

7



UNIVERSIDAD NACIONAL AUTONOMA DE MEXICO

FACULTAD DE CONTADURIA Y ADMINISTRACION

REDES NEURONALES ARTIFICIALES APLICADAS
A LA DETECCION DE ENFERMEDADES
CARDIOVASCULARES
(ROTULA VENTRICULAR AGUDA Y
ANGINA DE PECHO)

TESIS PROFESIONAL
QUE PARA OBTENER EL TITULO DE:
LICENCIADO EN INFORMATICA
PRESENTA:

SAUL ALQUICIRA ROMAN



ASESOR: ING. BRIBIESCA CORREA GRACIELA

MEXICO. D. F.

2001

298300



Universidad Nacional
Autónoma de México



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

AGRADECIMIENTOS

A MI DIOS.

El principio de la sabiduría es el temor a Jehová, ya que sin ti nada hubiera existido ni subsistido.

A MI PADRE.

Por su enseñanza fiel y su responsabilidad.

A MI MADRE.

Por ser mi refugio innegable de apoyo y de amor.

A MI HERMANO.

Por ser mi amigo, mas que mi hermano.

A MI HERMANA.

Por llegar al mundo ha iluminar de alegría mi vida.

A MIS ABUELOS.

Por el apoyo incondicional que me dieron.

A MI NOVIA.

Por ser aquella persona que robo mi corazón.

A MI MAESTRA

Por haber creído en mi y su gran dedicación

INDICE

INTRODUCCIÓN	6
OBJETIVO	8
ANTECEDENTES	9
PANORAMA HISTORICO	11
CAPÍTULO 1	13
LAS REDES NEURONALES ARTIFICIALES Y SU ENTORNO	13
1.1 <i>Definición de red neuronal</i>	13
1.2 <i>Ventajas de las redes neuronales</i>	13
1.3 <i>Áreas de aplicación</i>	14
1.4 <i>Herramientas software de desarrollo</i>	15
1.5 <i>Implementación en software</i>	15
1.6 <i>Implementación en hardware</i>	16
1.7 <i>Mercado de las redes neuronales artificiales</i>	17
CAPÍTULO 2	18
MODELO FÍSICO-BIOLÓGICO DE LA RED NEURONAL ARTIFICIAL	18
2.1 <i>Redes neuronales de tipo biológico</i>	18
2.2 <i>Las neuronas</i>	19
2.2.1 <i>Naturaleza bioeléctrica de la neurona</i>	19
2.2.2 <i>Potencial de acción de la neurona</i>	19
2.2.3 <i>Origen de potencial de la membrana celular</i>	20
2.2.4 <i>Potencial de membrana en fibras nerviosas</i>	20
2.2.5 <i>Potencial de acción</i>	20
2.3 <i>Sinapsis</i>	21
2.3.1 <i>Anatomía y fisiología de la sinapsis</i>	21
2.3.2 <i>Características especiales de la transmisión sináptica</i>	21
2.3.3 <i>Retraso sináptico</i>	21
2.3.4 <i>Facilitación de la sinapsis</i>	22
2.3.5 <i>Aumento en el número de terminales presinápticas después de la estimulación repetitiva prolongada</i>	22
2.3.6 <i>Funciones excitadoras de la sinapsis</i>	22
2.3.7 <i>Mecanismos por virtud del cual el potencial de acción libera vesículas de transmisor excitador</i>	23
2.4 <i>Transmisor excitador</i>	23
2.4.1 <i>Potencial postsináptico excitador y sus relaciones con el umbral excitación de las neuronas</i>	24
2.4.2 <i>Sumación espacial y bajo nivel de excitación del segmento inicial del axón</i>	24
2.4.3 <i>Sumación temporal</i>	25
2.4.4 <i>Facilitación de la neurona; excitación y facilitación</i>	25
2.5 <i>Transmisor inhibitorio</i>	25
2.5.1 <i>Funciones inhibitorias de la sinapsis</i>	26
2.5.2 <i>Acontecimientos eléctricos en la membrana durante la inhibición</i>	26
2.5.3 <i>Neuronas inhibitorias</i>	26
CAPÍTULO 3	27
MODELO MATEMÁTICO DE LA RED NEURONAL ARTIFICIAL	27
3.1 <i>Elementos de una red neuronal artificial</i>	27
3.2 <i>Neurona artificial</i>	28
3.3 <i>Estado de activación</i>	28
3.4 <i>Función de salida o de transferencia</i>	29

3.4.1 Neurona de función escalón	29
3.4.2 Neuronas de función lineal y mixta	30
3.4.3 Neuronas de función continua (sigmoideal)	30
3.4.4 Función de transferencia gaussiana	31
3.5 Conexión entre neuronas	31
3.6 Función o regla de activación	31
3.6.1 Función de activación escalón	32
3.6.2 Función de activación lineal o identidad	33
3.6.3 Función de activación lineal-mixta	33
3.6.4 Función de activación sigmoideal	33
3.7 Representación vectorial	34
3.8 Niveles o capas de neuronas	34
3.9 Formas de conexión entre neuronas	35
3.10 Topología de las redes neuronales	35
3.10.1 Redes monocapa (1 capa)	36
3.10.2 Redes multicapa	36
3.11 Mecanismos de aprendizaje	37
3.11.1 Redes con aprendizaje supervisado	39
3.11.1.1 Aprendizaje por corrección de error	39
3.11.1.2 Aprendizaje por refuerzo	41
3.11.1.3 Aprendizaje estocástico	41
3.11.2 Redes con aprendizaje no supervisado	41
3.11.2.1 Aprendizaje hebbiano	42
3.11.2.2 Aprendizaje competitivo cooperativo	43
3.12 Tipo de asociaciones entre las informaciones de entrada y salida	43
3.12.1 Redes heteroasociativas	44
3.12.2 Redes auto asociativas	44
3.13 Representación de la información de entrada y salida	45
3.14 Tipos de redes neuronales	45
CAPITULO 4	47
APLICACIÓN DE UNA RED NEURONAL ARTIFICIAL ENFOCADA AL DIAGNOSTICO DE ENFERMEDADES CARDIO VASCULARES (ANGINA DE PECHO Y ROTULA VENTRICULAR AGUDA)	47
4.1 Introducción a la aplicación	47
4.2 Características y funcionamiento de la red neuronal artificial	48
4.3 Ejecucción de la red neuronal artificial	52
4.4 Evaluación de la red neuronal artificial	53
4.5 Limitaciones del modelo de hopfield	54
CONCLUSION	56
APENDICE	57
BIBLOGRAFÍA	60

INTRODUCCIÓN

Uno de los grandes problemas presentados a la humanidad ha sido el diagnóstico correcto de enfermedades, ya que para llegar a dicho resultado no es condicionante que se presenten por completo todos los síntomas de dicha enfermedad.

Los médicos se han basado por siglos en su sentido común y su criterio para formular dicho diagnóstico, teniendo como consecuencia resultados correctos e incorrectos, los cuales pueden afectar o mejorar la vida de un ser humano.

El alto grado de dificultad para solucionar este tipo de problemas reside en la probabilidad de que un síntoma se presente, o no se presente, es decir el diagnóstico elaborado por un médico es una apariencia fundada en la verdad lo cual no garantiza la solución de dicho problema (enfermedad).

Las redes neuronales artificiales es la solución óptima, para el diagnóstico correcto de enfermedades, ya que aun cuando no se presente toda la información (síntomas) a la red neuronal artificial reaccionara satisfactoriamente, dando consigo un resultado satisfactorio.

Cabe mencionar que aun cuando la red neuronal artificial se le presente información incompleta tiene la capacidad de aprender información que no se le haya presentado en un pasado.

La propuesta para este trabajo de investigación fue desarrollar una aplicación de software basado en una red neuronal artificial que permitiera determinar enfermedades cardiovasculares como angina de pecho y rotula ventricular aguda por medio de síntomas (dolor torácico, soplo sistólico, estrés emocional, dolor subesternal), el cual nos permitiera formular un diagnostico correcto de la enfermedad, pero la mayor aportación de este trabajo de investigación consiste en que la red neuronal artificial reaccionara satisfactoriamente aun cuando no se le haya presentado todos los síntomas de una enfermedad.

Para lograr lo anterior se describe en el primer capítulo la definición de la red neuronal artificial como también ventajas, áreas de aplicación, herramientas software de desarrollo, implementación en software y hardware y por ultimo la distribución del mercado de las redes neuronales artificiales.

En el segundo capítulo se analiza el modelo físico biológico de las redes neuronales artificiales, partiendo de la descripción general de la neurona, la sinapsis, los transmisores excitadores e inhibidores, y así mismo una descripción detallada de la naturaleza bioeléctrica de la neurona, el potencial de acción de la neurona, el origen de potencial de la membrana celular, anatomía y fisiología de la sinapsis.

Así, en el capítulo tercero se describe el modelo matemático de la red neuronal artificial, describiendo las principales características como son los elementos, la neurona artificial,

tipos de activación, tipos de aprendizaje, representación vectorial, niveles o capas de neuronas, conexión entre neuronas.

En el cuarto capítulo el cual corresponde a la aportación de este trabajo de investigación de tesis y es la aplicación de una red neuronal artificial enfocada al diagnóstico de enfermedades cardiovasculares (angina de pecho y rotula ventricular aguda).

OBJETIVO

Demostrar que por medio de las redes neuronales artificiales es posible resolver problemas, los cuales no habían sido posible resolver por medio de una programación convencional, ya que esta programación no toma en cuenta las posibilidades que pueden presentarse en un hecho determinado, por tal motivo en este presente trabajo de investigación se comprobara que por medio de una aplicación desarrollada con los fundamentos de las redes neuronales artificiales es posible diagnosticar enfermedades correctamente por medio de padecimientos presentados a dichos pacientes.

Para poder observar los resultados obtenidos en esta investigación los mas fácil posible, se realizo un extracto de todas las enfermedades que pueden presentarse a un dicho paciente, seleccionado así las enfermedades cardio vasculares (rotula ventricular aguda y angina de pecho) como información para comprobar dicha teoría.

ANTECEDENTES

A principios del siglo XVIII comenzaron a surgir teorías del universo para poder explicar fenómenos que hasta nuestros días es un gran enigma.

Newton nos menciona que el universo es un sistema fijo de tiempo y espacio, se consideraba que el movimiento de un cuerpo podría ser descrito en términos de un sistema absoluto (siglo XVIII), posteriormente

En la Teoría General de la relatividad. **Einstein** en 1915 dice que todas las cosas son relativas, es decir que todo no es igual, y que puede cambiar, no es fijo ni el espacio ni el tiempo.

Llegando así a la conclusión que las mediciones de la física nunca son precisas, absolutas, en tiempo y espacio, y existirán siempre incertidumbres cuando se trata de resolver problemas relacionados con el mundo real (toma de decisiones y reconocimiento de formas). Dando lugar a conceptos nuevos como la **Contingencia**; que es la posibilidad de que una cosa suceda o no suceda, **Probabilidad**; Apariencia fundada en la verdad.

Como resultado de la revolución física, ya no se puede pretender decir que con toda seguridad un fenómeno dado se comportara absolutamente estable, si no de aquello que tiene probabilidades de ocurrir rayanas en la certidumbre (Contingencia GIBBSEANA).

A principios del siglo XVIII se creía que todo era absoluto y no podía cambiar, si no hasta que llego **Willard Gibbs** e introdujo la estadística en la física, para así poder decir que algo podrá tener la posibilidad de que pase o no.

En 1947 fue acuñada la palabra cibernética (Kubernetes o timonel) por **Norbert Wiener** para denominarla como la ciencia de la comunicación y el control en el animal y la maquina [Wiener 1948].

En su obra **Cybernetics** de modo general, nos dice que sólo puede entenderse la sociedad mediante el estudio de mensajes y de las facilidades de comunicación de que ella dispone y además que, en el futuro desempeñarán un papel más preponderante los mensajes cursados entre hombres y máquinas, entre máquinas y hombre, y entre maquina y máquina [Wiener 1948].

La idea fundamental de la cibernética es desarrollar una lengua y unas técnicas que nos permitan, no solo encarar los problemas más generales de comunicación y regulación, si no además establecer un repertorio adecuado de ideas y métodos para clasificar sus manifestaciones particulares por conceptos.

De aquí es donde se define la neotecnología llamada Inteligencia Artificial, que trata de idear programas de computo que aumenten la inteligencia de las computadoras para así poder llegar a una comunicación de maquina-hombre, maquina-maquina y hombre-

maquina. Para poder llegar a la Inteligencia Artificial (I.A.) se requiere de conocimiento, percepción, razonamiento, aprendizaje, comprensión etc. En ese momento comienzan a surgir técnicas colaterales de la I.A. y técnicas alternas para así poder llegar a la simulación de la inteligencia del hombre, surgiendo así las Redes Neuronales Artificiales (Aprendizaje), Sistemas Expertos (Razonamiento), Robotica (Manipulación) etc.,

En la actualidad existe un nuevo campo de las ciencias de la computación referente a la resolución de problemas, que no pueden ser descritos por medio de un enfoque algorítmico tradicional. Este enfoque tiene su origen de una emulación mas o menos inteligente de los sistemas nerviosos. A este nuevo campo todavía no de le da nombre pero se le han acuñado palabras como Computación Cognitiva, Computación del mundo Real, Computación Soft, para hacer una diferencia del enfoque algorítmico tradicional, que seria computación Hard. (ver cuadro 1).

Las redes neuronales artificiales en la actualidad son de gran importancia para las ciencias de la computación, ya que por medio de estos modelos en un futuro muy cercano podremos realizar funciones especializadas del ser humano como son el aprender, leer, escuchar, hablar entre otras.

	<i>Computacion Convencional</i>	<i>Computacion Simbolica</i>	<i>Computacion Neuronal</i>
<i>Basado en:</i>	Arquitectura Von Neumann	Logica Geometrica	Neurobiologia
<i>Apropiada para</i>	Algoritmos conocidos	Heurísticas	Articulación
<i>Pero no para:</i>	Combinación de tareas	Cambios de dependencia	Combinación de tareas
<i>Memoria:</i>	Procedimientos	Base de datos concurrencia	Redes de memoria
<i>Construida mediante:</i>	Diseño programático y prueba	Representación del conocimiento e inferencia	Construcción y aprendizaje
<i>Soporte:</i>	Ordenadores secuenciales	Máquinas LSI	Neocórtex con artefacto

1 Formas básicas de computación

PANORAMA HISTORICO

Las Redes Neuronales Artificiales (**ANNs** de Artificial Neural Networks) fueron originalmente una simulación abstracta de los sistemas nerviosos biológicos, formados por un conjunto de unidades llamadas "neuronas" o "nodos" conectadas unas con otras.

Estas conexiones tienen una gran semejanza con las dendritas y los axones en los sistemas nerviosos biológicos.

★ En 1936 **Alan Turing**, fue el primero en estudiar el cerebro humano, como una nueva forma de ver el mundo de la computación, sin embargo los primeros teorías de las redes neuronales y primer modelo de red neuronal fue propuesto en 1943 por **McCulloch**, un neurofisiólogo y **Pitts**, un matemático en términos de un modelo computacional de "actividad nerviosa" [McCulloch 43 y Hebb 49].

★ El modelo de McCulloch-Pitts es un modelo binario, y cada neurona tiene un escalón o umbral prefijado, este modelo fue construido con circuitos electrónicos. Este primer modelo sirvió de ejemplo para los modelos posteriores investigadores de las Redes Neuronales Artificiales. (ANN'S)

★ **Frank Rosenblatt** en 1957 realizó el **Perceptron**. El Perceptron es la red neuronal más antigua que se sigue utilizando hasta nuestros días para el reconocimiento de patrones, esta red es capaz de reconocer patrones aunque no se le hayan presentado anteriormente. Sin embargo este tipo de red tiene sus limitaciones como la de resolver la función de OR-exclusiva [Rosenblatt 58].

★ **Bernard Widrow y Macial Hoff** de la Universidad de Standford en 1959, desarrollaron el modelo **ADALINE** (ADaptive LINear Elements). Esta red fue la primera en ser aplicada en un problema real (Filtros adaptativos para eliminar ecos en las líneas telefónicas) [Widrow 60].

★ **Stephen Grossberg** de la Universidad de Boston en los años 60 hasta en la actualidad a tenido una gran importancia en el desarrollo de las Redes Neuronales, estudio la percepción y la memoria muy a fondo. Realizó en el año de 1967 la Red **Avalancha** que consistía en elementos discretos con actividad que varía en el tiempo, para resolver problemas como el habla y el aprendizaje de los movimientos de los brazos de un robot [Grossberg 82].

★ **Marvin Minsky y Seymour Paper** del Instituto Tecnológico de Massachusetts (Mit) en el año de 1969, realizaron investigaciones sobre el perceptron y descubrieron que tenía grandes limitaciones este tipo de red para resolver problemas. Esta investigación dio lugar a que giraran las investigaciones hacia la Inteligencia artificial [Minsky 69].

★ A pesar de esto **Kunihiko Fukushima** desarrolló el **Necognitrón** en Japon y Europa, este tipo de Red servía para el reconocimiento de patrones visuales. **Tuvo Kohonen** de

la Universidad de Helsinki, también desarrollo este tipo de red independientemente [Fukushima 80].

★ En 1982, coincidieron numerosos eventos que hicieron resurgir el interés por las Redes neuronales **John Hopfield** presento su trabajo en *Redes neuronales* en la Academia Nacional de las Ciencias. En este trabajo, describe con claridad y rigor matemático una Red a la que a dado su nombre **HOPFIELD**, que es un asociador lineal, pero además, mostró cómo tales redes pueden trabajar y que pueden hacer, en este mismo año **Fujitsu** comenzó el desarrollo en computadores pensantes para aplicaciones en robótica [Hopfield 82].

✦ En 1982 se celebro las **U.S Japan Joint Conference on Cooperative Competitive Neural Networks**.

✦ En 1985 se realizo la reunión anual **Neural Networks for Computing**

✦ En 1987 la IEEE realizo la primera conferencia sobre Redes Neuronales, en este mismo año se formo la **International Neural Networks Society (INNS)**

✦ 1988 con el espíritu de cooperación la IEEE y INNS se realizo la conferencia **International Joint Conference on Neural (IJCNN)**. Presentaron en esta un concierto de música realidad por Redes Neuronales Artificiales.

Una primera clasificación de los modelos de ANN's podría ser, atendiendo a su similitud con la realidad biológica:

* **Los modelos de tipo biológico** Este comprende las redes que tratan de simular los sistemas neuronales biológicos así como las funciones auditivas o algunas funciones básicas de la visión.

* **El modelo dirigido a aplicación** Estos modelos no tienen porque guardar similitud con los sistemas biológicos. Sus arquitecturas están fuertemente ligadas a las necesidades de las aplicaciones para las que son diseñados.

CAPÍTULO 1

LAS REDES NEURONALES ARTIFICIALES Y SU ENTORNO

1.1 Definición de red neuronal

- ◆ Sistemas procesales paralelos.
- ◆ Una nueva forma de computación, inspirada en modelos biológicos.
- ◆ Redes interconectadas masivamente en paralelo de elementos simples (usualmente adaptativos) y con organización jerárquica, las cuales intentan interactuar con los objetos del mundo real del mismo modo que lo hace el sistema nervioso biológico. [Kohonen 88].
- ◆ Un sistema de computación hecho por un gran número de elementos simples, elementos de proceso muy interconectados, los cuales procesan información por medio de su estado dinámico como respuesta a entradas externas. [Hecht-Niesen 88].
- ◆ Un modelo matemático compuesto por un gran número de elementos procesales organizados en niveles

1.2 Ventajas de las redes neuronales

- * **Aprendizaje Adaptativo.** Capacidad de aprender a realizar tareas basada en un entrenamiento o una experiencia inicial.
- * **Autoorganización.** Una red neuronal puede crear su propia organización o representación de la información que recibe mediante una etapa de aprendizaje.
- * **Tolerancia a fallos.** La destrucción parcial de una red conduce a una degradación de su estructura: sin embargo, algunas capacidades de la red se puede retener, incluso sufriendo un gran daño.
- * **Operación en tiempo real.** Los computadores neuronales pueden ser realizados en paralelo, y se diseñan y fabrican máquinas con hardware especial para obtener esta capacidad.
- * **Fácil inserción dentro de la tecnología existente.** Se puede obtener chips especializados para redes neuronales que mejoran su capacidad en ciertas tareas. Ello facilita la integración modular en los sistemas existentes.

1.3 Areas de aplicación

Las Redes Neuronales Artificiales son una neotecnología que puede aplicarse en casos militares, comerciales, etc. Casi todos estos son aplicados al reconocimiento de patrones (detección de formas simples), muchos deben de trabajar con datos sensoriales.

Biología

- † Aprender más acerca del cerebro y otros sistemas.
- † Obtención de modelos de retina.

Empresa

- † Evaluación de probabilidad de formaciones geológicas y petrolíferas.
- † Identificación de candidatos para posiciones específicas.
- † Explotación de bases de datos.
- † Reconocimiento de caracteres escritos.
- † Optimización de plazas y horarios de líneas de vuelo.

Medio ambiente

- † Analizar tendencias y patrones.
- † Previsión del tiempo.

Finanzas

- † Previsión de la evolución de los precios.
- † Valoración de riesgo de los créditos.
- † Identificación de falsificaciones.
- † Interpretación de firmas.

Manufactura

- † Robots automatizados y sistemas de control (visión artificial y sensores de presión, temperatura, gas, etc.)
- † Control de producción en líneas de proceso.
- † Inspección de calidad.

Medicina

- † Analizadores del habla para la ayuda de la audición de sordos profundos.
- † Diagnóstico y tratamiento a partir de síntomas y/o de datos analíticos (electrocardiograma, encefalograma, análisis sanguíneo, etc).
- † Monitorización en cirugía.
- † Predicción de reacciones adversas a los medicamentos.
- † Lectores de rayos X.
- † Entendimiento de la causa de los ataques epilépticos.

Militares

- † Clasificación de las señales de radar.
- † Creación de armas inteligentes.
- † Reconocimiento y seguimiento en el tiro al blanco.

1.4 Herramientas software de desarrollo

La comercialización de productos de software ha sido y sigue siendo la forma más extendida para simular redes neuronales debido a las ventajas citadas anteriormente. La diferencia entre los distintos productos de software radica en aspectos tales como el tipo y número de arquitecturas de red que soporta (backpropagation, Hopfield, Kohonen, etc), velocidad de procesamiento (numero de conexiones por unidad de tiempo), interfaz gráfica (ver cuadro 2).

	Vendedor	Algoritmos	Sistema Operativo
Productos Aplicados	SAIC		DOS
	SAIC		DOS
	Peak Software		DOS
	California Scientific		DOS
	NeuroDynamix		DOS
	ImageSoft		DOS;Windows
	Neural System		DOD
	AND America		DOS;Windows
	Neural Ware		DOS
	COSMIC/NASA		DOS;UNIX;VMS
	NeuroSyn		DOS
	Neural Computer		WINDOWS
	Software Bytes		DOS
	Ward System		DOS
	Neural Ware		DOS;MAC
Productos Neuronales	AI Ware		DOS;UNIX;VMS
	HC		DOS
	HNC		DOS;Windows
	IBM		DOS;WINDOWS; OS/2
	IBM		OS/400
Productos Prototipos	Neural Ware		DOS;OS/2;UNIX; VMS

2 Herramientas de desarrollo de software comercial [SIGÜENZA 93]

1.5 Implementación en software

El software basado en RNA ha tenido un gran éxito en el desarrollo de aplicaciones, ya que con ellas se pueden solucionar problemas que anteriormente se consideraban intratables para el ámbito computacional de desarrollo de software. (ver cuadro 3)

Un ejemplo de aplicaciones de software basadas en RNA se muestran en el siguiente cuadro informativo.

<i>Producto</i>	<i>Vendedor</i>	<i>Hardware</i>	<i>Sistema Operativo</i>	<i>Dominio</i>
<i>CAD/Chem Custom Formulation System Database Mining Workstation</i>	AI Ware	HP;Sun; DEC ws; RS/6000	UNIX; VMS	Diseño y formulación de productos químicos
<i>NeuroVision</i>	HNC	-	-	Análisis y de la detección de fraude de tarjeta.
<i>NT 5000 Neural Network Control System NueX Smart Structures Toll</i>	Vision Harvest	PC	DOS	Clasificación de objetos por forma color y textura.
	California Scientific Software	-	-	Control de procesos en tiempo real.
	Charles River Analytics	Mac II	Mac (Nexpert Object 2.0)	Sistema híbrido RN/SE Control de procesos, detección y aislamiento de averías, evaluaciones de daños
<i>QuickStrokes</i>	HNC	PC;Sun; SPARC Station	DOS; UNIX	Reconocimiento de caracteres manuscritos.

3 Productos comerciales especializados [SIGUENZA 93]

1.6 Implementación en hardware

La realización más simple consiste en simular una red sobre un ordenador convencional mediante un software específico. Este es un procedimiento muy poco costoso, rápido y muy útil, pero la gran desventaja, que esta simulación se realiza en computadores secuenciales, que no pueden tener un paralelismo alto.

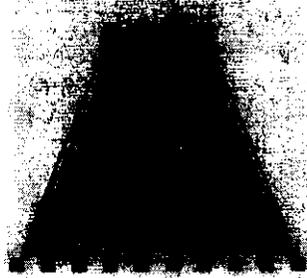
En cuanto al **hardware** se ha implementado neurocomputadores, que básicamente es un conjunto de procesadores conectados unos con otros que operan concurrentemente.

En la actualidad ya existen una serie de neurocomputadores comerciales destinados a la realización de redes neuronales: puedo citar el **Mark III** y **IV**, el **ANZA** y **ANZA plus** o el **Delta-Sigma**.

Por otra parte en la implementación de los **circuitos integrados**, para poder obtener una estructura que se comporte lo más similar posible a como lo haría una red neuronal. Aunque esta aproximación se encuentra se halla básicamente en manos de las Universidades y centros de investigación existen algunos productos comerciales como el

N64 Intel, chip que incluye 64 neuronas y 10.000 sinapsis y que puede procesar 2500 conexiones por segundo o el **MB4442** de Fujitsu, o el **MDI1220** de MicroDevices, con estructura de bit slice, o el conjunto **NU3232** y **N32** de neural semiconductores.

Existen matrices de unidades procesadores conectadas con una topología mas o menos regular como la **CONE** (Computation Network Enviroment), **NNETS** (Neural Network Enviroment Tranputer System), **RISC Neural** (ver imagen 1).

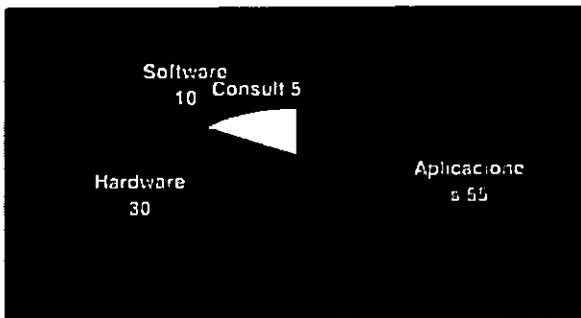


1 Risc neural

1.7 Mercado de las redes neuronales artificiales

Como se ha comentado en capitulos anteriores las redes neuronales artificiales tienen un papel muy importante desde el desarrollo de aplicaciones de software, lenguajes de desarrollo de software, aplicaciones de hardware como también en la consultoría.

Actualmente son numerosos los trabajos que se realizan y publican cada año, las aplicaciones nuevas que surgen y las empresas que lanzan al mercado productos nuevos, tanto hardware como software (sobre todo para simulación). Respecto a la situación del mercado de las redes neuronales, en la figura imagen 1.2 se muestra cómo esta repartido actualmente el mercado de las RNA.



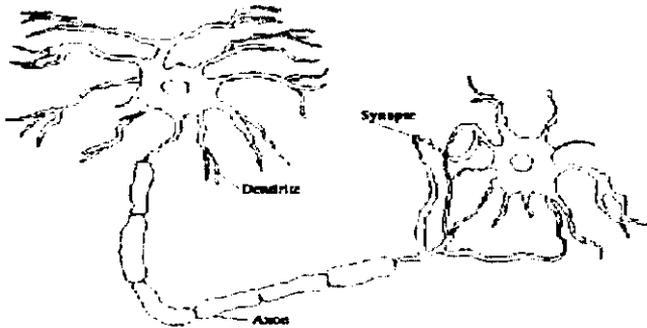
2 El mercado de las ma[Si[guenza 93]

CAPÍTULO 2

MODELO FISICO-BIOLOGICO DE LA RED NEURONAL ARTIFICIAL

2.1 Redes neuronales de tipo biológico

Se estima que el cerebro humano contiene más de cien mil millones (10 a la 11) de neuronas y (10 a la 14) de sinapsis en el sistema nervioso humano. Estudios sobre la anatomía del cerebro humano concluyen que hay más de 1000 sinapsis a la entrada y a la salida de cada neurona. Es importante notar que aunque el tiempo de conmutación de la neurona (unos pocos milisegundos) es casi un millón de veces menor que en los actuales elementos de las computadoras, ellas tienen una conectividad miles de veces superior que las actuales supercomputadoras (Ver imagen 3) [Guyton 1971].



3 RNA DE TIPO BIOLÓGICO

El objetivo principal de las redes neuronales de tipo biológico es desarrollar un elemento sintético para verificar las hipótesis que conciernen a los sistemas biológicos

Las neuronas y las conexiones entre ellas (sinapsis) constituyen la clave para el procesamiento de la información. Observe la figura:

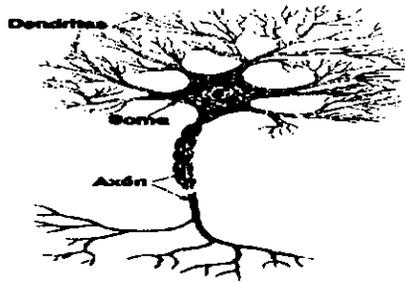
La mayor parte de las neuronas poseen una estructura de árbol llamadas dendritas (dendron = árbol) que reciben las señales de entrada que vienen de otras neuronas a través de las uniones llamadas sinapsis. Algunas neuronas se comunican solo con las cercanas, mientras que otras se conectan con miles.

Hay tres partes en una neurona:

- 1- El cuerpo de la neurona
- 2- Ramas de extensión llamadas dendritas para recibir las entradas,
- 3- y un axón que lleva la salida de la neurona a las dendritas de otras neuronas.

2.2 Las neuronas

Una neurona es una célula nerviosa y por tanto tiene un núcleo contenido en el soma o cuerpo de la célula de un tamaño aproximadamente de 5 a 10 micras de diámetro. Una de las características que diferencian a las neuronas del resto de las células vivas, es su capacidad de comunicarse (Ver imagen 4).



4 La neurona

Las neuronas pueden ser unipolares, bipolares o multipolares. Las que contiene el ser humano son la bipolares y multipolares, ya que las unipolares se encuentran en animales inferiores, para nuestro estudio solo se tomaran en cuenta las dos primeras mencionadas.

Existen líquidos tanto dentro como fuera de la célula (neurona) llamados intracelulares y extracelulares. Los líquidos extracelulares contiene grandes cantidades de sodio y pequeñas cantidades de potasio, ocurre exactamente lo opuesto en el líquido intracelular [Guyton 1971].

2.2.1 Naturaleza bioeléctrica de la neurona

Las señales que se utilizan, y a las que me estoy refiriendo, son de dos tipos distintos de naturaleza; *eléctrica* y *química*. La señal generada por la neurona y transportada a lo largo del axón es un impulsó eléctrico, mientras que la señal que se transmite entre los términos axónicos de una neurona y las dendritas de la neurona siguiente es de origen químico, esta se realiza mediante substancias transmisoras (neurotransmisoras) que fluyen a través por unos contactos llamados sinapsis [Guyton 1971].

2.2.2 Potencial de acción de la neurona

Hay potenciales eléctricos dentro de una neurona (membrana celular) o sea, capaces de transmitir impulsos electroquímicos a lo largo de sus membranas.

En la neurona existe un equilibrio de iones negativos (aniones) dentro de la célula contra los iones positivos (cationes) fuera de la célula, cuando se acumulan aniones en exceso dentro de la neurona, inmediatamente se producen cationes fuera de la célula. El resultado es el desarrollo de un potencial de membrana [Guyton 1971].

Los dos medios básicos para desarrollar un potencial de membrana son los siguientes:

a) Transporte de iones (positivos, negativos), creando un desequilibrio entre cargas positivas y negativas. Esta es la que nos interesa para nuestro estudio (transporte activo).

b) Difusión de iones a través de la membrana.

2.2.3 Origen de potencial de la membrana celular

1.-La membrana del nervio posee una bomba de sodio y una de potasio; el sodio es impulsado hacia el exterior y el potasio hacia el interior.

2.-La membrana del nervio en reposo normalmente es de 50 a 100 veces más permeable para el potasio que para el sodio. Por lo tanto, el potasio difunde con relativa facilidad a través de una membrana en reposo, mientras que el sodio difunde con gran dificultad [Guyton 1971].

2.2.4 Potencial de membrana en fibras nerviosas

El potencial de una membrana en reposo, medido en diferentes fibras nerviosas se encuentra entre el rango de -75 y -95 milivoltios con -85 milivoltios como valor medio probable de las diferentes mediciones [Ham 1969].

2.2.5 Potencial de acción

Mientras la membrana de la fibra nerviosa no sufre perturbación, el potencial de membrana se conserva en aproximadamente -85 milivoltios, valor denominado potencial de reposo. Cualquier factor que aumente bruscamente la permeabilidad de la membrana para el sodio tiene tendencia a desencadenar una serie de cambio rápidos en el potencial de membrana, que duran una pequeña fracción de segundo seguidos inmediatamente de vuelta del potencial de membrana a su valor de reposo. esta sucesión de cambios recibe el nombre de potencial de acción.

Algunos de los factores que pueden desencadenar el potencial de acción son la estimulación eléctrica de la membrana, la aplicación de productos químicos a la membrana aumentando su permeabilidad para el sodio, la lesión mecánica de la membrana, el frío, el calor u cualquier factor que perturbe momentáneamente el estado normal de reposo de la membrana [Guyton 1971].

- Permeabilidad de diferentes factores sobre la permeabilidad de los poros.

Algunas sustancias como el agua y muchos de los iones disueltos parecen atravesar los agujeros que hay en la membrana celular denominados poros de la membrana. No se sabe la naturaleza de tales poros, pudieran ser agujeros redondos, pequeñas hendiduras, etc.

La permeabilidad de los poros no se conserva exactamente la misma en todas las circunstancias, esto se debe al tipo de líquido que permita la permeabilidad en grandes cantidades o en pocas [Ham 1969].

2.3 Sinapsis

La palabra sinapsis proviene de un término griego que significa abrochar. Cuando las prolongaciones de una neurona se ponen en contacto con el cuerpo celular o una prolongación de otra neurona se llaman sinapsis [Ham 1969].

2.3.1 Anatomía y fisiología de la sinapsis

La unión de una neurona y la siguiente recibe el nombre de sinapsis. Las neuronas de otra parte del cuerpo humano difieren netamente unas con otras, estas neuronas pueden tener axones mas grandes o dendritas etc [Guyton 1971].

2.3.2 Características especiales de la transmisión sináptica

Los impulsos eléctricos son conducidos a través de la sinapsis solamente desde las terminales presinápticas a las neuronas sucesivas, nunca en dirección retrógrada. Esta es la denominada ley de Bell-Magendie.

2.3.3 Retraso sináptico

Al transmitirse un impulso una terminal presináptica a una neurona postsináptica, transcurre cierto tiempo en el proceso de:

- a) Descarga de la sustancia transmisora por la terminal presináptica.
- b) Difusión de transmisores a la membrana neuronal subsináptica.
- c) Acción de transmisor sobre la membrana.
- d) Difusión de sodio hacia el interior para elevar el potencial postsináptico excitatorio hasta valor suficiente para descargar un potencial suficiente para descargar un potencial de acción.

El mínimo de tiempo requerido para que ocurran todos estos acontecimientos, incluso cuando son estimulado simultáneamente gran número de terminales presinápticas es de aproximadamente de 0.5 milésimas de segundo. Este es el denominado retraso sináptico. Tiene importancia por el siguiente motivo: los neuro-fisiólogos pueden medir el mínimo retraso entre el momento de entrada de una descarga de impulsos en una zona del sistema nervioso y el de la salida, y así calcular el número total de neuronas que hubo en el circuito [Ham 1969].

Aumento en el número de terminales presinápticas después de estimulación repetitiva prolongada

2.3.4 Facilitación de la sinapsis

Cuando se aplica un estímulo rápidamente repetitivo (tetanizante) a las terminales presinápticas (Sinapsis) durante breve tiempo la neurona suele responder más que normalmente a los impulsos que llegan. Esto es lo que se llama **facilitación posttetánica**.

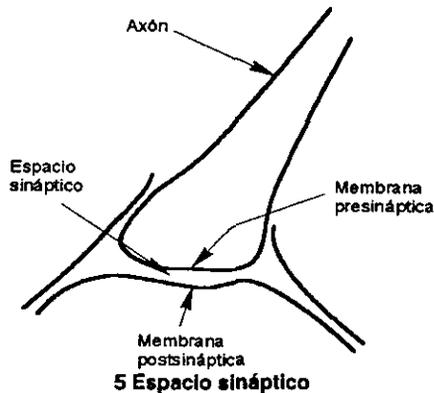
Una de las explicaciones más probables de la **facilitación posttetánica** es que la estimulación repetitiva altera la membrana de las terminales presinápticas de manera que vacía más rápidamente las vesículas que contienen transmisor. Por lo tanto este tipo de **facilitación** puede ser como una especie de **memoria a corto plazo**

2.3.5 Aumento en el número de terminales presinápticas después de la estimulación repetitiva prolongada

La estimulación repetitiva prolongada de la sinapsis durante varios días hace que el número de terminales presinápticas en cada sinapsis aumente, y también modifica su forma y dimensiones de sus terminales. **Se cree que estos cambios físicos pudieran ser la base de la memoria**. Las señales sensoriales que ingresan, teóricamente podrían originar cambios estructurales en la sinapsis de manera que éstas pueden ser estimuladas más tarde con mucha mayor facilidad que la primera vez; en ocasiones con tal facilidad que incluso un impulso desviado procedente del cualquier nivel del sistema nervioso puede desencadenar las mismas señales que las causadas por la experiencia sensitiva original [Guyton 1971].

2.3.6 Funciones excitadoras de la sinapsis

El mecanismo por virtud del cual las terminales presinápticas excitan las neuronas postsinápticas se cree que es la secreción de una sustancia excitadora denominada **transmisor excitador**. El soma neuronal está separado de la sinapsis por una hendidura de aproximadamente 200 amstroms (Ver imagen 5).



La terminal sináptica tiene dos estructuras internas importantes para la transmisión de los impulsos a través de la sinapsis, las vesículas sinápticas y las mitocondrias. Las

vesículas sinápticas contiene el transmisor excitatorio, que cuando es liberado en la hendidura sináptica excita la membrana del soma neuronal (cuerpo de la neurona). El ATP necesario para la síntesis del nuevo transmisor excitador lo proporcionan las mitocondrias, y es posible que las mitocondrias incluso sinteticen su propio transmisor excitador. Este transmisor debe sintetizarse con extraordinaria rapidez, porque la cantidad almacenada en las vesículas sólo basta para unos pocos minutos de función normal.

Cuando un potencial de acción difunde sobre una terminal presináptica, la despolarización de la membrana origina vaciamiento automático de un pequeño número de vesículas en la hendidura; el transmisor excitador liberado, a su vez origina un aumento inmediato de permeabilidad de la membrana somática subsináptica, que permite que los iones de sodio penetren libremente desde los líquidos extracelulares al interior de la neurona, provocando una disminución de electronegatividad en su interior. Esta disminución de electronegatividad se difunde casi por igual en todo el interior del cuerpo celular de la neurona, debido a la gran conductividad del líquido intracelular [Guyton 1971].

2.3.7 Mecanismos por virtud del cual el potencial de acción libera vesículas de transmisor excitador

Solo se puede especular acerca del mecanismo por virtud del cual un potencial de acción alcanza el botón terminal hace que las vesículas liberen sustancias transmisoras hacia la hendidura sináptica. Sin embargo, el número de vesículas vaciadas con cada potencial de acción disminuye considerablemente.

- a) Cuando la cantidad de iones de calcio en el líquido extracelular está disminuida.
- b) Cuando la cantidad de iones de sodio en el líquido extracelular está disminuida.
- c) Cuando la cantidad de iones de magnesio de los líquidos extracelulares está aumentada.
- d) Cuando la membrana de la terminal presináptica ya ha sido parcialmente despolarizada antes de transmitir el potencial de acción.

Como sea, está comprobado que cada vez que un potencial de acción viaja por la superficie del botón terminal se vacían bruscamente vesículas de sustancias transmisoras en la hendidura sináptica. Pueden vaciarse pocas o muchas vesículas, según los factores antes mencionados [Ham 1969].

2.4 Transmisor excitador

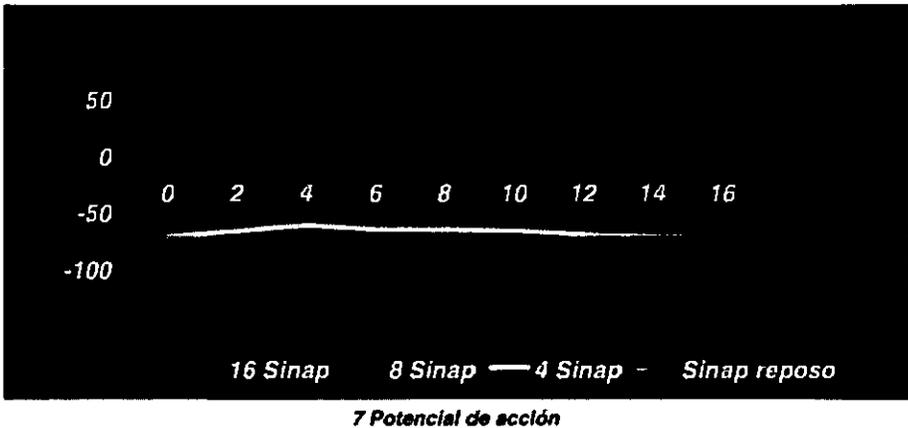
Aun no se conoce la naturaleza de la sustancia química exacta del transmisor excitador secretado en las sinapsis del sistema nervioso central, pero se intuye que es la ACETILCOLINA .

2.4.1 Potencial postsináptico excitador y sus relaciones con el umbral de excitación de las neuronas

Cuando una terminal presináptica excitadora libera su transmisor, la membrana neuronal se vuelve muy permeable a los iones tanto sódico como potasio durante aproximadamente durante una milésima de segundo.

En ese tiempo difunde suficiente sodio hacia el interior de la célula para neutralizar parte del potencial normal de reposo causada primariamente por la difusión del ion potasio, ósea que el potencial dentro de la célula se vuelve menos negativo, ese cambio de potencial de la membrana en reposo recibe el nombre de potencial excitador, persistente por cierto tiempo, hasta 15 milésimas de segundo [Guyton 1971].

El potencial normal de una neurona en reposo es de -70 milivoltios, en contraste con los -85 milivoltios de los axones periféricos (Ver imagen 7).



Así pues, el efecto básico de excitar la terminal presináptica es crear un potencial postsináptica excitador en la neurona. Si este potencial es muy ligero, la neurona no se descarga, pero si sobrepasa un **umbral** determinado, el umbral de excitación de la neurona comienza a aparecer potenciales de acción en la misma. El umbral medio de excitación de una neurona anda alrededor de los 11mv por encima del potencial de la membrana en reposo., o sea, que cuando el potencial se eleva desde de su valor normal de -70 a -59 mv se produce un potencial de acción [Ham 1969].

2.4.2 Sumación espacial y bajo nivel de excitación del segmento inicial del axón

La excitación simultánea de un número de terminales excitatorias presinápticas sucesivamente creciente provoca un aumento del potencial postsináptico. Esto es lo que se llama **sumación espacial**.

La sumación espacial no se produce solamente en la vecindad inmediata de las terminales excitadas, sino que ocurre en toda la membrana del soma, dendritas y

segmento inicial del axón al mismo tiempo. También los potenciales postsinápticos generados en las dendritas se suman con los del soma, a pesar de la amplia separación del espacial. El motivo de esta sumación es que la resistencia eléctrica intracelular, es muy baja lo cual permite un cambio de potencial de alguna parte de la célula que difundirá a todas las zonas celulares casi instantáneamente.

2.4.3 Sumación temporal

Puede sumarse entre sí no sólo descargas procedentes de terminales presinápticas separadas, sino también descargas rápidamente sucesivas de una misma terminal presináptica (Sinapsis). Cada potencial postsináptico simplemente se adicionan con lo que queda del anterior. Este efecto, denominado Sumación Temporal.

2.4.4 Facilitación de la neurona; excitación y facilitación

El potencial postsináptico causado por la descarga de una sola terminal presináptica casi siempre es muy bajo, casi nunca basta para provocar excitación de la neurona. Debe producirse sumación temporal, o ambas, para que la facilitación resulte suficientemente intensa para excitar la neurona.

Sin embargo, incluso valores inferiores al umbral de potencial postsináptico provocan que una neurona sea facilitada. Esto significa que la neurona puede excitarse mucho más fácilmente de lo que ocurría normalmente con descargas presinápticas adicionales. El grado de facilitación puede ser casi suficientemente intenso para causar excitación, en cuyo caso basta una sola descarga adicional de una terminal excitadora para poder causar un potencial de acción en la neurona. Por otra parte la neurona puede ser facilitada muy poco, en cuyo caso se necesitarán más descargas presinápticas para excitar la neurona.

En resumen, si el grado de potencial postsináptico sumado es mayor que el umbral para excitación de la neurona, se producirá un potencial de acción, pero si el grado de facilitación central es menor que el umbral de excitación, la neurona queda facilitada, pero no excitada [Guyton 1971].

2.5 Transmisor inhibitor

La naturaleza química exacta del transmisor inhibitor, como la del excitador, se desconoce. Se sabe que una sustancia denominada ácido gama aminoutírico (GABA) , que se halla presente en la corteza cerebral, inhibe la acción excitadora de las terminales presinápticas excitadoras en algunos animales inferiores. Por lo tanto se ha supuesto que esta sustancia podía ser la transmisor inhibitor. Otras sustancias que inhibirán las neuronas y que probablemente pueden actuar como transmisor inhibitor en algunas zonas del sistema nervioso es el aminoácido glicina (GLUCOLOLA) [Ham 1969].

2.5.1 Funciones inhibitoras de la sinapsis

Hay dos tipos diferentes de inhibición a nivel de la sinapsis: **inhibición postsináptica** e **inhibición presináptica**. La inhibición postsináptica depende de la secreción por algunas terminales presinápticas de un transmisor inhibitor en lugar de un transmisor excitador. Estas terminales derivan de tipos especiales de neuronas que sólo secretan en todas sus terminaciones transmisor inhibitor, en lugar de transmisor excitador.

El mecanismo de la inhibición postsináptica no es bien conocida pero se ha supuesto que el transmisor inhibitor aumenta la permeabilidad de la membrana neuronal para el potasio y los iones de cloruro, pero no a los iones de sodio.

Se ha supuesto que en realidad hay dos tipos diferentes de poros en la membrana neuronal, uno que tiene un calibre ligeramente menor de diámetro de 5 Å, suficiente para permitir el paso del sodio. Se ha admitido también que la mayor parte de estos poros están bloqueados por la presencia de cargas eléctricas en los conductores.

Además se cree que el transmisor inhibitor abre los poros menores, quizá suprimiendo cargas eléctricas, con lo cual permite que aumente mucho a la permeabilidad de la membrana para el potasio y los iones de cloruro. Por otra parte se cree que el transmisor excitador abre los poros mayores permitiendo el paso prácticamente todos los iones; y como hay un gradiente electroquímico mucho mayor que el desplazamiento de los iones de sodio a través de los poros que para cualquiera de los dos iones, el transmisor excitador origina primariamente un desplazamiento de iones de sodio, en contraste con el movimiento del potasio y del ion cloruro causado por el transmisor inhibitor [Ham 1969].

2.5.2 Acontecimientos eléctricos en la membrana durante la inhibición

Cuando la membrana se vuelve muy permeable a los dos (sodio y cloruro) los iones de potasio atraviesan rápidamente la membrana, porque hay un exceso de potasio dentro de la célula en comparación con el potencial eléctrico que este intentando retenerla en el interior. Por otra parte, los iones de cloruro no se desplazan o se desplazan muy poco, porque tales iones están distribuidos a través de la membrana en equilibrio exacto con el potencial electroquímico para el cloruro [Ham 1969].

2.5.3 Neuronas inhibitoras

Las terminales inhibitoras presinápticas provienen de tipos especiales de las neuronas denominadas neuronas inhibitoras, y todas las fibras terminales que se ramifican desde estas neuronas sólo secretan transmisor excitador (Análogamente, las neuronas excitadoras sólo secretan transmisor excitador) [Guyton 1971].

CAPITULO 3

MODELO MATEMATICO DE LA RED NEURONAL ARTIFICIAL

3.1 Elementos de una red neuronal artificial

Las redes neuronales artificiales son modelos que intentan reproducir el comportamiento del cerebro humano. Se pueden distinguir tres tipos de neuronas.

- 1) Aquellas que reciben estímulos externos, relacionadas con el aparato sensorial, que tomarán la información de entrada.
- 2) Las segunda llamadas neurona ocultas las que se ocupan del procesamiento de información.
- 3) Finalizado el período procesal, la información llega a las unidades de salida, cuya misión es dar respuesta al sistema..

Las neuronas artificiales pretenden mimetizar las características más importantes de las neuronas biológicas. Cada neurona i -ésima está caracterizada en cualquier instante por un valor numérico denominado **valor o estado de activación** $a_i(t)$; asociado a cada unidad, existe una **función de salida f_i** , que transforma el estado actual de activación en una señal de **salida y_i** . Dicha señal es enviada a través de los canales de comunicación unidireccionales a otras unidades de la red; en estos canales la señal se modifica de acuerdo con la sinapsis (el peso w_{ij}) asociado a cada uno de ellos según una determinada regla. Las señales modulares que han llegado a la unidad j -ésima se combinan entre ellas generando así la **entrada total, Net_j** .

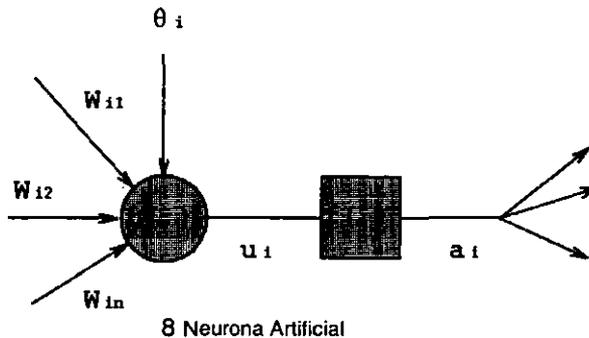
$$Net_j = \sum_i Y_i W_{ji}$$

Una función de activación F , determina el nuevo estado de activación $a_j(t+1)$ de la neurona, teniendo en cuenta total calculada y el anterior estado de activación $a_j(t)$.

3.2 Neurona artificial

Si se tiene N unidades (neuronas), podemos ordenarlas arbitrariamente y designar j -ésima unidad como U_j . Su trabajo es simple y único, y consiste en recibir las entradas de las células vecinas y calcular un valor de salida, el cual es enviado a todas las células restantes, como se muestra en la imagen inferior.

En cualquier sistema que se este modelando, es útil caracterizar tres tipos de unidades: entradas, salidas y ocultas. Las unidades de entradas reciben señales desde el entorno; estas entradas (que son a la vez de la red) pueden ser señales provenientes de sensores o de otro sectores del sistema. Las unidades de salida envían la señal fuera del sistema (salidas dela red) ; estas señales pueden controlar directamente potencias u otros sistemas. Las unidades ocultas son cuyas entradas y salidas se encuentran dentro del sistema; es decir no tiene contacto con el exterior [Hilera 1995].



Se conoce como capa o nivel a un conjunto de neuronas cuyas entradas provienen de las misma fuente (que puede ser otra capa de neuronas) y cuyas salidas se dirigen al mismo destino (que puede ser otra capa de neuronas).

3.3 Estado de activación

Adicionalmente a los conjuntos de unidades, la representación necesita los estados del sistema en un tiempo t . Esto se especifica por un vector de N números reales $A(t)$, que representa el estado de activación del conjunto de unidades de procesamiento. Cada elemento del vector representa la activación de una unidad de tiempo t . La activación de una unidad U_i en el tiempo t se designa por $a_i(t)$; es decir:

$$A(t) = (a_1(t), a_2(t), \dots, a_1(t), \dots, a_n(t))$$

El procesamiento que realiza la red se ve como la evolución de un patrón de activación en el conjunto de las unidades que lo componen a través del tiempo.

Todas las neuronas que componen las red se hallan en cierto estado. En una visión simplificada, podemos decir que hay dos posibles estados, reposo y excitado, a lo que denominaremos estados de activación, y a cada uno de los cuales se le asigna un valor.

Los valores de activación pueden ser continuos o discretos. Además, pueden ser limitados o ilimitados. Si son discretos, suelen tomar un conjunto pequeño de valores o

bien valores binarios. En notación binaria, un estado de activación se indica por un 1, y se caracteriza por la emisión de un impulso por parte de la neurona (potencial de acción), mientras que un estado pasivo se indica por un 0, y significa que la neurona está en reposo.

En otros modelos se consideran un conjunto continuo de estados de activación, en lugar de solo dos estados, en cuyo caso se le asigna un valor entre [0,1] o en el intervalo [-1,1], generalmente siguiendo una función sigmoideal [Hilera 1995].

3.4 Función de salida o de transferencia

Entre las unidades o neuronas que forma una red artificial existe un conjunto de conexiones que une unas con otras. Cada unidad transmite señales a aquellas que están conectadas con su salida. Asociada a cada unidad UI hay una función de salida $f_i(a_i(t))$, que transforma el estado actual de activación $a_i(t)$, en una señal de salida $y_i(t)$; es decir:

$$Y_i(t) = f_i(a_i(t))$$

Existen cuatro funciones de transferencia típicas que determinan distintos tipos de neuronas.

- ❖ Función escalón.
- ❖ Función lineal y mixta.
- ❖ Función Sigmoideal.
- ❖ Función gaussiana.

Para las redes neuronales de tipo binaria se utiliza el tipo de función de escalón o umbral. La salida de una neurona se activa sólo cuando el estado de activación es mayor o igual que cierto valor umbral. La función lineal o identidad equivale a no aplicar función de salida. Se usa muy poco. Las funciones mixta y sigmoideal son las más utilizadas cuando queremos como salidas de información analógica [Hilera 1995].

3.4.1 Neurona de función escalón

La forma más fácil de definir la activación de una neurona es considerada que ésta es binaria. La función de transferencia escalón se asocia a neuronas binarias en las cuales cuando la suma de las entradas es mayor o igual que el umbral de la neurona, la activación es 1; si es menor, la activación es 0 (o -1). Por otro lado, las redes formadas por este tipo de neuronas son fáciles de implementar en hardware, pero a menudo sus capacidades están limitadas [Rosenblatt 1958].

$$F(x) = \begin{cases} 1 & \text{si } x \geq 0 \\ 0 & \text{si } x < 0 \end{cases} \quad F(x) = \begin{cases} 1 & \text{si } x \geq 0 \\ -1 & \text{si } x < 0. \end{cases}$$

3.4.2 Neuronas de función lineal y mixta

La función lineal o identidad responde a la expresión $f(x)=x$. En las neuronas con la función mixta, si la suma de las señales de entrada es menor que un límite inferior, la activación se define como 0 (o -1). Si dicha suma es mayor o igual que el límite superior, entonces la activación es 1. Si la suma de entrada está comprendida entre ambos límites, superior e inferior, entonces la activación se define como una función lineal de la suma de las señales de entrada. Los siguientes ejemplos se toman como el límite superior y -c como el límite inferior

$$F(x) = \begin{cases} 0 & \text{si } x < -C \\ 1 & \text{si } x > C \\ X/(2C)+1/2 & \end{cases} \quad F(x) = \begin{cases} -1 & \text{si } x < -C \\ 1 & \text{si } x > C \\ a.x & \end{cases}$$

3.4.3 Neuronas de función continua (sigmoideal)

Cualquier función definida simplemente en un intervalo de posibles valores de entrada, con un incremento monotonico y que tenga ambos límites superiores e inferiores (por ejemplo, las funciones sigmoideal o arco tangente), podría realizar la función de activación o de transferencia de forma satisfactoria.

Con la función sigmoideal, para la mayoría de los valores del estímulo de entrada (variable independiente), el valor dado por la función es cercano a uno de los valores asintóticos.

Esto hace que en la mayoría de los casos, el valor de la salida esté comprendido en la zona alta o baja del sigmoide. De hecho, cuando la pendiente es elevada, esta función tiende a la función escalón. Sin embargo la importancia de la función sigmoideal (o cualquier otra función similar) es que su derivada es siempre positiva y cercana a cero para los valores grandes positivos o negativos.; además, toma su valor máximo cuando x es 0.

3.4.4 Función de transferencia gaussiana

Los centros y anchura de estas funciones pueden ser adaptados, lo cual hace más adaptativas que las funciones sigmoideales. Mapeos que suelen requerir dos niveles ocultos (neuronas en la red que se encuentran entre las de entrada y las de salida utilizando neuronas con funciones de transferencia sigmoideales; algunas veces se realizan con un solo nivel en redes con neuronas de función gaussiana.

3.5 Conexión entre neuronas

Las conexiones que unen a las neuronas que forman una RNA tienen asociado un peso, que es el que hace que la red adquiera conocimiento. Consideramos y_i como el valor de salida de una neurona i en un instante dado. Una neurona recibe un conjunto de señales que le dan la información del estado de activación de todas las neuronas con las que se encuentran conectadas. Cada conexión (sinapsis) entre la neurona i y la neurona j está ponderada por un peso W_{ij} . Normalmente como simplificación, se considera que el efecto de cada señal es aditivo, de tal forma que la entrada neta que recibe una neurona (potencial postsináptico) net_j es la suma del producto de cada señal individual por el valor de la sinapsis que conecta ambas neuronas:

$$Net_j = \sum_{i=1}^N W_{ji} \cdot Y_i$$

Esta regla muestra el procedimiento a seguir para combinar los valores de entrada a una unidad con los pesos de las conexiones que llegan a esa unidad y es conocida como **regla de propagación**.

Suele utilizarse una matriz W con todos los pesos W_{ij} que reflejan la influencia que sobre la neurona j tiene la neurona i . W es un conjunto de elementos positivos, negativos o nulos. Si W_{ji} es positivo, indica que la interacción entre las neuronas i y j es excitadora; es decir, siempre que la neurona i esté activada, la neurona j recibirá una señal de i que tenderá a activarla. Si W_{ji} es negativo, la sinapsis será inhibitoria. En este caso, si i está activada, enviará una señal a j que tendrá a desactivarla a ésta. Finalmente, si $W_{ij} = 0$, se supone que no hay conexión entre ambas.

3.6 Función o regla de activación

Así como es necesario una regla que combine las entradas a una neurona con los pesos de las conexiones, también se requiere una regla que combine las entradas con el estado actual de la neurona para producir un nuevo estado de activación. Esta función F produce un nuevo estado de activación en una neurona a partir del estado (a_i) que existía y la combinación de las entradas con los pesos de las conexiones (net_i).

Dado el estado de activación $a_i(t)$ de la unidad u_i , y la entrada total que llega a ella, Net_i , el estado de activación siguiente $a_i(t+1)$, se obtiene aplicando una función F , llamada **función de activación**.

$$a_i(t+1) = F(a_i(t), Net_i)$$

Por lo tanto, consideramos únicamente la función f , que denominaremos indistintamente de transferencia o de activación. Además, normalmente la función de activación no está centrada en el origen del eje que representa el valor de la entrada neta, sino que existe

cierto desplazamiento debido a las características internas de la propia neurona y que no es igual en todas las neuronas. Este valor se denota como 0_i y representa el umbral de activación de la neurona i

$$Y_i(t+1) = f(\text{Net}_i - 0_i) = f\left(\sum_{j=1}^N W_{ij} y_j(t) - 0_i\right)$$

Como el estado de transferencia, la función de activación cuenta con diferentes tipos que son:

- ❖ Función de activación escalón.
- ❖ Función de activación lineal o de identidad.
- ❖ Función de activación lineal-mixta.
- ❖ Función de activación sigmoideal.

3.6.1 Función de activación escalón

Si el conjunto de los estados de activación es $E=[0,1]$, tenemos que:

$$Y_i(t+1) = \begin{cases} 1 & \text{si } [\text{Net}_i > - 0_i] \\ y(t) & \text{si } \text{Net}_i = - 0_i \\ 0 & \text{si } [\text{Net}_i < - 0_i] \end{cases}$$

Si el conjunto es $E=\{-1,1\}$, tenemos que:

$$Y_i(t+1) = \begin{cases} +1 & \text{si } [\text{Net}_i > - 0_i] \\ y(t) & \text{si } \text{Net}_i = - 0_i \\ -1 & \text{si } [\text{Net}_i < - 0_i] \end{cases}$$

3.6.2 Función de activación lineal o identidad

El conjunto de estados E puede contener cualquier número real; el estado de activación coincide con la entrada total que ha llegado a la unidad.

$$y_i(t+1) = \text{Net}_i - 0_i$$

3.6.3 Función de activación lineal-mixta

$$Y_i(t+1) = \begin{cases} b & \text{Net}_i \leq b + 0_i \\ \text{Net}_i - 0_i & b + 0_i < \text{Net}_i < B + 0_i \\ B & \text{Net}_i \geq B \end{cases}$$

Con esta función, el estado de activación de la unidad está obligada a permanecer dentro de un intervalo de valores reales prefijados.

3.6.4 Función de activación sigmoideal

Es una función continua, por tanto el espacio de los estados de activación es un intervalo del eje real.

$$y_i(t+1) = \frac{1}{1 + e^{-(\text{net}_i - 0_i)}}$$

Para simplificar la expresión de la salida de una neurona i, es habitual considerar la existencia de una neurona ficticia, con valor de salida unidad, asociada a la entrada de cada neurona i mediante una conexión con peso de valor -0i. De esta forma la expresión de salida quedará:

$$y_i(t+1) = f\left(\sum_{j=1}^N W_{ij} y_j(t) - 0_i \cdot 1\right) = f\left(\sum_{j=0}^N W_{ij} y_j(t)\right) = f(\text{Net}_i)$$

3.7 Representación vectorial

En ciertos modelos de redes neuronales, se utiliza la forma vectorial como herramienta de representación de algunas magnitudes. Si consideramos una red formada por varias capas de neuronas idénticas, podemos considerar las salidas de cierta capa de n unidades como un vector n -dimensional $Y=(y_1,y_2,\dots,y_n)$. Si este vector n -dimensional de salida representa los valores de entrada de todas las unidades de una capa m -dimensional, cada una de las unidades de esta capa poseerá n pesos asociada a las conexiones procedentes de la capa anterior. Por tanto, hay m vectores de pesos n -dimensional asociados a la capa m .

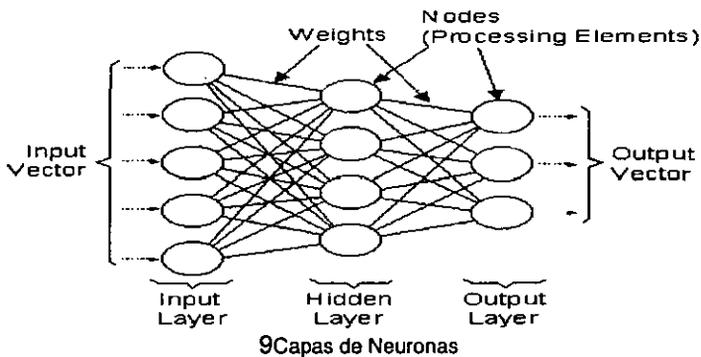
El vector de pesos de la j -ésima unidad tendrá la forma $Y=(y_{j1},y_{j2},\dots,y_{jn})$

La entrada neta de la j -ésima unidad se puede escribir en forma de producto escalar del vector de entradas por el vector de los pesos, Cuando los vectores tienen igual dimensión, este producto se define como la suma de los productos de los componentes correspondientes a ambos vectores. En donde n representa en número de conexiones de la j -ésima unidad. La ventaja de la notación vectorial, es que la anterior ecuación se puede escribir de la forma:

$$Net_j = \sum_i^n W_{ji} \cdot Y_i$$

3.8 Niveles o capas de neuronas

La distribución de neuronas dentro de la red se realizara formando niveles o capas de un número determinado de neuronas de cada una. A partir de su situación dentro de la red, se pueden distinguir tres tipos de capas:



-De entrada: Es la capa que recibe directamente la información proveniente de las fuentes externas de la red.

-Ocultas: Son internas a la red y no tienen contacto directo con el entorno exterior. El número de niveles ocultos puede estar entre cero y un número elevado, las distintas tipologías de redes neuronales.

-De salida: Transfieren la información de la red hacia el exterior.

3.9 Formas de conexión entre neuronas

La conectividad entre los nodos de una red neuronal está relacionada con la forma en que las salidas de las neuronas están canalizadas para convertirse en entradas de otras neuronas. La señal de la salida de un nodo puede ser una entrada de otro elemento de proceso, o incluso ser una entrada de sí mismo (conexión auto concurrente).

Cuando ninguna salida de las neuronas es entrada de neuronas del mismo nivel o de niveles precedentes, la red se describe como la **propagación hacia adelante**. Cuando las salidas pueden ser conectadas como entradas de neuronas de niveles previos o del mismo nivel, incluyéndose ellas mismas, la red es de **propagación hacia atrás**. Las redes de propagación hacia atrás que tienen lazos cerrados son sistemas recurrentes.

3.10 Topología de las redes neuronales

Como se adelantó en el apartado anterior, la topología o arquitectura de las redes neuronales consiste en la organización y disposición de las neuronas en la red formando capas o agrupaciones de neuronas más o menos alejadas de la entrada y la salida de la red. En este sentido, los parámetros fundamentales de la red son: el número de capas, el número de neuronas por capa, el grado de conectividad y el tipo de conexiones entre neuronas.

3.10.1 Redes monocapa (1 capa)

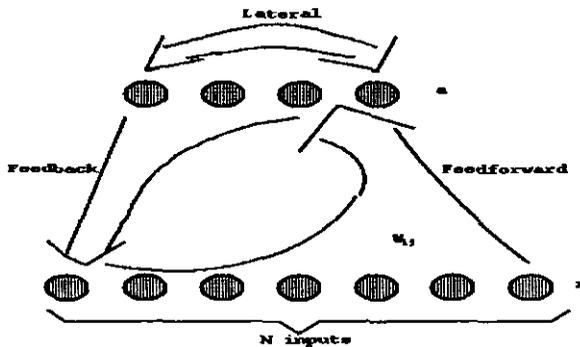
En este tipo de redes se establecen conexiones laterales entre las neuronas que pertenecen a la única capa que constituye la red. También pueden existir conexiones autorrecurrentes (salida de una neurona conectada a su propia entrada) también se indica que este tipo de redes monocapa se utilizan típicamente en tareas relacionadas con lo que se conoce como autoasociación; por ejemplo, para regenerar informaciones de entrada que se presentan a la red incompletas o distorsionadas.

3.10.2 Redes multicapa

Las redes multicapa son aquellas que disponen de conjunto de neuronas agrupadas en varios(2,3 etc.) niveles o capas. En estos casos, una forma para distinguir la capa a la que pertenece una neurona, consistirá en fijarse en el origen de las señales que recibe la entrada y el destino de la señal de salida. Normalmente, todas las neuronas de una capa reciben señales de entrada de otra capa anterior, más cercana a las entradas de la red, y envían las señales de salida a una capa posterior, más cercana a la salida de la red. A estas conexiones se les denomina conexiones adelante **feedforward**.

Sin embargo, en un gran número de estas redes también existe la posibilidad de conectar las salidas de las neuronas de capas posteriores a las entradas de las capas anteriores, a estas conexiones se les denomina conexiones hacia atrás o **feedback**.

Estas dos posibilidades permiten distinguir entre dos tipos de redes como múltiples capas: las redes con conexiones hacia adelante o redes feedforward, y las redes que disponen de conexiones tanto hacia adelante como hacia atrás o redes **feedforward/feedback** como se muestra en la imagen inferior.



10 Redes feedforward/feedback

3.11 Mecanismos de aprendizaje

Existen muchas definiciones del concepto general de aprendizaje, una de ellas podría ser: La modificación del comportamiento inducido por la interacción con el entorno y como resultado de experiencias conducente al establecimiento de nuevos modelos de respuesta a estímulos externos. Esta definición fue enunciada muchos años antes de que surgieran las redes neuronales, sin embargo puede ser aplicada también a los procesos de aprendizaje de estos sistemas.

Biológicamente como anteriormente se comentó, se suele aceptar que la información memorizada en el cerebro está más relacionada con los valores sinápticos de las conexiones entre las neuronas que con ellas mismas; es decir, el conocimiento se

encuentra en las sinapsis. En el caso de las redes neuronales artificiales, se puede considerar que el conocimiento se encuentra representado en los pesos de las conexiones entre neuronas. Todo proceso de aprendizaje implica cierto número de cambios en estas conexiones. En realidad, puede decirse que se aprende modificando los valores de los pesos de la red.

Al igual que el funcionamiento de una red depende del número de neuronas de las que disponga y de cómo estén conectadas entre sí, cada modelo dispone de su o sus propias técnicas de aprendizaje. Se realizara un estudio más completo de las distintas reglas de aprendizaje en el siguiente capítulo, al igual que nos referimos a ellas cuando se realice un estudio detallado de los tipos de redes neuronales más importantes.

El aprendizaje es el proceso por el cual una red neuronal modifica sus pesos en respuesta a una información de entrada. Los cambios que se producen durante el proceso de aprendizaje se reducen a la destrucción, modificación y creación de conexiones entre neuronas. En los sistemas biológicos existe una continua creación y destrucción de conexiones. En los modelos de redes neuronales artificiales, la creación de una nueva conexión implica que el peso de la misma pasa a tener un valor distinto de cero. De la misma forma, una conexión se destruye cuando su peso pasa a ser cero.

Durante el proceso de aprendizaje, los pesos de las conexiones de la red sufren modificaciones, por tanto se puede afirmar que este proceso ha terminado (la red ha aprendido) cuando los valores de los pesos permanecen estables ($dw_{ij}/dt=0$).

Un aspecto importante respecto al aprendizaje en las redes neuronales es el conocer cómo se modifican los valores de los pesos; es decir, cuales son los criterios que se siguen para cambiar el valor asignado a las conexiones cuando se pretende que la red aprenda una nueva información.

Estos criterios determinan lo que se conoce como la regla de aprendizaje de la red. De forma general, se suelen considerar dos tipos de reglas: las que responden a lo que habitualmente se conoce como aprendizaje supervisado, y las correspondientes a un aprendizaje no supervisado.

Es por ello por lo que una de las clasificaciones que se realizan de las redes neuronales obedecen al tipo de aprendizaje utilizado por dichas redes, Así se pueden distinguir:

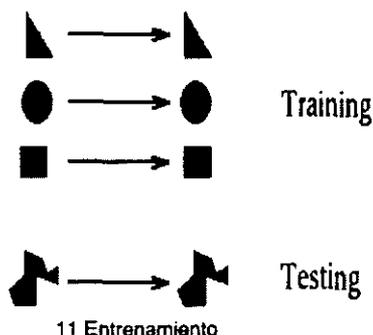
- ❖ Redes neuronales con aprendizaje supervisado.
- ❖ Redes neuronales con aprendizaje no supervisado.

La diferencia fundamental entre ambos tipos estriba en la existencia o no de un agente externo (supervisado) que controle el proceso de aprendizaje de la red.

Otro criterio que se puede utilizar para diferenciar las reglas de aprendizaje se basa en considerar si la red puede aprender durante su funcionamiento habitual o si el aprendizaje

supone la desconexión de la red; es decir su inhabilitación hasta que el proceso termine. Es el primer caso, se trataría de un aprendizaje **ON LINE**, mientras que el segundo es lo que se conoce como aprendizaje **OFF LINE**.

Cuando el aprendizaje es **OFF LINE**, se distingue entre una fase de aprendizaje o entrenamiento y una fase de operación o funcionamiento, existiendo un conjunto de datos de entrenamiento y un conjunto de datos de test o prueba que serán utilizados en la correspondiente fase. En las redes con aprendizaje **OFF LINE**, los pesos de las conexiones permanecen fijos después que termina la etapa de entrenamiento de la red. Debido precisamente a su carácter estático, estos sistemas no presentan problemas de estabilidad en su funcionamiento (véase imagen inferior).



En las redes con aprendizaje **OFF LINE** no se distingue entre fases de entrenamiento y de operación, de tal forma que los pesos varían dinámicamente siempre que se presente una nueva información al sistema. En este tipo de redes, debido al carácter dinámico de las mismas, el estudio de la estabilidad suele ser un aspecto fundamental de estudio.

3.11.1 Redes con aprendizaje supervisado

El aprendizaje supervisado se caracteriza porque el proceso de aprendizaje se realiza mediante un entrenamiento controlado por un agente externo (supervisor, maestro) que determina la respuesta que debería generar la red a partir de una entrada determinada.

El supervisor comprueba la salida de la red y en caso de que esta no coincida con la deseada, se procederá a modificar los pesos de las conexiones, con el fin de conseguir que la salida obtenida se aproxime a la deseada.

En este tipo de aprendizaje se suelen considerar, a su vez, tres formas de llevarlo a cabo que dan lugar a los siguientes aprendizajes supervisados:

- ❖ Aprendizaje por corrección de error.
- ❖ Aprendizaje por refuerzo.
- ❖ Aprendizaje estocástico

3.11.1.1 Aprendizaje por corrección de error

Consiste en ajustar los pesos de las conexiones de la red en función de la diferencia entre los valores deseados y los obtenidos en la salida de la red; es decir, en función del error cometido en la salida.

Una regla o algoritmo simple de aprendizaje por corrección de error podría ser el siguiente:

$$\Delta W_{ji} = \alpha y_i (d_j - y_j)$$

Siendo

ΔW_{ji} : Variación en el peso de la conexión entre las neuronas i y j
 ($\Delta W_{ji} = w_{ji}$ j actual - w_{ji} anterior).

y_i : Valor de salida de neurona i .

d_j : Valor de salida deseado por la neurona j .

y_j : Valor de salida obtenido en la neurona j .

α : Factor de aprendizaje ($0 < \alpha \leq 1$) que regula la velocidad del aprendizaje.

Sin embargo, existen otros algoritmos más evolucionados que éste presentado anteriormente (corrección de error), que presenta algunas limitaciones, como el no considerar la magnitud del error global cometido durante el proceso completo de aprendizaje de la red, considerando únicamente los errores individuales (locales) correspondientes al aprendizaje de cada información por separado.

Un algoritmo muy conocido que mejora el del perceptrón (primera red neuronal que utiliza el algoritmo de corrección de error) y permite un aprendizaje más rápido y un campo de aplicación más amplio es el propuesto por Windrow Y Hoff en 1960 [Windrow 60], denominado regla delta del mínimo error cuadrado (LMS error: Least-Mean-Squared Error), también conocida como regla de Windrow-Hoff, que se aplicó en las redes desarrolladas por los mismos autores conocidas como ADALINE y MADALINE [Hopfield 82].

Windrow y Hoff definieron una función que permitía cuantificar el error global cometido en cualquier momento durante el proceso de entrenamiento de la red, la cual es importante, ya que cuanto más información se tenga sobre el error cometido, más rápido se puede aprender.

Este error medio se expresa de la siguiente forma:

$$\text{Error global} = \frac{1}{2P} \left(\sum_{k=1}^P \sum_{j=1}^N y_j - d_j \right)^2$$

Siendo:

N: Número de neuronas de salida (en el caso de la ADALINE N=1)

P: Número de informaciones que debe aprender la red.

$$\frac{1}{2P} \sum_{j=1}^N (y_j - d_j)^2$$

Error cometido en el aprendizaje de la información k-esima.

Por lo tanto, de lo que se trata es de encontrar unos pesos para las conexiones de la red que minimicen esta función. Para ello, el ajuste de los pesos de las conexiones de la red se puede hacer de la forma proporcional a la variación relativa del error que se obtiene al variar el peso correspondiente:

$$\frac{\Delta W_{ji}}{W_{ji}} = k \frac{\partial \text{Error}_{\text{global}}}{\partial W_{ji}}$$

Mediante este procedimiento, se llegan a obtener un conjunto de pesos con los que consigue minimizar el error medio.

3.11.1.2 Aprendizaje por refuerzo

Se trata de un aprendizaje supervisado, más lento que el anterior, que se basa en la idea de no disponer de un ejemplo completo del comportamiento deseado; es decir, de no indicar durante el entrenamiento exactamente la salida que se desea que proporcione la red ante una determinada entrada.

En el aprendizaje por refuerzo la función del supervisor se reduce a indicar mediante una señal de refuerzo si la salida obtenida en la red se ajusta a la deseada (éxito=+1 o fracaso=-1), y en función de ello se ajustan los pesos basándose en un mecanismo de probabilidades. Se podrá decir que en este tipo de aprendizaje la función del supervisor se asemeja más a la de un crítico (que opina sobre la respuesta de la red) que a la de un maestro (que indica a la red la respuesta concreta que debe generar), como ocurría en el caso de supervisión por corrección de error.

3.11.1.3 Aprendizaje estocástico

Este tipo de aprendizaje consiste básicamente en realizar cambios aleatorios en los valores de los pesos de las conexiones de la red y evaluar su efecto a partir del objetivo deseado y de distribuciones de probabilidad.

3.11.2 Redes con aprendizaje no supervisado

Las redes con aprendizaje no supervisado (también conocido como auto supervisado) no requieren influencia externa para ajustar los pesos de las conexiones entre sus neuronas. La red no recibe ninguna información por parte del entorno que le indique si la salida generada en respuesta a una determinada entrada es o no correcta; por ello, suele decirse que estas redes son capaces de auto organizarse.

Estas redes deben encontrar las características, regularidades, correlaciones o categorías que se pueden establecer entre los datos que se presenten en una entrada. Puesto que nos hay un supervisor que indique a la red la respuesta que debe generar ante una entrada concreta, cabría preguntarse precisamente por lo que la red genera en estos casos. Existen varias posibilidades en cuanto a la interpretación de la salida de estas redes, que dependen de su estructura y del algoritmo de aprendizaje empleado.

En algunos casos, la salida representa el grado de familiaridad o similitud entre la información que se le esta presentando en la entrada y las informaciones que se le han mostrado hasta entonces (en el pasado). En otro caso, podría realizar una clusterización (clustering) o establecimiento de categorías, indicando la red a la salida a qué categoría pertenece la información presentada a la entrada, siendo la propia red quien debe encontrar las categorías apropiadas a partir de correlaciones entre las informaciones presentadas. Una variación de esta categorización es el prototipado. En este caso, la red obtiene ejemplares o prototipos representantes de las clases a las que pertenecen las informaciones de entrada.

También el aprendizaje sin supervisión permite realizar una codificación de los datos de entrada, generando a la salida una versión codificada de la entrada, con menos bits, pero *manteniendo la información relevante de los datos*.

Finalmente, algunas redes con aprendizaje no supervisado lo que realizan es un mapeo de características (feature mapping), obteniéndose en las neuronas de salida una disposición geométrica que representa un mapa topográfico de las características de los datos de entrada, de tal forma que si presentan a la red informaciones similares, siempre sean afectadas neuronas de salida próximas entre sí, en la misma zona del mapa.

En cuanto a los algoritmos de aprendizaje no supervisado, en general se suelen considerar dos tipos que dan lugar a los siguientes aprendizajes:

- ◆ **Aprendizaje hebbiano**
- ◆ **Aprendizaje competitivo y cooperativo.**

En el primer caso, normalmente se pretende medir la familiaridad o extraer características de los datos de entrada, mientras que el segundo suele orientarse hacia la clusterización o clasificación de dichos datos.

3.11.2.1 Aprendizaje hebbiano

Este tipo de aprendizajes se basa en el siguiente postulado formulado por Donald O. Hebb en 1949[Hebb 49]: Cuando un axon de una celda A está suficientemente cerca como para conseguir excitar una celda B y repetida o persistentemente toma parte en su activación, algún proceso de crecimiento o cambio metabólico tiene lugar en una o ambas celdas, de tal forma que la eficiencia de A, cuando la celda a activar es B, aumenta. Por celda, Hebb entiende un conjunto de neuronas fuertemente conexas a través de una estructura compleja. La eficiencia podría identificarse con la intensidad o magnitud de la conexión; es decir, con el peso.

Se puede decir, por tanto, que el aprendizaje hebbiano consiste básicamente en el ajuste de los pesos de las conexiones de acuerdo con la correlación (multiplicación en el caso de valores +1 y -1) de los valores de activación (salidas) de las dos neuronas conectadas:

$$\Delta W_{ji} = y_i \cdot y_j$$

Esta expresión responsable a la idea de Hebb, puesto que si las dos unidades son activas (positivas), se produce un reforzamiento de la conexión. Por el contrario, cuando una es activada y la otra pasiva (negativa), se produce un debilitamiento de la conexión. Se trata de una regla de aprendizaje no supervisado, pues la modificación de los pesos se realiza en función de los estados (salidas) de las neuronas obtenidos tras la presentación de cierto estímulo (información de entrada de la red), sin tener en cuenta si se desea obtener o no esos estados de activación

3.11.2.2 Aprendizaje competitivo cooperativo

En las redes con aprendizaje competitivo (y cooperativo), suele decirse que las neuronas compiten (y cooperan) unas con otras con el fin de llevar a cabo una tarea dada. Con este tipo de aprendizaje, se pretende que cuando se presente a la red cierta información de entrada, solo una de las neuronas de salida de la red, o una por cierto grupo, como neuronas compiten por activarse, quedando finalmente una, o una por grupo, como una neurona vencedora (winner-take-all unit) quedando anuladas el resto, que son forzadas a sus valores de respuesta mínimos.

La competición entre neuronas se realiza en todas las capas de la red existiendo en estas neuronas conexiones recurrentes de auto excitación y conexiones de inhibición (signo negativo) por parte de neuronas vecinas. Si el aprendizaje es cooperativo, estas conexiones con las vecinas serán de excitación (signo positivo).

El objetivo de este aprendizaje es categorizar (clusterizar) los datos que se introducen en la red. De esta forma, las informaciones similares son clasificadas formando parte de la misma categoría, y por tanto debe de activar la misma neurona de salida. La clase o categorías deben ser creadas por la propia red, puesto que se trata de un aprendizaje no supervisado, a través de las correlaciones entre los datos de entrada

En este tipo de redes, cada neurona tiene asignado un peso total, suma de todos los pesos de las conexiones que tiene a su entrada. El aprendizaje afecta sólo a las neuronas ganadoras (activas), redistribuyendo este peso total entre sus conexiones, sustrayendo una porción a los pesos de todas las conexiones que llegan a la neurona vencedora y repartiendo esta cantidad por igual entre todas las conexiones procedentes de unidades activas. Por tanto la variación del peso de una conexión entre la neurona *i* y otra *j* será nula si la neurona *j* no recibe excitación por parte de la neurona *i* (no vence en presencia de un estímulo por parte de *i*), y se modificara (se reforzara) si es excitada por dicha neurona *i*.

3.12 Tipo de asociaciones entre las informaciones de entrada y salida

Las redes neuronales son sistemas que almacenan cierta información aprendida; esta información se registra de forma distribuida en los pesos asociados a las conexiones entre neuronas. Por tanto, puede imaginarse una red. Como cierto tipo de memoria que almacena unos datos de forma estable, datos que se grabaran en dicha memoria como consecuencia del aprendizaje de la red y que podrán ser leídos a la salida como respuesta a cierta información de entrada, comportándose entonces la red como lo que habitualmente se conoce por memoria asociativa; es decir, cuando se aplica un estímulo(datos de entrada) la red responde con una salida asociada a dicha información de entrada.

Existen dos formas de realizar esta asociación entre entradas/salidas que se corresponden con la naturaleza de la información almacenada en la red. Una primera sería la denominada heteroasociación, que se refiere al caso en el que la red aprende

parejas de datos [(A1,B1)], [(A2,B2)]..... [(AN,BN)], de tal forma que cuando se presente cierta información de entrada A1 , deberá responder generando la correspondiente salida asociada Bi La segunda se conoce como autoasociación, donde la red aprende ciertas informaciones A1,A2....AN, de tal forma que cuando se le presenta una información de entrada realizara una auto correlación, respondiendo con uno de los datos almacenados, el más parecido al de la entrada.

Estos dos mecanismos de asociación dan lugar a dos tipos de redes neuronales: las redes heteroasociativas y las autoasociativas. Una red heteroasociativa podría considerarse aquella que computa cierta función, que en la mayoría de los casos no podría expresarse analíticamente, entre un conjunto de entradas y un conjunto de salidas, correspondiendo a cada posible entrada una determinada salida, correspondiendo a cada posible entrada una determinada salida. Por otra parte, una red autoasociativa es una red cuya principal misión es reconstruir una determinada información de entrada que se presenta incompleta o distorsionada (le asocia los datos almacenado más parecido).

En realidad, estos dos tipos de modelos de redes no son diferentes es principio, porque una red heteroasociativa puede siempre ser reducida a una autoasociación mediante la concatenación de una información de entrada de la red auto asociativa equivalente.

3.12.1 Redes heteroasociativas

Las redes heteroasociativas, al asociar informaciones de entrada con diferentes informaciones de salida, precisan al menos de 2 capas, una para captar y retener la información de entrada y otra para mantener la salida con la información asociada. Si esto no fuese así se perdería la información inicial al obtenerse el dato asociado, lo cual no debe ocurrir, ya que en el proceso de obtención de la salida se puede necesitar acceder varias veces a esta información, que, por tanto, deberá permanecer en la capa de entrada.

3.12.2 Redes auto asociativas

Una red autoasociativa asocia una información de entrada con el ejemplar más parecido de los almacenados conocidos por la red. Este tipo de redes pueden implementarse con una sola capa de neuronas. Esta capa comenzará reteniendo la información inicial presentada a la entrada, y terminara representando la información autoasociativa. Si se quiere mantener la información de entrada y salida, se deberán añadir capas adicionales; sin embargo, la funcionalidad de la red puede conseguirse en una sola capa.

3.13 Representación de la información de entrada y salida

Las redes neuronales pueden también clasificarse en función de la forma en que se representan las informaciones de entrada y respuestas o datos de salida. Así en un gran número de redes, tanto los datos de entrada como la salida son de naturaleza analógica; es decir, son valores reales continuos, normalmente estarán normalizados y su valor absoluto será menor que la unidad. Cuando esto ocurre, las funciones de activación de las neuronas serán también continuas, del tipo lineal o sigmoidea.

3.14 Tipos de redes neuronales

Estas son las características más importantes de cada una de las redes neuronales artificiales:

- ❖ Topología
- ❖ Mecanismo de aprendizaje
- ❖ Tipo de asociación de las informaciones de entrada y salida y la forma de representación de esta información.
- ❖ Señales de entrada / salida
- ❖ Auto(es)

La siguiente imagen nos ilustra las principales redes neuronales artificiales:

MODELO DE RED	TOPOLOGÍA	APRENDIZAJE			ASOCIACION AUTOMETERO	INFORMAC DE ENTRADA Y SALIDA	AUTORES
		ON/OFF F LINE	SUPERVISA/ NO SUPERVISA	REGLA			
PERCEPTRON	2 Capas feedforward	OFF	SUPERVISADO	CORREC-ERROR	HETEROA	E: ANALOGO S: BINARIO	ROSENBLAT 1958
CONTINUOUS HOPFIELD	1 CAPA CONEX LATERALES	OFF	NO SUPERVI.	HEBBIANO	AUTOAS.	ANALOGO	HOPFIELD 1984
COUNTER-PROPAGATION	3 CAPAS FEEDFORWARD CONEX LATERALES Y AUTORECURRENTES	OFF	SUPERVISADO	CORREC. ERROR + COMPETITIVO	HETEROA	ANALOG.	HETCH-NIELSEN 1987
FUZZY ASSOCIATE MEMORY	2 CAPAS FF/FEEDBACK	OFF	NO SUPERVISADO	HEBBIANO BORROSO	HETERO	ANALOGO	KOSKO 1987

.FAM							
LEARN. MATRIX. LM	1 CAPA CROSSBAR	OFF	NO SUPERVISAD O	HEBBIANO	HETERO	BINARIAS	STEINBUSH 1961

12 Principales redes neuronales artificiales

CAPITULO 4

APLICACIÓN DE UNA RED NEURONAL ARTIFICIAL ENFOCADA AL DIAGNOSTICO DE ENFERMEDADES CARDIO VASCULARES (ANGINA DE PECHO Y ROTULA VENTRICULAR AGUDA)

4.1 Introducción a la aplicación

Realización de un sistema de software basado en una red neuronal artificial, la cual pueda resolver el problema de identificación de enfermedades, la cual nos llevara a la conclusión que las RNA pueden implementarse y aplicarse a problemas complejos como el presentado.

Para identificar una enfermedad, los médicos realizan un diagnostico de una enfermedad tomando en cuenta los padecimientos que se presenten en cada paciente.

La complejidad en este tipo de problema reside que, no siempre es necesario que se presenten todos los padecimientos para que exista dicha enfermedad.

El modelo de red neuronal artificial adecuado para este tipo de problema es el de Hopfield, ya que su funcionamiento se basa en la auto asociación de la información.

Por medio de esta red podrá identificarse enfermedades aun cuando no se hallan presentado todos los padecimientos.

Las características mas importantes de la red Hopfield se presentan a continuación:

- 1) Conexiones laterales.
- 1) Aprendizaje off-line.
- 2) Aprendizaje no supervisado.
- 3) Aprendizaje hebbiano.
- 4) Autoasociación de la información.
- 5) La información de entrada es de tipo binario

El aprendizaje OFF-LINE es necesario la desconexión de la red, es decir su inhabilitación hasta que el proceso de aprendizaje termine.

Al no requerir de influencia externa para ajustar los pesos de las neuronas se cataloga como no-supervisada, ya que no requiere de influencia externa para ajustar los pesos de las conexiones entre sus neuronas [Hopfield 1982].

Al ser hebbiano su aprendizaje, se basa en la multiplicación de las salidas de cada neurona que se encuentran conectadas entre si en la fase de aprendizaje.

Se considera al sistema nervioso como una red muy grande y compleja, esta red recibe entradas desde un gran numero de receptores (tacto, presión, calor, frío, luz, sonido,

cambio químico, cambio de presión, etc.) que transformaran los estímulos procedentes del cuerpo mismo o del mundo exterior en impulsos eléctricos que proporcionan información a esta red [Hopfield 1982].

Para fines de esta red se tomar en cuenta tres elementos entrada, proceso y salida.

Una neurona se activa sólo si los pesos totales de la sinapsis que reciben impulsos durante el período de sumación latente es superior al valor del umbral.

4.2 Características y funcionamiento de la red neuronal artificial

- El modelo hopfield consiste en una red mono capa con N neuronas cuyos valores de salida son binarios: 0/1 ó -1/1.
- Cada neurona de la red se encuentra conectada a todas las demás (conexiones laterales), pero no consigo mismo (no existen conexiones autorrecurrentes). Además los pesos asociados a las conexiones entre pares de neuronas son simétricos. Esto significa que el peso de la conexión de una neurona i con la neurona j es de igual valor que la conexión de la neurona j con la i ($w_{ij}=w_{ji}$)
- Por lo tanto la función de activación de cada neurona (i) de la red ($f(x)$) es de tipo escalón.

$$\bullet \quad F(x) = \begin{array}{ll} +1 & x > 0_i \\ -1 & x < 0_i \end{array}$$

- Cuando el valor de x coincide exactamente con 0_i ,la salida de la neurona i permanece con su valor anterior. 0_i es el umbral de disparo de la neurona i.
- Es una red auto asociativa, cuando varias informaciones (patrones) diferentes pueden ser almacenadas en la red, como si de una memoria se tratase, durante la etapa de aprendizaje.
- Posteriormente, si se presenta a la entrada alguna de las informaciones almacenadas, la red evoluciona hasta estabilizarse, ofreciendo entonces en la salida la información almacenada, que coincide con la presentada en la entrada. Si por lo contrario, la información de entrada no coincide con ninguna de las almacenadas, por estar distorsionada o incompleta, la red evoluciona generando como salida la más parecida.
- La información que recibe esta red debe haber sido previamente codificada y representada en forma de vectores (como una configuración binaria si la red es discreta, y como conjunto de valores reales si es continua)

- Esta información es aplicada directamente a la única capa de que consta la red, siendo recibida por las neuronas de dicha capa (cada neurona recibe una parte de la información, un elemento del vector que representa dicha información)
- La suma de todos estos valores constituirá el valor de entrada neta de la neurona al que será aplicada la función de transferencia, obteniéndose el valor de salida correspondiente, $-1/+1$.
- En el instante inicial ($t=0$) se aplica la información de entrada (valores e_1, e_2, \dots, e_n). Inicialmente, la salida de las neuronas coincide con la información aplicada a la entrada.

$$S_i(t=0) = e_i \quad 1 \leq i \leq N$$

- La red realiza iteraciones hasta alcanzar la convergencia (hasta que $s_i(t+1)$ sea igual a $s_i(t)$)

$$S_i(t+1) = f\left(\sum_{j=1}^N W_{ij} s_j(t) - \theta_i\right) \quad 1 \leq i \leq N$$

- Donde f es la función de transferencia (activación) de las neuronas de la red. En el caso del modelo discreto, si se trabaja con los valores binarios -1 y $+1$, la salida se obtendrá según la función escalón:

$$S_i(t+1) = \begin{cases} +1 & \sum_{j=1}^N W_{ij} s_j(t) > \theta_i \\ S_i & \sum_{j=1}^N W_{ij} s_j(t) = \theta_i \\ -1 & \sum_{j=1}^N W_{ij} s_j(t) < \theta_i \end{cases}$$

- El proceso se repite hasta que las salidas de las neuronas permanecen sin cambios durante algunas iteraciones. En ese instante, la salida (s_1, s_2, \dots, s_n) representa la información almacenada por la red que más se parece a la información presentada en la entrada (e_1, e_2, \dots, e_n).

- El algoritmo de aprendizaje puede expresarse de la siguiente forma:

$$W_{ij} = \begin{cases} \sum_{K=1}^M e_i^{(k)} e_j^{(k)} & 1 \leq i, j \leq N; i \neq j \\ 0 & 1 \leq i, j \leq N; i = j \end{cases}$$

Siendo

W_{ij}: Peso asociado a la conexión entre la neurona j y la neurona i, que coincide con W_{ji}.

e_i: Valor de la componente i-ésima del vector correspondiente a la información k-ésima que debe aprender la red.

N: Número de neuronas de la red, y por tanto, tamaño de los vectores de aprendizaje.

M: Número de informaciones que debe aprender la red.

- El algoritmo de aprendizaje también se suele expresar utilizando una notación matricial. En tal caso podría considerarse una matriz W de dimensiones N*N que representase todos los pesos de la red:

$$W = \begin{bmatrix} W_{11} & W_{21} & W_{31} & \dots & W_{N1} \\ W_{12} & W_{22} & W_{32} & \dots & W_{N2} \\ W_{1N} & W_{2N} & W_{3N} & \dots & W_{NN} \end{bmatrix}$$

- Esta matriz es simétrica, al cumplirse que $w_{ij} = w_{ji}$, y tiene una diagonal principal con valores nulos debido a la no-existencia de conexiones autorrecurrentes ($w_{ij} = 0$).
- También se tendría el conjunto de los M vectores que representan las informaciones que ha de aprender la red.

$$E_1 = [e_1, e_2, \dots, e_n]$$

$$E_2 = [e_1, e_2, \dots, e_n]$$

$$E_M = [e_1, e_2, \dots, e_n]$$

- Utilizando esta notación, el aprendizaje consistiría en la creación de la matriz de pesos W a partir de los M vectores o informaciones de entrada (E₁, ..., E_M) que se enseñan a la red. Matemáticamente se expresaría:

$$W = \sum_{K=1}^{M} [E_K^T E_K - I]$$

- Donde la matriz E_K^T es la transpuesta de la matriz E_K e I es la matriz identidad de dimensiones $N \times N$ que anula los pesos de las conexiones autorrecurrentes (W_{ij}).

4.3 Ejecución de la red neuronal artificial

Se considerara dos tipos de enfermedades:

- ❖ Rotula ventricular aguda.
- ❖ Angina de pecho.

Su sintomatología por cada enfermedad es la siguiente:

- ❖ Rotula ventricular aguda.[1,1,-1,-1]
 - ◆ Dolor torácico 1
 - ◆ Soplo sistólico 1.....-1,-1
- ❖ Angina de pecho.[-1,-1,1,1]
 - ◆ Estrés emocional -1
 - ◆ Dolor subestenal o precordial -1.....1,1

- Las informaciones serían dos vectores ($m=2$) de 4 elementos ($n=4$) que contiene los valores de los síntomas. Por tanto la red, tendrá 4 neuronas para que cada una reciba el valor de los síntomas.
- Se dice que son 4 neuronas por el motivo de que son 4 sintomatologías; para tener una gran comprensión de este modelo, haga la similitud de la memoria de un niño que aprende sus primeros conocimientos. Para que pueda aprender se necesita hacer una diferencia de las dos enfermedades, subdivididas en dos sintomatologías, las sintomatologías serán representadas por medio de 1 y la ausencia de sintomatología por -1.
- Los valores de los vectores de entrada que representan a las figuras a y b

$$E1=[1,1,-1-1]$$

$$E2=[-1-1,1,1]$$

- Por tanto la rotula ventricular aguda se caracterizara por la secuencia de entrada 1,1,-1,-1.
- Por otro lado la angina de pecho tendrá la secuencia de entra -1,-1,1,1.
- El aprendizaje de estas dos informaciones consistirá en la obtención de los pesos de la red (matriz W).

T

$$E1 E1 - I = \begin{bmatrix} 1 & [1,1,-1,-1] \\ 1 & \\ -1 & \\ -1 & \end{bmatrix} - \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} = \begin{bmatrix} 0 & 1 & -1 & -1 \\ 1 & 0 & -1 & -1 \\ -1 & -1 & 0 & 1 \\ -1 & -1 & 1 & 0 \end{bmatrix}$$

$$T$$

$$E2 E2 - I = \begin{bmatrix} -1 & [-1,-1,1,1] \\ -1 & \\ 1 & \\ 1 & \end{bmatrix} - \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} = \begin{bmatrix} 0 & 1 & -1 & -1 \\ 1 & 0 & -1 & -1 \\ -1 & -1 & 0 & 1 \\ -1 & -1 & 1 & 0 \end{bmatrix}$$

$$W = \sum_{K=1}^2 [E_k E_k - I] = \begin{bmatrix} 0 & 0 & -2 & -2 \\ 2 & 0 & -2 & -2 \\ -2 & -2 & 0 & 2 \\ -2 & -2 & 2 & 0 \end{bmatrix}$$

- Una vez finalizada la fase de aprendizaje, la red podría ser utilizada como memoria asociativa de acceso por contenido, de tal forma que al presentarle una información a la entrada, iteraría hasta generar como salida la información más parecida de las almacenadas durante el aprendizaje. Por ejemplo que ocurriría si se presentara la información
- $E=[1-1-1-1]$ que representa la información codificada a dolor torácico de la enfermedad Rotula ventricular agudo.

4.4 Evaluación de la red neuronal artificial

- Este es el punto mas importante de la investigación en redes neuronales artificiales, realizado en mi tesis, ya que se comprobara en este apartado como reacciona la red a la incompletitud de información referente a una enfermedad, es decir, en el futuro se podrán hacer diagnósticos en computadores basados en los sistemas nerviosos del cerebro humano.
- Inicialmente, la salida corresponde a la propia información de entrada. Entonces se produce la primera iteración, obteniéndose las siguientes nuevas entradas netas en cada neurona:

E=[Dolor torácico]

$$E.W=[1,-1,-1,-1] \begin{bmatrix} 0 & 2 & -2 & -2 \\ 2 & 0 & -2 & -2 \\ -2 & -2 & 0 & 2 \\ -2 & -2 & 2 & 0 \end{bmatrix} = [2 \ 6 \ -2 \ -2]$$

- Si suponemos una función de activación de cada neurona de tipo escalón centrada en el origen (desplazamiento $0i=0$), la salida de la red después de esta primera iteración será:

$$S=[1 \ 1 \ -1 \ -1]$$

- Si se repite el proceso, en la segunda iteración las entradas netas serán:

$$E.W=[1, 1,-1,-1] \begin{bmatrix} 0 & 2 & -2 & -2 \\ 2 & 0 & -2 & -2 \\ -2 & -2 & 0 & 2 \\ -2 & -2 & 2 & 0 \end{bmatrix} = [6 \ 6 \ -2 \ -2]$$

- Entonces, después de la segunda iteración, se obtienen los siguientes valores de salida aun que no se haya presentado la totalidad de los padecimientos:

$$S=[1 \ 1 \ -1 \ -1]=\text{ROTULA VENTRICULAR AGUDA}$$

Nota: Para apoyar los resultados obtenidos de la red neuronal artificial se elaboro un sistema software el cual pudiera reconocer enfermedades.

El lenguaje Visual Basic 6 se utilizo para el desarrollo de la red neuronal artificial, para consulta de código fuente vea el **Apéndice**

4.5 Limitaciones del modelo de hopfield

En este tipo de redes presentado anteriormente, el numero de informaciones que puede ser aprendido (almacenado) está severamente limitado. Si se almacena demasiadas informaciones, durante su funcionamiento la red puede converger a valores de salida diferentes de los aprendidos durante la etapa de entrenamiento, con lo que la tarea de asociación entre la información presentada y alguna de las almacenadas se realiza incorrectamente, pues se está asociando dicha información de entrada a otra desconocida.

En tal caso, el número de informaciones que se puedan almacenar debe ser menos que el 13.8% del número de neuronas de la red ($0.138N$). Por tanto la capacidad o cantidad de informaciones que puede almacenar una red Hopfield de N neuronas es:

Capacidad = $0.138 N$ para una recuperación suficientemente buena

$$\frac{N}{4 \ln(N)} \text{ para una recuperación perfecta}$$

Esta es una seria limitación de la red Hopfield, puesto que para almacenar unas pocas informaciones se precisara una gran cantidad de neuronas, y por lo tanto, un número muy elevado de conexiones. Por ejemplo, tomando la limitación del 13.8%, en una red de 100 neuronas, que tendrá $100 \cdot 99 = 9900$ conexiones, solo se podrían almacenar 13 informaciones.

El tema de ANN'S es de gran relevancia para nuestro mundo, este tema me apasiona, y espero que esta tesis pueda llegar a dar algo a la sociedad humana como un reflejo de la conclusión de una educación Universitaria, en todos estos 19 años de estudio.

CONCLUSION

Basándose en los resultados obtenidos en el presente trabajo de investigación se asegura que en un futuro venidero podremos realizar comunicaciones bidireccionales entre hombres – maquinas, ya que por medio de las redes neuronales artificiales podremos construir neurocomputadores que puedan aprender, hablar y razonar.

Como se ha comprobado en este trabajo de investigación, las redes neuronales artificiales tienen la capacidad de aprender de fenómenos no presentados anteriormente, pudiendo así atacar problemas en donde las situaciones, características, atributos, escenarios de un problema no son constantes.

Esta clase de problema donde los factores de entrada para la solución del mismo tienden al desorden, ha sido como se ha comentado en apartados anteriores uno de los problemas más complejos de solución en el campo de la algorítmica computacional tradicional, ya que esta se fundamenta en la idea que todos los problemas pueden ser descritos en términos fijos. Aquí es donde las redes neuronales artificiales juegan un papel importante, ya que por medio de ellas pueden solucionarse y abordarse fácilmente estos tipos de problemas.

La aplicación desarrollada en la presente tesis de redes neuronales artificiales para el diagnóstico de enfermedades cardiovasculares (Ventricula Aguda y Angina de Pecho) nos comprueba satisfactoriamente lo citado en la hipótesis presentada al comienzo de esta investigación, ya que la aplicación es capaz de aprender de hechos desconocidos y dar un resultado satisfactorio (diagnóstico correcto) aun cuando la información presentada a la red neuronal artificial sea incompleta o nunca se le haya presentado tal información (síntomas).

Las redes neuronales artificiales jugará en los próximos años un papel importante en la evolución de la nueva teoría computacional, ya que por medio de las RNA podemos abordar problemas en los cuales la contingencia abunda.

APENDICE

Dim Info1(1 To 4, 1 To 1)
Dim Info2(1 To 4, 1 To 1)
Dim TRANS1(1 To 4)
Dim TRANS2(1 To 4)
Dim VERTICAL1(1 To 4, 1 To 4)
Dim TOTAL1(1 To 4, 1 To 4)
Dim TOTAL2(1 To 4, 1 To 4)
Dim PESOS(1 To 4, 1 To 4)
Dim ENTRADA(1 To 4)
Dim SALIDA(1 To 4)
Private Sub Command1_Click()

Info1(1, 1) = 1
Info1(2, 1) = 1
Info1(3, 1) = -1
Info1(4, 1) = -1

TRANS1(1) = 1
TRANS1(2) = 1
TRANS1(3) = -1
TRANS1(4) = -1

Info2(1, 1) = -1
Info2(2, 1) = -1
Info2(3, 1) = 1
Info2(4, 1) = 1

TRANS2(1) = -1
TRANS2(2) = -1
TRANS2(3) = 1
TRANS2(4) = 1

VERTICAL1(1, 1) = 1
VERTICAL1(1, 2) = 0
VERTICAL1(1, 3) = 0
VERTICAL1(1, 4) = 0

VERTICAL1(2, 1) = 0
VERTICAL1(2, 2) = 1
VERTICAL1(2, 3) = 0
VERTICAL1(2, 4) = 0

VERTICAL1(3, 1) = 0
VERTICAL1(3, 2) = 0
VERTICAL1(3, 3) = 1
VERTICAL1(3, 4) = 0

VERTICAL1(4, 1) = 0
VERTICAL1(4, 2) = 0
VERTICAL1(4, 3) = 0
VERTICAL1(4, 4) = 1

Call calculoPesos

End Sub

Sub calculoPesos()

For l = 1 To 4

For a = 1 To 4

TOTAL1(l, a) = Info1(l, 1) * TRANS1(a) - VERTICAL1(l, a)

Next a

Next l

For l = 1 To 4

For a = 1 To 4

TOTAL2(l, a) = Info2(l, 1) * TRANS2(a) - VERTICAL1(l, a)

Next a

Next l

For l = 1 To 4

For a = 1 To 4

PESOS(l, a) = TOTAL1(l, a) + TOTAL2(l, a)

Next a

Next l

End Sub

Private Sub Command2_Click()

Dim BANDERA As Boolean

Dim CONTADOR As Integer

If sint1.Value = 1 And sint2.Value = 1 And sint3.Value = 0 And sint4.Value = 0 Then

ENTRADA(1) = 1

ENTRADA(2) = 1

ENTRADA(3) = -1

ENTRADA(4) = -1

Elseif sint1.Value = 1 And sint2.Value = 0 And sint3.Value = 0 And sint4.Value = 0 Then

ENTRADA(1) = 1

ENTRADA(2) = -1

ENTRADA(3) = -1

ENTRADA(4) = -1

Elseif sint1.Value = 0 And sint2.Value = 1 And sint3.Value = 0 And sint4.Value = 0 Then

ENTRADA(1) = -1

ENTRADA(2) = 1

ENTRADA(3) = -1

ENTRADA(4) = -1

Elseif sint1.Value = 0 And sint2.Value = 0 And sint3.Value = 1 And sint4.Value = 1 Then

ENTRADA(1) = -1

ENTRADA(2) = -1

ENTRADA(3) = 1

ENTRADA(4) = 1

Elseif sint1.Value = 0 And sint2.Value = 0 And sint3.Value = 1 And sint4.Value = 0 Then

ENTRADA(1) = -1

ENTRADA(2) = -1

ENTRADA(3) = 1

ENTRADA(4) = -1

Elseif sint1.Value = 0 And sint2.Value = 0 And sint3.Value = 0 And sint4.Value = 1 Then

ENTRADA(1) = -1

ENTRADA(2) = -1

ENTRADA(3) = -1

ENTRADA(4) = 1

```

End If

While BANDERA = False
For l = 1 To 4
  For a = 1 To 4
    SALIDA(l) = SALIDA(l) + ENTRADA(a) * PESOS(l, a)
  Next a
Next l
For h = 1 To 4
  Select Case SALIDA(h)
    Case Is > 0
      SALIDA(h) = 1
      ENTRADA(h) = 1
    Case Is < 0
      SALIDA(h) = -1
      ENTRADA(h) = -1
    Case 0
      SALIDA(h) = 0
  End Select
Next h
For l = 1 To 4
  If SALIDA(l) <> ENTRADA(l) Then
    BANDERA = False
    CONTADOR = 0
  End If
Next l
If ENTRADA(1) = SALIDA(1) And ENTRADA(2) = SALIDA(2) And ENTRADA(3) = SALIDA(3) And
ENTRADA(4) = SALIDA(4) Then
  CONTADOR = CONTADOR + 1
  If CONTADOR = 2 Then
    BANDERA = True
    resultado
  End If
End If
End If
SALIDA(1) = 0
SALIDA(2) = 0
SALIDA(3) = 0
SALIDA(4) = 0
Wend
End Sub

Sub resultado()
If SALIDA(1) = 1 And SALIDA(2) = 1 And SALIDA(3) = -1 And SALIDA(4) = -1 Then
  MsgBox "La enfermedad diagnosticada por la RNA es Rotula Ventricular Aguda", vbInformation
Elseif SALIDA(1) = -1 And SALIDA(2) = -1 And SALIDA(3) = 1 And SALIDA(4) = 1 Then
  MsgBox "La enfermedad diagnosticada por la RNA es Angina de Pecho", vbInformation
End If
End Sub

```

**ESTA TESIS NO SALE
DE LA BIBLIOTECA**

BIBLOGRAFÍA

A continuación se indican las referencias bibliográficas de los documentos que hace referencia el presente trabajo de investigación.

[Ham 1969] Dr. Arthur W. Ham. "Tratado de Histología". México 1969.

[Guyton 1971] Dr. Arthur C. Guyton. "Tratado de fisiología Médica". México 1971.

[Ribes 1995] David Ribes. "El alma de la Cibemética". Puerto rico Madrid 1995.

[Hilera 1995] José R. Hilera / Víctor J. Martínez. "Redes Neuronales Artificiales", Madrid España 1995.

[Wiener 1948] Norbert Wiener. "Cybernetics or Control and Communication in the Animal and the Machine". MIT Press 1948, 1961

[McCulloch 1943 y Hebb 1949]. " W.S.McCulloch y W.A.Pitts." Alogical Calculus of the ideas Immanent in Nervous Activity". Boulet of Mathematics and Biophysics.

[Rosenblatt 1958]. "F.Rosenblatt. "The Perceptron: A probabilistic model for information storage and organization in the brain". Psychological Review, 65, págs. 346-408, 1958. Reimpreso en el texto "Neurocomputing" (J.Anderson y E. Rosenfeld ed.), págs. 92-114, MIT Press, 1998.

Windrow 1960] B. Windrow y M.Hoff. "Adaptative Switching Circuits". IREWESCON Convention Record, part 4, págs. 96-104, 1960. Reimpreso en el texto "Neurocomputing" (J.Anderson y E.Rosenfeld ed.), págs 126-134, MIT Press, 1998.

[Minsky 1969] M.Minsky y S.Papert. "Perceptrons". Ed. MIT Press, 1969.

[Grossberg 1982] S.Grossberg. "Studies of mind and brain: Neural principles of learning, perception, development, cognition and motor control". Ed. Reidel Press, Amsterdam, 1982.

[Fukushima 1980] K.Fukushima. "Necognitron: A self-organizing neural network model for a mechanism of pattern recognitron unaffected by shift in position". Biological Cybernetics, 36, págs 193-202, 1980.

[Hopfield 1982] J.Hopfield. "Neural Networks and physical systems with emergent colective computation abilities". 79 págs 2554-2558, 1982

[Hecht-Niesen 1988] R.Hecht-Nielsen. "Applications of counterpropagation networks". Neural Networks, 1, págs. 131-140, 1988.

[Kohonen 1988] T. Kohonen. "Learning vector quantization". Abstracts of the first annual INNS Meeting, 303, 1988.

[HAWKING 1993] Sthepen Hawking. "Agujeros Negros y Pequeños Universos" 1993