

FUES
504
1227
2000
EJ. 2

UNIVERSIDAD DE EL SALVADOR
FACULTAD DE INGENIERIA Y ARQUITECTURA
ESCUELA DE INGENIERIA ELÉCTRICA



TRABAJO DE GRADUACION

“Redes Neurales Artificiales Aplicadas al Despacho Económico de Carga”

PRESENTADO POR:

LUIS GUSTAVO CADENAS
ROBERTO CARLOS CAÑAS MELÉNDEZ

15101143
15101143

PARA OPTAR AL TITULO DE
INGENIERO ELECTRICISTA

ENERO DEL 2000



4739

SAN SALVADOR, EL SALVADOR, CENTRO AMERICA.

Recibido el 12 enero 2000



UNIVERSIDAD DE EL SALVADOR

RECTOR:

DRA. MARIA ISABEL RODRIGUEZ

SECRETARIA GENERAL:

LICDA. LIDIA MARGARITA MUÑOZ VELA

FACULTAD DE INGENIERIA Y ARQUITECTURA

DECANO:

ING. ALVARO ANTONIO AGUILAR ORANTES

SECRETARIO:

ING. SAUL ALFONSO GRANADOS

ESCUELA DE INGENIERIA ELÉCTRICA

DIRECTOR:

ING. RICARDO ALFREDO COLORADO EMÉSTICA



**UNIVERSIDAD DE EL SALVADOR
FACULTAD DE INGENIERIA Y ARQUITECTURA
ESCUELA DE INGENIERIA ELECTRICA**

Trabajo de Graduacion previo a la opción al grado de:

INGENIERO ELECTRICISTA

Titulo: "Redes Neurales Artificiales Aplicadas al Despacho Económico de Carga"

**Presentado por: Luis Gustavo Cadenas
Roberto Carlos Cañas Meléndez**

Trabajo de Graduación aprobado por:



Coordinador y Asesor: Ing. Ricardo Alfredo Colorado Eméstica.

A handwritten signature in black ink, appearing to read "Ricardo Colorado", written over the bottom right of the stamp.

San Salvador, diciembre de 1999

ACTA DE CONSTANCIA DE NOTA Y DEFENSA FINAL

En esta fecha, 16 de diciembre de 1999 en el local de Sala de Lectura de la Escuela de Ingeniería Eléctrica, a las diecisiete horas y treinta minutos en presencia de las siguientes autoridades de la Escuela de Ingeniería Eléctrica de la Universidad de El Salvador:

- 1- Ing. Ricardo Alfredo Colorado Eméstica
Director
- 2- Ing. Carlos Eugenio Martínez Cruz
Secretario



Firma

[Handwritten signatures]
Martínez, C.

Y con el Honorable Jurado de evaluación integrado por las personas siguientes:

- 1- Ing. Sergio David Pérez González
- 2- Ing. José Wilber Calderón Urrutia

Firma

[Handwritten signatures]

Se efectuó la defensa final reglamentaria del Trabajo de Graduación:

"Redes Neurales Artificiales Aplicadas al Despacho de Carga"

A cargo de los Bachilleres:

CADENAS, LUIS GUSTAVO
CAÑAS MELENDEZ, ROBERTO CARLOS

Habiendo obtenido el presente trabajo una nota final, global de 8.5

(OCHO. PUNTO CINCO)

Trabajo dedicado a:

A Dios todopoderoso, por su infinita bondad y grandeza

A mis padres, por todo el amor, sacrificio y entrega total que me han dedicado a lo largo de mi vida, sin ellos este logro no sería posible.

A mi hermano por su amor y apoyo incondicional.

A mis abuelitas, por sus esperanzas y oraciones.

A mi novia, por su amor y comprensión

Roberto

Trabajo dedicado a:

Primeramente a Dios Todopoderoso, por estar siempre presente en el caminar de mi vida.

Mi Madre, por que ha sido la inspiración a mis estudios.

Mi Padre, por apoyarme siempre cuando más lo he necesitado.

Mis Hermanas por estar siempre pendientes de mí.

Mi adorable sobrina Claudia por que con su cariño infantil hacia olvidarme los momentos difíciles que pasaba.

Gustavo.

AGRADECIMIENTOS

A Dios todo poderoso

Al Ing. Ricardo Colorado por su invaluable enseñanza tanto en lo profesional como en lo ético y moral.

A todos nuestros profesores que de una u otra forma nos apoyaron en nuestros proyectos y por todo lo que nos enseñaron.

A mis amigos, por su ayuda.

A toda la familia Cañas Melendez por toda su invaluable ayuda.

Gracias por hacer posible este logro.

Gustavo y Roberto

PREFACIO

Entre los objetivos de la Escuela de Ingeniería Eléctrica, se encuentra la investigación de los métodos recientes para la solución de problemas, con el objeto de continuar optimizando las soluciones en calidad y cantidad. El tema de las redes neuronales es de obligada discusión en todas las universidades de primer mundo, y esta presente en casi todas las plataformas de discusión, por lo tanto es necesario iniciar nuestro recorrido por los caminos de la inteligencia artificial, reconociendo que esta será una herramienta poderosa en un futuro cercano.

La necesidad de optimizar los recursos naturales y bajar los costos de producción de energía conllevan a la investigación de métodos de solución cada vez más óptimos y precisos. Las redes neuronales artificiales presentan las características apropiadas para resolver el problema de Despacho Económico de Carga.

Los métodos tradicionales como Gauss-Seidel y Newton Raphson son métodos iterativos que presentan tiempos de solución bastante largos, esto implica que las computadoras deberán tener una gran cantidad de memoria para la solución, a diferencia de las redes neuronales artificiales que trabajan en forma paralela al igual que una neurona biológica.

El despacho económico de carga es un problema que todas las plantas generadoras presentan, si se tiene un buen despacho de carga los costos de producción bajarán, se utilizará menos combustible y los recursos naturales se verán favorecidos.

El software para simulación de redes neuronales puede ser empleado en forma sistemática, y es expandible a cualquier problema de optimización que se presente, esto lo convierte en una herramienta poderosa y barata para el análisis.

RESUMEN

El presente trabajo investiga el uso de las Redes Neuronales Artificiales aplicadas a un campo de la Ingeniería de Potencia como es el Despacho Económico de Carga. Por ello se han estudiado los diferentes modelos de Redes Neuronales Artificiales, con el fin de elegir el modelo más favorable a nuestra investigación y aplicación.

Las redes neuronales artificiales se pueden describir como un "intento" de imitar el método de actuación del cerebro, a fin de dominar su versatilidad y su capacidad para decidir e intuir a partir de información incompleta o confusa. Debido a que la neurona artificial es un modelo abstracto de una neurona real, las redes formadas por varias unidades artificiales hereda, de las redes neuronales biológicas, la característica de "procesamiento de la información en paralelo". Sorprendentemente esta propiedad de procesamiento de una red neuronal artificial le permite utilizar algoritmos de aprendizaje basados en ciertas reglas de aprendizaje utilizadas por los seres humanos. Ya que el cerebro procesa información rápida y de manera exacta, reconociendo e identificando patrones desconocidos, la red neuronal artificial puede ser entrenada para que realice dicha función con la velocidad de cálculo de una computadora digital; aunque una de las neuronas de la red falle. Otra característica que presentan algunas de estas redes viene de su naturaleza matemática abstracta: la descripción de sistemas de ecuaciones diferenciales no lineales; esto las convierte en un nuevo medio para la solución de problemas de optimización, complejos de resolver por medios convencionales. Todas estas características de entrenamiento, aprendizaje y propiedades matemáticas, hacen de las redes neuronales artificiales elementos útiles para aplicaciones en los sistemas de potencia.

El objeto de estudio es explicar los principios biológicos que sirvieron como base para la creación del modelo matemático abstracto resultante de una red neuronal artificial, además pretendemos enmarcar en este trabajo las características, propiedades, algoritmos de aprendizaje, funcionamiento, y arquitectura de los principales tipos de redes neuronales artificiales.

Otro objetivo fundamental es resolver problemas de despacho económico sin pérdidas y con pérdidas a través de una red neuronal artificial, específicamente la red Hopfield, esto con la ayuda de un software que simula el comportamiento de las redes neuronales escrito en C++.

La metodología usada para la realización de este trabajo se basa en la investigación de una solución al problema de despacho económico de carga a través de una red neuronal artificial Hopfield, para ello se usó mucha documentación de universidades extranjeras disponible en Internet. Se adquirió mucha documentación de IEEE para lograr entender y hacer una aplicación a nuestro proyecto. Se usaron herramientas de programación basadas en el lenguaje C/C++ para simular la red neuronal Hopfield.

Al final logramos mostrar de la forma más clara posible, los principios básicos que dan origen a las redes neuronales artificiales, los diferentes tipos de redes neuronales que hay, el por qué de sus topologías y las ventajas que presentan como herramientas matemáticas para la optimización, así también queda la iniciativa de seguir investigando en otros campos como digitalización de señales, reconocimientos de patrones y en el ámbito de las comunicaciones.

Desarrollamos un software que esta escrito en lenguaje C/C++ que simula el funcionamiento de una red neuronal Hopfield, en la solución de problemas de despacho económico de carga, tanto con perdidas como sin ellas, El programa ademas calcula los coeficientes de perdidas para un sistema de n buses, los cuales pueden ser de utilidad en otros tipos de análisis en la ingeniería de potencia.

TABLA DE CONTENIDOS

Capítulo	Página
I. FUNDAMENTOS DE REDES NEURONALES ARTIFICIALES.....	1
1.0 Qué es una red neuronal?.....	2
1.1 Antecedentes históricos.....	2
1.2 Fisiología de la neurona biológica.....	4
1.2.1 El soma.....	7
1.2.2 Estructura de la membrana celular.....	8
1.2.3 Proteínas la firma de la célula.....	8
1.3 Funcionamiento Básico.....	9
1.3.1 Neuronas Artificiales : TLU (Unidades Lógicas de umbral).....	9
1.3.2 Disparo de una neurona.....	10
1.3.3 Consideración del tiempo en el proceso de disparo de la neurona.....	13
1.3.4 Interconexión neuronal.....	14
1.3.5 Tipos de aprendizaje básicos.....	15
1.4 Tipos de redes neuronales.....	15
1.4.1 El Perceptron.....	16
1.4.2 Perceptron multicapas.....	16
1.4.3 Redes Backpropagation.....	16
1.4.4 Redes de Hopfield.....	17
1.5 La red Hopfield – memorias asociativas.....	17

1.6	Funcionamiento de una red Hopfield.....	19
1.6.1	Diagrama de transición de estados para una red de 3 nodos.....	20
1.6.2	Definición de energía en la red neuronal Hopfield.....	21
1.6.3	Redes Hopfield en problemas de optimización.....	25
	Conclusiones.....	26
	Referencias Bibliográficas.....	27
II.	DESPACHO DE CARGA ECONÓMICO.....	28
2.0	Distribución de carga entre plantas.....	28
2.1	Modelo de la característica entrada-salida en las unidades generadoras.....	29
2.2	Costo de generación.....	30
2.3	Formulación matemática del despacho económico de carga.....	31
	Conclusiones.....	32
	Referencias Bibliográficas.....	33
III.	RED NEURONAL HOPFIELD EN EL DESPACHO ECONÓMICO DE CARGA.....	34
3.0	Modelo binario de la red neuronal Hopfield.....	34
3.1	Modelo continuo de la red neuronal Hopfield.....	36
3.2	Actualización de las neuronas en la red Hopfield.....	38
3.2.1	Actualización asíncrona.....	38
3.2.2	Actualización síncrona.....	38
3.3	Mapeo del ELD en la red Hopfield.....	39
3.3.1	Despacho económico de carga.....	40

3.3.2	Balance de potencia.....	40
3.3.3	Límites de Potencia máximos y mínimos	41
3.3.4	Mapeado del ELD en la red Hopfield.....	41
3.4	Algoritmo de solución al ELD con la red Hopfield.....	42
3.4.1	Introducción de las pérdidas en el algoritmo de solución.....	44
3.5	Desarrollo de la ecuación de energía y mapeo del ELD.....	44
	Conclusiones.....	46
	Referencias Bibliográficas.....	47
IV.	EJEMPLOS DE APLICACIÓN.....	48
4.0	Ejemplo de aplicación 1.....	48
4.1	Ejemplo de aplicación 2.....	50
4.2	Ejemplo de aplicación 3.....	52
4.3	Ejemplo de aplicación 4.....	53
	Conclusiones.....	56
	Referencias Bibliográficas.....	57
	ConclusionesGenerales y Recomendaciones.....	59
	Conclusiones.....	59
	Recomendaciones.....	60

LISTA DE TABLAS

Tabla	Página
1.1 Estados de la red neuronal.....	20
1.2 Energía en las dos neuronas.....	22
4.1 Resultados del problema 1.....	50
4.2 Datos de líneas y barras del ejemplo 2.....	51
4.3 Datos del flujo de carga en el ejemplo 2.....	51
4.4 Datos de placa y funciones de costo en los generadores del ejemplo 2.....	51
4.5 Resultados del despacho económico de carga por ambos métodos (Ej. 2).....	51
4.6 Nombre de ficheros válidos.....	52
4.7 Datos de placa y funciones de costo en los generadores del ejemplo 3.....	52
4.8 Resultado del despacho económico de de carga por ambos método (Ej. 3).....	53
4.9 Datos de líneas y barras del ejemplo 4.....	53
4.10 Datos de flujo de carga en el ejemplo 4.....	54
4.11 Coeficientes de pérdida para el ejemplo 4.....	54
4.12 Resultado de potencias de generación obtenidas.....	55

LISTA DE FIGURAS

Figura	Página
1.1 Diagrama básico de un neurona biológica.....	5
1.2 Sinapsis en detalle.....	5
1.3 Sumatoria temporal y espacio-temporal.....	6
1.4 Sección transversal de la membrana	8
1.5 Representación de un TLU.....	9
1.6 Función sigmoideal.....	11
1.7 Tren de pulsos.....	12
1.8 Distribución normal.....	12
1.9 Caída de activación.....	13
1.10 Esquema de una red neuronal.....	14
1.11 Sistema energético.....	17
1.12 Sistema energético en un solo plano.....	18
1.13 Corte en superficie rugosa.....	18
1.14 Red Hopfield de tres nodos.....	19
1.15 Diagrama de transición de estados.....	21
1.16 Dos nodos en conflicto.....	22
1.17 Estados de mínima energía.....	24
2.1 Características de entrada-salida de la salida de un generador.....	30
3.1 Función sigmoide.....	36
3.2 Actualización asíncrona.....	38

3.3 Actualización síncrona.....	39
4.1 Diagrama de potencia.....	50
4.2 Diagrama del sistema de potencia del ejemplo 3.....	55

CAPITULO I

FUNDAMENTOS DE REDES NEURONALES ARTIFICIALES.

Introducción.

Las redes neuronales son un elemento importante de las denominadas tecnologías de Inteligencia Artificial (IA). La IA es según H. Winston “ *la disciplina científica y técnica que se ocupa del estudio de las ideas que permiten ser inteligentes a las computadoras* ”. La ciencia de la Inteligencia Artificial ha generado numerosas herramientas prácticas, entre las que se encuentran las redes neuronales. Las redes neuronales, también llamadas redes de neuronas artificiales, son modelos bastante simplificados de las redes de neuronas que forman el cerebro. Y, al igual que este, intentan aprender a partir de los datos que se le suministran.

Así, las principales características que diferencian a las redes neuronales de otras tecnologías de IA son:

- Su capacidad de aprendizaje a partir de la experiencia (entrenamiento). Normalmente; para la elaboración de un programa informático es necesario un estudio detallado de la tarea a realizar para después codificarla en un lenguaje de programación: Pero, las redes neuronales pueden ser entrenadas para realizar una determinada tarea sin necesidad de un estudiar esta a fondo ni programarla usando un lenguaje de programación. Además; las redes neuronales pueden volver a entrenarse para ajustarse a nuevas necesidades de la tarea que realizan, sin tener que volver a escribir o revisar el código.
- Su velocidad de respuesta una vez concluido el entrenamiento, se comportan también en esta caso de manera similar a como lo hace el cerebro: los seres humanos no necesitamos pensar mucho para identificar un objeto, una palabra,... una vez hemos aprendido a hacerlo.
- Su robustez, en el sentido de que el conocimiento adquirido se encuentra repartido por toda la red, de forma que si se lesiona una parte se continua generando cierto numero de respuestas correctas (en este caso también hay cierta analogía con los cerebros parcialmente dañados).

En este capitulo se trata de dar una introducción a las Redes Neuronales Artificiales, presentando los diferentes modelos, características y analogías con las redes neuronales biológicas.

1.0 Qué es una red neuronal.

Una Red Neuronal Artificial (ANN)¹ es un paradigma² de procesamiento de información que está inspirado en la manera en que los sistemas nerviosos biológicos trabajan, tal como el cerebro, procesa la información. El elemento clave de este paradigma es la estructura novedosa del sistema de procesamiento de información. Se compone de un gran número de elementos altamente interconectados (las neuronas) trabajando al unísono para resolver problemas específicos, como es el caso del aprendizaje de las personas por el ejemplo. Un ANN se configura para aplicación específica, tal como datos o reconocimiento de un modelo de clasificación mediante un proceso de aprendizaje. Aprender en sistemas biológicos involucra ajustes a las conexiones sinápticas³ que existen entre las neuronas, esto es también cierto para las ANN.

1.1 Antecedentes históricos

Las simulaciones de redes neuronales parecen ser un desarrollo reciente. Sin embargo, este campo se estableció antes del advenimiento de las computadoras, y ha sobrevivido a varias eras a pesar de grandes retrocesos. Muchos han sido los adelantos importantes impulsados por el uso de emulaciones baratas de computadora. Seguido de un período inicial de entusiasmo, el campo sobrevivió un período de frustración y discrepancia. Durante este período cuando el financiamiento y apoyo profesional fueron mínimos, importantes adelantos fueron hechos por una cantidad relativamente escasa de investigadores. Estos pioneros eran capaces de desarrollar la tecnología convincente que sobrepasó las limitaciones señaladas por Minsky y Papert, los cuales publicaron un libro (en 1969) en el cual denotaron un sentimiento de frustración general (contra redes neuronales) entre investigadores, y era aceptado así por la mayoría sin un análisis adicional. Actualmente, el campo de las redes neuronales está en una etapa de resurgimiento y apoyo financiero.

La primera neurona artificial se produjo en 1943 por el neurofisiologista Warren McCulloch y el investigador en lógica Walter de Fossos. Pero la tecnología disponible entonces no les permitió hacer demasiado.

La historia de redes neuronales de la cual se habla en los párrafos anteriores se puede dividir en varios períodos:

1. Los Primeros Intentos: Había algunas simulaciones iniciales que usaban lógica formal. McCulloch y Pitts (1943) desarrollaron modelos de redes neuronales basándose en su comprensión del campo de la neurología. Estos modelos hicieron varias suposiciones

¹ Del Inglés Artificial Neural Network

² Del griego: algo que se asemeja cercanamente a otra cosa.

³ Sinapsis, punto de unión entre dos neuronas en la red.

sobre como trabajan las neuronas. Sus redes estuvieron fundamentadas en neuronas simples que eran consideradas dispositivos binarios con umbrales fijos. Los resultados de su modelo fueron las funciones lógicas simples, tales como "a OR b" y "a AND b"⁴. Otro intento fue usar las simulaciones de computadora, se identifican dos grupos (Farley y Clark, 1954; Rochester, Hollanda, Haibit y Duda, 1956). El primer grupo (investigadores de IBM) mantuvo contacto cercano con neurocientíficos de la Universidad de McGill. Así que cuando sus modelos no trabajaron, ellos consultaron a los neurocientíficos. Esta interacción estableció una tendencia multidisciplinaria que continúa hasta hoy en día.

2. *Promesas & Tecnología Emergente*: No solamente fue la influencia de la neurociencia en el desarrollo de redes neuronales, también psicólogos e ingenieros contribuyeron al progreso de simulaciones neuronales de red. Rosenblatt (1958) motivo el interés considerablemente en el campo cuando diseñó y desarrolló el Perceptron. El Perceptron tuvo tres de capas, con la capa media conocido como la *capa de asociación*. Este sistema podría aprender a conectar o asociar un aporte o entrada determinada a una unidad aleatoria de rendimiento o de salida. Otro sistema era el ADALINE (ADaptive Linear Element)⁵ que se desarrolló en el 1960 por Widrow y Hoff (Universidad de Stanford). El ADALINE era un dispositivo electrónico análogo hecho de componentes simples. El método usado para aprender era diferente al del Perceptron, este empleaba la regla de aprendizaje Least Mean Square⁶ (LMS).

3. *El periodo de Frustración & Discrepancia*: En 1969 Minsky y Papert escribieron un libro en el cual ellos generalizaron las limitaciones de la única capa del Perceptron a un sistema de multicapas. En el libro ellos dijeron: "**...nuestro fallo intuye que la extensión (a un sistema de multicapas) es estéril**". El resultado importante de su libro fue para eliminar el financiamiento para la investigación en las simulaciones de las redes neuronales. Como resultado se acentuó el prejuicio contra este campo

4. *La innovación*: Aunque el interés público y el financiamiento disponible fuesen mínimos, varios investigadores continuaron trabajando para desarrollar métodos computacionales basados en la solución de problemas tales como el reconocimiento de patrones. Durante este periodo fueron generados varios paradigmas los cuales continúan trabajando ahora. La influencia de Grossberg (Steve Grossberg y Gail Carpenter en 1988) fundó una escuela de pensamiento que explora los algoritmos resonantes. Ellos desarrollaron el ARTE⁷, redes con base en modelos plausibles biológicamente. Anderson y Kohonen desarrollaron técnicas asociativas independientes uno del otro. Werbos (Paul Werbos 1974) desarrolló y usó el método de aprendizaje backpropagation⁸, sin embargo varios años pasaron antes de que este enfoque se popularizara. Las redes Backpropagation son probablemente las más conocidas y ampliamente aplicadas de las redes neuronales hoy en día. En esencia, las redes Backpropagation son un Perceptron con múltiples

⁴ Funciones lógicas OR y AND de la lógica Booleana.

⁵ Elemento Lineal Adaptable

⁶ mínimo cuadrático medio.

⁷ Teoría Adaptable de Resonancia

⁸ Del ingles propagación hacia atrás

capas, diferenciándose por una función de umbral en la neurona artificial, y una regla de aprendizaje más capaz y robusta.

Amari (A. Shun - Ichi 1967) estuvo involucrado en desarrollos teóricos publicando un paper⁹ que estableció una teoría matemática para un aprendizaje básico (métodos de corrección de error) partiendo de una clasificación de patrones adaptable. Mientras Fukushima (F. Kunihiro) desarrolló un paso sabio entrenando a una red neuronal multicapas para la interpretación de caracteres escritos a mano. La red original se publicó en 1975 y se llamó el Cognitron.

5. *Re - Surgimiento*: El progreso durante el decenio de finales de 1970 y el decenio a principios de 1980 fueron importantes para el resurgimiento del interés en el campo de las redes neuronales. Varios factores influyeron este movimiento. Por ejemplo, las conferencias y libros comprensivos proveyeron un foro para la gente en campos diversos con idiomas técnicos especializados, y la respuesta a conferencias y publicaciones fue bastante positiva. Los medios de noticias recobraron gran actividad sobre el tema y ayudaron a diseminar la tecnología. Los programas académicos aparecieron y los cursos eran introducidos a la mayoría de las Universidades importantes (en US y Europa). La atención se enfoca ahora en financiar los niveles a lo largo de Europa, Japón y US, como este financiamiento llegó a ser disponible, varias nuevas aplicaciones en la industria y el comercio fueron hechas así también a las instituciones financieras.

6. *Hoy*: El progreso importante se ha hecho en el campo de redes neuronales - suficiente para atraer una gran atención y además fomentando la investigación. El adelanto más allá de aplicaciones comerciales actuales parecen ser posible, y la investigación en el campo avanza en gran manera. Chips¹⁰ basados en la Neuralgia están emergiendo y las aplicaciones a problemas complejos desarrollándose. Claramente, hoy es un periodo de transición para la tecnología de las redes neuronales.

1.2 Fisiología de la neurona biológica.

La neurona (del Griego: célula nerviosa) es la unidad fundamental del sistema nervioso, particularmente el cerebro. Considerando su tamaño microscópico, es una fábrica bioquímica para procesamiento de señales eléctricas sorprendentemente compleja. Desde un punto de vista clásico, la neurona es una unidad simple de procesamiento que, recibe y combina señales provenientes de otras neuronas a través de varias rutas de entrada denominadas dendritas (del griego: ramificaciones), como se ve en la Figura 1.1.

Las dendritas están dispuestas dentro de estructuras altamente complejas, denominadas "árboles dendríticos", los cuales tienen un área física enorme, comparada con el tamaño de una neurona. Los árboles dendríticos se conectan con el cuerpo principal de la célula

⁹ Publicación científica generalmente de pocas paginas

¹⁰ Circuitos Integrados

nerviosa, llamada soma (del griego: cuerpo). El soma puede tener forma piramidal o cilíndrica. La capa externa de la célula es la membrana. El interior de la célula esta lleno de fluido intracelular, la parte externa de la célula esta rodeada de fluido extracelular. La membrana de la neurona y las sustancias que se encuentran dentro y fuera de ella juegan un papel relevante para su operación y supervivencia. Cuando se excita arriba de cierto nivel denominado umbral, la neurona “dispara”; esto es, transmite una señal eléctrica, denominada acción potencial, a lo largo de una ruta sencilla denominada axón. El axón termina en un árbol de rutas filamentosas llamadas terminales axónicas que están conectadas con las dendritas de otras neuronas.

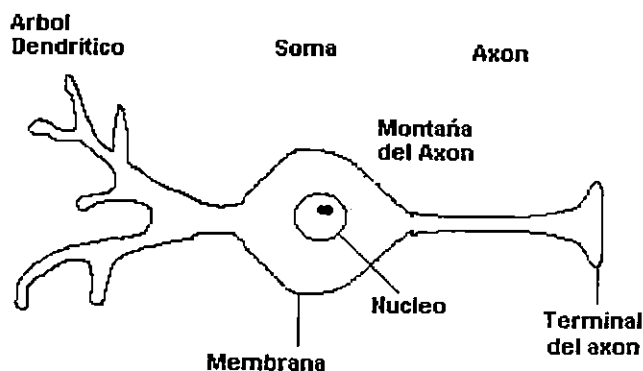


Figura 1.1 Diagrama Básico de una Neurona Biológica

La conexión o unión entre el axón de una neurona y la dendrita de otra neurona es llamada sinapsis (del griego: contacto). Una sinapsis esta compuesta de una terminal presináptica, un corte o división de la unión sináptica, y una terminal postsináptica (ver Figura 1.2).




Figura 1.2 Sinapsis en detalle

Una simple neurona podría tener entre 1000 y 10,000 sinapsis y podría estar conectada con 1000 neuronas. Pero no todas las sinapsis se excitan al mismo tiempo. Esto se debe a que un patrón sensorial recibido vía las sinapsis probablemente excitará un porcentaje relativamente pequeño de sitios; un sinnúmero de patrones diferentes pueden hacerse presentes en la neurona sin provocarle una respuesta. Cuando el potencial de acción alcanza los terminales axónicos los “mensajeros químicos”, conocidos como neurotransmisores, son liberados. Los neurotransmisores se almacenan en pequeñas estructuras esféricas, denominadas vesículas, las cuales son responsables de la comunicación efectiva entre neuronas.

Cuando un neurotransmisor es liberado, este es dirigido a través de la unión sináptica o se divide e inicia la despolarización de la membrana postsináptica; en otras palabras, la distribución de iones en la superficie de la membrana cambia, y así el voltaje a lo largo de la membrana receptora, llamado potencial postsináptico, cambia. A medida que la unión se hace más fuerte, una cantidad mayor de neurotransmisores alcanzan la membrana postsináptica.

La decodificación en la sinapsis es llevada a cabo por una sumatoria temporal y espacial, como se ve en la Figura 1.3. En la sumatoria temporal el potencial de cada impulso (considerando que las señales resultantes de la excitación tienen forma de impulsos) se adiciona a los potenciales de los impulsos previos. La suma total es el resultado de la sumatoria de todos los impulsos y sus amplitudes. La sumatoria espacial refleja la integración de las excitaciones o inhibiciones de todas las neuronas sobre la neurona receptora. El potencial total, dado por la sumatoria de carga temporal y espacial (espacio temporal) es codificado como un impulso nervioso transmitido a otras células. Los impulsos recibidos por las sinapsis de una neurona son integrados sobre un intervalo corto de tiempo, el cual está en concordancia con la velocidad de almacenamiento de carga en la membrana de la célula. Esta membrana actúa, inicialmente, como un capacitor y luego se convierte en un mensajero cuando complejos mecanismos biomecánicos son llevados a cabo.

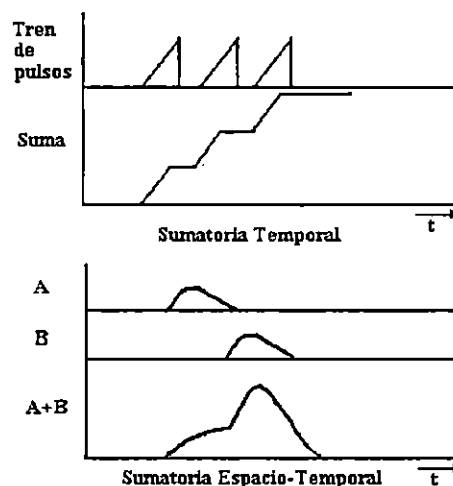


Figura 1.3. Sumatorias Temporal y Espacio-Temporal

Todas las señales integradas son combinadas en el soma, y si la amplitud de todas las señales combinadas alcanza el umbral de la neurona, un proceso de “disparo o activación” es activado y se produce una señal de salida. Esta señal, que puede ser un simple impulso ó una secuencia de pulsos a una tasa particular, es transmitida a través de el axón de la célula hacia los terminales axónicos.

1.2.1 El Soma.

El soma opera como una planta eléctrica “química”, altamente compleja. La membrana de la célula encierra el citoplasma. Al observar al soma bajo el microscopio, se puede reconocer al núcleo, el cuerpo de Golgi , las vacuolas, los retículos endoplasmáticos con los ribosomas , la mitocondria y el centrosoma. Los retículos endoplasmáticos junto a los ribosomas forman una serie de cadenas , constituyendo la planta química de la célula. La enzima en esta estructura convierten glucosa en glicógeno, el cual se almacena en los canales. Cuando se necesita energía, el glicógeno se reconvierte a glucosa, llevándose a cabo una liberación de energía . La mitocondria es la planta de potencia de la célula. Cuando el oxígeno y los nutrientes penetran a este organismo, una enzima causa una reacción química que genera trifosfato de adenosina (ADP). Una vez realizada esta transformación; el ATP se emplea para sintetizar ciertos componentes químicos, tales como el ADN, dentro de los ribosomas de la célula. Se cree también, que, el ATP también contribuye en la generación del potencial de acción. Cuando el ATP es usado; se reconvierte en ADP, retornando nuevamente a la mitocondria para la reactivación del ATP. Cuando se presente de nuevo el oxígeno en la mitocondria. El producto de esta reacción es el Dióxido de carbono (CO₂) y es retornado a la sangre para su eliminación en los pulmones.

Para el estudio del “potencial de acción es importante comprender la distribución de carga eléctrica a través de la membrana, esto es, las concentraciones iónicas y los potenciales dentro y fuera de la célula. La diferencia de potencial, debida al desbalance de las concentraciones iónicas de la membrana se expresa en términos de la concentración iónica externa (N_{ext}) e interna (N_{in}), la carga, q , y la temperatura, T :

$$V_i = (kT) \frac{1}{q} \frac{N_{in}}{N_{ext}} \quad 1.1$$

Donde k es la constante de Boltzmann, 1.38×10^{-23} , y $q = 6.09 \times 10^{-19}$ coulombs.

1.2.2 Estructura de la membrana celular.

La piel de la célula se conoce como la membrana. El bloque básico de construcción de la membrana está formado por moléculas fosfolípidas. La molécula fosfolípida consiste de dos moléculas: la hidrofóbica (Del griego: repelente del agua) en un lado; y la hidrofílica (Del griego: amiga del agua) al otro extremo (Figura 1.4); conformando un grupo polar. Ahora se puede considerar muchas moléculas fosfolípidas formando una capa (matriz bidimensional) con todas las cadenas de hidrocarbón en la misma superficie. La membrana consiste de dos de esas capas dispuestas de tal manera que, los lados que contienen las moléculas hidrocarbónicas coinciden (Figura 1.4); así la membrana tiene el grupo polar hidrofílico a ambos lados de su superficie. Las proteínas se encuentran en la estructura de la membrana.




Figura 1.4 Sección transversal de la membrana

1.2.3 Proteínas, las firmas de las células.

Las proteínas son los componentes esenciales de la célula. Se trata de largos polímeros compuestos de más de 20 tipos de aminoácidos, formando cadenas de alrededor de 300 moléculas en una secuencia específica. Cada secuencia constituye un código específico que caracteriza una proteína, y que, la distingue de las otras. Este código es conocido como gen. Los genes contienen el ácido desoxirribonucleico (DNA), el cual consiste de dos espirales largas de polímeros de glucosa que forman una doble hélice. Las proteínas se acomodan en una configuración definida (la cual se cree es diferente para cada organismo) que determina el funcionamiento de la célula; esto es, la configuración da la firma de la célula.

Cuando una proteína es creada, ciertos enlaces de aminoácido se debilitan más que otros, deformando así (ó formando) la geometría de la proteína. Esta geometría juega un papel importante en el proceso de reconocimiento, en el cual las proteínas de cierta configuración reconocen a otras de igual naturaleza, combinándose y creando enzimas con interesantes características. Por tanto, la configuración de la célula determina su funcionalidad.

Las proteínas se manufacturan continuamente, para el crecimiento, funcionamiento, y mantenimiento de la célula. Dicha fábrica se encuentra en el retículo endoplasmático con sus ribosomas. La molécula de DNA produce varios tipos de ácidos ribonucleicos (RNA), tales como el RNA mensajero (mRNA) y el transmisor (tRNA); el primero lleva el código genético al retículo endoplasmático, y el segundo encuentra los aminoácidos adecuados y los lleva al retículo. Una vez que un aminoácido es entregado el tRNA va en busca de más, lo que da inicio a un proceso de creación; los ribosomas se desplazan a través del mRNA, leen el código, y, sobre la base de éste sintetizan los aminoácidos recibidos, lo que da lugar a un proceso de "clonación" que da como resultado réplicas de la proteína. De lo anterior se concluye que los genes son la memoria de la célula, la cual es transmitida a nueva células. Este proceso es submicroscópico, y altamente complejo; los detalles están más allá del conocimiento que se tiene hasta el presente.

1.3. Funcionamiento básico.

1.3.1 Neuronas artificiales: TLU¹¹ (unidades lógicas de umbral)

El procesamiento de la información realizado por una neurona artificial se puede resumir crudamente como sigue: las señales (o potenciales de acción) aparecen en las entradas de la neurona (sinapsis. El efecto PPS (Potencial Post Sináptico) de cada señal podría ser aproximado por el producto de dicha señal por algún número o peso, para indicar la fuerza de la sinapsis. Las señales pesadas (o mejor dicho multiplicadas por un factor) se suman para producir un valor de activación de la unidad (neurona artificial). Si este valor de activación excede cierto nivel de umbral (preestablecido) la unidad produce una respuesta de salida. Esta función de activación es conocida en la neurona artificial como Unidad Lógica de Umbral (TLU), propuesta originalmente por McCulloch y Pitts (1943).

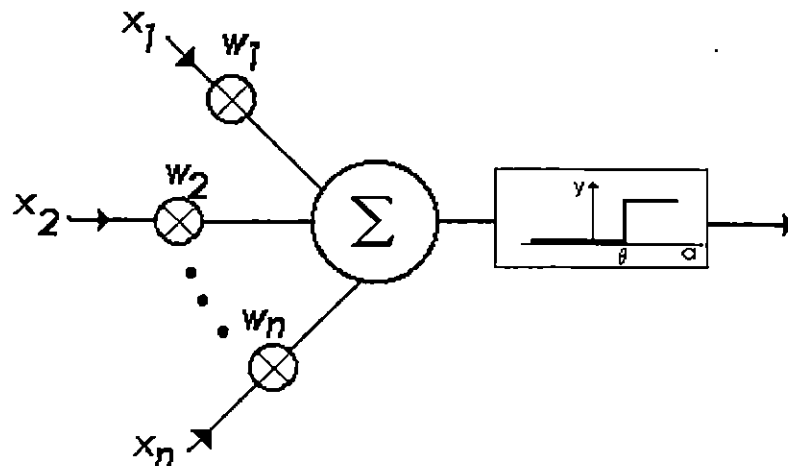


Figura 1.5 Representación de un TLU

¹¹ Del inglés Threshold Logical Unit

Supongamos que hay n entradas, con señales x_1, x_2, \dots, x_n asociadas y n pesos, w_1, w_2, \dots, w_n . Las señales pueden tomar solamente los valores de “1” o “0”. Es decir que las señales son booleanas (Esto permite su relación con los circuitos de lógica digital). La activación está dada por:

$$a = w_1x_1 + w_2x_2 + w_3x_3 + \dots + w_n \quad 1.2$$

Esta puede ser representada mas compactamente como:

$$a \approx \sum_{i=1}^n w_i x_i \quad 1.3$$

La salida y esta dada entonces por el umbral de activación:

$$y = \begin{cases} 1 & \text{si } a \geq \theta \\ 0 & \text{si } a < \theta \end{cases} \quad 1.4$$

El umbral θ frecuentemente será cero. La función de umbral se denomina algunas veces función escalón o hard limiter¹² por razones obvias. Si vamos a establecer una analogía con las neuronas reales, la presencia de un potencial de acción se denomina por un “1” binario y su ausencia por un “0” binario.

1.3.2 Disparo de una neurona (valores < 1, no binarios).

Las señales tratadas hasta el momento (tanto para las neuronas reales como para las artificiales) toman solo 2 valores, que son señales binarias. En el caso de las neuronas reales los dos valores son los “potenciales de acción” de voltaje y “el potencial de reposo de la membrana”. Para la TLU’s (Unidades Lógicas de umbral) estas señales son convenientemente etiquetadas como “1” o “0” respectivamente. Ahora, se acepta generalmente que, en las neuronas reales, la información es codificada; en términos de la “frecuencia de disparo”, aparte de la “presencia o ausencia de un pulso eléctrico”.

Hay dos caminos que podemos tomar para representar este fenómeno:

A) Disparo basándose en el concepto fundamental de la neurona biológica (presencia o ausencia de un pulso eléctrico).

Podemos afinar el rango por medio del cual se activa la neurona, de modo que sean números reales positivos entre cero y uno. Esto se utiliza cuando un grupo de señales genera la activación de la neurona en un tiempo corto (señales rápidas). Pero el uso de una función escalón limita a que todo tipo de señales de salida sean binarias. Esto se puede resolver “suavizando” la función escalón en una función continua conocida como sigmoide:

¹² Limitadora dura




Figura 1.6 Función Sigmoide

Una forma matemática conveniente para poder expresar a la función sigmoide (con umbral “ θ ”) esta dada por:

$$y = \sigma(a) = \frac{1}{1 + e^{-\frac{(a-\theta)}{\rho}}} \quad 1.5$$

Donde ρ representa la forma de la sigmoide: un valor alto hace de que la función se vuelva más plana. Por lo general se acostumbra a usar un valor de 1 para ese valor. Las neuronas que utilizan esta función se denominan: unidades “semi-lineales”. En la gráfica anterior el umbral tenía obviamente el valor de 0.5.

B)Disparo sobre la base de la frecuencia de excitación de la neurona.

Como una alternativa al uso real de valores de una señal (continuos o análogos), se puede emular una neurona real codificando (es decir, obtener la respuesta de activación de una neurona artificial) una señal basándose en la frecuencia de ocurrencia de aparición de un pulso “1” dentro un tren de pulsos (Dicho tren de pulsos se obtiene experimentalmente al alimentar a la neurona con una serie de señales de entrada, para N tiempos, observando cuantas veces nos da un valor de uno).

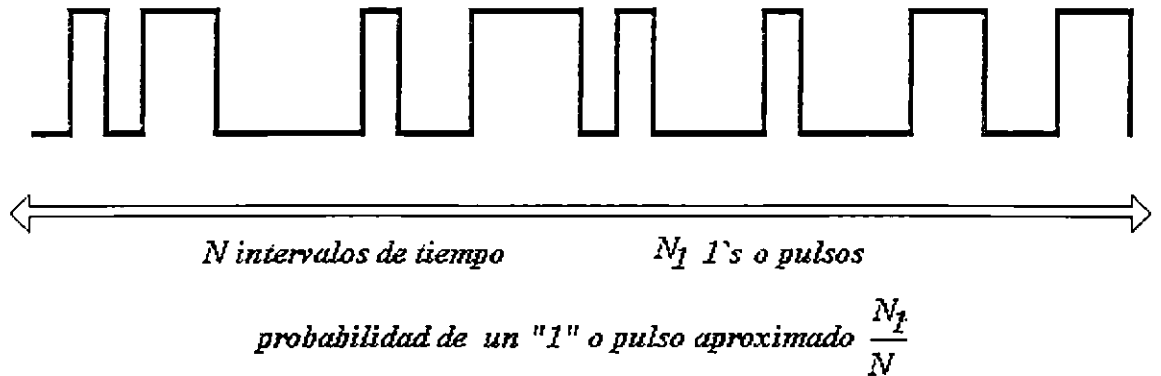


Figura 1.7 Tren de Pulsos

El tiempo se representa por intervalos discretos. Si el nivel requerido de la señal es p , donde $0 \leq p \leq 1$, entonces la probabilidad de aparición de un 1 en cada intervalo de tiempo será "p" (si necesitamos valores en algún otro rango, basta con normalizar la señal a un intervalo unitario. La señal de salida "y" ahora es interpretada como la probabilidad de obtener un 1, en lugar de ser interpretada como un valor de salida análogo (presencia de un tren de pulsos a la entrada que supera el umbral. Tales unidades se conocen a veces como unidades estocásticas semi-lineales. Si no conocemos el valor de "p" se puede obtener contando el número de 1's, N_1 , en el intervalo de tiempo. La probabilidad estimada de "p" esta dada por $p = N_1 / N$. En el caso estocástico es posible reinterpretar a la sigmoide en un modo más directo. Primero notemos que la sigmoide es una aproximación de distribución gaussiana acumulativa (distribución normal). Si consideramos lo dicho anteriormente, hemos modelado un umbral ruidoso; es decir que el umbral en cualquier instante es una variable aleatoria con distribución gaussiana (normal).

De esta forma, la probabilidad de disparo si el valor de activación es "a", es tan solo la probabilidad de que el umbral sea menor que "a", dicha probabilidad responde al valor acumulativo de la distribución gaussiana hasta este valor.




Figura 1.8 Distribución Normal

1.3.3 Consideración del tiempo en el proceso de disparo de la neurona

La discusión de la neurona que se ha llevado hasta este momento considera como instantáneas el disparo y activación de las mismas (no hay integración de las señales con respecto al tiempo). Para introducir la influencia del tiempo, definimos que la activación esta dada implícitamente por su razón de cambio da/dt . Esto requiere que la suma de las señales pesadas (es decir la activación misma) sea denotada por otra cantidad. Así, se tiene:

$$s = \sum_{i=1}^n w_i \cdot x_i \quad 1.6$$

y ahora definimos:

$$\frac{da}{dt} = -\alpha \cdot a + \beta \cdot s \quad 1.7$$

donde α y β son constantes positivas. El primer termino genera el decaimiento de la activación, mientras que el segundo representa las señales de entradas de las neuronas que podrían ser excitadoras. Para ver el efecto del decaimiento de la derivada de la activación con respecto al tiempo, hacemos $s=0$. Lo anterior, da dos casos:

- i) $a > 0$. Entonces $da/dt < 0$; esto es, a decrece.
- ii) $a < 0$. Entonces $da/dt > 0$; esto es, a crece.




Figura 1.9 Caída de la Activación.

La neurona alcanzara el equilibrio cuando $da/dt = 0$. Esto se da cuando:

$$a = \frac{\beta \cdot s}{s}$$

1.8

1.3.4 Interconexión Neuronal.

Las redes neuronales están formadas por un conjunto de neuronas artificiales interconectadas. Las neuronas de la red se encuentran distribuidas en diferentes capas de neuronas, de manera que las neuronas de una capa están conectadas con las neuronas de la capa siguiente, a las que pueden enviar información.

La arquitectura mas usada en la actualidad de una red neuronal (como la presentada en la figura 1.10) consistiría en:

- Una primera capa de entradas, que recibe información del exterior.
- Una serie de capas ocultas (intermedias), encargadas de realizar el trabajo de la red.
- Una capa de salidas, que proporciona el resultado del trabajo de la red al exterior.

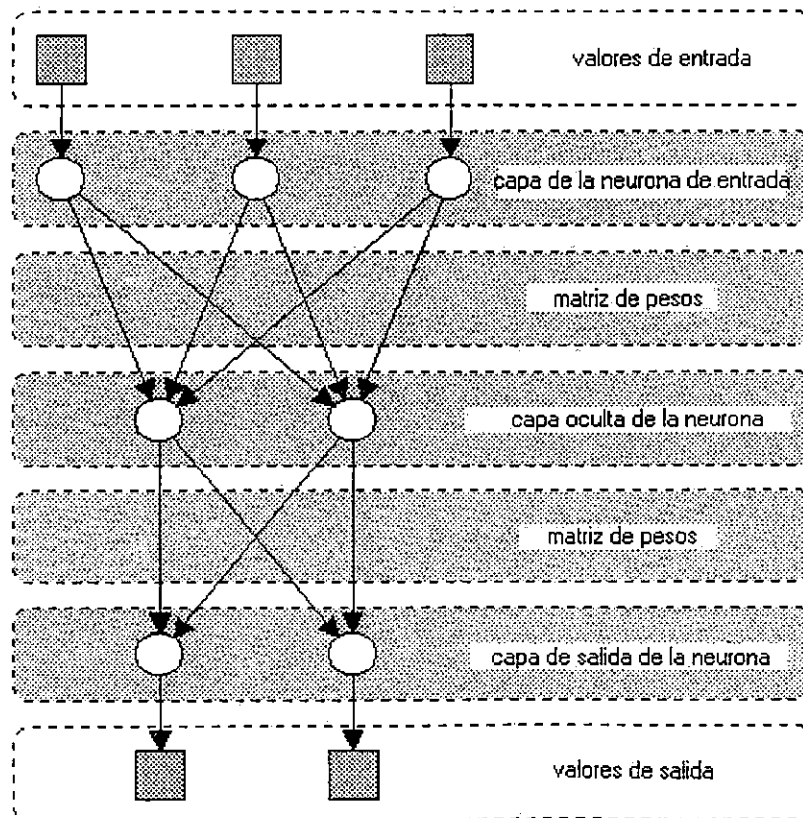


Figura 1.10 Esquema de una red neuronal

El número de capas intermedias y el número de neuronas de cada capa dependerá del tipo de aplicación al que se vaya a destinar la red neuronal.

1.3.5 Tipos de Aprendizaje Básicos.

Una red neuronal debe ser configurada tal que la aplicación del conjunto de entradas produzcan el conjunto de salidas deseadas. Existen varios métodos para ajustar las fuerzas sinápticas de las conexiones entre neuronas. Una forma es ajustar los pesos explícitamente, usando un conocimiento a priori. Otra manera es entrenar a la red neuronal por la alimentación de los patrones de aprendizaje y dejando que estos cambien sus pesos de acuerdo a alguna regla de aprendizaje.

Para poder aprender las redes neuronales se sirven de un algoritmo de aprendizaje, el cual se encarga de ajustar el umbral y los pesos sinápticos.

Estos algoritmos están formados por un conjunto de reglas que permiten a la red neuronal aprender (a partir de los datos que se le suministran), mediante la modificación de los pesos sinápticos de las conexiones entre las neuronas (tomando en cuenta que el umbral de cada neurona se modificara como si fuera un peso sináptico más).

Generalmente los datos que se usan para entrenar la red se le suministran de manera aleatoria y secuencial. Los tipos de aprendizaje pueden dividirse básicamente en tres, atendiendo a como está guiado este aprendizaje:

- ❑ Aprendizaje supervisado: se introducen unos valores de entrada a la red, y los valores de salida generados por esta se comparan con los valores de salida correctos. Si hay diferencia, se ajusta la red en consecuencia.
- ❑ Aprendizaje de refuerzo: se introducen valores de entrada, y lo único que se le indica a la red si las salidas que ha generado son correctas o incorrectas.
- ❑ Aprendizaje no supervisado: no existe ningún tipo de guía. De esta manera lo único que puede hacer la red es reconocer patrones en los datos de entrada y crear categorías a partir de estos patrones. Así cuando se le entre algún dato, después del entrenamiento, la red será capaz de clasificarlo e indicará en que categoría lo ha clasificado.

1.4 Tipos de Redes Neuronales.

Varios tipos de redes neuronales existen y pueden ser distinguidos por:

- ❑ Su tipo (feedforward¹³ o feedback¹⁴),
- ❑ Su estructura
- ❑ Y por el algoritmo de aprendizaje que usan.

¹³ Alimentación hacia delante

¹⁴ Alimentación hacia atrás .

El tipo de red neuronal indica, si las neuronas de una de las capas puede ser conectada con las otras. Las redes con alimentación hacia delante permiten solamente conexiones entre dos diferentes capas, mientras que las redes del tipo con alimentación hacia atrás también permiten conexiones entre neuronas de la misma capa.

1.4.1 El Perceptron.

El Perceptron fue introducido primeramente por F. Rosenblat en 1958. Esta es una red neuronal muy simple, la cual tiene dos capas de neuronas que aceptan solamente valores de entrada y salida binarios (0,1). El proceso de aprendizaje es supervisado y la red esta disponible para resolver operaciones de lógica básica como las funciones AND y OR. El modelo es también usado para propósitos de clasificación de patrones. Operaciones lógicas complicadas (como la función XOR) no pueden ser resueltas por un Perceptron.

1.4.2 Perceptron Multi-Capa.

Este modelo fue introducido primeramente por M. Minsky y S. Papert in 1969. Este modelo es un Perceptron extendido y tiene una o mas capas de neuronas ocultas entre sus capas de entrada y salida.

Debido a esta estructura extendida, un Perceptron Multi-Capa esta dispuesto a resolver cada operación lógica, incluyendo el problema de la XOR.

1.4.3 Redes Backpropagation.

Este tipo de red neuronal fue primeramente introducido por G.E. Hinton, E. Rumelhart y R.J. Williams en 1986, y es uno de los tipos mas potentes de redes neuronales. Esta tiene la misma estructura que el Perceptron Multi-Capa y usa el algoritmo de aprendizaje Backpropagation. En este tipo de redes, el problema a la hora de entrenarlas estriba en que solo conocemos la salida de la red y la entrada, de forma que no se puede ajustar los pesos sinápticos asociados a las neuronas de las capas ocultas, ya que no podemos inferir a partir del estado de la capa de salida como tiene que ser el estado de las capas ocultas.

El sistema de entrenamiento mediante backpropagation consiste en:

- Empezar con unos pesos sinápticos cualquiera (generalmente elegidos al azar).
- Introducir unos datos de entrada (en la capa de entradas) elegidos al azar entre los datos de entrada que se van a usar para el entrenamiento.
- Dejar que la red genere un vector de datos de salida (propagación hacia delante).
- Comparar la salida generada por la red con la salida deseada.
- La diferencia obtenida entre la salida generada y la deseada (denominada error) se usa para ajustar los pesos sinápticos de las neuronas de la capa de salidas.
- El error se propaga hacia atrás (backpropagation), hacia la capa de neuronas anterior, y se usa para ajustar los pesos sinápticos en esta capa.

- Se continúa propagando el error hacia atrás y ajustando los pesos hasta que se alcance la capa de entradas.

Este proceso se repetirá con los diferentes datos de entrenamiento.

El problema de este sistema es encontrar el mejor conjunto de pesos sinápticos para la red de manera que la eficiencia sea máxima. Esto se debe a que la función que mide la eficiencia de las redes con capas ocultas, en la mayoría de los casos, es una función compleja que presenta muchos mínimos locales. Y el mejor conjunto de pesos sinápticos es aquel que hace que la función alcance un mínimo global.

1.4.4 Redes de Hopfield.

Este modelo fue introducido en 1982, por John J. Hopfield. Gracias al trabajo sobre neurofisiología en invertebrados, desarrolló un tipo de red neuronal autoasociativa.

Estas redes son bastante parecidas al modelo del Perceptron, pero presentan una característica adicional: las neuronas en la capa media u oculta, presentan conexiones de salida hacia otras neuronas de la capa media. Además, cada neurona de la capa de entradas esta conectada con una neurona de la capa media, y cada neurona de la capa media emite una sola conexión hacia la capa de salida. Y estas conexiones no implican calculo de pesos sinápticos ni de valores de umbral.

El hecho de que todas las neuronas de la capa media se encuentren interconectadas, hace que en esta capa se de un feedback o retroalimentación entre sus neuronas, de forma que al activarse una neurona de esta capa hace que las otras neuronas cambien su estado de activación, que a la vez harán cambiar el suyo propio.

1.5 La Red Hopfield – memorias asociativas

Las redes que son empleadas para desarrollar recuerdos asociativos son ejemplos específicos de una amplia variedad de sistemas físicos. Esto permite que la operación de la red Neuronal sea vista como un sistema físico dinámico, y su comportamiento pueda ser descrito en términos de la “energía de la red”. Considere un tazón en el cual una bola es capaz de deslizarse libremente (vea la siguiente figura)




Figura 1.11 Sistema energético.

Esto se ve mejor por medio de un gráfico en 2D:



Figura 1.12 Sistema energético en un solo plano.

Supongamos que permitimos que la bola se deslice desde un punto en cualquier lugar de la parte superior del tazón con, posiblemente, un ligero empujón sobre uno de sus lados. La bola rodará ida y vuelta alrededor del tazón hasta que alcance el reposo.

La descripción física de “que ha sucedido” podría ser encontrada en términos de la energía del sistema. La bola inicialmente tuvo algo de energía potencial. Cuando la bola se colocó en el lado alto del tazón, manteniéndose ahí con una presión manual, ganó energía potencial que le sirvió para obtener velocidad al soltarla. Cuando la bola se liberó (ganó energía cinética). Eventualmente la bola alcanzó el reposo en el lugar donde su energía (potencial y cinética) es cero. El punto principal es que la bola alcanza el reposo en el mismo lugar cada vez, y este lugar está determinado por la mínima energía del sistema (bola + tazón). Se dice que el estado de reposo será estable debido a que el sistema permanece invariable una vez que este se ha alcanzado. Es aquí donde se presenta otra forma del proceso llevado a cabo por la memoria. Supongamos que la bola alcanza el reposo en el mismo lugar cada vez porque ésta “recuerda” donde está el fondo del tazón. Ahora nos podemos valer de tal analogía dándole a la bola una descripción por medio de un sistema de coordenadas. Así, su posición o **estado** en cualquier momento está dado por las tres coordenadas (x,y,z) o el vector de posición x . La localización del fondo del tazón x_0 representa el patrón que será almacenado. Si describimos al vector de la bola como la suma de x_0 y un desplazamiento Δx , tenemos: $x = x_0 + \Delta x$, podríamos pensar que la posición inicial de la bola representa el conocimiento parcial o la clave para un recuerdo, puesto que se aproxima a la memoria x_0 . Si ahora usamos una superficie rugosa en vez de una simple depresión (el tazón) podríamos obtener muchas “memorias”.



$\{x_1, x_2, x_3 \dots x_n\}$ son las memorias almacenadas
Figura 1.13 Corte en superficie rugosa

Si ahora la bola es colocada en algún lugar de esta superficie, eventualmente alcanzará el reposo en una depresión local, la cual es la más cercana a su punto de partida inicial. Esto invoca al patrón almacenado que sea más cercano al patrón inicial parcial o recuerdo parcial de tal patrón. Una vez más, este es un mínimo de energía para el sistema. Hay por tanto, dos formas complementarias de ver lo que esta sucediendo. En una el sistema cae dentro de un mínimo de energía; en la otra el sistema almacena un set de patrones y recuerda cual es el más cercano a su estado inicial. Si vamos a construir una red que se comporte de esta manera se deben incluir los siguientes elementos:

1. Debe estar completamente descrita por el vector de estado $\mathbf{v} = (v_1, v_2, \dots, v_n)$
2. Debe haber un conjunto de **estados estables** $v_1, v_2, v_3, \dots, v_n$ Esto corresponderá a los patrones almacenados y, en, una superficie rugosa por ejemplo, donde hubiesen depresiones en la superficie.
3. El sistema evoluciona en el tiempo de algún estado de inicio arbitrario \mathbf{v} a uno de los estados estables, y esto podría ser descrito como un decrecimiento en la energía E del sistema. Esto corresponde con el proceso de recuerdos que se da en la memoria.

1.6 Funcionamiento de una Red Hopfield.

Considerando una red de tres nodos, donde cada nodo es un TLU (Unidad Lógica de Umbral) como la que se muestra a continuación:




Figura 1.14 Red Hopfield de tres Nodos

Cada nodo se conecta con los otros nodos (excepto con el mismo) y los pesos son simétricos, de forma que el peso del nodo i al nodo j tiene el mismo valor que el peso del

nodo j al nodo i . Esto es, $w_{ij} = w_{ji}$, y $w_{ii}=0$ para todo i,j .¹⁵ Note que el flujo de la información en esta red no se da en una sola dirección. Es posible que la señal de un nodo regrese al mismo por medio de los otros nodos. Esto es, existe realimentación en la red y es por esa razón que son conocidas como redes recurrentes.

El estado de la red en cualquier instante esta dado por el vector de nodos de salida (x_1, x_2, x_3). Supongamos que encendemos la red en algún estado inicial y elegimos un nodo al azar de modo que su salida dispare. Lo que significa que el nodo disparará un uno cuando su activación sea mayor o igual que cero ó, su respuesta será cero de otra forma. La red se encuentra ahora en si misma dentro de dos posibilidades:

- El estado en el que se inicializó la red ó,
- En un nuevo estado, el cual se encuentra a una distancia Hamming¹⁶, de la anterior.

Si ahora seleccionamos un nuevo nodo al alzar con el objeto de ser disparado y continuamos de esa misma manera, podremos encontrar una tabla de estados de la red. Dicha tabla de estado nos dará el nuevo estado de la red basándose en el estado anterior (Tabla 1).

Estado		Nuevo Estado		
Número	Vector	(Después que el nodo ha sido disparado)		
	$x_1x_2x_3$	Nodo1	Nodo 2	Nodo 3
0	000	4	2	1
1	001	1	3	1
2	010	6	2	3
3	011	3	3	3
4	100	4	6	4
5	101	1	7	3
6	110	6	6	6
7	111	3	7	6

Tabla 1.1 Estados de la Red Neuronal

Esta información se puede representar en forma gráfica por medio de un diagrama de transición de estados.

1.6.1 Diagrama de transición de estados para una red de tres nodos

Los estados son representados por triángulos, con un numero en su interior representando el valor de estado binario de la red. Las líneas que unen los estados representan las

¹⁵ El Peso del nodo i al nodo j se denota algunas veces como w_i^j .

¹⁶ La distancia Hamming es el número de bits en que difieren dos estados binarios.

posibles transiciones entre los estados. Estos estados han sido dispuestos de tal forma que las transiciones tienden a darse hacia los puntos más bajos del sistema; se ha hecho de esta manera para reflejar la manera en que el sistema reduce su energía. Lo que hay que notar hasta este punto es que, sin importar estado en el cual inicializemos dentro del diagrama, la red eventualmente se encuentra a sí misma en uno de los estados 3 o 6. Siendo la probabilidad de caer en uno de esos dos: 1. Hasta este punto los nodos son estables –una vez que la red se encuentre en uno de esos dos estados, ésta permanecerá ahí. Los vectores de estado para 3 y para 6 son $(0,1,1)$ y $(1,1,0)$ respectivamente y representan “las memorias” almacenadas por la red.

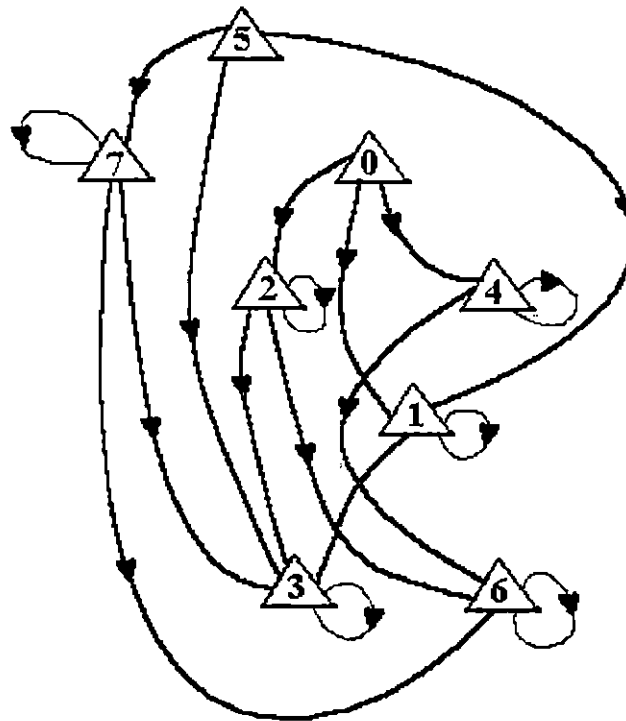


Figura 1.15 Diagrama de Transición de estados

1.6.2 Definición de Energía en la red neuronal.

La dinámica del comportamiento de la red es descrita por la tabla de transición de estado o el diagrama de transición de estados. Sin embargo, si podemos expresar el diagrama de transición de estado en términos de una función de energía, es posible mostrar que los estados estables siempre serán alcanzables por esa red.

Considere dos nodos i, j en la red los cuales están conectados por un peso positivo y en donde j esta actualmente sacando un "0", mientras que i esta sacando un "1".




Figura 1.16 Dos nodos en conflicto

Si a j se le diera la oportunidad de disparar, la contribución a la activación de i es positiva lo cual podría servir para llevar la activación de j arriba del umbral. Una situación similar podría prevalecer si el estado de salida inicial de los dos nodos ha sido revertido, ya que la conexión es simétrica. Si, por otra parte ambas unidades están encendidas entonces ambas están reforzando sus corrientes de salidas, el peso podría entonces verse como una limitante fija entre ambas neuronas, que tiende a hacerlas tomar el valor de 1. Un peso negativo podría tender a reforzar salidas opuestas. Esta idea puede ser capturada cuantitativamente en la forma de una función de energía adecuada al definir:

$$e_{i,j} = -w_{i,j} \cdot x_i \tag{1.9}$$

Los valores que $e_{i,j}$ se dan en la siguiente tabla:

x_1	x_2	e_{ij}
0	0	0
0	1	0
1	0	0
1	1	$-w_{ij}$

Tabla 1.2 Energía en las dos neuronas

Si el peso es positivo entonces la ultima entrada es negativa y es el valor más pequeño en la tabla. Si e_{ij} se define como "la energía" del par i,j entonces la mínima energía ocurre cuando ambas unidades están encendidas lo cual es consistente con los argumentos anteriores. Si el peso es negativo, el estado "(1,1)" es el estado de más alta energía y por lo tanto el menos favorable. La energía de la red se encuentra sumando todos los pares de nodos:

$$E = \sum_{\text{pares}} e_{i,j} = -\sum w_{i,j} \cdot x_i \cdot x_j \tag{1.10}$$

Esto puede ser reescrito como:

$$E = -\frac{1}{2} \cdot \sum_{i,j} w_{i,j} \cdot x_i \cdot x_j \quad 1.11$$

Puesto que la suma incluye cada par dos veces (note que $w_{i,j} \cdot x_i \cdot x_j$ y $w_{j,i} \cdot x_j \cdot x_i$) y $w_{i,j} = w_{j,i}$ $w_{i,i}=0$. Esto nos sirve para poder ver como se da el cambio en la energía. Suponiendo que k se elige para ser disparada, al escribir la ecuación de energía aislando los términos que involucran al nodo se tiene:

$$E = -\frac{1}{2} \sum_{\substack{i \neq k \\ j \neq k}} w_{i,j} \cdot x_i \cdot x_j - \frac{1}{2} \sum_{i \neq k} w_{k,i} \cdot x_k \cdot x_i - \frac{1}{2} \sum_{i \neq k} w_{i,k} \cdot x_i \cdot x_k \quad 1.12$$

Ahora, debido a que $w_{i,k}$ es igual a $w_{k,i}$ las dos últimas sumas se pueden combinar:

$$E = -\frac{1}{2} \sum_{\substack{i \neq k \\ j \neq k}} w_{i,j} \cdot x_i \cdot x_j - \sum_{i \neq k} w_{k,i} \cdot x_k \cdot x_i \quad 1.13$$

Para una fácil notación la primera suma se denota por S y el término x_k sale de la ecuación, porque es una constante, entonces:

$$E = S - x_k \cdot \sum_{i \neq k} w_{k,i} \cdot x_k \cdot x_i \quad 1.14$$

Pero la sumatoria por la cual esta multiplicada x_k es justamente la sumatoria de activación del k -ésimo nodo, de modo que:

$$E = S - x_k \cdot a^k \quad 1.15$$

Representemos el valor de energía de la red una vez que ésta se ha disparado E' y el nuevo valor de salida como x'_k , entonces:

$$E' = S - x'_k \cdot a^k \quad 1.16$$

Denotemos el cambio en la energía por ΔE ($E' - E$) y al cambio en la salida Δx_k ($x'_k - x_k$). Entonces restando las dos ecuaciones anteriores:

$$\Delta E = -\Delta x_k \cdot a^k \quad 1.17$$

Ahora hay dos casos a considerar:

1. $a^k \geq 0$. Entonces la salida va de "0" a "1" o permanece en "1". En cualquiera de los dos casos $\Delta x_k \geq 0$. Por lo tanto $\Delta x_k \geq 0$ y así $\Delta E \leq 0$.
2. $a^k < 0$. Entonces la salida va de "1" a "0" o permanece en "0". En cualquiera de los dos casos $\Delta x_k \leq 0$. Por lo tanto $\Delta x_k \leq 0$ y así $\Delta E \leq 0$.

De esta forma, para cualquier nodo que este siendo actualizado siempre tendremos que $\Delta E_k \leq 0$ y la energía de la red decrece o se mantiene al mismo nivel. Pero la energía se encuentra limitada por un valor obtenido al hacer que $x_i, x_j = 1$ en la ecuación

$$E = -\frac{1}{2} \cdot \sum_{i,j} w_{i,j} \cdot x_i \cdot x_j .$$

Así E debe alcanzar algún valor fijo y debe permanecer sin

cambio. Una vez esto ocurre, es posible que se lleven a cabo cambios posteriores en el estado de la red, debido a que $\Delta E = 0$ es aun un dato valido. Sin embargo, para que este sea el caso ($\Delta x_k \neq 0$ y $\Delta E = 0$) debemos tener a^k . Lo que indica que la transición de estado debe ser igual a uno. En esta situación pueden haber a lo mas N de esos cambios, en donde N es el numero de nodos de la red. Luego no pueden darse mas cambios en el estado de la red y se alcanza la estabilidad.

En el gráfico del ejemplo anterior todo estado tiene energía cero con excepción del estado 5 que tiene energía 2, y los estados estables 3 y 6 los cuales poseen energía -1.

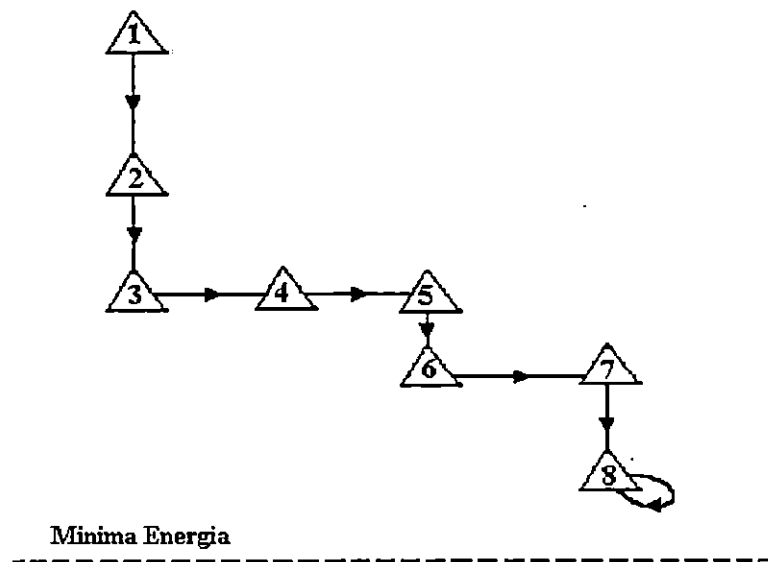


Figura 1.17 Estados de Mínima Energía

1.6.3 Redes Hopfield para problemas de Optimización.

Una gran cantidad de problemas de lógica provistos de situaciones dadas en el mundo real pueden ser formuladas como problemas de optimización, y así descritas cualitativamente como una investigación de la solución mejor. Estos problemas son encontrados en la ingeniería y el comercio. Estos problemas incluyen desde dar un mapa y con ello, el problema de manejar entre dos puntos, cual es la mejor ruta? Dar una tableta en la cual hay que poner chips, Cual es la mejor manera de colocar los chips para un buen y optimo alambrado (Kirkpatrick, 1983). O encontrar la optimización de problemas de consumo y demanda en la economía, y por nuestra parte como encontrar las potencias de generación optimas para que el costo de producción sea el mínimo, satisfaciendo así la demanda de carga así como también las perdidas.

CONCLUSIONES DEL CAPITULO I

- Una neurona artificial podrá ser representada por señales de entrada que son multiplicadas por un peso que indican las fuerzas sinápticas, y todas estas señales pesadas son sumadas para producir un valor de activación que será comparado con un nivel de umbral, y la salida dependerá de eso.
- Para tener una relación con los circuitos de lógica digital, se establece una analogía con las neuronas reales, en donde la presencia de un potencial de acción se denomina por un "1" binario y su ausencia por un "0" binario.
- El uso de una función escalón limita a que todo tipo de señales de salida sean binarias. Para resolver esto la función escalón se suaviza en una función continua llamada Sigmoide.
- Una red neuronal esta compuesta de una capa de entrada que recibe información del exterior, una serie de capas ocultas encargadas de realizar el trabajo de la red y una capa de salida la cual proporciona el resultado del trabajo de la red al exterior.
- El aprendizaje de una red neuronal podrá ser supervisado, de refuerzo o no supervisado.
- Las redes con alimentación hacia delante permiten solamente conexiones entre dos diferentes capas, mientras que las redes del tipo alimentación hacia atrás también permiten conexiones entre neuronas de la misma capa.
- En las redes de Hopfield la interconexión de todas las neuronas de la capa media, hace que se de una retroalimentación entre sus neuronas, de manera que al activarse una neurona de esta capa hace que las demás neuronas cambian su estado de activación, que a la vez hará cambiar el suyo propio.

REFERENCIAS BIBLIOGRAFICAS.

Gurney, Karen. Neural nets 2
Human Sciences Department, Brunel University, 1997.

Gurney , Karen. Neural networks a comprehensive foundation
Ph D. Thesis Dept. Electrical Engineering. Brunel University, Uxbridge, Middx, UK.,
1997.

Haykin, Simon. A comprehensive foundation
Prentice Hall International Editions, 1994.

Kröse , Ben y Van der Smagt, Patrick. An introduction to neural networks
The University of Amsterdam, 1996.

Hopfield, J.J. Neural networks and physical systems with emergent collective computational abilities;
Division of Chemistry and Biology, Institute of Technology, California, 1982.

Kartalopoulos, Stamatios V. Understanding neural networks and fuzzy logic, basic concepts and applications,
IEEE Press, Piscataway New Jersey. 1996.

Lau, Clifford. Neural networks, theoretical foundations and analysis .
IEEE Press. 1992.

CAPÍTULO II

DESPACHO DE CARGA ECONÓMICO

Introducción.

Para determinar la distribución económica de carga entre distintas unidades generadoras, los costos operacionales variables de la unidad deben expresarse en términos de la salida de potencias. El factor principal en las plantas de generación es el costo del combustible. Para cualquier condición de carga específica, el despacho económico determina la salida de potencia de cada central generadora o planta que minimizará el costo total de combustible necesario para alimentar la carga del sistema. La operación económica de un sistema de potencia es importante para poder recuperar y obtener los beneficios del capital que se ha invertido. La importancia de conservar el combustible y las tarifas que fijan las instituciones reguladoras a las compañías generadoras las obliga a buscar la máxima eficiencia del sistema.

La operación económica que involucra la generación de potencia y el suministro, se puede subdividir en dos partes: una, llamada despacho económico, que trata con el costo mínimo de producción de potencia y otra, la del suministro con pérdidas mínimas de la potencia generada a las cargas. Para cualquier condición de carga específica, el despacho económico determina la salida de potencia de cada central generadora o planta que minimizara el costo total de combustible necesario para alimentar la carga del sistema. El costo incremental de combustible se determina por las pendientes de las curvas de entrada-salida de las unidades generadoras.

El criterio que se debe seguir para que exista una distribución económica de la carga entre unidades dentro de una planta radica en el hecho que todas las unidades deben operar al mismo costo incremental de combustible. Las características de Entrada-Salida de las unidades generadoras conectadas a la red de transmisión son fundamentales para el problema de despacho económico de carga. En este capítulo, se discuten los modelos de estas características. Subsecuentemente, se presenta una formulación matemática del problema de despacho económico.

2.0 Distribución de Carga entre plantas generadoras.

Para determinar la distribución económica de carga entre plantas se necesitara considerar las perdidas en las líneas de transmisión. Aunque el costo incremental de combustible en la barra de una planta puede ser mas bajo que el de otra planta para una distribución de carga dada entre las plantas, la planta con el costo incremental mas bajo en su barra puede estar mucho mas alejada del centro de carga. Las perdidas de transmisión desde la planta

que tiene el costo incremental mas bajo pueden así ser tan grandes que la economía determinaría reducirle la carga a la planta con el costo incremental bajo e incrementar la de la planta con el costo incremental mas alto. Así, se necesitan coordinar las perdidas por transmisión para la programación de salida de cada planta, de manera que se tenga la máxima economía a un nivel dado de la carga del sistema.

Para un sistema de K unidades generadoras, se tiene que

$$f = f_1 + f_2 + f_3 + \dots + f_k = \sum_{i=1}^k f_i \quad 2.1$$

Donde f es la función de costo que da el costo total del combustible del sistema y es la suma de los costos de combustible de las unidades individuales f_1, f_2, \dots, f_k . La entrada total de potencia en megawatts a la red desde todas las unidades es la suma dada por

$$P_{g1} + P_{g2} + \dots + P_{gk} = \sum_{i=1}^k P_{gi} \quad 2.2$$

Donde $P_{g1}, P_{g2}, \dots, P_{gk}$ son las salidas individuales de las unidades que son alimentadas a la red. El costo total de combustible, f , del sistema es una función de todas las salidas de potencia de la planta. La ecuación de restricciones del valor mínimo de f esta dado por el balance de potencia de la ecuación

$$P_L + P_D - \sum_{i=1}^k P_{gi} = 0 \quad 2.3$$

Donde P_D es la potencia total recibida por las cargas y P_L es la perdida de transmisión del sistema. Nuestro objetivo es obtener una f mínima para una carga fija del sistema P_D , sujeta a la restricción de balance de potencia de la ecuación anterior.

2.1 Modelos de las características entrada-salida de las unidades generadoras.

La característica de un generador describe la relación entre la entrada total y la salida neta de la unidad. La entrada es la cantidad total de combustible suministrado a la unidad. La salida neta de la unidad es la potencia eléctrica activa neta disponible de la planta que suministra el servicio. La Figura 2.1 ilustra una característica típica de entrada-salida para una unidad generadora.




Figura 2.1. Característica entrada – salida de la Turbina de un generador-

La entrada total, mostrada en el eje de las ordenadas, se designa por H . La variable H se declara en GJ/h en este ejemplo, porque las unidades de H están dadas como el producto de las unidades para el valor calorífico del combustible utilizado, dado en MJ/kg, y la masa del flujo de combustible suministrado, dado en $t/h = 10^3 \text{ kg/h}$. La salida mostrada en la abscisa, marcada con P , es la potencia eléctrica activa neta en la salida de la unidad generadora, dada en MW. La suave curva que muestra esta característica puede ser modelada por una aproximación polinomial de la siguiente forma:

$$H(P_i) = a_i + b_i P_i + c_i P_i^2, \quad P_{imin} \leq P_i \leq P_{imax}, \quad 2.4$$

Las variables P_{imin} y P_{imax} denotan los límites mínimo y máximo del rango de salida respectivamente. El índice i se usa para indicar que se trata con la i -ésima unidad de la red.

2.2 Costo de generación.

Para obtener el costo de generación en función de la potencia eléctrica activa neta, $H_i(P_i)$ es multiplicada por el costo total de combustible C_i . El costo de combustible C_i se declara en CU/GJ donde CU se toma como el costo ficticio del combustible del generador. El costo de la generación esta dado por:

$$F_i(P_i) = H_i(P_i) \times C_i \quad 2.5$$

El costo de generación $F_i(P_i)$ está dado en CU/h.

2.3 Formulación Matemática del Despacho Económico de Carga.

Consideraremos un sistema de N unidades de generación conectadas a la red de transmisión. La optimización en el despacho de carga económico busca encontrar el punto de operación más económico de N unidades conectadas al sistema por medio de la minimización del costo total de generación:

$$F_G = \sum_{i=1}^N F_i(P_i) \quad 2.6$$

Sujeto a las siguientes restricciones o limitantes:

Balance de Potencia.

$$D + L = \sum_i P_i \quad 2.7$$

Donde C es el costo total, a_i , b_i y c_i son los coeficientes del generador “ i ” (de la función $F_i(P_i)$ que aparece en la ecuación (3.18); P_i es la potencia generada por el generador “ i ”.

L representa a las pérdidas de transmisión, las cuales se pueden representar por la ecuación:

$$L = \sum_i \sum_j \beta_{ij} P_i P_j \quad 2.8$$

Donde β_{ij} es el coeficiente de pérdidas de transmisión.

Potencias de generación máximas y mínimas.

La potencia de generación de cada unidad debe estar entre los límites máximo y mínimo. Esto es:

$$P_{imin} \leq P_i \leq P_{imax} \quad 2.9$$

En donde P_{imin} y P_{imax} denotan los límites de potencia mínimo y máximo respectivamente

CONCLUSIONES DEL CAPITULO II

- El factor principal en las plantas de generación es el costo del combustible.
- Para cualquier condición de carga especifica el despacho económico determina la salida de potencia de cada central generadora que minimizara el costo total de combustible necesario para alimentar la carga del sistema.
- El criterio que se debe seguir para que exista una distribución económica de la carga entre unidades dentro de la planta, es que todas las unidades deben operar al mismo costo incremental de combustible.
- Cuando se considera la distribución económica de carga entre plantas, se vuelve necesario considerar las perdidas en las líneas de transmisión.
- Para obtener el costo de generación en función de la potencia eléctrica, $H_i(P_i)$ es multiplicada por el costo total de combustible C_i .
- Los parámetros β_{ij} , son los coeficientes de perdidas de transmisión y representan la parte física del sistema, el calculo de estos parámetros por operaciones matriciales representan una gran dificultad al hacer la aplicación de software.
- Para el calculo del Despacho Económico de Carga será necesario partir del hecho que el flujo de carga ya ha sido encontrado previamente y por lo cual los valores de corrientes se conocen.

REFERENCIAS BIBLIOGRÁFICAS

Grainger, John J. y Stevenson Jr, William D. Análisis de sistemas de potencia
Mc Graw Hill, 1996.

Kai ,Strunz; Object oriented implementation of a genetic algorithm based approach to economic dispatch of power systems ;
Brunel University Uxbridge, 1996.

Kirchmayer, Leon K. ; Economic operation of power systems;
John Wiley & Sons; 1958.

CAPÍTULO III

RED NEURONAL HOPFIELD EN EL DESPACHO DE CARGA ECONÓMICO

Introducción.

El presente capítulo presenta la formulación teórica utilizada en el planteamiento de una solución al despacho de carga económico por medio de una red neuronal Hopfield. Inicialmente se muestra el funcionamiento y ecuaciones de los modelos binario y continuo de la red que se está considerando. Luego hay un apartado en el cual se describen los dos procesos de actualización que se pueden emplear en una red neuronal, ya que es un factor que influye, en gran medida, en la dirección de convergencia de la red. La parte central del capítulo es la presentación del algoritmo matemático de optimización que se emplea con la red neuronal Hopfield, demostrando como mapear en la ecuación de energía estándar de la red, las restricciones impuestas por el despacho de carga económico. Finalmente se presenta la solución completa al problema considerando un problema sin pérdidas en las líneas y otro con pérdidas, las cuales son un factor físico inherente a cualquier red de potencia que se estudie.

3.0 Modelo binario de la red neuronal Hopfield

El modelo original de esta red utilizaba una neurona de dos estados con umbral¹⁷, el cual seguía un algoritmo probabilístico. Cada neurona o elemento de procesamiento “i” tenía dos estados con valores V_i^0 y V_i^1 los cuales podían tomarse como 0 y 1 respectivamente. La salida de cada neurona viene de dos fuentes, entradas externas I_i y entradas de otras neuronas V_j . La entrada total a la neurona i está dada por:

$$U_i = \sum_{j \neq i} T_{ij} V_j + I_i \quad 3.1$$

Donde:

U_i es la entrada total en la neurona i.

T_{ij} es el peso de Interconexión sináptico de la neurona j a la neurona i

¹⁷ Potencial presente en la polarización de la neurona

I_i : es la entrada externa a la neurona i

V_j : es la salida de la neurona j .

En este modelo cada neurona muestrea su entrada en forma aleatoria. Esto cambia el valor de sus entradas o los fija de acuerdo a una "regla de umbral" con valores θ_i :

$$V_i = V_i^0 \text{ si } U_i < \theta_i \text{ y } V_i = V_i^1 \text{ si } U_i > \theta_i \quad 3.2$$

Donde:

θ_i : Umbral de la neurona i

La función de energía en la red Hopfield se define como:

$$E = -1/2 \sum_{j \neq i} \sum T_{ij} V_i V_j - \sum_i I_i V_i + \sum_i \theta_i V_i \quad 3.3$$

El cambio ΔE en E debido al cambio de estado en la neurona i por ΔV_i es:

$$\Delta E = - \left[\sum_{j \neq i} T_{ij} V_j + I_i - \theta_i \right] \Delta V_i \quad 3.4$$

Donde ΔV_i es el cambio en la salida de la neurona i .

Suponga que la entrada U_i de la neurona i es mayor que el umbral. Esto provocará que los términos entre corchetes de la Eq. (3.4) sean positivos y, de las ecuaciones (3.1) y (3.2), la salida en la neurona i cambia en una dirección positiva. Lo que significa que ΔV_i es positivo, y ΔE negativo; por tanto la energía de la red decrece. Similarmente, cuando U_i es menor que el umbral, se puede ver que ΔE también es negativo.

Las dinámicas del sistema siguen esta regla asíncrona simple (actualización asíncrona, la cual será vista más adelante): un elemento elegido al azar evalúa sus entradas, y cambia de estado dependiendo si la suma de sus entradas está por arriba o por debajo del umbral.

Al examinar la ecuación de energía nos damos cuenta que un cambio de estado nos lleva a un decrecimiento de la energía y eventualmente a la estabilidad de la red.

3.1 Modelo continuo de la red neuronal Hopfield

El modelo continuo determinístico¹⁸ de red neuronal Hopfield esta basado en variables y respuestas continuas, pero retiene todos los comportamientos principales del modelo original.

La variable de salida V_i para la neurona i puede estar en el rango $V_i^0 \leq V_i \leq V_i^1$ y la función que relaciona la entrada¹⁹ con la salida es continua y monótona creciente.

La función típica que relaciona la entrada con la salida, $g_i(U_i)$, es una función sigmoideal tal como se muestra en la figura siguiente:




Figura 3.1 Función Sigmoideal

Las dinámicas²⁰ de la neurona están definidas por la siguiente relación:

$$\frac{dU}{dt} = \sum_{j \neq i} T_{ij} V_j + I_i \quad 3.5$$

¹⁸ Modelo que obedece a una distribución normal

¹⁹ La entrada de la neurona es la suma de todas las entradas previamente multiplicadas por los pesos respectivos.

²⁰ Cambios diferenciales con respecto al tiempo de la entrada

Donde.

$V_i = g_i(U_i)$ es el valor de salida de la neurona i

$$g_i(U_i) = 1/(1 + \exp(-U_i/U_0))$$

g_i : es la función de entrada salida de la neurona i (ver figura 3.1)

U_0 : Es un coeficiente que determina la forma de la función sigmoideal.

La función de energía para la red Hopfield continua se define similarmente como :

$$E = -1/2 \sum_i \sum_j T_{ij} V_i V_j - \sum_i I_i V_i \quad 3.6$$

y su derivada con respecto al tiempo esta dada por:

$$\frac{dE}{dt} = -1/2 \sum_i \sum_j T_{ij} \left[V_j \left(\frac{dV_i}{dt} \right) + V_i \left(\frac{dV_j}{dt} \right) \right] - \sum_i I_i \left(\frac{dV_i}{dt} \right) \quad 3.7$$

$$\frac{dE}{dt} = -1/2 \sum_i \left(\frac{dV_i}{dt} \right) \left[\sum_j (T_{ij} V_j + T_{ji} V_i) + 2I_i \right] \quad 3.8$$

$$\frac{dE}{dt} = -1/2 \sum_i \left(\frac{dV_i}{dt} \right) (2 \sum_j T_{ij} V_j + 2I_i) \quad 3.9$$

$$\frac{dE}{dt} = - \sum_i \left(\frac{dV_i}{dt} \right) (\sum_j T_{ij} V_j + I_i) \quad 3.10$$

$$\frac{dE}{dt} = - \sum_i \left(\frac{dV_i}{dt} \right) \left(\frac{dU_i}{dt} \right) \quad 3.11$$

$$\frac{dE}{dt} = - \sum_i g_i'(U_i) \left(\frac{dU_i}{dt} \right)^2 \quad 3.12$$

De esto podemos ver que dE/dt siempre es menor que cero porque g_i es una función monótona creciente. Por lo tanto la solución de la red se mueve en la misma dirección en que la energía decrece. La solución busca un mínimo para E y se detiene al llegar a ese punto

3.2 Actualización de las Neuronas en la red Hopfield.

Cuando hablamos de “actualización” en una red de neuronas artificiales nos referimos a la metodología que se emplea en la obtención de los potenciales respuesta²¹ en cada unidad neuronal que tiene la red. El proceso de actualización afecta significativamente la respuesta colectiva de la red ya que influye en la convergencia y oscilación de la misma. Hay dos procesos actualización: asíncrono y síncrono.

3.2.1 Actualización asíncrona.

En este caso se obtienen los estados estables de la red por medio de un proceso serial en el cual se elige una neurona de la red (secuencialmente o al azar) y se actualiza hasta que alcanza su estado estable, esto significa que las demás neuronas cambiarán sus salidas en respuesta a las entradas de otras neuronas y la salida de la “neurona a estabilizar”. Una vez que la neurona en cuestión no cambia su valor de salida con actualizaciones sucesivas, se repite el proceso con otras neuronas de la red.

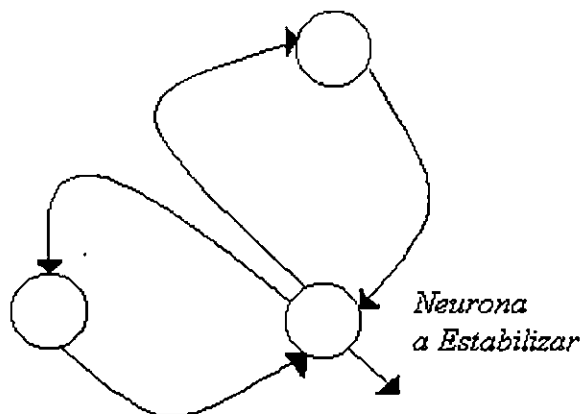


Figura 3.2 Actualización asíncrona

A pesar de que esta forma de actualización puede insertar un retardo en la convergencia global de la red es uno de los métodos más utilizados en el campo de la redes neuronales.

3.2.2 Actualización Síncrona

Esta forma de actualización explota la propiedad de interconectividad paralela presente en la red Hopfield, ya que todas las neuronas de la red alcanzan la estabilidad casi simultáneamente, lo cual reduce el tiempo de respuesta de la red, el cual comienza con la

²¹ Potenciales de salida de la neurona

inicialización de las neuronas en la red y finaliza cuando se alcanza el estado de mínima energía.

Básicamente el procedimiento que se emplea consiste en inicializar la red con un estado cualquiera en un tiempo "t", luego se actualizan las neuronas una a una en el tiempo "t+1" considerando que sus entradas provienen de las salidas de las otras neuronas y tienen los valores del tiempo "t". En otras palabras la respuesta de una neurona actualizada en el tiempo "t+1" no afecta la salida de ninguna otra neurona de la red en ese instante, pero sí lo hará en "t+2".

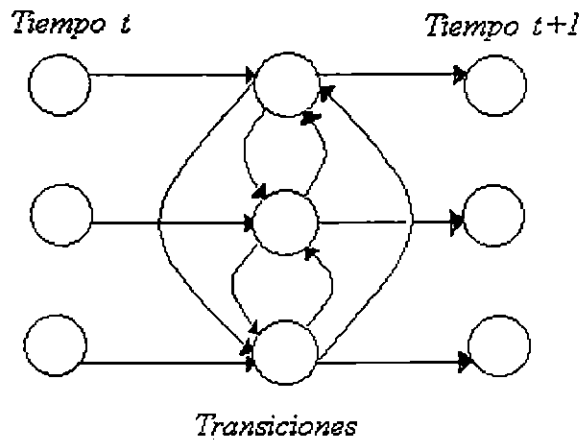


Figura 3.3 Actualización síncrona

3.3 Mapeo del ELD en la red de Hopfield.

En sistemas de potencia, el costo de operación cada vez necesita ser minimizado por medio del despacho económico de carga ELD.

Tradicionalmente, la función de costo de cada generador ha sido representada aproximadamente por una función de costo cuadrática simple. Prácticamente, las condiciones de operación de muchas unidades generadoras requieren que la función de costo de generación sea representada como funciones cuadráticas segmentadas inteligentemente. Por consiguiente, es más realista representar la función costo como una función costo cuadrática segmentada.

Desde que Hopfield introdujo en 1982 y 1984, la red neuronal Hopfield han sido usadas en muchas aplicaciones diferentes. Una propiedad importante de la red neuronal Hopfield es el decremento en energía por cantidad finita siempre que hay cualquier cambio en las entradas. Así, la red neuronal Hopfield puede ser usada para optimización. Tank y

Hopfield describieron como varios problemas de optimización pueden ser rápidamente resueltos por redes interconectadas en gran magnitud de un simple procesador análogo, el cual es una implementación de la red neuronal Hopfield. Park y otros presentaron el despacho económico de carga por funciones de costo cuadráticas segmentadas, usando la red neuronal Hopfield. Los resultados de este método fueron comparados muy bien con los métodos numéricos en una aproximación jerárquica. King y otros aplicaron la red neuronal Hopfield en economía y despacho ambiental de sistemas de potencia eléctricos. Estas aplicaciones, sin embargo, envuelven un gran número de iteraciones y a menudo muestran oscilaciones durante los transitorios. Esto indica una necesidad para el mejoramiento en la convergencia a través de una aproximación adaptiva, tal como la razón de aprendizaje adaptivo, método desarrollado por Ku y Lee, para una red neuronal recurrente diagonal.

3.3.1 Despacho Económico de Carga (ELD).

El problema ELD es encontrar la combinación óptima de generación de potencia que minimice el costo total mientras se satisface la demanda total.

La función de costo de ELD es definida como:

$$C = \sum_i C_i(P_i) \quad 3.13$$

$$C_i(P_i) = [a_i + b_i P_i + c_i P_i^2] \quad 3.14$$

Donde:

$C_i(P_i)$: Costo del $i^{\text{ésimo}}$ generador.

P_i : Potencia de salida del generador i

a_i, b_i, c_i : Coeficientes de costo del $i^{\text{ésimo}}$ generador.

Para minimizar el costo total, las limitantes de balance de potencia y límites de potencia deben ser satisfechas:

3.3.2 Balance de Potencia.

El total de potencia generada tiene que ser igual a la suma de la carga demandada más las pérdidas en las líneas de transmisión.

$$D + L - \sum_i P_i = 0 \quad 3.15$$

donde:

D: carga total.

L: pérdidas de transmisión.

Las pérdidas de transmisión pueden ser representadas por el método del coeficiente B como:

$$L = \sum_i \sum_j P_i \beta_{ij} P_j \quad 3.16$$

donde:

β_{ij} coeficientes de pérdida de transmisión.

3.3.3 Límites de Potencia Máxima y Mínima.

La generación de potencia de cada generador debe estar colocada entre el límite máximo y el límite mínimo, esto es:

$$\underline{P}_i \leq P_i \leq \overline{P}_i \quad 3.17$$

donde:

\underline{P}_i : Es la potencia de generación mínima de cada unidad generadora.

\overline{P}_i : Es la potencia de generación máxima de cada unidad generadora.

3.3.4 Mapeado del ELD dentro de la Red Neuronal Hopfield.

Para resolver el problema ELD, la siguiente función de energía es definida al combinar la función objetivo:

$$C = \sum_i (a_i + b_i P_i + c_i P_i^2) \quad 3.18$$

con la limitante:

$$D + L = \sum_i P_i \quad 3.19$$

quedando:

$$E = A(D + L - \sum_i P_i)^2 / 2 + B \sum_i (a_i + b_i P_i + c_i P_i^2) / 2 \quad 3.20$$

donde : $A \geq 0$ y $B \geq 0$, son los factores de pesos.

La fuerza sináptica y la entrada externa son obtenidos por el mapeo de la función de energía anterior dentro de la función de energía de Hopfield.

$$E = -\frac{1}{2} \sum_i \sum_j T_{ij} V_i V_j - \sum_i I_i V_i \quad 3.21$$

Primero asumiremos que las pérdidas L son una constante, la ecuación (3.20) es expandida y comparada con la ecuación (3.21) en la cual V_i y V_j corresponden a P_i y P_j respectivamente. Comparando con la ecuación (3.21), las fuerzas sinápticas y entradas externas de la neurona “ i ” en la red de Hopfield están dadas por (el desarrollo de esta ecuación está en el apartado 3.7):

$$\begin{aligned} T_{ij} &= -A - Bc_i \\ T_{ij} &= -A \\ I_i &= A(D + L) - Bb_i / 2 \end{aligned} \quad 3.23$$

Donde la diagonal de pesos es no cero. Esto se convierte en la siguiente regla de actualización sincrona:

$$\begin{aligned} U_i(k) - U_i(k-1) &= \sum_j T_{ij} V_j(k) + I_i \\ V_i(k+1) &= gi[U_i(k)] \end{aligned} \quad 3.24$$

A diferencia del modelo asíncrono, el modelo síncrono tiene tantos puntos fijos como ciclos límite atrayentes tenga. Sin embargo esto no converge a un mínimo local tan fácilmente como el modelo asíncrono. Hay ventajas adicionales de el modelo síncrono como son el ahorro en tiempo de calculo y de hardware. La función sigmoideal (3.24) puede ser modificada para reunir los limites de las limitantes como sigue:

$$V_i = g_i(U_i) = (\bar{P}_i - \underline{P}_i) / (1 + \exp(-U_i / u_0)) + P_i \quad 3.25$$

3.4 Algoritmo de Solución del ELD con la Red Neuronal de Hopfield

Ya que hemos encontrado la ecuación de Energía de Hopfield mapeando el ELD dentro de ella se prosigue con el algoritmo para encontrar las potencias de salida de cada uno de los generadores o las fuentes generadoras.

Para ello usamos el modelo de transición sincrona diferencial, que es el que se usa en calculo para esta red neuronal Hopfield, esto es:

$$\begin{aligned} U_i(k) - U_i(k-1) &= \sum_j T_{ij} V_j(k) + I_i \\ V_i(k+1) &= g_i(U_i(k)) \end{aligned} \quad 3.24$$

Procederemos a encontrar el valor de salida de P_i para esta red Hopfield, se tendrá en cuenta que $V_i(k+1)$ representa a las potencias de cada uno de los generadores. El algoritmo a seguir y el cual ha sido aplicado al programa para resolver el despacho económico es el siguiente:

Se introducen los parámetros de potencia mínima y potencia máxima de cada una de las unidades generadoras, con esto nos aseguramos que la potencia de generación encontrada esté en el rango válido. Se introducen las funciones de costo de cada una de las unidades generadoras:

$$C_i = a_i + b_i P_i + c_i P_i^2$$

Los parámetros a_i , b_i , c_i , son los coeficientes de costo del generador i -ésimo, y esta función de costo es la que se pretende optimizar.

Se debe conocer también cuanto es la demanda (D) que el sistema tiene, siendo esta la carga total del sistema de potencia.

La similitud que observamos de la red Hopfield con la ecuación de energía nos da:

$$\begin{aligned} T_{ij} &= -A - Bc_i \\ T_{ij} &= -A \\ I_i &= A(D + L) - Bb_i / 2 \end{aligned} \tag{3.23}$$

Los parámetros T_{ii} y T_{ij} deben ser tomados en consideración ya que si se obvia uno de ellos los resultados obtenidos serán errados y dentro del algoritmo de solución ambos deben de ir especificados y validados.

Se utiliza una función sigmoideal modificada con el fin de limitar la potencia de salida a sus extremos mínimos y máximos, con lo cual se tendrán de una sola vez los valores reales de salida.

$$V_i = g_i(U_i) = (\bar{P}_i - \underline{P}_i) / (1 + \exp(-U_i / u_0)) + \underline{P}_i \tag{3.25}$$

Realizamos las iteraciones necesarias hasta que las condiciones siguientes sean satisfechas:

Que ΔU_i se mantenga sin cambio alguno,

Que la $D + L = \sum_i P_i$, si las pérdidas no están incluidas ellas son cero.

Que los valores encontrados de los factores de peso A y B sean mayores o iguales a cero.

Cuando se cumplen estas condiciones aseguramos que la solución encontrada por la ecuación (3.25) es el mínimo óptimo y el despacho económico de carga se ha realizado satisfactoriamente.

Debido al algoritmo síncrono todo este proceso se debe hacer en forma paralela para los n generadores que existan, de allí la complejidad del desarrollo del algoritmo de solución y la razón de usar C++ como un lenguaje potente para la implementación.

3.4.1 Introducción de la Perdidas en el algoritmo de solución.

Para mapear y resolver el problema de ELD incluyéndole las perdidas del sistema se sigue el mismo procedimiento expuesto anteriormente con la diferencia que ahora el factor de la suma de las entradas externas se ve afectado por:

$$I_i = A(D+L) - Bb_i / 2 \quad 3.26$$

En donde el factor de perdidas L ya no se considera como una cantidad constante o en una dado caso despreciable sino que L estará variando conforme varían las potencias de los generadores encontradas en cada una de las actualizaciones de los pesos, hasta encontrar el valor de generación óptimo. Así las perdidas L vendrán dadas por:

$$L = \sum_i \sum_j \beta_{ij} P_i P_j \quad 3.27$$

En donde el factor β_{ij} son los coeficientes de perdidas encontrados por flujo de carga y el método presentado por Kirchmayer. Estos coeficientes dependerán siempre del sistema.

Las perdidas son calculadas para cada actualización, se calculan los valores de Potencia de cada generador y se procede a cumplir las limitantes explicadas anteriormente, una vez estas son satisfechas por la propiedad de la red Hopfield de su mínima energía se ha encontrado su mínimo óptimo.

3.5 Desarrollo de la ecuación de energía y mapeo del ELD.

Ecuación de energía de la red de Hopfield.

$$E = -\frac{1}{2} \sum_i \sum_j T_{ij} V_i V_j - \sum_i I_i V_i \quad 3.28$$

El mapeo se desarrollara en una función cuadrática para encontrar el punto óptimo de la parábola.

$$E = \frac{1}{2} A(D+L - \sum_i P_i)^2 + \frac{1}{2} B \sum_i (a_i + b_i P_i + c_i P_i^2)$$

$$E = \frac{A}{2} (D+L)^2 - A \sum_i P_i (D+L) + \frac{A}{2} (\sum_i P_i)^2 + \frac{B}{2} \sum_i (a_i + b_i P_i + c_i P_i^2)$$

$$E = \frac{A}{2} (D+L)^2 - \sum_i [A(D+L) - \frac{Bb_i}{2}] P_i + \frac{B}{2} \sum_i a_i + \frac{A}{2} (\sum_i P_i^2 + \sum_{i \neq j} P_i P_j) + \frac{B}{2} \sum_i c_i P_i$$

$$E = \frac{A}{2} (D+L)^2 + \frac{B}{2} \sum_i a_i + \sum_i [-A(D+L) + \frac{Bb_i}{2}] P_i + \sum_i \sum_i P_i P_i \frac{(A+c_i B)}{2} + \frac{A}{2} \sum_{i \neq j} P_{ij}$$

$$E = -(\frac{A}{2} (D+L)^2) - (\frac{B}{2} \sum_i a_i) + \sum_i [A(D+L) - \frac{Bb_i}{2}] P_i + \sum_i \sum_i P_i P_i \frac{-A-c_i B}{2} - \frac{A}{2} \sum_{i \neq j} P_{ij}$$

Comparando la Ecuación anterior con la ecuación 3.28 vemos que:

$$T_{ii} = -A - c_i B \quad 3.29$$

$$T_{ij} = -A \quad 3.30$$

$$I_i = A(D+L) - \frac{Bb_i}{2} \quad 3.31$$

Los cuales son los pesos y el umbral de la red neuronal Hopfield cuando se mapean las funciones de costo y las restricciones de potencia.

CONCLUSIONES DEL CAPITULO III

- El conocimiento de los modelos básicos de la red Hopfield nos ayuda a comprender la dinámica de la red, cuando es objeto de estudio una aplicación determinada.
- Varias propiedades de la respuesta que se obtendrá en la red neuronal Hopfield sin importar la aplicación en la cual esté siendo utilizada dependerá del tipo de actualización que se decida utilizar
- El gradiente de la ecuación de energía de la red Hopfield presenta un comportamiento monótono decreciente, lo que implica que la red tiende a un mínimo, esto convierte a la red en una herramienta de optimización.
- La función de costo de cada generador ha sido representada tradicionalmente por una función de costo cuadrática simple, pero en la práctica las condiciones de operación con muchas unidades generadoras requieren que la función de costo de generación sea representada por funciones cuadráticas segmentadas.
- La propiedad importante de la red neuronal de Hopfield es el decremento finito de energía siempre que haya cualquier cambio en las entradas, de allí que esta tiene su gran uso en problemas de optimización.
- Para minimizar el costo total, las restricciones de balance de potencia y límites de potencia deberán ser satisfechas.
- Para realizar el mapeo del problema ELD en una red neuronal de Hopfield es necesario combinar la función objetivo de costo con la restricción de demanda y potencia dentro de la ecuación de energía de una parábola.
- La ecuación resultante del mapeo es comparada con la función de energía de Hopfield para encontrar las fuerzas sinápticas y las entradas externas.
- La actualización de las neuronas termina hasta que se satisfacen las condiciones de que el gradiente de la energía de la red Hopfield se mantenga sin cambio, que la sumatoria de la demanda y las pérdidas sea igual a la sumatoria de las potencias de generación y que los factores de A y B sean mayores de cero, cuando esto se cumple se ha encontrado el óptimo.

REFERENCIAS BIBLIOGRÁFICAS

- Gurney, Karen. Neural nets 2
Human Sciences Department, Brunel University, 1997.
- Gurney , Karen. Neural networks a comprehensive foundation
Ph D. Thesis Dept. Electrical Engineering. Brunel University, Uxbridge, Middx, U.K., 1997.
- Grainger, John J. y Stevenson Jr, William D. Análisis de sistemas de potencia
Mc Graw Hill, 1996.
- Freeman, James A. y Skapura, David M. Redes neuronales, algoritmos, aplicaciones y técnicas de programación
Addison – Wesley, 1993.
- Kröse , Ben y Van der Smagt, Patrick. An introduction to neural networks
The University of Amsterdam, 1996.
- Hopfield, J.J. Neural networks and physical systems with emergent collective computational abilities.
Division of Chemistry and Biology, Institute of Technology, California, 1982.
- Lee, Kwang Y.; Sode-Yome, Arthit Park, June Ho. Adaptive hopfield neural networks for economic load dispatch.
Departments of Electrical Engineering of The Pennsylvania State University and Pusan National University. 1997.
- King, T. Denise; El – Hawary, E. y El – Hawary, Ferial. Optimal environmental dispatching of electric power systems via improved hopfield neural network model.
Technical University of Nova Scotia. 1995.
- Park, J.H; Kim, Y. S; Lee K.Y. Economic load dispatch for piecewise quadratic cost function using hopfield neural network .
Pusan National University. 1993.
- Kai ,Strunz; Object oriented implementation of a genetic algorithm based approach to economic dispatch of power systems ;
Brunel University Uxbridge; 1996.
- Kirchmayer, Leon K. ; Economic operation of power systems;
John Wiley & Sons; 1958.

CAPITULO IV

EJEMPLOS DE APLICACIÓN

Introducción.

En este capítulo se pretende demostrar como el algoritmo del modelo de Hopfield es tan preciso y eficiente como los viejos modelos matemáticos. El despacho económico de carga será resuelto emulando el comportamiento de la red neuronal Hopfield por medio de un programa de consola compilado en C++ versión 5.0 en el Sistema Operativo Windows. Por estar escrito en C++ puede ser compilado y corrido en el Sistema Operativo Linux de gran auge hoy en día. Varias pruebas han sido realizadas para analizar la habilidad del programa en la solución del problema de despacho económico.

En el primer problema se investiga el desempeño del modelo de Hopfield en un sistema de tres generadores sin pérdidas en las líneas, y los resultados obtenidos son comparados con el método clásico de optimización del despacho económico. El segundo ejemplo da la solución a un problema de cuatro buses, considerando pérdidas en las líneas. El tercer ejemplo muestra el desarrollo del despacho económico para un sistema de 10 unidades generadoras con y sin pérdidas.

En cada ejemplo los resultados se plasman en tablas permitiendo la comparación de los métodos involucrados. Una corrida de prueba para cada problema es discutida más detalle.

4.0 Ejemplo de aplicación 1.

El siguiente conjunto de tres unidades generadoras es considerado:

Unidad 1: tipo de combustible Carbón.

Salida Mínima de Potencia: 150 MW,

Salida Máxima de Potencia: 600 MW,

Curva de Entrada-Salida:

$$\frac{H_1}{GJ/h} = 510.0 + 7.20 \frac{P_1}{MW} + 0.00142 \frac{P_1^2}{(MW)^2}$$

Unidad 2: tipo de combustible Aceite.

Salida Mínima de Potencia: 100 MW,

Salida Máxima de Potencia: 400 MW,

Curva de Entrada-Salida:

$$\frac{H_2}{GJ/h} = 310.0 + 7.85 \frac{P_2}{MW} + 0.00194 \frac{P_2^2}{(MW)^2}$$

Unidad 3: tipo de combustible Aceite.

Salida Mínima de Potencia: 50 MW,
Salida Máxima de Potencia: 200 MW,
Curva de Entrada-Salida:

$$\frac{H_3}{GJ/h} = 78.0 + 7.97 \frac{P_3}{MW} + 0.00482 \frac{P_3^2}{(MW)^2}$$

Para el momento se asumen los siguientes costos de combustibles:

Costo de Combustible de la Unidad 1: $C_1 = 1.1 \text{ CU/GJ}$,
Costo de Combustible de la Unidad 2: $C_2 = 1.0 \text{ CU/GJ}$,
Costo de Combustible de la Unidad 3: $C_3 = 1.0 \text{ CU/GJ}$.

De acuerdo al la ecuación (2.3), los costos de generación serán evaluados por:

$$F_i(P_i) = H_i(P_i) \times C_i, \quad i, \in \{1,2,3\} .$$

Las funciones de costo dentro de los rangos de salida especificados son entonces:

$$\frac{F_1(P_1)}{(CU/h)} = 561.0 + 7.92 \frac{P_1}{MW} + 0.00156 \frac{P_1^2}{(MW)^2}, \quad 100 \leq \frac{P_1}{MW} \leq 600$$

$$\frac{F_2(P_2)}{(CU/h)} = 310.0 + 7.85 \frac{P_2}{MW} + 0.00194 \frac{P_2^2}{(MW)^2}, \quad 100 \leq \frac{P_2}{MW} \leq 400$$

$$\frac{F_3(P_3)}{(CU/h)} = 78.0 + 7.97 \frac{P_3}{MW} + 0.00482 \frac{P_3^2}{(MW)^2}, \quad 50 \leq \frac{P_3}{MW} \leq 250$$

Ahora el punto de operación mas económico para una demanda de carga supuesta de $D = 850 \text{ MW}$ será determinada.

Resultado Método	P1 [MW]	P2 [MW]	P3 [MW]	Potencia total [MW]	Costo Total	Pérdidas
Método Numérico	393.2	334.6	122.2	850	8194.47	0
Método Neuronal	393.416	334.265	122.319	850	8194.36	0
Los valores de A y B apropiados son: 0.4 y 1.38778e-016 respectivamente						

Tabla 4.1 Resultados para el Problema 1.

El método numérico clásico de solución al despacho económico [Ref paper] lleva a los resultados mostrados en la primera fila de la Tabla 4.1, estos datos se pueden comparar con los que obtuvimos utilizando la red neuronal.

Un promedio de 10000 iteraciones se necesitaron para encontrar el valor óptimo. El alto grado de precisión alcanzado por la red neuronal en comparación con aquel dado por el método clásico revela que el costo total de generación es menor con el método de la red Hopfield.

4.1 Ejemplo de aplicación 2.

El problema que se desarrolla en este apartado se encuentra en libro Análisis de Sistemas de Potencia, específicamente en el ejemplo 13.3; el cual consiste de cuatro barras tal como se muestra en la figura 4.1 y tiene los datos de líneas y barras en la tabla 4.1. La tabla 4.2 muestra los resultados del flujo de carga asociado a este sistema. En la tabla 4.3 se presentan los datos de placa de los generadores. Se calculó el despacho económico de carga a través del método tradicional con ayuda de Mathcad 6.0²², y en el programa que emula el funcionamiento de la red neuronal Hopfield; los resultados se muestran en la tabla 4.4.

Comparando los datos obtenidos se observa que tenemos mejores resultados que los dados por el método tradicional.




Figura 4.1 Diagrama de potencia

²² Mathcad Release 6.0, MathSoft

Líneas	R	X	Y	Barra	Pg	Voltaje	Pc	Qc
1-4	0.00744	0.0372	0.0775	1	-	1.0 $\angle 0$	-	-
1-3	0.01008	0.0504	0.1025	2	3.18	1.0	-	-
2-3	0.00744	0.03712	0.0775	3	-	-	2.20	1.3634
2.4	0.01272	0.0636	0.1275	4	-	-	2.80	1.7352

Todos los valores están en por unidad sobre la base de 230KV y 100MVA

Tabla 4.2 Datos de líneas y barras del ejemplo 2

Barra	Generación		Voltaje	
	P	Q	Magnitud	Angulo
1	1.913152	1.872240	1.0	0
2	3.18	1.325439	1.0	2.4399
3	-	-	1.96051	-1.07932
4	-	-	0.94304	-2.62658
Total	5.093152	3.197679	(Base 230kV 100MVA)	

Tabla 4.3 Datos del flujo de carga en el ejemplo 2

Unidad	a	b	c	Pmin	Pmax
1	0	8	.004	100	625
2	0	6.4	.0048	100	625

Tabla 4.4 Datos de placa y funciones de costo en los generadores del ejemplo 2

Resultado Método	P1 [MW]	P2 [MW]	Potencia total	Costo Total	Pérdidas
Método Numérico	190.2204	319.1015	509.32	4197.51	9.32
Método Neuronal	186.429	322.631	509.06	4194.93	9.06

Tabla 4.5 Resultados del Despacho Económico de Carga por ambos métodos (Ej. 2).

4.2 Ejemplo de aplicación 3.

En este ejemplo se calcula el despacho económico para un sistema de 12 buses de los cuales 10 son de generación concentrándose la carga en los dos restantes (Figura 4.2). Los coeficientes de costo y las potencias mínimas y máximas de cada una de las unidades generadoras están dadas en la tabla 4.6, Las pérdidas en la líneas del sistema no son consideradas. El tiempo de simulación para encontrar la solución con ELD99 es pequeño, un promedio de 45 segundos. El ELD99 tiene la capacidad de leer desde ficheros escritos en modo texto, esto con el fin de evitar lo tedioso que puede ser estar ingresando los datos desde teclado cuando el sistema crece, como es el caso de este ejemplo en el cual solo la matriz de incidencia tiene 510 datos. Los ficheros están creados con nombres específicos que son los que reconoce el ELD99 así que deberán de tomarse en cuenta para la solución de otros problemas, los nombres validos se muestran en la tabla 4.5.

VARIABLE	NOMBRE DE FICHERO
Coefficientes de perdida	Beta.txt
Factor a de la función de costo	a.txt
Factor b de la función de costo	b.txt
Factor c de la función de costo	c.txt
Voltajes de Generación	Vgen.txt
Voltajes de Carga	Vcar.txt
Potencias de Generación	Sgen.txt
Impedancias de las líneas	Ye.prn
Potencias Máximas	Pmax.txt
Potencias Mínimas	Pmin.txt

Tabla 4.6 Nombres de Ficheros Validos

Los resultados del método neuronal y el método clásico se muestran en la tabla 4.7.

Coeficientes de costo			Límites de Potencia	
a	b	c	Pmin	Pmax
2.70E+01	-0.3975	2.18E-03	100	196
1.18E+02	-1.27E+00	4.19E-03	157	230
3.98E+01	-0.3116	1.46E-03	200	332
5.29E+01	-0.6348	2.76E-03	138	200
1.39E+01	-8.73E-02	1.07E-03	190	338
2.67E+02	-2.34E+00	5.94E-03	200	265
1.89E+01	-0.1325	1.11E-03	200	331
2.67E+02	-2.34E+00	5.94E-03	200	265
8.85E+01	-0.5675	1.55E-03	213	370
1.33E+01	-9.94E-02	1.10E-03	200	362

Tabla 4.7 Datos de placa y funciones de costo en los generadores del ejemplo 3

Potencias de Generación	Red Neuronal	Método Clásico
P1	191.482	193.2
P2	204.205	204.1
P3	259.267	259.1
P4	194.717	195.5
P5	249.222	249.0
P6	234.361	234.3
P7	260.388	260.1
P8	234.361	234.3
P9	325.41	325.3
P10	246.585	246.3
Potencia Total	2400	2401.2
Costo Total	487.273	488.50

Tabla 4.8 Resultados del Despacho Económico de Carga por ambos métodos (Ej. 3).

4.3 Ejemplo de aplicación 4.

Este ejemplo utiliza los mismos datos del problema anterior pero además considera las pérdidas en las líneas. Los datos de líneas y barras del sistema propuesto están mostrados en la tabla 4.8 y los datos de flujo de carga son mostrados en la tabla 4.9. El ELD99 calcula los coeficientes de pérdidas del sistema a partir de los valores de admitancias que caracterizan al sistema. Estos valores se ingresan de nuevo al ELD99 para encontrar el despacho económico de carga. Los coeficientes de pérdidas encontrados a través del ELD99 se muestran en la tabla 4.10 y las potencias y costos encontrados son mostrados en la tabla 4.11.

Líneas	Z	X	Y	Barra	Pg	Voltaje	Pc	Qc
1-2	50	-150	0.03	1		1	-	-
1-3	12.5	-37.5	0.025	2	220	0.98		-
1-8	16.67	-50	0.02	3	259	0.989	-	-
2-4	16.67	-50	0.02	4	195	0.97	-	-
2-5	25	-75	0.015	5	-	-	-11.05	-6.848
3-5	61.95	-70.8	0.01	6	-	-	-12.954	-8.028
3-9	49.72	-55.25	0.025	7	234	0.98	-	-
3-10	50	-150	0.028	8	280	0.985	-	-
4-6	15.59	-44.54	0.01	9	192	0.995	-	-
4-7	25.86	-60.34	0.025	10	234	0.98	-	-
6-7	100	-300	0.011	11	324	0.98	-	-
6-10	66.67	-133.3	0.011	12	246	0.99	-	-
7-12	6.897	-82.76	0.013	Todos los valores de Voltaje y Potencia están expresados en valores por unidad				
8-9	100	-200	0.025					
9-11	12.2	-109.8	0.029					
10-11	20	-60	0.027					
10-12	50	-150	0.01					

Tabla 4.9 Datos de líneas y barras del ejemplo 4

Barra	Generación		Voltaje	
	P	Q	Real	Imaginario
1	3.332	5.378	1.0	0
2	2.2	2.879	0.98	-0.019
3	2.59	7.534	0.989	-0.02
4	1.95	-1.469	0.97	-0.02
5			0.866	-0.097
6			0.952	-0.047
7	2.34	7.03	0.979	-0.037
8	2.8	-4.074	0.984	0.034
9	1.92	2.714	0.995	0.018
10	2.34	-0.349	0.98	-0.016
11	3.24	-3.719	0.98	0.021
12	2.46	1.487	0.99	-0.023
Total	(Base 230kV 100MVA)			

Tabla 4.10 Datos del flujo de carga en el ejemplo 4

Los coeficientes de perdidas son calculados y presentados en la tabla 4.10, siendo estos coeficientes los de la diagonal principal ya que son los que representan en si las perdidas del sistema.

Coeficientes de Perdidas
0.0001799
0.0001386
0.0002446
6.85E-05
0.0005632
8.47E-05
0.000123
3.85E-05
04.91E-05
1.73E-05

Tabla 4.11 Coeficientes de Perdida para el ejemplo 4

Finalmente tabulamos los resultados obtenidos por medio de ELD99, en la tabla 4.11 mostramos los valores de las potencias de cada una de las unidades generadoras y mostramos las perdidas obtenidas como también el costo total que este despacho de carga ha generado.

Potencias de Generación	Red Neuronal
P1	195.14
P2	208.797
P3	272.489
P4	198.728
P5	267.288
P6	237.607
P7	277.787
P8	237.607
P9	337.778
P10	264.028
Potencia Total	2497.25
Costo Total	532.197

Tabla 4.12 Resultados de Potencias de Generación obtenidos.

Vemos que las perdidas del sistema para este despacho económico son de 97.25 MW.

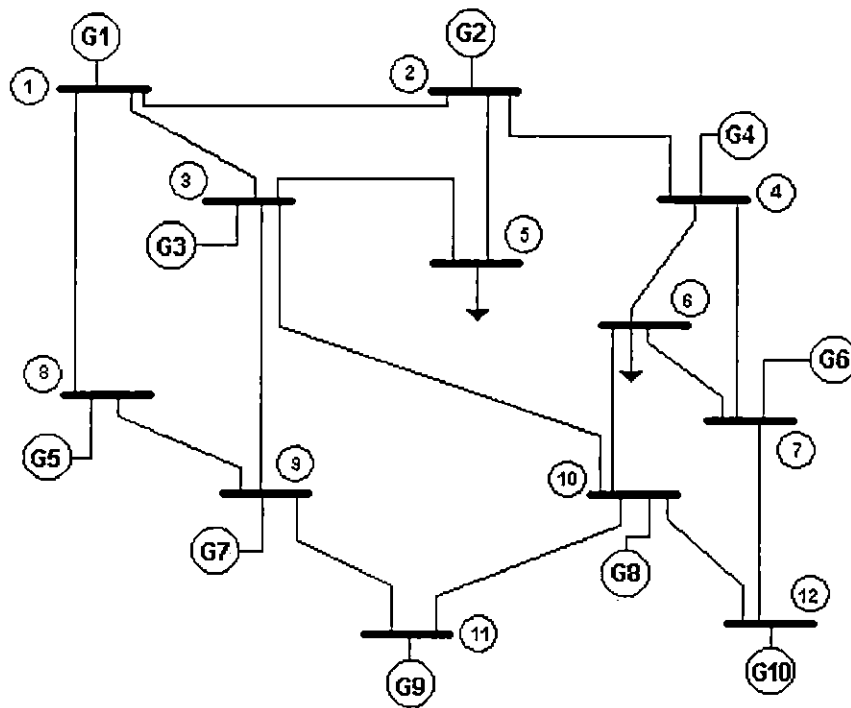


Figura 4.2. Diagrama del Sistema de Potencia del Ejemplo 3.

CONCLUSIONES DEL CAPÍTULO IV

- En todos los casos que se analizaron a lo largo del capítulo se demostró que la respuesta obtenida por parte de la red neuronal Hopfield utilizando el programa ELD99 encuentra un valor mínimo más preciso con relación a los métodos clásicos empleados para la resolución de l problema del despacho económico.
- La red neuronal Hopfield simplifica en forma significativa la mecánica de solución del despacho económico de carga por medio de un algoritmo sencillo de actualización sincrónico de las neuronas.
- La convergencia de la red depende, aparte de los valores de entrenamiento fijados al inicio del proceso iterativo, de las características de la red de potencia; ya que si el dominio de solución de la red es bastante plano tarda mas tiempo en estabilizarse. Mientras que si tiene un dominio más sinuoso (con crestas y valles pronunciados) la red converge rápidamente.
- Los coeficientes diagonales presentes en la matriz de pérdidas del sistema de potencia son los que representan significativamente las pérdidas, siendo menos importantes los que se encuentran fuera de la diagonal.
- Un factor crítico que influye en la funcionalidad de la red Hopfield son las bases del sistema de potencia, es decir que se debe trabajar con la misma base, ya que un error en los datos lleva a la oscilación descontrolada de la red neuronal.
- Los coeficientes A y B que están presentes en los pesos de la red deben ser mayores que cero, sin ser excesivamente grandes, ya que en la mayoría de los casos los valores encontrados por medio del entrenamiento fueron menores que uno. Valores altos llevan a oscilaciones inesperadas en la red, y retardan el tiempo de respuesta en la red.
- Se debe notar que en todos los casos la red neuronal Hopfield demostró arrojar costos de generación mas bajos, lo que la convierte en una herramienta útil en la distribución económica de energía.

REFERENCIAS BIBLIOGRÁFICAS

Cevallos , Javier. Programación orientada a objetos con C++
Addison Wesley Iberoamericana Rama Editorial, 1993.

Andrews, Mark. Aprenda visual c++ ya
Mc. Graw Hill, 1997.

Kruginsky, David J. Programación avanzada con visual c++
Mc. Graw Hill, 1996.

Deitel, H.M. y Deitel , P.J. Cómo programar en C/C++
Prentice may, 1996.

Grainger, John J. y Stevenson Jr, William D. Análisis de sistemas de potencia
Mc Graw Hill, 1996.

Freeman, James A. y Skapura, David M. Redes neuronales, algoritmos, aplicaciones y técnicas de programación
Addison – Wesley, 1993.

Hopfield, J.J. Neural networks and physical systems with emergent collective computational abilities;
Division of Chemistry and Biology, Institute of Technology, California, 1982.

Lee, Kwang Y.; Sode-Yome, Arthit Park, June Ho: Adaptive hopfield neural networks for economic load dispatch.
Departments of Electrical Engineering of The Pennsylvania State University and Pusan National University. 1997.

King, T. Denise; El – Hawary, E. y El – Hawary, Ferial. Optimal environmental dispatching of electric power systems via improved hopfield neural network model.
Technical University of Nova Scotia. 1995.

Park, J.H; Kim, Y. S; Lee K.Y. Economic load dispatch for piecewise quadratic cost function using hopfield neural network .
Pusan National University. 1993.

Kai ,Strunz; Object oriented implementation of a genetic algorithm based approach to economic dispatch of power systems ;
Brunel University Uxbridge; 1996.

Kirchmayer, Leon K. ; Economic operation of power systems;
John Wiley & Sons; 1958.

CONCLUSIONES GENERALES Y RECOMENDACIONES

CONCLUSIONES

1. El método de optimización ocupando la red neuronal artificial de Hopfield, resulta ser más eficiente que cualquiera de los métodos tradicionales empleados para obtener la solución al despacho económico de carga.
2. Los pesos de la red neuronal Hopfield, cuando se utiliza en el problema de optimización que plantea el despacho económico de carga, son el resultado de una analogía matemática entre la ecuación de energía estándar de la red Hopfield y una ecuación de energía que tiene las restricciones del problema pesadas por operadores de Lagrange.
3. El estudio del despacho económico de carga es de vital importancia para las compañías generadoras de electricidad ya que les permite producir la energía necesaria para satisfacer la demanda y las pérdidas a un costo mínimo.
4. La emulación del comportamiento de las redes neuronales biológicas por medio de modelos abstractos como las redes neuronales artificiales le ha permitido a la ciencia aprovechar mucha de las características del cerebro humano: como el procesamiento paralelo de información, memoria asociativa, aprendizaje, etc.

RECOMENDACIONES

1. Incentivar estudios futuros en el campo de las redes neuronales y la lógica fuzzy, ya que estas pueden ser implementadas no solo en el área de potencia eléctrica, sino también en telecomunicaciones, procesamiento digital de señales y otras áreas de gran interés para la ingeniería eléctrica.
2. Proponer la infraestructura y diseño necesarios para que la red neuronal mostrada en este trabajo sea implementada en una planta de generación en nuestro país.
3. Se recomienda la implementación de una interface visual para el programa de la red neuronal propuesta, con el fin de crear un ambiente más amigable al usuario y mejorar la rapidez de procesamiento.
4. La biblioteca de la Facultad de Ingeniería y Arquitectura debe adquirir bibliografía sobre redes neuronales ya que durante el proceso de investigación no se encontró ningún libro que tratara el tema.
5. Se recomienda investigar nuevos métodos de optimización, como es el caso de los Algoritmos Genéticos los cuales tienen amplio auge en el campo de las ciencias.
6. Incluir en el programa de estudios de la carrera una materia electiva orientada al estudio del campo de las redes neuronales.