

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

E. Buendía-Rodríguez¹; E. Vargas-Pérez²; Á. Leyva-Ovalle²; S. Terrazas-Domínguez²

¹INIFAP, Campo Experimental Valle de México. Apdo. Postal No. 307. C. P. 56101. Chapingo, México. E-mail:ebuendia_uach@yahoo.com

²División de Ciencias Forestales de la Universidad Autónoma Chapingo. Chapingo Estado de México. C.P. 56230.

RESUMEN

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 y la ejecución de programas de manejo forestal. Un método para la obtención de este tipo de información es a través de modelos de predicción. El presente estudio tiene 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 basaron en información geográfica (altitud, exposición, pendiente, distancia a los escurrimientos, geología y edafología) e imágenes de satélite haciendo uso del análisis de componentes principales (acp1, acp2 y acp3), para definir 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 otros autores con métodos tradicionales.

PALABRAS CLAVE: sensores remotos, SIG, redes neuronales, coberturas forestales.

APPLICATION OF ARTIFICIAL NEURONAL NETWORKS AND GIS TECHNIQUES IN THE PREDICTION OF FOREST COVERS

SUMMARY

Mexico, like the rest of the world, needs to make an inventory of their forest resources in order to plan and execute forest management programs in a timely and appropriate way. A method for the obtaining this type of information is through prediction models. This study was conducted to evaluate the ability of the artificial neuronal networks (ANN) to predict types of forest coverings. The ANN was based on geographic information (altitude, aspect, slope, distances to the rivers, geology and edafology) and satellite images transformed with a principal components analysis (ACP1, ACP2 and ACP3), to define the dependent variable (vegetation). This information was processed with a back-propagation ANN with two hidden layers, with its respective activation functions (tangential hyperbolic and Gaussian). An $r^2=0.8617$ for the phase of training and $r^2=0.8514$ in the test phase were obtained, achieving 83% correctly predicted sites. This exceeds values reached by other authors using traditional methods.

KEY WORDS: remote sensing, GIS, neural networks, forest cover.

INTRODUCCIÓN

En varios sectores de la sociedad mexicana la preocupación por la pérdida desmedida de los recursos naturales de nuestro país, es considerablemente alta por los efectos que esto ocasiona en el medio ambiente, 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 los sensores remotos, sistemas de información geográfica (SIG) y modelos de simulación, han contribuido notablemente a la

solución de muchos de los problemas ocasionados por el uso indebido del recurso. Uno de los principales limitantes en el uso de estas técnicas es la baja precisión con que se evalúan los recursos naturales. Para solventar esta situación se han desarrollado varias técnicas o procedimientos que permiten un mayor grado de confiabilidad.

Por tanto, para mejorar la precisión de la cartografía de la vegetación por medios remotos (imágenes de satélite), los investigadores se han valido de información auxiliar, tal como clima, suelo, topografía, etc. Esta información se

utiliza en procesos de clasificación mediante diferentes metodologías, de aquí que en años recientes se han estado desarrollando metodologías basadas en una técnica denominada Redes Neuronales Artificiales, RNA.

Por ello el presente trabajo tuvo como objetivo determinar un modelo para la predicción de tipos de coberturas vegetales a través de redes neuronales artificiales, alimentada con información satelital y cartográfica, en la región del cerro del Telapón que se encuentra ubicado en la Sierra Nevada, al oriente del Valle de México.

Las redes neuronales artificiales 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, 1994). Estas consisten de un gran número de neuronas (elementos básicos de cómputo) 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 humano 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.

Las redes neuronales son principalmente usadas en cuatro formas: modelos de sistemas nerviosos biológicos, inteligencia artificial, adaptador en tiempo real de procesos simples o implemento de control en hardware para aplicaciones, tales como: robótica, análisis de datos y reconocimiento de patrones.

Teniendo en cuenta que una red neuronal se caracteriza por un patrón de *conexiones entre neuronas* (arquitectura o topología), el método para determinar los pesos (ponderaciones) sobre las conexiones (entrenamiento o aprendizaje), y su *función de activación*. La *neurona* (X_i), es el elemento básico de una red neuronal; cada neurona tiene una salida, la cual está 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*. El vector de entradas se conforma por el estado de las neuronas de entrada multiplicada por los pesos de la sinapsis (W_i). La activación de la neurona es procesada por la aplicación de

una *función umbral* (q) a esta neurona (Blum, 1992). Un modelo abstracto de la neurona se muestra en la Figura 1.




Figura 1. Diagrama del modelo abstracto de la neurona.

La primera parte de una red neuronal es la *función de activación* denotada por q , la cual 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.

La segunda parte se compone de la *topología o arquitectura* de las redes neuronales que 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).

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).

Y por último la fase de aprendizaje y/o entrenamiento considerado como 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).

Estudios realizados con redes neuronales

Sharda (1994), realizó una revisión bibliográfica respecto al uso de redes neuronales, encontrando que el 71 % de los estudios publicados sobre modelos de RNA predicen mejor que las técnicas estadísticas tradicionales, que el 12 % de los estudios de RNA predicen aproximadamente igual que las técnicas estadísticas tradicionales, en tanto que sólo el 17 % de los estudios reportan que las técnicas estadísticas tradicionales son mejores que los modelos de RNA.

En tanto que Blackard y Dean (1996), realizaron un estudio para evaluar la habilidad de dos modelos espaciales, ambos basados en sistemas de información geográfica (SIG), 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 altitud, 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 mejores 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 cinco clases de parénquima utilizadas y para la fase de prueba logró un 92 % de patrones clasificados correctamente. En ese mismo año, Lai y Fyfe, 1999 derivaron un método de aplicación de análisis de correlaciones canónicas en conjunto con redes neuronales artificiales. Estos autores demostraron la capacidad de la red neuronal, cuando la estadística convencional no es efectiva. Demostrando que la combinación de estas técnicas es extremadamente efectiva en la detección de cambios en la información.

Estudios realizados con imágenes de satélite

Buendía (1996), realizó un estudio en la región oriente del Valle de México, utilizando imágenes Landsat TM y Spot con el software SPIPR II. Estableció cuatro tratamientos (componentes principales, análisis de textura, convolución y filtro pasa baja) en tres combinaciones de bandas

(Landsat TM3-TM4-TM5 y TM2-TM5-TM7, y SPOT XS1-XS2-XS3). Obteniendo que la 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 encontró un 69.07 % y con las imágenes Spot XS1-XS2-XS3 con análisis de componentes principales obtuvo un 69.07 %.

Martínez (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 ofrecidos 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 Márquez-Linares y Vargas-Pérez (1999), elaboró la cartografía de cinco asociaciones arbóreas en la microcuenca "El Tecolote", en el municipio de San Dimas, Durango. Usó dos métodos cartográficos: el primero basado en información digital del satélite Landsat TM mediante criterio de mínima distancia cuadrada generalizada (testigo); y el segundo mediante la combinación de información del satélite, información topográfica del sitio (topografía 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 de 82.42 %, y su generalización mediante un filtrado de moda, de 91.91 %.

MATERIALES Y MÉTODOS

El área de estudio se localiza al oriente del Estado de México, entre las coordenadas 19°28'30" y 19°20'30" latitud norte 98°50'30" y 98°41'30" longitud oeste. Cubre una superficie aproximada de 25,678 ha y una altitud que va desde 2400 hasta los 4120 msnm (Figura 2).

La geología del está conformada en su mayor parte por rocas sedimentarias (brecha sedimentaria), y en las partes más elevadas se encuentran rocas ígneas (andesitas, brechas volcánicas) (Adame, 1991). Los tipos de suelos del área de estudio de acuerdo con la clasificación FAO-UNESCO 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 Köppen modificada por García



Figura 2. Localización geográfica del área de estudio.

(1981), este clima se clasifica como C(Wo)(w)b(i)g. Las condiciones de clima y del sustrato varía de un lugar a otro y estas variaciones tienen que reflejarse en la existencia de comunidades vegetales (Noguez, 1993). Se observan varios tipos de vegetación como son los bosques de pino conformados por: *Pinus montezumae*, *P. pseudostrubus*, *P. hartwegii*, 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*, *Schinus molle*, entre otros (Adame, 1991).

1). Material cartográfico e información digital. La zona de estudio se encuentra ubicada en la carta de CHALCO, con clave E14B31 de INEGI, utilizándose las cartas temáticas de vegetación y uso de suelo, edafología, geología y topografía en escala 1: 50 000. También para este estudio se hizo uso de imágenes de satélite Landsat TM de 1997 y modelo de elevación digital (MED) en escala 1:50 000, con una resolución de 90 metros de INEGI.

2). Material de cómputo. Se utilizó el SIG IDRISI, para windows 98, AutoCad ver. 14, sistema de análisis estadístico (SAS) y NeuroShell 2 ver. 3.0.

METODOLOGÍA

La metodología se divide en dos etapas: recolección y adecuación de la información, y procesamiento de datos.

En la primera etapa se usó un recorte de 666 columnas por 550 renglones de la imagen Landsat TM 2647, en formato LTM, con una resolución espacial de 30 m, a la cual se le aplicó un *análisis de componentes*

principales generando tres bandas (acp1, acp2 y acp3). También se utilizó el modelo de elevación digital (MED) de INEGI escala 1:50 000 de la zona correspondiente a la carta E14B31-CHALCO, a partir del cual se generaron las capas de exposición, pendiente y altitud.

En esta misma etapa se procesó la información referente a los escurrimientos, edafología, geología y vegetación, los cuales fueron digitalizados en el software AutoCad versión 14, sobre la información cartográfica de INEGI y exportados a *IDRISIW* para procesarlos como archivo raster.

Para la segunda etapa se construyó una matriz de datos la cual contiene valores de los componentes principales (acp1, acp2 y acp3), altitud, exposición, pendiente, distancia a los escurrimientos, geología, edafología y vegetación, quedando conformada por 366 300 renglones (registros), por nueve columnas (información temática), generando un archivo con formato texto (TXT).

Con el archivo resultado de la etapa previa, se construyó la red neuronal artificial dentro de *NeuroShell 2* en los siguientes pasos:

- Se ingresa en el módulo de importación de archivos, indicando el tipo de archivo (TXT), transformándolo en un archivo con extensión PAT.
- Una vez ingresada la información se pasa al módulo 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 seccionó 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.

Generados los archivos para la fase de entrenamiento se elige la arquitectura y los parámetros de RNA como son: índice de aprendizaje, momentos y pesos iniciales. También se indicó el criterio de entrenamiento y el momento de paro del entrenamiento de la RNA.

Una vez que se indicaron los parámetros requeridos se aplicó la red al archivo de datos para el entrenamiento de la RNA (archivo con extensión TRN). La finalidad de la aplicación de la red es proporcionar 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.

Inmediatamente después de que ha sido entrenada la red, se aplicaron los parámetros obtenidos de la fase de entrenamiento al archivo con extensión TST (datos que nunca ha visto la red), generando los datos estadísticos antes mencionados, los cuales indican como se comportan la información a través de la RNA.

Después de terminado el entrenamiento y prueba de la red, se generaliza, al total de datos obtenidos de la información cartográfica, este proceso generó la predicción de datos, los cuales se utilizan para la reconstrucción de la imagen, datos que fueron importados al programa *IDRISI*, para su manipulación, visualización e impresión del mapa de coberturas forestales.

Para evaluar la clasificación, se muestreo el 1 % del área de estudio, recabando 3,660 datos a nivel píxel, tanto del mapa de INEGI de vegetación y uso de suelo como de la imagen clasificada, generando una matriz de confusión para determinar la precisión.

RESULTADOS

Con base en los objetivos planteados y a la metodología utilizada se obtuvieron los siguientes resultados.

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, quedó conformada por cuatro capas; nueve neuronas en la capa de entrada, 36 neuronas en la primera capa oculta, 36 neuronas en la segunda capa oculta y una neurona en la capa de salida. Cada una de estas capas contiene una función de activación, lineal (-1,1), tangh15 (Tangencial Hiperbólica), gaussian (Gausiana) y logistic (Logística), respectivamente.




Figura 3. Mapa de vegetación.

Para esta etapa de la red neuronal se utilizó el algoritmo de retropropagación (backpropagation), dicho proceso se corrió sobre los datos de entrenamiento que constan de 5,855 patrones (1 %), que fueron obtenidos de manera aleatoria de la población, los cuales se dividieron en 60% de patrones de entrenamiento (4,392) y 40 % de patrones de prueba, dicho datos fueron conformados con un vector de entrada de nueve variables (unidades o neuronas) que consta de siete bandas del satélite Landsat TM transformadas en tres componentes principales (ACP), altitud, exposición, pendiente del terreno, distancia a escurrimientos, geología y edafología; dichas características conforman las variables independientes, y la vegetación que es la variable dependiente (Figura 3), con las cuales se entrena la red. Con la ayuda de *Neuroshell 2*, se entrenó y probó exitosamente la arquitectura antes propuesta en alrededor de 26 horas, utilizando para ello 672 épocas, con un error mínimo de 0.0025413, alcanzando una $r^2=0.8617$ y un coeficiente de correlación de 0.9283.

La red neuronal encontró los pesos más adecuados para la generalización de los patrones hacia toda la población, observándose que las variables que tienen mayor relevancia 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. Las dos variables a las cuales se les asignó los mayores pesos fueron la altitud y la edafología con un 0.21060 y 0.13269, respectivamente; resultando lógico desde el punto de vista ecológico, ya que la vegetación responde principalmente al gradiente altitudinal.

Fase de prueba

Con fines de validación del sistema se utilizaron 1,463 patrones de prueba por cada tipo de vegetación, es decir nueve variables con su correspondiente tipo de vegetación, alcanzando una $r^2=0.8514$ y un coeficiente de correlación de 0.9227.

Aplicación de la red neuronal

Al procesar los 37 subconjuntos, conformado por nueve variables y 10 000 registros, se encontró el valor de r^2 para cada uno de ellos, los cuales varían de 0.4109 a 0.8507. Examinando la matriz de confusión (Cuadro 1), se observó 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), esto se debe atribuir a los disturbios que ha sufrido esta zona, ya que ha sido constantemente afectada por el fuego y por la corta clandestina de madera.

CUADRO 1. Matriz de confusión

| Clase procesadas | Clases originales | | | |
|------------------|-------------------|-------|-------|-------|
| | 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 cambio, las tres clases restantes ofrecen una mejor discriminación entre ellas, reflejándose un mayor porcentaje de aciertos, teniendo el mejor resultado la clase de pastizal-matorral con un 93.99 % de sitios clasificados correctamente, con ello se logró incrementar la precisión de 75 % encontrada por Buendía (1996), utilizando imágenes de satélite únicamente, a un 83 % obtenido con el modelo de predicción de RNA y variables cartográficas.

Los resultados obtenidos en este estudio alcanzan mayor precisión a la reportada por Márquez-Linares y Vargas-Pérez (1999), quienes alcanzaron un 82.42 % de precisión, utilizando imágenes de satélite y variables cartográficas como la topeforma 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 estos autores 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), los cuales lograron un 70.58 % de precisión, superando aún más al estudio con análisis discriminante, el cual obtuvo un 58.38 %. Timmermans y Hulzebosch (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 extensible al presente trabajo dado la gran variabilidad de patrones utilizados.

Reconstrucción de la imagen

La Figura 4 fue el resultado de la reconstrucción de la imagen que se clasificó con el modelo de redes neuronales, la cual no se observa tan nítida como el patrón original de entrenamiento (Figura 3), ya que algunas clases fueron clasificada incorrectamente, esto es debido a la forma de procesar la información (por segmentos), como se mencionó con anterioridad, no se puede procesar toda la información en *NeuroShell*.




Figura 4. Imagen clasificada con redes neuronales artificiales.

CONCLUSIONES

Como conclusión se corroboró la eficiencia de las RNA para la clasificación de patrones que presenta gran variabilidad, como es el caso del presente trabajo, cimentándose los 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.

Sin embargo, y con la debida cautela, se puede aplicar el procedimiento utilizado para resolver diversos problemas donde se requiere 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.

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. 141 p
- BLACKARD, J. A.; DEAN, D. J. 1996. Evaluating integrated artificial neural network and gis techniques for predicting likely vegetative cover types. In: Proceedings of the First Southern Forestry GIS Conference (Greg J. Arthaud and William C. Hubbard, editors). University of Georgia. Athens, Georgia. Pp 151-159.
- BLACKARD, J. A.; DEAN, D. J. 1998. Comparative accuracies of neural networks and discriminant 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 York. 212 p.
- BUENDÍA, 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. Chapingo, México. 97 p.
- GARCÍA, E. 1981. Modificaciones al sistema de clasificación climática de Köppen. Offset Larios. México, D. F. 286 p.
- HAYKIN, S. 1994. Neural networks: a comprehensive foundation. MacMillan publishing Company. Toronto, Canada. 696 p.
- LAI, P. L.; FYFE, C. 1999. A neural implementation of canonical correlation analysis. Elsevier Science Ltd: Neural Networks, 12(10):1391-1397.
- LEYVA, O. A. 1999. Clasificador de tipos de parénquima en madera, usando redes neuronales para un sistema de identificación de maderas mexicanas. Tesis de maestría. Colegio de Postgraduados, Montecillos, México. 68 pág.
- MÁRQUEZ-LINARES, M. A; VARGAS-PÉREZ, E. 1999. Cartografía de asociaciones arbóreas mediante imágenes de satélite Landsat TM y modelos ecológicos. Revista Chapingo Serie Ciencias Forestales y del Ambiente 5(1):59-65.
- 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.
- NOGUEZ, H. R. 1993. Comparación entre imágenes Landsat Thematic Mapper (TM) y Multispectral Scanner (MSS) en la clasificación de uso de suelo. Tesis de licenciatura. División de Ciencias Forestales, Universidad Autónoma Chapingo, Chapingo, México. 115 p.
- SALAS, M. I. 2000. Redes neuronales artificiales en la medición de temperatura y humedad relativa. Tesis de licenciatura. Dpto. Irrigación, Universidad Autónoma Chapingo. Chapingo, México. 151 p.
- SARLE, S. W. 1994. Neural networks and statistical models. Proceedings of the nineteenth, annual SAS users group international conference.
- SHARDA, R. 1994 Neural networks for the MS/OR analyst: an application Bibliography. Interfaces 24(2):116-130.
- TIMMERMANS, A. J; 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.