

APLICACIÓN DE LA TEORIA MEMORIA-PREDICCIÓN EN LA INVENTARIZACIÓN DE OLIVAR

APPLICATION OF THE MEMORY-PREDICTION THEORY IN OLIVE GROVE INVENTORY

Alberto J. Perea^{1*}, José E. Meroño² y María J. Aguilera¹

¹ Departamento de Física Aplicada, Edificio Einstein, Escuela Técnica Superior de Ingenieros Agrónomos y de Montes, Universidad de Córdoba, Campus de Rabanales, Córdoba 14071, España.

*Autor para correspondencia. E-mail: g12pemoa@uco.es

² Departamento de Ingeniería Gráfica y Geomática, Edificio Gregor Mendel, Escuela Técnica Superior de Ingenieros Agrónomos y de Montes, Universidad de Córdoba, Campus de Rabanales, Córdoba 14071, España.

RESUMEN

La teledetección a partir de imágenes aéreas o de satélite ofrece una interesante alternativa a los tradicionales procedimientos manuales para el inventariado agrícola, incorporando procesos automáticos. Este artículo presenta un sistema de inferencia para la detección de olivar con fotografías aéreas digitales. El sistema se inspira en la reciente teoría memoria-predicción y en los modelos de arquitectura de alto nivel de la neocorteza humana. El documento describe la arquitectura jerárquica y el reconocimiento de la actuación de este modelo Bayesiano. Los resultados indican que se logra detectar el 95% de las parcelas utilizando un fotograma procedente de un sensor fotogramétrico. Se concluye que el proceso automático desarrollado puede ser integrado fácilmente en el Sistema de Información Geográfica del usuario final y produce información útil para la gestión del olivar.

Palabras clave: memoria temporal jerárquica, fotografías aéreas digitales, teoría Memoria-Predicción, cámara DMC.

ABSTRACT

Remote sensing using aerial or satellite images represents an interesting alternative to the traditional manual procedures used for agricultural inventory by incorporating automatic processes. This paper presents an inference system for olive grove detection using aerial photographs. The system is inspired by a recent memory-prediction theory and models of high-level architecture of the human neocortex. This paper describes the hierarchical architecture and recognition performance of this Bayesian model. Results indicate that 95% of the olive groves are detected by using images obtained from a photogrammetric sensor. It is concluded that the automatic process developed can be easily integrated into the final user's Geographical Information System and produces useful information for olive grove management.

Key words: hierarchical temporal memory, digital aerial photographs, Memory-Prediction theory, DMC camera.

INTRODUCCIÓN

La gestión del olivar dentro de la Unión Europea es responsabilidad de un amplio rango de organizaciones, que necesitan datos geográficos precisos, así como de sistemas para la integración de la información para asesorar sus procesos de toma de decisiones. La responsabilidad de la creación, mantenimiento y actualización de un registro oleícola se delega en los Estados Miembros, donde esta responsabilidad se comparte entre diferentes administraciones públicas o asociaciones profesionales. Estas organizaciones deben mantener un registro de las actividades relacionadas con el cultivo del olivar, tomar decisiones asociadas a la Política Agraria Común, analizar la evolución del impacto producido por decisiones políticas y, en algunos casos, desarrollar la producción del aceite de alta calidad dentro de un entorno ambientalmente sostenible.

En España hay más de 2 millones de hectáreas dedicadas al olivar, con aproximadamente 300 millones de árboles repartidos en casi todo el territorio nacional. En los últimos años, con objeto de acceder a ayudas y subvenciones de la Unión Europea, se ha hecho necesario disponer de un censo fiable y actualizado del número de árboles. Hasta hace poco, los inventarios del olivar a nivel europeo, se elaboraban a partir de trabajos de campo y entrevistas con los agricultores, contando en algunos casos con el apoyo de fotointerpretación de fotografía aérea. Estos procesos necesitan de amplios periodos de tiempo para su desarrollo, no siendo los resultados siempre satisfactorios debido a limitaciones técnicas y defectos o sesgos en la información de partida. Además, la base cartográfica para la elaboración del registro de olivar es el catastro oficial de rústica (predios rurales), a menudo obsoleto y no ajustado a los límites reales de las parcelas.

La teledetección es una herramienta que ha permitido detectar y monitorizar cultivos. La monitorización y control de áreas cultivadas es un campo muy activo de la teledetección y con un indiscutible potencial de aplicaciones, entre ellas, el censo automático de árboles en explotaciones agrarias y zonas forestales (Gougeon, 1995; Pollock, 1996; Brandtberg y Walter, 1998; Larsen, 1999). La mayoría de los estudios de clasificación e inventariado de cultivos por teledetección se han llevado a cabo con sensores multiespectrales (Bastiaansen et al., 2000; Rama Rao et al., 2007). La técnica de clasificación temática de cultivos mediante imágenes procedentes de un sensor embarcado en una plataforma espacial tiene numerosas ventajas, entre las que podemos destacar el ahorro de tiempo, dinero y personal dedicado al proyecto (Calera et al., 1999; Rubio et al., 2001) utilizando datos del programa Landsat.

Hoy día existe un gran interés por el desarrollo

de algoritmos de clasificación que mejoren los problemas derivados de las clasificaciones basadas únicamente en la reflectancia de los píxeles. Como parte de estos problemas destaca la mezcla radiométrica de píxeles vecinos, impidiendo la extracción de regiones homogéneas de interés.

Gong y Howarth (1990) afirman que es importante reconocer que los clasificadores convencionales (clasificador de máxima probabilidad, clasificador mínima distancia) no reconocen los modelos espaciales del mismo modo que lo hace el intérprete humano. Con esta idea nacen los sistemas expertos, cuya misión principal es incorporar datos distintos a las características espectrales a fin de mejorar los resultados de la clasificación puramente espectral.

Por otro lado, con los recientes avances que se han realizado en el campo de la neurociencia, sabemos más sobre la organización y funcionamiento de la corteza cerebral, por lo que podemos aplicar los algoritmos de su funcionamiento al software, cosa que hasta ahora sólo se había conseguido de forma muy simplista y con resultados muy limitados, usando redes neuronales.

Tras varios años de estudio nace una nueva teoría basada en el córtex cerebral, lugar donde reside realmente la memoria y por tanto la inteligencia. El córtex es básicamente igual en todas partes, y aunque se sabe que diversas zonas tienen relación con ciertos sentidos y atributos (ej., la visión, el tacto, el lenguaje, etc.) en realidad todas sus partes, capas celulares, densidad, etc., son básicamente iguales. Esta nueva teoría, llamada Memoria-Predicción, argumenta que todas las capas del córtex pueden realizar las mismas funciones (Hawkins y Blakeslee, 2004), lo cual explicaría por qué funciones en zonas que son dañadas por accidentes o enfermedad (ej., el lenguaje) puedan volver a desarrollar en otra zona.

El número y disposición de las conexiones al córtex, así como la diferencia de tamaño relativo (cuerpo/cerebro) y el tipo y el número de neuronas en el córtex humano y en el de los animales es lo que nos hace básicamente diferentes; los humanos somos más inteligentes porque somos en cierto modo más conscientes del mundo que nos rodea y porque tenemos mayor capacidad de predicción y simulación mental (Hawkins y Blakeslee, 2004).

El algoritmo que utiliza la mente es un proceso que almacena patrones y hace predicciones sobre los patrones que encuentra o espera encontrar (Hawkins y Blakeslee, 2004). La exposición a los diversos estímulos (inputs) se guarda en el córtex. Pero el córtex es muy diferente a lo que habitualmente conocemos como "la memoria" de un ordenador. Las diferencias fundamentales de cómo funciona la memoria en el cerebro respecto a otros tipos de memorias (como un archivo o un ordenador) son las siguientes (Hawkins y Blakeslee, 2004):

La memoria almacena secuencias de patrones en vez de los datos en sí. Esto es como almacenar las diferencias de una nota a otra en una canción en vez de almacenar las notas en sí.

La memoria es accesible de forma auto-asociativa. Todos los recuerdos están asociados unos con otros de algún modo; ver una parte de una cara está asociado con que esa cara corresponde a una cabeza completa.

La memoria almacena los patrones en formato invariante. Una vez que has aprendido a leer, puedes reconocer las palabras y leerlas en cualquier ángulo, perspectiva, condición luminosa o aunque cambie el tipo de letra.

Los patrones se almacenan en una jerarquía. El concepto de jerarquía tiene que ver con las diversas capas del córtex, y básicamente consiste en una estructura que podría denominarse fractal, bellamente simétrica porque además cuenta con retroalimentación, en el que las regiones de menor nivel transmiten los patrones y los "nombres" que asignan a los patrones a las zonas de nivel superior. Pero todas son iguales y equivalentes en realidad. Esta jerarquía se corresponde, curiosamente, con el hecho de que también el mundo en sí sea jerárquico.

En parte de esta teoría, conocida como Teoría Memoria-Predicción (TMP), se basa el modelo de Memoria Temporal Jerárquica desarrollado por la empresa Numenta®. En este modelo, las relaciones temporal y espacial entre patrones de señales sensoriales forman una arquitectura de memoria jerárquica durante el proceso de aprendizaje. El aprendizaje puede ser supervisado y no supervisado. Cuando aparece un nuevo patrón el proceso de reconocimiento se activa y elige entre los patrones almacenados el que mejor lo representa.

Perea et al.(2009) llevaron a cabo una clasificación de usos del suelo sobre fotografías aéreas digitales empleando una red basada en la Memoria Temporal Jerárquica. Se alcanzaron buenos resultados pero dicha red presentaba como limitación la clasificación de un único patrón dentro de una misma imagen.

Sensor DMC

El sensor de la cámara DMC Zeiss/Intergraph es del tipo CCD matricial, que proporciona precisiones y resoluciones en el rango del centíme-

tro gracias al sistema digital de compensación del movimiento del avión que incorpora la cámara.

La instalación de la cámara digital en la aeronave es idéntica a la de las cámaras tradicionales, y se puede aprovechar la misma plataforma de estabilización y usar el mismo sistema de navegación.

La geometría de la cámara es cónica, a diferencia de otras cámaras que tienen geometría de barrido, muy adecuada para la realización de ortofotos, pero que complican mucho los procesos de restitución fotogramétrica.

La parte electro-óptica dispone de 8 cabezales, 4 para imágenes pancromáticas de alta resolución con focal de 120 mm y 4 para imágenes multispectrales. Sobre la óptica de la cámara se encuentra la electrónica, desde la cual se controlan los distintos cabezales de la cámara, la captura de los datos y la comunicación con la unidad central de control, que se encarga de configurar todo el sistema, comunicarse con otros sistemas externos, controlar la captura de los datos y almacenarlos en un sistema de almacenaje presurizado.

Con las imágenes de los 4 cabezales pancromáticos de alta resolución se generan las fotografías pancromáticas de medida 13.824 x 7.680 píxeles, y usando técnicas de "pan-sharpening" se obtienen estas mismas imágenes en color RGB e infrarrojo color IRC, usando las imágenes de cada uno de los cabezales multispectrales.

El objetivo general de este estudio es proponer una metodología basada en el modelo de Memoria Temporal Jerárquica, propuesta por la empresa Numenta®, para mejorar las sistemáticas empleadas actualmente en los registros de olivar empleando fotografías aéreas digitales. Este método debe ser simple, factible, económicamente viable y aplicable a otras zonas productoras de aceite de oliva, ya que los registros de olivar exigen una continua actualización.

MATERIALES Y MÉTODOS

La zona de estudio objeto de este trabajo está situada en la provincia de Córdoba, España, concretamente en el municipio de Villafranca (37°57' N, 4°32' O) (Fig. 1).



Fig. 1. Área del estudio. España, provincia de Córdoba, municipio de Villafranca.
Fig. 1. Study area. Spain, province of Cordoba, Villafranca county.

Para llevar a cabo esta investigación, se empleó un fotograma captado por el sensor fotogramétrico DMC de Zeiss/Intergraph® el 21 de Abril de 2007 a una altura sobre el terreno de 3000 m, con dimensiones de 13824 x 7680 píxeles y una combinación de bandas formada por el rojo, verde y azul. Posee una escala 1/25000, un tamaño de píxel de 12 micras y una resolución espacial de 30 cm.

Mapas digitales vectoriales, ortofotos a color y modelos digitales del terreno fueron utilizados para ortorrectificar la imagen, seleccionar las áreas de entrenamiento y validar las clasificaciones. Los datos cartográficos se proyectaron

a partir de las coordenadas UTM en el Sistema Europeo 1950 (ED-1950; UTM-Zone30N).

El sistema se preparó para discernir entre los siguiente usos: Olivar (*Olea europaea* L.); Otros usos: suelo desnudo, superficie edificada y superficie en regadíos.

Memoria Temporal Jerárquica (MTJ)

La Memoria Temporal Jerárquica (MTJ) es una tecnología que replica la estructura y las propiedades algorítmicas de la neocorteza. Es una colección de nodos interconectados, organizados con forma de jerarquía en árbol (Fig. 2).

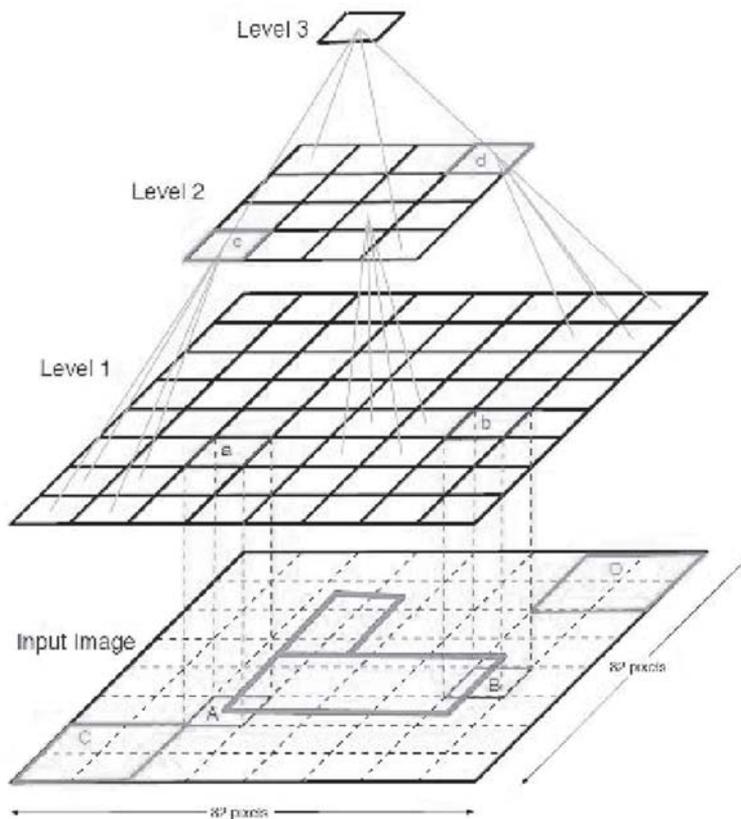


Fig. 2. Modelo de MTJ (Memoria Temporal Jerárquica) con 3 niveles de nodos. Cada subregión en el nivel 1 se corresponde con un fragmento de imagen de tamaño 4x4 píxeles. Cada subregión en el nivel 2 se corresponde con un fragmento de imagen de tamaño 8x8 píxeles. Una única región en el nivel 3 se corresponde con todas las subregiones del nivel 2 (George y Jaros, 2007; Figure 4).

Fig. 2. HTM (Hierarchical Temporal Memory) model with three layers of nodes. Each subregion in level 1 receives image fragment of size 4x4 pixels. Each subregion in level 2 receives image fragment of size 8x8 pixels. A single subregion in level 3 receives input from all subregions of level 2 (George y Jaros, 2007; Figure 4).

Todos los objetos del mundo tienen una estructura. Esta estructura es jerárquica, tanto en espacio como en tiempo. La MTJ es también jerárquica en espacio y tiempo y, por lo tanto, puede representar de manera eficiente la estructura del mundo.

La MTJ está formada por varias capas o niveles de nodos con un solo nodo en la capa superior. Este sistema funciona en dos fases: la fase de aprendizaje y la fase de inferencia. Durante la fase de aprendizaje, la red se expone a patrones de entrenamiento y se construye un modelo que estructura los patrones en categorías. Durante la fase de inferencia la red generará la distribución en estas categorías para patrones nuevos. Todos los nodos (excepto el nodo inicial) procesan la información aproximadamente de la misma forma y consta de dos módulos: temporal y espacial. Comprender un nodo de la MTJ se reduce a comprender el funcionamiento de estos módulos durante la fase de aprendizaje y entrenamiento.

Funcionamiento de los nodos durante el aprendizaje

Durante la fase de aprendizaje, el módulo espacial aprende a clasificar la entrada de datos en base a las coincidencias espaciales de los elementos que las componen. El vector de entrada es almacenado sólo si la distancia euclídea entre éste y los vectores ya almacenados es suficientemente grande como para ser diferente a ellos (esto es controlado con el parámetro Máxima distancia). La salida del módulo espacial (entrada del módulo temporal) se produce en términos de sus coincidencias y como tal se puede ver como una fase de preproceso para el módulo temporal, simplificando su entrada. El módulo temporal aprende grupos temporales, que son grupos de coincidencias que se suceden de forma frecuente cerca en el tiempo.

Módulo espacial

Los módulos espaciales de los nodos de entrada reciben datos sin tratar desde el sensor, los módulos espaciales de los nodos superiores reciben los datos de salida desde sus nodos inferiores. La entrada del módulo espacial en las capas superiores es la concatenación del orden fijado de la salida de los inferiores. Su entrada se representa mediante una serie de vectores y la función del módulo espacial es construir una matriz (matriz de coincidencia) de los vectores de entrada que se han producido recientemente. Hay varios algoritmos de los módulos espaciales como por ejemplo el Gausiano y el Producto. El algoritmo Gausiano se usa para nodos en el nivel de entrada, considerando que los nodos superiores de la jerarquía utilizan el módulo espacial del Producto.

El algoritmo Gausiano

El algoritmo Gausiano compara el vector de entrada sin tratar con las coincidencias existentes en la matriz de coincidencia. Si la distancia euclídea entre el vector de entrada y la coincidencia existente es suficientemente pequeña, la entrada se considera como la misma coincidencia y el recuento para esa coincidencia se incrementa y almacena en la memoria.

$$d^2(\vec{x}, \vec{w}) = \sum_{i=1}^D (x_i - w_i)^2 \quad [1]$$

donde D es la dimensionalidad de los vectores. El umbral de coincidencia de un vector de entrada para una coincidencia existente es el parámetro Máxima distancia.

El algoritmo del producto

Calcula la probabilidad de similitud ($belief_i$) entre una entrada en la inferencia y un vector que previamente ha sido memorizado por el módulo espacial:

$$belief_i = \prod_{j=1}^{nchildren} y_j [child_j] * x [child_j] \quad [2]$$

donde $nchildren$ es el número de nodos secundarios que tiene el nodo primario, x es el vector de entrada, y_i son los vectores previamente almacenados por el módulo espacial, y $a[child_n]$ es la parte de un vector que se obtiene de la n -ésima potencia de un nodo secundario.

Módulo temporal

El módulo temporal forma grupos de coincidencias en el tiempo, llamados grupos tempora-

les. Posteriormente construye una matriz de coincidencia en el tiempo. Después de la etapa de aprendizaje, el módulo temporal utiliza esta matriz para crear dichos grupos temporales. Este módulo usa el algoritmo de la suma que toma las mejores representaciones de cada grupo para clasificar los nuevos patrones de entrada durante la inferencia. Cuando un nuevo vector de entrada se presenta durante la fase de aprendizaje, el módulo espacial lo representa como una de sus coincidencias aprendidas. Esto incrementa los elementos (j, i) de la matriz de coincidencia en el tiempo y es controlado por el parámetro $TransitionMemory$. Este incremento se calcula como:

$It = transitionMemory - t + 1$, donde t es el tiempo entre la coincidencia actual y la del pasado.

Funcionamiento de los nodos durante la fase de inferencia

Tras entrenar un nodo, pasa al modo de inferencia. Cuando se entrena la red completa, todos los nodos están en estado de inferencia y la red es capaz de realizar la inferencia con nuevos patrones de entrada. Al inicio, se genera una distribución de probabilidad sobre las categorías que se han utilizado durante la etapa de aprendizaje.

Funcionamiento del módulo espacial durante la inferencia

Los tres algoritmos del módulo temporal (Gausiano, Punto y Producto) trabajan de forma diferente durante la etapa de inferencia, pero todos convierten un vector de entrada en un vector de probabilidad sobre las coincidencias. Como se ha expuesto anteriormente, el algoritmo del módulo temporal Gausiano se usa en los nodos de primer nivel y el Punto o Producto se utiliza con los nodos más altos de la jerarquía.

Módulo espacial Gausiano

En el módulo espacial Gausiano, la distancia entre un vector de entrada x y cada una de las coincidencias aprendidas se calcula utilizando la ecuación 1.

Esta distancia se convierte en un vector de probabilidad considerando x como un cálculo de una muestra aleatoria de una serie de distribuciones Gaussianas multidimensionales, todas ellas centradas en una de las coincidencias aprendidas. Todas estas distribuciones de probabilidad tienen la misma constante varianza en todas las dimensiones, presididas por el parámetro σ , que es la raíz cuadrada de la varianza. Cada elemento i del vector de probabilidad b , que representa la probabilidad de que el vector de entrada x tenga la

misma causa que la coincidencia i , se calcula según la siguiente ecuación:

$$y_i = \exp\left\{-\frac{d^2(x, W_i)}{2\sigma^2}\right\} \quad [3]$$

donde d^2 se define en la ecuación 1 y W_j es la coincidencia de la posición j en la matriz de coincidencia W .

Módulo espacial Punto

Utiliza el producto escalar del vector de entrada con cada una de las coincidencias aprendidas y se obtiene como resultado los elementos del vector de probabilidad.

Módulo espacial Producto

El algoritmo del módulo espacial Producto divide el vector de entrada en las salidas de cada uno de sus subgrupos. Utiliza el producto escalar con las mismas partes de la coincidencia y calcula posteriormente el producto de estos números dando un elemento del vector de probabilidad sobre las coincidencias.

Funcionamiento del módulo temporal durante la etapa de inferencia

Durante la etapa de inferencia, el módulo temporal recibe un vector de probabilidad sobre las coincidencias del módulo espacial. Posteriormente, calcula la distribución de las probabilidades sobre los grupos. Se realiza una elección entre dos algoritmos diferentes del módulo temporal durante la inferencia: maxProp and sumProp, presididos por el parámetro temporal PoolerAlgorithm.

MTJ Diseño e Implementación

La red MTJ usada para este experimento fue creada usando la plataforma Nupic® desarrollada por la empresa Numenta®. Para poner a punto dicha red fueron necesarios dos pasos: la creación de la arquitectura y la formación con un conjunto de patrones de entrenamiento. La arquitectura MTJ consta de 3 niveles. El nivel de entrada consta de 16 nodos, cada uno recibiendo una característica de la imagen patrón de entrenamiento. El nivel 2 se compone de 4 nodos, cada uno recibe la información de salida de 4 nodos secundarios de nivel de entrada. El nivel 3 se compone de un nodo en el nivel superior.

Parámetros de entrenamiento

maxDistance

Este parámetro es sólo relevante en el algoritmo del módulo espacial Gaussiano (en los nodos de primer nivel). Durante el entrenamiento, un nuevo patrón se compara con las coincidencias existentes. Cuando el cuadrado de la distancia Euclidiana (no normalizado) entre ellas es mayor que maxDistance, el nuevo patrón se almacena como una coincidencia.

Sigma

Cuando un nodo está en estado de inferencia, el módulo espacial genera un vector de probabilidad sobre las coincidencias aprendidas para un patrón de entrada dado. La probabilidad en una coincidencia se representa como un Gaussiano multidimensional (no normalizado) con el vector de coincidencia que depende de su media y de la variación de sigma.

El número de imágenes empleadas tanto para el entrenamiento como para la validación de la clasificación fueron 300 y 100, respectivamente (Tabla 1), tanto para la categoría *Olea europaea* (Olivar) como para la categoría Otros usos.

Tabla 1. Número de imágenes de entrenamiento y de evaluación.
Table 1. Number of training and test images

Categoría	Imágenes Entrenamiento	Imágenes Evaluación
<i>Olea europaea</i> L.	300	150
Otros usos	300	150

RESULTADOS Y DISCUSIÓN

Se analizó el efecto de los parámetros Máxima distancia y Sigma en la Tasa de Error Total (TET) de la clasificación y el promedio número de coincidencias y de grupos temporales obtenidos por los nodos de cada uno de los niveles.

El resto de parámetros (TRANSITIONMEMORY y TOPNEIGHBOURS) se establecieron en 5 y 1, respectivamente. Estos son los valores por defecto y la modificación por otros valores tuvieron un efecto negativo sobre el rendimiento del

sistema. Se ha modificado la red a través de diferentes valores para maxDistance y se ha establecido SIGMA como la raíz cuadrada de maxDistancia. Este es un valor de partida razo-

nable para SIGMA, porque las distancias entre las coincidencias se calculan como el cuadrado de la distancia euclídea en lugar de la distancia euclidiana normalizada (Tabla 2).

Tabla 2. Tasa de Error Total (TET), número de coincidencias y grupos temporales aprendidos por los 16 nodos del nivel 3 para diferentes valores de MAXDISTANCIA y SIGMA.

Table 2. Total Error Rate (TET), average number of coincidences and temporal groups learned in the 16 bottom nodes for different values of MAXDISTANCE and SIGMA.

MaxDistancia	Sigma	TET(%)	N° Coinc.	N° groups
1	0,5	9,01	55,03	23,98
2	1,00	3,76	45,43	21,06
5	3,34	19,42	15,71	12,32
10	4,55	21,55	11,23	7,63

La menor Tasa de Error Total (TET) se obtuvo con un valor intermedio para maxDistance de 2. Esta tasa indica que con un valor inferior de maxDistance, la MTJ observará variaciones en los patrones de entrada debido al ruido de las diferentes coincidencias.

Por otro lado, cuando maxDistance es mayor que el valor óptimo, el módulo espacial reunirá patrones que tienen causas diferentes. En la matriz de confusión se puede observar los aciertos experimentados por el sistema en cada una de las categorías (Fig. 3).

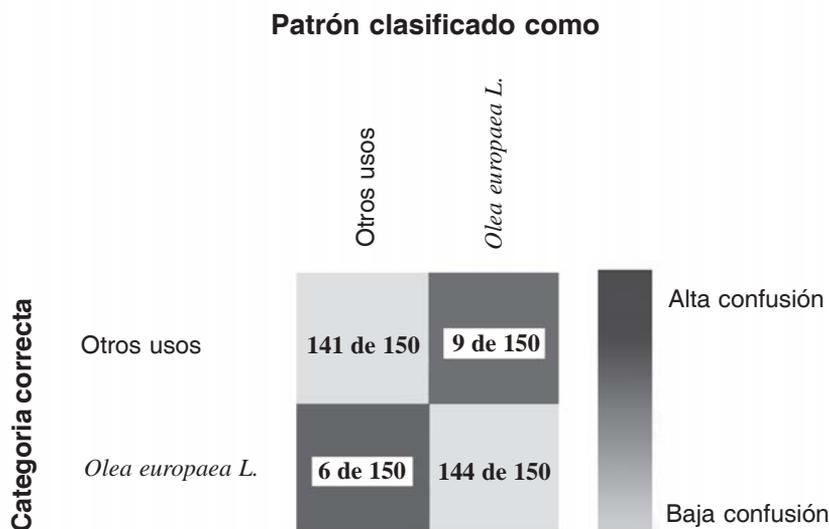


Fig. 3. Matriz de confusión de la mejor combinación del sistema.
Fig. 3. Confusion matrix of the best combination of the system.

Mientras se experimentaba con el sistema, también se comprobó su capacidad de aprender representaciones invariables de patrones visuales, alma-

cenar estos patrones en la jerarquía y recuperarlos de forma autoasociativa. El sistema puede funcionar como una memoria autoasociativa (Fig. 4).

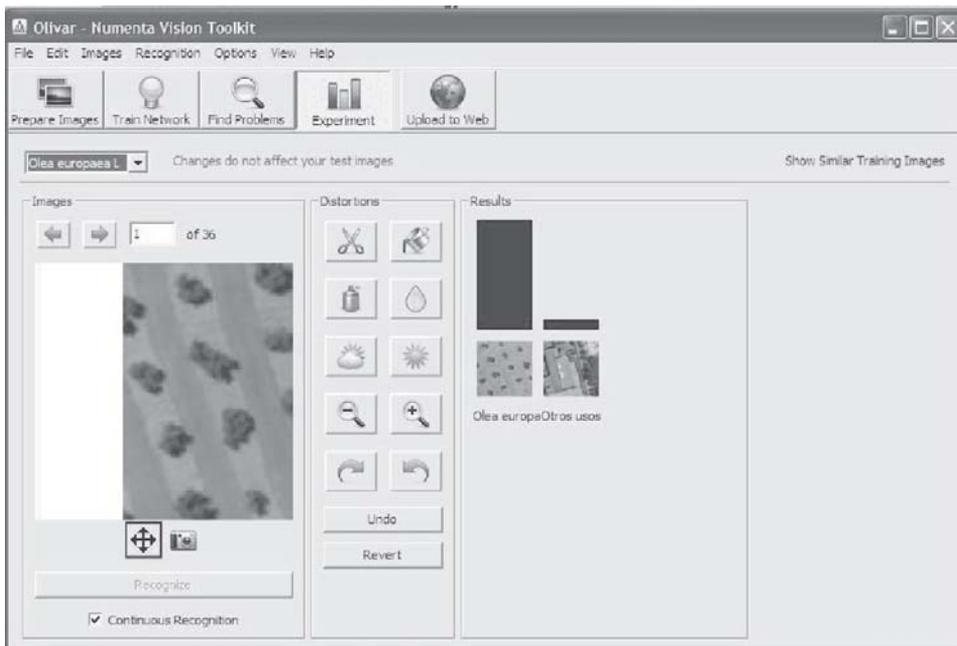


Fig. 4. Imagen parcial de la categoría *Olea europaea* L.
Fig. 4. Partial image of the category *Olea europaea* L.

Teniendo en cuenta una parte de la imagen original, la información que falta es reconstruida y la categoría se predice correctamente. Esto se asemeja a la capacidad del cerebro para recordar falta de información dada sólo la entrada parcial.

El sistema también puede tolerar una considerable cantidad de ruido de varios tipos y sigue re-

conociendo correctamente la categoría.

En general se ha observado que el sistema funciona mejor reconociendo imágenes que tienen características perceptibles, tales como esquinas e intersecciones de la línea, así imágenes que contenían el uso superficie edificada eran clasificadas con un 100% de acierto (Fig. 5).

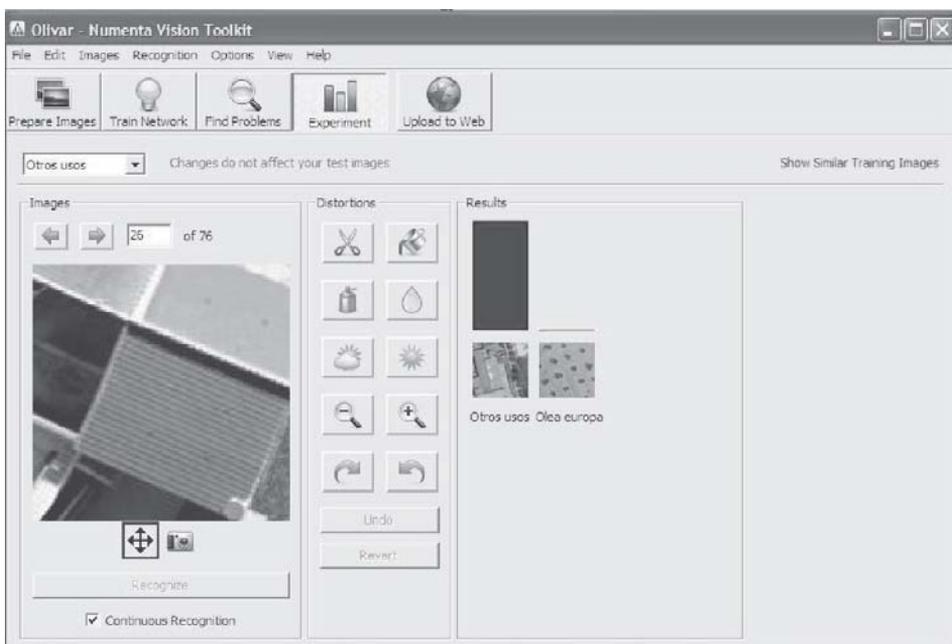


Fig. 5. Gráfico que muestra un 100% de acierto en la categoría "Otros usos".
Fig. 5. Graph showing 100% confidence in category "Other land uses".

El sistema también a veces tiende a confundir las categorías compartiendo muchas porciones similares, tales como olivar y vid, que poseen una distribución espacial parecida en algunos casos. También se observa que el rendimiento del reconocimiento se reduce cuando se introducen categorías muy similares en el entrenamiento, debido a la misma confusión entre las imágenes similares. En algunos casos raros, el sistema comete errores al reconocer una imagen aunque sea muy si-

milar a uno de los ejemplos de entrenamiento.

Finalmente se puede observar los buenos resultados de la clasificación, en la que se reducen en gran medida los problemas asociados al uso de imágenes de alta resolución espacial, como es el caso del habitual efecto sal y pimienta. Este efecto dificulta obtener una imagen clasificada limpia, observándose diferentes usos dentro de una parcela donde solo debía de haber uno único (Fig. 6).

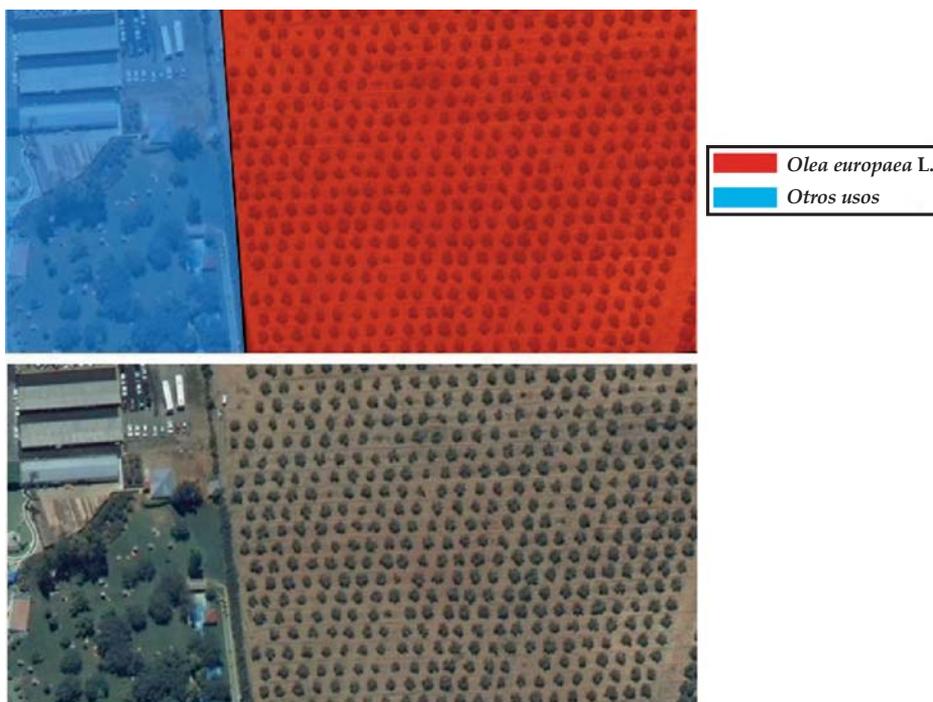


Fig. 6. Imagen clasificada obtenida del sistema basado en la Memoria Temporal Jerárquica.

Fig. 6. Classified image obtained from the system based on Hierarchical Temporal Memory.

El valor de precisión obtenido de la clasificación empleando el algoritmo basado en la Memoria Temporal Jerárquica es similar y/o superior a valores obtenidos por otros autores, lo que demuestra que la metodología es adecuada para la inventarización de olivares.

En la localidad de Granger, Washington, USA, los investigadores Warner y Steinmaus (2005) llevaron a cabo una clasificación basada en patrones espaciales en imágenes pancromáticas Ikonos sobre las categorías viñas y huertos, obteniendo una precisión total del 95,4%, valor inferior al obtenido en este trabajo.

En el sur de México, Mas (2005) realizó una clasificación usando sistemas expertos sobre las siguientes categorías: selva, manglar, cultivos agrícolas, agua y áreas urbanas. Se empleó una única imagen la cual incluía 5 bandas de las imágenes

satelitales LANDSAT ETM (Enhanced Thematic Mapper), consiguiéndose una precisión total del 67 %.

Aitkenhead y Wright (2004) clasificaron áreas urbanas, cultivos y suelo desnudo, usando redes neuronales en imágenes LANDSAT TM y obtuvieron un 60 % de precisión para áreas urbanas, 100% para agua y bosques, 90% para suelo desnudo y 95% para cultivos agrícolas.

CONCLUSIONES

En este estudio se ha propuesto un proceso integral para la detección de olivar, su delimitación y su caracterización dentro de la parcela. Las principales ventajas de este método son su fácil implementación, la velocidad de procesamiento y la cantidad limitada de parámetros.

El modelo empleado en este trabajo, llamado Memoria Temporal Jerárquica (MTJ), es una red de tipo Bayesiano, que asume una jerarquía de nodos donde cada nodo aprende coincidencias espaciales y temporales de patrones que aportan información del mundo que nos rodea. Este modelo posee una jerarquía similar a la que poseen las regiones corticales y en la que los nodos del modelo se corresponden con pequeñas regiones de la corteza cerebral.

En este trabajo se ha creado una red MTJ a través de la aplicación Nupic de la empresa Numenta® con la novedad de su uso en la inventarización de olivar, logrando discernir dentro de una misma imagen superficies de olivar y superficies con otros usos. Estos resultados demuestran que el enfoque MTJ contiene promesas para el registro de olivar.

BIBLIOGRAFÍA

- Aitkenhead, M.J., and G.G. Wright. 2004. Mapping land use in NE Scotland with neural networks from remote sensing imagery. 11 p. In *Remote Sensing and Photogrammetric Society Annual Conference*, Aberdeen. 6-7 September 2004. The Macaulay Institute, Craigiebuckler, United Kingdom.
- Bastiaanssen, W.G.M., D.J. Molden, and I.W. Makin. 2000. Remote sensing for irrigated agriculture: examples from research and possible applications. *Agric. Water Manage.* 46:137-155.
- Brandtberg, T., and F. Walter. 1998. Automated delineation of individual tree crowns in high spatial resolution aerial images by multiple-scale analysis. *Mach. Vision Appl.* 11:64-73.
- Calera, A., J. Reyes, C. Martínez, y J. Sánchez. 1999. Seguimiento de los cultivos de regadío en la mancha oriental desde 1982 a 1997, utilizando imágenes TM y MSS, en combinación con herramientas SIG. *Rev. Teledetección* 12:57-61.
- George, D., and B. Jaros. 2007. The HTM learning algorithms, Numenta. Numenta Incorporated, Redwood City, California, USA. Disponible en: http://www.numenta.com/for-developers/education/Numenta_HTM_Learning_Algos.pdf
- Gong, H., and P.J. Howard. 1990. An assessment of some factors influencing multispectral land-cover classification. *Photogramm. Eng. Rem. Sens.* 56:597-603.
- Gougeon, F. 1996. A crown-following approach to the automatic delineation of individual tree crowns in high resolution aerial image. *Can. J. Remote Sens.* 3(21):274-284
- Hawkins, J., and S. Blakeslee. 2004. *On intelligence*. Times books. Henry Holt and Co., New York, USA.
- Larsen, M. 1997. Crown modeling to find treetop positions in aerial photographs. p. 1007-1014. In *Proceedings of the 10th Scandinavian Conference on Image Analysis*. June 9-11, 1997. SCIA, Lappeenranta, Finland.
- Mas, J.F. 2005. Un método para combinar datos espectrales e informacion auxiliar en una red artificial neuronal. p. 3543-3549. In *Anais XII Simposio Brasileiro de Sensoriamento Remoto*. Goiania, Brasil. 16-21 abril 2005. Disponible en: <http://marte.dpi.inpe.br/col/ltid.inpe.br/sbsr/2004/11.16.18.07/doc/3543.pdf> (Verificado mayo 2011)
- Pollock, R.J. 1996. The automatic recognition of individual trees in aerial images of forest based on a synthetic tree crown image model. Ph.D. thesis. Computer Science. The University of British Columbia, Vancouver, Canada.
- Perea, A.J., J.E. Meroño, and M.J. Aguilera. 2009. Application of Numenta® Hierarchical Temporal Memory for land-use classification. *S. Afr. J. Sci.* 105(9-10):370-375.
- Rama Rao, N., P.K. Garg, and S.K. Ghosh. 2007. Development of an agricultural crops spectral library and classification of crops at cultivar level using hyperspectral data. *Precis. Agric.* 8:173-185.
- Rubio, E., M.M. Artigao, V. Caselles, C. Coll, y E. Valor. 2001. Cartografiado de la vid con datos Landsat-TM: Aplicación a una zona de Tormelloso (Ciudad Real). *Rev. de Teledetección* 15:47-56.
- Warner, T., and K. Steinmaus. 2005. Spatial classification of orchards and vineyards with high spatial resolution panchromatic imagery. *Photogramm. Eng. Rem. Sens.* 71(2):179-187.