



**COLEGIO DE
POSTGRADUADOS**

**INSTITUCIÓN DE ENSEÑANZA E
INVESTIGACIÓN EN CIENCIAS AGRÍCOLAS**

**CAMPECHE · CÓRDOBA · MONTECILLO · PUEBLA
SAN LUIS POTOSÍ · TABASCO · VERACRUZ**

Colegio de Postgraduados




- ❖ Reconocimiento de Cultivos (sensores de radar y ópticos).
- ❖ Estudios de Manejo Integral de Cuencas.
- ❖ Estudios en torno a la determinación de las necesidades hídricas.
- ❖ Estudios en torno a la caracterización y mapeo de hábitat en bosque.
- ❖ Estudios en torno a las necesidades nitrógeno.
- ❖ Estudios en torno a la estimación de rendimientos (determinación de biomasa).
- ❖ Estudios en torno a la aplicación automática de fertilizante y herbicidas (identificación de maleza).
- ❖ Estudios sobre la evaluación del impacto de eventos extremos en la agricultura (caracterización del estado de emergencia)

Redes neuronales artificiales y variables topográficas en la estimación de zonas con vocación forestal

Dra. Antonia Macedo Cruz
Colegio de Postgraduados, México

e-mail: macedoan@colpos.mx



Equipo de trabajo:

Dra. Antonia Macedo Cruz Colegio de Postgraduados

Dr. Isidro Villegas Romero. Universidad Autónoma Chapingo.

Dr. Enrique Mejía Saenz. Colegio de Postgraduados

MC. Delia Gijón Pérez. Egresada del Colegio de Postgraduados

Dr. Héctor Flores Magdaleno

Dr. Demetrio Fernández

Dr. Jesús Soria

Dra. Yolanda Fernández

MC. José Manuel Espinosa H

Ing. Sergio Morales

Ing. Daniel Hernández

.....

Agenda

- Introducción
- Muestreo
- Pre-procesamiento de imágenes
- Estructura de la Red Neuronal
- Entrenamiento
- Evaluación de la exactitud temática
- Resultados
- Conclusiones y trabajo futuro
- Preguntas/Respuestas

Las necesidades económicas y sociales ocasionan cambios de uso de suelo, ya sea para la explotación de recursos naturales o la adaptación a tierras agrícolas. Esto da lugar a la pérdida de áreas con recursos forestales, creando un impacto directo sobre el medio biótico, tal como la degradación de la tierra, emisiones de carbono, y el deterioro de la capacidad del sistema para satisfacer las necesidades humanas (Lambin *et al.*, 2003).

Vocación forestal

Un terreno preferentemente forestal es aquel que en el pasado estuvo cubierto con vegetación forestal y en la actualidad esté terreno se encuentra sin presencia de ella, pero dadas las condiciones topográficas, clima y suelo es más apto para el uso forestal. Un criterio para caracterizar los terrenos preferentemente forestales es la pendiente, por lo que las áreas agrícolas, pastizales cultivados o inducidos y áreas sin vegetación aparente, con pendiente mayor al 15%, se considera con vocación forestal (Diario Oficial de la Federación, 2011).

Modelo de Clasificación

- Existen distintos algoritmos para clasificación supervisada; sin embargo, cuando es necesario analizar datos complejos como el caso de imágenes naturales, con distribuciones no lineales y múltiples variables de entrada, es necesario seleccionar modelos competentes como las Redes Neuronales Artificiales (RNAs), que han respondido satisfactoriamente por su potencial para el reconocimiento de patrones y el procesamiento de imágenes satelitales (Ramirez y Chacon, 2011; Lizarazo, 2008).

Muestreo

- ❖ Para definir los sitios de entrenamiento se utilizó un **esquema de muestreo estratificado aleatorio**.
 - ❖ Los estratos se determinaron mediante un modelo de clasificación no supervisada (Macedo, 2011).
 - ❖ La aleatoriedad se determinó mediante la generación N coordenadas (x,y), de manera aleatoria por estrato.
- ❖ El **tamaño de la muestra** se determinó mediante un modelo estadístico de distribución multinomial con intervalos de confianza de 95% para cada una de las categorías previamente calculadas.

Las **unidades de muestreo** fueron los polígonos.

Mediante recorridos de campo con GPS y

Digitalización sobre la imagen SPOT con **refinado
pancromático** por el método de **nitidez espectral**

Gram-Schmidt conocido como “pansharpened”, donde

los pesos para el satélite SPOT 7 son: R: 0.166, G:

0.167, B: 0.167, IR: 0.5. a 1.5 m.

Pre-procesamiento

Correcciones radiométricas.

Correcciones geométricas.

Cuya metodología se publicó en (Macedo, 2019)

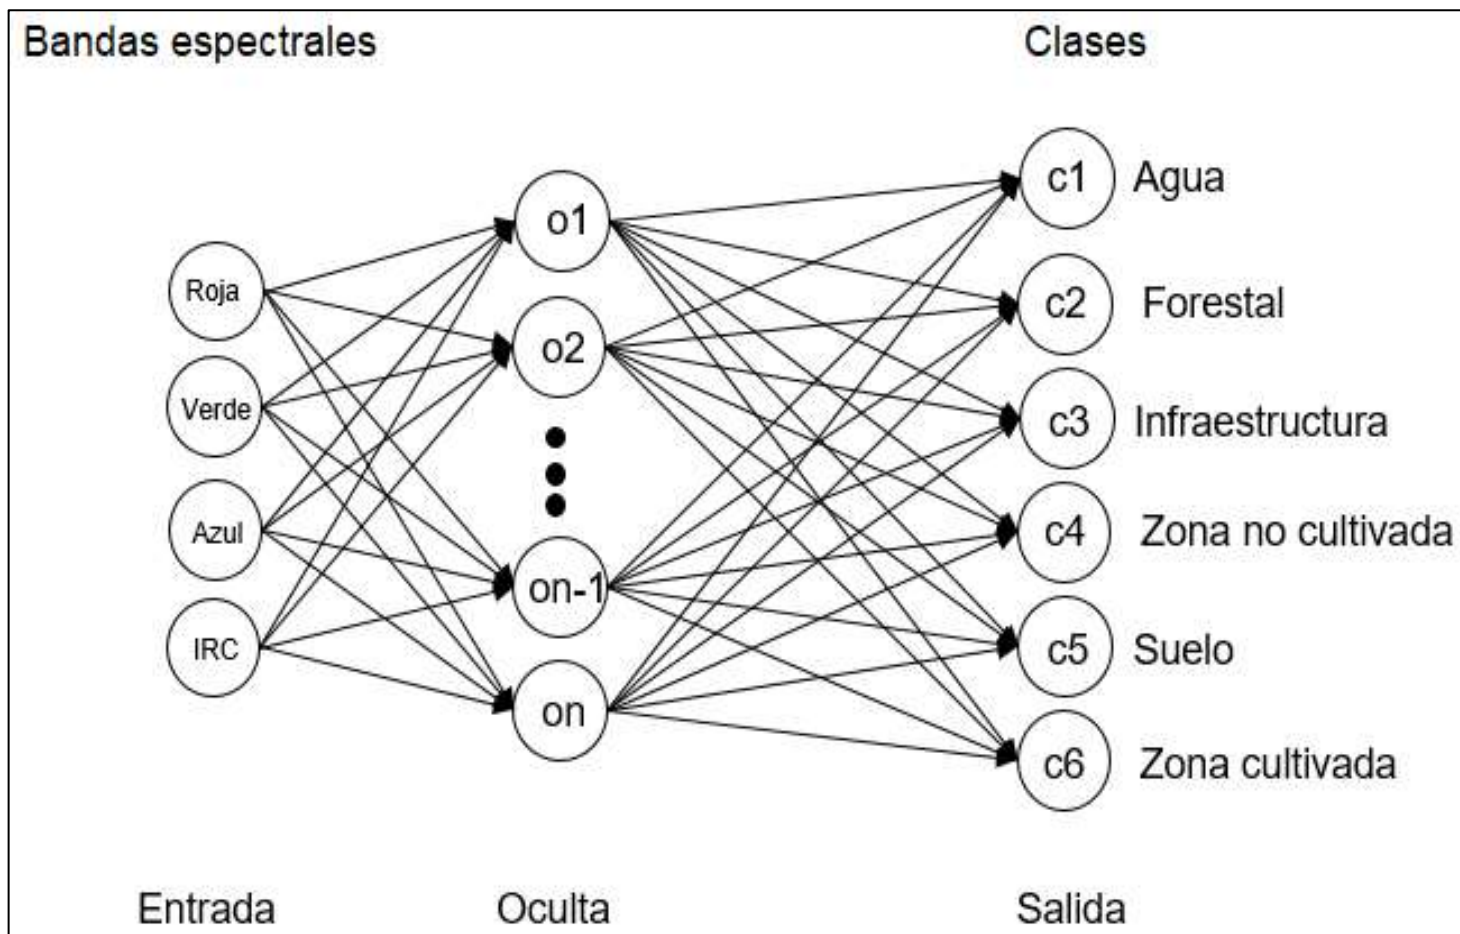
Estructura de la Red neuronal artificial

La arquitectura utilizada fue: la de **Perceptrón multicapa**.

Como se muestra en la figura 1. se caracteriza por tener una capa de entrada, una capa oculta y una capa de salida.

Cada neurona es una unidad de procesamiento fundamental y tiene 3 elementos básicos:

1. Enlace con un valor peso (w).
2. Un modelo lineal entre las neuronas de entrada y los pesos.
3. Una función de activación. Un algoritmo de propagación resiliente como se indica en Riedmiller (1993).



[Figura 1](#). Tipología de la red neuronal utilizada en la investigación

Entrenamiento

- Como variables de entrada (neuronas) son: las reflectancias de las cuatro bandas mas la media y covarianza y la topografía (7 neuronas de entrada).
- Como neuronas ocultas se usaron 15 ya que de acuerdo con Huang (2002).

$$NO = 2 \cdot NE + 1$$

Donde NO son las neuronas ocultas y NE las neuronas de entrada.

- La función de activación sigue un modelo gaussiano con valores de beta y gamma por default (en este caso 1). Como criterios de término de la función se usó $\epsilon=1.9$ y 2000 iteraciones.

Como variables de salida (neuronas) se usaron 6 neuronas de salida (tomadas del 80% del muestreo)

Evaluación de la exactitud temática

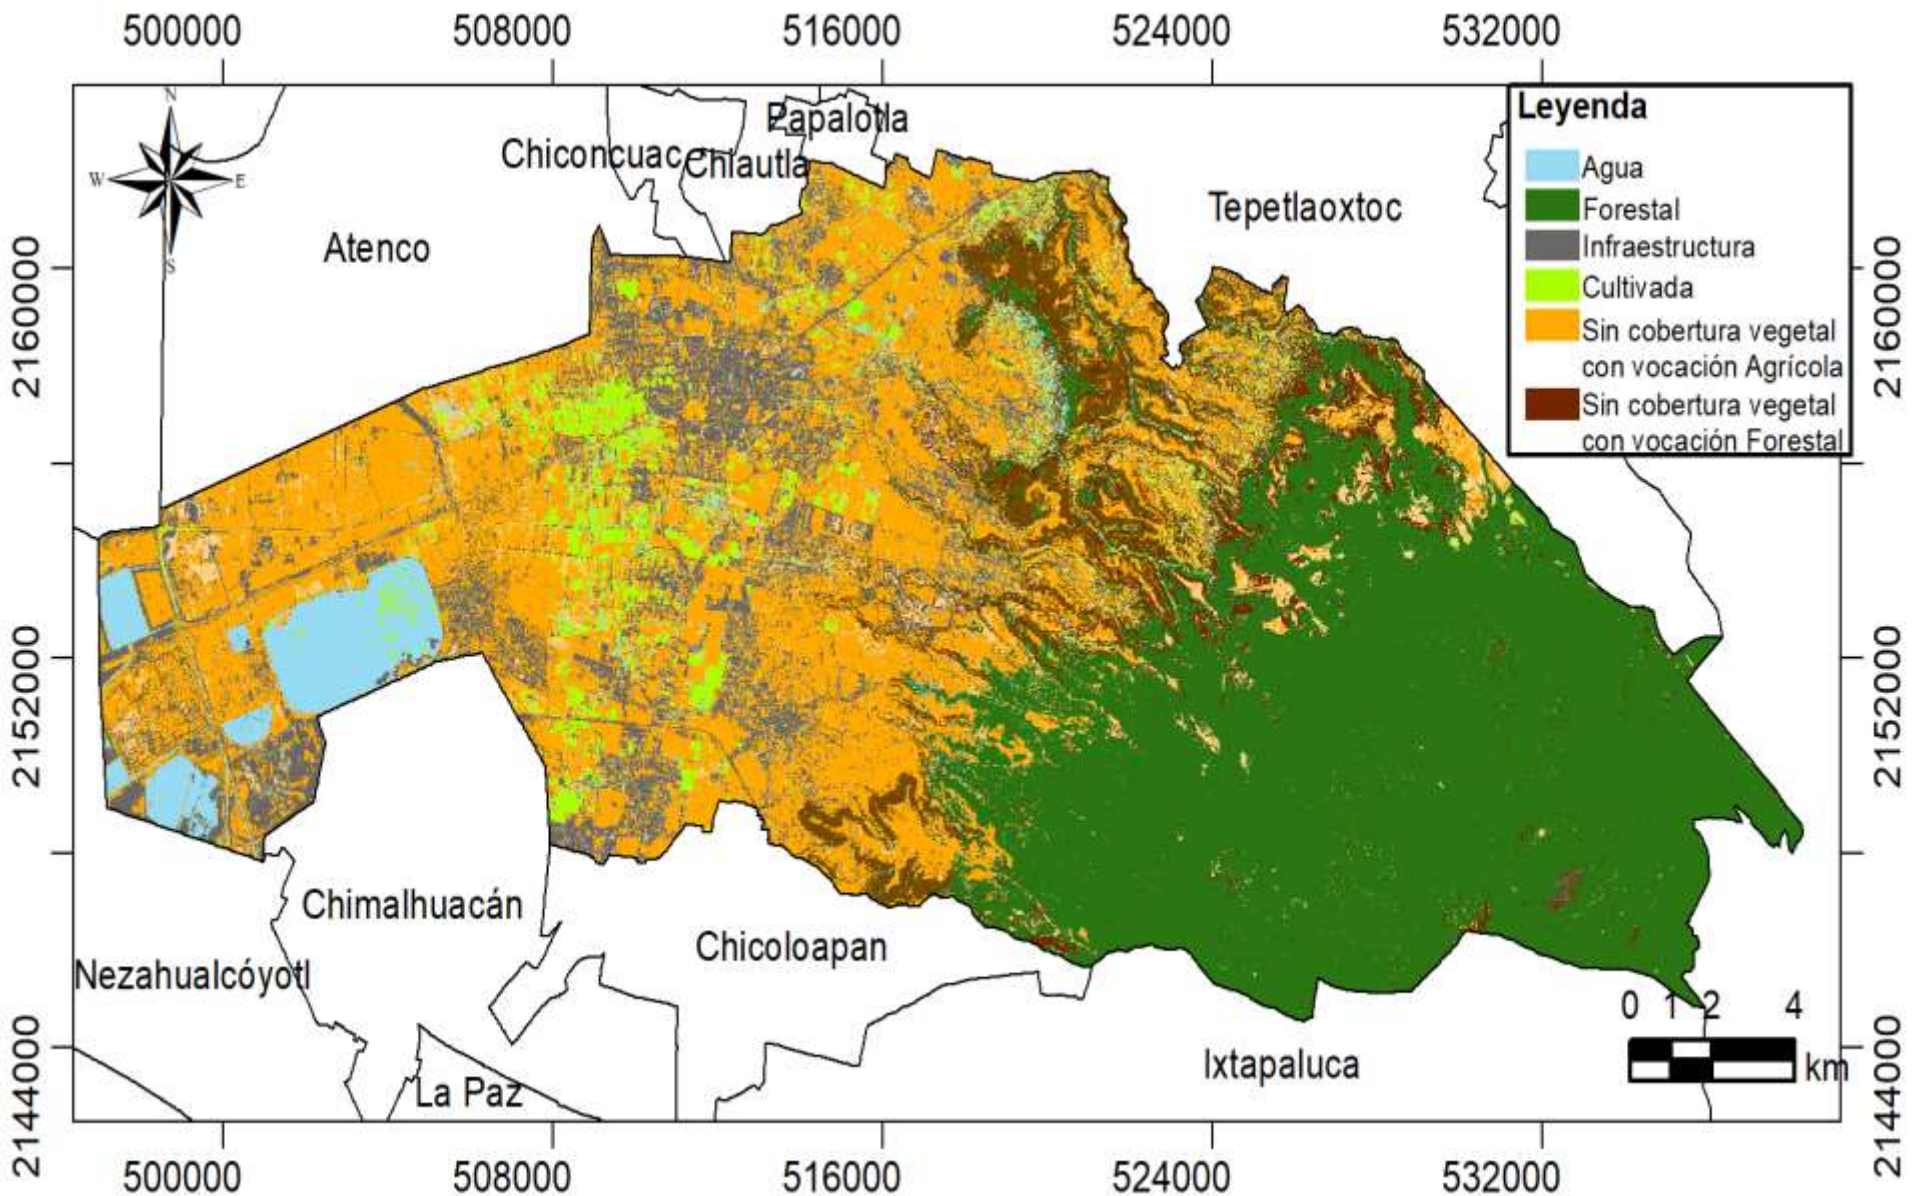
Una vez entrenado el modelo, se clasificó toda la imagen y el 20% de las muestras reservadas, se usaron para calcular el estadísticos basados en **matrices de confusión.**

A partir de la matriz de confusión se calculan distintos índices que permiten evaluar el grado de concordancia entre la clasificación evaluada y una clasificación de referencia.

Resultados

Numero de muestras para el entrenamiento y evaluación del modelo

Cobertura	Superficie		No. De muestras por tipo de cobertura
	Ha	%	
Forestal	17668.9	41.3%	279
Superficie no cultivada	11452.3	26.8%	181
Suelo desnudo	5583.9	13.1%	88
Agua	3688.7	8.6%	58
Infraestructura	3419.7	8.0%	54
Superficie cultivada	963.7	2.3%	15
Totales		100%	675



Superficie por clase de cobertura incluyendo AVF

Clase	Superficie (ha)	%
Zona cultivada	1,540.10	3.60
Agua	2,136.50	4.99
Áreas Con Vocación Forestal	3,612.20	8.44
Infraestructura	4,922.00	11.51
Forestal	15,267.80	35.69
Sin cobertura vegetal y pendientes < 15%	15,298.70	35.76
Total	42,777.30	

Resultados

. Matriz de confusión de la imagen con fecha 12 de abril 2017 (%)

		Clasificador						
		A	F	I	Znc	SD	Zc	Pr
Referencia	A	100.00	0.00	0.00	0.00	0.00	0.00	100%
	F	0.05	97.85	0.00	0.00	2.09	0.00	98%
	I	1.47	0.24	73.13	14.91	8.67	1.58	73%
	Znc	0.03	0.00	2.99	90.62	6.37	0.00	91%
	SD	0.00	0.00	10.37	0.99	88.64	0.00	89%
	Zc	0.88	0.00	0.00	2.65	3.65	92.81	93%
	Pc	98%	100%	85%	83%	81%	98%	

A: Agua, F: Forestal, I: Infraestructura, Znc: zona no cultivada, SD: suelo desnudo, Zc: zona cultivada, Pr: Precisión de referencia, Pc: Precisión de clasificador

. Indicadores de precisión para la clasificación supervisada por el método de RNA en el municipio de Texcoco, 2017.

Clase	P_p	P_u	Kappa	P_g
Agua	1.00	0.91		
Forestal	0.98	1.00		
Infraestructura	0.73	0.91		
Herbáceas temporales	0.91	0.93	0.83	0.88
Suelo desnudo	0.89	0.24		
Zona cultivada	0.93	0.92		

Donde: **pp** es precisión del productor (pixeles correctamente clas)
pu es la precisión del usuario (error de comisión)

Interpretación del coeficiente kappa (Ladis, 1977)

Coeficiente kappa	Fuerza de concordancia
Pobre	<0.00
Leve	0.01-0.20
Aceptable	0.21-0.40
Moderada	0.41-0.60
Buena	0.61-0.80
Muy buena	0.81-1.00

Conclusiones

El uso de redes neuronales artificiales permite desarrollar clasificaciones de alta precisión en comparación con otros métodos tradicionales en los que se analizan menos variables.

El área sin cobertura vegetal con vocación agrícola, se puede clasificar como áreas con necesidad de restauración inmediata (reforestación).

Trabajos futuros

Sería interesante evaluar si la precisión de un análisis multicriterio como este puede mejorarse usando un clasificador como redes neuronales artificiales que incluya información auxiliar como variables climáticas, de suelo, topográficas etc.

Literatura citada

- Huang, W.; Foo, S. Neural network modeling of salinity variation in Apalachicola River. *Water Research*, 2002, 36, 356–362.
- Ramírez, Q.J.; Chacón, M.M. Redes neuronales artificiales para el procesamiento de imágenes , una revisión de la última década. *Riee&C*, **2011**, 9, 7–16.
- Riedmiller, M; Braun, H. A Direct Adaptive Method for Faster Backpropagation Learning: The RPROP Algorithm. *IEEE International Conference on Neural Networks*. **1993**, 1, 586-591.

- Lambin EF, Geist HJ, Lepers E (2003) Dynamics of land-use and land-cover change in tropical forest. *Annu. Rev. Environ. Resourc.* 28: 205-241.
- Landis J; Koch G. The measurement of observer agreement for categorical data. *Biometrics.* 1977, 33, 159-174.
- Lizarazo, I. Clasificación de La Cobertura y Del Uso Del Suelo Urbano Usando Imágenes de Satélite y Algoritmos Supervisados de Inteligencia Artificial. *UD y la Geomática.* 2008,1, 4–18.
- Macedo-Cruz, A.; Pajares, G.; Santos, M.; Villegas-Romero, I. Digital image sensor-based assessment of the status of oat (*Avena sativa* L.) crops after frost damage. *Sensors.* 2011, 11, 6015–6036, doi: [10.3390/s110606015](https://doi.org/10.3390/s110606015)