



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

ESCUELA NACIONAL DE ESTUDIOS PROFESIONALES

“ARAGON”

302ej
ATZ
30
BLIA:

FALLA DE ORIGEN

**REDES NERVIOSAS ARTIFICIALES:
SEXTA GENERACION DE COMPUTADORAS**

T E S I S
Que para obtener el Título de:
INGENIERO EN COMPUTACION
P r e s e n t a :
ALBERTO SAGRERO RODRIGUEZ

San Juan de Aragón Edo. de Méx.

1995



Universidad Nacional
Autónoma de México



UNAM – Dirección General de Bibliotecas Tesis Digitales Restricciones de uso

DERECHOS RESERVADOS © PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

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

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

**FALLA DE ORIGEN
EN SU TOTALIDAD**

A mi madre:

LILIA RODRIGUEZ VDA. DE SAGRERO

A la memoria de mi padre:

ING. ISIDRO SAGRERO HERNANDEZ

A mi hermana:

LILIA SAGRERO RODRIGUEZ

A la memoria de mi abuela:

GUADALUPE OROZCO PRECIADO

A la memoria de mi abuelo:

RODOLFO RODRIGUEZ VERDUGO

A mi tío:

LIC. ARMANDO RODRIGUEZ OROZCO

"No puedo cambiar la dirección del viento, pero si ajustar mis velas para llegar siempre a mi destino".

Dean, Jimmy.

"Jamás envidié la riqueza de un hombre, ni me sentí inferior a él. Sólo reconocí superioridad en quien me aventajaba en virtudes y conocimientos".

Diógenes.

"La mayoría de la gente se avergüenza de la ropa raída y de los muebles destartados, pero jamás se ruborizan de las ideas andrajosas y de las filosofías gastadas".

Einstein.

"La mayoría de nosotros preferimos ver hacia afuera, en lugar de hacia adentro de nosotros mismos; ya que en el segundo caso no vemos sino un hoyo negro, lo cual significa: nada".

Einstein.

"Todos los hombres que encuentro son superiores a mí en algún sentido; y en tal sentido puedo aprender de todos".

Emerson.

"Nadie conoce mejor los obstáculos, sus vueltas, recodos, trampas, riesgos, peligros y atajos del camino como quien lo ha recorrido".

Marden.

"El triunfo no está en el vencer siempre, sino en nunca desanimarse".

Napoleón.

"Es grande el hombre que reconoce sus errores, pero más grande es el que calla sus aciertos".

Pascal.

"El que quiere vencer un obstáculo, debe armarse de la fuerza de un león y de la prudencia de la serpiente".

Pindaro.

"Es mejor ser corregido por un sabio, que ser admirado por un necio".

Platón.

"Consideremos, además, que todo hombre puede ser, si se lo propone, "escultor de su propia cerebra", y que aun el peor dotado es susceptible, al modo de las tierras pobres, pero bien cultivadas y abonadas, de rendir copiosas mies".

Ramon y Cajal, Santiago.

"Como los árboles son las personas; unas dan sombra o fruto, y otras ni fruto ni sombra".

Twain, M.

"La rosa se ve hermosa en su vaso, mas uno se olvida de todo el trabajo de jardineria que ayudo a hacerla hermosa".

Yogananda.

"En el esfuerzo, como en el agua fria, hay que vencer la primera impresion".

"La flecha da en el blanco porque no se desvia de su camino".

"La gota horada la piedra no por su fuerza sino por su constancia".

"El hombre sabio aspira a la perfección; el hombre vulgar, al bienestar".

Aforismo.

"El que empieza un trabajo lleva la mitad adelantado".

Aforismo.

"El sabio lo espera todo de sus propios esfuerzos; el hombre vulgar lo espera todo del favor de los demás".

Aforismo.

"No temas ir despacio sólo teme no avanzar".

Aforismo.

"No envidies los meritos de otro, sino mejora tus propios talentos".

Del Archivo Tibetano.

"Pregunta lo que ignoras y pasarás por tonto cinco minutos; no lo preguntes, y serás tonto la vida entera".

Proverbio Chino.

"Mientras el tímido reflexiona, el valiente va, triunfa y vuelve".

Proverbio Griego.

"Los ríos hondos corren en silencio, los arroyos son ruidosos".

Proverbio Hindú.

"Llegamos a la sabiduría más a través del fracaso que del éxito".

Proverbio Japonés.

"Quien no quiera tener paciencia para instruirse y educarse, la tendrá que tener soportando la humillante desgracia de su propia ignorancia".

Sabiduría Árabe.

INDICE

Introducción.....	i
Capítulo 1: Historia de las Redes Nerviosas Artificiales.....	1
1. Historia del desarrollo de los sistemas nerviosos artificiales.....	2
1.1 Perspectivas para el futuro.....	17
1.2 El futuro.....	22
Capítulo 2: Redes Nerviosas Biológicas.....	25
2. La estructura del Sistema Nervioso Central.....	26
2.1 La neurona.....	26
2.2 La corteza cerebral.....	40
Capítulo 3: Conceptos fundamentales de las Redes Nerviosas Artificiales.....	50
3. Conceptos fundamentales de las redes nerviosas artificiales.....	51
3.1. Análisis Estadístico.....	63
3.1.1. Variable.....	65
3.1.2. Distribución Normal.....	66
Capítulo 4: Algoritmos de aprendizaje para redes nerviosas artificiales.....	68
4.1. Aprendizaje en redes nerviosas.....	69
4.2. Retropropagación de las redes.....	73
4.2.1. Flujo de activación hacia adelante.....	76
4.2.2. Flujo de error hacia atrás.....	80
4.2.3. La regla Delta generalizada.....	84
4.3. Aprendizaje competitivo Kohonen.....	87
4.3.1. Competencia dentro del aprendizaje.....	90
4.3.2. La regla de aprendizaje Kohonen.....	93

4.3.3.	Creación de modelos estadísticos.....	95
4.3.4.	El mapa topologicamente conservado.....	99
4.3.5.	Resultados prácticos.....	103
4.3.6.	Ventajas de la aplicación.....	106
4.4.	Aprendizaje outstar.....	107
4.4.1.	Grossberg y Pavlov.....	107
4.4.2.	Ley de Hebb.....	110
4.4.3.	Instars y outstars.....	112
4.4.4.	Ecuación de la actividad del instar.....	116
4.4.6.	La ley de aprendizaje.....	122
4.4.6.	El valor de las constantes.....	124
4.4.7.	Los outstars en acción.....	126
4.5.	La avalancha.....	131
4.5.1.	La ecuación de actividad del outstar.....	132
4.5.2.	Ecuación de aprendizaje del outstar.....	135
4.5.3.	Aprendizaje sencillo de la ruta del tiempo.....	137
4.5.4.	La avalancha.....	143
4.5.5.	La avalancha en operación.....	145
4.5.6.	Entrenando a la avalancha.....	149
4.5.7.	Ventajas de la avalancha.....	151
4.6.	Teoría del reforzamiento de la transmisión.....	153
4.6.1.	El outstar y Pavlov.....	155
4.6.2.	Teoría del reforzamiento de la transmisión.....	157
4.6.3.	Las ecuaciones.....	160
4.6.4.	Biológico y artificial.....	168
4.6.5.	Una simulación de frecuencia codificada.....	167
4.7.	Red de Resonancia Adaptiva.....	171
4.7.1.	Entablando una búsqueda.....	176

4.7.2.	Control de ganancia y la regla 2/3.....	181
4.7.3.	Aprendizaje autonomo.....	187
4.7.4.	Cuestiones prácticas.....	190
4.7.5.	Aprendizaje autónomo.....	192
Capítulo 5:	Aplicaciones de las redes nerviosas artificiales....	196
5.1.	Predicción de series de tiempo.....	197
5.1.1.	El mapa logístico.....	197
5.1.2.	Una ecuación diferencial retardada no lineal... ..	199
5.1.3.	Predicción no lineal de las series de tiempo ruidosas.....	203
5.2.	Aprendiendo a jugar Backgammon.....	205
5.3.	Predicción de la estructura secundaria de las proteínas.....	208
5.4.	NET-Talk: Aprendiendo a pronunciar texto en inglés....	212
5.5.	Otras aplicaciones.....	215
Bibliografía.....		223

INTRODUCCION

INTRODUCCION

El misterio del cerebro humano ha fascinado a científicos y filósofos de la misma forma por siglos. Descartes identificó nuestra habilidad para pensar como la piedra angular de la filosofía ontológica. Otros han tomado al cerebro humano como evidencia de la existencia de poderes supernaturales, o iguales a Dios. La investigación científica formal, la cual comenzó aproximadamente hace medio siglo, tiene parcialmente contestado algunas de las cuestiones más sencillas (como de qué manera el cerebro procesa la información visual), pero ha tocado escasamente otros más profundamente concernientes con la naturaleza de la conciencia y la posible existencia de características mentales transcendentales a la sustancia biológica del cerebro, frecuentemente encapsulado en el concepto de *mente*.

Una larga investigación —con la excepción de un periodo breve a principios de 1960— interesó a un grupo pequeño de científicos dedicados y esparcidos alrededor del mundo, la investigación de red nerviosa ha surgido en primera plana como un campo de investigación *de moda*. Mucha de esta oleada de atención resulta, no del interés en redes nerviosas como modelos del cerebro humano, sino en lugar de sus promesas para proveer soluciones a problemas técnicos de la *inteligencia artificial* que el acercamiento tradicional, basado en la lógica no produjo.

La veloz elevación a la celebridad también ha permitido la salida de una cantidad considerable de exageración de las virtudes de los modelos presentes de redes nerviosas.

2 FALLA DE ORIGEN

Incluso en las áreas de mas éxito de aplicación de las redes nerviosas, por ejemplo en la memoria de contenido direccionable (asociativo) y reconocimiento de ruta, relativamente poco ha sido aprendido lo cual seria nuevo para expertos en los varios campos. El problema realmente difícil, el reconocimiento invariante de la posición y la distorsión de rutas, no ha sido aun solucionados por las redes nerviosas de un modo satisfactorio, quizás todos conozcamos de experiencia que nuestros cerebros pueden hacerlo. De hecho, es difícil localizar con toda precisión cualquier problema técnico donde las redes nerviosas han sido mostrados a producir soluciones que son superiores a aquellos previamente conocidos. El argumento estándar, que las redes nerviosas pueden hacer cualquier cosa que una computadora tradicional pueda, pero no es necesario ser programada.

El reciente resurgimiento de interés en redes nerviosas tiene sus raíces en el reconocimiento que el cerebro ejecuta calculos de una manera diferente en que lo hacen las computadoras digitales convencionales. Las computadoras son extremadamente veloces y precisas para ejecutar secuencias de instrucciones que han sido formuladas para ellas. Un sistema de procesamiento de información humano está compuesto de neuronas pasando a velocidades aproximadamente un millón de veces mas lentas que las compuertas de las computadora. Aun, los humanos son mas eficientes que las computadoras para tareas de calculos complejos como el entendimiento del habla. Por otra parte, no solo humanos, sino incluso los animales,

pueden procesar información visual mejor que las computadoras más veloces.

Este trabajo introduce los fundamentos de los sistemas nerviosos artificiales. Mucha de la inspiración para tales sistemas viene de la Neurociencia.

El objetivo final de la investigación es procesar la información con una eficiencia comparable a aquel del cerebro.

Para llevar a cabo este objetivo de la investigación, necesitamos definir el enfoque del estudio de los sistemas nerviosos artificiales. Los sistemas nerviosos artificiales, o redes nerviosas, son sistemas celulares físicos los cuales pueden adquirir, almacenar, y utilizar conocimiento experimental. El conocimiento es dentro de la forma de estados estables o mapeos fijos dentro de las redes que pueden ser rellamados en respuesta a la presentación de ejemplos. Este trabajo enfoca los fundamentos de tales redes y ejemplos de aplicaciones.

Los fundamentos de los sistemas nerviosos artificiales son los asuntos principales de este trabajo. Los conceptos son introducidos gradualmente.

Las redes nerviosas artificiales han demostrado ser útiles en el proceso de señal y tareas de reconocimiento de ruta, aún para manejar problemas del mundo real las redes pueden ser aumentadas a escala o modularizarios, y pueden ser implementados en hardware. Las redes nerviosas artificiales estan basadas en gran parte de sus rutas de conexión, pero

tienen elementos procesadores muy sencillos o nodos.

CAPITULO 1: HISTORIA DE LAS REDES NERVIOSAS ARTIFICIALES.

1. Historia del desarrollo de los sistemas nerviosos artificiales.

Las computadoras convencionales procesan información en *serie*, esto es, efectúan una instrucción después de otra. Como consecuencia, la mayor parte de la computadora y de sus periféricos están ociosos gran parte del tiempo mientras esperan instrucciones del procesador central. Con el objeto de acelerar este proceso, han sido diseñadas grandes máquinas, llamadas supercomputadoras, cuyo propósito es llevar a cabo el procesamiento de la información *en paralelo*. (Constan de varios elementos procesadores, cada uno de los cuales efectúa tareas de manera independiente y simultánea. De esta forma, el trabajo se divide en subtrabajos independientes, los cuales son asignados a diferentes elementos procesadores. Un ejemplo de estas máquinas es la computadora modelo CRAY 1, la cual consta de 64 elementos procesadores).

Estas *supercomputadoras paralelas* tienen un costo de producción muy alto, que se refleja en su costo de uso comercial¹, de manera que existen muy pocas en el mundo. Debido a esto, en los Estados Unidos de América se han organizado centros de supercomputación en los cuales se da servicio a un gran número de usuarios, a través de la línea

¹ El costo comercial de uso de estas computadoras es de aproximadamente 2,000.00 dólares por hora.

telefónica.

Además de su elevado costo, este tipo de computación presenta algunas inconveniencias: es difícil programar una computadora paralela, ya que el programador debe fraccionar el problema en pequeñas tareas independientes, y optimizar la manera de asignarlas. Además, la mayor parte de los problemas no son *paralelos* por naturaleza; es decir, no siempre es posible dividir un trabajo en subtrabajos independientes, o hacerlo de manera eficiente, pues algunos procesadores requieren de los resultados obtenidos por otros para poder continuar sus cálculos. Como consecuencia, a menudo nos encontramos con que la más veloz supercomputadora opera a la misma velocidad que un procesador en serie. Este problema es conocido como el *cuello de botella de Herman*.

En los últimos años, ha aparecido un nuevo concepto en la computación, que probablemente proporcionará una solución a algunos de los problemas recién indicados. Este nuevo concepto, conocido con el nombre de *redes neuronales*, es radicalmente diferente al anterior: se utilizan elementos electrónicos que emulan neuronas simplificadas, los cuales se conectan entre sí formando redes similares a las que se encuentran en el cerebro, aunque a una escala mucho menor. Recientemente, los avances obtenidos por el estudio en el desarrollo de las redes neuronales han logrado resultados sorprendentes, y todo parece indicar que, en el futuro, estos dispositivos podrán dotar a las computadoras de capacidades similares a las humanas para la solución de problemas

complejos.

Hasta el momento, una de las diferencias básicas que existe entre computadoras y seres humanos tiene que ver con la utilidad práctica del material memorizado. Esta diferencia consiste en que mientras una computadora almacena información que únicamente puede ser llamada de manera explícita por un programa, el ser humano *aprende*. En el hombre, la adquisición de nueva información modifica su comportamiento (o su forma de pensar), en la medida que la aporta nuevos criterios para la toma de decisiones, tanto a nivel consciente como inconsciente. El hombre debe su gran capacidad de adaptación, también llamada *plasticidad neuronal*, a su habilidad de aprender.

Para poder construir máquinas que tengan ciertas características de inteligencia es necesario el diseño de arquitecturas radical y conceptualmente diferentes. Esta es la filosofía presupuesta en el estudio de las llamadas *redes neuronales* (artificiales). Estas redes constituyen un concepto totalmente nuevo y diferente de la computación, el cual se basa en un modelo simplificado de la manera en que las neuronas se organizan en redes dentro del cerebro.

Las *redes neuronales* (artificiales) se encuentran en sus primeras fases de desarrollo, sin embargo, se ha encontrado que tienen capacidades autónomas de aprendizaje, y que la información que almacenan es recuperable con base en su contenido. También se ha observado que estos sistemas pueden *recordar* a partir de información incompleta o con

mucho ruido. Todas estas son características análogas a las de la mente humana.

Recientemente ha habido un gran auge en la investigación de redes neuronales, y como consecuencia se han logrado grandes avances de carácter fundamental. Estos avances comienzan a verse reflejados en el plano tecnológico, ya que se empiezan a desarrollar computadoras que funcionan con base en estos principios. En estos momentos ya existen en el mercado algunos programas que operan en computadoras convencionales y que funcionan *imitando* estas nuevas arquitecturas. Estos programas son ejemplos modestos de lo que tendremos en los años por venir.

Todo parece indicar que el estudio de este tipo de modelos contribuirá al desarrollo de los llamados *robots inteligentes*. Idealmente, la característica principal de estos nuevos robots inteligentes sería su alto grado de adaptación, esto es, exhibirían un comportamiento que se ajustaría a las condiciones externas de una manera apropiada. Para ello sería necesario dotarlos de funciones sensoriales artificiales, y de un sistema para procesar la información recibida a través de los *sentidos*. Después de procesada, la información sería almacenada, y de manera paralela esta información recién aprendida modificaría las respuestas del robot al medio. Esto es, se pretende lograr construir máquinas en las cuales los circuitos mismos aprendan a partir de la experiencia, y que se autoorganicen. Por el momento, sin embargo, esto es aún ciencia ficción.

El desarrollo de sistemas nerviosos artificiales tiene una historia interesante. Como no es posible cubrir esta historia a fondo en unas cuantas páginas, únicamente las hazañas principales se mencionarán. Esta ojeada de los hitos del pasado del campo deben proporcionar al lector una apreciación de cuántas contribuciones al campo ha permitido su desarrollo sobre los años. El resumen histórico de abajo no es exhaustivo; algunos hitos son omitidos y algunos son mencionados brevemente.

Fueron Galvani y sus colaboradores, en el año de 1780, los que nos dieron la herramienta para pensar sobre el cerebro de una manera diferente: la electricidad animal. Y varias décadas más tarde, en 1920, Hans Berger utilizó la incipiente tecnología médica de su tiempo e inventó la electroencefalografía. Y así, registrando las señales eléctricas producidas por el cerebro humano dió pauta para modelar físicamente un cerebro. Ya se podía especular si el cerebro era una esfera maciza de materia gelatinosa capaz de generar potenciales eléctricos o un aglomerado de partes con propiedades eléctricas. Una parte de la respuesta la había dado Don Santiago Ramón y Cajal desde finales del siglo XIX, ayudado por el microscopio, los colorantes histológicos y la fotografía.

Cajal demostró que el tejido nervioso está constituido por elementos individuales, las células nerviosas o neuronas, como las llamó el anatomista alemán Waldeyer en 1891. La variedad de neuronas es enorme, así como las conexiones entre

ellas. La otra parte de la respuesta, la relacionada con la existencia de electricidad en las neuronas, tiene una historia muy larga que se inicia con Galvani, siguió con Matteucci, Du Bois-Reymond y Einthoven en la parte experimental, y con Bernstein y Höber en la teoría de la membrana de la neurona, hasta concluir —cuando menos una etapa— con los experimentos con electrodos realizados por Hodgkin y Huxley en el axón o nervio del calamar gigante, y cuyos resultados fueron publicados en 1952. En este nervio o axón, que es el componente de una neurona que le permite comunicarse con otras, estos investigadores estudiaron las corrientes iónicas responsables del potencial eléctrico que se desplaza a todo lo largo del axón, de una manera de todo-o-nada, es decir, que una vez que se produce no puede detenerse.

A partir de estos experimentos, Hodgkin y Huxley propusieron un modelo matemático del axón compuesto de varias ecuaciones diferenciales no lineales. El modelo es capaz de reproducir los eventos eléctricos en el axón y también predijo otros mecanismos en él, que no se habían observado en los experimentos.

En el presente vemos un gran individualismo entre los investigadores, y se dice que un investigador no sabe lo que hace su vecino de al lado. Hubo una temporada corta, un poco antes y un poco después de la Segunda Guerra Mundial, en que la multidisciplinaria era bien vista. Un campo donde fructificó fue en el estudio del funcionamiento del cerebro, quizás por

la fascinación que éste ejerce sobre la curiosidad de los estudiosos. En los años 30 había una cantidad considerable de investigadores que se interesaban en el funcionamiento del cerebro, sin que éste fuera su disciplina principal de trabajo. Tanto matemáticos, médicos, como psicólogos e ingenieros estaban interesados, por diversas razones, en modelar aspectos del funcionamiento del cerebro. Destacaron en esto dos psicólogos: Donald Hebb y Warren McCulloch, que a sus conocimientos del cerebro desde el campo de la Psicología añadieron el aspecto matemático. Propusieron modelos matemáticos muy sencillos de las neuronas y con ellas trataron de construir la Teoría del Cerebro basada en redes neuronales y sus interconexiones. Su propuesta tuvo una acogida entusiasta de parte de la comunidad científica y, sin duda, fue una de las responsables de la creación de la Cibernética (N. Wiener y A. Rosenblueth). Lo que hay que notar es el intento de Hebb y McCulloch por utilizar sus conocimientos sobre el cerebro completo para modelarlo a partir de sus componentes elementales. Pareciera que esta hubiera sido la mejor manera de acercarse a estudiar el funcionamiento del cerebro, pero no fue así. Con una suerte un poco mejor que la que Galvani tuvo con Volta, McCulloch causó revuelo con las Neuronas Formales, pero lo que floreció fue la Inteligencia Artificial. Hebb no tuvo mejor suerte, y su trabajo permaneció agazapado esperando mejores días. Sus seguidores, como Rosenblatt, tuvieron una suerte peor un poco más tarde.

Existen varias explicaciones para lo anterior, pero dejaremos por ahora, para concentrarnos en sólo una: nuestro conocimiento sobre el cerebro a mediados del siglo XX. Los avances tecnológicos en la electrónica, microscopía y diseño mecánico, hicieron posible el estudio cada vez más detallado y microscópico del sistema nervioso. Podría asegurarse que la miniaturización en la electrónica avanzó paralelamente con el estudio de los componentes, cada vez más minúsculos, del sistema nervioso. Primero, las fibras musculares, luego los axones y de ahí a las membranas y sus canales iónicos. Fue demostrada la trasducción electro-química en la sinapsis y se identificó a la acetilcolina como el neurotransmisor dedicado de la placa neuromuscular, en la que a su vez se descubrieron los potenciales miniatura. Todo este conocimiento agregó una cantidad de preguntas acerca del funcionamiento del sistema nervioso; no se veía un horizonte claro, aunque fuere lejano, sino un aumento en la complejidad de lo estudiado. En cierta forma, la multidisciplinaria dejó de ser algo tangible. Cada quien se dedicó a su especialidad y en el estudio de los cerebros esto implicó que cada grupo o escuela tomara su parte preferida de estudio y la separó del resto, olvidándose así del que el sistema nervioso es precisamente lo que dice su nombre: un sistema. El estudio de las redes neuronales se vio fuertemente afectado por esta tendencia, pues los esfuerzos tecnológicos y analíticos se concentraron en una neurona, o un pedazo de membrana, o un neurotransmisor, o un canal iónico. Por supuesto, el efecto también alcanzó a los

modelos de redes neuronales, pues más bien se volvieron modelos de neuronas, de axones o de membranas. Desde 1960 hasta 1980 casi no existían modelos de redes neuronales que fueran amables en su manejo, y de alcance, en cuanto a su capacidad de análisis y habilidad para hacer predicciones. Es cierto que en esos 20 años no se tenían ni las computadoras ni los circuitos integrados que se tienen ahora.

El año de 1943 es frecuentemente considerado el año inicial dentro del desarrollo del modelo de una neurona computacional elemental. El modelo incluyó todos los elementos necesarios para realizar operaciones lógicas, y así puede funcionar como un elemento computacional aritmético-lógico. Sin embargo, la implementación de su modelo electrónico compacto, no fue tecnológicamente factible durante la era de los voluminosos tubos al vacío. El modelo de la neurona formal no fue muy adoptado por la descripción del *Hardware* computacional de tubos al vacío, y el modelo nunca llegó a ser técnicamente significativo. Sin embargo, el modelo de neurona de McCulloch y Pitts proporcionó las bases para desarrollos futuros.

En 1943 Warren McCulloch y Walter Pitts propusieron una teoría general de procesamiento de información basada en redes de conmutación binaria o elementos de decisión, los cuales son un poco eufemísticamente llamados *neuronas*, quizás son mucho más simples que sus contrapartes biológicas reales.

Investigadores influyentes de aquel tiempo sugirieron que aquella investigación de diseño de procesadores como

cerebros podrían ser interesantes.

Donald Hebb (1949) fue el primero que propuso un esquema de aprendizaje para actualizar las conexiones de las neuronas que ahora denominamos como la *regla de aprendizaje Hebbiano*. Comenzó con que la información puede ser almacenada en las conexiones, y postulada la técnica de aprendizaje que tuvo un profundo impacto en los desarrollos futuros dentro de este campo. La regla de aprendizaje de Hebb hace primeramente contribuciones a la teoría de las redes nerviosas.

Durante los 50's, aparecieron las primeras neurocomputadoras construidas y probadas. Adoptaron conexiones automáticamente. Durante esta etapa, el elemento como neurona llamado *perceptron* fue inventado por Frank Rosenblatt en 1958. Era una máquina adiestrable capaz de aprender a clasificar ciertas rutas modificando conexiones a los elementos del umbral. La idea atrapó la imaginación de los ingenieros y científicos y proporcionó las bases para los algoritmos de aprendizaje de la máquina básica que todavía usamos hoy.

Alrededor de 1960 Frank Rosenblatt y sus colaboradores estudiaron extensivamente un tipo específico de red nerviosa, a la cual ellos denominaron *perceptron*, porque ellos lo consideraron para ser un modelo simplificado de los mecanismos biológicos de procesamiento de información sensorial, por ejemplo, la percepción.

A principios de 1960 un mecanismo nombrado *ADALINE* (por

las palabras inglesas: ADAPtive LINEar combiner; combinación lineal adaptivo) fue introducido, una nueva regla de aprendizaje poderosa denominada la *regla de aprendizaje de Widrow-Koff* fue desarrollada por Bernard Widrow y Marcian Hoff (1960, 1962). La regla minimizó el error cuadrado sumado durante la educación implicando la clasificación de la ruta. Aplicaciones más recientes del ADALINE y sus extensiones a MADALINE (por las palabras inglesas: Many ADALINES; Muchos ADALINES) incluyen el reconocimiento de ruta, si pronostica, y controles adaptivos. El monograma de máquinas de aprendizaje por Nils Nilsson (1965) claramente resumió muchos de los desarrollos de aquél tiempo. Aquél libro también formula inherentes limitaciones de máquinas de aprendizaje con conexiones modificables.

A pesar de los sucesos y entusiasmos de a principios y mediados de 1960, la existencia de los teoremas de aprendizaje de la máquina de aquél tiempo fueron muy débiles para soportar más problemas computacionales complejos. Aunque los cuellos de botella fueron exactamente identificados en el trabajo de Nilsson y la arquitectura de la red nerviosa denominada *redes con capas* también eran conocidas, no existieron esquemas de aprendizaje eficientes en aquél tiempo que engañarían a los enormes obstáculos. Otra razón que contribuyó a este retraso en la investigación en aquél tiempo fueron los relativamente modestos recursos computacionales disponibles entonces.

El episodio final de esta era fue la publicación de un

libro por Marvin Minsky y Seymour Papert (1969) que dio más duda del aprendizaje en capas del potencial de la red. Las limitaciones empezaron cuando las redes de clase perceptron fueron hechas públicas; sin embargo, el estímulo no fue atendido hasta mediados de 1980. El descubrimiento de divulgaciones exitosas del conocimiento de la red nerviosa tuvo que esperar hasta 1986. Mientras tanto, la moda en la investigación fluyó hacia otras áreas, y la actividad científica dentro del campo de la red nerviosa, nombrado en aquel tiempo *cibernética*, tuvo que disminuir repentinamente. El área de la inteligencia artificial emergió como un campo de investigación dominante y promisorio, la cual asumió, entre otras, muchas tareas que las redes nerviosas de aquél día no pudieron resolver.

Durante el periodo de 1965 a 1984, el fomento del trabajo inicial fue desarrollado por un puñado de investigadores. El estudio de aprendizaje en redes de elementos del umbral y de la teoría matemática de redes nerviosas fue perseguida por Sun-Ichi Amari (1972, 1977). También en Japón, Kunihiko Fukushima desarrolló una clase de arquitectura de red nerviosa conocida como *neocognitrones* (Fukushima y Miyaka 1980). El neocognitron es un modelo para reconocimiento de ruta visual y está relacionado con plausibilidad biológica. La red emula imágenes retinales y los procesa usando capas de neuronas de dos dimensiones.

La investigación de memoria asociativa ha sido continuada por, entre otros, Tuevo Kohonen en Finlandia

(1977, 1982, 1984, 1988) y James A. Anderson (1977). Las redes no supervisadas fueron desarrolladas del mapa característico en arreglos regulares de neuronas (1982). Stephen Grossberg y Gail Carpenter han introducido un número de arquitecturas nerviosas y teorías (1974, 1982), y desarrollaron la teoría de las redes de resonancia adaptiva que se explicará en el capítulo 4.

Durante el período de 1982 hasta 1986, distintas publicaciones fueron publicadas que fomentaron significativamente el potencial de las redes nerviosas. El área del renacimiento comenzó con John Hopfield (1982, 1984) introduciendo una arquitectura de red nerviosa recurrente para memorias asociativas. Sus papeles formularon propiedades computacionales de una red conectada completamente de unidades.

Otra revitalización del campo vino de la publicación en 1986 de dos volúmenes sobre proceso distribuido en paralelo, editado por James McClelland y David Rumelhart (1986). Las nuevas reglas de aprendizaje y otros conceptos introducidos en este trabajo han quitado una de las barreras de enseñanza de red esencial que enseñó los conocimientos básicos a la corriente principal tentativamente de mediados de 1980. La publicación de McClelland y Rumelhart abrió una nueva era para un potencial computacional frecuentemente en una estimación demasiado baja de redes en capas.

A pesar de que el marco matemático del nuevo esquema de enseñanza de redes en capas fue descubierta en 1974 por Paul

Werbos, fue ampliamente inadvertida en aquel tiempo. Según la más reciente declaración (Dreyfus 1990), los primeros autores de la optimización que se acercan a los sistemas en la dirección de desplazamiento multicapa fueron Bryson (1969) y Kelley (1969) quienes obtuvieron una pendiente de solución para la educación de red multicapa. En 1982, Dreyfus usó una simple y nueva derivación recursiva basada en la regla de la cadena de diferenciación para demostrar los resultados de Bryson-Kelley y trató explícitamente el problema de control óptimo en su forma de etapa discreta (Dreyfus 1982). Su trabajo, sin embargo, no ha sido llevado a vencimiento y se adoptó para algoritmos de aprendizaje de la red nerviosa.

A principios de 1986, muchos programas nuevos de investigación de redes nerviosas fueron iniciados. La intensidad de investigación dentro de la disciplina de neurocomputación puede ser medida por un crecimiento rápido de conferencias y boletines dedicados al campo. En resumen, muchos volúmenes editados que contienen colecciones de papeles y distintos libros ya han aparecido. La lista de aplicaciones que puede ser resuelta por redes nerviosas se ha expandido desde ejemplos de pruebas pequeñas hasta grandes pruebas prácticas. Chips de red nerviosa integrada a escala muy grande ya han sido fabricados. Aunque la neurocomputación ha tenido una historia interesante, el campo está aún en sus primeras etapas de desarrollo.

Los modelos actuales de redes neuronales tienen el

potencial de dotar con capacidades cognoscitivas a las computadoras. El desarrollo teórico del campo ha madurado brillantemente, a partir de 1982 con los trabajos de John Hopfield, y las aplicaciones están brotando por doquier: Procesamiento Distribuido en Paralelo, Procesamiento de Señales Digitales, Imagenología, Robotica, Diseño de Computadoras, Investigación de Operaciones, Economía y Finanzas. Existe un gran revuelo en las revistas de divulgación y pareciera que todo está resuelto y andando. No es así, para que el potencial de que se había llegado a realizarse, se necesita todavía mucha investigación, pruebas piloto de las aplicaciones y mucha familiarización con una tecnología que ha parecido brotar, de repente, de la nada.

Existen muchos problemas científicos y tecnológicos en los que la información contiene cantidades considerables de ruido o incertidumbre, razón por la cual requieren para su manejo o solución de dispositivos capaces de adaptación o aprendizaje, es decir, las llamadas técnicas inteligentes. Problemas de este tipo se encuentran en el procesamiento de señales biológicas y tecnológicas, en el control de robots y de procesos, así como en la Sociología y la Economía.

Disponemos de varios métodos para tratar de solucionar el problema; uno muy poderoso, sobre todo cuando otros como las técnicas adaptivas y los sistemas expertos fallan, es la tecnología de redes neuronales.

Una red neuronal artificial es un conjunto de elementos procesadores o nodos (*neuronas*) conectados unos con otros

de acuerdo a arquitecturas específicas y con pesos o intensidades modificables en la conexión (*sinapsis*) de una neurona a otra. En terminos más generales, una red neuronal es un modelo inspirado en las neuronas biológicas que constituyen los cerebros de animales incluyendo los humanos.

Las redes neuronales debutaron hace casi medio siglo, desaparecieron en los años 60 y han revivido en los años 80 con un vigor extraordinario. De las neuronas formales de McCulloch y Pitts, luego a los perceptrones de Rosenblatt y los adalines de Widrow, han llegado a los modelos de Hopfield y los de Anderson. La clave del éxito, de esta quizás inesperada reaparición es, sin duda, el algoritmo de retropropagación para el ajuste automático de los pesos sinápticos en las conexiones de la red.

1.1 Perspectivas para el futuro.

La explosión general de interés en sistemas nerviosos artificiales está basada en un número de expectativas científicas y económicas. Uno debe estar consciente, no obstante, que algunas de las expectativas populares pueden estar exageradas y no ser realistas. La tendencia de sobreexpectaciones viene para el campo de los sistemas nerviosos artificiales naturalmente a causa de su nombre y, algunas veces, a través de la terminología que usa. Es poco tentador para un ser humano concebir una máquina como humano con una percepción humana o cerca de lo humano, razonamiento,

y capacidades de movimiento. La terminología antropomórfica, inspiraciones, y aplicaciones de procesamiento sensorial de la tecnología de la red nerviosa pueden tener la culpa parcialmente por enlazar tales máquinas hechas por el hombre como humanos con lo que es meramente una disciplina técnica. Tales *entaces* deben ser disueltos con buen humor.

Podemos estar completamente seguros que las redes nerviosas no reemplazarán a las computadoras convencionales. Las razones básicas impiden a las neurocomputadoras reemplazar a las otras convencionales para la gran mayoría de las tareas. Las computadoras convencionales son ahora muy baratas. Son extremadamente rápidas y exactas para la ejecución de rutinas matemáticas, procesamiento de texto, diseño ayudado por computadora, procesamiento y transferencia de datos, y muchas otras pruebas. En general, las computadoras digitales convencionales realizan cualquiera de los cálculos numéricos.

Una posibilidad para el uso de sistemas nerviosos artificiales es simular sistemas físicos que están mejor expresadas por redes paralelas imponentemente. También, el proceso de señal de bajo nivel debe de ser mejor hecho por redes nerviosas analógicas paralelas o analógicas y digitales. Quizás las aplicaciones más probables para las redes nerviosas serán aquellas que atañen a la clasificación, asociación y razonamiento en vez de cálculos aritméticos secuenciales. No de modo sorprendente, la mejor esperanza para el uso extendido de los sistemas nerviosos artificiales,

o neurocomputación, es dentro de áreas computacionales intensivas que no son atacadas exitosamente por computadoras convencionales. Parece que las áreas requieren inferencia como la humana y la percepción de la velocidad y visión son los candidatos más probables para las aplicaciones en control de tiempo real de sistemas complejos y otras aplicaciones que no podemos aun anticiparnos.

Las redes nerviosas todavía están supuestas para ser muy aplicadas dentro de los sistemas expertos y dentro de una variedad de procesadores de señal. En la actualidad, tales sistemas están disponibles como ayudas para diagnósticos médicos, servicios financieros, predicciones de precios, pronóstico de estallidos solares, identificación de pulso por radar, y otras aplicaciones. En lo que la mayoría de los investigadores están de acuerdo, es que el futuro de los sistemas nerviosos artificiales no van a reemplazar las simulaciones computacionales y de inteligencia artificial en otras computadoras convencionales. En vez, ofrecerán una tecnología complementaria. El último objetivo puede hacer explotar ambas tecnologías bajo el mismo techo, hasta que se presente una interfase individual, flexible para el usuario.

Las neurocomputadoras de hoy son frecuentemente computadoras convencionales programables que corren *software* de simulación nerviosa. Tales neurocomputadoras simulan un conveniente suministro pero con interfases convencionales de entrada y salida. Algunas neurocomputadoras emplean arquitecturas dedicadas, o tablas de neurocomputación, que

hacen que las simulaciones de la red nerviosa operen más rápido y más exactamente que las comparadas con las arquitecturas estándares.

Mientras las neurocomputadoras se vuelven más rápidas, más pequeñas y más eficientes, los límites de las aplicaciones se ampliarán más allá de las soluciones simuladas. Además, parece cierto que la proliferación de aplicación específica de redes nerviosas integradas a escala muy grande (VLSI) es de importancia crucial para el éxito de grandes términos de tecnología.

Afortunadamente, la fabricación de los sistemas nerviosos artificiales sigue los paradigmas computacionales inventados. Las implementaciones de la red nerviosa óptica está supuesta para volverse directamente aplicable. Desde 1986, cuando la primera memoria nerviosa de circuito integrado de AT&T fue fabricada, hemos visto la proliferación de la microelectrónica de chips de red nerviosa. Los sistemas nerviosos VLSI con pesos modificables han llegado al mercado. No obstante, los chips de red nerviosa educadas para propósito general con aprendizaje sobre un chip estarán probablemente dentro de varios años.

En términos generales, podríamos suponer que los sistemas nerviosos artificiales serán usados en aplicaciones concernientes con la visión, el habla, la toma de decisiones, y el razonamiento, pero también como procesadores de señal tal como filtros, detectores, y sistemas de control de calidad. Las aplicaciones están supuestas especialmente para

procesar cantidades grandes de datos. También, las redes nerviosas pueden ofrecer soluciones para casos en el cual un algoritmo procesador o soluciones analíticas son difíciles de encontrar, ocultos, o no tienen. Tales casos incluyen modelos de procesos complejos, extracción de propiedades de colecciones grandes de datos, y probar la identificación de plantas que necesitan ser controladas. Ya existe un sistema de robot que combine la visión con el control del movimiento del brazo del robot y aprenda la coordinación mano-ojo. Tales sistemas pueden ser esperados a ser prolongados sobre los próximos años para producir un sistema robótico sofisticado. Los sistemas de reconocimiento del habla continuo independiente del orador, están siendo desarrollados. Estarán probablemente en unos años, pero los sistemas de vocabulario limitado pueden estar disponibles comercialmente muy pronto.

La tecnología de redes nerviosas artificiales es todavía muy nuevo y está desarrollándose rápidamente. Estamos presenciando la rápida expansión de máquinas inteligentes basadas en red nerviosa. De un modo alentador, esta expansión realiza la calidad de nuestras vidas y hace muchas pruebas difíciles más fáciles de ejecutar. Otras especulaciones pueden no ser necesarias, porque las hazañas tecnológicas y productos disponibles hablarán por ellos mismos.

1.2 El Futuro.

La evolución de la ciencia y la técnica en los países capitalistas se ha llevado a cabo bajo presiones de intereses políticos y económicos, principalmente. Dentro de este contexto, la creación de máquinas *pensantes* es de primordial importancia, debido a su potencial de comercialización y a su uso con objetivos militares. Podríamos decir que su rango de aplicaciones sería prácticamente ilimitado.

Lo anterior ha sido advertido por los gobiernos de los países desarrollados, quienes apoyan de manera substancial proyectos institucionales y regionales cuyo propósito es la planeación de la investigación en este campo. Como muestra de lo anterior tenemos que la antigua República Federal de Alemania tenía un presupuesto gubernamental de 100 millones de dólares destinados exclusivamente al desarrollo de esta área; Japón tiene un programa llamado *fronteras humanas*, y la Comunidad Económica Europea ha creado un programa llamado *BRAN* (investigación básica en inteligencia adoptiva y neurocomputación). Por otro lado, a finales de 1988 la oficina de tecnología táctica del Gobierno de Estados Unidos de América recomendó una inversión federal de casi 400 millones de dólares para investigación y desarrollo de redes neuronales. De igual manera, en estos países se han venido formando asociaciones científicas de investigadores activos y estudiantes interesados en estos proyectos. Estas asociaciones agrupan personas con diversas formaciones profesionales, que incluyen psicólogos, neurobiólogos,

matemáticos, computólogos, físicos e ingenieros.

También la iniciativa privada ha dedicado fuertes sumas de dinero para el desarrollo de sus propios proyectos de redes neuronales. Se calcula que para finales de 1988 había ya más de 200 empresas privadas en los Estados Unidos dedicadas a la fabricación de redes neuronales; por otro lado, cualquier revista de computación contiene una larga lista de anuncios relacionados con esta nueva tecnología que evoluciona día a día. Los cambios pequeños en las máquinas se dan mediante un proceso similar al de la *selección natural*. Un fabricante introduce variaciones en su producto que lo hacen más útil o, al menos, más atractivo para el consumidor. Como resultado, el producto gana mercado a los productos elaborados por sus competidores. Estos últimos, para poder subsistir y recuperar mercados, deben innovar su producto introduciendo características análogas o superiores a las de los productos de los otros fabricantes. En este proceso muchas pequeñas compañías, incapaces de incorporar todos los avances tecnológicos, desaparecen. Otras compañías se consolidan y adquieren un lugar importante.

Creemos que bajo esta presión, las redes neuronales tendrán un gran impulso en los años que se avecinan, y que esto repercutirá, aun más, en todos los aspectos de nuestras vidas. Estas computadoras no sustituirán a las computadoras convencionales, sino que las complementarán. De manera que podremos contar con computadoras *híbridas*, que utilicen uno u otro tipo de computación, dependiendo del problema, o de la

parte del problema a resolver.

El cerebro humano tiene un número de conexiones del orden de 10^{15} , y transmite 10^{10} impulsos eléctricos por segundo; por otro lado, el cerebro de una mosca trabaja enviando 10^9 señales por segundo. En comparación, la neurocomputadora *JRV Mark IV* tiene 10^7 interconexiones y envía 1.6×10^7 señales por segundo; y los programas de *redes neuronales* escritos para computadoras personales funcionan típicamente con 30,000 interconexiones que envían 25,000 señales por segundo. Como podemos ver a partir de estas cifras, existe un abismo entre el cerebro humano y las neurocomputadoras.

Aunque la tecnología de este nuevo tipo de computadoras está aun en su infancia, existe un gran entusiasmo y optimismo acerca de su futuro. Sin embargo, se considera muy remota la posibilidad de construir algo comparable al cerebro humano. Según B. Widrow, director de la Sociedad Internacional de Redes Neuronales, pasarán más de mil años antes de que pueda construirse cerebros sintéticos.

CAPITULO 2: REDES NERVIOSAS BIOLÓGICAS.

2. LA ESTRUCTURA DEL SISTEMA NERVIOSO CENTRAL

2.1 LA NEURONA.

A pesar de que el sistema nervioso central ha sido estudiado por médicos desde la Edad Media, su estructura detallada comenzó a ser descrita sólo hace un siglo. En la segunda mitad del siglo XIX dos escuelas se enfrentaron por la prevalencia científica: los *reticularistas* afirmaron que el sistema nervioso estaba formado por una red continua, ininterrumpida de fibras nerviosas, mientras que los *neuronistas* sostuvieron que esta red nerviosa está compuesta de un número vasto de unidades celulares individuales, interconectadas, las *neuronas*. Como frecuentemente en el curso de la ciencia, la lucha entre estas dos doctrinas fue decidida por la venida de una nueva técnica, inventada por Camillo Golgi alrededor de 1880, por el tñido de las fibras nerviosas mediante una reacción de bicromato de plata. Esta técnica fue ingeniosamente aplicada por el doctor español Santiago Ramón y Cajal en 1888 para refutar la doctrina del reticularismo exhibiendo los pequeñísimos espacios entre neuronas individuales. La ciencia moderna del sistema nervioso central humano de esta manera ha celebrado su primer centenario².

La investigación detallada de la estructura interna de las células nerviosas, especialmente después de la invención

²

Golgi y Ramón y Cajal compartieron en 1906 el Premio Nobel en Medicina por sus descubrimientos.

del microscopio electrónico unos 50 años después, ha revelado que todas las neuronas están construidas de las mismas partes fundamentales, independientemente de su tamaño y forma (ver fig. 2.1.1): La parte central es denominada el cuerpo de la célula o *soma*; desde él proyecta diversas extensiones como raíz, las *dendritas*, igual que una fibra tubular individual, el *axón*, el cual ramifica a su terminación en un número de pequeñas ramificaciones. El tamaño del soma de una neurona típica es aproximadamente de 10-80 μm , mientras que las dendritas y axones tienen un diámetro de unos cuantos μm . Mientras las dendritas sirven como receptoras de las señales de las neuronas adyacentes, el propósito del axón es la transmisión de la actividad nerviosa generalizada hacia otras células nerviosas o hacia fibras musculosas. En el primer caso el término *interneurona* es frecuentemente usado, en tanto que la neurona es llamada una *neurona motor* en el próximo caso. Un tercer tipo de neurona, la cual recibe información de los músculos u órganos sensoriales, tales como el ojo o el oído, es nombrada una *neurona receptora*.




Fig. 2.1.1 Estructura de una neurona típica (esquemática).

La unión entre la terminación de una ramificación axónica, la cual asume una forma como de placa, y otra

neurona o músculo es denominada una *sinapsis*, como lo sugirió Sherrington en 1906. En la sinapsis las dos células están separadas por un espacio pequeñísimo aproximadamente del ancho de 200 nm (el *espacio sináptico* o *hendidura*), apenas visible para Ramón y Cajal, pero fácilmente revelado por técnicas modernas. Las estructuras son llamadas según la relación de la sinapsis como *presináptico* y *postsináptico*, por ejemplo, neurona postsináptica. La sinapsis puede estar localizada en cualquiera de los dos directamente al cuerpo de la célula, o a las dendritas, o a la neurona subsecuente, su fuerza de influencia generalmente disminuye cuando la distancia aumenta desde el cuerpo de la célula. La longitud de 0.01 mm para las interneuronas dentro del cerebro humano contra 1 m para neuronas dentro de los miembros.

Las señales nerviosas son transmitidas tanto eléctrica o químicamente. La transmisión eléctrica se genera dentro del interior de una neurona, en tanto que la transmisión química operan entre diferentes neuronas, por ejemplo en la sinapsis. La transmisión eléctrica² está basada en una descarga eléctrica lo cual comienza en cualquier parte de la célula y luego se extiende al axón hacia las varias conexiones sinápticas.

² Estudios detallados de los mecanismos de transmisión de señal eléctrica oculta dentro del sistema nervioso fueron promovidos por Sir John Eccles, Alan Lloyd Hodgkin, y Andrew Huxley, quienes fueron conjuntamente merecedores al Premio Nobel en Medicina en 1963.

La velocidad de propagación de la descarga de la señal a lo largo de la fibra nerviosa varía enormemente. En las células del cerebro humano la señal viaja con una velocidad de aproximadamente 0.5 - 2 m/s. Aunque esto permite a dos cualesquiera células del cerebro comunicarse a 20 - 40 ms, lo cual es algo como una parte temporal dentro de la operación del sistema nervioso central humano, causaría tiempos inaceptablemente de reacción largas para neuronas periféricas conectadas al cerebro y miembros: una persona golpearía la tierra antes de siquiera conocer que ha tropezado. Para incrementar la velocidad de propagación, los axones para tales neuronas están compuestos de segmentos individuales que están cubiertos por un forro de mielina eléctricamente aislante, lo cual es interrumpida de vez en vez a los tan nombrados nodos Ranvier. La presencia de una cubierta aislante le causa a la señal propagarse a lo largo del axón como dentro de una guía de ondas desde un nodo Ranvier hacia el próximo, accionando casi instantáneamente la descarga dentro del segmento mielinado entero. Este modo de propagación, llamado *conducción saltón*, teniendo en cuenta velocidades de transmisión de más de 100 m/s.

La señal de descarga viaja a través del axón y viene a pararse en la sinapsis, porque aquí no existe puente conductor para la próxima neurona o fibra muscular. La transmisión de la señal a través del espacio sináptico es afectado grandemente por mecanismos químicos. La transmisión eléctrica directa es también conocida por ocurrir en casos

raros, pero es de menos interés aquí en vista del mucho más bajo grado de ajustabilidad de este tipo de sinapsis. En la transmisión química, cuando la señal punta llega a la terminal nerviosa presináptica, sustancias especiales denominadas *neurotransmisores* son liberados en cantidades pequeñísimas desde vesículas contenidas dentro del endpliate (por ejemplo de aproximadamente 10^{-17} moles de acetilcolina por impulso). La liberación del transmisor parece ser accionado por la entrada de iones Ca^{++} en el axón presináptico durante la depolarización causada por el flujo hacia dentro de la célula de iones Na^{++} . Las moléculas neurotransmisoras viajan a través de la hendidura sináptica, como se exhibe en la fig. 2.1.2, alcanzando a la neurona postsináptica (o fibra muscular) aproximadamente a 0.5 ms. Sobre su llegada a receptores especiales estas sustancias modifican la conductancia de la membrana postsináptica de ciertos iones (Na^+ , K^+ , Cl^- , etc.), los cuales luego fluyen hacia afuera de la neurona, causando una hiperpolarización o depolarización del potencial postsináptico local. Después de su acción las moléculas transmisoras son rápidamente capturadas por enzimas, las cuales son menos potentes al cambio de conductancia iónica de la membrana.




Fig. 2.1.2 La transmisión de la señal al espacio sináptico es afectado por neurotransmisores químicos, tales como el acetilcolina.

Aunque, en principio, una sinapsis individual puede inspirar a una neurona a *disparar*, esto raramente ocurre, especialmente si la sinapsis está localizada en el exterior de la terminal de una dendrita. Justo en el momento en que cada axón envía sinapsis hacia las dendritas y cuerpos de un número de neuronas más abajo, así está cada neurona conectada a muchas neuronas más arriba las cuales transmiten sus señales hacia ella. El cuerpo de una neurona actúa como una clase de mecanismo *sumador* el cual añade los efectos depolarizantes de sus diversas señales de entrada. Estos efectos desaparecen con un tiempo característico de 5 - 10 ms, pero si distintas señales llegan a la misma sinapsis sobre un periodo, sus efectos excitatorios se acumulan. Un promedio alto de repetición de disparos de una neurona por consiguiente expresa una gran intensidad de la señal. Cuando la magnitud total del potencial de depolarización dentro del cuerpo de la célula excede el umbral crítico

(aproximadamente 10 mV), la neurona dispara.

La influencia de una sinapsis dada por tanto depende de aspectos diversos: la fuerza inherente de su efecto depolarizante, su localización con respecto al cuerpo de la célula, y el promedio de repetición de la señales que llegan. Hay una gran cantidad de evidencia que la fuerza inherente de una sinapsis no está arreglada de una vez para siempre. Como originalmente declaró Donald Hebb, la fuerza de una conexión sináptica puede ser ajustada, si su nivel de actividad cambia. Una sinapsis activa, la cual repetidamente acciona la activación de su neurona postsináptica, crecerá en fuerza, mientras otras gradualmente disminuyen. Este mecanismo de *plasticidad* sináptica dentro de la estructura de conectividad nerviosa, conocida como *regla de Hebb*, parece jugar un papel dominante dentro del proceso complejo de *aprendizaje*.

La liberación de acetilcolina igual que sus acciones a los lugares de los receptores en la membrana postsináptica puede ser químicamente inhibida por sustancias tales como la atropina o el curare, o sus subsecuentes inactivaciones pueden ser bloqueadas, por ejemplo por cocaína, así incrementan sus acciones. De modo similar, mediante cambios menos drásticos de eficacia sináptica son probables que ocurran naturalmente dentro del cuerpo, dando a todas las sinapsis un cierto grado de *plasticidad*.

Es posible que el campo de la Medicina, que más se interesa en las redes neuronales biológicas (vease la figura 2.1.3) sea la Neurofisiología. La Neurofisiología es el

estudio del funcionamiento dinámico del sistema nervioso del hombre y los animales. Los experimentos en animales se hacen en la médula espinal, los centros subcorticales, y la corteza cerebral. Los niveles de estudio son: molecular (membranas, canales, receptores); celular (neuronas, glia); y sistema (redes de neuronas, ganglios, cerebros). La vanguardia del campo es, por un lado, el estudio de la organización cortical, de microcircuitos a redes neuronales y de ahí a constelaciones de redes y, por otro lado, el estudio molecular de las membranas, los receptores y los transmisores químicos neuronales.




Fig. 2.1.3 La retina: una red neuronal biológica. En la base del cubo están los conos y los bastones. En la parte superior del cubo, al fondo, están los axones de las neuronas ganglionares, que constituyen el nervio óptico. (El dibujo está basado en los de Cajal).

Las neuronas (véase la figura 2.1.4) son las células nerviosas, comparten como el resto de las células del organismo, los mecanismos metabólicos y otros, están especializadas en la comunicación con otras neuronas, con glándulas y con el sistema muscular. Para ello, poseen estructuras de entrada/salida y de procesamiento de

información, así como de toma de decisiones. El puerto de entrada de una neurona se llama el *árbol dendrítico*; el puerto de salida consta de un canal de comunicación, el *axón*, y de un transductor electro-químico llamado *botón terminal* que se encuentra en la terminal del axón. El área de contacto del puerto de salida de una neurona, con el puerto de entrada de otra neurona se llama la *sinapsis*.




Fig. 2.1.4
la corteza
según Cajal.

Diferentes neuronas de
cerebral del hombre.
La letra "a" denota
al axón.

Las neuronas son los procesadores fundamentales de los cerebros o computadoras biológicas. Se reconoce en la actualidad, que la transmisión de información se realiza por medio de trenes de potenciales de acción, que viajan a lo largo del axón. Estos potenciales de acción son pulsos

eléctricos de muy corta duración (aproximadamente 1 msec; véase la figura 2.1.5).




Fig. 2.1.5 a) Potencial de acción registrado intracelularmente en el axon gigante del calamar. b) Onda senoidal utilizada como reloj. Frecuencia = 500 Hz.

La actividad eléctrica a la entrada de una neurona —los potenciales postsinápticos— puede provocar efectos excitatorios o inhibitorias, dependiendo del tipo de neurotransmisor en la neurona presináptica. Esta actividad tiene características especiales y temporales que son integradas por la neurona por medio de un mecanismo no lineal, y el resultado es comparado con un umbral (figura 2.1.6), de manera que la neurona produce un potencial de acción si éste es alcanzado, y no lo produce si la actividad integrada queda por debajo de él.




Fig. 2.1.6 Potenciales eléctricos en la membrana neuronal. Solo las depolarizaciones que alcanzan el umbral producen un potencial de acción.

La excitación y la inhibición son mecanismos centrales del funcionamiento del sistema nervioso. En base a ellos, las neuronas poseen un campo receptivo sensible a una modalidad sensorial, o varias, es decir, a la luz, al sonido o al movimiento. Por ejemplo, el campo receptivo de una neurona del sistema visual puede definirse como aquella área del campo visual, o la correspondiente área en la superficie retinal, dentro de la cual un estímulo visual como una banda luminosa en movimiento, provoca actividad eléctrica (potenciales de acción) en esa neurona.

Para dar un ejemplo de la organización total, consideremos el sistema visual. El proceso comienza en la retina (figura 2.1.3), que tiene un espesor de un cuarto de milímetro, y en la cual están acomodadas tres capas de neuronas y una de receptores visuales (que son neuronas sensibles a la luz). La entrada visual la reciben simultáneamente 125 millones de receptores y la capa de

neuronas de salida de la retina tiene un millón de neuronas, que con sus axones, forman un cable de pocos centímetros de largo conocido como el nervio óptico.

Los nervios ópticos, uno proviene de cada ojo (retina), se unen en el quiasma óptico y de ahí hay una bifurcación hacia los dos cuerpos geniculados laterales. Estos núcleos neuronales tienen seis capas y un millón y medio de neuronas. Cada una de las capas repite más o menos los campos receptivos de la retina. La salida de los cuerpos geniculados laterales se proyecta a muchas regiones de la corteza visual. Por ejemplo, a la corteza visual primaria, donde las neuronas tienen campos receptivos complejos, porque son sensibles a puntos de luz y de oscuridad, a la dirección del movimiento de bandas de luz, a la orientación de tales bandas, y a la longitud de las mismas. La descripción nos da una idea de la complejidad del sistema visual, y sin mencionar la visión del color, ni mucho menos el proceso para integrar todas las regiones visuales y tratar de entender los mecanismos de percepción visual.

Las redes neuronales, debido a la complejidad de su comportamiento dinámico, generan efectos colectivos que no pueden explicarse a partir del análisis de las neuronas individuales. Sus propiedades emergentes pueden interpretarse como capacidad computacional, debido a la naturaleza del funcionamiento distribuido y paralelo de la red. La conectividad es muy intrincada, y patrones de conexión diferentes tienen significado en términos de control

funcional y transformaciones del estímulo. Por ejemplo, a nivel sensorial, los circuitos de conexión cambian en función de cambios en la estimulación.

La asociación cambiante de neuronas, por ejemplo, las motoneuronas, generan programas o partituras de las motoneuronas para dirigir a los músculos. Falta mucho por hacer para conocer el funcionamiento de las redes neuronales biológicas, pues se requiere del análisis experimental para entender los principios de operación de las conexiones y formular leyes de las mismas.

Se necesitan técnicas electrofisiológicas nuevas para estudiar redes neuronales biológicas, desde un punto de vista computacional, y entender su posible función en el procesamiento y almacenamiento de la información en paralelo. Mountcastle, que es uno de los pioneros en el uso del microelectrodo de metal, cree que con el registro simultáneo de neuronas, la Neurofisiología dará un gran paso. Un implante crónico capaz de acomodar 200 microelectrodos, registraría una cantidad enorme de información que requeriría de una nueva generación de métodos de análisis para interpretarla. Los problemas son enormes, pero deberán superarse si quiere llegarse a una nueva época del análisis de la función cerebral.

2.2 LA CORTEZA CEREBRAL

La increíble complejidad del sistema nervioso central, especialmente del cerebro humano no resta tanto en complejidad y diversidad de la célula nerviosa individual, la cual está totalmente limitada, como en el vasto número de sus unidades constituyentes, por ejemplo de las neuronas y sus conexiones mutuas. De cualquier manera sería engañoso asumir que todas las neuronas dentro del cerebro están de la misma forma. Aquí existen muy diversos tipos, distinguidos por el tamaño y grado de ramificación de su árbol dendrítico, la longitud de sus axones, y de otros detalles estructurales. Estos tipos ocurren en diferentes partes o capas de la corteza (uno típico, la vista esquemática de la estructura cortical es mostrada en la Fig. 2.2.1), y sus cooperaciones parecen ser esenciales para la solución de pruebas complejas de conocimiento. Pero repetimos: todas las neuronas operan en los mismos principios básicos como se explicaron arriba.

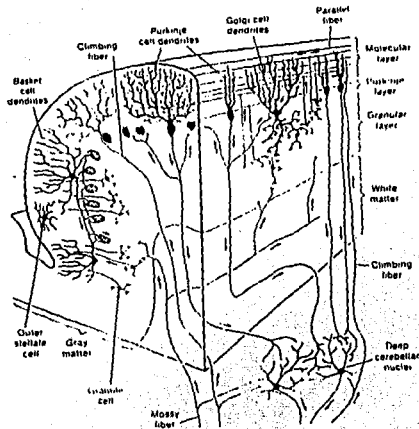


Fig 2.2.1 Sección a través de la corteza cerebral, mostrando la multiplicidad de diferentes tipos de neuronas conectadas a la red de capas.

La conectividad dentro del sistema nervioso está caracterizada por las propiedades complementarias de *convergencia* y *divergencia*. En la corteza humana cada neurona está estimada para recibir entrada convergente en el promedio desde aproximadamente 10,000 sinapsis. Por otro lado, cada célula alimenta su salida hacia muchas miles de otras neuronas, frecuentemente hasta el final de un número grande de sinapsis toca una célula nerviosa individual, como

se ilustra en la Fig 2.2.2. Quizás los ejemplos más expresivos son encontrados en la corteza cerebelar, donde las tan nombradas *celulas Purkinje*, reciben tantos como 80,000 entradas sinápticas, y una neurona de *celula granulo* individual conecta a 50 o más *celulas Purkinje*.




Fig. 2.2.2 Convergencia y divergencia dentro de la arquitectura nerviosa: (izquierda) *celula Purkinje* dentro del cerebro humano, (derecha) un axón ("fibra escaladora") que se entrelaza con el árbol dendrítico de la *celula Purkinje*.

El número total de neuronas dentro de la corteza humana es inmensa y puede sólo ser estimada. Cuentas completas en varias regiones pequeñas han producido una constante de densidad aproximadamente de 150,000 neuronas por mm^2 , las cuales están distribuidas en capas sobre la completa

profundidad del tejido cortical. Considerando que el area total de la corteza encerrada profundamente mide aproximadamente $200,000 \text{ mm}^2$, uno obtiene un numero de al menos 3×10^{10} neuronas. Algunas estimaciones incluso colocan el numero total de neuronas dentro del sistema nervioso central humano en la vecindad de 10^{11} . Combinando con el numero promedio de sinapsis por neurona, este produce un total de aproximadamente 10^{15} conexiones sinapticas dentro del cerebro humano, la mayoría de las cuales se desarrollaron unos pocos meses después de nacer (ver Fig. 2.2.3).

FALLA DE ORIGEN




Fig. 2.2.3 Desarrollo de la arborización dendrítica dentro de la corteza visual humana, de infantes: un recién nacido (derecha), de uno de tres meses (en medio), y uno de dos años (derecha).

Todas estas sinapsis pueden variar en fuerza y localización precisa. Cuando el número de conexiones sinápticas exceden con mucho la cantidad de información genética transmitida al individuo en su ADN, la estructura detallada de la red nerviosa dentro del cerebro humano debe de estar determinada por una combinación en vez de principios generales e información recogida por el mismo cerebro. De hecho, está bien establecido que ciertas funciones del

cerebro, tales como la capacidad para percibir estructuras ópticas, no son innatas. Si un gatito es vendado el ojo derecho después de nacer por varias semanas, su sentido de discriminación de ruta óptica no se desarrolla, aunque la sensibilidad de la retina y de las percepciones ópticas transmisoras nerviosas hacia el cerebro estén completamente operantes. Sin embargo, la conectividad nerviosa del centro visual queda altamente deficiente, igual si el gato está continuamente expuesto hacia la experiencia óptica en la etapa próxima de su vida⁴.

Podemos así llegar a la conclusión tentativa que la superioridad del cerebro humano tiene su raíz en su complejidad aumentada, especialmente en una cierta mirada sobre abundancia de neuronas, dando algunas neuronas libres para realizar tareas no asociadas con la reacción inmediata para, o almacenar, información sensorial. Esta hipótesis es supuesta por el hecho de que hay grandes regiones dentro de la corteza que no sirven aparentemente para nada, de propósito bien definido, pero las cuales de algún modo contribuyen a la organización y modulación general de

⁴ Uno no puede evitar maravillarse acerca del valor ético de estos y otros experimentos con animales, aunque a menudo, son esenciales para el progreso de la investigación del cerebro. Similarmente, una mayor parte del conocimiento acerca del cerebro humano ha sido derivado de la experiencia con lesiones de cabeza sostenidas por soldados durante las muchas guerras del pasado siglo. La perspectiva de aprendizaje referente del cerebro a través de simulaciones computacionales parecen particularmente atractivas y beneficiosas en este contexto.

actividades del cerebro. La trayectoria para un entendimiento del modo de operación del cerebro dentro de sus varias funciones, culminando dentro del estado ya inexplicado de la conciencia, puede así guiar completamente el estudio de las propiedades de sistemas complejos formados de unidades simples, idénticas.

Aunque existe una gran variedad de formas y especializaciones entre las neuronas, básicamente su función puede resumirse en la generación y envío de señales eléctricas (figura 2.2.4); por lo anterior, tomaremos a cada una de las neuronas como *entes* con dos estados posibles, ya que pueden estar activas o inactivas. Estas neuronas están en contacto, unas con otras, de manera que reciben señales provenientes de otras neuronas a través de la sinapsis. La interacción entre las neuronas podrá ser excitatoria, si incita a la neurona a la actividad, o inhibitoria, si tiende a mantenerla en reposo. Finalmente la red neuronal recibe señales del exterior a través de las células receptoras. De esta manera, cada neurona, promediará las señales que recibe, y si la señal resultante tiene una magnitud mayor que un cierto umbral característico, entonces ajustará su estado emitiendo una señal de respuesta (figura 2.2.5). En caso contrario permanecerá en reposo, esto es, no emitirá ninguna señal de respuesta.




Fig. 2.2.4 Aunque existe una gran variedad de formas y especializaciones entre las neuronas, básicamente su función puede resumirse como generación y envío de señales eléctricas.




Fig. 2.2.5 Las hileras de libros de esta figura muestran que los impulsos nerviosos son un evento del tipo "todo o nada". Un estímulo que sea demasiado débil, no producirá ningún efecto; pero si su "fuerza" está por encima de cierto umbral, entonces se generará un impulso nervioso. Si ahora hacemos el estímulo dos veces más intenso, tendrá el mismo efecto que el anterior.

Cada neurona —como ya mencionamos— recibe señales provenientes de un número muy grande de otras neuronas, algunas de las cuales pueden ser excitatorias y otras inhibitorias. Sin embargo, la neurona no puede excitarse e inhibirse simultáneamente, por lo que suma las señales de entrada. Si la señal total es más fuerte que un cierto umbral, entonces la neurona se excita y emite una señal de

respuesta; en caso contrario, la neurona permanece inactiva. De esta manera, podemos decir que siempre habrá un gran número de pares *frustrados* de neuronas, debido a que dichos pares no contribuyen a reducir la energía total de la red⁵.

⁵ Las neuronas contribuyen por pares a la energía total del sistema. Entonces, aunque cada neurona haga lo que más le conviene en forma individual, no podrá "tomar una actitud" que satisfaga a todos, y que con algunos vecinos quedara bien y con otros no. Es por eso que hablamos de "pares frustrados".

**CAPITULO 3: CONCEPTOS FUNDAMENTALES
DE LAS REDES NERVIOSAS ARTIFICIALES**

3. CONCEPTOS FUNDAMENTALES DE LAS REDES NERVIOSAS ARTIFICIALES.

En los últimos años se ha visto un enorme interés dentro del tópico de sistemas nerviosos artificiales. Estos sistemas, también llamados redes nerviosas, sistemas conexiónados, conexionismo, procesamiento distribuido en paralelo, computación nerviosa, modelos de red nerviosa, computación estilo cerebro, y neurocomputadoras, fueron puestos en relieve en el reciente anuncio de Japón de su proyecto de Sexta Generación. Mientras que el proyecto de la Sexta Generación consiste de mucho más que esfuerzos en la ciencia de la computación, dentro de este campo, la importancia era claramente colocada en sistemas basados en modelos neurológicos.

Los modelos actuales de redes nerviosas tienen el potencial de dotar con capacidades cognoscitivas a las computadoras. El desarrollo teórico del campo ha madurado brillantemente, a partir de 1982 con los trabajos de John Hopfield, y las aplicaciones están brotando por doquier: Procesamiento de Señales Digitales, Imagenología, Robótica, Diseño de computadoras, Investigación de Operaciones, Economía y Finanzas.

Las redes nerviosas debutaron hace casi medio siglo, desaparecieron en los años 60 y han revivido en los años 80 con un vigor extraordinario.

Una red nerviosa artificial es un conjunto de elementos procesadores o nodos (*neuronas*) conectados unos con otros

de acuerdo a arquitecturas específicas y con pesos o intensidades modificables en la conexión (*sinapsis*) de una neurona a otra. En términos más generales, una red nerviosa es un modelo inspirado en las neuronas biológicas que constituyen los cerebros de animales y humanos.

Una excelente definición de una red nerviosa es provista por Robert Hecht-Nielsen: Una red nerviosa es un sistema de computación el cual está montado de un número de elementos procesadores simples altamente interconectados, y los cuales procesan información y por su estado dinámico responde a entradas externas.

Las computadoras convencionales procesan información en *serie*, esto es, efectúan una instrucción después de otra. Como consecuencia, la mayor parte de la computadora y de sus periféricos están ociosos gran parte del tiempo mientras esperan instrucciones del procesador central. El procesador central que puede direccionar una celda de localidades de memoria. Los datos y las instrucciones son almacenados en localidades de memoria. El procesador busca una instrucción y cualquier dato requerido por aquella instrucción, ejecuta la instrucción, y salva los resultados regresándolos dentro de la localidad de memoria específica. Con el objeto de acelerar este proceso, han sido diseñadas grandes máquinas, llamadas supercomputadoras, cuyo propósito es llevar a cabo el procesamiento de la información en *paralelo*; esto es, constan de varios elementos procesadores, cada uno de los cuales efectúa tareas de manera independiente y simultánea.

De esta forma, el trabajo se divide en subtrabajos independientes, los cuales son asignados a diferentes elementos procesadores. Un ejemplo de estas máquinas es la computadora modelo **CRAY 1**, la cual consta de 64 elementos procesadores.

Una red nerviosa, en contraste, no es ninguno de los dos: ni secuencial y ni siquiera necesariamente determinístico. No tiene una celda de memoria separada para el almacenaje de los datos. Los procesadores que montan una red nerviosa no son unidades procesadores centrales altamente complejas. En su lugar, una red nerviosa está compuesta de muchos elementos procesadores simples.

La red nerviosa no ejecuta en serie las instrucciones, sino en su lugar responde en paralelo para las entradas presentadas a ella. El resultado no es almacenado dentro de una localidad de memoria específica, sino consiste del estado global de la red después que ha alcanzado alguna condición de equilibrio.

El conocimiento dentro de una red nerviosa no está almacenado en una localidad particular. No podemos mirar la dirección de memoria 1354 para recuperar el valor de la variable x . En su lugar, el conocimiento es almacenado en ambos: en el camino de los elementos procesadores que están conectados (el camino de la señal de salida de un elemento procesador está conectado a las señales de entrada de muchos otros elementos procesadores), y dentro de la importancia (o peso de valor) de cada entrada hacia los elementos

procesadores. El conocimiento es así más una función de la arquitectura o estructura de la red que los contenidos de una localidad particular dentro de la red.

Dos elementos primarios constituyen a una red nerviosa: **elementos procesadores** (llamados *neuronas*) e **interconexiones**^d.

Una neurona es generalmente un mecanismo extremadamente simple que tiene algunas señales de entrada y una única señal de salida (Figura 3.1).




Fig. 3.1 Una neurona es un mecanismo simple que tiene señales de entrada y una única señal de salida.

Los elementos procesadores, dentro de la red nerviosa

^d Los "elementos procesadores" emulan la operación de neuronas dentro de los organismos vivos. Están interconectados vía canales de información llamados "interconexiones".

equivalen a la neurona, son simples mecanismos que reciben un número de señales de entrada y, basados en esas entradas, ambos generan una señal de salida única (un disparo) o no. La señal de salida de una neurona es enviada a otras muchas neuronas (y posiblemente regresen hacia si mismas) como señales de entrada via las interconexiones entre neuronas.

La importancia de las redes nerviosas artificiales es que ellas parecen ser enormemente útiles en la resolución de problemas que la mayoría de los sistemas tradicionales han encontrado completamente intratables. En particular, las redes nerviosas han hecho fuertes avances en distintos problemas *mentales* tradicionales de la Inteligencia Artificial, incluyendo el reconocimiento de sonido continuo y síntesis, visión, reconocimiento de ruta, y vehículos autónomos.

Las redes nerviosas aparecen para ser totalmente buenos en la solución de clases de problemas exactamente como la gente puede resolverlos fácilmente. Ellas también son completamente terribles al resolver las clases de problemas que las computadoras tradicionales hacen completamente bien, pero que la gente resuelve muy despacio e ineficientemente.

Una neurona artificial o procesador está *inspirada* en una neurona biológica. El parecido radica en que el procesador recibe múltiples entradas (análogos de potenciales eléctricos) que una a una son ponderadas y luego sumadas. El resultado de esta sumatoria, es luego presentado

como entrada a un componente no lineal, que actúa como umbral, y de la comparación resulta o no una respuesta o activación. Si la entrada es mayor que el valor del umbral, la neurona dispara o genera una señal de salida. Si la entrada es menor que el umbral, el elemento procesador no dispara y no es generada la salida. Hasta ahí es el parecido biológico.

Como muestra la Figura 3.2, la señal de salida de la neurona se abre como abanico hacia afuera para actuar como entradas a un número de otras neuronas. También puede actuar como una de las señales de entrada para sí mismo, dependiendo en sí la arquitectura de la red requiera retroalimentación directa. Además, estas salidas (y las correspondientes señales de entrada), pueden ser cada una excitatoria o inhibitoria. Una entrada excitatoria significa que la señal contribuye para causar a la neurona receptora a disparar; y una entrada inhibitoria significa que esta señal contribuye para mantener inactiva a la neurona desde el disparo. A menudo, las entradas excitatorias son rotundamente pesadas, categóricamente valoradas, mientras que las entradas inhibitorias son negativamente pesadas o negativamente valoradas.




Figura 3.2 La señal de salida de la neurona se abre en abanico hacia afuera para accionar como entradas para otras neuronas.

En la figura 3.3 se muestra un procesador donde las entradas u_j son ponderadas por los llamados pesos p_j y la suma de todos ellos da como resultado el valor P . El valor P se aplica como entrada al elemento no lineal tipo sigmoidal que produce una salida o activación y . Es costumbre presentar al procesador como un círculo con dos flechas, una que entra al círculo y que indica la entrada, y otra que sale, que indica la salida o activación. A un círculo pueden entrar muchas flechas, pero sólo sale una.




Figura 3.3 Los componentes de una neurona artificial y su símbolo.

La inclusión del elemento no lineal sigmoidal es una de las adiciones importantes a la neurona artificial contemporánea, ya que hace a estas analógicas en lugar de digitales como eran, por ejemplo, los modelos neuronales de McCulloch y Pitts y, además, proporciona continuidad y diferenciabilidad en el sentido matemático. Debemos recordar que los cerebros biológicos son *computadoras* analógicas no lineales. De esta manera, los modelos de ahora son más cercanos a la realidad.

Una vez que se ha definido el procesador se puede hablar de redes nerviosas artificiales. Una red nerviosa artificial, a diferencia de un procesador, casi no está inspirada en las redes nerviosas biológicas, pues se sabe muy poco acerca de ellas. Una red nerviosa artificial es un arreglo de procesadores masivamente interconectados en arquitecturas específicas, que generalmente son capas en cascada. Usualmente están constituidas por una capa de entrada, una o más capas intermedias o escondidas y una capa de salida como se muestra en la figura 3.4. La organización de las interconexiones no está inspirada biológicamente. Sin embargo, la red en su totalidad es capaz de aproximar algunas de las tareas que realizan las redes nerviosas biológicas.




Figura 2.4 Red nerviosa artificial con tres capas de neuronas artificiales.

Tanto en las redes nerviosas biológicas, como en las artificiales, su punto fuerte está en la capacidad para comunicarse unas con otras. Una neurona o procesador puede excitar o inhibir la actividad de otra u otras neuronas, por medio de su conexión con ellas. En redes nerviosas artificiales, a la magnitud de este efecto de una neurona sobre otra, se le da el nombre de peso de la conexión. El peso de la conexión es un modelo burdo del efecto sináptico de una neurona sobre otra u otras como sucede en las neuronas biológicas.

El peso de la conexión entre dos neuronas que se comunican una con la otra, es uno de los conceptos básicos de las redes nerviosas artificiales. En una red nerviosa donde existen muchas conexiones, los pesos pueden ser constantes⁷. Sin embargo, es en redes nerviosas, con pesos

7

Los pesos pueden ser constantes cuando se desea que la

que pueden variar en donde se encuentran las posibilidades de aplicación práctica más relevantes.

Estamos acostumbrados a manejar pocas unidades, podemos tener una cámara fotográfica, una videocasetera, dos automóviles y, a veces, hasta dos casas. En nuestra computadora personal tenemos un procesador, y si tenemos acceso a una supercomputadora disponemos de cuatro, ocho o 16 procesadores. Para visualizar el potencial de las redes nerviosas, tenemos que aprender a pensar en cientos y hasta en miles de procesadores con capacidad de comunicarse entre ellos de cualquier manera imaginable. Una red nerviosa con mil procesadores en la capa de entrada y mil en la capa de salida, tiene un millón de conexiones si conectamos todos los procesadores de la capa de entrada con todos los procesadores de la capa de salida. Tal masividad en número de procesadores y de conexiones no es una exageración, es la realidad en las aplicaciones de las redes nerviosas. No podría ser de otra forma, ya que estamos inspirándonos en el cerebro humano, donde existen 10^{10} neuronas. No es de extrañar que al estudio de redes nerviosas artificiales también se le llame conexionismo.

Esta arquitectura basada en multitud de procesadores y de conexiones implica que la red posee una actividad en

red nerviosa aprenda alguna cosa y después no siga aprendiendo, se quede con únicamente los conocimientos que le dieron en la etapa de entrenamiento.

paralelo y distribuida en todas sus conexiones. La actividad de la red en respuesta a una entrada específica es una decisión colectiva, basada en el intercambio concurrente de información entre los procesadores. Un conocimiento o su transformación no se localizan en un lugar específico de la red, sino que está desparramado sobre las conexiones. Se acostumbra decir que la actividad de la red es una computación colectiva.

Durante la vida de un ser humano se pierden muchas células nerviosas y conexiones entre ellas sin pérdida de funcionalidad. Incluso, ante la pérdida más drástica que puede ocasionar una lesión, en ocasiones se observa que otras partes del cerebro realizan la función de la región dañada. En cambio, nuestras computadoras están diseñadas de manera que toda parte y toda conexión son imprescindibles para su buen funcionamiento. Si le amputamos un chip o le cortamos un cable limitados inmediatamente su desempeño. Esto se podría resolver si en cada computadora se tuvieran múltiples copias de cada componente a manera de repuesto; esta multiplicidad haría al equipo más complicado y más caro, pero no mejor, y no parece ser la vía que la naturaleza escogió para diseñar nuestro cerebro. Por el contrario, parece que la operación de nuestro cerebro se da de una manera distribuida, lo que implica que las funciones están repartidas entre un número muy grande de componentes, y ninguna parte del trabajo se delega exclusivamente en una de ellos. La necesidad de funcionar de esta manera justifica el

conexionismo masivo que revelan los estudios anatómicos del cerebro. Llevar a cabo simultáneamente varios procesos es una capacidad del cerebro necesaria para realizar tareas de alto nivel como controlar visualmente la locomoción. Si no tuviéramos esta capacidad de procesamiento en paralelo no podríamos hacer deporte o tocar un instrumento musical, pues muchas de las acciones que esto requiere tienen que coordinarse colectivamente y ocurrir en un lapso demasiado pequeño para que puedan realizarse en orden secuencial.

Las redes nerviosas son sistemas con capacidad de procesamiento paralelo y distribuido. Aunque se han diseñado diversos modelos de computadoras que funcionan como redes nerviosas, el paradigma clásico es un arreglo numeroso de procesadores (unidades) altamente interconectados. Una vez que los procesadores están dados, el funcionamiento de la red está determinado por los pesos de las conexiones, y al modificar éstos, se modifica el comportamiento de la red.

Las computadoras que funcionan con este tipo de redes, a diferencia de las convencionales, no se programan sino que se entrenan. Después de un periodo de entrenamiento, durante el cual los pesos de la red se van modificando para condicionar a la red a que produzca el comportamiento deseado, viene la etapa de operación, durante la cual la red debe conducirse de manera adecuada ante situaciones que nunca conoció en el periodo de entrenamiento. Una red será más eficiente a medida que tenga más experiencia (por ejemplo, que sus conexiones hayan sido arregladas para dar la respuesta

adecuada ante un número mayor de escenarios diferentes). Obviamente, el problema crucial en esta arquitectura es el diseño de métodos y algoritmos para cambiar los pesos secuencialmente, una vez que cierta colección de parejas de estímulos y respuestas han sido dados.

Hasta el momento, una de las diferencias básicas que existe entre computadoras y seres humanos tiene que ver con la utilidad práctica del material memorizado. Esta diferencia consiste en que mientras una computadora almacena información que únicamente puede ser llamada de manera explícita por un programa, el ser humano *aprende*. En el hombre, la adquisición de nueva información modifica su comportamiento (o su forma de pensar), en la medida que la aporta nuevos criterios para la toma de decisiones, tanto a nivel consciente como inconsciente. El hombre debe su gran capacidad de adaptación, también llamada *plasticidad*, a su habilidad de aprender.

Una ventaja potencialmente importante de las redes nerviosas es su alto grado de *resistencia de error*. Una computadora normal puede fallar completamente en su operación si un solo bit de la información almacenada o una declaración de programa es incorrecto. Esto conduce a un alto riesgo de fracaso, especialmente si el sistema no puede ser continuamente supervisado. En contraste, la operación de una red nerviosa a menudo queda casi no afectada si una neurona individual falla, o si unas pocas conexiones sinápticas se averían. Usualmente requiere una fracción importante de

elementos que fallen antes de que el deterioro sea observable. En vista del rápido uso incrementado del procesamiento electrónico de datos dentro de áreas vitales esto es una característica atractiva de la computación nerviosa, lo cual puede volverse de importancia práctica.

Las diferencias principales entre las computadoras tradicionales y las computadoras nerviosas se resumen en la figura 3.5.

Computadoras Tradicionales

Computadoras Nerviosas

Útiles para seguir instrucciones precisas.

Útiles para resolver problemas en los que no es posible dar una receta precisa.

Excelentes para efectuar cálculos matemáticos.

No muy confiables para efectuar cálculos matemáticos.

Se alimentan con programas; se requiere del uso de algoritmos.

Se alimentan con datos; no se requiere del uso de algoritmos.

No aprenden; su desempeño es siempre el mismo.

Aprenden mediante la inspección de datos; su desempeño mejora con la cantidad de información recibida.

No toleran errores.

Toleran errores.

No se equivocan (si acaso, el que se equivoca es el programador).

Pueden equivocarse.

No usan los datos guardados en su memoria, a menos que éstos sean explícitamente llamados por el programa.

Usan activamente, toda la información guardada en la memoria.

Su funcionamiento depende del buen funcionamiento de TODOS sus componentes.

Su funcionamiento no se ve alterado por la falla de un pequeño número de sus componentes.

Procesa datos digitales que son escritos en 1's o 0's para una precisión matemática.

Procesa señales analógicas que fluctúan continuamente

NEVES NERVIOSAS ARTIFICIALES

Hace o no decisiones, usando funciones matemáticas y lógicas.

Manipula datos en una secuencia rigidamente estructurada de manera que las operaciones estan siempre bajo control y los resultados son predecibles. Encuentra respuestas precisas para cualquier problema, dado una cantidad de tiempo.

Almacena información de manera que los datos especificos pueden ser recuperados fácilmente.

Hace decisiones en base de datos confusos, incompletos y, contradictorios.

Formula metodos independientemente de los datos procesados, frecuentemente con resultados sorprendentes

Encuentra respuestas buenas, rápidas -aproximadamente- para problemas altamente complejos.

Almacena información de manera que la recuperación de cualquier pieza de información automáticamente llama todos los hechos relacionados.

Figura 3.5. Esta tabla compara las características de las computadoras convencionales y las computadoras nerviosas.

3.1 ANALISIS ESTADISTICO.

3.1.1 VARIABLE.

Las *variables* se les clasifica en *determinísticas* y *aleatorias*; a su vez, cada uno de estos grupos se subdivide en variables *escalares*, *nominales*, *discretas* y *continuas*.

Algunas variables asumen VALORES NUMERICOS, tal es el caso de la estatura y peso de los estudiantes; las calificaciones obtenidas por cinco alumnos en un examen fueron 5, 7, 6, 10, 8. Esta variable asume, por lo tanto, valores numéricos. Una variable que sólo toma valores numéricos se llama VARIABLE ESCALAR.

Cuando una variable sólo puede tomar valores designados por *nombres o atributos*, se dice que toma VALORES NOMINALES.

Los valores nominales de la variable resultado de lanzar un moneda son cara y cruz.

Quando una variable puede tomar un numero finito o infinito, pero numerable (que se puede numerar) de valores, se llama VARIABLE DISCRETA O DISCONTINUA. Una variable nominal toma forzosamente un numero finito de valores, por lo cual es una variable discreta.

Una variable que puede tomar un numero infinito de valores no numerables (que no se pueden numerar) se llama VARIABLE CONTINUA. Entonces, una variable es discreta o es continua.

Una VARIABLE ALEATORIA es una función con valores reales que está definida sobre el espacio muestral. Al termino variable aleatoria también se le conoce como variable posible, cantidad incierta o variable estocástica.

3.1.2 DISTRIBUCION NORMAL

La distribución NORMAL o de GAUSS se aplica solamente a variables continuas.

Una variable aleatoria tiene distribución normal si su distribución de probabilidades tiene la siguiente fórmula

$$f(x) = \frac{1}{\sqrt{2\pi} \sigma(x)} e^{-\frac{(x - E(x))^2}{2\sigma^2(x)}}$$

donde $\pi = 3.141\dots$, $e = 2.718\dots$, $E(x)$ es la media de x ,

$\sigma^2(x)$ es la variancia, y $\sigma(x)$ es la desviación estándar.

**CAPITULO 4: ALGORITMOS DE APRENDIZAJE
PARA REDES NERVIOSAS ARTIFICIALES**

4.1 APRENDIZAJE EN REDES NERVIOSAS.

Primero, considere qué aprendizaje quiere en el contexto de la red nerviosa. Recuerde que una red nerviosa está montada de muchos elementos procesadores simples que están interconectados con cada uno de los otros (figura 4.1.1). Cada elemento procesador recibe un número de entradas, x_i , los cuales están denotados con pesos, w_i . Desde la entrada total de pesos, el elemento procesador calcula una única señal de salida y .




Figura 4.1.1 Un elemento procesador simple.

Aprender implica que el elemento procesador de algún modo cambia su conducta en respuesta al ambiente. Por ejemplo, si el elemento procesador originalmente da una salida de +1 en respuesta a una ruta de entrada particular, después de que el aprendizaje ha tomado lugar, el elemento procesador debe ahora tener una salida de -1 para aquella ruta de entrada igual. El elemento procesador de algún modo ha *cambiado su mente* con respecto a la respuesta correcta.

para aquella entrada debiera ser.

El cambio de los pesos en las entradas se efectúa de acuerdo a unas leyes o ecuaciones de aprendizaje, las cuales se explicaran posteriormente. La ley de entrenamiento para la red debe definir precisamente cómo cambiar los pesos en respuesta para un par de entrada y salida dados.

Debo señalar aquí la diferencia entre *entrenar* y *aprender*. Casi frecuentemente estos terminos son confusos, aprendizaje se refiere al proceso interno por el cual los pesos u otros aspectos de la red cambia. Entrenar por otro lado, es un proceso externo aplicado a la red para causar que el aprendizaje ocurra. El investigador de la red nerviosa entrena; la misma red nerviosa aprende.

El entrenamiento en redes nerviosas pueden estar acompañadas usando cualquiera de los distintos *estilos* generales. Entrenamiento supervisado significa que la red tiene alguna entrada *omnisciente* que está presente durante el entrenamiento para decirle que la respuesta correcta debiera estar. La red luego tiene un propósito de determinismo si su salida fue correcta o no, y así conocer cómo aplicar su ley de aprendizaje para ajustar sus pesos (más adelante se explicará más detalladamente). Entrenamiento calificado significa que aunque la red reciba alguna retroalimentación en la calidad de sus salidas, aquella retroalimentación no es exacta. Entrenamiento no supervisado significa que la red no tiene conocimiento de toda la respuesta *correcta* y así no puede conocer exactamente qué respuesta *correcta* debe de ser.

Las tres clases de entrenamiento pueden estar mejor ejemplificadas por el juego simple de niños de *Adivina un Número*. Suponga que Juan piensa en un número entre 1 y 10 y contesta José a la adivinanza. Si él usa entrenamiento calificado, la sesión debiera ir como esto:

Juan : Tengo mi número. Adivina
 José : 5
 Juan : Muy alto
 José : 2
 Juan : Muy bajo
 José : 3
 Juan : Muy bajo
 José : 4
 Juan : ¡ Correcto !

Si Juan usa entrenamiento supervisado, la sesión debería ir como esto:

Juan : Tengo mi número. Adivina
 José : 6
 Juan : Tu adivinanza es dos números más alto
 José : 4
 Juan : ¡ Correcto !

Finalmente, si Juan usa el entrenamiento no supervisado, la sesión debería ir como esto:

Juan : Tengo mi número. Adivina
 José : 5
 Juan : No. Adivina
 José : 4
 Juan : No. Adivina
 José : 3
 Juan : No. Adivina
 |

Como puede ver, solo el entrenamiento calificado hace este juego divertido para jugar. En el entrenamiento supervisado, el juego siempre termina en la segunda adivinanza. Con el entrenamiento no supervisado, el juego nunca termina porque el pobre de José nunca recibe cualquier

conocimiento de cuán tan bien el lo está haciendo. Al igual que cuando el adivina la respuesta correcta (cuatro), el no recibe retroalimentación para decirle que estuvo en lo correcto. Mientras que el entrenamiento supervisado termina después de dos adivinanzas, el entrenamiento no supervisado nunca termina hasta que Jose decide que el ha encontrado el número y elige parar las adivinanzas.

Todas estas clases de entrenamientos son importantes para aplicaciones diferentes, pero en este trabajo nos enfocaremos únicamente a el entrenamiento supervisado, el método usado más comunmente en aplicación de desarrollo.

El algoritmo de aprendizaje más comunmente usado en el mundo de hoy es un esquema supervisado, desarrollado por Bernard Widrow y Ted Hoff de la Universidad de Stanford (Palo Alto, California) y publicado primeramente en 1960.

4.2: RETROPROPAGACION DE LAS REDES.

Vamos a construir una simple retropropagación de red que aprenda a reconocer *imagenes* digitales de letras. Suponga que la tarea es presentar a la red con una rejilla, por decir 5×7 , la cual contiene una imagen binaria de letras —como la impresora de matriz de puntos produce—. La red debe generar el código ASCII de 8 bits de una letra como su salida.

Las redes con retropropagación son jerárquicas; eso es, ellas siempre contienen al menos tres capas de neuronas: Una capa de entrada, una capa de salida y una capa intermedia. (La capa intermedia es generalmente llamada *capa oculta*).

Obviamente, la capa de entrada debe tener 5×7 , o 35, neuronas de entrada. La capa de salida debe tener 8 neuronas para dar una salida de 8 bits. El tamaño de la capa intermedia es realmente elegida por el diseñador de la red. Si la capa intermedia es muy grande, fomenta a la red hacia la ruta de entrada del antecedente (*memorizar*) en vez que generalice la entrada dentro de características. Esta situación reduce la habilidad de la red para dirigir entradas no familiares después de que el entrenamiento está completo. De otro modo, si la capa intermedia es muy pequeña drásticamente ampliaría el número de iteraciones requeridas para enseñar a la red. Por esta discusión, asume la capa intermedia un tamaño de cuatro neuronas como un compromiso razonable.

Cada capa dentro de la red está completamente conectada

a la próxima capa. En otras palabras, toda neurona dentro de la capa de entrada envía su salida hacia otra neurona dentro de la capa intermedia, y toda neurona dentro de la capa intermedia envía su salida hacia toda neurona dentro de la capa de salida. Los diagramas de la figura 4.2.1 muestran esta conectividad dentro de una red un poco más pequeña. Dentro de cada capa, no existen conexiones para todos. Así, las neuronas conectan a todos las neuronas dentro de la(s) capa(s) antes y después de ellos, pero no conectan a cualquiera de las neuronas dentro de sus propias capas.




Figura 4.2.1 Típica retropropagación de la red.

Este esquema de conectividad es solo una ruta posible de construcción de una retropropagación de la red. El término

de *retropropagación* se refiere a la regla general de aprendizaje, no a una arquitectura específica, de manera que los investigadores pueden, y hacen, arreglos con la estructura de la red cuando construyen los sistemas de retropropagación.

La red es presentada con una ruta de entrada similar a la figura 4.2.2. Además de la ruta de la rejilla de entrada durante el entrenamiento, las neuronas de la capa de salida también están mostrando la salida *correcta* que ellas producen.



Figura 4.2.2 Una simple entrada/salida para la retropropagación de la red -letra A-

El proceso de entrenar es simplemente sencillo. Antes de comenzar, primero colocamos al azar los pesos dentro de la red, excepto aquellos pesos del mundo exterior para la capa de entrada. Estos pesos de entrada son simplemente ajustados a +1. El problema particular no es exactamente cómo los pesos son colocados al azar de los pesos restantes, sino que los pesos deben ser diferentes y no ser 1; típicamente son pequeños, valores aleatorios entre ellos, por decir, -0.25 y +0.25 son usados.

Después, presenta la red con las series repetidas de las rutas de entrada. Por cada ruta de entrada, ajusta los pesos en las interconexiones usando la Regla Delta⁸. Después hace esto muchas veces, mirando la salida de la red desde la capa de salida, su ejecución mejora de manera que eventualmente genera correctamente las rutas de salida deseadas para cada una de las rutas de entrada presentadas a él.

4.2.1 FLUJO DE ACTIVACION HACIA ADELANTE.

Considere una representación completa de una ruta de entrada, por decir la letra A, mire exactamente como esta muestra es realizada. Recuerde que los pesos están dispuestos al azar recientemente y la red está ahora mirando la ruta por la primera vez.

La capa de entrada recibe la ruta y lo pasa a cada neurona dentro de la capa intermedia. Cada neurona calcula

⁸ La Regla Delta cambia los pesos w y esta expresada como:

$$w_{\text{nuevo}} = w_{\text{viejo}} + \frac{\beta E x}{[x]^2}$$

donde x y w son los vectores de entrada y peso, respectivamente. Esta regla es también conocida como la regla de entrenamiento Widrow-Hoff, o regla del Menor Promedio Cuadrado (LMS). La constante β es una constante de aprendizaje que se elige después. Observe que esta ecuación es una ecuación vectorial, no una ecuación escalar. El error E y la constante β son valores escalares; los otros elementos son vectores. Observe un punto importante, solamente los pesos modificados son aquellos pesos que están en las entradas x .

su activación dentro de este modo: Primero la suma de las entradas, I , es determinada multiplicando cada una de las veces de la señal de entrada al peso (aleatorio) en aquella interconexión:

$$I = \sum w_i x_i$$

$$Y_i = f(I) \quad (4.2.1.1)$$

donde la suma es tomada sobre i , y $1 \leq i \leq 35$. El valor máximo de 35 para i resulta porque la red tiene una rejilla de la capa de entrada de 5×7 . Los términos de w y x son las señales de peso y entrada, respectivamente, en cada una de las conexiones de esas neuronas de la capa de entrada para cada neurona de la capa intermedia.

La función $f(I)$ es llamada la función de activación de la neurona. Determina la actividad, o el nivel de excitación, generada dentro de la neurona como un resultado de una señal de entrada de un tamaño particular. Para una retropropagación de la red, esta función debe ser sigmoideal; aquello es, debe ser continuo, de forma de S, incrementado monótonamente, y valores establecidos que se acercan asintóticamente como los acercamientos de entrada del infinito más o menos. La figura 4.2.1.1 muestra una función típica sigmoideal.




Figura 4.2.1.1 Función de activación típica sigmoideal.

Los detalles exactos del sigmoideo no son usualmente críticos en una retropropagación de red. Típicamente, el límite superior del sigmoideo es +1, y el límite inferior es cualquiera de los dos: 0 o -1. La pendiente de la curva e incluso la función exacta usada para calcularla son menos importantes que la forma de S general. Claro, las características de la curva afectan la actividad individual de la neurona, pero la red global usualmente trabaja a pesar de todo bien. Para este ejemplo, la red usa una curva sigmoideo *logística*, expresada como una función de I, la entrada de peso neta para la neurona:

$$f(I) = \frac{1}{1 + e^{-(I+T)}} \quad (4.2.1.2)$$

donde T es un umbral simple, x es la entrada de arriba y e es la constante matemática exponencial. Para hacerlo aun más simple, ponga el umbral a 0 para este problema.

FALLA DE ORIGEN

NEDES NERVIOSAS ARTIFICIALES

Una breve inspección de la función logística revela distintos puntos. Primero, la red no puede producir salida binaria, cuando x tendría que ir a cualquiera de los infinitos más o menos para permitir un resultado de +1 o 0. Después, observe que los pesos, y así la suma de las entradas, pueden ser ambos positivo o negativo. Únicamente con una suma de entradas menor que cero puede la activación aproximarse a un valor de cero. Finalmente, observe que le tomaría una cantidad de tiempo infinito a la neurona para llegar a cada uno de los resultados de +1 o 0; por consiguiente, arbitrariamente declaramos que cualquier activación mayor que +0.9 será considerada un +1 en la capa de salida final, y cualquiera menor que 0.1 será considerado una salida de cero para la capa de salida.

La activación total de las neuronas de la capa intermedia calculada por la función de activación es usada como la salida de cada neurona. Esta situación asegura que las salidas de las neuronas están forzadas a estar dentro del rango de 0 a 1, cuando aquellas están en el rango de la función de activación.

Esas salidas desde las neuronas de la capa intermedia viajan a lo largo de las conexiones entre las capas intermedias y de salida para volverse las señales de entrada hacia la capa de salida. Cada neurona aquí recibe sus señales de todas las neuronas de la capa intermedia; y, en exactamente la misma manera como antes, una activación es calculada por cada neurona de la capa de salida. Esas

activaciones vuelven a la salida para la red.

4.2.2 FLUJO DE ERROR HACIA ATRAS.

Ahora compare la salida de la red a la ruta de la salida deseada de 0100 0001 (el código ASCII para "A"). Claro, la ruta está equivocada, de manera que los pesos de la red deben de ser ajustados para completar esta iteración de la red. Para llevar a cabo esta tarea, recurrimos a la familiar Regla Delta y calcula los cambios de peso como:

$$w_{\text{nuevo}} = w_{\text{viejo}} + \frac{\beta EX}{[X]^2} \quad (4.2.2.1)$$

Considere este pensamiento un momento. En la capa de salida, cada neurona ciertamente conocen ambos: sus pesos viejos y las señales de entrada que reciben. La constante β es simplemente un parámetro entre 0 y 1, la cual está presente por el diseñador. El error E es simplemente la salida actual sustraída de la salida deseada. Esto es conocido. La capa de salida debe sacar el código ASCII, y su actual salida es también conocida, así el error puede ser calculado fácilmente. Así, la Regla Delta es fácil para aplicarla a la capa de salida.

La Regla Delta no puede ser aplicada a la capa intermedia: Las señales de entrada de cada neurona dentro de la capa intermedia son conocidas, como es la salida resultante. El problema es el error dentro de la capa intermedia: la salida deseada para esas neuronas es

desconocida, así que el cálculo del usual *error deseado menos el actual* es imposible aquí.

La respuesta a este dilema son ambos simple y complejo. Lógicamente, si las neuronas de salida generaron la respuesta errónea puede ser debido a sus propios pesos incorrectos, pero también puede ser debido a las neuronas de la capa intermedia que generan señales de entrada erróneas hacia la capa de salida. Considere una neurona particular de la capa intermedia, la cual generó una señal de, por decir, 0.6. Esta señal va hacia cada una de las neuronas de la capa de salida, y cualquier error dentro de aquel valor de 0.6 ciertamente contribuye a cada uno de esos errores de salida de las neuronas.

Para asignar esta culpa, primero los errores de *retropropagación* para cada neurona de la capa de salida hacia la capa intermedia, usando las mismas interconexiones y pesos como la capa intermedia usa para transmitir sus salidas hacia la capa de salida (fig. 4.2.2.1). Luego calcule un error para cada neurona dentro de la capa intermedia, basado en su parte de la culpa para el error de la capa de salida. Este cálculo se ve como:

$$e_i = f'(I_i) \left[\sum_j w_{ij} E_j \right] \quad (4.2.2.2)$$

donde e_i es el error dentro de la i -ésima neurona de la capa intermedia, y la suma es tomada sobre j , donde j es la j -ésima neurona de la capa de salida.




Fig. 4.2.2.1 La activación fluye hacia adelante mientras que los errores fluyen hacia atrás a través de la red.

El término restante es la derivada de la función de activación de la neurona de la capa intermedia para la entrada de la red recibida. Para la función logística simple, la derivada es:

$$f'(x) = f(x) (1 - f(x)) \quad (4.2.2.3)$$

El cálculo de esta derivada es sencillo hacer. La figura 4.2.2.2 muestra que para la curva logística, la derivada se parece mucho a una campana, con valores relativamente grandes dentro del rango intermedio de entradas y valores muy pequeños al final de ambos. (Esta condición es verdadera de cualquier curva sigmoideo). Aplicando la derivada se consiguen dos propósitos: Primero, contribuye a la estabilidad de la red, cuando asegure que como las salidas se aproximan al 0 y 1, solo cambios muy pequeños pueden

ocurrir. Segundo, ayuda a compensar para la culpa excesiva unida a una neurona de la capa intermedia.




Figura 4.2.2.2 La derivada de una curva sigmoideal.

En casos donde la conexión entre una neurona de la capa intermedia y una neurona de la capa de salida puede ser muy fuerte (valores extremos para el peso en la interconexión), y la neurona de la capa de salida tiene un error muy grande, los pesos de una neurona de la capa intermedia pueden estar asignados a un error muy grande también, incluso si aquella neurona tuvo una salida muy pequeña y así no pudo haber colaborado mucho al error de salida de la neurona. Aplicando la derivada de la función de señal, este error es moderado, y sólo pequeño para mejorar cambios son hechos a los pesos de la neurona de la capa intermedia.

El error propagado desde la parte posterior de la capa de salida hacia la capa intermedia, y cada error de la neurona de la capa intermedia ha sido calculado. Ahora use

este error dentro de la Regla Delta y ajuste sus pesos como antes. Si la red tuvo más de tres capas —y algunas retropropagaciones de redes hacen— este error de la capa luego se retropropaga hacia la capa previa, los cambios de peso son calculados al mismo tiempo, y así sucesivamente. En este caso, sin embargo, la ecuación de la Regla Delta ajusta los pesos en la única capa intermedia.

4.2.3 LA REGLA DELTA GENERALIZADA.

Este ejemplo simple no parecía tan difícil como antes de que comenzó, pero se ha convertido mucho más complejo. Para resumir la operación de la red durante el entrenamiento primero presenta una ruta hacia la red y permite el flujo de la activación del resultado desde la capa de entrada completamente hacia la capa de salida. Luego compara la ruta de salida resultante hacia la ruta deseada y, comenzando con la capa de salida, ajusta los pesos, capa por capa, propagando cada regreso del error de la capa hacia la capa anterior y calculando los cambios de peso como va. No cambia actualmente cualquiera de los pesos hasta después de que el error tuvo el regreso propagado hacia la capa anterior.

Una vez que la activación ha fluído hacia adelante de la red completamente y el error ha fluído hacia atrás completamente toda la red, esta iteración de la red está completa, y está lista para recibir la próxima ruta.

Una de las características no tan bonitas de la

retropropagación de las redes es que ellas frecuentemente requieren cientos, miles, o a veces decenas de millares de iteraciones para aprender la ruta. También, el valor del parámetro β (mencionado anteriormente) debe ser puesta convenientemente pequeña. Tales valores pequeños de β pueden causar que la red tome mucho más iteraciones para aprender que con valores más grandes.

La retropropagación es una de las más importantes redes nerviosas disponibles hoy, convirtiéndose en razonablemente simple para implementar y trabaja extremadamente bien para una amplia variedad de aplicaciones. No es perfecto del todo, pero ciertamente es una red altamente práctica para aplicaciones de hoy.

El primer inconveniente de la retropropagación, de hecho, es que requiere muchas presentaciones de los datos de entrada para aprender y cada presentación requiere dos pasos desde el principio hasta el fin de la red, un paso hacia adelante y un paso hacia atrás, cada uno de los cuales es relativamente complejo computacionalmente. Así, sus usos primarios son para aplicaciones en los cuales el aprendizaje pueda tomar el lugar de *fuera de línea* y dentro de un ambiente no de tiempo real. —Una vez entrenado, los pesos y las conexiones de la red pueden ser enfriadas y la red puede manipular a mucha más alta velocidad de entrada—.

La popular red de retropropagación aprende ajustando los pesos de las neuronas con una regla de aprendizaje, la cual es una variación de la vieja Regla Delta usada por el

adeline. .

Para encontrar la solución correcta a un problema. La retropropagación tienen otra grave dificultad también: Requiere la red ser provista con la respuesta correcta durante el entrenamiento.

4.3: APRENDIZAJE COMPETITIVO KOHONEN.

El modelo de aprendizaje Kohonen, originalmente propuesta por Teuvo Kohonen de la Universidad Tecnológica de Helsinki en Finlandia, este modelo de aprendizaje aun no es conocido en America como lo es en Europa, pero provee un modelo relativamente simple y aun fascinante de cómo las redes nerviosas pueden organizarse ellas mismas.

El término de *organización de sí mismas* dentro de la comunidad de red nerviosa se refiere a la habilidad que algunas redes tienen a aprender sin estar provistas con la respuesta correcta para una ruta de entrada. Generalmente, todas estas redes están modeladas estrechamente de los sistemas neurobiológicos. Los investigadores quienes desarrollaron tales sistemas están casi siempre probando entender cómo los cerebros actualmente trabajan y, dentro del proceso, crear algunas redes nerviosas altamente útiles y fascinantes.

Una red organizadora de sí misma Kohonen es sorprendentemente simple a primera vista. Desafortunadamente la red Kohonen, generalmente no es un sistema jerárquico y consiste de dos capas de neuronas (fig. 4.3.1). La capa de entrada tiene una función similar a la capa de entrada de la red de retropropagación; simplemente distribuye (y tal vez escala) la ruta de datos entrantes hacia las neuronas procesadoras primarias dentro de la capa Kohonen.




Fig. 4.2.1 Una capa Kohonen típica mostrando interconexiones intracapa.

Cada neurona de la capa Kohonen recibe típicamente la ruta de entrada completa de la capa de entrada. Estas neuronas, sin embargo, están altamente interconectadas con la capa Kohonen. Otras redes discutidas aquí carecen de conexiones entre las neuronas de una capa dada; en su lugar, las conexiones solo existen para las neuronas dentro de otras capas o hacia (o desde) el mundo exterior para las neuronas de la capa de salida (o capa de entrada).

La capa Kohonen de neuronas, por otro lado, no solo recibe la ruta de entrada entera dentro de la red, sino también numerosas entradas de las otras neuronas dentro de la capa.

Cuando construya una capa Kohonen, debe de hacer dos

cosas que no se requerirán generalmente por las otras redes. Primero, debe estar seguro que los vectores de peso de las neuronas dentro de la capa sean inicializados apropiadamente, lo cual significa que los vectores de peso apunten en direcciones aleatorias alrededor de un círculo unitario. Segundo, debe usar vectores de peso y vectores de entrada que han sido normalizados a una constante, la longitud arreglada, usualmente uno. Estos dos pasos son vitales para el éxito de la red Kohonen.

Permítanos seguir la presentación de una ruta de entrada hacia la capa Kohonen y ver lo que hace. Así puede describir fácilmente los resultados sobre un pedazo de papel, el ejemplo usará únicamente dos entradas bidimensionales, pero nada dentro de esta red de cualquier manera limita la operación de la red para entradas bidimensionales en general.

Comience con los vectores de peso normalizados a la longitud unitaria. Por conveniencia, comience con los vectores de peso aleatoriamente apuntando alrededor del círculo unitario. La figura 4.3.2 muestra a lo que esto podría parecerse. Luego, presente una ruta de entrada hacia la red. Cada neurona dentro de la capa Kohonen recibe la ruta de entrada y calcula el producto punto de su vector de peso con aquel vector de entrada.




Fig. 4.3.2 Distribución inicial con vectores de peso aleatoriamente colocados en el primer cuadrante. Datos de un simulador Kohonen.

4.3.1 COMPETENCIA DENTRO DEL APRENDIZAJE.

Dentro del aprendizaje Kohonen, algo muy interesante ocurre. Cada neurona ha calculado cómo cerrar su vector de peso que está hacia el vector de entrada. Las neuronas entonces compiten por el privilegio de aprender. En esencia, la neurona con el producto punto más grande es declarada la *ganadora* dentro de la competencia. Después de la competencia, esta neurona es la única neurona que deja de generar una señal de salida; todas las demás generan cero. Además, esta neurona, y sus vecinas inmediatas, son las

únicas neuronas permitidas a adoptar esta presentación de ruta.

Esta aproximación es completamente nueva para aprender; en la mayoría de las demás redes, toda neurona dentro de la red ajustaban sus pesos en cada iteración de entrenamiento. Dentro de las redes Kohonen, la filosofía es la primera ganadora toma todo. Únicamente la ganadora está permitida a salir, y sólo la ganadora y sus vecinas están permitidas a ajustar sus pesos.

Los sistemas Kohonen que son diseñados como modelos biológicos usan las interconexiones intracapa para moderar esta competencia. Cada neurona dentro de la capa saca su activación, y esta actúa como una entrada inhibitoria para cada una de sus compañeras. Estas entradas inhibitorias tienden a reducir la activación de las otras neuronas, y así reducen sus correspondientes entradas inhibitorias para sí mismas. En la mayoría de estas conexiones, el efecto es completamente inhibitorio, pero dentro de las vecinas próximas de la neurona, o aquellas físicamente más cercanas a la neurona, es excitatoria (positiva).

El resultado es que cada neurona prueba dispararse a sí misma, y si no es posible, prueba ayudar a sus vecinas a disparar excitándolas. Así, si cualquiera de las vecinas de la neurona gana, todavía será permitido cambiar sus pesos, aunque no pueda generar (después de que la competencia termina) una señal de salida. Como las salidas de la competencia circulan dentro de la capa, las neuronas

eventualmente se normalizan de manera que algun pedazo pequeño de la red, la cual tiene la excitación global más grande, genera una salida, y el resto de la capa está inactiva.

El esquema complejo para moderar la competencia dentro de la capa es llamado inhibición lateral o, algunas veces, en centro/fuera del medio ambiente. El impacto relativo de cualquier inhibición intracapa de la neurona también está permitido para decrecer más lejos del que tomamos de la neurona. Así, el efecto global de la inhibición lateral ve a bit como la función de la figura 4.3.1.1.




Fig. 4.3.1.1 La función muestra la inhibición lateral como una función de distancia de la neurona ganadora.

También necesitamos ver un bit más atentamente a cuáles neuronas comprenden las *vecinas* de la ganadora. En general, estas neuronas son aquellas que están más cercanas físicamente a la neurona ganadora; dentro de una rejilla como

arreglo de neuronas, esta vecindad podían ser aquellas que están en una fila o en una columna lejos de la ganadora. No obstante, el tamaño exacto de esta vecindad, o el ancho de la función, no está limitada necesariamente a las vecinas inmediatas de la ganadora. Puede, si escoge, permitir a la vecindad expandirse para incluir a todas las neuronas que están, por decir, en distintas columnas o en filas lejanas. Nada más con muchos otros parámetros dentro de las redes nerviosas, el tamaño exacto de la vecindad también puede variar durante el entrenamiento; típicamente comienza bastante grande y es reducida lentamente para incluir solo a la ganadora y posiblemente a sus vecinas inmediatas.

Observe también que mientras el vector de peso de la neurona ganadora está garantizado a estar cerrado para el vector de entrada (de otra manera no habría ganado la competencia), los vectores de peso de las vecinas de la ganadora pueden apuntar cualquier lugar de la hiperesfera. Así, el peso cambia para los vectores de peso de las vecinas están probablemente para ser mayores que aquellas de la misma ganadora.

4.3.2 LA REGLA DE APRENDIZAJE KOHONEN.

Ya que hemos elegido nuestra neurona ganadora. Ahora tenemos que ajustar los pesos de la neurona usando la regla de aprendizaje Kohonen. Esta regla es incluso más simple que la regla Delta; dice:

$$W^{\text{nuevo}} = W^{\text{viejo}} + \beta (X - W^{\text{viejo}}) \quad (4.3.2.1)$$

donde W es el vector de peso, X es el vector de ruta de entrada (excluyendo cualquier entrada intracapa), y β es la constante de aprendizaje. Recuerde que la ganadora es el vector de peso que genere el producto punto más grande con el vector de entrada; geoméricamente, esto nos dice que el vector de peso ganador es el más cercano al (eso es, con la distancia del ángulo más pequeño del) vector de entrada. El aprendizaje Kohonen simplemente toma la diferencia del vector entre los dos y suma alguna parte de esta diferencia al vector de peso original.

No solo la ganadora consigue ajustar sus pesos; aquellas neuronas que están dentro de la vecindad de la ganadora llevan a cabo un ajuste similar. Estas neuronas ajustan sus pesos usando la misma regla de aprendizaje pero lo aplican para sus propios vectores de peso. El efecto global de esta presentación es que la neurona ganadora saca una señal +1, y que ella y sus vecinas dan un codazo a sus vectores de peso ligeramente más próximos al vector de entrada.

Permitámonos tomar una consideración más de la vecindad de la neurona ganadora durante el entrenamiento. En general, dentro de una red Kohonen la *vecindad* de la neurona ganadora es un círculo decreciendo lentamente. Al principio del entrenamiento, la *vecindad* de la ganadora puede ser bastante grande, de manera que las porciones substanciales de la red pueden aprender en cada ruta. Como el entrenamiento procede,

el tamaño de la vecindad es decrementado lentamente, de manera que menos y menos neuronas aprenden en cada iteración. Finalmente, solo la misma ganadora ajustará sus pesos.

Ahora estamos listos para el próximo vector de entrada. Otra vez, es presentado para toda neurona dentro de la capa Kohonen, y nuevamente las neuronas compiten. Una nueva neurona ganadora es elegida, genera una señal de salida, y ella y sus vecinas dan un codazo a sus vectores de peso levemente más cercanos hacia el vector de entrada. Esta ruta es repetida muchas veces hasta que el entrenamiento es completo.

4.3.3 CREACION DE MODELOS ESTADISTICOS.

Puede parecer como si la red no ha realizado mucho con tal entrenamiento, pero en realidad, algo completamente asombroso ha ocurrido. Para entender lo que ha pasado, necesitamos realizar un experimento.

Supongase que un generador de vector es usado para generar la serie de datos de entrada para la red (fig. 4.3.3.1). Cada vector generado consiste de un vector de longitud unitario a la misma posición dentro del círculo unitario. Para el propósito de este experimento, el generador puede crear 500 vectores, aproximadamente la mitad de los cuales están dentro del primer cuadrante (entre los ángulos 0° y 90° del eje X), y aproximadamente un cuarto de los cuales están en ambos, el segundo y el cuarto cuadrante,

entre los ángulos 00° y 180° o entre 270° y 360° con el eje X. Los vectores de ruta de entrada no están permitidos dentro del tercer cuadrante. Los vectores de entrada no tienen organización particular; cada nuevo vector generado tiene un 50% de probabilidad de estar dentro del cuadrante 1, un 25% de posibilidad de estar dentro del cuadrante 2, y un 25% de probabilidad de estar dentro del cuadrante 4.




Fig. 4.3.3.1 Brazo de un robot manteniendo un marcador con el que puede hacer puntos dentro del círculo. Los ángulos son las entradas a la red Kohonen.

Al principio después de la normalización, los vectores de peso de la red tienen una inicialización arbitrariamente aleatoria de manera que todos están aleatoriamente dentro del primer cuadrante del círculo unitario. Los resultados experimentales mostrados en la fig. 4.3.3.2 indican que después de 500 vectores de entrada son generados, aproximadamente el 5% de ellos apuntan hacia el primer cuadrante, cerca del 22% hacia el segundo cuadrante, alrededor del 28% hacia el cuarto cuadrante, y ninguno hacia

el tercer cuadrante.




Fig. 4.3.3.2 El círculo unitario mostrando la distribución de las rutas de entrada alrededor del círculo unitario.

La figura 4.3.3.3 muestra que los vectores de peso después de que todos los 500 vectores de entrada han sido presentados. Observe que los vectores de peso se han realineado a sí mismos de manera que están aproximadamente distribuidos en la misma ruta como los vectores de entrada. Los vectores de peso aprenden a modelar la distribución de las rutas de entrada. Dese cuenta, también, que esta tarea fue realizada sin decirle a la red a cuál ruta de distribución debe parecerse.

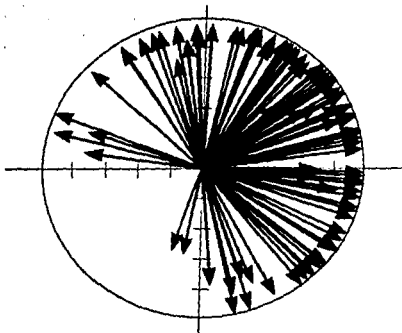


Fig. 4.3.3.3 Circuito unitario con pesos trazados después de 500 rutas de entrada.

Una red Kohonen modela la función de distribución de probabilidad¹⁹ de los vectores de entrada usados durante el entrenamiento, con muchos vectores de peso agrupados en esas

¹⁹ Dada una variable aleatoria x , es la función $f(x)$ igual a la probabilidad de que ocurra cada valor de x . Si todos los valores de x entre a y b son igualmente probables, x tiene "distribución uniforme" en el intervalo y el gráfico de la función de distribución $f(x)$ respecto de x es una recta horizontal. Por lo general, las variables aleatorias continuas tienen función de distribución variable con un valor máximo x_m y en el cual la probabilidad de x disminuye al alejarse x de x_m . La función de distribución acumulada

$F(x)$ es la probabilidad de un valor menor o igual que x . Para las funciones continuas, $F(x)$ puede ser una curva en forma de S. En ambos casos $F(x)$ es el área bajo la curva de $f(x)$ y a la izquierda de x .

porciones de la hiperesfera con relativamente muchas entradas y pocos vectores de peso en aquellas porciones de la hiperesfera con relativamente pocas entradas. Las redes de Kohonen llevan a cabo estos modelos estadísticos, incluso en casos donde no forma expresión analítica cerrada puede describir la distribución. Realiza este modelo espontáneamente, y no fuera del tutor.

En la cima de esta habilidad para modelar la distribución de las entradas, las redes Kohonen tienen otra cualidad muy especial. Pueden crear mapas topológicamente conservadas.

4.3.4 EL MAPA TOPOLOGICAMENTE CONSERVADA.

Los resultados de la simulación pueden ayudar a explicar cuál es la intención de un mapa topológicamente conservada. Suponga que las neuronas dentro de la red están arregladas como un montaje ingenioso de filas y columnas, con cada neurona asignada a una locación específica dentro de esta matriz. La simulación usa 10 filas y 10 columnas. Inicialmente, los vectores de peso están aleatoriamente orientados, y podemos dibujar un punto espacial de sus posiciones. Esta gráfica tiene un punto correspondiendo a cada vector de peso de la neurona y una línea enlazando los puntos de las neuronas que son vecinos físicamente dentro de la matriz únicamente fuera de una fila o de una columna.

Inicialmente, esta gráfica es una mezcla de líneas,

cuando los vectores de peso son dispuestos al azar, y no existe correlacion entre la posicion de la fila y columna de la neurona y su vector de peso. La fig. 4.3.4.1a exhibe a lo que una vista tipica inicial pudiera parecerse. Para este ejemplo, todas las neuronas tienen vectores de peso en algún lugar dentro del primer cuadrante del circulo.




Fig. 4.3.4.1 Resultados de un simulador Kohonen del mapa topologicamente conservado.

Recuerde que las rutas entrenadas usadas anteriormente

no estaban distribuidas uniformemente alrededor del círculo unitario. Específicamente, alrededor de la mitad de las rutas de entrada están dentro del primer cuadrante (ambos componentes positivos), y aproximadamente un cuarto están dentro de cada uno de los cuadrantes 2 y 4 (un componente positivo, el otro negativo). Las rutas de entrada no están dentro del tercer cuadrante (ambos componentes negativos).

Durante el entrenamiento después de cada 50 rutas de entrada, toma una foto instantánea de los vectores de peso. Esta información es luego usada para construir otra copia de la gráfica de la distribución del vector de peso al punto dentro del proceso de entrenamiento. Las figuras 4.3.4.1b, c, y d muestran estas gráficas para diversas de estas fotos instantáneas.

Los vectores de peso se organizan para sí mismos de manera que la gráfica de los mapas de la función de distribución de los datos de la ruta de entrada, no importa cómo las rutas de entrenamiento están distribuidas alrededor del círculo unitario, después de entrenar la red Kohonen traza aquella distribución. Duplica la topología, o forma, de la distribución de rutas. Estas gráficas se parecen un poco a un mapa topológico de una región montañosa. Donde muchos vectores de entrada son agrupados, la rejilla similarmente es agrupada y amontonada; donde solo unos pocos vectores de entrada son agrupados, la rejilla es mucho más escasa.

Otros detalles fascinantes acerca de esta capacidad de

abundar. Suponga que las entradas representan notas musicales (frecuencias) en lugar de coordenadas. En este caso, los mapas topológicos muestran que los vectores de peso de la red Kohonen se arreglan a sí mismos de manera que son sensibles a (ganar la competencia) frecuencias en cualquiera de las dos clases: ascendente o descendente. Aunque las neuronas comienzan con sensibilidades aleatorias para la frecuencia, después de entrenar ellas están altamente organizadas realmente. En otras palabras, la *topología* que es conservada con una red Kohonen no necesita corresponder a un arreglo físico; puede corresponder a cualquier característica estadística del conjunto de entrada.

Los mapas topológicamente conservados no son únicamente características de redes nerviosas, son características del cerebro también. Por ejemplo, mapas tonotópico dentro de la porción auditiva de la corteza cerebral dentro de la cual las neuronas son sensibles a diferentes frecuencias de sonido, dentro de cualquiera de las dos clases: creciente o decreciente. Los mapas geotópico han sido encontrados dentro de los cerebros de los ratones que han aprendido un laberinto; neuronas específicas dentro del mapa disparan cada vez que el ratón está en una locación específica dentro del laberinto. Muchos otros ejemplos probablemente existen, también. Las redes Kohonen ofrecen una explicación simple, efectiva de cómo tales mapas biológicos pueden ser generados.

4.3.5. RESULTADOS PRACTICOS.

Dentro de esta discusión del aprendizaje Kohonen, algunos problemas prácticos han sido disvirtuados. El primero de estos problemas es el problema de la normalización de los vectores de pesos y de entrada. Muchas personas, cuando piensan normalizar un vector, consideran el método de dividir cada componente probado y verdadero por la longitud del vector. Este método es usado dentro del programa de simulación. Debe ser evidente de la operación de la red Kohonen, no obstante, que esta red es fundamentalmente estadística dentro de su respuesta.

Si quiere la red para modelar las características estadísticas correctas, necesita estar seguro que los procedimientos de normalización usados son apropiados para aquellas características. La normalización Euclidiana simple no puede extraer la estadística que quiere; correctamente entrenada una red Kohonen y todavía tener que modelar enteramente las características erróneas de sus datos es todo demasiado fácil.

Otro resultado directamente relacionado a esto. Una red Kohonen debe ser entrenada con datos que sean estadísticamente significativos para que la entrada total sea la experiencia en la operación. Este problema es serio en muchos casos, particularmente si la estadística de los datos del problema no son bien comprendidos. Esta situación también implica que la serie de entrenamiento necesita ser relativamente grande; muchas muestras pueden ser requeridas

para que el entrenamiento proceda apropiadamente.

Los vectores de peso son casi siempre normalizados, pero algunos no están en la superficie del círculo. Mientras el entrenamiento de la red es hecho en pasos pequeños (manteniendo β muy pequeño) el ajustamiento de peso resulta de la regla de aprendizaje Kohonen es aproximadamente una rotación del vector de peso a lo largo de la superficie del círculo, en lugar de una suma o sustracción de la longitud (fig. 4.3.3.3).

Así, mientras los vectores de entrada son normalizados a una longitud unitaria, los vectores de peso se ajustan a ellos mismos para estar más cercanos a los vectores de entrada. Cualquier vector de peso que se meta por debajo de la superficie del círculo tenderá a echarse para atrás hacia la orilla, tarde o temprano. No obstante, la condición que asegura que los cambios de peso sean rotaciones es un valor pequeño para la constante de aprendizaje. Dentro de la simulación, el valor era puesto a 0.2; esto es realmente el límite superior para la mayoría de las aplicaciones.

Así, dos factores contribuyen a una red Kohonen conseguir un tiempo largo para entrenar: la necesidad para que las series de entrenamientos sean largas, estadísticamente significativas y la necesidad para mantener la constante de aprendizaje muy pequeño.

Otro problema que ocurre dentro de la aplicación de las redes Kohonen es la propia inicialización de los vectores de peso. Las redes Kohonen trabajan mejor cuando los vectores

de entrada están dentro de una región conectada, próxima. Si los vectores de entrada, por ejemplo, son de los cuadrantes 1 y 3, la distribución incluye dos áreas desconectadas. Dentro de esta situación, cualquier vector de peso que fue inicializado dentro de los cuadrantes 2 o 4 probablemente nunca podrán ser ninguno ganador y también nunca podrán ser el vecino de un ganador. Tales vectores son esencialmente ineficientes para el modelo estadístico y son frecuentemente llamados vectores muertos.

Algunos trucos de entrenamiento pueden evitar este problema. Uno es inicializar los vectores de peso colocando cada uno igual a una ruta de vector de entrada. Por ejemplo, el simulador podría tener inicializado los vectores de peso colocándolos igual a las primeras 100 entradas. Esta técnica se tropieza con una trampa, y es en cierta manera, pero si el número de neuronas dentro de la red es mucho más pequeña que el número de entradas entrenadas, la tendencia que se incorporó con esta técnica es insignificante.

Finalmente, las redes Kohonen trabajan mejor con redes muy grandes. La red más pequeña, será el modelo estadístico menos exacto. La red Kohonen es a menudo más útil para su habilidad de generar un modelo estadístico bueno que para su habilidad de calcular una respuesta exacta a una pregunta particular. Algunos de estos efectos pueden ser superados mediante la modificación de la filosofía de la ganadora toma todo para permitir más de una neurona ganadora. Esta modificación permite a la salida de la red ser una

interpolación entre, por decir, las dos o tres mejores respuestas, en lugar de la única mejor respuesta.

4.3.6. VENTAJAS DE LA APLICACION.

El aprendizaje Kohonen tiene ventajas lo mismo que inconvenientes. Primero, las redes Kohonen potencialmente son más rápidas, incluso mientras se entrenan. Con retropropagación diferente, la activación de la red es un paso unico, con flujo de desplazamiento hacia adelante, en lugar de retroalimentación multipaso. Así, los sistemas Kohonen tienen el potencial para el aprendizaje de aplicación en tiempo real.

Además, estas redes pueden aprender continuamente. Así, si la distribución estadística de los datos de entrada cambian sobre el tiempo, la red Kohonen puede adaptarse continuamente para aquellos cambios y mantener un modelo común de la distribución de los datos de la ruta de entrada. Finalmente, las capacidades de modelos estadísticos de la red Kohonen no están emparejados con cualquier otra red nerviosa y sistemas tradicionales para muchos problemas. La característica que la red Kohonen se organizó a si misma dentro del modelo estadístico correcto los hace sin igual para algunas aplicaciones.

Sin duda, son complicados para aplicarlos a un problema real, pero ofrecen una visión momentánea integrante en cómo nuestros cerebros deben realmente trabajar.

4.4: APRENDIZAJE OUTSTAR.

Los sistemas biológicos —en otras palabras animales— parecen aprender constantemente. Sus comportamientos se modifican a través de la experiencia para permitirles adaptarse al mundo. Con las redes nerviosas, los investigadores finalmente están comenzando a prestar atención a los ejemplos del mundo biológico y a desarrollar sistemas de computadora que deliberadamente traten de imitar el aprendizaje específico de los comportamientos de animales. La red Kohonen pueden organizarse a si mismas, aquello es, aprenden sin un tutor, de manera que imita las estructuras que encontramos dentro de ciertas áreas de algunos cerebros de mamíferos. Algunas de estas estructuras son llamadas mapas tonotopic porque están organizadas de manera que las neuronas que responden a frecuencias de sonido específicas son físicamente ordenados dentro de ambas sensibilidades de frecuencia: ascendente o descendente.

Este artículo atraviesa una explicación de incluso un modelo más poderoso de aprendizaje biológico, llamado aprendizaje outstar (o, más completamente, aprendizaje instar/outstar).

4.4.1 GROSSBERG Y PAVLOV.

Como ejemplo considere el muy famoso experimento psicológico —los perros de Pavlov—. Pavlov observó que cada vez que él mostraba un plato con comida a un perro

hambriento, el perro babeaba. Esta reacción es una respuesta completamente no entrenada por ver la comida; los psicólogos llaman al plato con comida el estímulo no condicionado, y a la respuesta de babear la respuesta no condicionada. Ambos son *no condicionados* porque el comportamiento no es un comportamiento entrenado, sino es uno automático, uno innato al perro.

Luego, Pavlov comenzó a entrenar a los perros mediante el sonido de una campana cada vez que les mostraba el plato con comida. Él hizo esta prueba muchas veces, siempre tocando la campana al mismo tiempo cuando la comida era mostrada; claro, los perros babeaban cada vez. Eventualmente, encontró que él podía simplemente tocar la campana, sin mostrar a los perros la comida, y los perros todavía babeaban. La campana es ahora denominada el estímulo condicionante y la respuesta de babear es la respuesta condicionante. Ellos son *condicionantes* porque el comportamiento ha sido entrenado (figura 4.4.4.1).

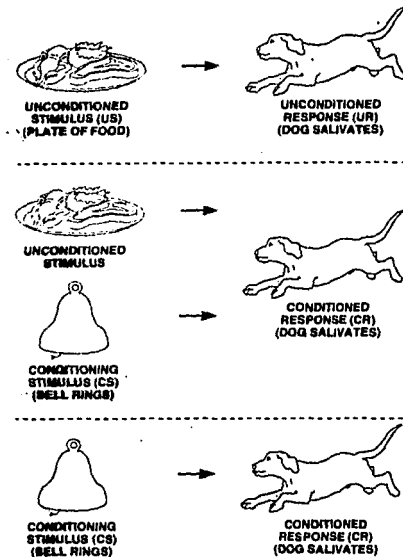


Fig. 4.4.1.1 Un diagrama del experimento de Pavlov.

En las décadas de los 60's y 70's, Stephen Grossberg pensó acerca de este experimento clásico y trató de entender que estructuras dentro del cerebro podrían explicar tal comportamiento del aprendizaje. También recurrió al trabajo del prominente psicólogo Donald Hebb.

4.4.2 LEY DE HEBB.

En 1949, Donald Hebb introdujo una de las más influyentes ideas de aprendizaje aun desarrollada. Aunque no es una exposición matemática, la *ley de Hebb* trata de describir lo que ocurre en un nivel celular durante el aprendizaje. Hebb explicó el aprendizaje de la siguiente manera:

Una neurona dentro del cerebro recibe muchas entradas de un número grande de otras neuronas. Estas entradas son recibidas por la neurona a través de sus conexiones sinápticas de otras células (fig. 4.4.2.1). En cualquier tiempo dado, la neurona también tiene algún nivel de excitación o activación que determina si, y cuán fuertemente, producirá una señal de salida de sí misma. La regla de Hebb afirma: *Si una neurona, A, es repetidamente estimulada por otra neurona, B, a veces cuando la neurona A está activa (para cualquier razón), entonces la neurona A se volverá más sensible al estímulo de la neurona B; la conexión sináptica de B hacia A será más eficiente. Así, B encontrará más fácil estimular A para producir una salida en el futuro.*

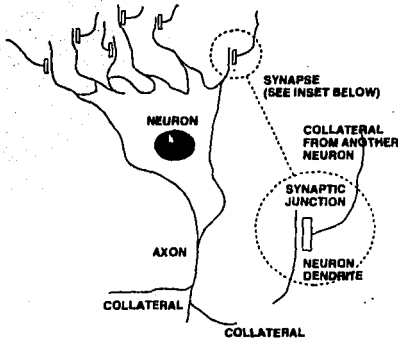


Fig. 4.4.2.1 Una neurona recibe entradas a través de sus conexiones sinápticas.

La regla de Hebb no es completamente una formulación matemática de una ley de aprendizaje. De hecho, tiene un par de dificultades prioritarias. Primero, la ley no provee medios de reducir la eficiencia sináptica de la conexión entre las neuronas α y β ; así, los pesos en las interconexiones potencialmente podrían ir hacia el infinito.

Segundo, la ley no tiene medios de tratar con conexiones inhibitorias o negativas entre neuronas; esta condición es contraria para lo que sabemos de los sistemas biológicos que tienen tales conexiones inhibitorias.

Finalmente, la regla de Hebb carece de la precisión de una formulación matemática y así prueba de algunos teoremas

fundamentales de estabilidad. Pese a estos inconvenientes, el aprendizaje Hebbiano ha sido vital para un número de redes nerviosas, incluyendo al aprendizaje outstar. Pero antes de que usted pueda mirar a la teoría misma, necesitamos considerar el punto de vista de Grossberg de la red nerviosa; necesita entender los conceptos instars y outstars.

4.4.3 INSTARS Y OUTSTARS.

Grossberg formuló una perspectiva fresca para el estudio de las redes nerviosas. En particular, él desarrolló dos maneras de mirar a las neuronas dentro de una red que ha sido probada. Estos son los conceptos de instars y outstars.

Dentro de cualquier red nerviosa, toda neurona dentro de la red recibe muchas señales de entrada (fig. 4.4.3.1). Desde el punto de vista de la neurona, está en el centro de un número grande de señales de entrada y conexiones dirigidas hacia adentro. Puede incluso dibujar esta forma como una estrella, con todas las flechas, correspondiendo a las señales de entrada, apuntando hacia el centro de la estrella, donde la neurona misma está situada. Este objeto es llamado el instar.




Fig. 4.4.3.1 En cualquier red nerviosa, toda neurona dentro de la red recibe muchas señales de entrada.

Al mismo tiempo, toda neurona genera una señal de salida única, una distribuida para un número grande de otras neuronas a través del axón de la neurona (fig. 4.4.3.2). De nuevo, desde el punto de vista de la neurona, esta en el centro de una estrella grande, apuntando hacia afuera. A este objeto es denominado el outstar.




Fig. 4.4.3.2 Cada neurona genera una señal de salida única, una vez distribuida hacia un número grande de otras neuronas a través del axón de la neurona.

Cada red nerviosa está así compuesta de una malla compleja y entrelazada de instars y outstars. Cada neurona dentro de la red está simultáneamente en el centro de un instar, y en el centro de un outstar. La operación de la red así depende de las interacciones que ocurren entre los instars y outstars.

Con este concepto en mente, considere el aprendizaje Pavloviano. Imagine una red simple que tiene una única neurona que actúa como un outstar, junto con una rejilla de neuronas que individualmente reciben del outstar de la señal de salida de la neurona. En suma, cada una de esas neuronas de la rejilla (los instars de la red) también pueden recibir una señal externa fuerte y separada, una que, cuando encienda, force a la neurona a responder de un modo particular (tal y como el plato con comida fuerza al perro a

babear). La figura 4.4.3.3 ilustra esta red.




Fig. 4.4.3.3 Un ejemplo de red que muestra la rejilla de neuronas únicamente recibiendo entradas de la única neurona del outstar.

Si un modelo puede ser desarrollado que describa cómo la actividad de cada neurona de la rejilla cambia con el tiempo, también cómo las conexiones de los pesos entre las neuronas de la rejilla y la única neurona del outstar cambia con el tiempo, entonces todo lo que necesita saber del comportamiento de la red a cualquier tiempo en el futuro son las condiciones iniciales (los pesos iniciales más la actividad inicial). El aprendizaje outstar trata de suministrar ecuaciones que modelen estas dos características de la red: el cambio dentro de la actividad y dentro de los pesos cuando el tiempo pasa.

4.4.4. ECUACION DE LA ACTIVIDAD DEL INSTAR.

Primero, las neuronas necesitan responder a estímulos externos. Cuando tales estímulos están presentes, la neurona debe volverse más activa; cuando los estímulos son eliminados, la actividad de la neurona debe volverse menos activa. El modelo instar debe responder rápidamente a los estímulos y perder la actividad rápidamente cuando los estímulos sean removidos.

Esta situación asume que la actividad del instar es una función del tiempo; una de las cosas que hacen estas ecuaciones relativamente confusas es que el aprendizaje outstar explícitamente responde a la dependencia de los parámetros del tiempo de la red. También, la discusión presenta únicamente una de las versiones más simples del aprendizaje outstar; las ecuaciones pueden ser mucho más complejas que las mostradas aquí.

Recuerde que los perros Pavlovianos recibieron unos estímulos condicionantes durante el entrenamiento (la campana). Estos estímulos vienen del exterior del mismo perro; no fue un resultado de hambre natural o la respuesta de ver u oler comida. La expresión matemática más simple que pueda ser usada para permitir que la actividad crezca cuando los estímulos externos estén presentes es

$$\frac{dy(t)}{dt} = I \quad (4.4.4.1)$$

Observe que la actividad de la neurona, $y(t)$, es

explícitamente una función del tiempo como un recuerdo que el nivel de activación de la neurona cambiará a través del tiempo. \mathcal{I} es el estímulo de entrada que viene del exterior de la red; cualquier estímulo de otras neuronas dentro de la red no está incluido. Es la equivalencia matemática del plato con comida mostrado al perro.

El modelo también debe permitir a la actividad de la neurona decaer hacia atrás hacia un estado inactivo si los estímulos son eliminados. La expresión más simple que suministra esta característica es

$$\frac{dy(t)}{dt} = -Ay(t) \quad (4.4.4.2)$$

Esta expresión es la ley de decaimiento exponencial trazado en la fig. 4.4.4.1. En efecto, afirma que si de ninguna manera otro está pasando para detenerlo, el nivel de activación de la neurona decrecerá alguna cantidad proporcional al mismo nivel de activación. Dentro de la ecuación, \mathcal{A} es una constante positiva, denominada la constante del tiempo de activación, porque su tamaño determina cuán rápido ocurre el decaimiento; un valor grande de \mathcal{A} conduce hacia un decaimiento muy rápido, mientras un valor pequeño de \mathcal{A} conduce hacia un decaimiento lento y largo de la activación.




Fig. 4.4.4.1 La ley del decaimiento exponencial trazado.

Otra fuente de estímulos para la neurona es el estímulo generado por todas las demás neuronas que tienen enlaces sinápticos hacia la primera. Esto es equivalente para el estímulo condicionado dentro del experimento de Pavlov; en otras palabras, corresponde al toque de campana. Una adivinanza inicial buena es que esta fuente de activación puede ser escrita como

$$\frac{dy(t)}{dt} = \sum_{i=1}^n w_i y_i(t) \quad (4.4.4.3)$$

Esta ecuación es simplemente la suma de los pesos de las señales de entrada de otras neuronas, la neurona ava específicamente, a la cual hemos visto muchas veces antes. Los términos y_i se refieren a las fuerzas de las señales de entrada (niveles de activación) de las demás neuronas. Dentro del ejemplo la red mostrada en la fig. 4.4.3.3, las neuronas de la rejilla únicamente reciben tales entradas de la única neurona oustar. En este caso, entonces, la suma es

unicamente tomada sobre una neurona individual y $n = 1$.

Puede haber observado que un término y existe en ambos lados de la ecuación. El primero en el lado izquierdo es el nivel de activación de la neurona instar particular cuyo nivel de activación está siendo calculado. El otro en el lado derecho son los niveles de activación corrientes de todas las neuronas dentro de la red que envían señales hacia esta neurona receptora.

Para hacer esto más claro, considere a la neurona 10 dentro de una red de 15 neuronas. El término $y^{(i)}$ en el lado izquierdo es el cambio dentro de la activación de la neurona 10, el cual está siendo calculado, o el cambio dentro de la activación de la neurona 10 dentro del siguiente instante de tiempo. El término de la sumatoria en el lado derecho es la suma de los pesos de las activaciones desde la neurona 1 hasta el 15. Observe que la suma de los pesos incluso puede incluir la salida de la neurona 10 si aquella neurona se retroalimenta a si misma; si esta situación no es el caso, el término w_{10} es 0.0 para indicar que tales conexiones no existen.

No obstante, un par de problemas existen con este término dentro de la ecuación. El primero es que el sistema debe modelar los sistemas biológicos actuales, lo cual significa que debe tomar en cuenta unas pocas realidades de la vida. Una de estas realidades es que las señales no se transmiten infinitamente rápidas. De hecho la señal recibida al instar no es el nivel de activación corriente de la

neurona transmisora, pero en vez, el nivel de activación transmitido a algunos tiempos anteriores t_0 , donde t_0 es el tiempo necesario para que la señal viaje desde la neurona transmisora a lo largo de la red interconectada hasta la sinapsis del instar. Así el término se parece más propiamente a

$$\frac{dy(t)}{dt} = \sum_{i=1}^n w_i y_i(t - t_0) \quad (4.4.4)$$

Incluso esta ecuación no es completamente precisa, no obstante, porque el instar debe tener una tolerancia razonable para el ruido. Como los sistemas biológicos, el cerebro es bombardeado constantemente con una cacofonia de estímulos del mundo exterior, también ruido de adentro de los sistemas electroquímicos que lo componen. Si respondió a toda entrada detectada, sería reducido a una protuberancia espástica, estremecida y sería incapaz de funcionar de todo. El instar debe tener un aislamiento similar de entradas insignificantes. Así, el instar debe tener un umbral que permita solo aquellas entradas que excedan el umbral para contribuir al término de la suma de los pesos. Este umbral es expresado por la siguiente modificación:

$$\frac{dy(t)}{dt} = \sum_{i=1}^n w_i [y_i(t - t_0) - T]^+ \quad (4.4.5)$$

Aquí el umbral es T , y el índice "+" simplemente actúa como un recordatorio de que únicamente los términos positivos contribuyen a la sumatoria; cualquier señal de entrada menor que el umbral contribuye cero.

Considere este umbral a un bit más. Claramente, el

valor del umbral es extremadamente importante para la operación de la red. Si es demasiado alto, la red ignorará estímulos vitales y será *ausiosa*; será renuente para responder a eventos a su alrededor. Si el valor del umbral es demasiado bajo, la red será *hiperactiva*, respondiendo ampliamente a los estímulos de ruido mas leves. El valor correcto para el umbral depende del valor de ruido supuesto para el sistema específico implicado, y debe de ser colocado como corresponde.

Poniendo todos estos términos juntos hacen la ecuación de actividad para el instar. Cuando cada uno de estas tres influencias (entradas externas, decaimiento de la activación, y entradas interneurona) pueden ser presentadas independientemente de la otra, pueden ser sumadas juntas. Con una ligera modificación para hacer hincapié en la característica que la ecuación pertenezca a una red entera de instars, la ecuación para el cambio en la actividad de ava neurona dentro de la red se vuelve

$$\frac{dy_j(t)}{dt} = A_{ij}(t) + I_j(t) + \sum_{i=1}^n w_i [y_i(t - t_0) - T]^+ \quad (4.4.4.5)$$

Observe que el estímulo externo ϕ también es una función del tiempo, y que es específico para cada neurona instar; otros instars pueden tener una entrada externa completamente diferente, o ninguna para todos. En general, claro, solo aquellas neuronas dentro de la capa de la red tendrán valores diferentes de cero para ϕ .

Mientras que la forma más general de la ecuación, no es

suficiente para un entendimiento de su significado.

4.4.6 LA LEY DE APRENDIZAJE.

Como se ha visto, una red nerviosa aprende mediante la modificación de los pesos en sus sinapsis. Así, la ley de aprendizaje le dice a la red cómo calcular los cambios de pesos apropiados. El aprendizaje outstar combina el aprendizaje Hebbiano como una afirmación matemática de olvido para hacer un paradigma poderoso de aprendizaje.

El olvido es fundamental para los sistemas biológicos. Un modelo exacto del aprendizaje biológico debe de tener en cuenta esta característica. El aprendizaje outstar usa el mismo periodo corto del decaimiento exponencial para olvidar cuando aparece en la ecuación de actividad anterior; así el término de olvido se parece a

$$\frac{dy(t)}{dt} = -F_{\omega} y(t) \quad (4.4.5.1)$$

Esta ecuación se refiere al cambio dentro del peso de la ava sinapsis de entrada de la neurona outstar (rejilla). Tal y como con la actividad de la neurona, los pesos son funciones explícitas del tiempo, cuando cambian durante el aprendizaje. La constante F_{ω} es la constante de olvido. Determina la rapidez con la cual las memorias de la red decaen. Observe que esta constante no es la misma como la constante de decaimiento de actividad λ . Dentro de los sistemas biológicos, una actividad de la neurona puede decaer

en el orden de milisegundos, pero la memoria decae sobre un periodo de tiempo más grande.

El segundo término dentro de la ecuación de aprendizaje implementa una forma matemática del aprendizaje Hebbiano. Una sinapsis particular de un instar aprende si es estimulado por otra neurona a un tiempo cuando el instar está activo. El modo más fácil para implementar esta ley matemática es multiplicar la señal de entrada por la propia salida del instar. Si ambas señales, la de entrada y la de salida, son simultáneamente grandes, el cambio del peso será grande; si cualquiera de los dos es pequeño, el cambio de peso será pequeño. Esta ecuación inicialmente se parece a esto:

$$\frac{dy(t)}{dt} = Gw_j(t) y_{\text{recibido}}(t) \quad (4.4.5.2)$$

El subíndice j se refiere a la salida de la misma neurona; el subíndice *recibido* se refiere a las señales de entrada recibidas por la neurona en sus interconexiones de entrada. G es simplemente una constante positiva que determina la importancia relativa del término del aprendizaje Hebbiano comparado al término de olvido.

Tal y como dentro de la ecuación de la actividad, no obstante, el tiempo que viaja debe ser tomado en cuenta. Recuerde que los estímulos no pueden viajar instantáneamente desde la neurona generadora hasta la neurona receptora; así, la señal de entrada recibida es aquella la cual fue generada en algún tiempo, t_0 , antes del tiempo corriente t .

Además, las señales también pueden ser umbrales para

evitar los mismos problemas de ruido como antes. Únicamente los términos que tienen una señal de entrada más grande que el umbral \mathcal{J} contribuye al cambio de peso, cualquier entrada menor que el umbral en nada contribuye. El índice "+" nos dice que únicamente contribuyen periodos positivos. La ecuación ahora se vuelve

$$\frac{dw_{ij}(t)}{dt} = G y_j(t) [y_i \text{ recibida}(t - t_0) - \mathcal{J}]^+ \quad (4.4.5.3)$$

Finalmente, ambos términos de la ley de aprendizaje pueden combinarse, sustituyendo el subíndice *recibida* con un reconocimiento que el peso está en la conexión desde la i^{ava} neurona hasta la j^{ava} neurona:

$$\frac{dw_{ij}(t)}{dt} = -\mathcal{J} y_j(t) + G y_j(t) [y_i(t - t_0) - \mathcal{J}]^+ \quad (4.4.5.4)$$

Aquí, w_{ij} se refiere al peso en la conexión que enlaza la salida de la i^{ava} neurona a la entrada de la j^{ava} neurona, y_i y y_j son las señales de salida para la i^{ava} y j^{ava} neuronas, respectivamente. t_0 es el tiempo de viaje para la señal de salida desde la neurona i hasta su recepción en la neurona j , y \mathcal{J} es el umbral de abajo, el cual la neurona receptora ignora las señales de entrada.

4.4.6 EL VALOR DE LAS CONSTANTES.

Antes de finalizar esta discusión, permitámonos tomar una última mirada a las constantes dentro de la ecuación de

actividad y de la ecuación del aprendizaje. La ecuación de la actividad calcula la actividad de la neurona basado en sus entradas y en el decaimiento de sus previas activaciones. Esta ecuación, recuerde, es

$$\frac{dy_j(t)}{dt} = -Ay_j(t) + I_j(t) + \left(\sum_{i=1}^n w_{ij} [y_i(t - t_0)] - T \right) \quad (4.4.8.1)$$

Similarmente, la ley de aprendizaje es usado para calcular los cambios dentro de los pesos en las interconexiones entre las neuronas dentro de las redes; esta ecuación es

$$\frac{dw_{ij}(t)}{dt} = -\mathcal{F}y_j(t) + G y_j(t) [y_i(t - t_0) - \mathcal{J}] \quad (4.4.8.2)$$

Las dos ecuaciones contienen cuatro constantes: \mathcal{A} , \mathcal{F} , \mathcal{G} y \mathcal{J} . El umbral, \mathcal{J} , ha sido discutido anteriormente; su valor depende del nivel de ruido actual o esperado dentro del sistema. Si ruido pequeño está presente, el umbral debe ser colocado a algun valor muy pequeño; si el ruido es más molesto, el umbral debe ser más alto.

\mathcal{A} es la constante del decaimiento de actividad, determinando cuán rápidamente una actividad de la neurona decairá si los estímulos le son quitados; \mathcal{F} es la constante del olvido que determina cuán rápidamente una interconexión particular (memoria) decairá si no se ejercitó. Los valores específicos para estas constantes variarán, claro, pero el decaimiento de activación de una neurona debe ocurrir en distintos órdenes de magnitud más rápido que el decaimiento de interconexión; \mathcal{A} es así mucho más grande que

F.

Recuerde que los niveles de activación de la salida están típicamente dentro del rango de 0 a 1.0, aunque otros rangos son posibles. Dentro de la ley de aprendizaje, esta situación implica que el producto del aprendizaje Hebbiano de dos salidas similarmente deben estar dentro del rango de 0 a 1.0. ξ debe ser positivo (de otro modo el término Hebbiano tendría el efecto opuesto al pretendido) y típicamente dentro del rango de 0 a 1.0. Este término es lo que Grossberg llama *ganancia* porque sirve al mismo propósito como un control de ganancia en un instrumento electrónico. En función, es casi idéntico con aquellas de las constantes de aprendizaje encontradas en retropropagación y en el aprendizaje Kohonen. Controla cuán rápidamente la sinapsis aprende la ruta; una ganancia más grande significa un aprendizaje más rápido, mientras que una ganancia más pequeña significa un aprendizaje más lento.

4.4.7 LOS OUTSTARS EN ACCION.

Permítanos cambiar nuestra perspectiva de la red ligeramente desde la rejilla del instar hasta la neurona individual del outstar y ver lo que ocurre. Recuerde, sin embargo, que cada neurona está simultáneamente en el centro de un instar y en el centro de un outstar.

Suponga que un outstar envía su salida a cada uno de las 70 neuronas arregladas dentro de una simple rejilla, mostrada

en la fig. 4.4.3.3. También, suponga que el outstar tiene solo una entrada, una exterior una tal que cuando el outstar reciba este estímulo, genere una señal de salida de 1.0 a cada uno de las 70 neuronas dentro de la rejilla. En otras palabras, un mecanismo existe tal que la neurona outstar puede ser encendida o apagada a voluntad. Finalmente, permite a cada neurona de la rejilla tener estímulos externos que puedan forzarlos a salir como deseo.

Esta simulación tiene algunas suposiciones simplificadas fundamentadas dentro de él. El primero es que la red opera en incrementos de tiempo pequeños, contados como un intervalo de tiempo unitario. Cada una de las 70 neuronas que reciben el estímulo del outstar son actualizadas sincrónicamente después de cada uno de estos incrementos de tiempo. Los sistemas biológicos reales operan asincrónicamente, así esta explicación es una sobreesimplificación precisa.

La simulación también solo contiene un outstar individual, las 70 neuronas de la orilla son, claro los instar correspondientes que reciben estímulos del outstar y del mundo exterior; en este caso, el mundo exterior es simplemente una serie de señales externas arregladas.

Ahora conduzca un experimento. Comience con una serie aleatoria de pesos entre el outstar y la rejilla de neuronas. Las neuronas estimuladas dentro de la rejilla (a través de la estimulación individual del exterior de cada neurona) tal que un dibujo de la letra A aparece en la rejilla. En otras palabras, imprime un dibujo de A en la rejilla. Al mismo

tiempo, estimula la neurona outstar para causarle, en turno, transmitir una señal de salida fuerte a cada neurona de la rejilla. Lo que pasa es lo siguiente:

Primero considere las neuronas de la rejilla que no están activas en la producción de la letra A. Estas neuronas de la rejilla son instars que reciben dos entradas, una de la neurona outstar y otra del mundo exterior. Sus niveles de actividad corriente son bajos porque la entrada externa no les es estimulada. El cambio de peso en la sinapsis entre el outstar y cada una de estas neuronas inactivas están poco activas porque es el producto de la actividad de entrada (del outstar) y la actividad corriente de la neurona de la rejilla, la cual determina el incremento dentro del peso en aquella interconexión.

Así, aunque reciben una entrada sustancial del outstar, la característica que estas neuronas tienen o no una pequeña actividad corriente significa que sus sinapsis no están reforzadas significativamente en respuesta a la estimulación del outstar. De hecho, la sinapsis puede incluso decrecer en fuerza porque el término de olvido puede ser suficiente para vencer cualquier incremento pequeño de peso positivo. Así, estas neuronas de la rejilla no aprenden a responder al outstar o, más exactamente, no aprenden a responder hacia el outstar.

Aquellas neuronas dentro de la rejilla que reproducen activamente el dibujo de la letra A, también son instars, pero sus niveles de actividad corrientes son altos debido a

los estímulos externos. Así, cuando el estímulo del outstar es recibido, ellas tienen una activación alta de estímulos externos, más unos estímulos grandes de entrada del outstar. El producto de estos dos es también grande, y los pesos sinápticos se fortalecen sustancialmente.

Suponga que repetidamente imprime la ruta para $\#$ en las neuronas de la rejilla al mismo tiempo que golpea al outstar en estimularlos. Puede imaginar que las fuerzas sinápticas hacia la rejilla de neuronas que actualmente disparan hagan la ruta $\#$ se vuelvan muy fuertes sobre el tiempo, mientras las fuerzas sinápticas para otra rejilla de neuronas tienda a debilitarse incesantemente.

Ahora suponga que bloquea los pesos dentro del sistema y luego estimula a la neurona del outstar sin abastecer de los estímulos exteriores para que la rejilla de neuronas. Debe ser claro que estas neuronas de la rejilla que componen la ruta $\#$ de nuevo disparan cuando tienen conexiones sinápticas fuertes para la estimulación de la neurona outstar, mientras las otras neuronas de la rejilla no porque sus conexiones sinápticas hacia el outstar están débiles.

El resultado es que el outstar ha aprendido a reproducir la letra $\#$, aunque los avisos externos ya no están presentes. El outstar, de hecho, se ha comportado dentro de la condición Pavloviana clásica, con el mismo resultado; ha sido *condicionado* para responder cuando era estimulado por los *estímulos condicionantes* adecuados.

No es todo lo que la red puede aprender. Usted puede

usar esta misma colección de neuronas de la rejilla para producir cualquier otra ruta que queramos. Puede llevar a cabo esta tarea de dos maneras. Uno es reconvertir el outstar de manera que generará el nuevo dibujo en lugar de la *s*. Desafortunadamente, este procedimiento tiene el efecto del lado indeseable de olvidar cómo producir la ruta original *s*.

El segundo método es usar otro outstar conectado a las mismas neuronas de la rejilla y entrenar la rejilla para producir la nueva ruta cuando el segundo outstar dispare. Claro, este entrenamiento modifica las conexiones sinápticas entre las neuronas de la rejilla y el segundo outstar. (Las conexiones sinápticas para el primer outstar serán más o menos iguales dentro de tal entrenamiento). Las neuronas de la rejilla pueden aprender aun más rutas mediante la suma adicional de outstars estimuladores, uno para cada ruta nueva de salida. Así, puede aprender tantas rutas disponibles como tenga estímulos de los outstars.

El aprendizaje outstar provee una base matemática de la explicación para diversos efectos psicológicos. La potencia de esta técnica de experimentos psicológicos *ideados* han provisto su valor y da un mejor entendimiento de las redes nerviosas biológicas lo mismo que para las artificiales. Mientras que los outstars raramente son usados como redes nerviosas únicas, ellas tienen enormes potenciales para las aplicaciones cuando los conceptos son aplicados y combinados con otras técnicas de redes.

4.5: LA AVALANCHA.

El artículo previo introdujo el aprendizaje outstar, el cual exhibe características de condicionamiento Pavloviano. Este artículo modifica el outstar para crear una red que aprenda secuencias temporales o variantes con el tiempo de rutas espaciales. Tales secuencias pueden ocurrir, por ejemplo, dentro de señales del habla, la repetición de los movimientos de un brazo robótico, o cualquier número de otras aplicaciones. Antes de aprender, sin embargo, permitámonos primero recordar cómo trabaja el aprendizaje outstar.

El modelo outstar consiste de dos ecuaciones diferenciales, una ecuación de actividad y una de aprendizaje. Estas dos fórmulas tomadas juntas suministran una estructura matemática que pueden ser usadas para describir la actividad corriente de cada neurona dentro de la red a cualquier tiempo y la manera en la cual los pesos en las interconexiones entre las neuronas se modifican durante el entrenamiento. Cuando estos atributos son las características fundamentales de interés dentro de la red, ellos completamente especifican el estado de la red para nuestros propósitos.

Esta situación obviamente asume que las interconexiones de la red sean estables e iguales, algo evidentemente no está en el caso para los sistemas biológicos, cuando las neuronas pueden y hacen crecer nuevas conexiones para otras neuronas. Para una red nerviosa artificial, no obstante, puede principiarse con un grado alto de interconectividad de lo que

realmente, necesita, luego permite a la ley de aprendizaje reducir los pesos en interconexiones no necesarias hasta cercas de cero. Mientras que no esten con la tan exactitud biológica como las interconexiones cambiantes, es generalmente mucho más fácil implementar un modelo fiel al biológico.

4.5.1 LA ECUACION DE ACTIVIDAD DEL OUTSTAR.

La ecuación de actividad para el aprendizaje outstar especifica el nivel de excitación o actividad de cada neurona dentro de la red en cualquier tiempo dado. La fig. 4.5.1.1 muestra dos neuronas típicas dentro de la red. El cambio en la actividad a cada instante de tiempo para la j^{ava} neurona dentro de la red es mostrado por la ecuación:

$$\frac{dy_j(t)}{dt} = -Ay_j(t) + I_j(t) + \sum_{i=1}^n w_{ij}(y_i(t-t_{ij}) - T) \quad (4.5.1.1)$$

Esta ecuación calcula la activación de la neurona j , la cual recibe entradas del mundo exterior ($I_j(t)$) y de las salidas de las otras neuronas dentro de la red (el término de la sumatoria). La actividad de la neurona j , $y_j(t)$, es una función del tiempo.

El primer término dentro de la ecuación indica cómo la actividad de la neurona decae cuando todos los estímulos son quitados; define un término de decaimiento exponencial. El segundo término define cómo la actividad de la neurona se incrementa si una señal de entrada es aplicada hacia la

neurona; dentro de un experimento biológico, esto debe corresponder a aplicar una prueba eléctrica externa a una célula nerviosa. Como el estímulo externo puede estar presente o no, y a niveles variantes, esta entrada externa es dependiente del tiempo.

Finalmente, el tercer término especifica cómo las activaciones (salidas) de las demás neuronas de la red contribuyen al nivel de actividad de la i ava neurona. La entrada total a la i ava neurona del resto de la red es la suma de los pesos de las entradas de las neuronas de la red con un valor de umbral restado. Solo entradas más grandes que este umbral son permitidas a contribuir a la suma; términos negativos no existen dentro de la suma. Cuando requiere algún tiempo finito para cualquier salida de la neurona i para alcanzar a la neurona j , el nivel de actividad supuesto es el nivel de actividad generado que hace en t_0 unidades de tiempo. Nada en esta ecuación prohíbe a la neurona j de contribuir al término de suma, permitiendo la retroalimentación desde j hacia sí mismo si lo desea.

Las constantes dentro de esta ecuación, α y β , pueden ser colocadas como parámetros para la red. Mientras que β puede ser colocado fácilmente a uno, normalmente quiere que la actividad de las neuronas vayan desapareciendo rápidamente en cuanto el estímulo externo sea quitado. Así, α debe ser colocado hacia algún valor bastante grande que debe causar un rápido decaimiento exponencial, donde rápido es relativo para otras funciones de la red. Dentro de tal red, un outstar

individual exhibe pulsos de actividad como aquellos vistos en la fig. 4.5.1.2, cuando un estímulo externo es aplicado.




Fig. 4.5.1.1 La actividad $y(t)$ de la j ^{ava} neurona depende de la entrada externa $I(t)$ y de las entradas de los pesos de las demás neuronas.




Fig. 4.5.1.2 Un estímulo aplicado a t_0 y quitado a t_1 causa un pulso de actividad que decae bruscamente.

4.5.2 ECUACION DE APRENDIZAJE DEL OUTSTAR.

La ecuación de aprendizaje para la red outstar es ligeramente más simple en concepción:

$$\frac{dw_{ij}(t)}{dt} = -\tau y_j(t) + G y_j(t) [y_i(t - t_0) - \tau]^+ \quad (4.5.2.1)$$

Aquí, como dentro de la previa ecuación de actividad, w_{ij} es el peso en la interconexión que enlaza la salida de la i ava neurona hacia la entrada de la j ava neurona. Tal y como dentro de la ecuación de actividad, el primer término consiste de un término de decaimiento exponencial; sin embargo, lo que decae aquí no es la actividad de la neurona,

sino el valor del peso en la interconexión entre las dos neuronas. Permitiendo a los valores de los pesos decaer permite a la red olvidar así como aprender. Así, la constante \mathcal{F} es denominada la constante de *olvido*, controla la proporción a la cual las memorias son perdidas. El término de suma es muy similar al término de suma dentro de la ecuación de actividad con la misma explicación para sus términos. El producto de la salida corriente de la neurona j con aquella señal entrante de la neurona i provee una ley de aprendizaje Hebbiano.

La constante de enfrente de la suma, \mathcal{G} , es llamada la *ganancia* y es la constante de aprendizaje. Controla la velocidad a la cual los pesos aprenden nuevas rutas; un valor más grande de la ganancia implica aprender más rápido, mientras un valor más pequeño de la ganancia implica aprender más lentamente.

Todas las constantes dentro de ambas ecuaciones, de paso, generalmente están limitadas al rango de cero a uno, y todas siempre son positivas.

Para esta red, el decaimiento de cada actividad de la neurona generalmente debe ocurrir en una escala de tiempo mucho más rápido que el decaimiento de los pesos. Por consiguiente, la constante \mathcal{A} , la cual controla el decaimiento de la actividad, debe estar dos o tres grados de magnitud más grande que la constante \mathcal{F} . Esta situación es frecuentemente el caso para muchas aplicaciones. No obstante, si las constantes son puestas diferentes, tal arreglo puede ser

usado para aprender rutas que cambian en el tiempo.

4.5.3 APRENDIZAJE SENCILLO DE LA RUTA DEL TIEMPO.

El outstar puede ser usado de diversos modos para aprender rutas espaciales temporales. El metodo mas simple consiste de una neurona outstar individual, el cual se retroalimenta a si mismo a traves de un número de conexiones, como el mostrado en la fig. 4.5.3.1.




Fig. 4.5.3.1 Un outstar puede aprender rutas temporales. La entrada externa *I* comienza a retirar y cuidadosamente los colaterales espaciados causan a la ruta cambiar.

Dentro de una neurona biológica, recuerde, una célula tiene una salida individual, llamada axón, el cual tiene muchas derivaciones, denominadas colaterales. El axón, como ya se mencionó, pueda ser imaginado como una cola muy larga

prolongada hacia afuera de la neurona, con bifurcaciones hacia cualquier lado. Las ramificaciones terminan en uniones sinápticas a los lados de las entradas de las otras neuronas (dendritas). Si una neurona tiene un arreglo similar, las señales pueden ramificarse al revés —no hacia otras neuronas, sino hacia las entradas del mismo outstar—. (Recuerde que nada dentro de las ecuaciones de actividad o aprendizaje prohíbe tal retroalimentación).

Suponga que alguna entrada exterior hacia el outstar le causa volverse activo y envía un pulso de actividad bajo la línea de salida. Cada vez que llega una ramificación donde un colateral interconectado le quita la línea principal, el pulso se desintegra y baja a la interconexión principal y a la interconexión colateral. La interconexión colateral vuelve a llevar hacia el lado de la entrada de la neurona, el cual causa que la neurona se vuelva activa y de nuevo produzca un pulso de actividad.

Entre tanto, el pulso original continua desplazandose bajo la interconexión principal hacia la siguiente ramificación, desintegrada y realimentada hacia las entradas del outstar. Este proceso continua, con cada pulso retroalimentado hacia la entrada y produciendo otros pulsos de actividad, mientras que cada uno eventualmente termina en colaterales que no se dirigen al revés hacia el outstar, sino hacia el mundo exterior. El mundo exterior ve la colección entera de pulsos como una ruta de salidas variantes del tiempo, la ruta del espacio temporal.

Este esquema, hasta relativamente simple para explicar, mientras es fácil ver cómo tal sistema podía comenzar, es más difícil ver cómo para. En algún lugar a lo largo del sistema de ramificación algún nivel de conexiones inhibitorias (pesos negativos) necesitan existir para disminuir fuera de la ruta.

Además, si el outstar es difícil para aprender un número significativo de rutas variantes dentro de una secuencia temporal, tendría que permitir la amplificación de la señal a cada ramificación así el pulso permanecería en un nivel razonablemente alto cuando se desplaza bajo el axón. Pero que esta situación, sin embargo, es la rigidez de la red. La única ruta temporal de este sistema que puede aprender es aquella la cual está definida por las locaciones de las ramificaciones colaterales. El outstar literalmente debe de ser construido con ramificaciones precisamente a las locaciones de la derecha de manera que el paso de los cambios puedan operar correctamente. Finalmente, porque puede únicamente tener una salida individual, está limitado en las clases de rutas espaciales que puede representar hacia un número individual real.

Las representaciones de ruta espaciales pueden ser mejoradas teniendo las ramificaciones realimentadas hacia un arreglo de neuronas similares para las neuronas de la rejilla dentro de la red outstar del artículo anterior. La fig. 4.5.3.2 ilustra este arreglo.




Fig. 4.5.3.2 El outstar aprender rutas de salida sofisticadas.

Aquí, la salida del outstar todavía se desplaza bajo el axón largo, la ramificación a puntos temporales seleccionados, pero la ruta reproducida puede ser mejorada para permitir, por decir, la reproducción de una imagen de un pixel en las neuronas de la rejilla. Cuando la salida alcanza cada punto de la ramificación, el pulso se transmite hacia cada neurona de la rejilla, causando que la rejilla reproduzca la ruta específica. Cuando cada punto de la ramificación corresponda a una serie separada de pesos de la rejilla, puede aprender tantas rutas diferentes en la rejilla como puntos tenga la ramificación. Así, la rejilla puede reproducir A , B , C , y así sucesivamente en secuencia, todas como un resultado de un disparo del outstar individual.

Incluso este esquema no es bastante flexible para las rutas complejas. Suponga que quiera entrenar una red para reproducir una ruta visual, seguido por un movimiento de control de un brazo robótico, seguido por un ajustamiento de válvula. Una serie individual de neuronas de la rejilla son insuficientes para esas tareas diferentes. En su lugar, tendría una serie de neuronas de rejilla que suministran la exhibición del pixel, otro controla el brazo robótico, y todavía otro controla la válvula.

Puede crear esta clase de sistema mediante el uso del diseño mostrado en la fig. 4.5.3.3. Aquí, cada punto de la ramificación tiene una *interneurona*, la cual se ramifica hacia una serie completamente separada de neuronas de la rejilla. Cada rejilla puede ser independiente de todas las otras rejillas y pueden realizar funciones ampliamente variantes. No obstante, de otra manera, este diseño trabaja igual como las dos versiones anteriores.




Fig. 4.5.2.3 Rutas diferentes en la secuencia temporal.

Incluso este esquema para aprender rutas de espacio temporales tiene algunas fallas. El primero es que no todo está exactamente claro de cómo construiría tal sistema para un problema arbitrario. La fuerte dependencia de estos diseños en tener una distancia exacta entre las ramificaciones interconectantes significa que ellas son altamente inflexibles en términos de variabilidad temporal. Y, claro, el esquema de entrenamiento es confuso y oscuro.

4.5.4 LA AVALANCHIA.

La red Avalancha presenta un método limpio, y sencillo de reproducir rutas espaciales temporales de casi flexibilidad infinita.

Comenzamos con una red de tres capas, como la mostrada en la fig. 4.5.4.1. El diseño de la red es mantenerla muy pequeña, con las neuronas arregladas como una fila individual dentro de cada capa. Tiene 10 neuronas en cada una de las capas de entrada e intermedia, con cada neurona de la capa de entrada conectando hacia todas las neuronas de la capa intermedia. La capa de salida define el formato de la salida de la red; por simplicidad, tiene una clase de neurona de salida de la rejilla individual, la cual puede reproducir una imagen de pixel de 7×10 . La capa intermedia de la avalancha es la capa interesante.

Las neuronas de la capa de avalancha están altamente interconectadas hacia las otras neuronas dentro de la capa. Para esta red, asuma que cada neurona dentro de la capa de avalancha tiene conexiones para todas las otras neuronas dentro de la capa. Estas conexiones son modificables; pueden ser entrenadas usando la ecuación de aprendizaje del outstar especificado previamente.




Fig. 4.5.4.1 La red avalancha.

También modificaremos levemente las ecuaciones de actividad de estos outstars mediante la colocación del parámetro de decaimiento de activación, λ , hacia un nuevo valor. En lugar de tener el decaimiento de la actividad de las neuronas de la capa de avalancha inmediatamente, el parámetro de decaimiento de la activación es colocado así la activación de estas neuronas decaen lentamente sobre un periodo prolongado de tiempo. La fig. 4.5.4.2 exhibe cómo una breve entrada externa hacia tal outstar produce un pulso diferente distintamente de actividad que antes.

Asuma para claridad que cada neurona de la capa de avalancha requiere dos periodos de tiempo para producir su actividad para bajar el valor del umbral J . También asuma que todas las interconexiones (intercapa o intracapa) requieren exactamente una unidad de tiempo para viajar entre neuronas.




Fig. 4.5.4.2 Una actividad de desencadenamiento de la neurona avalancha.

4.5.5 LA AVALANCHA EN OPERACION.

La fig. 4.5.5.1 muestra cómo la red avalancha completamente entrenada trabaja para producir una secuencia temporal de rutas espaciales, a saber el alfabeto. Principiando con la actividad de la red (fig. 4.5.5.1a) son mostradas a cada segundo del reloj desde $t = 0$ hasta $t = 4$.




Fig. 6.5.5.1 La Avalancha en acción.

- Tiempo $t = 0$. Una rta de entrada externa es presentada a la red, consistente de una rta binaria con un único bit "1". La neurona de entrada 1 se

vuelve activa, transmitiendo su señal hacia todas las neuronas de la capa avalancha. La salida de la neurona de entrada llegará allí en una unidad de tiempo.

- *Tiempo $t = 1$.* La ruta de entrada ha llegado a la capa avalancha, causando que la neurona 3 en aquella capa dispare. La salida de la neurona 3 es enviada a la capa de salida y hacia las neuronas 2 y 6 dentro de la capa avalancha. (Otras conexiones intercapa tienen pesos cercanos a cero y pueden así ser ignorados).
- *Tiempo $t = 2$.* Las neuronas 2 y 6 reciben la señal de entrada de la neurona 3. En suma, cada uno ve la ruta desde la capa de entrada, lo cual ahora ha decaído a la mitad de fuerza. De la neurona 2 y 6, solo la neurona 6 tiene pesos en sus entradas desde la capa de entrada y la neurona 3 se vuelve activa. La neurona 2 no se vuelve activa; la neurona 6 dispara. Envía su salida hacia las neuronas 2 y 5 y a la capa de salida. A la capa de salida, la señal de la neurona 3 ha sido recibida y causa que la letra *x* sea reproducida en la rejilla.
- *Tiempo $t = 3$.* Las neuronas 2 y 5 reciben la entrada de la neurona 6. En suma, también la neurona 2 ve la salida de la neurona 3, aunque ahora ha decaído a la mitad de fuerza. (La ruta de entrada ahora ha decaído hasta abajo del umbral). La neurona 2 ahora tiene suficiente estimulación para volverse activa.

así dispara y envía su salida hacia la neurona 5 y a la neurona 7, igual que hacia la capa de salida. La neurona 5 ve la señal de entrada de la neurona 6, pero eso es insuficiente (debido a los pesos en las interconexiones) para que la neurona 5 dispare. A la capa de salida, la señal de la neurona 6 es recibida, y las neuronas de la rejilla reproducen 3.

- *Tiempo t = 4.* Las neuronas 5 y 7 reciben la señal de salida de la neurona 2. La neurona 5 ve la mitad de la señal restante de la neurona 6, y esta señal combinada pone a la neurona 5 encima del umbral, causando disparar. La neurona 7 es estimulada insuficientemente hasta quedar inactiva. La salida de la neurona 5 es enviada hacia las neuronas 7 y 1 y hacia la capa de salida. A la capa de salida, la salida de la neurona 2 ha sido recibida, y las neuronas de la rejilla reproducen 8.

La operación de la avalancha debe de ser evidente por ahora. El parámetro de decaimiento de la activación es colocada así a cada señal de salida que requiera un par de unidades de tiempo para decaer abajo del umbral, y el umbral es tal que una señal entrante individual es insuficiente para causar que la neurona dispare. Cada neurona de la capa avalancha debe de recibir al menos dos señales simultáneamente para volverse activa. (La primera neurona en la secuencia es una excepción a esta regla; la ruta de

entrada por si misma es suficiente para causar a la primera neurona volverse activa).

4.5.6 ENTRENANDO A LA AVALANCHA.

El entrenamiento de la avalancha para llevarlo a cabo como se describió anteriormente puede sonar desalentador, pero es totalmente sencillo. Primero, considere cómo la capa de salida aprende a reproducir las letras A, B, C, etc. En cualquier momento que las neuronas ven un estímulo fuerte (completamente resistente) de una neurona específica dentro de la capa avalancha, pueden estar condicionadas usando técnicas de aprendizaje outstar estándares para reproducir la letra apropiada en la rejilla. Como vimos tiempo después, este proceso trabaja hermosamente, así la capa de salida de la red es equivalente a la rejilla outstar de la previa discusión del aprendizaje outstar.

Para un modelo biológicamente consistente, la red necesitaría una versión más complicada de las ecuaciones de actividad y aprendizaje. No obstante, para un sistema práctico que trabaja, las ecuaciones existentes bastan con una estructura de red levemente más complicado. El sistema simplemente necesita algo para monitorizar la respuesta de cada neurona de la capa avalancha para un estímulo. Esta estructura luego elige a la neurona con el nivel de actividad más grande a cualquier tiempo dado y aplica estímulos adicionales suficientes (instantáneas) para forzar a

aquella neurona a tener una salida +1.

Esta ocurrencia coloca a la neurona bajo la misma situación del aprendizaje Hebbiano como las neuronas de la capa de salida: La neurona es forzada a ser activa al mismo tiempo que recibe una serie particular de señales entrantes, la cual causa al aprendizaje *outstar* derribarlo y a la neurona volverse más sensible a las señales entrantes en el futuro (los pesos se incrementan en aquellas sinapsis de entrada).

Dentro de un sistema biológico, este efecto del *ganador toma todo* podría ser llevado a cabo mediante una arquitectura de inhibición lateral similar aquel discutido dentro de la red Kohonen.

Permitiendo al que llega corriendo más velozmente ajustar sus pesos al igual como la ganadora hace entrenar al sistema un 1 más rápido, pero no es estrictamente requerido. Esta situación tiende a influenciar a la avalancha de manera que la ganadora en el próximo pulso de reloj será la que llega corriendo más velozmente a este instante en el tiempo. Este proceso tiene una elegancia y simplicidad que lo hace fácil de comprender.

En general, no obstante, la ganadora a cada pulso podría estar relacionada aleatoriamente a la ganadora anterior y a la casi ganadora. También, mientras que la discusión usó disparos de neurona individual para claridad, la red avalancha podría generar una ruta de actividad en lugar. Esto hace a la red más robusta (perdiendo una neurona de la

capa avalancha no destruiría la recuperación de cualquier ruta dada y hace que la salida del sistema genere un número grande de respuestas de rutas de espacio temporales sin incrementar el tamaño de la red.

4.5.7 VENTAJAS DE LA AVALANCHA.

La Avalancha presenta un sistema que tiene un método de entrenamiento realista; ya no tiene que construir la red de manera que físicamente conviene la secuencia de ruta que necesita para aprender. En cierta manera, este proceso significa que la red avalancha comienza como una red de espacio temporal de propósito general que aunque solo el entrenamiento aprende a especializarse dentro de una secuencia de rutas particulares.

En suma, desafortunadamente las redes más simples, la avalancha puede comenzar y detener una ruta temporal a puntos arbitrarios. Los sistemas más simples discutidos anteriormente transmiten un pulso bajo el axón que es más o menos imparables una vez empezado. En contraste, la avalancha puede tener capacidades sofisticadas *empezar de aquí y para ahora* incorporadas mediante el uso juicioso de pesos inhibitorios y entradas externas. Si permite una señal inhibitoria global hacia la capa avalancha, puede parar la reproducción de la secuencia en cualquier momento. Si quiere comenzar desde la mitad de la secuencia, necesita solo estimular las neuronas de la avalancha apropiada dentro de la

acción sobre un par de periodos de tiempo para comenzarlos a subir desde aquel punto.

4.6: TEORIA DEL REFUERZO DE LA TRANSMISION.

El ultimo par de subcapitulos han explorado los paradigmas del aprendizaje que son directamente tratadas para sus sistemas de aprendizaje de modelos biologicos. En particular, el subcapitulo 4.4 considero el modelo de aprendizaje outstar desarrollado por Steve Grossberg para ver cómo puede modelar el condicionamiento Pavloviano. El subcapitulo 4.5 modifico el outstar ligeramente y mostro cómo puede aprender rutas espaciales temporales, o rutas que varien con el tiempo al igual que en el espacio.

Este subcapitulo mira más de cerca el problema del condicionamiento Pavloviano y desarrolla un paradigma de aprendizaje que lo modela incluso más exactamente que el outstar. Este paradigma es denominado la Teoria del Refuerzo de la Transmision, o DRT (Drive-Reinforcement Theory), y fue desarrollado por Harry Klopf en la Base de la Fuerza Aérea de Wright-Patterson.

El paradigma del aprendizaje outstar modela el comportamiento Pavloviano razonablemente bien (citado anteriormente). Desafortunadamente, esta descripción simple de los experimentos de condicionamiento de Pavlov no es completamente preciso, y el problema esta en la frase *al mismo tiempo*. Pavlov encontró que el condicionamiento trabajó mucho más efectivamente si tocó la campana antes de que mostrara la comida al perro. Dependiendo del animal y del experimento, el tiempo de decaimiento entre el estímulo condicionante (la campana) y el estímulo no condicionante

(la comida) debe ser bastantes grandes para mejores resultados. Abasteciendo ambos estímulos simultaneamente resultó ser mucho menos efectivo que colocarlos dentro de una secuencia temporal (tiempo).

Considerando el condicionamiento Pavloviano como una herramienta de supervivencia para el animal, puede ver exactamente porque trabaja mejor cuando la campana toca antes de que llegue la comida. Desde la perspectiva del perro, aprende a reconocer que la comida que esta alrededor (o, tal vez, algun depredador peligroso) parece darle tiempo para reaccionar hacia aquel evento, de manera que efectivamente puede prepararse a comer —o evitar ser comido—.

Asociando unos estímulos con la aparición de la comida o del depredador tiene un pequeño punto; para entonces, el perro puede sentir directamente que ha llegado y puede inmediatamente comenzar a comer, huir, o pelear. El aprendizaje de una asociación ha provisto al animal no con la habilidad mejorada para la supervivencia. Por otro lado, si el animal asocia un estímulo particular que ocurre antes de que llegue la comida o el peligro, puede preparar sus reacciones. Así, el animal puede ser un poco más rápido que sus compañeros para apoderarse de un sabroso bocado, o un poco más probablemente para evitar al depredador. Los beneficios de supervivencia global del aprendizaje de tales asociaciones relacionadas temporalmente son claras.

Como resultado, los experimentos de condicionamiento han mostrado consistentemente que una secuencia de estímulos

dentro del tiempo es lo más efectivo dentro del entrenamiento. Primero toque la campana y luego muestre la comida para una experimentación óptima. Tal condicionamiento Pavloviano no es el único verdadero de los experimentos *totalmente con animales*, sino también de los experimentos a nivel de neurona individual.

4.6.1 EL OUTSTAR Y PAVLOV.

Desafortunadamente, mientras el outstar efectivamente modela el condicionamiento Pavloviano dentro de su comportamiento global, correlacionando una respuesta del outstar para el comportamiento detallado de un animal, dentro de un experimento condicionante revela algunos problemas serios.

Mientras que las ecuaciones del outstar ciertamente consideran el tiempo dentro de una escala pequeña —el tiempo de viaje entre neuronas, por ejemplo— no provee que exista para especificar una secuencia temporal de eventos. Cada neurona reacciona a estímulos y los recibe bien ahora, en lugar de considerar la historia del estímulo recibido en el pasado reciente. En otro sentido, las neuronas del outstar no tienen memoria a todo; simplemente existen en un momento continuo individual, incluso cambiante, no con recolección o estar relacionado con sus pasados o futuros. Ellos son simples automatismos no con sentido del tiempo para todo. Mientras esta condición hace un simple sistema para

implementar y sencillo para comprender, no sirve como un modelo efectivo para sistemas biológicos de gran escala.

En otros detalles de escala fina del condicionamiento Pavloviano, errores y problemas similares ocurren con el modelo outstar. Por ejemplo, el outstar aprende el comportamiento apropiado en un modo más o menos lineal; en otras palabras, los pesos suben linealmente con el número de repeticiones del experimento. En contraste, los experimentos biológicos exhiben una curva de adquisición de forma de S, con un incremento inicial fuerte dentro de las primeras pocas pruebas, el cual más tarde se aminora, causando a los valores de peso cambiar en menos repeticiones posteriores. La fig. 4.6.1.1 muestra la forma de la curva de adquisición para el outstar y para aquel el cual fue encontrado experimentalmente dentro de sistemas biológicos. También el outstar no modela precisamente otros varios más semejantes resultados experimentales dentro del condicionamiento animal y celular.




Fig. 4.6.1.1 La forma de la curva de adquisición para el outstar.

Si estos problemas con el outstar son serios dependen de su perspectiva. Ciertamente, el outstar es bastante efectivo para usarlo dentro de muchas aplicaciones, particularmente aquellos donde la secuencia de tiempo estímulo-respuesta no es importante para nosotros. Sin embargo, si verdaderamente quiere modelar sistemas biológicos, o si tiene un problema donde necesite correlacionar un estímulo de entrada con una respuesta posterior, el outstar simplemente no lo hará. Necesita un modelo de aprendizaje más sofisticado.

4.6.2 TEORIA DEL REFORZAMIENTO DE LA TRANSMISION.

Harry Klopf desarrolló la Teoría del Reforzamiento de la Transmisión (DRT) hace unos años, creando un sistema de

aprendizaje que corrientemente abastece el mejor modelo del condicionamiento Pavloviano.

Dentro del aprendizaje outstar, un plazo simple del aprendizaje Hebbiano indicó que el aprendizaje ocurre unicamente cuando la neurona A estimula a la neurona B al mismo tiempo cuando B esta ya activa. Asi, la necesidad de la estimulación simultánea fue construida dentro de la red. La DRT, en contraste, usa una ley de aprendizaje que ofrece dos variaciones distintas en el aprendizaje Hebbiano. Primero, usa un termino de aprendizaje Hebbiano diferencial que dice: el cambio dentro de la estimulación de A y de B, al mismo tiempo que la salida de B cambia es lo que causa el aprendizaje. Segundo, no usa solo el cambio corriente dentro de la estimulación de A y de B, sino la acumulacion de estos cambios sobre algun periodo de tiempo significante para determinar el nivel de aprendizaje.

La fig. 4.6.2.1 muestra esta configuración, con una neurona outstar estimulante individual conectada a una rejilla de 7 x 10 de neuronas instars. Esta configuración, claro, es identica a la red usada dentro de la red outstar. Solamente porque esta red usará una ley de aprendizaje diferente que el paradigma del aprendizaje outstar no hace esto algo menos que una red de instars y outstars. Recuerde que el concepto de un instar o un outstar es simplemente un modo de ver a cualquier neurona como o el centro de una estrella radiante de movimientos aparentemente de señales de activación (un outstar) o el foco de una estrella radiante

interiormente de señales de entrada (un instar). No importa que red use, considerando los componentes de la red como instars y outstars es perfectamente adecuado.




Fig. 4.6.2.1 La configuración de la red.

Esta red aprenderá a reproducir unas series de imágenes en la rejilla de neuronas de 7×10 , con el nivel de activación de las neuronas de la rejilla determina el nivel relativo de luminosidad u oscuridad dentro del dibujo. Arbitrariamente, una activación alta dentro de una neurona de la rejilla crea un punto negro al elemento del dibujo correspondiente, y una salida baja o cero crea un punto blanco. (Esto podría ser definido fácilmente en la manera opuesta si lo prefiere).

Cada una de las neuronas de la rejilla reciben una entrada de la neurona outstar y también una entrada de alguna otra fuente externa. Esta fuente externa puede ser cualquier fuente controlable de estímulo —quizas unas series de sondas eléctricas—. Cada neurona de la rejilla puede ser

estimulada arbitrariamente y así generar cualquier nivel de actividad (oscuridad) que elija. El outstar puede ser estimulado similarmente dentro de la actividad a cualquier tiempo que queramos.

Porque esta operación de la red está conectada íntimamente con el paso del tiempo y siendo estimulada en una computadora digital y serial, debe de operar dentro de unas series de pasos de tiempo. Para esta situación, use una unidad básica de tiempo denominada *pulse* y lo incrementa paso a paso, calculando el cambio dentro de la red después de cada unidad de tiempo que halla ocurrido. Una vez que las ecuaciones de actividad y de aprendizaje sean especificadas, la red está lista para correr.

4.6.3 LAS ECUACIONES.

La ecuación de la actividad debe de parecer familiar. Cada cambio de la neurona dentro de su actividad corriente es calculado por la ecuación:

$$\frac{dy_i(t)}{dt} = \sum_{j=1}^n w_{ij}(t) [y_j(t) - T_j] \quad (4.6.3.1)$$

Esta ecuación significa que para cualquier neurona j dentro de la red, su nivel de actividad corriente es la suma de los pesos de cada entrada recibida por (y_j) menos a un valor de umbral, T_j . Para simplicidad, el tiempo de viaje entre las neuronas estimulantes y receptoras es ignorado aquí. Tal como con el outstar, sin embargo, puede compensarse para este efecto mediante el uso de $y_j(t - t_{0j})$

en lugar de $y_i(t)$, con t_0 siendo el tiempo de viaje de la neurona i hacia la neurona j . Los terminos de las entradas externas y del decaimiento de actividad también han sido omitidos por simplicidad.

Los pesos en las conexiones entre el i y el j están especificadas por w_{ij} en una manera usual —con un par de restricciones, no obstante—. Los pesos pueden ser o positivos (tendiendo a excitar a la neurona receptora) o negativos (tendiendo a inhibir a la neurona receptora). El nivel de activación, sin embargo está limitado; esto es, puede variar unicamente entre los valores de cero y de algun valor máximo de, por decir, 1.0.

Estos límites existen por una razón. Un modelo exacto de sistemas biológicos debe reflejar el hecho que el nivel de actividad corresponda a una frecuencia de disparo de una neurona dentro de un animal. En otras palabras, la fuerza de la respuesta del animal no está medida por el tamaño de su salida (la cual es aproximadamente constante en todo momento), sino mas bien por la frecuencia con la cual la neurona dispara. Las frecuencias no tienen significado, así no tiene sentido permitir a y volverse negativo. Además, cada neurona biológica tiene una frecuencia de disparo máximo fuera de la cual no puede ir. Así, el sistema biológico usa niveles de actividad positivos, y limitados; similarmente, el DRT limita a y con un valor máximo arbitrario.

La ley de aprendizaje es un poco más complejo que los otros:

$$\Delta \omega_{ij}(t) = \Delta y_j(t) \sum_{k=1}^r \beta | \omega_{ij}(t - k) | \Delta y_i(t - k) \quad (4.6.3.2)$$

Dentro de esta expresión, $\Delta \omega_{ij}$ es el cambio dentro del peso conectando la salida de la neurona i hacia la entrada de la neurona j , $\Delta y_j(t)$ es el cambio dentro de la salida de la neurona receptora, $\Delta y_i(t - k)$ es el cambio dentro de la entrada de la neurona i en los últimos k pulsos del reloj, $\omega_{ij}(t - k)$ es el peso en la conexión al tiempo de cada una de las varias señales de estímulo de entrada que llegan a la neurona i , y β es la constante de aprendizaje. El parámetro r indica que únicamente el estímulo recibido sin los últimos pulsos r es importante en este problema. La ecuación de aprendizaje ha sido cambiada en la forma de una ecuación diferencial así puede ser simulado fácilmente en una computadora.

Permitanos correr a través de cada término para ver lo que significa. Recuerde que el cambio del peso es el primero en llevar a cabo la interconexión desde la neurona i hasta la neurona j , así j es la neurona con la actividad calculada más temprano, mostrado en la fig. 4.6.3.1. El lado izquierdo de esta ley de aprendizaje indica que este es el cambio de peso en esta interconexión entre el pulso de tiempo $t - 1$ (el pulso de reloj más reciente) y el pulso t (el pulso de reloj actual).




Fig. 4.6.3.1. La neurona con la actividad calculada.

El cambio de peso entre el último peso y el peso nuevo, el peso actual es el producto de dos términos: el cambio dentro de la actividad de la neurona receptora entre el último pulso ($t - 1$) y el pulso de reloj actual (t), y la suma sobre todos los pulsos de tiempos pasados J de los cambios dentro de las entradas de los pesos desde otra neurona.

Considere lo que esta parte de la expresión implica. En el caso donde el estímulo entrante es incrementado en fuerza y al mismo tiempo la salida de la neurona receptora también sube, los cambios en ambos son positivos. Cuando β es positivo ($0 < \beta < 1$), y el valor absoluto del peso es positivo, esto significa que el peso se incrementa en valor (se vuelve más positivo si es más grande que cero, y menos negativo si es menor que cero). La neurona estimuladora,

por consiguiente, lo encuentra más fácil para excitar a la neurona receptora en el futuro.

Lo que pasaría si la actitud de la neurona receptora baja cuando el estímulo entrante se incrementa. Es que el cambio dentro de y es negativo en lugar de ser positivo, causando que el cambio de peso sea negativo, también. El peso se vuelve menos positivo (si es mas grande que cero) o más negativo (si es menor que cero); en el futuro, la neurona estimuladora lo encuentra mas difícil para excitar a la neurona receptora, pero más fácil para inhibirlo desde el disparo.

Puede analizar similarmente los casos donde la señal estimulante decrece al mismo tiempo que la salida de la neurona receptora o se incrementa o decrece. En esencia, si el estímulo se incrementa o decrece cuando la salida de la neurona receptora cambia al mismo modo, el cambio de peso total será positivo, y la señal tiene un efecto excitatorio global. Si los estímulos cambian de manera opuesta a la salida de la neurona receptora, el cambio de peso es negativo y la señal tiene un efecto global inhibitorio.

Cada contribución de los pesos es modificada mediante la constante de aprendizaje, β . Para esta discusión, todas las neuronas tienen el mismo valor de β , pero, en general, cada interconexión y cada pulso de reloj podría tener un valor diferente. Al momento, no necesita permitir tal variación, pero mantenga en mente que nada dentro de la descripción de la red le impide variar cualesquiera de las constantes

durante el entrenamiento.

El parámetro r determina cuantas entradas quedan relacionadas hacia el estado actual de la neurona; en otras palabras, cuantos pulsos previos de reloj se necesitan considerar a cada pulso.

Observe también que el valor absoluto del peso actual aparece dentro del término de suma; solo la magnitud del peso cuenta, sin preocuparse por su signo. Esta restricción está incluida porque permite al sistema modelar exactamente la curva de adquisición biológica mencionada anteriormente. Usando el valor absoluto le causa a la curva de adquisición tener una forma de S encontrada experimentalmente dentro de los sistemas biológicos.

Restringiendo el término $\Delta y_i(t - A)$ a solo aquellos valores que sean positivos, significa que solo los incrementos en las señales de entrada son importantes, es también una práctica común; si el cambio de la señal entrante es negativa, es tratado como un valor de cero, lo cual significa, claro, que solo incrementa señales que sean tomadas en cuenta; las señales estables o decrecientes son ignoradas. De nuevo, las consideraciones biológicas hacen esta restricción razonable para aplicar.

Cuando aplica todas estas restricciones, todos los elementos del término de la suma han de ser forzados a ser positivos o cero. Esta situación significa que el único modo de que el cambio de peso pueda ser negativo es si el cambio dentro de la actividad de la neurona receptora sea negativa a

si misma. Así, si la actividad de la neurona se incrementa, todos los pesos implicados se incrementan; si la actividad de la neurona decrece, todos los pesos involucrados decrecen.

Normalmente, un límite inferior es colocado en el valor absoluto de los pesos, así nunca pueden ir exactamente a cero. Puede ver fácilmente que si el peso incluso alcanza exactamente el cero, no fomenta cambios hacia aquel peso que pueda ocurrir y está efectivamente afuera de la operación de la red. El efecto global es para forzar a los pesos excitatorios quedarse siempre excitados y los pesos inhibitorios siempre queden inhibidos. Esta condición corresponde a la experiencia con sistemas biológicos dentro de los cuales una unión sináptica particular o es excitatoria o es inhibitoria, pero algunas veces no es excitatoria y ni tampoco inhibitorias.

4.6.4 BIOLÓGICO Y ARTIFICIAL

Una razón clave para revisar los sistemas de la Teoría del Reforzamiento de la Transmisión era que estos sistemas modelen fielmente el comportamiento del sistema biológico.

Las diferencias entre una implementación típica de una neurona (dentro de un silicio o dentro de una simulación de software) y una neurona biológica son ambas vitales y profundas. En primer lugar, la neurona tiene un grado de conectividad hacia sus compañeras que la tecnología actual no puede esperar igualar, incluso en simulaciones. Una neurona

típica dentro del cerebro conecta entre 10,000 y 100,000 de otras neuronas; dentro de una red nerviosa artificial, un nivel de conectividad de 100:1 es difícil de manejar.

Las neuronas biológicas también son inherentemente electroquímicas en naturaleza. Eso es, los pesos sinápticos están modelados mediante señales químicas y eléctricas, en lugar de únicamente por las señales eléctricas. Además, son completamente análogas, permitiendo un grado continuo de respuestas. Tan lejos, pocas implementaciones de redes nerviosas artificiales han tratado de duplicar la naturaleza electroquímica de los pesos, quizás algunos investigadores están trabajando en *redes análogas dentro de un chip*.

Más importante, no obstante, las neuronas biológicas operan en base de pulso de frecuencia. Eso es, no es la fuerza de la señal que transporta la información, sino la frecuencia con la cual la señal llega y, más específicamente, la frecuencia con la cual unas series de pulsos llegan. Para citar, muy pocas implementaciones de neurona han hecho cualquier intento para igualar esta versión de pulso codificado; corrientes o voltajes casi siempre son usados en hardware y las fuerzas de señal simple dentro de la simulación de software.

4.6.5 UNA SIMULACION DE FRECUENCIA CODIFICADA.

Unas pocas excepciones existen, no obstante, y una fue construida por Mark Gluck, David Parker, y Eric Reifsnider de

la Universidad de Stanford (Palo Alto, California). Estos investigadores han reformulado la DRT de esta manera que es implementada usando señales de pulso codificado en una simulación de software, en lugar del acercamiento más común de señal-fuerza.

El pulso codificado de señales analógicas ha aventajado sobre otras técnicas más sencillas, particularmente cuando opera en medios ambientes ruidosos. Un poco de ruido fácilmente confunde una simple señal analógica: Por ejemplo, no sabemos si es el valor supuesto 0.83489 o 0.90152 cuando recibimos un 0.88657, o era verdaderamente es 0.88657; no sabemos cuanto cambia el ruido a la señal. En contraste a esta casi anarquía, casi cualquier receptor de moderada resolución puede determinar exactamente si un pulso de señales ha llegado o no. Simplemente contando el número de estos pulsos dentro de un intervalo de tiempo estándar, la fuerza del pulso codificado de la señal entrante puede ser calculada con seguridad. La frecuencia de los pulsos puede estar expresada como un simple promedio de los pesos sobre el intervalo de tiempo de interés:

$$y(t) = \mu \sum_{k=1}^{\tau} x(k) e^{-\mu(t-k)} \quad (4.6.5.1)$$

Aquí, A y τ tienen el mismo significado como en la ley de aprendizaje discutido previamente, y μ es la constante de decaimiento que refleja la importancia relativa de eventos más nuevos hacia eventos más viejos (como μ es incrementado, la velocidad a la cual los eventos más viejos se vuelven

incrementos sin importancia). El término $x(t)$ es un 1 si una señal llega al instante $(t - \lambda)$, y un 0 de otro modo.

Para conseguir el promedio de tiempo de cambio de la señal con este esquema de frecuencia codificada, simplemente calcule la diferencia:

$$\Delta y(t) = \mu [x(t - \lambda) - y(t)] \quad (4.8.5.2)$$

Gluck, Parker, y Reifsnider usaron un esquema similar de frecuencia codificada para construir una simulación del sistema de Reforzamiento de Trayectoria de Klopff. Con sus simulaciones, ellos pudieron confirmar un número de características interesantes del modelo DRT. En particular, observaron que exactamente modela más si no todas las características experimentales conocidas del condicionamiento clásico, incluyen bastantes efectos isotéricos diferentes. Parece que mediante un revestimiento de un código de frecuencia-pulso biológico de señales analógicas para la DRT, llegaron a la red nerviosa que sirve como un modelo muy fuerte para el condicionamiento clásico.

Debe de venir no como una sorpresa que uno de los estímulos claves para desarrollar modelos de redes nerviosas es exactamente este corto razonamiento hacia atrás: Los investigadores toman un comportamiento experimental y prueban modelarlo con una red nerviosa artificial; luego prolongan el modelo artificial para hacerlo igual al sistema biológico más fielmente. Cuando todo está hecho, entonces tienen algo que pueden usar para probar pronosticar el comportamiento de

sistemas biológicos dentro de otras circunstancias y comprender cómo el sistema biológico está estructurado y cómo opera.

El DRT no ha sido usado en muchas aplicaciones en este momento. Para citar, ha servido más como una herramienta de investigación para ayudar a entender el condicionamiento clásico; no obstante, tiene el potencial para algunas aplicaciones interesantes. En particular, cuando el problema atañe una señal de *presagio* que sirva como una advertencia de alguna situación venidera que la red necesita responder, es difícil imaginar una red más capaz de aprender la relación entre presagio y respuesta que el sistema DRT.

Aquellos quienes quieren jugar con las existencias del mercado pueden probar una red DRT que asocie noticias de hoy (los estímulos de *presagio*) con los precios de los artículos de mañana.

4.7 RED DE RESONANCIA ADAPTIVA.

Este modelo está basado en la teoría de la resonancia adaptiva (más comunmente denominada ART, por las siglas en inglés de Adaptive Resonance Theory) desarrollado por Stephen Grossberg y Gail Carpenter. Existen diversas redes ART. Las redes ART-1, discutidas aquí, pueden procesar solo rutas de entradas binarias; pero existen otras redes ART: las redes ART-2 pueden procesar datos de entrada en escala de gris; las redes ART-3 suministran mejor estabilidad en el tratamiento con datos en escala de gris.

Aquí únicamente se considerará al sistema ART-1 el más simple, el cual acepta solo rutas de entrada binarias. Esta limitación es crucial para la operación y estructura de esta red.

El outstar puede modelar (al menos crudamente) el condicionamiento Pavloviano en animales. Dentro de esta discusión, asuma que la red ART-1 usa el aprendizaje outstar.

La red ART-1 es un buen intento para hacer un sistema de aprendizaje autónomo. Puede clasificar rutas de entrada automáticamente y retirar inmediatamente rutas bien conocidas. Automáticamente busca una ruta desconocida y, si no lo encontró, aprende aquella nueva ruta. Mediante el ajustamiento de un parámetro individual, el diseñador de la red puede forzar a la red a reconocer su clasificación de rutas dentro de las distinciones más toscas o más elegantes como sea conveniente. En muchas maneras, la red cumple los requerimientos de un sistema de aprendizaje autónomo.

Las redes ART-1 a corto plazo caen de este ideal en distintas maneras, claro. El más obvio a este punto es que puede aceptar únicamente rutas de entradas binarias. En lugar que procese datos de entrada en bruto, la red ART-1 debe de tener sus entradas cuidadosamente predirigidas en simples rutas binarias. Este problema es crucial para la red y uno debe estar considerando cuidadosamente cuando su operación sea revisada. Por el momento, permitámonos construir una de estas redes y ver como opera.

Comenzamos nuestra construcción de una red ART-1 con dos capas de nodos, completamente interconectados hacia el otro, como se muestra en la fig. 4.7.1. Cuidadosamente denominamos a los componentes de estas capas *nodos* en lugar de neuronas porque cada unidad dentro de estas capas está compuesto de una colección de neuronas que se establecen dentro de una estructura muy específica. Esta estructura, algo de lo que esotéricamente es nombrado un *dipolo* (y a la capa un *campo de dipolo cancelado*) por Grossberg, puede ser considerado como nada más un simple interruptor eléctrico. Porque la red acepta solo rutas binarias dentro de la red, las salidas de estos interruptores están obligadas a un arreglo simple de encendido-apagado.

Estos interruptores especiales tienen un número de propiedades interesantes, pero el más importante es este: Cuando el interruptor recibe una señal de entrada especial, llamada una señal de reajuste global, cualquier interruptor que esté actualmente *encendido* (generando una salida +1) se

apaga y permanece apagado por algún periodo de tiempo específico; en otras palabras, un interruptor activo es reajustado *persistentemente* a cero de acuerdo con la señal de reajuste global. Un interruptor que esté actualmente *apagado* cuando recibe la señal de reajuste global (no generando salida) no es afectado por la señal. Es crucial para la operación de esta red que el interruptor activo tenga esta propiedad de reajuste *persistentemente* hacia la salida cero al recibir la señal de reajuste global.




Fig. 4.7.1 Dos capas de nodos, completamente interconectados juntos.

Construimos dos capas de estos nodos interruptores y los interconectamos de manera que cada nodo dentro de la capa inferior está conectado a cada nodo dentro de la capa superior, y viceversa. (Cuando la sinapsis son de un solo camino, esta construcción implica dos conexiones entre cada nodo dentro de las capas, uno dirigido desde la capa inferior hacia la capa superior y uno dirigido de la capa superior

hasta la capa inferior). Las conexiones entre las dos capas tienen pesos modificables; asuma que ellos se modifican de acuerdo con el sistema de aprendizaje outstar. Todas las otras conexiones dentro de la red tienen pesos arreglados. La capa inferior actúa como la capa de entrada (a menudo designado como F1) y la capa superior como la capa de almacenamiento (F2).

La capa de almacenamiento también tiene una arquitectura de inhibición lateral. La inhibición lateral significa que una competencia de una segura regulación ocurre entre los nodos de la capa de almacenamiento, con cada nodo interruptor simultáneamente probando disparar y mantener sus nodos competidores desde el disparo. Únicamente el nodo con la respuesta más fuerte para la ruta entrante desde la capa de entrada puede generar una salida.

Supongase que aplica una ruta de entrada para los nodos dentro de la capa de entrada. Esta ruta de entrada puede ser una ruta binaria, y como resultado, la ruta de actividad producida dentro de la capa de entrada necesariamente es una copia exacta de la ruta de entrada externa aplicada (ver fig 4.7.2). Esta actividad es transmitida via las interconexiones de los pesos hacia la capa de almacenaje donde genera alguna actividad dentro de aquella capa. La ruta transmitida hasta la capa de almacenamiento es nombrada la ruta *abajo-arriba* o *perspectiva*. Debido a que la ruta *abajo-arriba* es alterada por los pesos en las interconexiones, la actividad generada dentro de la capa de

almacenamiento es completamente diferente de aquella directamente generada dentro de la capa de entrada. En realidad, porque de la arquitectura de inhibición lateral y otros sistemas confusos, esta ruta de actividad consiste de exactamente un nodo activo dentro de la capa de almacenamiento.

La ruta de actividad de la capa de almacenamiento es vuelto a transmitir hacia atrás hacia la capa de entrada sobre las conexiones de los pesos separadas de la capa de almacenamiento hacia la capa de entrada. Como antes, la ruta arriba-abajo o ensayo es alterada por su paso a través de las conexiones de los pesos, y causa alguna actividad para ser generada dentro de la capa de entrada.

Para operar la red, la capa de entrada todavía debe de estar recibiendo la ruta de entrada externa cuando la ruta arriba-abajo llega. Si la actividad generada dentro de la capa de entrada mediante la ruta arriba-abajo iguala la actividad generada por la ruta de entrada exterior, las capas son dichas a estar dentro de un estado de resonancia adaptiva. En otras palabras, son mutuamente reforzadas y han llevado a cabo una capa estable. El nodo que disparó dentro de la capa de almacenamiento corresponde a la clasificación dentro del cual esta ruta de entrada es colocada. La fig. 4.7.2 ilustra los pasos dentro de este proceso.




Fig. 4.7.2 La ruta de actividad de la capa de almacenamiento.

La red ART-1 ya ha incorporado una de las propiedades deseadas para un sistema autónomo: Si la ruta de entrada es de una clase conocida, la red inmediatamente retira la clasificación correcta. Ningún mecanismo de búsqueda es requerido para responder. Pero si la ruta de entrada es una nueva, nunca antes vista por la red, sucede algo diferente.

4.7.1 ENTABLANDO UNA BÚSQUEDA.

Suponga que la actividad generada dentro de la capa de la red para la ruta arriba-abajo no iguala aquella generada por la ruta de entrada externa. Esto significa, claro, que la ruta no era correctamente reconocida por la capa de almacenamiento. La red ahora debe de entablar una búsqueda de sus rutas almacenadas para ver si una iguala esta nueva entrada existe. Para realizar esta tarea, la red necesita de

un subsistema adicional. Este subsistema, mostrado en la fig. 4.7.1.1, es el sistema de reajuste.




Fig. 4.7.1.1 El sistema de reajuste.

El sistema de reajuste consiste, en el caso más simple, de una neurona individual. Esta neurona recibe entradas de dos lugares, de la capa de entrada y de la ruta de entrada externa. Los nodos de la capa de entrada suministran el peso arreglado, y las conexiones inhibitorias hacia la neurona de reajuste; la ruta de entrada externa tiene el peso arreglado, y conexiones excitatorias. La salida de la neurona de reajuste va hacia cada nodo dentro de la capa de almacenamiento sobre las conexiones inhibitorias del peso arreglado.

Recuerde que la ruta generada dentro de la capa de

entrada mediante la entrada externa es una copia exacta de la ruta de entrada externa. Esta condición es verdadera únicamente porque la ruta de entrada está limitada a entradas binarias. Suponga que la ruta de entrada tiene 10 nodos y de esta manera, la capa de entrada también tiene 10 nodos. Si la ruta de entrada tiene, por decir, cuatro bits de 1's y seis bits de 0's, entonces, el sistema de reajuste recibe un total de cuatro entradas excitatorias. Sin embargo, la actividad generada dentro de la capa de entrada también consiste de cuatro bits de 1's y seis bits de 0's. Como un resultado, el sistema de reajuste recibe un total de cuatro entradas inhibitorias. Su entrada a la red es cero y no hace nada. Mientras la actividad de la capa de entrada iguala aquella de la ruta de entrada externa, el sistema de reajuste no hace nada. Así, cuando las capas realizan la resonancia adaptiva, el sistema de reajuste no hace nada a todos.

Cuando las rutas de ensayo y de perspectiva no se igualan la situación es totalmente diferente. En particular (para razones explicadas posteriormente), cuando ocurre un mal emparejamiento, el número total de nodos disparando dentro de la capa de entrada siempre debe decrecer.

Asumiendo que esta declaración es verdadera, la entrada a la red hacia el sistema de reajuste puede incrementar por encima de cero en esta situación. Esto es debido a que la ruta de entrada original tiene, por decir, cuatro nodos activos dentro de cada ruta de entrada externa y de la ruta

abajo-arriba original. Con un emparejamiento malo, el número de nodos activos dentro de la capa de entrada debe de decrecer, por decir, a dos. La neurona de reajuste de esta manera ve cuatro entradas excitatorias (directamente de la ruta de entrada externa). Su entrada a la red es mayor que cero, y el sistema de reajuste dispara.

La salida del sistema de reajuste actúa como una entrada inhibitoria para todos los nodos dentro de la capa de almacenamiento. De hecho, esta entrada actúa como una señal de reajuste total hacia el interruptor dentro de esta capa. Retirar aquella señal de reajuste global apaga cualquier nodo interruptor activo y los mantiene apagados, mientras no afecte a cualquiera de los interruptores actualmente inactivos. Si el nodo tres dentro de la capa de almacenamiento era el nodo clasificado como activo, este nodo es ahora aislado del sistema de reajuste global.

El aislamiento de este nodo y mantenerlo apagado permite a algún otro nodo intentar ganar la competencia de inhibición lateral. Este nuevo ganador envía su ruta arriba-abajo hacia abajo hasta la capa de entrada en un intento por igualar la ruta de entrada. Si es exitoso, la resonancia adaptiva es lograda; si no tuvo éxito, el sistema de reajuste de nuevo dispara, aislando a este ganador y permite a un tercer nodo intentarlo. En efecto, la capa de almacenamiento busca a través de sus clasificaciones conocidas, tratar de igualar a la ruta de entrada. Una vez que la igualación ocurre, el sistema de reajuste ya no es

accionado y la resonancia adaptiva es conseguida.

Dos cuestiones aún pueden ser confusas. El primero es el grado de igualación requerida para el sistema de reajuste para permanecer apagado. La neurona reajustada tiene un parámetro de umbral que determina cuán exactamente la ruta arriba-abajo iguala la entrada exterior. Si un umbral alto es colocado, las dos rutas no se han igualado muy exactamente en todo; dos o tres bits pudieron diferir entre las dos rutas, por ejemplo, sin causar al sistema de reajuste exceder su umbral y disparar. Si un umbral bajo es puesto, las dos rutas deben de ser muy, muy similares. Un umbral de cero significa que tienen que igualarse exactamente; cualquier mal emparejamiento causa que el sistema de reajuste entable una búsqueda.

La colocación del umbral es comúnmente nombrado el parámetro de vigilancia. Una *vigilancia alta* significa que la red está muy alerta a pequeñas diferencias entre rutas y así, corresponde a un valor de umbral bajo. Una *vigilancia baja* significa que la red es relativamente insensible a diferencias más pequeñas y así, corresponde a un valor de umbral relativamente alto. En otras palabras, un valor de *vigilancia alta* implica diferencias finas entre clasificaciones; una *vigilancia baja* implica diferencias de clasificación toscas.

Un segundo problema puede ocurrir. Si la primera clasificación no iguala la ruta de entrada correctamente, porque debe cualquiera posteriormente intentar ser más

exitoso, o, porque no el primer intento habria sido el más *apropiado* de la red. Claro, esta situación seria el caso, excepto por un detalle aun no mencionado: el aprendizaje dentro de esta red está constantemente *encendida*.

Cada vez que una ruta abajo-arriba o arriba-abajo es transmitida entre las capas, los pesos sinápticos en las interconexiones convenientes se modifican levemente (usando la regla de aprendizaje outstar u otro sistema similar). De esta manera, cuando el esfuerzo de búsqueda principia, la actividad generada dentro de la capa de almacenaje mediante la ruta abajo-arriba dentro del segundo intento no es exactamente el mismo como fue antes. Los cambios dentro de los pesos entre las dos capas aseguran que esto suceda. Las modificaciones del peso también aseguran que si la ruta de entrada persiste bastante grande, tarde o temprano los pesos cambian bastante a que la igualación ocurra, incluso si la red tiene que *asumir* al nodo correspondiente hacia alguna otra clasificación.

4.7.2 CONTROL DE GANANCIA Y LA REGLA 2/3.

Una declaración más debe de ser justificado para hacer que esta red opere apropiadamente: Dentro del evento de un mal emparejamiento, la actividad total de la capa de entrada es garantizada a decrecer. Si recuerda, esta característica es esencial para la propia operación del sistema de reajuste. Para forzar la operación correcta, la red necesita una

tercera sección, nombrada el subsistema de control de ganancia, mostrada en la fig. 4.7.2.1.




Fig. 4.7.2.1 El subsistema de control de ganancia.

Dos controles separados de ganancia existen, marcados con G1 y G2 dentro de la figura. Por el momento, considere únicamente a G1. El control de ganancia G1 recibe la ruta de entrada externa tal como el sistema de reajuste hace. (Tal como con el sistema de reajuste, todas las conexiones dentro y fuera del control de ganancia son pesos arreglados y no modificables). En suma, no obstante, recibe una entrada inhibitoria desde la capa de almacenamiento. Esta inhibición es tan fuerte que cualquier actividad dentro de la capa de almacenamiento es suficiente para impedir el control de ganancia desde el disparo. La salida del control

de ganancia va hacia los nodos de la capa de entrada.

Puede ver ahora que la capa de entrada tiene tres posibles fuentes de señales de entrada: la misma ruta de entrada externa, la ruta arriba-abajo desde la capa de almacenamiento, y el sistema de control de ganancia. Ahora añado una característica más a estos nodos de la capa por insistir que los umbrales para los nodos de la capa de entrada sean colocados de tal forma que cualquiera de los dos de estas tres posibles fuentes de entrada debe estar presente para cualquier nodo de la capa de entrada a disparar. Este requerimiento es llamado la *Regla 2/3* y es el elemento crucial final para la operación de la red ART-1.

Permitamos caminar a través de la presentación de una ruta desconocida para la red para ver como trabaja la Regla 2/3 y el sistema de ganancia.

Una nueva ruta es presentada a la red. Esta ruta binaria va hacia tres lugares: la capa de entrada, el control de ganancia, y el sistema de reajuste. Como la capa de entrada está actualmente inactiva, así la ruta de entrada alcanza al sistema de reajuste, una señal de reajuste global es transmitida hacia la capa de almacenamiento, aislando cualquiera de los nodos que pasen a ser activos aquí. Esta acción prepara a la capa de almacenamiento a responder a la ruta de entrada. Mientras tanto, la ruta de entrada es probada hacia la actividad de encendido dentro de la capa de entrada. No puede actualmente encender a la capa de entrada por sí misma, cuando la ruta de entrada externa constituye

solo una de las tres fuentes de estímulos para la capa de entrada.

La ruta de entrada también va hacia el control de ganancia G_1 . Porque el sistema de reajuste ha aislado cualquier actividad dentro de la capa de almacenamiento (y por consiguiente no puede inhibitar al control de ganancia), el control de ganancia dispara y provee el segundo estímulo a la capa de entrada. La capa de entrada ahora tiene dos fuentes de estimulación y así, está libre para disparar. Porque la ruta es una ruta binaria, esta acción reproduce exactamente la ruta de entrada dentro de la capa de entrada.

La ruta de entrada está ahora activa, y su actividad va hacia dos lugares. Primero, es transmitido hacia el sistema de reajuste, donde equilibra la excitación de la ruta externa y aísla la señal de reajuste global. Segundo, se vuelve la ruta abajo-arriba presentada (a través de sinapsis levemente modificadas) a la capa de almacenamiento.

Cuando el sistema de reajuste es ahora aislado, la ruta abajo-arriba, combinado con la arquitectura de inhibición lateral competitiva de la capa de almacenamiento, resulta en el disparo de un nodo clasificador individual (la *mejor suposición*) dentro de la capa de almacenamiento. Esta señal es transmitida como la ruta de ensayo arriba-abajo hacia la capa de entrada y también es enviada a lo largo de las fuertes conexiones inhibitorias hacia el control de ganancia G_1 , el cual lo aísla.

La ruta de entrada ahora ve señales entrantes únicamente

desde dos fuentes, la ruta arriba-abajo y la ruta externa ya presente. La ruta arriba-abajo genera alguna ruta de actividad dentro de la capa de entrada. Considere un nodo que fue encendido mediante la ruta externa (con la ayuda, originalmente, del control de ganancia), pero que la ruta arriba-abajo no estimula. Este nodo recibe una señal de *dispara* de únicamente una fuente (la ruta de entrada externa). Porque de la Regla 2/3, esta situación es insuficiente para continuar disparando y aislarse.

Similarmente, un nodo que originalmente estaba apagado dentro de la ruta de entrada, pero que la ruta arriba-abajo intenta estimular, enfrentará una suerte igual: no puede encender porque solo tiene uno de los dos estímulos requeridos para aplicarlos a él. Solo aquellos nodos encendidos por ambos, la ruta de entrada y la ruta arriba-abajo, permanecerán activos. Puede ver fácilmente que esta construcción garantiza absolutamente que el número total de nodos activos dentro de la capa de entrada será menor que o igual al número de nodos activos dentro de la ruta de entrada.

Suponga que una igualación exacta no sucede. Esta condición significa que la actividad dentro de la capa de entrada decrece y que la inhibición en el sistema de reajuste también decrece. Si esta situación causa la disparidad entre la excitación de la ruta de entrada y la inhibición de la capa de entrada para exceder el umbral del sistema de reajuste, el sistema de reajuste dispara, enviando

la señal de reajuste global hacia la capa de almacenamiento. Esta reacción, claro, aísla al nodo activo dentro de la capa de almacenamiento y le impide inmediatamente intentar igualar de nuevo.

Cerrando a la capa de almacenamiento también quita la inhibición en el sistema de control de ganancia, permitiéndole actuar como el segundo estímulo para la capa de entrada y permitiendo a la capa de entrada otra vez reproducir la ruta de entrada. Este acto tiene la característica adicional de aislar al sistema de reajuste global, también. El proceso entero está ahora listo a comenzar de nuevo, excepto por dos cosas: Los pesos (ambos abajo-arriba y arriba-abajo) ahora son levemente diferentes de lo que eran antes; y el nodo clasificador específico que solo intentó igualar la ruta está impedida de intentar de nuevo debido a la persistencia característica del efecto de la señal de reajuste global. La capa de almacenamiento debe intentar una nueva clasificación. Las rutas conocidas dentro de la capa de almacenamiento serán buscadas hasta que una de las tres cosas suceda: cualquier ruta será igualada a una categoría existente, la red aprenda una nueva categoría, o la ruta de entrada externa desaparezca antes de que la ruta iguale o aprenda.

La función del control de ganancia G_2 ya no ha sido dirigido, y este artículo no dedicará mucho tiempo a ello. El control de ganancia G_2 recibe la ruta de entrada externa, tal y como el control de ganancia G_1 hace. G_2 , no obstante,

envía su salida hacia la capa de almacenamiento en lugar de a la capa de entrada. Cuando una ruta de entrada está presente, G2 envía una señal excitatoria global y pequeña hacia todos los nodos dentro de la capa de almacenamiento. Esta acción sirve para influir a la capa de almacenamiento levemente de manera que responda convenientemente a la ruta abajo-arriba. En suma, algunas implementaciones del control de ganancia G2 ayuda a moderar la competencia entre los nodos de almacenamiento. G2, en efecto, espera por uno de los nodos de almacenamiento para mostrarse a sí mismo como ligeramente más fuerte que sus compañeros; una vez que la transformación sucede, G2 asiste aquel nodo para volverse el nodo de categoría ganadora. Esto reduce el tiempo necesario para la inhibición lateral para decidir sobre un ganador.

4.7.3 APRENDIZAJE AUTONOMO.

La red ART-1 demuestra un número de características deseadas dentro de un sistema de aprendizaje autónomo. Automáticamente clasifica rutas. Por medio de ajustar el parámetro de vigilancia, puede controlar fácilmente cuán tosca o elegantemente distingue entre rutas en la ejecución de la clasificación. Si la red conoce una ruta de entrada particular, su categoría es recordada inmediatamente sin una búsqueda de la memoria; por otro lado, la búsqueda es iniciada automáticamente si la ruta no es reconocida inmediatamente.

La red ART-1 también automáticamente aprende cualquier nueva ruta importante. Un modo de distinguir ruido y datos es que el ruido es efímera y transitoria. Una red ART-1 determina que una ruta es bastante importante para aprender si la ruta esta presente bastante grande (o frecuentemente suficiente) para los pesos de la red para ser modificados convenientemente.

Un número de ciclos entre la capa de entrada y la capa de almacenamiento generalmente es requerido antes de que los pesos se ajusten de manera que una muy buena igualación ocurre para una ruta nueva. Estos ciclos toma tiempo. Si la ruta de entrada está aún presente hasta el final de este período de tiempo, entonces la ruta lo considera como *no ruido* y lo aprende como una nueva categoría de ruta. Por otro lado, si la ruta aparece solo brevemente, cualquier leve modificación de los pesos que ocurrió en aquel tiempo tiene un impacto insignificante en las rutas almacenadas de la red.

A pesar de estos éxitos, la red ART-1 tiene algunos defectos serios. Dos problemas, en particular, limitan esta utilidad de la red. El primero es que la red ART-1 puede manipular únicamente rutas de entrada binarias. Esta limitación es fundamental para la operación de la red. Porque de las rutas de entrada binarias, la actividad de la capa de entrada es una copia exacta de la entrada externa y así, exactamente equilibra la influencia de la entrada externa en el subsistema de reajuste, permitiendo al mecanismo de reajuste entero trabajar convenientemente.

Porque de las rutas de entrada binarias, la Regla 2/3 exitosamente asegura que la actividad total de la capa de entrada debe decrecer dentro del evento del mal emparejamiento, así asegura que el sistema de reajuste pueda entablar una búsqueda dentro de la capa de almacenamiento.

Esta limitación binaria es construida literalmente dentro de la estructura y operación de la red. Esto también significa, claro, que todos los datos de entrada deben de ser preprocesados para generar representaciones binarias.

Un segundo problema distinto con esta red es el método de almacenamiento; la red ART-1 invariablemente usa *células abuelas* dentro de la capa de almacenamiento. El artículo anterior brevemente mencionó a las células abuelas, el término simplemente significa que una neurona individual (o nodo, en este caso) es responsable de almacenar una ruta o categoría completa. La característica del ganador toma todo de la arquitectura de inhibición lateral usado dentro de la capa de almacenamiento demanda esta representación de ruta.

El problema con esta situación es doble. Con 10 nodos dentro de la capa de almacenamiento, la red puede solo almacenar 10 diferentes rutas dentro de la implementación de una célula abuela. Si cualquier número de nodos están permitidos a disparar (en una manera binaria) la red puede almacenar 1023 rutas con los mismos 10 nodos. Así, la capacidad de almacenamiento de una implementación de célula abuela es obligada por separado hacia el número de nodos dentro de la red.

Además, cualquiera de estos nodos que estuviera perdido debido al nodo o a la falla de la conexión, todo lo que la categoría codificó también estaría perdido. Una de las ventajas claves que las redes nerviosas tienen sobre las soluciones más tradicionales son sus fuerzas innatas, así este esquema de célula abuela descarta una ventaja importante de la red nerviosa.

Hay un problema más sutil con el uso de células abuelas para almacenar rutas. Tales representaciones son incapaces de representar conocimiento jerárquico. Como los practicantes de IA están bien conscientes, las nociones jerárquicas de *árbol*, *árbol de naranja*, y *árbol de naranja dentro de mi patio trasero* demandan variar el número de nodos para representarlos. Idealmente, la ruta para *árbol de naranja* debe contener una subruta correspondiente a la noción de *árbol*; similarmente *árbol de naranja dentro de mi patio trasero* debe contener una subruta de *árbol de naranja*, lo mismo que de *árbol*.

Con una célula abuela codificando tal conocimiento, cualquier esperanza de conservar las relaciones jerárquicas entre ellas está perdida; cualesquiera de ellas agrupan todo junto como la misma ruta, o son representados como rutas desconectadas individuales.

4.7.4 PREGUNTAS PRACTICAS.

A pesar de las molestias mencionadas previamente, las

redes ART-1 trabajan bastante bien. Una cuestión más, sin embargo, debe de ser dirigido con estas redes y son tan prácticas para aplicaciones reales. Este artículo no ha hecho intento para presentar actualmente las ecuaciones diferenciales complejas que gobiernan las relaciones entre los subsistemas de la red. Cuando estas presentaciones son implementadas dentro de una simulación únicamente de software, tanto cálculo general existe que la red es inaceptablemente lenta en cualquier corto plazo de una estación de trabajo. Esta red absolutamente demanda soporte de hardware para ser todo práctico dentro del mundo real.

El soporte de hardware puede ser presentado de dos formas. Una solución es usar unas tarjetas aceleradoras para una PC, las cuales aceleran la emulación del software sustancialmente y hacen a la red ART-1 más razonable en velocidad.

La segunda solución en hardware es usar una implementación actual de chip paralelo de la red. Al escribir esto, tales implementaciones de chip no estaban disponibles comercialmente.

Las redes ART únicamente mezclan revisiones como herramientas de aplicaciones. Las redes ART-1, y especialmente las ART-2 (redes mucho más complejas que pueden manejar rutas de entrada en escala de gris) han sido encontradas ser remilgadas y complicadas para ajustar. Dentro de algunas implementaciones de ART-2, por ejemplo, cambiando un parámetro individual de la red de 0.05 a 0.10

puede causar que la red entera falle. Mientras que las redes ART-1 son considerablemente más resistentes que ésta, ellas están limitadas severamente por sus entradas binarias.

Además, el grado de conectividad requerido por la arquitectura es extrema. Por ejemplo, no solo deben las capas de entrada y de almacenamiento estar completamente conectadas, requerimientos difíciles para las conexiones de inhibición lateral están dentro de la capa de almacenamiento. En la cima de esta situación, los sistemas de control de ganancia y el sistema de reajuste también deben conectarse a cada nodo dentro de una o ambas capas.

A pesar de estas dificultades, no obstante, las redes ART nos proveen con una visión momentánea de algunos modelos de redes sofisticadas. Estas redes tienen características no encontradas dentro de cualquier otro diseño de red nerviosa y, si es aplicado convenientemente (y cuidadosamente) puede ofrecer el potencial para algunos excelentes resultados de aplicación. Esta red debe ser considerada un sistema de *nivel de investigación* debido a su complejidad y dificultad de implementación, algún día, no obstante, ella, o una de sus descendientes, podrán mudarse de los laboratorios de investigación y estar dentro del terreno de una red de aplicación práctica.

4.7.5 APRENDIZAJE AUTÓNOMO.

El aprendizaje autónomo implica mucho más que la misma

organización de la red Kohonen. Si suponemos para un día ser capaces de crear sistemas que sean capaces de operar independientemente dentro del mundo real —si incluso esperamos construir un R2-D2 o un C3-P0— debemos suministrarles con un cierto nivel de independencia. Tales sistemas deben de ser capaces de aprender sus errores y de sus observaciones del mundo alrededor de ellos. Una breve lista de sus cualidades que necesitaremos para construir dentro de cualquier sistema autónomo incluye:

- 1.- Las funciones del sistema como una memoria asociativa autónoma; eso es, organiza su conocimiento en categorías asociadas no con ayuda de nosotros, y seguramente recupera información relacionada con señales de entrada parciales o truncadas.
- 2.- Responde rápidamente cuando solicito retirar información o reconocer alguna ruta de entrada que ya halla aprendido. Prácticamente hablando, esto significa que el sistema usa una arquitectura paralela y técnicas de búsqueda paralelas.
- 3.- Cuando debe funcionar dentro del mundo real, el sistema aprende y retira arbitrariamente rutas de entradas complejas. Además, no coloca restricciones en la forma de aquellas rutas —no ortogonalmente, separable linealmente, o cualquier otra molestia—.
- 4.- El sistema aprende constantemente, pero aprende

únicamente información significativa, y no tiene que ser explicado qué información es significativa.

- 5.- El conocimiento nuevo no cubre o destruye información que el sistema ya halla aprendido.
- 6.- Automáticamente aprende más detalle dentro de una categoría asociativa particular si la información retroalimentada indica que esto es necesario. Esta propiedad algunas veces es nombrada vigilancia. Esto significa que el sistema autónomo puede comenzar tratando alguna entrada como significativa que previamente halla sido ignorada, o viceversa.
- 7.- Reorganiza sus categorías asociativas si el nuevo conocimiento indica que los primeros presentados son ineficientes o inadecuados.
- 8.- Puede generalizar de ejemplos específicos para generalizar categorías.
- 9.- Su capacidad de almacenamiento es esencialmente ilimitado. Esto es, la capacidad de almacenamiento es mayor que el requerido sobre el tiempo de vida esperada del sistema.

Estas cualidades son difíciles para implementar, pero es difícil ver cómo cualquier sistema podía operar dentro de un medio ambiente libre sin tener al menos esta serie de propiedades. La red nerviosa no ha llevado a cabo todas ellas. Las redes de resonancia adaptiva han hecho mejor que la mayoría a conocer estas especificaciones de diseño, pero

ellas fallan lamentablemente en corto plazo en maneras diferentes, como se discutió en el artículo.

**CAPITULO 5: APLICACIONES DE LAS
REDES NERVIOSAS ARTIFICIALES.**

5. APLICACIONES.

Hace pocos años, el aprendizaje de las redes nerviosas de desplazamiento hacia adelante con capas por medio del error de retropropagación han sido aplicados para un número de problemas. No podemos discutir todos ellos, a veces aplicaciones totalmente impresionantes, aquí en detalle, pero discutiremos unos pocos ejemplos seleccionados.

5.1 PREDICCIÓN DE SERIES DE TIEMPO.

Lapades y Farber estudiaron la habilidad de las redes nerviosas de desplazamiento hacia adelante con capas para pronosticar series de tiempo, lo cual es un problema importante en Economía, Meteorología y otras muchas áreas.

5.1.1 EL MAPA LOGÍSTICO.

Lo más dificultoso en este contexto es la predicción de aquellas series de tiempo las cuales exhiben un comportamiento caótico, por ejemplo, para los cuales un cambio infinitesimal en el valor inicial resulta en un crecimiento exponencial, desviaciones dramáticas de valores en el futuro. Relaciones funcionales simples remarcablemente pueden mostrar una carencia completa de predictibilidad en largo plazo, por ejemplo, el tan nombrado *mapa logístico*:

$$x(t+1) = F[x(t)] \quad \text{con } F[x] = 4x(1-x), \quad 0 \leq x \leq 1 \quad (5.1.1.1)$$

Para una red nerviosa una predicción de $x(t+1)$ de $x(t)$

se vuelve simplemente la tarea de aprender a representar la función cuadrática $\mathcal{F}(x)$. Claro, la red no *conoce* que la función es tan simple, tiene que *descubrir* en sí misma en la base de los datos enseñados disponibles $(x^\mu, \mathcal{F}(x^\mu))$, $\mu = 1, \dots, n$.

Lapedes y Farber usaron una red nerviosa de desplazamiento hacia adelante consistente de una neurona de entrada y una de salida, y una única capa con cinco neuronas ocultas. Había también una conexión sináptica directa entre las capas de entrada y de salida. Con error de retropropagación esta red fue tomada con una respuesta de 1,000 pares. La función de actividad de las unidades ocultas fue la función de Fermi:

$$K(A) = (e^{2A} + 1)^{-1} = \frac{1}{2} (1 + \tanh(A)) \quad (5.1.1.2)$$

la neurona de salida tuvo respuesta lineal. La ejecución de la red fue luego probada con 500 puntos $x(t)$ adicionales elegidos arbitrariamente, donde la red debía predecir el correcto $x(t+1)$. La red encontraba la ejecución muy bien de esta tarea, con una desviación cuadrada promedio entre la predicción y el valor correcto de 1.4×10^{-6} . Un análisis de las conexiones sinápticas, revela que la función (5.1.1.1) fue representada en la forma:

$$\begin{aligned} \mathcal{F}(x) = & -0.64K(-1.11x - 0.26) - 1.3K(2.22x - 1.71) \\ & - 2.285K(3.91x + 4.82) - 3.905K(2.46x - 3.06) \\ & + 5.99K(1.68x + 0.60) + 0.31x - 2.04 \quad (5.1.1.3) \end{aligned}$$

Como mostramos en la Fig. 5.1.1.1, esto provee una muy buena representación de la función parabólica (5.1.1.1)

dentro del intervalo $0 \leq x \leq 1$.




Fig. 5.1.1.1 Representación de la función del mapa logística $F(x)$ ("línea punteada") mediante una superposición de funciones de Fermi ("línea sólida").

5.1.2 UNA ECUACION DIFERENCIAL RETARDADA NO LINEAL

Una prueba más demandante de la habilidad profética está provista por las series de tiempo generadas por la ecuación diferencial retardada, no lineal

$$\frac{dx}{dt} = \frac{ax(t - \tau)}{1 + [x(t - \tau)]^{10}} - \delta x(t) \quad (5.1.2.1)$$

con $a = 1/5$ y $\delta = 1/10$, lo cual fue investigado primero por Mackey y Glass. Lapedes y Farber estudiaron (5.1.2.1) para los parámetros de retardo $\tau = 17$ y $\tau = 30$, para los cuales las series de tiempo $x(t + n\Delta)$ con una longitud de paso arreglado $\Delta = 6$ exhibe un comportamiento caótico. Para representar la ecuación de Mackey-Glass es una red nerviosa, ellos eligieron una arquitectura de red como la ilustrada en la Fig. 5.1.2.1 con cuatro neuronas de entrada, dos estratos ocultos de diez neuronas cada uno, y una única neurona de

salida, representando el valor de $x(t + \mathcal{P})$, donde \mathcal{P} era un múltiplo de Δ .




Fig. 5.1.2.1 Arquitectura de red empleada para pronosticar la ecuación (5.1.2.1) de Mackey-Glass.

Hay dos métodos de obtener predicciones para diferentes valores de $\mathcal{P} = n\Delta$ con $n > 1$ (ver Fig. 5.1.2.2). En el primer método (D), uno actualmente le enseña a la red para el valor específico \mathcal{P} , así que la fuerza sináptica depende del valor elegido. En el segundo método (E), la red está capacitada para predecir el valor $\mathcal{P} = \Delta$, y la predicción es iterada n veces para producir un estimado para el valor a $\mathcal{P} = n\Delta$. La última es, claro, la más severa prueba de la habilidad de la red para predecir las series de tiempo generadas por la ecuación de Mackey-Glass, porque los errores de cada paso de iteración empieza en el próximo, causando el peligro de magnificación de error¹⁰.

¹⁰ Porque de la naturaleza caótica de las series de tiempo, este segundo método está obligado a fallar para valores grandes de "n", sin embargo la buena calidad profética puede ser.

La habilidad profética de la red nerviosa de desplazamiento hacia adelante capacitada por error de retropropagación es comparada en la Fig. 5.1.2.2 con que obtuvo por tres métodos comúnmente usados de la predicción de series de tiempo, el *método profético lineal* (B), y el método de predicción polinomial de Gabor para polinomios de sexto orden con predicción directa (C) o iterada (A). Obviamente la red provee con mucho la más segura predicción de las series de tiempo (curvas D y E), y de modo sorprendente el método de iteración (curva E) trabaja mejor. De algún modo la red debe ser capaz de capturar la esencia del mapeo descrito por la ecuación Mackey-Glass, con tan pocos como 500 puntos de las series de tiempo usados para entrenar la red.

El recientemente desarrollado *método lineal local* de Farmer y Sidorowich pronostica las series de tiempo aproximadamente con comparable precisión. Este método requiere mucho menos tiempo para la adaptación de parámetros que son necesarios para entrenar a la red nerviosa (la cual tomó aproximadamente una hora de tiempo de CPU en un CRAY X-MP), pero la predicción debe estar basado en muchos más puntos de las series de tiempo (más de 10^4). Esta es una clara desventaja en el caso de las series de tiempo empíricas, donde la cantidad de datos conocidos son frecuentemente más bien limitados.




Fig. 5.1.2.2 Error de prediccion normalizado de las series de tiempo de Mackey-Glass para varias predicciones de tiempo P (para $r = 30$). La red nerviosa (curvas D y E) realizan mejor que los metodos de pronostico estandares (curvas A - C).

5.1.3 PREDICCIÓN NO LINEAL DE LAS SERIES DE TIEMPO RUIDOSAS.

La predicción de valores futuros dentro de unas series de tiempo generados por una combinación de procesos determinísticos y estocásticos es frecuentemente difícil o completamente, cuando no es fácil distinguir entre ruido real e irregularidades aparentes los cuales son el resultado de comportamiento determinístico o caótico del mapeo fundamental. El método estándar es aquella de predicción lineal, donde una función lineal es ajustada para los valores pasados conocidos de las series de tiempo por medio de convenientes cuadrados pequeños. Este método a menudo no produce una buena potencia profética si el mapeo fundamental es fuertemente no lineal. Desafortunadamente, la construcción del método de predicción no lineal óptima requiere un conocimiento a priori de las propiedades de mapeo determinístico fundamental, lo cual no está disponible en muchos casos de interés práctico.

H. Reininger ha estudiado la habilidad de las redes nerviosas simples con capas para generar pronosticadores casi no lineales óptimos de series de tiempo ruidosas. El número de neuronas de entrada N_i correspondió al número de puntos de datos en las cuales la predicción individual estaba basada (el orden de la predicción); solo $N_i = 1, 2$ fueron considerados. El número de neuronas ocultas N_h fue elegido razonablemente pequeño. Algunas de las series de tiempo consideradas fueron:

- (1) $x(t) = n(t) + 0.9x(t-1)$
 (2) $x(t) = n(t) + 0.21x(t-1)^2$
 (3) $x(t) = n(t) + 3 \tanh[x(t-1)]$
 (4) $x(t) = n(t) + 3 \tanh[x(t-1)] + 3 \sin[x(t-2)]$ (5.1.3.1)

donde $n(t)$ es una variable estocástica de distribución normal (aquí se toman con varianzas $\langle n(t)^2 \rangle = 1$). Una medida de la calidad de la predicción es provista por la tan llamada ganancia profética \mathcal{G} , la cual está definida como¹⁴

$$\mathcal{G} = 10 \log \frac{\langle x(t)^2 \rangle}{\langle [x(t) - \bar{x}(t)]^2 \rangle} \quad (5.1.3.2)$$

donde $\bar{x}(t)$ es la predicción para $x(t)$ y los paréntesis indican un promedio sobre muchas predicciones. La desviación más pequeña entre el valor afirmado $\bar{x}(t)$ y el actual valor $x(t)$, el más alto es la ganancia profética. Cuando la parte estocástica $n(t)$ no puede ser pronosticada por cualquier método, la ganancia más grande posible está dada por

$$\mathcal{G}_{opt} = 10 \log \frac{\langle x(t)^2 \rangle}{\langle n(t)^2 \rangle} \quad (5.1.3.3)$$

Los resultados del estudio, en el cual la red fue entrenada con series de datos de 2,000 elementos con el algoritmo del error de retropropagación, son mostrados en la siguiente tabla:

Series	N_t	N_h	\mathcal{G}_{opt}	\mathcal{G}_{net}	\mathcal{G}_{lin}
1	1	1	8.12	6.02	6.12
2	1	2	0.63	0.63	0.05
3	1	1	9.55	9.55	6.80
4	2	8	11.64	9.03	2.92

¹⁴ La ganancia es aquí definida en unidades de dB (decibel).

La columna etiquetada G_{net} muestra la ganancia producida por la red nerviosa con capas; aquella etiquetada por G_{lin} indica la ganancia llevada a cabo por el método de predicción lineal estándar. Excepto para las primeras series, las cuales están basadas en unas series de tiempo lineal, la red viaja considerablemente mejor: en algunos casos incluso proveen predicción óptima.

5.2 APRENDIENDO A JUGAR BACKGAMMON.

Un divertido método de estudiar la habilidad de las redes nerviosas para adquirir alguna forma de *inteligencia* es enseñarlas a jugar juegos competitivos, tal como el backgammon. El éxito en jugar backgammon, en comparación con juegos determinísticos como el ajedrez, implica una combinación de destreza y suerte, y ninguna estrategia preconcebida puede ser perfecta. Otra característica relacionada que hace al backgammon bien conveniente para una red nerviosa es que los movimientos son seleccionados más en la base de juicios basados en la posición implicando el reconocimiento de ruta, que en mirar el porvenir, cálculos de búsqueda-árbol, los cuales no son muy útiles reconociendo el elemento probabilístico introducido por los dados.

El concepto seguido por Tesauro y Sejnowski era entrenar a la red para *seleccionar* movimientos (fuera de una serie de movimientos predeterminados permitidos), más bien que *generarlos*, así evita las dificultades asociadas con enseñar

las complejidades de la legalidad del movimiento. Equipado con un *preprocesador* que generaba los movimientos legales, la red era entrenada para conseguir todos los movimientos alternativos en un nivel relativo, los resultados recorriendo desde -100 (el peor movimiento posible) hasta +100 (el mejor movimiento posible). La posición y su cambio causado por el movimiento fueron codificados por 459 neuronas de entrada (18 cada una para las 24 localidades del tablero básicas, así como algunas neuronas para la barras blancas y negra)¹². Varias arquitecturas de redes fueron probadas; la red de mejor ejecución tuvo dos capas ocultas de neuronas con 24 elementos cada una. Sin embargo, las diferencias en ejecución, cuando pocas o incluso ninguna neurona oculta eran empleadas, no fue muy grande. La red siempre tuvo una neurona de salida representando el resultado.

La base de datos para entrenar contenía ligeramente más de 3,000 posiciones del tablero (fuera de un total estimado de aproximadamente 10^{20}), unas dadas particulares hacen rodar para cada posición, y una serie de movimientos legales. Una pequeña subserie de estos movimientos han sido conseguidos por un experto humano; para la parte más grande de los movimientos, sin embargo, un resultado fue elegido al

¹² En resumen, unas pocas neuronas de entrada fueron usadas para la representación de algunas características precalculadas de la posición que son útiles para la evaluación. Este procedimiento, equivale a dar a la red útiles "pistas", enormemente ayudado en producir una red capaz de jugar adecuadamente.

azar con una tendencia ligeramente negativa (del intervalo $(-85, +35)$). Esta técnica un poco insatisfactoria tuvo que ser introducida en vista del gran número de movimientos posibles. La tendencia negativa fue introducida para explicar la tendencia del experto para seleccionar buenos movimientos para el resultado. La red fue primeramente entrenada en los movimientos conseguidos explícitamente, pero también fue expuesta a los movimientos conseguidos aleatoriamente para evitar una tendencia exagerada en la serie de entrenamiento.

La ejecución de la red entrenada fue medida de varios modos, siendo lo más interesante su juego contra el programa de software comercial *Gammontool*. En su mejor configuración la red derrotó a *Gammontool* en casi 80% de sus combinaciones, lo cual constituye una hazaña bastante impresionante. La inclusión de las características precalculadas en el código de entrada demostró ser esencial: sin éstos la red podía producir un promedio ganador de únicamente 40%. Una buena ejecución (de promedio ganador de 54%) también fue lograda si las características precalculadas eran sustituidas por los términos individuales de la función de evaluación del movimiento de la posición usada en el programa *Gammontool*. Obviamente, la red era capaz de combinar éstos exitosamente dentro de una función de resultado, el cual fue superior a aquél desarrollado por los programadores humanos de software. Esta habilidad puede indicar otras aplicaciones útiles en casos similares, sustituyendo con cuidado a mano la puesta a

punto de prueba-y-error.

Finalmente, la red fue enfrentada contra un experto humano en backgammon (uno de sus creadores, G. Tesauro), en una serie de 20 juegos. Extraordinariamente, la red ganó 11:9. Sin embargo, el oponente humano afirmó después en base de los análisis detallados que este éxito sorprendente era facilitado por pura suerte en hacer rodar los dados, cuando la red cometió serios errores en nueve de los juegos, de los cuales todavía llevó a ganar cinco reconociendo los lanzamientos favorables de los dados. El análisis de estos juegos también exhibieron que la red había adquirido un *entendimiento* de muchos conceptos globales y estrategias así como elementos tácticos importantes de juego avanzado de backgammon. Los errores cometidos eran, a menos en la mayoría de los casos, errores no aleatorios pero en su lugar cae dentro de categorías bien definidas, las cuales imaginablemente podían ser eliminadas por sumar casos apropiados para la puesta de entrenamiento.

5.3 PREDICCIÓN DE LA ESTRUCTURA SECUNDARIA DE LAS PROTEINAS.

H. Bohr y colaboradores entrenaron a una red nerviosa para pronosticar la tan llamada estructura secundaria de

proteínas¹³ de sus secuencias locales de aminoácidos con una precisión aproximada del 70%. Esta tarea difiere de los anteriores en que la solución no es conocida en principio. El tradicional planteamiento, el cual implica la consideración de las varias fuerzas entre residuos de aminoácidos y de sus interacciones con el agente solucionador, únicamente permite la predicción correcta de la estructura secundaria en aproximadamente la mitad de todos los casos como promedio. Uno por consiguiente tiene que confiar aquí en la habilidad de la red para extraer de la serie de datos entrenados relaciones funcionales que hallan escapado a lo lejos de la inteligencia humana. Como los resultados han mostrado, este acercamiento práctico —originalmente sugerido por Qian y Sejnowski— es sorprendentemente exitoso pese a su carencia de transparencia física.

La red empleada por Bohr y otros recibieron como entrada el código del aminoácido de una cierta fracción de la proteína; un tamaño de ventana de 51 aminoácidos consecutivos abastecidos para ser la elección exitosa¹⁴. Los 20 diferentes

¹³ Uno distingue tres niveles de estructuras proteínicas: la estructura "primaria" describe la secuencia de aminoácidos, la estructura "secundaria" determina la forma química-estereoscópica local de la cadena del aminoácido (por ejemplo: la hélice α , la capa β , la vuelta β , o espiral aleatorio), mientras que la estructura "terciaria" describe como las macromoléculas enteras son liquidadas en el espacio.

¹⁴ Los tamaños de ventanas entre 7 y 51 fueron probados, con 51 dando los mejores resultados. Esta longitud de

tipos de aminoácidos fueron codificados con una secuencia de 19 ceros y un único 1, representado por 19 neuronas de entrada inactivas y una activa. El glicina, por ejemplo, fue codificado como 00000010000000000000, la alanina como 0000000000000000001000, etc. La longitud de ventana elegida por consiguiente requirió $51 \times 20 = 1,020$ neuronas de entrada. La entrada era luego procesada por una capa de 40 neuronas ocultas, mientras la capa de salida consistió solo de dos neuronas, las cuales indicaban la presencia o la ausencia de un cierto tipo de estructura secundaria. Las redes nerviosas separadas eran entrenadas para detectar o la hélice α , o la capa β , o el espiral aleatorio. El número total de sinapsis y umbrales sumaron aproximadamente 40,000.

Para entrenar a la red, los autores eligieron 56 proteínas (consistente de un total de aproximadamente 10,000 aminoácidos) del Banco de Datos de Proteínas Brookhaven. El entrenamiento era realizado en una subserie consistente de n de estas proteínas, las cuales eran extendidas en pasos de ocho hasta la serie de entrenamiento contenidas todas las 56 proteínas. Durante este proceso las proteínas restantes ($56 - n$) fueron usadas para monitorear la ejecución de la red dentro del pronóstico de la presencia de la categoría específica de la estructura secundaria dentro de las

ventana mas o menos corresponde a la cadena de enlaces de hidrogeno entre los residuos de aminoácido en la estructura de capa β .

proteínas desconocidas. El resultado de este proceso están mostrados en la Fig. 5.3.1 para la red asignada para detectar la presencia de la estructura hélice α . Después de la conclusión del entrenamiento, consiguió aproximadamente 73%.




Fig. 5.3.1 Porcentaje de predicciones correctas de la presencia de una estructura α hélice contra el número de proteínas en la serie de entrenamiento.

La habilidad de la red para predecir la estructura secundaria fue luego comparada con aquella de los algoritmos convencionales en la proteína *rodopsina*, la cual juega un papel en la fotosíntesis bacteriana. La habilidad de la red para detectar la presencia de una estructura de hélice α fue claramente superior al método más tradicional, como se muestra en la Fig. 5.3.2. La red actualmente confirmó que el electrón microscópico más viejo trabaja en la estructura secundaria del rodopsina, cuya validez ha sido cuestionada por estudios más recientes utilizando otras técnicas.




Fig. 5.3.2 Actividad en la señal de la neurona de salida de la estructura α helice' contra el numero de aminoacidos' dentro de la rodopsina. "Histograma": red nerviosa. "Curva superior": metodo convencional ; alterado hacia arriba por 0.9).

5.4 NET-Talk: APRENDIENDO A PRONUNCIAR TEXTO EN INGLES.

Uno de los campos más promisorios de aplicación de redes nerviosas es el reconocimiento del habla. Una razón es que la representación del lenguaje por señales acústicas del habla no siguen reglas simples, y así la conversación es difícil para implementar dentro de computadoras electrónicas programables. La ventaja de las arquitecturas de redes nerviosas es que ellas pueden ser hechas para aprender la representación simple de ejemplos de lenguaje hablado sin conocimiento de reglas fundamentales. No es problema si el proceso de entrenamiento toma mucho tiempo, porque necesita ser hecho solo una vez. Una vez que la representación ha sido aprendida, el procedimiento de la señal del habla sería rápido a causa de la arquitectura paralela de la red.

El reconocimiento versátil del habla es uno de los

descubrimientos más grandes para los investigadores de redes nerviosas¹⁵. Un ejemplo es la pronunciación de texto escrito. Para aquel propósito, Sejnowski y Rosenberg entrenaron una red nerviosa de desplazamiento hacia adelante multicapa para distinguir grupos de letras en palabras en Inglés asociadas con fenómenos individuales. Estos podían ser luego convertidos en lenguaje hablado real mediante un generador de habla comercial, así que el texto era leído en voz alta.

La red miró una secuencia de texto de siete letras a la vez, por consiguiente contuvo siete grupos de 29 neuronas de entrada que cada una codificaba una letra de la fracción de texto, para lo cual el valor fonético era determinado. Había una capa de 80 neuronas ocultas, y las 28 neuronas dentro de la capa de salida representaron los varios valores posibles fonéticos, tal como posición en la boca (labial, glótico, etc.), el tipo de fonema (sonora, nasal, etc.), frecuencia vocálica, y puntuación. La red era entrenada para asociar un valor fonético con un cierto grupo de letras por los ejemplos provistos por 1024 palabras del lenguaje Inglés. Después de 50 ciclos de entrenamiento la red ha alcanzado una precisión de aproximadamente el 95% para las palabras contenidas dentro de la serie de entrenamiento. En una prueba de su habilidad para generalizar, la red entonces era capaz de pronunciar

¹⁵ El progreso totalmente impresionante recientemente ha sido hecho usando redes con arquitectura modular e incorporando con retardos de tiempos entrenados por error de retropropagación.

correctamente el nuevo texto con una exactitud de alrededor del 80%. En vista de la complejidad de la relación entre el valor fonético y el deletreo en el lenguaje Inglés, esto es una realización completamente extraordinaria. Sin embargo, en comparación con programas de software diseñados para convertir texto Inglés en fonemas basados en reglas derivadas de investigación lingüística todavía la red nerviosa más bien ejecuta mal. Es hermoso decir que el diseño del NET-Talk tomó únicamente una fracción de esfuerzo lo cual fue gracias al desarrollo de programas comerciales de conversión de texto-a-habla ya existentes.

La red resuelve esta tarea usando una versión reducida a escala de la red NET-Talk, un intento ha sido hecho para analizar el paso en el cual las neuronas ocultas contribuyen al reconocimiento de los fonemas, mirando el producto de la activación de una neurona oculta y su fuerza de conexión sináptica hacia la neurona de salida representando el fonema reconocido, por ejemplo, su contribución a la activación de esta neurona de salida. Este análisis de contribución revela, por ejemplo, que algunas neuronas ocultas no eran relevantes para el reconocimiento de cualquier fonema, y así podía ser eliminadas de la red sin pérdida de la ejecución. Sin embargo, muchos detalles de cómo la red implementa la representación fonética quedan aun mal entendidos.

5.5 OTRAS APLICACIONES.

Las redes nerviosas de desplazamiento hacia adelante con capas han sido aplicadas a una gran variedad de otras tareas, con éxitos variables. En comparación con la representación de mapeos matemáticos, donde la existencia de teoremas generales han sido probados, poco conocido es cuando una red perceptrón con neuronas ocultas tendrá éxito con una tarea práctica específica. En particular, esto es verdadero cuando la solución no formal del problema es conocido y la red está supuesta a descubrir la complejidad de la solución en sí misma. Después de todo, las redes nerviosas del grado bajo de complejidad discutido aquí seguramente *no* son más inteligentes que los seres humanos.

A continuación se enlistan las aplicaciones más prácticas en las siguientes referencias:

- 1.- *Separación de sílabas con guiones.* Dentro de otra aplicación lingüística, una red fue entrenada para pronosticar la separación de sílabas con guiones de la elección de palabras aleatoriamente largas, las cuales eran presentadas a través de una ventana de seis letras. La capa de entrada consistió de 26 neuronas para cada una de las seis letras, una para cada letra en el alfabeto. La capa oculta contenía 20 neuronas, y una única neurona de salida que señalaba si la separación de sílabas con guiones es posible en el centro de la ventana de seis letras. Después de entrenar la red con 17228 palabras, la

separación de sílabas con guiones era pronosticado correctamente con aproximadamente 99% de precisión.

2. - *Energías de enlaces nucleares.* La energía de enlace E de núcleo atómico es una función de sus protones y neutrones, cuyos números son Z y N respectivamente. Cuando una función es casi lineal sobre una distancia ancha, es más significativo predecir la energía de separación del último neutrón: $f(Z, N) = E(Z, N) - E(Z, N - 1)$. Un perceptrón de tres capas con 60 neuronas en cada capa (la representación de los números Z , N y f fueron poco artificiales) era entrenado para modelar la función $f(Z, N)$, usando valores de aproximadamente 1.000 isótopos nucleares. La red era luego capaz de pronosticar la energía a menos de 3% para cercas del 60% de otros núcleos; pero fallaron algo mal en 20% del núcleo que no ha sido visto en la fase de entrenamiento.

3. - *Orientación de la fundición.* El montaje de circuitos electrónicos requiere la determinación de la correcta orientación de sus componentes, los cuales pueden ser llevado a cabo mediante la detección de la orientación del texto impreso en ellos. Una red nerviosa de cuatro capas fue construido para detectar si los símbolos (letras y números) en el texto eran orientados correctamente o al revés. La red no era entrenada por

retropropagación, sino que fue alambrada difícilmente.

- 4.- *Robótica.* El control de trayectorias de los manipuladores robóticos operando en plantas de producción o bajo medios ambientes hostiles es una tarea para la cual las redes nerviosas parecen estar bien adaptadas. Un ejemplo es el modelo CMAC (Cerebellar Model Articulation Controller, Controlador de Articulación del Modelo Cerebral), la cual está basado en un análisis del cerebelo, por ejemplo aquella parte del cerebro de los vertebrados la cual controla los movimientos del cuerpo y mantiene el equilibrio estático. El CMAC es una red de desplazamiento hacia adelante la cual puede ser entrenada por aprendizaje supervisado para generar un mapeo no lineal complejo de un espacio de señales de entrada, las cuales incluyen la posición y orientación actuales de los miembros y articulaciones, para una serie de señales de salida, las cuales manejan actuadores robóticos.
- Una tarea demandante será la construcción de robots autónomos los cuales interpreten sus medios ambientes desde datos visuales y otros sensoriales y respondan en tiempo real con las reacciones correctas del control del motor, por ejemplo evitando colisiones con objetos los cuales obstruyan sus trayectorias.

5.- *Citodiagnóstico.* Las redes nerviosas pueden clasificar trayectorias incluso en casos donde es dificultoso formular reglas simples para distinguir las categorías deseadas. Esta habilidad ha conducido hacia una aplicación de recompensa potencialmente dentro de los diagnósticos médicos. El método de citodiagnóstico desarrollado por G. N. Papanicolaou en el año de 1920 permite la detección de ciertos tipos de cáncer en una etapa muy temprana por medio de la proyección microscópica de la mucosidad para células malignas. Expertos humanos son capaces de reconocer y clasificar tales células anormales, pero es deseable automatizar el procedimiento de proyección. Un portaobjeto microscópico de una prueba *Papomear* para el cáncer cervical contiene típicamente 100,000 células, solo unas cuantas de las cuales pueden ser anormales. La fatiga del experto humano puede conducir hacia el peligro de una estimación negativa falsamente. El sistema PAPNET recientemente introducido por la Neuromedical Systems Inc. emplea una red nerviosa para buscar automáticamente células anormales. Imágenes digitalizadas de células extrañas identificadas por un sistema de clasificación convencional son presentadas a una red nerviosa que ha sido entrenada para reconocer las formas de células malignas. En este paso para cada

portaobjeto microscópico una colección de los casos más sospechosos son montados para inspección por medio de un Patólogo quien tiene la última palabra. Aparentemente en este método el peligro de reportes de prueba negativamente falsas es virtualmente eliminado.

6.- *Aplicaciones comerciales.* Estos incluyen objetos tan diversos como la predicción de existencias y precios de artículos, verificación de firma de cheques bancarios, y la estimación de riesgo en préstamo de aseguradoras.

7.- *Manejo de vehículos.* En otra aplicación, un vehículo sin operador tiene como sistema visual una red neuronal que ve a través de una cámara de video y mide distancias con un buscador por rayo láser, y sus actuadores son mecanismos acoplados a la dirección del vehículo. El método de aprendizaje fue una variación del método de retropropagación y los ejemplos los proporcionó un simulador de caminos. Una vez que la red aprende, el vehículo es capaz de navegar sin piloto por cualquier camino desconocido.

8.- *Lectura de manuscrito japonés.* Con una red neuronal muy compleja, Fukushima ha logrado construir un sistema capaz de leer un manuscrito japonés. La red es insensible a traslaciones y rotaciones en los caracteres, así como a caracteres borrosos o

incompletos. En esta aplicación la red lee por medio de una cámara y envía los datos al almacenamiento de una computadora.

- 9.- *Optimización.* Hay otras aplicaciones en las que la red neuronal no está comunicada con sensores y actuadores como los de los ejemplos anteriores. Haciendo una analogía biológica, o más bien psicológica, podríamos decir que la red se comunica de manera introspectiva con bases de datos o conocimientos, y luego actúa tomando decisiones que no se traducen en un movimiento físico sino económico o administrativo. Un ejemplo de esto es la solución de problemas de optimización en los cuales existen muchas soluciones posibles y algunas pueden ser tan buenas como otras. Es usual que estos problemas tengan una estructura distribuida, y es conveniente proponer métodos de solución con estructuras semejantes. Una red neuronal es un candidato idóneo por su arquitectura distribuida y funcionamiento en paralelo. Hopfield demostró que las redes neuronales que llevan su nombre pueden resolver el problema del vendedor viajero tan bien como los métodos de investigación de operaciones.

Existen bastantes aplicaciones de las redes neuronales en la ciencia, la tecnología, la industria y los servicios. No es posible reseñar aquí más ejemplos, pero es importante

hacer notar que muchos problemas que se han mencionado se pueden resolver con otros métodos.

Debe recordarse que muchos problemas científicos, ingenieriles y administrativos pueden resolverse por métodos bayesianos, por lógica difusa, por investigación de operaciones, o con un sistema experto. Sin embargo, ni estos métodos ni las computadoras convencionales son capaces de detectar y reconocer patrones visuales, auditivos, táctiles, etc., con los procedimientos con que los humanos y los animales lo hacen. Además, somos capaces de hacerlo en condiciones adversas e inciertas y podemos llegar a una buena decisión, aunque también podemos equivocarnos. Una red neuronal llega a una decisión con base en su funcionamiento colectivo. Esta conducta emerge de la dinámica distribuida de las conexiones, de la adaptación de los pesos y no de la decisión de un procesador privilegiado. Al estar basada en el funcionamiento de las neuronas biológicas, la red neuronal artificial también puede equivocarse, pero todavía no sabemos si cometer errores es uno de los lubricantes que mantiene funcionando la evolución humana.

En resumen, se ha consolidado la idea de imitar en las computadoras la manera en que funcionan los cerebros biológicos, pero hace falta mucha investigación básica sobre su funcionamiento, sobre todo acerca de las redes neuronales biológicas, pues ya es un lugar común la aceptación de que las neuronas se organizan en módulos en los cuales hay conexiones intramodulares así como intermodulares, aunque

nadie ha logrado hacer registros electrofisiológicos consistentes de más de 50 neuronas y en los que se demuestre de qué manera se reorganiza la conectividad cuando cambian las tareas sensoriales del animal en el que se experimenta. Es también muy importante investigar las relaciones que puedan existir entre la intensidad sináptica y la plasticidad de la sinapsis en las redes neuronales biológicas con la dinámica colectiva de los pesos y el aprendizaje en una red neuronal artificial.

Para concluir, podemos afirmar que en un futuro las redes neuronales artificiales abrirán el camino para que las computadoras de la sexta generación posean capacidades cognoscitivas como la memoria asociativa, y los robots sean flexibles con capacidades sensoriales parecidas a los de los seres vivos.

BIBLIOGRAFIA

- Anderson, J. A., and Rosenfeld, E.; *"Neurocomputing: Foundations of Research"*; Cambridge, Mass.; MIT. Press, 1988.
- Anderson, J. A.; Pellionisz, and Rosenfeld, E.; *"Neurocomputing 2: Directions for Research"*; Cambridge, Mass.; MIT, Press, 1990.
- Beale, Russell and Finlay, Janet; *"Neural networks and pattern recognition in human computer interaction"*; Edit.: Ellis Horwood Limited; USA; 1992; pp.: 460
- Callatay, Armand M. de; *"Natural and artificial intelligence: misconceptions about brains and neural networks"*; Amsterdam, Holanda; pp.: 560.
- Carpenter, Gail; and Grossberg, Stephen; *"Neural Networks for Vision and Image Processing"*; Edit.: MIT Press; Cambridge, Massachusetts, London, England, 1992; pp: 467.
- Castrillón, Laura Viana; *"Memoria Natural Y Artificial"*; La Ciencia desde México; Vol. 88; SEP-FCE-CONACYT; Junio de 1990; México, D.F.; pp. 153.
- Caudill, M; and Butler C.; *"Naturally Intelligent Systems"*; Cambridge, Mass.; MIT, Press, 1990.
- Codenotti, Bruno; and Leoncini, Mauro; *"Introduction to Parallel Processing"*; International Computer Science Series; Edit.: Addison-Wesley; 1993; USA; pp.: 272.

- Freeman, James A.; and Skapura, David M.; *"Neural networks: Algorithms, Applications, and Programming Techniques"*; Computation and Neural Systems Series; Series editor: Christof Koch; Edit.: Addison-Wesley Publishing Company; USA, 1992; V-X; pp: 401.
- Haken, H.; *"Synergetic computers and cognition. A Top-Down Approach to Neural Nets"*; Edit.: Springer-Verlag; USA; 1991; pp.: 225.
- Herch-Nielsen, R.; *"Neurocomputing"*; Mass; Addison-Wesley; 1990; pp: 433.
- Holden, Arun V. and Kryukov, Vitaly I.; *"Neurocomputers and attention II: neurobiology, synchronisation and chaos"*; Proceedings in nonlinear Science; Edit.: Manchester University Press; USA; 1991; pp.: 786
- Hulme, E. C.; *"Receptor biochemistry: a practical approach"*; The practical Approach Series; Edit.: IRL Press; USA 1990; r-xxr; pp.: 328.
- Khanna, Tarun; *"Foundations of neural networks"*; Edit.: Addison-Wesley, Publishing Company; USA; 1990; r-xrr; pp.: 196.
- Kosko, Bart; *"Neural networks and fuzzy systems. A dynamical system approach to machine intelligence"*; Edit.: Prentice Hall; Englewood Cliff, New Jersey, USA; 1992; r-xxrr; pp.: 449.

- Kosko, Bart; "*Neural Networks for Signal Processing*"; Edit.: Prentice Hall; USA; 1992; XIII-XV; pp: 399.
- McKenna, Thomas; Davis, Joel; Zornetzer, Steven F.; "Single Neuron Computation"; Office of Naval Research Biological Intelligence Program; Edit.: Academic Press, Inc.; Arlington, Virginia, USA; 1992; i-xrv; pp.: 644
- Mehra, Pankaj; and Wah, Benjamin W.; "*Artificial Neural Networks: Concepts and Theory*"; Edit.: IEEE Computer Society Press, 1992, USA, pp.: 686.
- Miller, W. Thomas; Sutton, Richard S.; and Werbos, Paul J.; "*Neural Networks for Control*"; Edit.: MIT Press; Cambridge, Massachusetts, London, England, 1991; I-XII; pp: 524.
- Müller, B. and Reinhardt, J.; "*neural networks. An Introduction*"; Physics of Neural Networks; 2^a edición corregida; Edit.: Springer-Verlag; USA; 1991; pp.: 286.
- Pao, Y.; "*Adaptive Pattern Recognition and Neural Networks*"; Mass, Addison-Wesley, 1989.
- Souček, Branko and Souček, Marina; "*Neural and Massively Parallel Computers: The Sixth Generation*"; Edit.: John Wiley & Sons; USA, 1988; V-X; pp: 460.

Souček, Branko and The Iris Group; *"Neural and Intelligent Systems Integration"*; Sixth-Generation Computer Technology Series; Edit.: John Wiley & Sons, Inc.; USA; 1991; r-xviii; pp.: 684

Tapia, Ricardo; *"Las células de la mente"*; La Ciencia desde México, vol 30, Fondo de Cultura Económica, 1987.

Vemuri, V.; *"Artificial neural networks: Concepts and Control Applications"*; IEEE Computer Society Press; USA, 1992; pp: 509.

Widrow, B. and Hoff, M. E.; *"Neurocomputing: Foundations of Research"*;

Yu, Francis T. S.; and Jutamulia, Saganda; *"Optical signal processing, computing and neural networks"*; Wiley Series in Microwave and Optical Engineering, Edit.: John Wiley & Sons, Inc., 1992, USA, pp.: 419.

Zurada, Jacek M.; *"Introduction to artificial neural systems"*; Edit.: Publishing Company; USA; 1992; r-xxv; pp.: 683.

"Applications of artificial neural networks 99"; editor: Rogers, Steven K.; vol. I y II; USA; Abril 1991; pp.: 854.

"*Artificial Neural Networks. Electronic Implementations*"; edited by Morgan, Nelson; IEEE Computer Society Neural Networks Technology Series; Edit.: IEEE Computer Society Press; 1990; USA; pp.: 130.

"*Introduction to the Theory of Neural Computation*"; Mass, Addison-Wesley, 1991.

"*Neural Networks and Natural Intelligence*"; Cambridge, Mass.; MIT, Press, 1989.

"*Neural Networks. Theoretical Foundations and Analysis*"; edited by Lau, Clifford; Edit.: IEEE Press; prólogo: I - VIII; USA; 1992; pp.: 327

"*Progress in neural networks*", vol.: 1, edited by Omidvar, Omid; Edit.: Ablex Publishing Corporation, New Jersey, USA; 1991, pp.: 228.

Revistas

- Abu-Mostafa, Yaser and Psaltis, Demetri, "Optical Neural Computers",
Scientific American, vol. 256, Núm.: 3, pp.: 88 - 96,
Marzo de 1987.
- Anderson, J. A., "Networks for fun and profit", publicado en *Nature* vol
323, p. 406, julio de 1986.
- Barrera Zárate, Francisco; y Carbajal Castañeda, Victor Hugo;
"Simulación electrónica de una red neural"; Tesis; 1976;
Facultad de Ingeniería, UNAM; pp.: 127
- Carrillo Calvet, Humberto; "Las redes neuronales artificiales"; *INCYT*:
Información Científica y Tecnológica; CONACYT; Abril 1990;
México, D.F.; pp.: 37 - 47.
- Caudill, M. "Using Neural Networks: Knowledge Representation"; *AI
Expert* 4 (12); p. 39 - 41, 1989;
- Espinosa Espinosa, Ismael; "Las redes neuronales artificiales"; *INCYT*:
Información Científica y Tecnológica; CONACYT; Abril 1990;
México, D.F.; pp.: 37 - 47.
- Espinosa Espinosa, Ismael; "Los robots flexibles y las redes
neuronales"; *Ciencias*; Grupo de Difusión, Departamento de
Física, Facultad de Ciencias, UNAM; Num. especial 3; Enero de
1991; pp.: 89 - 103; México, D.F.

- Espinosa Espinosa, Ismael; "Neurocibernética: fisiología y modelos matemáticos de la neurona"; *Ingeniería*; Edit.: UNAM; Enero-Marzo; 1977; México, D.F.; pp.: 88 - 100.
- Flores Becerril, Carlos; Villalobos Sánchez, Eugenio; "Elementos de una Red Neuronal Artificial"; Tesis; 1994; Escuela Nacional de Estudios Profesionales Aragón; UNAM; pp: 100.
- Gómez, Antonio; "Presentación Gráfica de Resultados de la Simulación de Redes Neuronales"; Tesis; 1982; Facultad de Ingeniería; División de Estudios de Posgrado; Sección de Electrónica y Control; UNAM; pp.: 158.
- Grossberg, S.; "Nonlinear Neural Networks: Principles, Mechanism, and Architectures", *Neural Networks* 1, p. 17, 1988.
- Kohonen, T, "An Introduction to Neural Computing", publicado en *Neural Networks*, vol 1, p. 3, 1988.
- McClelland, J. L., Rumelhard, D. E. & PDP Research Group, *Parallel Distributed Processing*, Cambridge, Massachusetts, MIT Press, 1986.
- Sompolinsky, H.; "Statistical Mechanics of Neural Networks", publicado en *Physics Today*, p. 71, vol 41, diciembre de 1988.
- Sutherland, S., "Parallel Distributed Processing", publicado en *Nature*, vol. 323, p.486, octubre de 1986.

Tank, D. W., Hopfield, J. J., "Collective Computation in Neurolike Circuits", *Scientific American*, vol. 257, núm.: 12, pp.: 104 - 114, diciembre de 1987.

Artificial Intelligence; Edit. Elsevier Science Publishers; Editor en Jefe: Daniel G. Bobrow; Editor Asociado: Michael Brady; vol. 62; num. 1; Julio 1993; Amsterdam, Holanda.

Neural Networks; Co-editors-in-chief: Shun-ichi. Amari; Grossberg, Stephen; Taylor, John; Edit.: Pergamon Press, Inc.; USA; 1991, 1992, 1993, 1994.