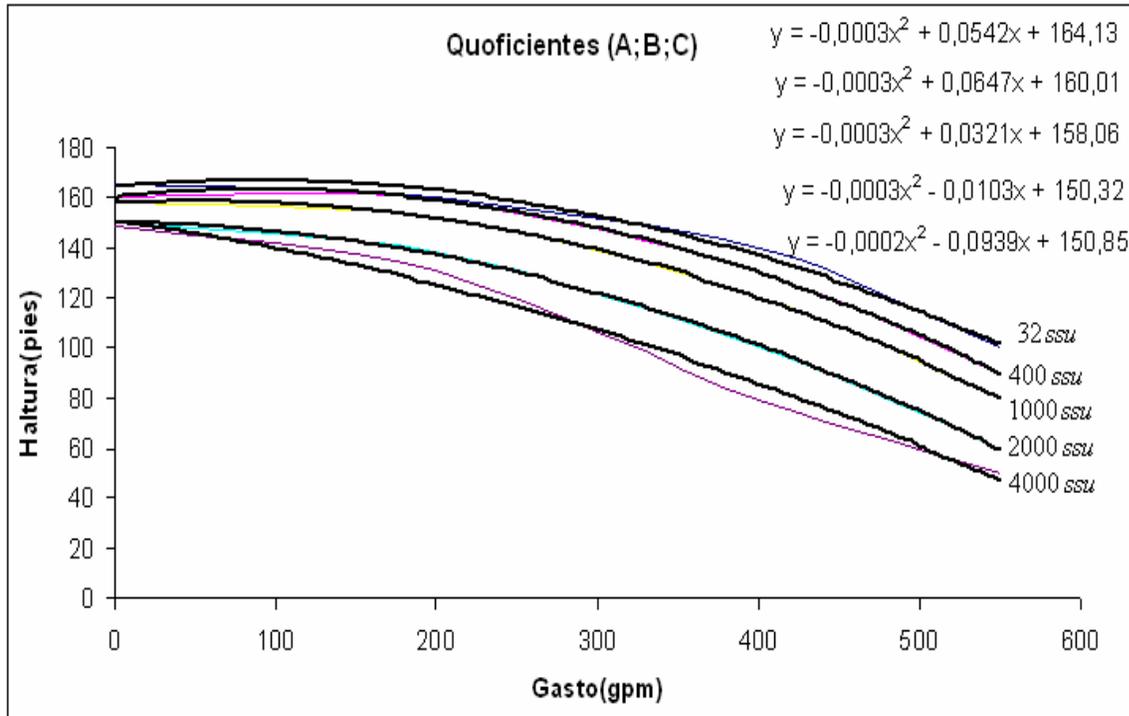
21. Whitley, D. ( 1994) A Genetic Algorithm

[http://www.tesisenxarxa.net/TESIS\\_UPC/AVAILABLE/TDX-1126101-115234//TESIS.pdf](http://www.tesisenxarxa.net/TESIS_UPC/AVAILABLE/TDX-1126101-115234//TESIS.pdf)

[http://pierre.ici.ro/ici/revista/sic1999\\_2/art03.html](http://pierre.ici.ro/ici/revista/sic1999_2/art03.html)

**ANEXOS**

**Anexo I**



**Figura 1.** Curva de trabajo la bomba para diferente viscosidad.

**Tabla1.** Datos para el entrenamiento de la red.

Datos de entrada (e)				Datos de salida (s)		
Viscosidad	A	B	C	A <sub>1</sub>	B <sub>1</sub>	C <sub>1</sub>
32	164,13	0,0542	-0,0003	164,13	0,0542	-0,0003
400	160,01	0,0647	-0,0003	160,01	0,0647	-0,0003
1000	158,06	0,0321	-0,0003	158,06	0,0321	-0,0003
2000	150,32	0,0103	-0,0003	150,32	0,0103	-0,0003
4000	150,85	0,0939	-0,0002	150,85	0,0939	-0,0002

## Anexo II

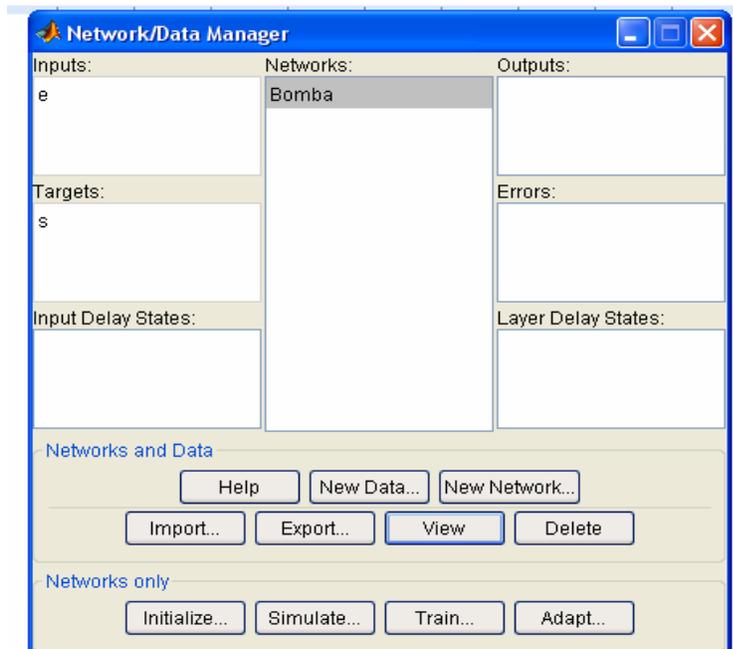


Figura 2. Ventana Network/Data manager.

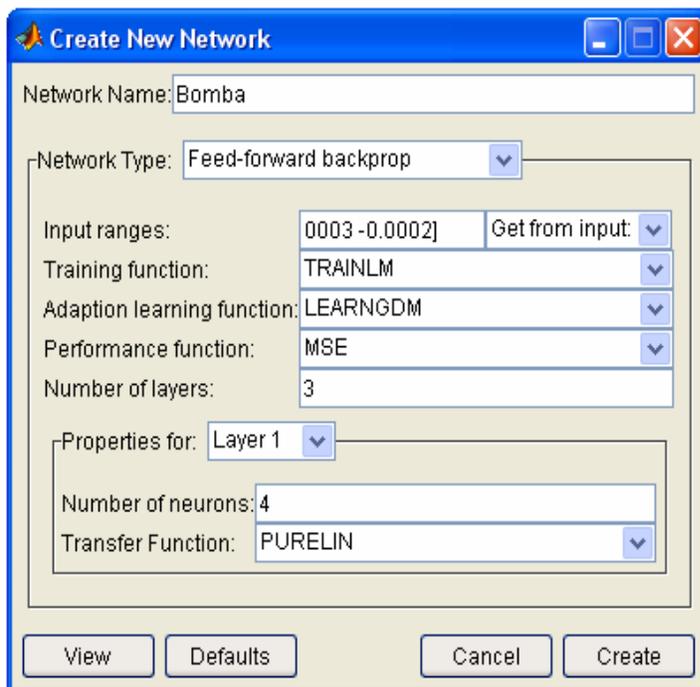
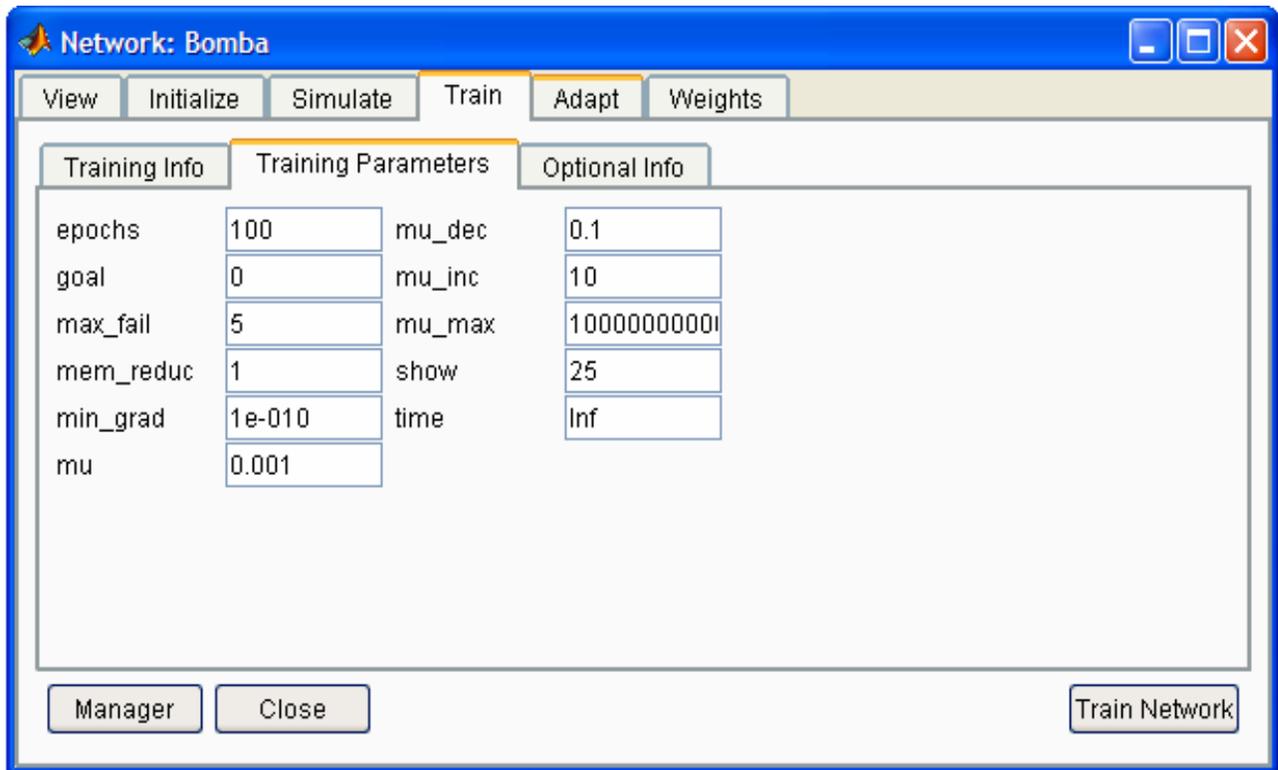


Figura 3. Ventana Create New Network.



**Figura 4.** Parámetros de entrenamiento.

**Anexo III****Tabla 2.** Parámetros de la simulación.

<b>Entrada (a)</b>				<b>Salida (u)</b>		
<b>Viscosidad</b>	<b>A<sub>agua</sub></b>	<b>A<sub>agua</sub></b>	<b>A<sub>agua</sub></b>	<b>A</b>	<b>B</b>	<b>C</b>
32	164,13	0,0542	-0,0003	164,13	0,05419898	-0,000301
400	164,13	0,0542	-0,0003	164,130003	0,05421073	-0,000288
1000	164,13	0,0542	-0,0003	164,130008	0,05422988	-0,000268
2000	164,13	0,0542	-0,0003	164,130017	0,05426181	-0,000234
4000	164,13	0,0542	-0,0003	164,130034	0,05432565	-0,000166