


c.1



UNIVERSIDAD AUTÓNOMA CHAPINGO

DIVISIÓN DE CIENCIAS FORESTALES

APLICACIÓN DE REDES NEURONALES ARTIFICIALES Y
TÉCNICAS SIG PARA LA PREDICCIÓN DE COBERTURAS
FORESTALES

TESIS

QUE COMO REQUISITO PARCIAL
PARA OBTENER EL GRADO DE:

**MAESTRO EN CIENCIAS
EN CIENCIAS FORESTALES**



DIRECCION ACADEMICA
DEPTO. DE SERVICIOS ESCOLARES
OFICINA DE EXAMENES PROFESIONALES

PRESENTA:

ENRIQUE BUENDÍA RODRÍGUEZ

Chapingo, Estado de México.
Agosto 2000

B.1693965




APLICACIÓN DE REDES NEURONALES ARTIFICIALES Y TÉCNICAS SIG PARA LA PREDICCIÓN DE COBERTURAS FORESTALES

Tesis realizada por Enrique Buendía Rodríguez bajo la dirección del Comité Asesor indicado, aprobada por el mismo y aceptada como requisito parcial para obtener el grado de:

MAESTRO EN CIENCIAS EN CIENCIAS FORESTALES

DIRECTOR: _____



M.C. Eduardo Vargas Pérez.

ASESOR: _____



A-37123

M.C. Angel Leyva Ovalle

ASESOR: _____



M.C. Silvia Terrazas Domínguez

APLICACIÓN DE REDES NEURONALES ARTIFICIALES Y TÉCNICAS SIG PARA LA PREDICCIÓN DE COBERTURAS FORESTALES

El jurado que revisó y aprobó el grado de Enrique Buendía Rodríguez, autor de la presente tesis de Maestría en Ciencias en Ciencias Forestales estuvo constituido por:

PRESIDENTE: _____



M.C. Eduardo Vargas Pérez.

ASESOR: _____



M.C. Angel Leyva Ovalle

ASESOR: _____



M.C. Silvia Terrazas Domínguez

*Quien detiene su formación
se convierte en anciano,
sea a los veinte o a los ochenta.*

*Quien sigue aprendiendo,
se mantiene joven por siempre.*

Henry Ford.

DEDICATORIAS

Dedico este trabajo a DIOS por haberme dado la vida y la oportunidad de superarme y nunca me a dejado solo.

Con cariño y respeto a mis padres Enrique Buendía Luque y Silvia Rodríguez, quienes me han dado cariño y un buen ejemplo, motivándome siempre a seguir adelante por el camino del bien.

A mis hermanos que German, Emilio y Martha Gabriela que con su apoyo y amista hemos salido adelante todos como familia.

A Verónica por su apoyo y todos aquellos momentos de felicidad que me a brindado.

A mi amigo Luisito que con su apoyo incondicional, siempre esta ahí cuando lo necesito.

MUCHAS GRACIAS.

AGRADECIMIENTOS

A Dios por el simple hecho de que yo exista.

Al Consejo Nacional de Ciencia y Tecnología (CONACYT), por el apoyo económico recibido para la realización de este trabajo.

A la División de Ciencias Forestales de la Universidad Autónoma Chapingo (DICIFO-UACH), por permitirme hacer uso de sus instalaciones e inmobiliarios, así como a los profesores que me compartieron sus conocimientos y me brindaron su amistad.

Al Instituto Mexicano de Tecnología del Agua (IMTA), por la facilitación de las imágenes de satélite empleadas en el trabajo.

Al MC. Eduardo Vargas Pérez y MC. Silvia Terrazas Domínguez por haberme incursionado en el estudio y aplicaciones de las imágenes de satélite.

Al MC. Angel Leyva Ovalle por su amistad y su apoyo con lo referente a la aplicación de redes neuronales y el fascinante mundo de la computación.

DATOS BIOGRÁFICOS

El autor nació el 23 de Diciembre de 1973, en la Cd. De México, Distrito Federal. Estudio la preparatoria de 1988 a 1991 en el CBTA #35, obteniendo el título de Técnico Agropecuario. Ingreso a la Universidad Autónoma Chapingo, en la División de Ciencias Forestales (UACH-DICIFO) de la cual egreso en 1996, con el grado de Ingeniero Forestal con Orientación en Evaluación y Abastecimiento. En 1997 ingreso a la Maestría en Ciencias en Ciencias Forestales de esta misma Universidad. Apartir de Junio de 1999 trabaja en la Comisión Federal de Electricidad (CFE), en el Depto. De Geomática, desarrollando diversos proyectos de monitoréo de los recursos naturales, con ayuda de Imágenes de Satélite. También a participado en 6 tesis de licenciatura como asesor y jurado examinador, en la UACH-DICIFO.

RESUMEN

APLICACIÓN DE REDES NEURONALES ARTIFICIALES Y TÉCNICAS SIG PARA LA PREDICCIÓN DE COBERTURAS FORESTALES

En México como en todo el mundo se tiene la necesidad de realizar un inventario de sus recursos forestales, a fin de llevar a cabo en forma oportuna y adecuada la planeación de los programas de manejo. Un método para la obtención de este tipo de información es a través de modelos de predicción. De aquí que el presente estudio tenga como objetivo evaluar la habilidad de las redes neuronales artificiales (RNA) en la predicción de tipos de coberturas forestales. Las RNA desarrolladas en este trabajo se basan en información geográfica (altitud, exposición, pendiente, distancia a los escurrimientos, geología y edafología) e imágenes de satélite transformadas con análisis de componentes principales (ACP1 ACP2 y ACP3), para obtener la variable dependiente (vegetación). Esta información fue procesada con una RNA de retropropagación (Backpropagation) con dos capas ocultas, con sus respectivas funciones de activación (tangencial hiperbólica y gaussiana). Obteniendo una $r^2=0.8617$ para la fase de entrenamiento y una $r^2=0.8514$ en la fase de prueba, alcanzando un 83% de sitios predichos correctamente, sobrepasando lo alcanzado por Buendía (1996), de un 75% con métodos tradicionales.

PALABRAS CLAVE: Imagen de Satélite, SIG, Redes Neuronales, Coberturas Forestales.

ABSTRACT

APPLICATION OF ARTIFICIAL NEURAL NETWORKS AND TECHNICAL SIG FOR THE PREDICTION OF FOREST COVER

In Mexico like in the entire world one has the necessity to carry out an inventory of their forest resources, to make an appropriate management. A method for the obtaining this type of information is through prediction models. So this study has as objective to evaluate the ability of the artificial neuronal networks (ANN) in the prediction of types of forest coverings. The ANN was based on cartographic information (altitude, aspect, slope, distances to the glides, geology and edafology) and satellite images transformed with a principal components analysis (ACP1 ACP2 and ACP3), to obtain the dependent variable (vegetation). This information was processed with a backpropagation ANN with two hidden layers, with its respective activation functions (tangential hyperbolic and gaussian). Obtaining a $r^2=0.8617$ for the phase of training and $r^2=0.8514$ in the test phase, reaching 83% of places predicting correctly, surpassing that reached by Buendía (1996), of 75% with traditional methods.

KEYWORDS: Satellite Images, SIG, Neural Networks, Forest Cover.

ÍNDICE

	Página
DEDICATORIAS.	v
AGRADECIMIENTOS.	vi
DATOS BIBLIOGRÁFICOS.	vii
RESUMEN.	viii
ABSTRACT.	ix
ÍNDICE.	x
LISTA DE CUADROS.	xii
LISTA DE FIGURAS.	xiii
LISTA DE ANEXOS.	xiv
1. INTRODUCCIÓN.	1
2. OBJETIVOS E HIPÓTESIS.	3
2.1. Objetivos.	3
2.2. Hipótesis.	3
3. JUSTIFICACIÓN.	4
4. ANTECEDENTES.	8
4.1. Redes Neuronales Artificiales.	8
4.1.1. Introducción a las Redes Neuronales.	8
4.1.2. Modelo de una Neurona.	11
4.1.3. Función de Activación.	12
4.1.4. Topología de las Redes Neuronales.	15
4.1.5. Mecanismos de Aprendizaje.	19
4.1.6. Tipos de Asociación.	22
4.1.7. Red de Retropropagación.	23
4.2. Estudios Realizados con Redes Neuronales.	25
4.3. Estudios Realizados con Imágenes de Satélite	30
5. MATERIALES Y MÉTODOS.	33
5.1. Materiales.	33
5.2. Métodos.	34
5.2.1. Descripción del Área de Estudio	34
5.2.2. Metodología.	38
5.2.2.1. Información del Satélite LANDSAT TM.	38

5.2.2.2. Información del Modelo de Elevación Digital.	39
5.2.2.3. Información Cartográfica.	40
5.2.2.4. Formación de la Base de Datos.	41
5.2.2.5. Procesamiento de Datos con Redes Neuronales.	41
5.2.2.6. Reconstrucción de la Imagen.	43
6. RESULTADOS.	44
6.1. Información del Satélite LANDSAT TM.	44
6.2. Información del Modelo de Elevación Digital.	46
6.3. Información Cartográfica.	50
6.4. Formación de la Base de Datos.	54
6.5. Procesamiento de Datos con Redes Neuronales.	54
6.5.1. Fase de Entrenamiento.	54
6.5.2. Fase de Prueba.	57
6.5.3. Aplicación de la Red Neuronal.	58
6.6. Reconstrucción de la Imagen.	60
7. DISCUSIÓN.	62
	64
8. CONCLUSIONES Y RECOMENDACIONES.	64
8.1. Conclusiones.	65
8.2. Recomendaciones.	
9. LITERATURA CITADA.	67
10. ANEXOS.	71

LISTA DE CUADROS

Cuadro		Página
1	Clases de exposición.	47
2	Rangos de pendientes.	48
3	Clases edafológicas.	51
4	Clases de material geológico.	52
5	Tipos de vegetación.	53
6	Pesos sinápticos por variables ambientales.	57
7	Matriz de confusión	59

LISTA DE FIGURAS

Figura		Página
1	Ejemplo de límites paramétricos usados para la clasificación de dos clases.	5
2	Ejemplo de límites generados por redes neuronales para dos clases.	6
3	Diagrama del modelo abstracto de la neurona.	12
4	Función de activación de escalón.	13
5	Funciones de activación mixta.	13
6	Función de activación sigmoideal	14
7	Función de activación gaussiana.	15
8	Red monocapa, conectada hacia delante.	16
9	Red multicapa, conectada hacia delante.	17
10	Red recurrente con una conexión hacia atrás sin ninguna capa oculta.	18
11	Diagrama esquemático de un sistema de entrenamiento supervisado.	20
12	Diagrama esquemático de un sistema de entrenamiento no supervisado.	21
13	Localización geográfica del área de estudio.	35
14	Primer componente principal.	45
15	Segundo componente principal.	45
16	Tercer componente principal.	46
17	Mapa de altitud (msnm).	47
18	Mapa de exposición.	48
19	Mapa de pendiente del terreno.	49
20	Mapa de distancia a los escurrimientos.	50
21	Mapa edafológico.	51
22	Mapa geológico.	52
23	Mapa de vegetación.	53
24	Precisión de la red en la fase de entrenamiento.	56
25	Precisión de la red en la fase de prueba.	58
26	Imagen clasificada con redes neuronales artificiales.	60
27	Imagen LANDSAT TM, composición infrarrojo.	61

LISTA DE ANEXOS

Anexo		Página
I	Programa en SAS para formar la matriz de datos.	71
II	Resultado de la georreferencia de la imagen LANDSAT TM.	72
III	Programa para extraer datos al azar en SAS.	73
IV	Resultados obtenidos de la aplicación de la red neuronal (r^2).	74

1. INTRODUCCIÓN

En México, como en todo el mundo la preocupación por la pérdida desmedida de los recursos naturales, y los efectos que esta acarrea en el medio ambiente es considerablemente alto, razón por la que existe en la actualidad un gran número de programas gubernamentales destinados a evaluar, controlar y prevenir el deterioro ambiental.

En décadas recientes la utilización de técnicas como la teledetección, Sistemas de Información Geográfica (SIG) y los modelos de simulación, han contribuido notablemente a la solución de muchos de los problemas ocasionados por el uso indebido del recurso. Uno de los problemas principales en el uso de estas técnicas es la baja precisión con que se puede evaluar los recursos naturales. Para solventar este problema se han desarrollado varias técnicas o herramientas que permite un mayor grado de confiabilidad.

Por tanto, para mejorar la precisión de la cartografía de la vegetación, elaborada con imágenes de satélite, los investigadores se han valido de información auxiliar, como son los factores del clima, suelo, topográficos, etc. En años recientes se han desarrollado metodologías basadas en una nueva técnica denominada “Redes Neuronales Artificiales, RNA” (*ANN, Artificial Neural Networks*), que fueron originalmente una simulación abstracta de los sistemas nerviosos biológicos, aunque en la actualidad distan mucho de aquellos, ahora se encuentran fuertemente ligadas a aplicaciones en inteligencia artificial. En las metodologías que involucran RNA, la información auxiliar puede ser

introducida como un canal más de información, o bien ser usada para determinar las probabilidades de encontrar una categoría dada, bajo las condiciones establecidas por dicha información.

De aquí que el presente trabajo pretenda determinar un modelo para la predicción de tipos de coberturas vegetales, utilizando una técnica nueva de modelación a través de Redes Neuronales Artificiales, aplicadas a información procedente de imágenes de satélite LANDSAT TM, información cartográfica convencional e información obtenida mediante Sistemas de Información Geográfica. El área de estudio fue el cerro del Telapón que se encuentra ubicado en la Sierra Nevada, al Oriente del Valle de México.

2. OBJETIVOS E HIPÓTESIS

2.1. Objetivos

- Elaborar un modelo de predicción de coberturas vegetales del Cerro del Telapón, Sierra Nevada, en el Edo. de México, utilizando Redes Neuronales Artificiales en información de imágenes de satélite y cartografía.
- Reconstruir el mapa de coberturas vegetales mediante el modelo de predicción elaborado.

2.2. Hipótesis

Con el uso de imágenes de satélite, información cartográfica y técnicas de inteligencia artificial (Redes Neuronales Artificiales), se incrementa la precisión en la determinación de coberturas forestales.

3. JUSTIFICACIÓN

Las Redes Neuronales Artificiales (RNA) son similares o idénticas a las técnicas estadísticas convencionales tales como: modelos lineales generalizados, regresión polinomial, regresión no paramétrica y análisis discriminante, siendo las RNA más eficientes que sus homónimos en la estadística convencional en problemas no lineales; análisis de componentes principales y conglomerados, las cuales son utilizadas especialmente cuando la finalidad de una predicción son fenómenos complicados que no tienen explicación. Estas técnicas son muy útiles en análisis de datos mediante técnicas de retropropagación (backpropagation) que no tiene una equivalencia estadística, siendo práctica su utilización y/o implementación (Sarle (a), 1994).

Las RNA son más rápidas y en algunos casos con mejor desempeño que los métodos estadísticos convencionales (Sarle (b), 1994). Para el análisis de datos se han implementado ciertas aplicaciones que procesen la información en paralelo y no en serie como la mayoría de estas (Blum, 1992).

Principalmente, la arquitectura de las redes neuronales son estructuradas y aplicadas como función de aproximación, como en regresión no lineal. Algunas redes neuronales tienen algún elemento probabilístico implícito, no paramétrico, no lineal y potencialmente adaptables (Mokken,1995).

Una de las ventajas que proporciona la utilización de las redes neuronales, es que una vez entrenada la red, procesan datos no considerados en su entrenamiento con relativa rapidez, propiciando un análisis en tiempo real, reduciendo costos y tiempo de operación (Blum, 1992).




Figura 1. Ejemplo de límites paramétricos usados para la clasificación de dos clases.

La principal ventaja de las redes neuronales en las técnicas estadísticas, es sin duda la detección de límites entre clases. Las técnicas estadísticas convencionales producen una regla de decisión basada en el *error más bajo* y dan la asignación de la muestra a la clase más probable. El resultado de la regla es un límite que es dado por la

intersección de L (número de clases) funciones, produciendo límites como se observan en la Figura 1, mostrando los resultados de las regiones de decisión cuando las formas paramétricas son lineales (denotado por g_L), cuadrática (g_Q) y por fragmentos lineales (g_{PL}).

En cambio las redes neuronales producen límites con técnicas no paramétricas dependiendo de la particularidad de la muestra usada y de su distribución. Esto queda evidente en la Figura 2, en la cual se observa una muestra totalmente delimitada por la región de la clase ω_2 (Antognetti, 1991).




Figura 2. Ejemplo de límites generados por redes neuronales para dos clases.

Por estas razones se lleva a cabo el siguiente trabajo aplicando redes neuronales en la clasificación y predicción de coberturas vegetales, sin tener que probar o hacer las comparaciones con las técnicas estadísticas convencionales, enfocando el presente estudio a la implementación de una modelo de redes neuronales artificiales (RNA) en materia forestal, con base en información cartográfica georreferenciada (edafología, geología y distancia a los escurrimientos), imágenes de satélite e información extraída de los modelos de elevación digital (exposición, pendiente y altitud).

4. ANTECEDENTES

4.1. Redes Neuronales Artificiales

4.1.1. Introducción a las Redes Neuronales

Las Redes Neuronales Artificiales RNA (*ANN, Artificial Neural Networks*) fueron originalmente una simulación abstracta de los sistemas nerviosos biológicos, formados por un conjunto de unidades llamadas “neuronas” o “nodos” conectadas unas con otras. Estas conexiones tienen una gran semejanza con las *dendritas* y los *axones* en los sistemas nerviosos biológicos. Las RNA son una amplia gama de regresiones no lineales, modelos discriminantes, modelos de reducción de datos y sistemas dinámicos no lineales (Sarle (a), 1994). Estas constan de un gran número de neuronas (elementos básicos de computo) interconectadas en un arreglo complejo y frecuentemente organizado en capas.

Mientras que Haykin (1994), conceptualiza una red neuronal artificial como una unidad de proceso masivo distribuido en paralelo que tiene una propensión natural para almacenar conocimiento y lo usa en una situación similar. Esto se asemeja al cerebro en dos aspectos: Primero, el conocimiento es adquirido por la red a través de un proceso de aprendizaje, y segundo, la conexión entre neuronas, conocida como conexiones sinápticas, se usan para almacenar el conocimiento.

En tanto que Kohonen (1998), define las redes neuronales artificiales como redes interconectadas masivamente en paralelo de elementos simples (usualmente adaptativas) y con organización jerárquica, las cuales interactúan con el mundo real del mismo modo que lo hace el sistema nervioso biológico.

Las redes neuronales son principalmente usadas en cuatro formas:

- Modelos de sistemas nerviosos biológicos e inteligencia artificial.
- Adaptador en tiempo real de procesos simples o implemento de control en hardware para aplicaciones tales como robótica.
- Análisis de datos.
- Reconocimiento de patrones.

Una primera clasificación de los RNA podría ser, atendiendo a su similitud con los modelos biológicos:

- Los modelos de *tipo biológicos*. Este comprende las redes que tratan de simular los sistemas neuronales biológicos así como las funciones auditivas o algunas funciones básicas de la visión.
- El modelo *dirigido a aplicaciones*. Estos modelos no tienen porque guardar similitud con los sistemas biológicos. Sus arquitecturas están fuertemente ligadas a las necesidades de las aplicaciones para las que son diseñadas.

Una red neuronal se caracteriza por un patrón de *conexiones entre neuronas* (arquitectura o topología), el método de determinar *los pesos* sobre las conexiones (entrenamiento o aprendizaje), y su *función de activación*.

La compleja operación de las redes neuronales es el resultado de abundantes lazos de retroalimentación junto con funciones no lineales de los elementos de proceso y cambios adaptativos de sus parámetros, que pueden definir incluso fenómenos dinámicos muy complicados.

Las características principales de las redes neuronales generadas en aplicaciones son las siguientes:

- *Autoorganización*: Una red neuronal puede crear su propia organización o representación de la información que recibe mediante una etapa de aprendizaje.
- *Adaptabilidad*: Capacidad de aprender a realizar tareas basadas en un entrenamiento o una experiencia inicial.
- *Tolerancia a fallos*: La destrucción parcial de una red conduce a una degradación de su estructura; sin embargo, algunas capacidades de la red se pueden retener, incluso sufriendo un gran daño.
- *Operación en tiempo real*: Las redes neuronales pueden operar en paralelo, es decir que al mismo tiempo que se esta procesando los datos se obtienen resultados.

Los clasificadores basados en redes neuronales son fundamentalmente diferente de aquellos basados en el enfoque estadístico. En vez de estudiar la estructura de los datos simultáneamente, cada ejemplo es considerado por separado y los parámetros son ajustados si el ejemplo es clasificado incorrectamente (Antognetti, 1991).

La arquitectura de red más ampliamente usada es la denominada red de retropropagación (Backpropagation). El 90% de las aplicaciones de redes neuronales utilizan esta arquitectura (Welstead, 1994; citado por Leyva, 1999).

4.1.2. Modelo de una Neurona

La *neurona* (X_i) es el elemento básico en una red neuronal. Cada neurona tiene una salida, la cual es generalmente relacionada al estado de la neurona (activación) y puede dirigir salidas a varias neuronas. Cada neurona recibe varias entradas de diferentes conexiones, nombradas *sinapsis o ligas de conexión*. Las entradas son la activación de las neuronas de entrada multiplicada por los *pesos de la sinapsis* (W_j). La activación de la neurona es procesada por la aplicación de una *función umbral* (θ) a esta neurona (Blum, 1992). Un modelo abstracto de la neurona se muestra en la Figura 3.





Figura 3. Diagrama del modelo abstracto de la neurona.

4.1.3. Función de Activación

La función de activación denotada por θ define la salida de una neurona en términos del nivel de activación de la neurona de entrada. Esta *función Umbral* es generalmente alguna forma de función no lineal. Se puede identificar cuatro tipos básicos de función de activación:

Función Escalón: Esta se asocia a neuronas binarias en las cuales cuando la suma de las entradas es mayor o igual que el umbral de la neurona, la activación es 1; si es menor, la activación es 0 (Figura 4).



En ambos casos se ha tomado que el umbral es cero; en caso de que no lo fuera, el escalón quedaría desplazado

Figura 4. Función de activación de escalón.

Función lineal y mixta: Esta responde a la expresión $f(x)=x$. En las neuronas con función mixta, si la suma de las señales de entrada es menor que un límite inferior, la activación se define como 0 (o -1). Si dicha suma es mayor o igual que el límite superior, entonces la activación es 1. Si la suma de entrada está comprendida entre ambos límites, entonces la activación se define como una función de la suma de las señales de entrada (Figura 5).




Figura 5. Funciones de activación mixta.

Función sigmoideal: En esta función, la mayoría de los valores del estímulo de entrada (variable independiente), el valor dado por la función es cercano a uno de los valores asintóticos. Esto hace que en la mayoría de los casos, el valor de salida esté comprendido en la zona alta o baja del sigmoide. Sin embargo, la importancia de la función sigmoideal es que su derivada es siempre positiva y cercana a cero para valores grandes positivos o negativos; además, toma su valor máximo cuando x es 0, como se puede observar en la Figura 6.




Figura 6. Función de activación sigmoideal.

Si se requiere utilizar una función sigmoideal no lineal en una red multicapa, se recomienda la *función tangencial hiperbólica*, o de lo contrario el entrenamiento será equivalente a una red monocapa. Esta función no es más que una modificación de la función sigmoideal para acepta valores negativo, analizando perfectamente datos asimétricos.

Función de activación Gaussiana: Los centros y anchura de estas funciones pueden ser adaptados, lo cual las hace más adaptativas que las funciones sigmoidales. En los mapeos que requieren dos capas ocultas, utilizan neuronas con funciones de activación sigmoidales; algunas veces se pueden realizar con una sola capa oculta en redes con neuronas de función gaussiana (Figura 7).




Figura 7. Función de activación gaussiana.

4.1.4. Topología de las Redes Neuronales

La *topología o arquitectura* de las redes neuronales consiste en la organización y disposición de las neuronas en la red formando *capas* o agrupaciones de neuronas más o menos alejadas de la entrada y salida de la red. En este sentido, los parámetros fundamentales de la red son: *el número de capas, el número de neuronas por capa, el grado de conectividad y el tipo de conexiones entre neuronas* (Salas, 2000).

Es decir, es la manera en la cual las neuronas de una red son estructuradas y como esta ligadas con el algoritmo de entrenamiento usado en el entrenamiento de la red (Haykin, 1994). En general se identifican tres diferentes clases de arquitectura de redes.

a) Red monocapa: Una Red mono capa solo tiene una capa de entrada de neuronas de origen que se conectan a una capa de salida de neuronas, pero no viceversa. En otras palabras esta red es estrictamente de *conexiones hacia delante* (feedforward), como se puede observar en la Figura 8.




Figura 8. Red monocapa, conectada hacia delante.

b) Red multicapa: La segunda clase de red neuronal (Figura 9), se distingue por la presencia de una o más capas ocultas, dichos componentes son llamadas *neuronas ocultas*. La función de las neuronas ocultas es la de intervenir entre la entrada y salida de la red. Adicionando una o más capas ocultas, la red esta capacitada para extraer parámetros estadísticos altos (Haykin, 1994).




Figura 9. Red multicapa, conectada hacia adelante.

c) **Red recurrente:** Estas redes se caracterizan por redes neuronales de conexiones *hacia delante* (feedforward) y conexiones *hacia atrás* (feedback) entre neuronas. Por ejemplo una red recurrente puede consistir de una red monocapa cuya neurona de entrada se alimenta de una simple salida regresando a la entrada de todas las otra neuronas como se ilustra en la Figura 10.




Figura 10. Red recurrente con una conexión hacia atrás sin ninguna capa oculta.

4.1.5. Mecanismos de Aprendizaje

El aprendizaje y/o entrenamiento es el proceso por el cual una red neuronal modifica sus pesos en respuesta a una información de entrada a través de una época; se denomina época cuando todo el conjunto de entrenamiento ha sido presentado a la red. Los cambios que se producen durante el proceso de aprendizaje se reduce a la modificación y creación de conexiones entre neuronas. En los modelos de RNA, la creación de una nueva conexión implica que el peso de la misma pasa a tener un valor distinto de cero. De la misma forma, una conexión se destruye cuando su peso pasa a ser cero (Haykin, 1994).

El algoritmo de aprendizaje es dividido en dos métodos el *supervisado* y *no supervisado*.

El *aprendizaje supervisado* denota un método en el cual el vector de entrada es presentado a la red. La salida obtenida por la red es medida entre la respuesta observada y la esperada, corrigiendo los pesos de acuerdo con la magnitud del error en el arreglo definido por el algoritmo de entrenamiento. Esta bondad del aprendizaje es a veces llamado *aprendizaje con un maestro*, siendo un control del proceso conociendo la respuesta correcta para el vector de entrada seleccionado (Figura 11).




Figura 11. Diagrama esquemático de un sistema de entrenamiento supervisado.

El aprendizaje supervisado es dividido en dos métodos los cuales son: el de *refuerzo* y de *corrección de error*.

- El *aprendizaje de Refuerzo* se basa en la idea de no disponer de un ejemplo completo del comportamiento deseado; es decir, de no indicar durante el entrenamiento exactamente la salida que se desea que proporcione la red ante una determinada entrada. En este aprendizaje la función del supervisor se reduce a indicar mediante una señal de refuerzo si la salida obtenida en la red se ajusta a la deseada y en función de ello se ajustan los pesos basándose en un mecanismo de probabilidad.
- El *aprendizaje con corrección de error*, consiste en ajustar los pesos de las conexiones de la red en función de la diferencia entre los valores deseados y los obtenidos en la salida de la red; es decir, en

función del error cometido en la salida. El aprendizaje lo constituye el denominado regla delta generalizada o algoritmo de retropropagación del error, también conocida como regla LMS (Least Mean Square Error) multicapa.

El *aprendizaje no supervisado* es usado cuando para una entrada dada, produce una salida desconocida por la red (Figura 12). La red no recibe ninguna información por parte del entorno que le indique si la salida generada en respuesta a una determinada entrada es o no correcta.



Figura 12. Diagrama esquemático de un sistema de entrenamiento no supervisado.

En cuanto a los algoritmos de aprendizaje no supervisado, en general se suelen considerar dos tipos: *Aprendizaje hebbiano* y *Aprendizaje competitivo y cooperativo*. En el primer caso, normalmente se pretende medir la familiaridad o extraer características de los datos de entrada, mientras que el segundo suele orientarse hacia el agrupamiento o clasificación de dichos datos (Haykin, 1994).

4.1.6. Tipos de Asociación

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

La tarea del aprendizaje puede ser de dos formas denominadas, *autoasociación* y *heteroasociación*. En la autoasociación la red neuronal requiere de almacenar un conjunto de patrones, para una repetida presentación a la red. Subsecuentemente, la red presenta una descripción parcial o distorsionada (ruido), del patrón original almacenado en la red, y la tarea de dicha red es retribuir (renombrar) el patrón original. La heteroasociación difiere de la autoasociación en que un conjunto arbitrario de patrones de entrada forman pares con un conjunto arbitrario de patrones de salida. La autoasociación implica el uso de aprendizaje no supervisado, mientras que el tipo de aprendizaje que implica una heteroasociación es de naturaleza supervisada (Salas, 2000).

4.1.7. Red de Retropropagación

El algoritmo de retropropagación (backpropagation), es una regla de aprendizaje que se puede aplicar en modelos de redes con más de dos capas de neuronas. Una característica importante de este algoritmo es la representación interna del conocimiento que es capaz de organizar en la capa intermedia de las neuronas para conseguir cualquier correspondencia entre la entrada y la salida de la red.

La retropropagación es un algoritmo para una red de aprendizaje con conexión hacia atrás usando error medio cuadrático (Least Mean Square, LMS) y gradiente descendente. El método numérico fue usado por diferentes comunidades de investigadores en diferentes contextos, fue redescubierto en 1985, esta búsqueda fue principalmente encaminada para conexiones en inteligencia artificial (AI) (Rojas, 1996).

El modelo de retropropagación por lo general tiene tres capas de neuronas: una capa de entradas, una capa oculta y una capa de salida, tiene dos capas de pesos sinápticos, una tasa de aprendizaje que indica que tanto cambian los pesos en el traslado de cada paso, esto es típicamente un número entre 0 y 1. En términos de momentos, θ indica que tanto puede influenciar el cambio de pesos iniciales en los pesos subsecuentes, indicando que tolerancia puede ser aceptada para una buena salida.

La importancia de la red de retropropagación consiste en su capacidad de autoadaptar los pesos de las neuronas de las capas intermedias para *aprender* la relación

que existe entre un conjunto de patrones dados como ejemplo y sus salidas correspondientes.

Se utiliza generalmente el método de retropropagación con *la regla delta generalizada* como el manejador de la estructura de la red que a probado ser eficiente, pero computacionalmente un tipo lento de optimización recurrente, a veces altamente susceptible a la gran cantidad de óptimos locales que pueden ocurrir en complicadas redes (Mokken, 1995).

Regla delta generalizada. El algoritmo de retropropagación sigue esta regla para ajustar los pesos, ya que estos se actualizan de forma proporcional a la delta o a la diferencia entre la salida deseada y la obtenida ($\delta = \text{salida deseada} - \text{salida obtenida}$).

En la práctica un típico entrenamiento de una red multicapa por medio de algoritmo de retropropagación puede durar varios días incluso semanas (Blum, 1992). Una vez que la red ha sido entrenada, su tiempo de respuesta supera en mucho al desempeño algorítmico, por lo cual es posible plantear aplicaciones en tiempo real (Rufiner, 1995; citado por Leyva, 1999).

4.2. Estudios Realizados con Redes Neuronales

Los primeros estudios sobre redes neuronales artificiales fueron realizados por Warren McCulloch 1927, pero tuvo un problema de formulación general del modelo biológico con los tratamientos matemáticos de redes recurrentes (McCulloch, 1974; citado por Rojas, 1996). El modelo McCulloch-Pitts fue propuesto a la vez por Norbert Wiener y Arturo Rosenblueth, quienes iniciaron la discusión de la importante regla de regeneración (feed-back) en sistemas biológicos y servomecanismos.

En el concepto actual de RNA, algunos investigadores consideran el perceptrón como el primer modelo abstracto serio de células neuronales, el perceptrón fue la primera red neuronal comercial, a través de los primeros prototipos que fueron principalmente utilizados en investigaciones de laboratorio. En 1950, Frank Rosenblatt uso el perceptrón para resolver problemas de reconocimiento de patrones (Hecht-Nielsen, 1990; citado por Rojas, 1996).

En 1959, Bernard Widrow y Marcial Hoff, de Stanford, desarrollaron el modelo ADALINE (ADaptative LINear Elements). Esta fue la primera red neuronal aplicada a un problema real (filtros adaptativos para eliminar ecos en las líneas telefónicas) y se ha usado comercialmente durante varias décadas (Widrow y Hoff, 1960; citado por Salas, 2000).

En 1969, Minsky y Papert citado por Rojas (1996), analizaron los rasgos distintivos y limitantes del modelo de perceptrón de un riguroso modo. Ellos mostraron que el algoritmo del perceptrón necesita un número exponencial de pasos de aprendizaje en el peor de los casos.

A principios de los 70's, Frank Rosenblatt fue el primero en experimentar con aprendizaje no supervisado en redes con elementos de umbral (threshold). Él interpretó la habilidad de la red para encontrar conglomerados (clusters), como un bondadoso mecanismo similar al poder abstracto de la mente humana, capaz de formar nuevos conceptos de material empírico (Rojas, 1996).

En 1974, Werbos citado por Rojas (1996), consideró el caso de una función general de composición y propone el algoritmo de retropropagación (backpropagation) como una robusta regresión no lineal.

En 1982, coincidieron numerosos eventos que hicieron resurgir el interés por la redes neuronales. John Hopfield presentó su trabajo de redes neuronales en la Academia Nacional de las Ciencias. En el trabajo, describe con claridad y rigor matemático una red. Además, mostró cómo tales redes pueden trabajar y que pueden hacer (Hopfield, 1982; citado por Salas, 2000).

En los 80's la comunidad de AI (Artificial Intelligence), por medio de Rumelhart *et al* citado por Rojas (1996) usa la optimización de la redes neuronales multicapas.

En 1986, Rumelhart *et al* formalizaron un método para que una red neuronal aprendiera la asociación que existe entre los patrones de entrada a la misma y las clases correspondientes, utilizando más niveles de neuronas que los que utilizó Rosenblatt para desarrollar el Perceptrón. Este método, conocido en general como *backpropagation* (retropropagación), está basado en la generalización de la regla delta y a pesar de sus propias limitaciones, ha ampliado de forma considerable el rango de aplicaciones de las redes neuronales.

El 1994 Sharda, hace una revisión bibliográfica sobre redes neuronales encontrando que el 71% de los estudios publicados sobre modelos de RNA predicen mejor que las técnicas estadísticas tradicionales. En resumen, el 12% de los estudios de RNA predicen aproximadamente igual que las técnicas estadísticas tradicionales, en tanto que solo el 17% de los estudios reportan que las técnicas estadísticas tradicionales son mejores que los modelos de RNA.

En 1996 Martínez y Velázquez, mostraron la metodología de diseño, construcción, entrenamiento y aplicación de dos tipos de redes con diferente tipo de entrenamiento (supervisado y no supervisado) a una imagen del satélite NOAA-TIROS. Este estudio tiene un enfoque meteorológico, realizando una asignación de cada pixel de la imagen en forma automática un valor que representa tierra, mar o la clase de nube; llegando a la conclusión que las RNA son un posible camino para integrar información procedente de distintos sistemas de observación y obtener información adicional.

También en 1996 Timmermans y Hulzebosch citado por Leyva (1999), desarrollaron un sistema para la clasificación de diversos tipos de plantas. Se hace una comparación entre la utilización de un clasificador basado en redes neuronales y otro basado en análisis estadístico (análisis discriminante).

En tanto que Blackard y Dean (1996), realizaron un estudio para evaluar la habilidad de dos modelos espaciales, ambos basados en SIG (Sistemas de Información Geográfica), pero incorpora una RNA y la otra utilizando Análisis Discriminante (AD), para predecir tipos de coberturas en bosques sin disturbios. Los resultados indicaron que ningún modelo ofrece una buena predicción de las coberturas, obteniendo una precisión de 47.13% para RNA y 58.04% para AD con un modelo cuadrático.

Los mismos autores en 1998, después de adecuar los datos al incrementar variables cartográficas como elevación, exposición, distancia a escorrentía superficial y dividiendo los datos por áreas y dentro del modelo en datos de validación y datos de prueba, encontraron que las RNA fueron significativamente mejor con un 70.58% contra un 58.38% del análisis discriminante.

Un estudio de aplicación de redes neuronales en cuestiones forestales fue el realizado por Leyva (1999), desarrollando un sistema para clasificar tipos de parénquima denominado SPIMM-M1, obteniendo en la fase de entrenamiento una $r^2=1.0$ clasificando correctamente el 100% de las 5 clases de parénquima utilizadas y para la fase de prueba logró un 92% de patrones clasificados correctamente.

En 1999, Lai y Fyfe derivaron un nuevo método de funcionamiento de Análisis de Correlaciones Canónicas y Redes Neuronales Artificiales. Estos autores demostraron la capacidad de la red neuronal en dos situaciones, cuando la estadística convencional no es efectiva. Demostrando que la combinación de estas técnicas son extremadamente efectivas en la detección de cambios en la información.

En tanto que Zhou y Civco, implementaron una técnica de toma de decisiones en SIG mediante un modelo de redes neuronales usando un algoritmo genético como mecanismo de aprendizaje. Su conclusión es que la red neuronal puede proveer una alternativa y mejorar el método de análisis de sustentabilidad tradicional en SIG.

Muttiah *et al.*, desarrollaron una aplicación de redes neuronales con una interface para GRASS GIS, utilizándolo en un ejemplo en la identificación de la mejor práctica de manejo de erosión, utilizando imágenes de satélite como principal fuente de información.

Deadman y Randy, integraron un GIS y una RNA, para análisis de patrones en el crecimiento de vegetación. Utilizaron datos biofísicos del sitio (pendiente, exposición, suelo). La red fue entrenada con asociación de patrones de características biofísicas y unidades muestrales específicas con condiciones de crecimiento de la selva. Los patrones en el crecimiento de la vegetación predichas por la red neuronal fue encontrada cerca de la información de campo del actual sitio. La RNA hace una correcta predicción en solo 4 de las 13 pruebas con un 69% de confiabilidad.

4.3. Estudios Realizados con Imágenes de Satélite

En 1992, Muviria citado por Buendía (1996) desarrolló una metodología para mapear agrotopoclimas en áreas de relieve complejo, integrando datos ecológicos, de topografía y meteorología, mediante un SIG. El método fue desarrollado en el área de Lom Sak en el centro-norte de Thailandia. La información ecológica, topoclimática son primeramente componentes topoclimáticos y mapas de unidades de tierra. Los mapas agrotopoclimaticos son aplicados a algunos criterios de usos a característicos de unidades de suelo a niveles de provincias climáticas vs. temperatura media anual y longitud de las estaciones.

En tanto que Petersen *et al* (1991), aplicaron los sistemas de información geográfica en conjunto con sensores remotos demostrando que estas herramientas pueden ser usadas en dirección espacial y variabilidad temporal, mejorando la organización e integrado datos donde la ayuda a los modelos de simulación que son usados mediante tecnología SIG, manejos del paisaje como ecosistema y calidad de procesos geomorfológicos.

Esto permite la modulación de suelos-paisaje usando calidad y métodos estadísticos que definen relaciones entre fracciones de paisajes y propiedades de suelo. Los sistemas de posición global (GPS) son una nueva herramienta para la investigación de la ciencia del suelo, que nos permite el uso de coordenadas geográficas y elevación siendo procesadas directamente en un SIG. El análisis digital de terrenos pueden ser

usados en características topográficas en tercera dimensión. De esto se derivan límites de drenajes aéreos, canales de corrientes, bordes de áreas de contribución y características topográficas sobre cada área de contribución.

Mientras que Noguez en 1993, en un estudio comparativo en la clasificación con imágenes de satélite LANDSAT TM y MSS, encontró que la mejor precisión global de la imágenes LANDSAT TM, se obtiene mediante la combinación de las bandas 1, 4 y 5 con proceso de filtrado con un 71% de precisión.

En 1996, Buendía realizó un estudio en la región oriente del Valle de México, utilizando imágenes LANDSAT TM y el software SPIPR II. Se establecieron cuatro tratamientos (Componentes Principales, Análisis de Textura, Convolución y Filtro pasa baja) en tres combinaciones de bandas (LANDSAT TM2-TM5-TM7, y SPOT XS1-XS2-XS3). Se obtuvo que la mejor clasificación en la combinación de bandas TM2-TM5-TM7 sin tratamiento y/o transformación fue de un 75% de confiabilidad, en tanto que para LANDSAT TM3-TM4-TM5, también sin tratamiento y encontró un 69.07% y con las imágenes SPOT XS1-XS2-XS3 con análisis de Componentes Principales se obtuvo un 69.07%.

Martínez en 1997, realizó un estudio en el oriente del Valle de México, estableciendo la relación que existe en algunas propiedades físicas y químicas del suelo y características de la vegetación, sobre los valores de reflectancia ofrecidas en imágenes de satélite LANDSAT TM. Los resultados obtenidos mostraron que la mayoría de las

características edáficas evaluadas se ajustan a un modelo cuadrático. Por otra parte, las características de la vegetación presentaron comportamientos lineales, cuadráticos y logarítmicos, diferenciándose en las bandas 3, 4 y 5.

En tanto que Marquez 1998, elaboró la cartografía de cinco asociaciones arbóreas en la microcuenca de “El Tecolote”, en el municipio de San Dimas, Durango. Se desarrollaron dos métodos cartográficos: el primero basado en información digital del satélite LANDSAT TM mediante criterio de distancia cuadrada generalizada (testigo); y el segundo mediante la combinación de información del satélite, información topográfica del sitio (topoforma y exposición) y relaciones de probabilidad de las asociaciones arbóreas con respecto a la topografía (combinada). La cartografía testigo tuvo una precisión de 65.6%, mientras que la cartografía por el método combinado fue de 82.45, y su generalización mediante un filtrado de moda, de 91.91%.

5. MATERIALES Y MÉTODOS

5.1. Materiales

Los materiales que se utilizaron para realizar este estudios se dividen en dos categorías las cuales son:

a) Información Cartográfica y Satelital

La zona de estudio se delimitó en la carta de CHALCO escala 1:50 000, con clave E14B31 de INEGI, con los temas siguientes:

- Carta de vegetación y uso de suelo.
- Carta edafológica.
- Carta geológica.
- Carta topográfica.
- Imágenes de Satélite, LANDSAT TM, bandas 1,2, 3, 4, 5, y 7.
- Modelo de Elevación Digital (MED).

b) Material de cómputo

SOFTWARE

- Sistemas de Información Geográfica (IDRISI, for Windows).
- AutoCad ver. 14.

- Sistema de Análisis Estadístico (SAS).
- NeuroShell 2 ver. 3.0

HARDWARE

- Microcomputadora Hewlett Packard con procesador AMD y monitor SVGA.
- Impresora Hewlwt Packard láser Jet 4L.
- Impresora Epson Stylus color 600.

5.2. Métodos

5.2.1. Descripción del Área de Estudio

El área de estudio *se localiza* al oriente del Estado de México, entre las coordenadas 19°28'30" y 19°20' 30" latitud norte y 98°50'30" y 98°41'30" longitud oeste (Figura 13). Cubre una superficie aproximada de 25,678 ha. y una altitud que oscila desde 2400 hasta los 4120 msnm.

En cuanto a la *hidrografía* del lugar se encuentran las subcuenca de los ríos Texcoco, Chapingo, San Bernardino, Coatlinchán y Coatepec. Estos ríos se originan en la zona montañosa al noroeste de la Cuenca del Valle de México en la Sierra Nevada y

desembocan en el antiguo lago de Texcoco (INEGI, 1985). También existe un acueducto que baja desde el llano "Tula" y llega al poblado de Tequexquihuac.




Figura 13. Localización geográfica del área de estudio.

La **geología** del área de estudio esta conformada en su mayor parte por rocas sedimentarias (brecha sedimentaria), y en las partes más elevadas se encuentran rocas ígneas (andesitas, brechas volcánicas); estos tipos de materiales fueron formados en el terciario y cuaternarios como consecuencia de las fallas de San Andrés (Adame, 1996).

Los tipos de **suelos** del área de estudio son homogéneos (Adame, 1996), tomando en cuenta la información de la carta edafológica editada por INEGI. Reportando cinco unidades de uso de suelo dentro de la zona, de acuerdo con la clasificación FAO-UNESCO las cuales son: Feozem, Litosol, Cambisol y en una menor proporción se encuentran el Regosol y Andosol.

El **clima** de la zona es templado subhúmedo con lluvias en verano, con una temperatura media anual de 15.8 °C y una precipitación media anual de 650 mm. De acuerdo con la clasificación de Koppen modificada por García (1981), este clima se clasifica como: C(Wo)(w)b(i')g.

Las condiciones de clima y del substrato varía de un lugar a otro y estas variaciones tienen que reflejarse en la existencia de comunidades vegetales, (Noguez, 1993). Observándose tipos de **vegetación** como son los bosques de pino conformados por: *Pinus montezumae*, *P. pseudostrobus*, *P. hartweggi* y *P. leiophylla*. Aisladamente encontramos

algunos elementos de *Abies religiosa* y *Cupressus sp.* Encontrándose además especies de latifoliadas como: *Senecio praecox*, *Quercus rugosa*, *Alnus sp.*, *Arbutus glandulosa* y *Schinus molle* entre otros.

También se encuentran algunos elementos de *Opuntia spp*, *Cactus sp*, *Agave sp*, *Prosopis juliflora*, *Acacia tortuosa* y algunos pastos tales como: *Hilaria cenchoroides*, *Boutelou radiculosa* y *Abildgardia mexicana*.

En los años 70's se realizaron plantaciones forestales en esta zona con fines principalmente de proteger al suelo contra la erosión, las especies utilizadas fueron: *Pinus leiophylla*, *P. montezumae*, *P. pseudostrobus*, *P. rudis*, *P. radiata* var. *binata*, *Cupressus lindleyi*, *Eucalyptus sp*, *Fraxinus udhei*, *Casuarina sp* entre otras.

Encontramos extensiones de áreas agrícolas de temporal en las cuales los cultivos principales son: Maíz, Trigo, Avena, Cebada, Frijol, que son cultivados tradicionalmente.

5.2.2. Metodología

5.2.2.1. Información del Satélite LANDSAT TM

Se uso la imagen LANDSAT TM No. 2647, en formato LTM, de 3439 líneas por 3572 columnas, con una resolución espacial de 30 m. La imagen corresponde a la Sierra Nevada, que se encuentra al Oriente del Valle de México. Dicha imagen se utiliza como base para los procesos siguientes:

a) Georreferencia de la imagen. La imagen anteriormente mencionada se georreferenció haciendo uso de 20 puntos de control, eliminando 5 puntos (los de mayor error). Los puntos son localizaron en la carta topográfica de INEGI (E14B31-CHALCO), usando la opción del tipo de proceso (*RESAMPLE*) polinomial y la función cuadrática, con un error medio cuadrático (RMS) de 2.077, mostrándose el resultado de la georreferencia en el Anexo I.

b) Recorte de la imagen. Se desplegó la imagen georreferenciada compuesta de las bandas 7, 4 y 2 para la localización del área de estudio y realizar el recorte final dentro de las coordenadas *UTM (Universal Transversal Mercator)*: **X** de 515000 a 535000 y **Y** de 2138000 a 2154500, quedando el recorte de 666 columnas y 550 renglones.

c) Proceso de la imagen. Una vez que se recorta el área de estudio, se aplicó a las siete bandas *análisis de componentes principales* reduciéndolas a tres componentes, esta transformación a las bandas originales se realizó por medio del *PCA* de *IDRISI*. El objetivo de este proceso es resumir un grupo amplio de variables (7 bandas) en un nuevo conjunto, más pequeño (3 bandas), sin perder una parte significativa de la información original, enfatizando la representación de la vegetación y los suelos desnudos (Chuvieco, 1990).

5.2.2.2. Información del Modelo de Elevación Digital

Se utilizó un modelo de elevación digital (MED) de INEGI de la zona, correspondiente a la carta E14B31-CHALCO, dicho modelo contiene 702 columnas por 555 renglones, con una resolución de 50 m. Una vez que se aceptó el modelo por medio del módulo *DOCUMENT* de *IDRISIW*, se cambió la resolución del pixel a 30 m. por medio de *RESAMPLE* de *IDRISIW*, al mismo tiempo se realizó el recorte del MED con las coordenadas **X** que van de 515000 a 535000 y **Y** de 2138000 a 2154500, teniendo el mismo tamaño de la subimagen y así sobreponer la información obtenida con las imágenes de satélite y demás información generada.

a) Elaboración de mapa de exposición. El mapa digital de exposiciones en grados se obtuvo mediante la opción *SURFACE*, teniendo como entrada el MED, al mapa resultante se le aplicó una reclasificación con la opción *RECLASS*.

b) Elaboración de mapa de pendiente. Para el mapa de pendiente se aplicó la misma instrucción que en el procedimiento anterior (*SURFACE*), y reclasificando con la opción *RECLASS*.

5.2.2.3. Información Cartográfica

En esta fase se proceso la información referente a los escurrimientos, edafología, geología y vegetación fueron digitalizados en el software AUTOCAD versión 14. sobre a información cartográfica de INEGI previamente escaneado (topografía, edafología, geología y uso de suelo y vegetación), los cuales se importaron del formato DXF a *IDRISIW* con la opción *IMPORT/EXPORT*, quedando como mapa *vector*.

a) Elaboración de mapa de distancia a los escurrimientos. Ya realizado la importación se transformo el mapa de escurrimientos al formato *raster* (*RASTER/VECTOR conversion: LINERAS*), dando un proceso intermedio para obtener la imagen booleana (valor de 1 para los escurrimientos y 0 para zonas sin escurrimientos) útil para calcular la distancia a los escurrimientos al aplicar el procedimiento de *DISTANCE*, obteniendo el mapa de distancia a escurrimientos.

b) Elaboración de los mapas. Una vez que se importaron los mapas edafológico, geológico y de vegetación en formato *vector* de *IDRISIW*, se transformaron a formato *raster* con la opción *RASTER/VECTOR conversion: POLYRAS*.

5.2.2.4. Formación de la Base de Datos

La base de datos contiene los valores de tres componentes principales, altitud, exposición, pendiente, distancia a los escurrimientos, geología, edafología y vegetación, formado de cada pixel del área de estudio mediante un programa realizado en SAS (Anexo II). Este lee los datos de las imágenes contenidas en *IDRISIW* convertidos a formato de números reales enteros y ASCII, por medio de la opción *CONVERT*; resultando una matriz de 666 columnas por 550 renglones, teniendo 366 300 observaciones, por cada uno de los mapas.

5.2.2.5. Procesamiento de Datos con Redes Neuronales

En este estudio se aplicó la RNA con el fin de análisis de datos, ya que son capaces de procesar una basta cantidad de datos y hacer predicciones que algunas veces son sorprendentemente exactas.

a) Adecuación de información. Con el archivo con extensión TXT generado en la fase previa se construyó la red neuronal artificial dentro del software NeuroShell 2 de la siguiente manera:

- Se ingresa en el módulo de importación de archivos, indicando el tipo de archivo (TXT), transformándolo en un archivo con extensión PAT.

- Una vez que se ingresó la información, esta se pasa al modulo de construcción de la RNA, en la cual se define la entrada y salida a la red, indicando que las entradas fueron las variables independientes (acp1, acp2, acp3, altitud, exposición, pendiente, distancia, edafología y geología) y la variable dependiente (vegetación). De esta forma se le indica a la red como debe procesar la información.
- Después que se aceptaron los datos y se creó el archivo PAT, éste se secciono en tres archivos que fueron: TRN (archivo de entrenamiento), TST (archivo de prueba) y PRO (archivo de producción), para ser procesados según las fases siguientes.

b) Fase de entrenamiento. Para realizar esta fase se debe elegir la arquitectura y los parámetros de RNA como son: índice de aprendizaje, el momento, los pesos iniciales. También se indica el criterio de entrenamiento y el momento de paro del entrenamiento de la RNA.

Una vez que se indicaron los parámetros necesarios se inicia el proceso de aprendizaje de la RNA, cuyo tiempo varió según la cantidad de datos y el equipo de cómputo (pueden ser varias horas).

Terminado el proceso de aprendizaje de la RNA, se aplica a la red creada el archivo de datos procesados (archivo con extensión TRN). La aplicación de la red proporciona datos estadísticos (r^2 , error cuadrado medio, error absoluto promedio, error absoluto mínimo, error absoluto máximo y coeficiente de correlación) que indican el desempeño de la red.

c) Fase de prueba. Una vez que ha sido entrenada la red, se aplican los parámetros obtenidos de la fase de entrenamiento al archivo con extensión TST (datos que nunca ha visto la red), generando datos estadísticos (antes mencionados), indicando como se comportan los datos a través de la RNA.

d) Aplicación de la RNA. Una vez que se ha entrenado la red con los datos del muestreo, se aplicó los parámetros obtenidos al total de datos recolectados de la información cartográfica, generando así los datos predichos por la red.

5.2.2.6. Reconstrucción de la Imagen

Después de que la información fue procesada por la RNA se exportan los datos a formato texto, se construye el encabezado de la imagen en *WORD* y se importa al programa *IDRISI* con ayuda del módulo de *IMPORT/EXPORT* para la manipulación, visualización e impresión del mapa de coberturas forestales.

6. RESULTADOS

6.1. Procesamiento de imagen

Al procesar la información de la imagen LANDSAT TM, se encontró que el primer componente (Figura 14), presenta una fisonomía muy similar a la de una imagen pancromática, con una valoración diferenciada en la mayor parte de las cubiertas, proporcionando valores bajos en los cuerpos de agua así como en la vegetación y altos en los suelos desnudos. El segundo componente principal (Figura 15), remarca con claridad los cuerpos de agua. Por el contrario, la vegetación se manifiesta en tonos gris medio a gris claro. Y el tercer componente (Figura 16), evidencia todos los sectores con una actividad clorofílica intensa, como son los cultivos de riego.

Por lo que la varianza original asociada con cada uno de estos componentes fue de 80.54% para el primer componente, 9.78% para el segundo y 5.57% para el tercero, obteniendo un 95.89% de la variabilidad total de las 7 imágenes,




Figura 14. Primer componente principal.




Figura 15. Segundo componente principal.




Figura 16. Tercer componente principal.

6.2. Información del Modelo de Elevación Digital

Considerando que la vegetación esta estrechamente ligada a la fisiografía del terreno, se trabajo con Modelos de Elevación Digital (MDE), cuya principal característica es proporcionar datos altimétricos e información de pendientes y de exposición del terreno.

Con la información del MED se obtuvo el mapa de altitud por rangos de 100 m. que va desde 2000 hasta 4100 msnm (Figura 17). La información fue procesada por rangos y por datos de altitud continua.

Así como el mapa de exposición (Figura 18), a partir del cual se definieron 8 clases de exposición que se muestran en el Cuadro 1. En este mapa se encontró que la mayoría del área tiene una exposición hacia el oeste (6257.38 ha), suroeste (5727.20 ha) y sur (5036.30 ha), esto propicia un mayor tiempo de exposición al sol, generando microhábitat más secos, que en regiones con exposición norte y/o noreste.

Cuadro 1. Clases de exposición.

CLASE	NOMBRE	SUPERFICIE(ha)
1	NORTE	4259.70
2	NORESTE	2206.12
3	ESTE	1999.81
4	SURESTE	2625.40
5	SUR	5036.30
6	SUROESTE	5727.20
7	OESTE	6257.38
8	NOROESTE	4892.97




Figura 17. Mapa de altitud (msnm).




Figura 18. Mapa de exposición.

El mapa de pendiente obtenido (Figura 19), muestra que en la zona de estudio se presentan cuatro tipos de pendientes (Cuadro 2), predominando los terrenos ondulados (14851.53 ha) y escarpados (10362.97 ha) que se distribuyen uniformemente.

Cuadro 2. Rangos de pendientes.

CLASE	NOMBRE	% DE PENDIENTE	SUPERFICIE (ha)
1	PLANO	0-9.99	751945.00
2	ONDULADO	10-29.99	14851.53
3	ESCARPADO	30-99.99	10362.97
4	ABRUPTO	> 100	275.04




Figura19. Mapa de pendiente del terreno.

La consideración de las corrientes hidrológicas se hizo mediante la construcción de un mapa de distancias (Figura 20), como lo sugiere Blackard (1998), obteniéndose 14 rangos de distancias que van de 81 a 1140 metros con categorías de 81 metros.




Figura 20. Mapa de distancia a los escurrimientos.

6.3. Información Cartográfica

La información cartográfica que se utilizó fue extraída de mapas temáticos de INEGI generados en 1973, propiciando desfases en la información, aunque en lo referente a edafología y geología no hay cambios significativos a través del tiempo, en cuanto a los tipos de vegetación se actualizó la información con ortofotomapas y recorridos en campo.

Para el mapa edafológico de la región se encontró que existen 36 categorías edáficas como se observa en la Figura 21, resumiéndose en 6 unidades básicas, siendo el suelo Cambisol la clase de mayor superficial con 763988.81 ha (Cuadro 3).

Cuadro 3. Clases edafológicas.

CLASE	ASIGNACION	NOMBRE	SUPERFICIE (ha)
1	B	CAMBISOL	763988.81
2	H	FEOZEM	7053.5
3	I	LITOSOL	2196.92
4	R	REGOSOL	2.1
5	T	ANDOSOL	4117.45
6	V	VERTISOL	75.76

En lo referente al mapa geológico, se encontró 7 clases (Cuadro 4), predominando las Andesitas (A) con una superficie de 21803.33 ha, distribuida a través de la región alta, y en la parte baja brecha sedimentaria (bs), con 9876.66 ha, las clase restantes se distribuyen en toda la zona de estudio como se observa en la Figura 22.




Figura 21. Mapa edafológico.




Figura 22. Mapa geológico.

Cuadro 4. Clase material geológico.

CLASE	ASIGNACION	NOMBRE	SUPERFICIE (ha)
1	A	ANDESITA	21803.33
2	Agre	AGREGADO	1.9
3	Al	ALUVION	511.35
4	B	BASALTO	81.17
5	Bs	BRECHA SEDIMENTARIA	9846.66
6	Bvb	BRECHA BASALTICA	18.37
7	Tb	TOBA BASALTIVA	739.09

La zona de estudio se caracteriza por presentar diferentes tipos de (Figura 23), los cuales fueron agrupados en 4 clases, sin tomar las asociaciones entre estas

comunidades, asignando una clase más, que considera a toda aquella área que no pertenece a vegetación forestal, como son las zonas de cultivos agrícolas, tanto de riego como de temporal, zonas erosionadas, bancos de préstamo de material (minas), principalmente. Las clases utilizadas se observan en el Cuadro 5. La información obtenida de este mapa se utilizó como variable dependiente para entrenar la red neuronal (como maestro y/o testigo).

Cuadro 5. Tipos de vegetación.

CLASE	ASIGNACION	NOMBRE	SUPERFICIE (ha)
No Ftal	No Ftal.	No Forestal	8872.43
1	Ba	Bosque de Abies	2414.32
2	Bp	Bosque de Pino	14694.86
3	Bq	Bosque de Encino	1256.30
4	Pi-Mi	Pastizal-Matorral	5762.07




Figura 23. Mapa de vegetación.

6.4. Formación de la Base de Datos

La matriz que resulto al unir los datos, consta de 9 variables (acp1, acp2, acp3, altitud, exposición, pendiente, distancia a los escurrimientos, edafología, y geología) y 366300 observaciones. Para procesar la información con el software *NEUROSHELL 2 versión 3.0* se utilizó un subconjunto de los datos, aproximadamente el 1% de la población total (5855 observaciones). Los datos fueron extraídos al azar por medio de un programa en SAS (Anexo III), generando un archivo con extensión TXT.

6.5. Procesamiento de Datos con Redes Neuronales

Para el procesamiento de la información mediante el modelo de redes neuronal, se dividió en tres fases: entrenamiento, prueba y aplicación.

6.5.1. Fase de Entrenamiento

La arquitectura final de la red neuronal que dio mejor resultado, después de probar varios algoritmos de entrenamiento y diferentes números de capas, quedo de la siguiente manera:

Red neuronal de 4 capas que son:

- 9 neuronas de entrada.
- 36 neuronas en la primera capa oculta.
- 36 neuronas en la segunda capa oculta.
- 1 neurona en la capa de salida.

Cada una de estas capas contiene una función de activación, las cuales son:

- Lineal(-1,1).
- Tangh15 (Tangencial Hiperbólica).
- Gaussian (Gausiana).
- Logistic (Logística), respectivamente.

Como se mencionó en la metodología y con la arquitectura anterior, la etapa de entrenamiento de la red neuronal se realizó utilizando el algoritmo de retropropagación (backpropagation), dicho proceso se corrió sobre los datos de entrenamiento que constan de 5855 patrones (1%), que fueron obtenidos de manera aleatoria de la población, los cuales se dividieron en 60% de patrones de entrenamiento (4392) y 40% de patrones de prueba, dicho datos fueron conformados con un vector de entrada de 9 variables (unidades o neuronas) que consta de 7 bandas del satélite LANDSAT TM transformadas en 3 componentes principales (ACP), altitud, exposición, pendiente del terreno, distancia a escurrimientos, geología y edafología; estas conforman las variables independientes, y la vegetación que es la variable dependiente, con las cuales se entrena la red. Con la

ayuda de *Neuroshell 2*, se entrenó y probó exitosamente a la arquitectura antes propuesta en alrededor de 26 horas, utilizando para ello 672 épocas, con un error mínimo de 0.0025413. En la Figura 24 se muestra la precisión alcanzada en esta etapa, resultando una $r^2=0.8617$ y un coeficiente de correlación de 0.9283.

La red neuronal encontró los pesos más adecuados (Cuadro 6) para la generalización de los patrones hacia toda la población. En el Cuadro 6 observamos que las variables que tienen mayor importancia fueron en primer lugar la altitud con 0.21060, la edafología con un 0.13269 y el componente principal de las imágenes de satélite con 0.12051.




Figura 24. Precisión de la red en la fase de entrenamiento.

Cuadro 6. Pesos sinápticos por variables ambientales

VARIABLES AMBIENTALES	PESOS
ACP1	0.12051
ACP2	0.08458
ACP3	0.07631
Altitud	0.21060
Exposición	0.10298
Pendiente	0.09512
Distancia a Escurremientos	0.07638
Edafología	0.13269
Geología	0.10083

6.5.2. Fase de Prueba

Con fines de validación del sistema se utilizaron 1463 patrones de prueba por cada tipo de vegetación, es decir 9 variables con su correspondiente tipo de vegetación.

Encontrando un $r^2=0.8514$ y un coeficiente de correlación de 0.9227, cómo se observa en la Figura 25.




Figura 25. Precisión de la red en la fase de prueba.

6.5.3. Aplicación de la Red Neuronal

Una vez que ha sido entrenada y probada la red, se aplica el modelo a todos los datos obtenidos de la región de estudio. Para esta fase se dividieron los datos en 36 subconjuntos, cada uno con 10 000 registros, con sus 9 variables y 1 con 6300 registros con sus correspondientes variables. Esto se llevo acabo por la dificultad que tienen el *NeuroShell* para procesar gran cantidad de datos. Al procesar estos 37 subconjuntos, se obtuvo su correspondiente r^2 , que varían de 0.4109 a 0.8507, como se pueden observar en el anexo IV.

Para determinar cuales clases presentaron confusión, se construyó una matriz (Cuadro 7), donde se observan los sitios que la red clasificó de manera correcta y cuales sitios se clasificaron dentro de otra clase. Encontrando que la clase de Bosque de Encino (Bq) tiene el menor porcentaje de clasificación con 26.09%, teniendo una mayor confusión con las clases de Pastizal-Matorral (Pi-Mi) y Bosque de Pino (Bp). En cambio, las tres clases restantes ofrecen una mejor discriminación entre ellas, reflejándose en su mayor porcentaje de aciertos, teniendo el mejor resultado la clase de Pastizal-Matorral con un 93.99% de sitios clasificados correctamente.

Cuadro 7. Matriz de confusión.

Clase Original Clase Procesada	Ba	Bp	Bq	Pi-Mi
Ba	76.81	20.53	0.76	1.90
Bp	8.52	82.63	1.16	7.09
Bq	1.97	30.32	26.09	41.61
Pi-Mi	0	1.70	4.31	93.99

En lo referente al uso de redes neuronales en comparación con las metodologías tradicionales se logro incrementar la precisión de 75% encontrada por Buendía (1996) utilizando únicamente imágenes de satélite, a un 83% resultado del modelo de predicción de RNA y variables cartográficas como son: altitud, edafología, geología, exposición, pendiente y distancia a los escurrimientos.

6.6. Reconstrucción de la Imagen

Al reconstruir la imagen (Figura 26), analizada mediante redes neuronales, se encontró que estas conserva las clases que se describen en el cuadro 5, no obstante el análisis hecho mediante redes neuronales nos señala que existen algunas unidades clasificadas incorrectamente, esto es debido a la forma de procesar la información (por segmentos), ya que como se menciona con anterioridad, no se puede procesar toda la información en *NeuroShell*.




Figura 26. Imagen clasificada con redes neuronales artificiales.

El área con mayor superficie incorrectamente clasifica, se encuentra ubicada en la parte inferior izquierda de la imagen, en la cual se observa una región clasificada como pastizal, en cambio en la imagen infrarrojo (Figura 27) encontramos esa misma zona cubierta por agricultura, atribuyendo este error al proceso de clasificación con base a la red neuronal.




Figura 27. Imagen LANDSAT TM, composición infrarrojo.

7. DISCUSIÓN DE RESULTADOS

En relación a las variables que se emplearon, se encontró que dos de ellas la RNA le asignó los mayores pesos (ó ponderaciones), resultando 0.21060 y 0.13269 para las clases altitud y edafología, respectivamente. Esto resulta lógico desde el punto de vista ecológico, puesto que la vegetación responde principalmente al gradiente altitudinal.

Al aplicar el Análisis de Componentes Principales (ACP) a las bandas originales, resulto tres componentes principales obteniendo el 95.89% de la varianza original de la imagen, el 80.54% para el primer componte, proporcionando mayor información de las coberturas forestales. Esto se observo cuando se calculo los pesos sinápticos, ya que el ACP1 quedo como el tercer lugar en importancia con un peso de 0.12051, es decir, que es la tercer variable que aportó mayor información al entrenamiento de la red, para la predicción de coberturas.

Con respecto al comportamiento de las clases el Bosque de Encino (Bq) presenta un menor porcentaje de aciertos debido a los disturbios que ha sufrido esta zona, encontrando que ha sido constantemente afectada por el fuego y por la corta clandestina de madera, principalmente para la obtención de carbón. Otra razón por la que este tipo de cobertura ofrece mayor confusión es porque no son de distribución uniforme, encontrando varios arbustos y pastos entre los arboles de encino. De aquí que tenga mayor confusión con la clase de pastizal-matorral (Pi-Mi).

Los resultados obtenidos en este estudio alcanzan mayor precisión a la reportada por Marquéz (1998), quien alcanzó un 82.4% de precisión, utilizando imágenes de satélite y variables cartográficas como la topoforma y exposición procesadas con métodos tradicionales basados en estadística, aunque al compararlo con el resultado del filtrado de moda, quedo por debajo, ya que la precisión alcanzada por Marquéz fue de un 91.91%.

En cuanto a estudios con características similares (proceso con redes neuronales), se superó al estudio realizado por Blackard y Dean (1998), el cual logró un 70.58% de precisión, superando aún más al estudio con *Análisis Discriminante*, el cual obtuvo un 58.38%. Timmermans (1996), menciona que a medida que los patrones son más complejos el clasificador basado en redes neuronales presenta menor error comparado con el clasificador estadístico, lo cual es aplicable al presente trabajo, dado la gran variabilidad de patrones utilizados.

8. CONCLUSIONES Y RECOMENDACIONES

En base a los objetivos y resultados obtenidos se concluye y se hacen las siguientes recomendaciones.

8.1. Conclusiones

Se corroboró la eficiencia de las RNA para la clasificación de patrones que presenta gran variabilidad, como es el caso del presente trabajo.

El presente estudio aporta fundamentos para implementar una nueva técnica como son las Redes Neuronales Artificiales en la predicción de coberturas, probando que alcanzan una mayor precisión que las formas convencionales de clasificación y/o modelos de predicción.

Las RNA son una técnica nueva en el ámbito forestal, por lo que su implementación se debe de llevar con cautela. Aunque se pueden aplicar para resolver diversos problemas que requieren una gran cantidad de información para una adecuada toma de decisiones.

Con la aplicación de RNA es posible introducir una gran cantidad de parámetros ambientales, puesto que una vez entrenada la red todos los datos que se le presenten a la RNA serán procesados casi en tiempo real.

8.2. Recomendaciones

En base a los resultados obtenidos se recomienda lo siguiente:

- Probar diferentes topologías y funciones de activación para estudios con similares características.
- Utilizar más variables ambientales, por ejemplo incidencia solar como lo hizo Blackard (1996), o apertura del dosel, distribución de rodales, etc.
- Procesar la información sobre plataforma Linux o Unix, para reducir tiempo de entrenamiento de la red.
- Desarrollar un Software con capacidad para procesar gran cantidad de información.
- Realizar la fase de entrenamiento con una muestra que sea obtenida por un muestreo por conglomerado. Para que la muestra sea distribuida conforme a la superficie de cada clase.
- Aplicar filtros adaptativos a las imágenes de satélite, por ejemplo logarítmicos, o filtros de moda (utilizado por Marquez, 1998).
- Realizar estudios sobre RNA en diferentes sectores del manejo forestal.

- Realizar varios estudios de RNA en imágenes de satélite de mayor resolución, como sería el satélite Indú (IRS), el satélite IKONOS, o imágenes hiperespectrales, los cuales tienen una resolución de un metro.

- Probar diferentes técnicas de entrenamiento de RNA como los *Algoritmos Genéticos y/o lógica difusa*.

9. LITERATURA CITADA

- ADAME, M. S. 1991. Cartografía y evaluación de las plantaciones forestales en la parte oriente de la Cuenca de México. Tesis de Maestría. Colegio de Posgraduados. Montecillos, Méx.
- ANTOGNETTI, P.; VELJKO, M. 1991. Neural networks: concepts, applications, and implementations. Vol 1. Prentice Hall. USA. 223 p.
- BLACKARD, J A.; D. J. DEAN. 1996. Evaluating integrated artificial neural network and gis techniques for predicting likely vegetative cover types. In: Porceedings of the First Southern Forestry GIS Conference (greg J. Arthaud and William C. Hubbard, editors). University of Georgia. Athens, Georgia. Pag 151-159.
- BLACKARD, J A.; D. J. DEAN. 1998. Comparative accuracies of neural networks and discriminat analysis In Predicting Forest Cover Types From Cartographic Variables. <http://www.verinet.com/~blackard/sofor98.htm>.
- BLUM, A. 1992. Neural networks in C++. An object-oriented framework for building connectionist systems . Wiley. New Yord. 212 p.
- BUENDIA, R. E. 1996. Aplicación de imágenes de satélite en la cartografía de usos de suelo y vegetación en una región del oriente del Valle de México. Tesis de Licenciatura. División de Ciencias Forestales, Universidad Autónoma Chapingo. México. 97 pág.
- CHUVIECO, M. E. 1990. Fundamentos de teledetección espacial, ediciones Rialp, S.A. Madrid España. 453 p.
- GARCIA, E. 1981. Modificaciones al sistema de clasificación climática de Koppen. Offset Larios México, D:F: 286 p.

DEADMAN P. J; BRANY G. H. Application of neural net based techniques to vegetation management plan development.
<http://srnr.arizona.edu/~gimblett/aidead97.html>.

HAYKIN, S. 1994. Neural networks: a comprehensive foundation. macmillan publishing company. Toronto, Canada. 696 p.

INSTITUTO NACIONAL DE ESTADÍSTICA GEOGRAFÍA E INFORMÁTICA.
1985. Cartas Edafológicas Esc. 1: 50 000.

INSTITUTO NACIONAL DE ESTADÍSTICA GEOGRAFÍA E INFORMÁTICA.
1985. Cartas Geológicas Esc. 1:50 000.

INSTITUTO NACIONAL DE ESTADÍSTICA GEOGRAFÍA E INFORMÁTICA.
1985. Carta Topográfica Cartas Esc. 1: 50 000.

INSTITUTO NACIONAL DE ESTADÍSTICA GEOGRAFÍA E INFORMÁTICA.
1985. Cartas de Vegetación y Uso de Suelo Esc. 1:50 000.

KOHONEN, T. 1988. An Introduction to Neural Computing. Neural Networks. Vol 1.
Pag 3-16.

LAI P, L y FYFE, C. 1999. Aneural Implementati3n of Canonical Correlation Analysis.
Elsevier Science Ltd: Neural Networks, Vol. 12(10) 1391-1397 pp.

LEYVA O., A. 1999. Clasificador de tipos de par3nquima en madera, usando redes neuronales para una sistema de identificaci3n de maderas mexicanas. Tesis de Maestría. Colegio de Postgraduados, Montecillos, M3xico. 68 p3g.

- MARQUEZ, L., M. A. 1998. Cartografía de asociaciones arbóreas mediante imágenes de satélite landsat tm y modelos de relación asociación-topografía. Tesis de Maestría. División de Ciencias Forestales, Universidad Autónoma Chapingo, Chapingo, México. 78 pag.
- MARTÍNEZ; VELÁZQUEZ. 1996. Técnicas de redes neuronales aplicadas al reconocimiento y clasificación de pixeles de imágenes de satélite. IV Simposio Nacional de Predicción. Madrid España.
- MARTÍNEZ, C., A. 1997. Determinación de la relación espectral entre características de la cubierta terrestre y datos de imágenes de satélite LANDSAT TM. Tesis de Licenciatura. División de Ciencias Forestales, Universidad Autónoma Chapingo. Chapingo, México. 61 p.
- MOKKEN, R. 1995. Remote sensing, statistic and artificial neural networks. some & perspectives. University of Amsterdam. <http://ltpwww.gsfc.nasa.gov/ISSSR-95/remotes3.htm>.
- MUTTIAH, R; SRINIVASAN R; ENGEL B. Development and application of neural network interfece for grass Gis. http://www.sbg.ac.at/geo/idrisi_environmental_modeling/st_papers/muttiah.../muttiah.htm.
- NOGUEZ, H. R. 1993. Comparación entre imágenes LANDSAT Thematic Mapper (TM) y Multiespectral Scanner (MSS) en la clasificación de uso de suelo. Tesis de Lincenciatura. División de Ciencias Forestales, Universidad Autónoma Chapingo, Chapingo, México. 115 p.
- PETERSEN, G. W., NIELSEM, G.A. WILDING L. P. 1991. Geographic Information System and Remote Sensing in land resouces análisis and management. Suelo y planta 1-4 pp. 531-543 pp.

- ROJAS, R. 1996. Neuronal networks: a systematic introduction. Springer-Verlag. Germany 494 p.
- RUMELHART, D., G. HINTON Y WILLIAMS, R. 1986. Learning representations by backpropagating errors. Nature. No. 323. Pags. 533-536.
- SALAS, M., I. 2000. Redes neuronales artificiales en la medición de temperatura y humedad relativa. Tesis de Licenciatura. Dpto. Irrigación, Universidad Autónoma Chapingo. México. 151 p.
- SARLE S: W. (a). 1994. Neural networks and statistical models. . Proceedings of the Nineteenth, Annual SAS Users Group Internatinal Conference.
- SARLE S. W.(b). 1994. Neural Networks In SAS Software. Proceedings of the Nineteenth, Annual SAS Users Group Internatinal Conference.
- SHARDA, R. 1994 Neural Networks for the MS/OR analyst: An aplication bibliography. Interfaces 24(2):116-130.
- TIMMERMANS, A. J. y HULZEBOSCH, A. A. 1996. Computer vision system for on-line sorting of pot plants using an artificial neural network classifier. Computers and Electronics in Agriculture. 15 (1996). pp 41-55.
- ZHOU, J.; CIVCO, D. Using genetic learning neural network for spatial decision making_in_GIS.
<http://www.lib.ucom.edu/CANR/nrme/leris/projects/overlay.html>.

10. ANEXOS

Anexo I. Resultado de la georreferencia de la imagen LANDSAT TM.

Resample : Summary of Transformation

Computed polynomial surface : Quadratic (based on 15 control points)

Coefficient	X	Y
b0	199253.2193546295170000	-122325.3117580413820000
b1	0.0361163713571955	-0.0041580524183047
b2	-0.1974965961235284	0.0793613998275760
b3	-0.0000000193630289	-0.0000000011766305
b4	0.0000000089171480	0.0000000050266090
b5	0.0000000437111231	-0.0000000110323286

Note : Figures are carried internally to 20 significant figures.
Formula shown is the back transformation (new to old).

Control points used in the transformation :

Old X	Old Y	New X	New Y	Residual
136.000000	654.000000	518250.000000	2155100.000000	omitted
57.000000	481.000000	516020.000000	2151750.000000	2.366511
425.000000	560.000000	526600.000000	2152250.000000	2.366475
699.000000	623.000000	534550.000000	2152950.000000	2.118886
1013.000000	668.000000	543700.000000	2152750.000000	1.181690
35.000000	449.000000	515350.000000	2150850.000000	1.497119
544.000000	380.000000	529500.000000	2140250.000000	omitted
943.000000	356.000000	540450.000000	2144250.000000	1.122506
3.000000	332.000000	514000.000000	2147700.000000	1.360674
156.000000	320.000000	518650.000000	2146750.000000	omitted
536.000000	295.000000	528050.000000	2144350.000000	omitted
948.000000	299.000000	540350.000000	2142700.000000	1.682764
32.000000	214.000000	514250.000000	2144250.000000	0.524874
521.000000	212.000000	527850.000000	2142050.000000	1.174591
949.000000	216.000000	539900.000000	2140350.000000	3.206632
78.000000	96.000000	515000.000000	2140650.000000	2.644891
70.000000	17.000000	514400.000000	2138600.000000	2.157219
519.000000	49.000000	529350.000000	2137150.000000	omitted
723.000000	111.000000	533200.000000	2138400.000000	3.727429
999.000000	56.000000	540650.000000	2135600.000000	1.411938

Overall RMS = 2.077581

Note : RMS Error is expressed in output map units.

With low RMS errors, be careful that an adequate sample exists
(eg. 2-3 times the mathematical min).

Anexo II. Programa en SAS para formar la matriz de datos.

```
/* PROCEDIMIENTO PARA ABRIR LOS DATOS EN UNA COLUMNA */

data is1; infile 'e:\enrique\tesis_mc\tes_dat\is1.dat'; input acp1;
data is2; infile 'e:\enrique\tesis_mc\tes_dat\is2.dat'; input acp2;
data is3; infile 'e:\enrique\tesis_mc\tes_dat\is3.dat'; input acp3;
data alt; infile 'e:\enrique\tesis_mc\tes_dat\altitud.dat'; input alt;
data exp; infile 'e:\enrique\tesis_mc\tes_dat\expos.dat'; input exp;
data pend; infile 'e:\enrique\tesis_mc\tes_dat\pend.dat'; input pend;
data dist; infile 'e:\enrique\tesis_mc\tes_dat\distan.dat'; input dist;
data eda; infile 'e:\enrique\tesis_mc\tes_dat\edafos.dat'; input eda;
data geol; infile 'e:\enrique\tesis_mc\tes_dat\geolos.dat'; input geol;
data veg; infile 'e:\enrique\tesis_mc\tes_dat\vegeta.dat'; input veg;
run;

/* CREA UNA LIBRERIA */

libname datos 'e:\enrique\tesis_mc\tes_dat';

/* DAR NOMBRE A LAS CLASES */

proc format;
  value vegnom
    1='BA'
    2='BP'
    3='BQ'
    4='PI'
run;

/* PROCEDIMIENTO PARA UNIR DATOS EN UNA MATRIZ Y GUARDARLO EN LA
LIBRERIA DATOS */

data datos.sasdat1;
merge acp1 acp2 acp3 alt exp pend dist eda geol veg;
run;
```

Anexo III. Programa para extraer datos al azar en SAS.

```
/* CREA UNA LIBRERIA */  
  
libname prueba 'e:\enrique\tesis_mc\tes_dat';  
  
/* PROCEDIMIENTO PARA EXTRAER UNA MUESTRA ALEATORIA UNIFORME DE DATOS  
*/  
  
data prueba.datos8;  
infile 'e:\enrique\tesis_mc\tes_dat\sasdat1.dat';  
input acp1 acp2 acp3 alt exp pend dist eda geol veg;  
x=ranuni(4);  
if x>0.02 then delete;  
run;
```

Anexo IV. Resultados obtenidos de la aplicación de la red neuronal (r^2).

No. de subconjunto	r^2	No. de subconjunto	r^2
1	0.7885	20	0.7144
2	0.6545	21	0.7976
3	0.4218	22	0.8008
4	0.4818	23	0.6475
5	0.6535	24	0.7531
6	0.6204	25	0.8235
7	0.8507	26	0.7820
8	0.4070	27	0.6348
9	0.4514	28	0.6113
10	0.7523	29	0.5606
11	0.7003	30	0.5837
12	0.6846	31	0.6006
13	0.7072	32	0.8273
14	0.4162	33	0.8450
15	0.8073	34	0.5132
16	0.4109	35	0.6276
17	0.6370	36	0.5647
18	0.6870	37	0.6289
19	0.7660		

