

Enfoques para la clasificación digital de imágenes mono y multispectrales y su implementación en el software cubano TN Estudio V2.0

J. L. Gil¹, E. B. García¹, D. R. Ponvert-Delisle², R. Sánchez³, M. B. Vega⁴

Correo electrónico: jlgilr@hotmail.com, edel@cubalse.cu - dponvert@unah.edu.cu
mvega@civil.ispjae.edu.cu

¹GEOCUBA - Investigación y Consultoría, Calle 4 N.º 304, Playa, C. Habana, Cuba

²Universidad Agraria de La Habana, Autopista Nacional Km. 231/2 y

Carretera de Tapasta, A. P. 18 y 19, San José de Las Lajas, Provincia Habana, Cuba

³GEOCUBA Guantánamo, 1 Oeste N.º 1053 altos e/ Bernabé Varona y Donato Mármol, Guantánamo, Cuba

⁴Inst. Superior Politécnico José A. Echeverría, 127 s/n, Marianao, CP-19390, C. Habana, Cuba

RESUMEN

En el presente trabajo se hace una descripción conceptual de todos los procesos que intervienen en la clasificación digital de imágenes mono espectrales y multispectrales. Se hace una revisión en publicaciones recientes para ofrecer una información actualizada sobre el concepto de *clasificación*, sus campos de aplicación en la actividad de investigación humana, *modalidades* en que se emplea y los *clasificadores* estadísticos y de redes neuronales artificiales implementados con más frecuencia en sistemas computacionales. El *muestreo digital* de imágenes es descrito como la columna vertebral del proceso de clasificación así como los factores que intervienen en su calidad. Se analiza el uso de procedimientos para el mejoramiento de las muestras seleccionadas buscando la eliminación de muestras tomadas por error y la atenuación / eliminación de la redundancia informativa. Teniendo en cuenta la importancia de la matriz de informaciones se describe su estructura a partir de *cráteros de clasificación* basados en los tonos, en descriptores de textura y el uso combinado de ambos para diferenciar las categorías temáticas presentes en la imagen. La generación de la *información de aprendizaje / control* destinadas al entrenamiento de los clasificadores y como vía para conocer la *efectividad* del clasificador. Se ofrecen detalles acerca de la *matriz de confusión* y su uso para evaluar la calidad con que han quedado establecidas las categorías deducidas después del proceso de clasificación. Finalmente, se hace una descripción de los métodos comúnmente empleados en el proceso de *muestreo de campo* para la verificación "in situ" del documento temático que está en preparación como resultado de toda la secuencia de la clasificación digital.

PALABRAS CLAVE: clasificación, imágenes, multispectrales, muestreo, matriz de confusión.

ABSTRACT

Presently work is made a conceptual description of all the processes that take place in mono and multispectral images digital classification. A revision is made in recent publications to offer an up-to-date information on the classification concept, its application fields in the activity of human investigation, the modalities that it is used and the statistical classifiers and then the neuronal-artificial nets classifiers implemented with more frequency in computational systems. The digital sampling of images is described as the spine of the classification process as well as the factors that take place in its quality. The use of procedures is analysed for the improvement of the selected samples looking for the elimination of samples taken by mistake and the attenuation / elimination of the informative redundancy. Keeping in mind the importance of the matrix of information their structure is described starting from based classification approaches in the tones, in texture descriptors and the combined use of both to differentiate the categories thematic present in the image. The generation of the learning information / control designated to the training of the classifiers and as form to know the effectiveness of the classifier. They offer particulars about the matrix of confusion and their use to evaluate the quality with which they have been established the derived categories after the classification process. Finally, a description of the methods is made commonly employees in the process of field sampling for the verification "in situ" of the thematic document that is in preparation as a result of the whole sequence of the digital classification.

KEY WORDS: classification, images, multispectral, sampling, matrix of confusion..

INTRODUCCIÓN

La clasificación digital de imágenes es el proceso de ordenar los píxeles de una imagen en un número definido de clases o categorías de datos, basado en los valores de un conjunto de variables o de píxeles. Si el valor satisface un conjunto de condiciones se asigna a una clase que responde a esas condiciones. Expresado más rigurosamente, el objetivo de la clasificación es, dado un conjunto de objetos presentes en la imagen, cada uno de los cuales viene descrito por un conjunto de variables, asignar cada uno

		descriptores			
		V_1	V_2	V_M
individuos	1	X_{11}	X_{12}	X_{1M}
	.	X_{21}

	N	X_{N1}	X_{NM}

Figura 1. Matriz de observaciones.

de ellos a la clase con la que mejor se identifica. La Fig. 1 muestra precisamente esa estructura multivariada, donde los N individuos representan los objetos y los V_M descriptores, las variables.

Al final, la imagen ha quedado dividida en áreas que están etiquetadas, o simplemente segmentada en regiones, por lo cual a este proceso también se le llama segmentación de la imagen. La clasificación digital de imágenes se dirige a obtener una nueva imagen en la cual cada uno de los píxeles originales viene definido por un nivel digital que es el identificador de la clase en donde se haya incluido. La clasificación está relacionada con la obtención de un mapa temático a partir de la conversión de los tonos continuos de la imagen mediante un proceso que categoriza los píxeles en tipos de coberturas o temas.

Importancia de la clasificación digital de imágenes. Aplicaciones en disímiles ramas de las ciencias

El objetivo principal de la aplicación de las técnicas de procesamiento digital de imágenes en las geociencias, es la obtención de una clasificación digital que representa los tipos de cubrimientos que existen en la escena, y en este sentido, están orientados los tratamientos previos que se le realizan a la imagen como son, su mejoramiento visual, el filtrado digital, la detección de fronteras, las operaciones entre bandas, etc, puesto que los resultados de la clasificación “marcan la calidad final del proyecto desarrollado” (Chuvieco, 1995).

La necesidad del empleo de las técnicas de clasificación está dada por las características de los sensores de teledetección, los cuales originan diferentes ND para un mismo tipo de cubierta, lo que obliga a encontrar métodos y medidas de semejanzas basados en los valores multispectrales asociados a los puntos. Dichas medidas de semejanza se utilizan para agrupar los píxeles en categorías que faciliten la asociación con los tipos de cubrimientos presentes en el terreno. Son precisamente, las técnicas de clasificación las que proporcionan el conjunto de herramientas para desarrollar esta tarea, posibilitando finalmente, una etiqueta para cada pixel haciéndolos “interpretables; esto es, convertibles a categorías que supongan un mejor conocimiento del territorio” (Chuvieco, 1995). La interpretación se puede hacer analógicamente empleando versiones impresas de las imágenes, o automatizadamente mediante computadoras. El resultado de la clasificación digital es producir una cartografía que describa espacialmente, la distribución de las categorías objeto de estudio y unas tablas estadísticas, que ayuden a resumir y comprender mejor el inventario superficial de las categorías de interés.

Chuvieco (1995), ha definido claramente que “la clasificación digital no busca una definición absoluta de cada cubierta, que pudiera ser aplicable a cualquier imagen, sino más bien una característica peculiar, válida para una determinada imagen, un territorio concreto y un momento dado. Con este planteamiento, no resulta preciso conocer detalladamente las condiciones de adquisición; basta identificar en la imagen, las cubiertas de interés, sin pretender que esa identificación sea extrapolable a otras situaciones. En resumen, no se trata de establecer un modelo entre medidas digitales y parámetros físicos, sino entre medidas digitales, en un momento dado y tipos de cubierta. En este sentido,

la clasificación supone un enfoque más cualitativo, si bien, por tratarse de un proceso numérico, incorpora un aparato estadístico y modelos matemáticos ciertamente importantes”.

La clasificación digital obtiene una nueva imagen, en la cual cada uno de los píxeles originales ha sido redefinido por un ND o un color, que es el identificador de la clase en donde se haya incluido. Estas clases pueden describir distintos tipos de cubierta, por ejemplo, una clasificación de especies vegetales, o un intento de señalar niveles de afectación en un incendio forestal, o de humedad en una inundación. Estos son ejemplos típicos del campo de las geociencias, pero otros válidos se podrían encontrar en laboratorios de anatomía patológica para evaluar la extensión superficial de ateromas, zonas sanas, zonas oscuras por la presencia de huecos; en medicina interna para el estudio del aparato óseo mediante radiografías; la clasificación de los cromosomas humano; en biotecnología de las plantas para la delimitación del citoplasma, el núcleo y otros eventos. El tema de la clasificación de imágenes se extiende cada vez más en muy diversos campos de la actividad humana.

Sea uno u otro el propósito del proyecto, la clasificación digital mediante computadoras sigue cauces análogos a los que se emplea en foto – interpretación, o el análisis visual de un dato gráfico. En esta última técnica, en primer lugar, el interpretador identifica cada cubierta con un patrón de referencia, para lo cual se apoya en una serie de criterios de clasificación como tono, textura, forma, disposición, etc. Esa misma identificación, del patrón previamente definido, la realiza sobre las restantes reproducciones gráficas. La interpretación analógica consiste, entonces, en asignar a cada categoría, determinadas superficies, en función de la semejanza de éstas con el patrón tipo identificado previamente, lo que resta es verificar sobre el *terreno* la interpretación realizada. Por cauces diferentes, este es el mismo esquema de la clasificación digital. Se necesita una secuencia de pasos para traducir los criterios analógicos por digitales, por cuanto se realiza sobre los ND presentes en la imagen. Chuvieco (1995), ha distinguido las siguientes fases: (i) definición digital de las categorías (fase de muestreo - entrenamiento), (ii) distribución de los píxeles de la imagen en una de esas categorías (fase de asignación), y (iii) comprobación y verificación de resultados. Estas ideas se discuten en el presente trabajo.

Principales enfoques que existen en la clasificación digital

La clasificación de imágenes se lleva a cabo a partir de un método y de una medida cuantitativa que ayude a encontrar la semejanza o no, entre las partes de la imagen. Hay muchos métodos y también muchas medidas. Los métodos pueden aplicar una técnica supervisada, o una técnica no supervisada, un enfoque estadístico, o redes neuronales artificiales para el reconocimiento de los patrones. Se requiere la combinación de uno de esos métodos, con una de esas medidas, para llevar a cabo la clasificación a través de un proceso integrado por varios pasos que dependen del carácter supervisado o no supervisado del método que se aplique.

La clasificación no supervisada es una técnica de “agrupamiento”, cuyo término viene del inglés “clustering”. En esta técnica una imagen es segmentada en clases desconocidas. Este enfoque se dirige a definir las clases espectrales, que están presentes en la imagen. No implica ningún conocimiento del área de estudio, por lo que, la intervención humana se centra más en la interpretación de los resultados, que en la preparación de los datos para su obtención. Estas técnicas no necesitan del proceso de muestreo de la imagen. Esto es así, por cuanto la clasificación no supervisada de imágenes es la búsqueda automática de grupos de valores homogéneos dentro de la imagen, a partir de un algoritmo que ha sido adecuado para etiquetar convenientemente esos grupos de píxeles. La tarea final del usuario es comprender el significado de las clases formadas asociándolas con eventos naturales que tienen un significado físico. En este sentido debe decidir qué cluster representa cada clase física de las presentes en la imagen, es decir, qué cluster corresponde con vegetación, suelos, área urbana, etc., o en términos médicos qué cluster representa ‘la enfermedad’, cuál representa el área ‘no enferma’, etc.

El método supervisado parte de un cierto conocimiento de la zona de estudio, adquirido por experiencia previa o por trabajos de campo. Esta mayor familiaridad con la zona de estudio, permite al interpretador delimitar sobre la imagen áreas piloto, que se consideran suficientemente representativas de las categorías que componen la leyenda. Estas áreas se denominan, en la bibliografía anglosajona, “training fields” (campos de entrenamiento) y que en este trabajo se le ha identificado como información de aprendizaje y de control. El término indica

que tales áreas sirven para “entrenar” al algoritmo en el reconocimiento de las distintas categorías. A partir de ellas el procedimiento determina que ND definen cada una de las clases, para luego asignar el resto de los píxeles de la imagen a una de estas categorías en función de sus ND y la textura. La clasificación supervisada es el procedimiento empleado comúnmente en el análisis cuantitativo de los datos de teledetección, aunque muchas especialidades que no están vinculadas a las ciencias de la tierra, ya aprovechan esta tecnología.

La lógica indica que el método supervisado pretende definir clases informacionales, mientras que el no supervisado tiende a identificar las clases espectrales presentes en la imagen, aunque a decir verdad, ninguno de los dos, puede considerarse como algo completamente eficaz. Existen ventajas y desventajas que el usuario tendrá que evaluar a la hora de decidir como abordar el proyecto en cuestión.

MATERIALES Y MÉTODOS

Procesos generales que están contenidos en la clasificación digital de una imagen (CDI)

Al abordar la CDI, resulta prácticamente imprescindible para el especialista, desde el punto de vista metodológico, desarrollar los siguientes tres grupos de procesos:

- Procesos previos a la CDI

Incluye los procesos preparatorios de la imagen a clasificar y la definición de los datos de partida necesarios para abordar la clasificación. Los primeros son elementales e incluyen el despliegue de la imagen, su revisión, la comprobación de sus datos de cabecera y el más importante de todos, el estudio de la escena hasta llegar a conocerla bien. Este último aspecto, es muy parecido a lo que comúnmente se conoce como foto-interpretación. Su objetivo es que el analista identifique cada cobertura presente en la escena, de acuerdo a una serie de criterios: tono, textura, forma, disposición, etc. Entonces, en lo adelante esta interpretación visual, le permitirá delimitar mentalmente, sobre la superficie que ocupa la escena, las zonas que se corresponden con cierto patrón previamente definido. En otras palabras, asocia cada categoría con determinadas superficies, en

función de la semejanza de éstas con el patrón - tipo identificado previamente (Chuvieco, 1995). Sin embargo, lo anterior resultaría muy difícil, si previamente no se ha establecido una leyenda de clases informacionales, que responda a los objetivos particulares del proyecto y que en última instancia debiera concretarse a partir de una leyenda de categorías de ocupación del suelo, más general, concebida para estudios por teledetección. Hacemos hincapié en este último aspecto, pues si no se conocen estas denominaciones, difícilmente podrá alcanzarse una clasificación temática posterior con la organicidad y homogeneidad que se requiere en estudios de este carácter.

- Procesos durante la CDI

Los procesos que se desarrollan dependen del tipo de clasificador que se utiliza; supervisado o no supervisado. La clasificación supervisada contiene dos momentos básicos: (1) Definición digital de categorías o fase de entrenamiento y (2) Asignación de los píxeles de la imagen a una de esas categorías.

El objetivo de la fase de entrenamiento es seleccionar una cantidad de píxeles (muestra), que sean lo suficientemente representativos de cada una de las clases informacionales de la leyenda adoptada en el proyecto. Esto ha sido considerado por la inmensa mayoría de los analistas de imágenes como el momento crucial del proceso clasificatorio supervisado, pues de la “pureza” de dicha muestra, dependerán los procesos ulteriores de asignación del resto de los píxeles de la imagen a las categorías establecidas. Para garantizar una buena selección de una muestra, existen medios visuales interactivos y se puede acudir a modelos matemáticos-estadísticos que favorecen la depuración del conjunto de muestras de cada clase informacional, con un criterio lo suficientemente aceptable. La fase de asignación, tiene por objetivo adjudicar a cada una de las clases previamente definidas, cada uno de los píxeles de la imagen, proceso que se realiza a partir de la similitud de sus ND y/o el valor cuantitativo de la textura, ya se trate de una imagen monobanda o en todas las bandas involucradas. El resultado de esta asignación, será una nueva imagen conformada por conglomerados de píxeles similares que representan las clases informacionales (temáticas) en que se han incluido los mismos.

La clasificación no supervisada es menos exigente, incluye dos procesos también: (1) definición de la cantidad de clases o grupos en que debe ser segmentada la imagen, y (2) asignación de los píxeles de la imagen a esos grupos. La fase de asignación se ejecuta a partir de centroides iniciales que se le establecen a cada clase y se van moviendo hacia un nuevo centro de clase en la medida en que se incorporan nuevos píxeles a las clases como resultado de la evaluación de sus ND y/o el valor cuantitativo de la textura. El resultado ofrece las clases espectrales, no las temáticas, por lo que estas deben ser interpretadas. Esa nueva imagen, supervisada o no, ahora con el rango de imagen clasificada, en numerosos casos suele ser el producto final del trabajo (mapa temático) o puede ser incorporada a un proyecto de mayor alcance que permita la realización de análisis espaciales georreferenciados en un Sistema de Información Geográfica (SIG).

- Procesos post CDI

Son los procesos realizados a la imagen clasificada con el fin de mejorar el resultado, obtener un grupo de estadísticas y evaluar la precisión de la clasificación. En cuanto al primer aspecto, habitualmente se mejora la imagen obtenida mediante la combinación de las clases y el agrupamiento de píxeles (en inglés, Clump and Sieve descrito en ENVI (1998), y el filtrado digital con la media, la mediana, o la moda; todos ellos dirigidos a obtener un producto temático de mejor definición, generalización y estética. Las estadísticas que comúnmente se obtienen acerca de cada superficie delimitada (categoría), comprenden al menos los siguientes parámetros; ND mínimo, ND máximo, ND promedio, desviación standard y autovalor, este último sugerido en algunos sistemas computacionales; además del análisis de sus histogramas. Sin embargo, el proceso post-clasificatorio más importante consiste en la comprobación o verificación "in situ" de los resultados de la clasificación, para lo cual habrá de desarrollarse toda una estrategia dirigida a verificar el grado de correspondencia existente entre las clases temáticas obtenidas luego de la clasificación digital y la realidad del terreno. La imagen clasificada que ha sido aceptada por su rigor técnico y su valor informativo puede ser exportada a un mapa – imagen, o vectorizados sus rasgos más importantes para un SIG.

tada a un mapa – imagen, o vectorizados sus rasgos más importantes para un SIG.

Evolución de los criterios de clasificación

Tradicionalmente han sido empleados como criterios de clasificación los siguientes: (i) emplear los niveles digitales (tonos) de las imágenes, (ii) emplear los valores texturales en torno al pixel, y más recientemente, (iii) combinar los tonos y la textura. El más universal de ellos es el criterio *Tono*, que además, fue el primero que se utilizó y puede decirse, que con la aparición de nuevas bandas en los sensores espaciales se refuerza su presencia, ya que se incrementa su poder de resolución de los objetos. El criterio *Textura* ha sido utilizado como una alternativa para añadir nuevas variables a la matriz observacional y por esa vía intentar un mayor poder descriptivo de los objetos. En esta dirección han aparecido muchos enfoques teóricos (Gil, 1996) donde se describen algoritmos y procedimientos para llegar al cálculo numérico de la textura. Esto es así, dado que aún se carece de una definición precisa del concepto textura y los diferentes modelos teóricos hacen sus aportes en definiciones y algoritmos matemáticos para su cálculo. Hoy se continúa internacionalmente en esta fase experimental buscando los mejores descriptores. El criterio *Tono + Textura*, es aún más reciente, y sigue un cauce análogo al anterior. Sea cual fuere el criterio de clasificación que se adopte, siempre se pretende encontrar las mejores variables para describir las superficies recogidas en la imagen y entregárselas al clasificador.

Evolución de los clasificadores

Un cuadro resumen del desarrollo de los clasificadores según su algoritmo, podría organizarse en paramétricos, no paramétricos, estadísticos, redes neuronales artificiales, supervisados, no supervisados y según el número de imágenes en el proceso de clasificación en Monoespectrales, Multiespectrales e Hiperespectrales (Fig. 2). Se les denomina clasificadores paramétricos a aquellos que hacen uso de una figura geométrica para ubicar dentro de sus contornos los puntos pertenecientes a una clase. El término "paramétrico", entonces, se refiere a los parámetros que describen la figura geométrica. A modo de ejemplo podrían ser citados, el clasificador de Máxima

Probabilidad que utiliza una elipse para delimitar cada clase; y el Paralelepípedo que lo hace con una figura del mismo nombre. Los clasificadores no paramétricos no hacen uso de figuras geométricas, sino que sus principios son otros, por ejemplo, los que usan medias migratorias, para contornear la membresía de las clases. En general, los clasificadores se han utilizado como métodos heurísticos en el análisis de datos en diferentes campos, en particular con imágenes satelitales. En teledetección, el clasificador tradicionalmente utilizado es el de “Máxima Probabilidad (Verosimilitud)” aunque han jugado un papel importante aquellos basados en las medias migratorias como son el “ISODATA” (Iterative Self-Organizing Data Analysis Techniques), el de las “K-Medias”, la “Mínima Distancia a la Media” y otros como el “Paralelepípedo”, conocido también como regla MinMax, el de “Distancia de Mahalanobis” y el “Vecino más Cercano” con una nueva variante (García, 1996). Autores como Chuvieco (1995), señalaban otros clasificadores tales como el “Clasificador de Árbol”, pero hasta el presente no conocemos de su implementación a nivel operacional. Otras tendencias más actuales aprovechan las capacidades de aprendizaje, robustez ante los ruidos y capacidad de generalización que poseen las redes neuronales artificiales (Gil, 1995; García, 1996), y los métodos de clasificación utilizando datos hiperespectrales que están capacitados para mejorar los resultados hasta el punto que pueden ser comparados con las propiedades espectrales de los materiales. Entre ellos se encuentran: “Binary Encoding Classification” y “Spectral Angle Mapper Classification” (ENVI, 1998).

En Cuba se comenzó por primera vez a investigar y experimentar con clasificadores adaptados al análisis de imágenes, a comienzos de 1992 y se han obtenido resultados alentadores en ese campo. Se han hecho tres implementaciones que se han difundido

en el país (DIPSY, 1993; RSI, 1996; Tn Estudio, 2000) con aplicaciones en medicina y teledetección. En esta última dirección han sido introducidos métodos estadísticos paramétricos y no paramétricos, redes neuronales artificiales con opciones supervisadas y no supervisadas, estudiándose sus ejecutorias sobre imágenes aéreas pancromáticas, de vídeos y procedentes de plataformas espaciales de SPOT y Landsat. El enfoque espectral ha predominado sobre el contextual (textura), limitándose este último al tratamiento de imágenes pancromáticas en regiones donde se carecía de imágenes multiespectrales.

Integración de estos procesos en Tn Estudio

Tn Estudio V2.0 es un sistema de Procesamiento Digital de Imágenes desarrollado por un grupo de especialistas en Teledetección Espacial y Programadores del Grupo Empresarial GEOCUBA para asistir los estudios por métodos de Teledetección. Está concebido para los investigadores que necesitan realizar la interpretación del contenido de la imagen digital y desde este punto de vista tiene funcionalidades de propósito general. La aplicación posee las siguientes características: (1) Contiene implementada una tecnología para el procesamiento, el análisis y la interpretación de imágenes digitales donde están representados los principales grupos de algoritmos para el tratamiento del tono en imágenes mono y multiespectrales. (2) Contiene implementado un conjunto de descriptores de textura, que se combinan con el tono natural de la imagen, para apoyar la generación de imágenes temáticas con técnicas de clasificación supervisada y no supervisada. (3) La diversidad de algoritmos que contiene responden a principios físico – matemáticos para el tratamiento digital de la imagen, métodos

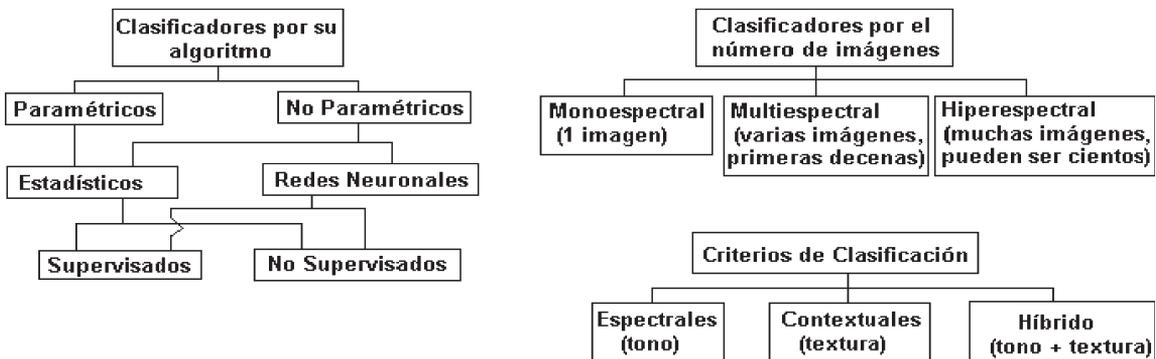


Figura 2. Los clasificadores multivariados según los diferentes modelos teóricos desarrollados.

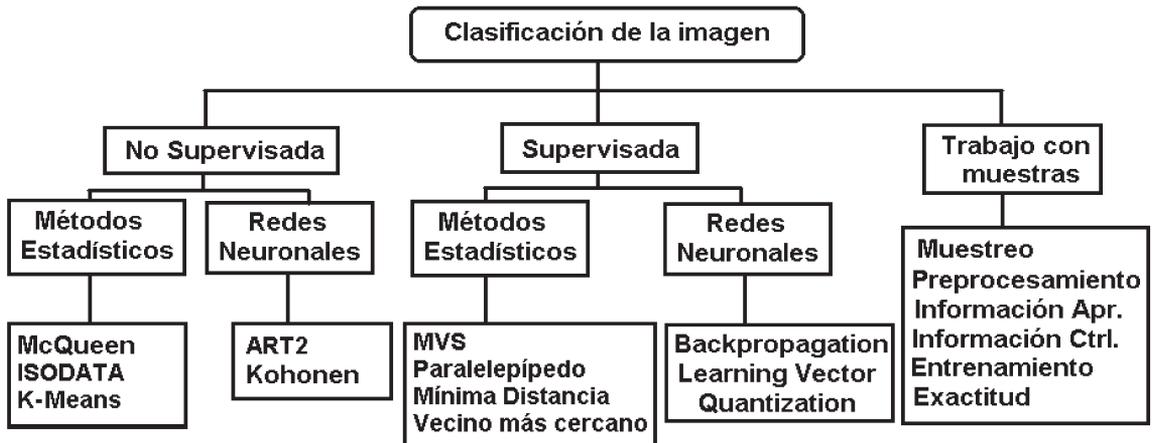


Figura 3. Clasificadores no supervisados y supervisados, estadísticos y de redes neuronales artificiales que posee el Sistema Tn Estudio V2.0

de la estadística univariada y multivariada cuya finalidad última es la descomposición de la información contenida en la imagen. Los operadores de transformación están organizados en: operaciones puntuales, entre dos bandas espectrales, entre múltiples bandas espectrales, de mejoramiento del contraste basado en el histograma de la imagen y en técnicas estadísticas; de filtrado digital lineal y no lineal mediante filtros internos y externos suministrados por el usuario, operaciones de diseño de filtros digitales en el dominio de las frecuencias y en el dominio de los datos, operaciones de detección de bordes y lineamientos; operaciones de segmentación local, global y basada en regiones. Todas estas operaciones dan el soporte necesario para la descomposición de la información gráfica, aislándola en imágenes nuevas, para su interpretación dando lugar así a la creación de capas informativas.

Clasificadores de la aplicación Tn Estudio

En el software Tn Estudio V2.0 se incluyen clasificadores supervisados y no supervisados de imágenes que responden a principios de la estadística multivariada, markovianos o no, y otros pertenecientes al campo de la inteligencia artificial como son las redes neuronales artificiales (Fig. 3).

Clasificadores estadísticos

Los clasificadores estadísticos consideran que los patrones de las clases forman una población estadís-

tica caracterizada por una determinada función de distribución o función de densidad. Estas funciones tienen una forma en general desconocida, por lo que los clasificadores intentan ajustarlos a los diferentes modelos teóricos conocidos, siguiendo enfoques paramétricos o no paramétricos. Sobre la base de esta modelación se definen fronteras de decisión con el objetivo de disminuir las probabilidades de error de asignación de los patrones. Los clasificadores estadísticos implementados en Tn Estudio son: los métodos de McQueen, el tradicional ISODATA, el de K-Medias, Máxima Verosimilitud (Probabilidad), el Paralelepípedo, Mínima Distancia a la Media y la regla del Vecino más Cercano (1nn). Los tres primeros en la relación son clasificadores no supervisados y los restantes, supervisados.

Clasificadores basados en redes neuronales artificiales

Las redes neuronales son modelos matemáticos y computacionales inspirados en estructuras existentes en el cerebro humano que han encontrado gran aplicación en tareas complejas de procesamiento de información (Wasserman, 1989). Existen numerosos modelos y paradigmas de redes neuronales, pero todos parten del uso de unidades de procesamiento de información elementales (las neuronas artificiales), las que se utilizan colectivamente de diferentes maneras, según los diferentes modelos que se representan. En general, una red neuronal es una estructura paralela y distribuida de procesamiento de información, compuesta de estos proce-

sadores elementales interconectados mediante pesos sinápticos.

Un clasificador neuronal es el que se diseña para generar, mediante un proceso adaptativo de los pesos de interconexión, un operador de asignación que permite asociar un elemento del conjunto de patrones, con un elemento del conjunto de categorías o clases. En general el conjunto de patrones a clasificar está asociado a la capa de neuronas de entrada de la red, y las clases se asocian a la capa de salida. Se generan tantas neuronas artificiales en la capa de entrada, como variables espectrales haya (tonos, texturas, tonos+texturas), y el entrenamiento de la red especializa una neurona de la capa de salida para cada clase informacional definida (red supervisada) o encontradas en los datos (red no supervisada).

Los clasificadores basados en redes neuronales implementados en ese software son los modelos de ART2, el Mapa Auto – Organizativo diseñado por el finlandés Kohonen, el algoritmo de entrenamiento de redes multicapas de Propagación hacia Atrás (Eberhart y Dobbins, 1990) y el modelo LVQ. Los dos primeros desarrollan la clasificación no supervisada y los dos últimos, la supervisada.

Criterios de clasificación: Tono, Textura, Híbrida

Hay tres posibilidades para preparar la matriz de observaciones, (1) utilizando el “Tono”, (2) calcu-

lando descriptores de “Textura”, y (3) combinando “Tono + Textura”. En el *Criterio Tono* el clasificador va a utilizar el valor que tiene el ND en todas y cada una de las bandas que se decide incorporar al proceso. Cada punto de la imagen está representado por un vector de tonos de gris. En el *Criterio Textura* el clasificador va a utilizar el valor cuantitativo que tiene la textura en todas y cada una de las bandas que intervienen en la clasificación y con ellos se construye el vector de rasgos. Como la textura es un concepto asociado a la vecindad del pixel, el software tiene que ofrecer la implementación computacional para calcular el conjunto de estos descriptores; en nuestro caso se ofrecen hasta 10 variantes pertenecientes a la estadística de primer orden (Gil, 1996a; Gil y Vega, 1996b, 1997a, 1997b) a partir de una vecindad de tamaño 3x3 píxeles. Cada punto de la imagen está representado por un vector de parámetros de textura. En el *Criterio Tono+Textura* la matriz de observaciones se construye utilizando los tonos de la imagen multispectral, a los que se le adicionan los parámetros de textura.

Es de notar que una implementación de esta naturaleza está conceptualizada para llevar a cabo la *clasificación mono espectral* (la entrada sólo tiene una imagen), la *clasificación multispectral* (la entrada es un conjunto de imágenes) y la *clasificación híbrida* donde se mezclan el tono y la textura (Fig. 4).

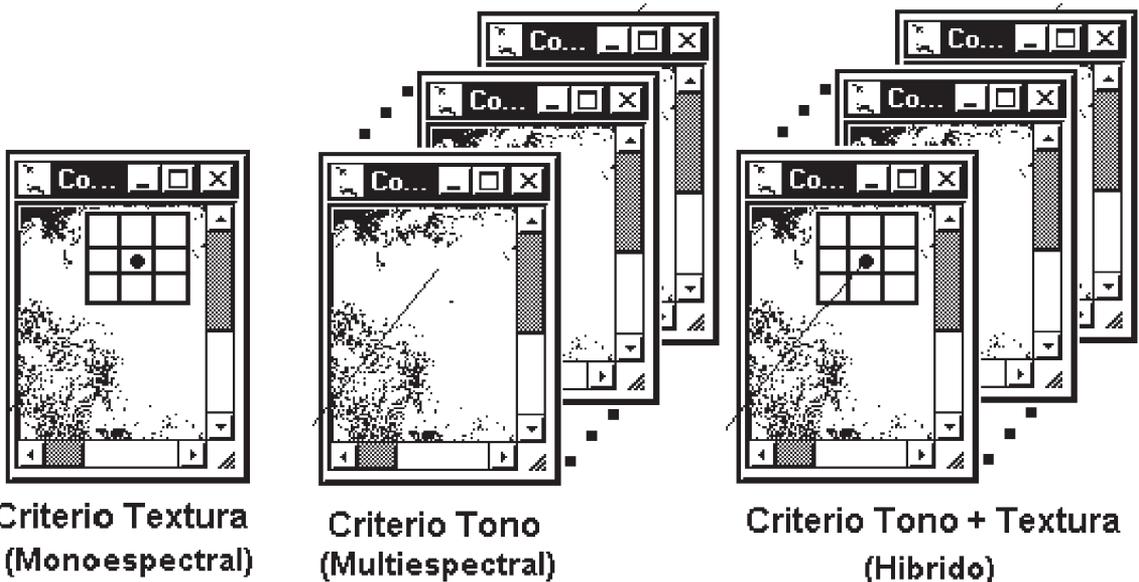


Figura 4. Criterios de clasificación implementados en Tn Estudio V2.0.

El software puede contemplar el caso de clasificación mono espectral usando el tono de una vecindad de tamaño $N \times M$ píxeles, lo cual no está considerado en nuestra versión actual.

Muestreo digital de imágenes. Factores

La clasificación supervisada exige un conjunto de ejemplos compuestos por patrones que describan las categorías informacionales de interés, lo que se obtiene a partir del muestreo. El diseño y desarrollo del muestreo de datos supone la columna vertebral del proceso de clasificación. En particular el muestreo de datos, a partir de una imagen digital es un proceso que determina la calidad de su clasificación digital. El muestreo espacial sirve para seleccionar una pequeña parte del área de estudio, de tal forma que sea suficientemente representativa del conjunto de categorías. Esa semejanza con la población de referencia debe conseguirse, además, minimizando el tamaño de la muestra (Chuvieco, 1995). La principal virtud de un buen muestreo es seleccionar adecuadamente una parte de la imagen que va a ser clasificada, de tal forma que, siendo tan pequeña como sea posible, sea a la vez suficientemente representativa del conjunto de categorías. Esa semejanza depende de varios factores, entre los cuales consideramos como más importantes los siguientes: (1) calidad en la selección de la muestra, (2) valor informativo de la imagen o imágenes para el propósito deseado, (3) poder discriminante de los descriptores para diferenciar las categorías que están presentes, y por último, (4) calidad del entrenamiento (si se trata de redes neuronales supervisadas). Esos factores los interpretamos como sigue:

Calidad en la selección de la muestra: La calidad de la muestra está en relación directa con los niveles digitales que van a describir cada categoría o clase. Se exige que el especialista sea capaz de identificar la expresión digital que toma cada categoría, en términos de las tonalidades en el display. Para ayudar a resolver este punto, la interfaz debe ofrecer la capacidad de emplear imágenes a color o en tonalidades de gris (Fig. 5), a partir de las cuales sea posible llevar a cabo el muestreo de la imagen. Incluso, emplearlas de manera combinada en un mismo proceso de muestreo, de tal modo que el especialista aproveche la mejor expresión de las categorías.

Valor informativo de la imagen: La imagen debe reflejar los objetos que se desean estudiar. Este aspecto hace una referencia directa a la necesidad que tiene el especialista de conocer los objetos que está buscando en la imagen y para ello debe interiorizar el contenido de la imagen y llegar a conocerla bien, aún antes de hacer el muestreo. Sólo así puede estar en capacidad de saber si la imagen disponible para hacer el trabajo posee la información que desea extraerle. Normalmente se requieren de algunos pasos de pre-procesamiento para generar nuevas imágenes donde alcance mejores expresiones sobre los objetos que se desean categorizar.

Poder discriminante de los descriptores: No todos las bandas espectrales y descriptores de textura poseen igual poder discriminante y hay que encontrar los conjuntos apropiados. Crosta (1992) afirma que existen grandes posibilidades de que las situaciones reales no sean solucionadas con apenas una o dos bandas espectrales. En ese caso, es esencial que se disponga de un número mucho mayor de bandas para que sea alcanzada una buena caracterización espectral de las superficies. Por tanto, como regla general, se puede decir que cuanto mayor sea la precisión de las bandas espectrales, mayor será la precisión de la clasificación. Luego, es posible resolver este problema, usando el criterio de tonos con más de tres bandas de una imagen multiespectral, o usando criterios de textura. En oportunidades la mejor solución está en el uso combinado de ambos criterios.

Calidad del entrenamiento: Las redes neuronales tienen la capacidad de aprender a partir de ejemplos y esos ejemplos son las muestras de aprendizaje. Ellas aprenden a diferenciar los objetos si los descriptores los diferencian, y cuando esto sea así, se debe exigir un mínimo de error en el proceso de convergencia.

Habitualmente el muestreo de la imagen queda almacenado en un archivo donde cada punto tiene la referencia de las coordenadas – imagen al que pertenece. Partiendo de este archivo se procede a construir la información de aprendizaje y de control.

Información de aprendizaje / control

La “Información de Aprendizaje” es un conjunto de puntos pertenecientes a las áreas conocidas de la imagen que sirven para entrenar el algoritmo de clasificación en el reconocimiento e identificación de



Figura 5. Interfaz de Tn Estudio para muestrear la imagen. Se ilustra el empleo de una imagen falso color en el proceso de muestreo de una imagen multispectral.

las distintas categorías presentes en el contexto de la imagen. El clasificador aprende sobre la base de los ejemplos que están en este conjunto de muestras. El aprendizaje se realiza examinando la colección de vectores que representan los ejemplos de cada clase lo que permite al clasificador, ajustarse para poder reconocer los patrones de entrada correspondientes a las clases que ellos representan. Esto habla de la importancia que tiene el haber realizado un buen muestreo.

La “Información de Control” es un conjunto de puntos pertenecientes a las áreas conocidas de la imagen, que sirven para verificar numéricamente la calidad del reconocimiento de las distintas categorías presentes en la imagen y que el clasificador no ha visto. Difícilmente el entrenamiento del clasificador es perfecto, es decir, sin error, y por ello existe un error o tolerancia que el usuario debe asumir. De aquí la necesidad de llegar a conocer en que categorías se cometieron los errores y en que cuantía. A partir de las áreas de control es el clasificador quien calcula el nivel de error con el que fueron

definidas cada una de las clases. La información detallada acerca de la exactitud obtenida en la clasificación es brindada en la así llamada Matriz de Confusión que se describe más adelante.

El interpretador tiene la capacidad de muestrear la imagen, pero en nuestra consideración, no debe decidir cuáles son las muestras que formaran parte del conjunto de aprendizaje y cuáles el de control; esa selección puede seguir un criterio de aleatoriedad simple.

Los elementos que van a formar parte de cada uno de esos dos conjuntos, el conjunto de las muestras de aprendizaje y el conjunto de las muestras empleadas en el proceso de control, se eligen de tal forma que todas las muestras (patrones) cuenten con la misma probabilidad de ser seleccionadas para uno u otro subconjunto, y que la elección de una no influya en la probabilidad de la siguiente para ser elegida. Gracias a este carácter probabilístico, el muestreo aleatorio es el más sólido estadísticamente, si bien presenta problemas en su aplicación espacial, por cuanto existe cierta probabilidad de no recoger adecuadamente la variación espacial presente en la imagen de partida. Esa desventaja la soluciona el interpretador con su rigor al asignar una muestra a determinada categoría, consciente de lo que aprecia sobre el display, siendo conocedor de la imagen que pretende interpretar, y ejecutando experimentos comprobatorios para seleccionar el mejor conjunto de bandas / parámetros y el método de clasificación.

La Figura 6 contiene la idea desarrollada en nuestro software para construir la información de aprendizaje y control para cada una de las clases o categorías. La interfaz carga el archivo de coordenadas creado en el muestreo, el interpretador selecciona las bandas espectrales que van a intervenir en el proceso clasificatorio, se establecen los por cientos en que deben estar representados los subconjuntos de aprendizaje y de control, se define el criterio de clasificación que será utilizado, y acto seguido se aplica un algoritmo para la selección aleatoria de los miembros de cada subconjunto. Después de ese paso se procede a formar la colección de vectores de rasgos (variables) y se construye la matriz de observaciones. Es aquí donde se tiene en cuenta el criterio de clasificación (Tono, Textura, Tono + Textura). Cuando el criterio es “Tono” la acción se limita a extraer los vectores con el ND de cada banda y cuando interviene la “Textura” se procede al cálculo de cada descriptor seleccionado para después construir el vector de rasgos. La información

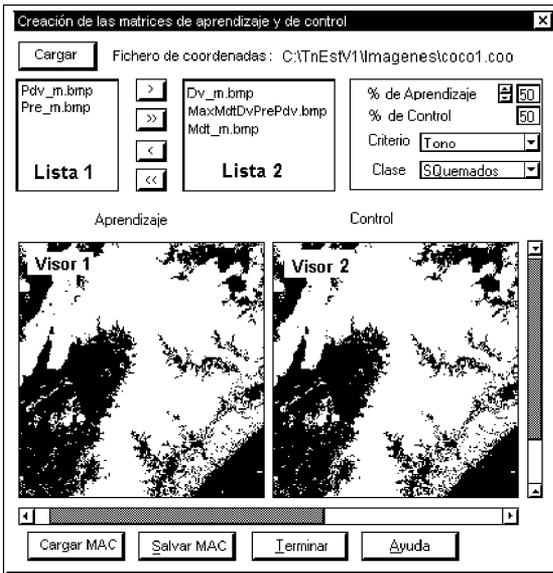


Figura 6. Interfaz de Tn Estudio para la creación de la Información de Aprendizaje y la Información de Control, que permite almacenar la estrategia para desarrollar la clasificación digital de la imagen compatible con todos sus clasificadores.

obtenida se almacena en un nuevo archivo que más que la información de aprendizaje / control, contiene toda la estrategia descrita. Entonces, es posible crear varias estrategias, generando varios de estos archivos. Lo que es común a todos ellos es que son compatibles con todos los clasificadores supervisados que están implementados en la aplicación. Es sabido que una estrategia puede ser mejor que otra y que un clasificador ofrece mejores resultados que otro. Lo bueno es poder compararlos y seleccionar la mejor combinación.

Procedimientos para el mejoramiento del muestreo digital de la imagen

Es deseable poder contar con un procedimiento que sea capaz de llevar a cabo un análisis sobre las muestras tomadas durante el proceso de muestreo de la imagen y determinar si son representativas de las clases, eliminar aquellas que no lo son y tratar de evitar la redundancia informativa, de modo que sea generado un nuevo conjunto “optimizado” de muestras, más pequeño y de mayor calidad que garantice sin un deterioro significativo la exactitud de la clasificación. Un procedimiento de esta naturaleza estaría orientado a (1) limpiar la muestra de puntos muy distanciados en el espacio de los patro-

nes de cualquier clase, que representan errores de selección evidentes (“outlayer” en la literatura técnica), (2) reducir el tamaño de la muestra original mediante la eliminación de puntos con información redundante, y por último, (3) obtener patrones de las clases que sean prototipos representativos de ellas. En la bibliografía sobre ese tema se mencionan varios métodos, entre ellos, una serie de enfoques basados en la regla del vecino más cercano como son; Edición, Edición Generalizada, y Depuración (Barandela, 1987; Cortijo, 1996) y en la regla de máxima verosimilitud (Matter, 1987). Otros intentos han estado dirigidos a la obtención de prototipos basados en el enfoque adaptativo (Huang et al., 1995). Un último grupo de métodos, se orientan en diferentes heurísticas (Hart, 1968; Gowda y Krishna, 1979) y modelos geométricos con el objetivo de limpiar la muestra (Preparata y Shamos, 1985).

En una fase muy preliminar de nuestras investigaciones en este terreno, se concibió la idea de procesar las muestras contenidas en la Matriz de Aprendizaje / Control mediante el algoritmo de Hart (1968), por ser este uno de los primeros intentos reportados para enfrentar esta problemática. El método está concebido para obtener un “conjunto consistente”, entendiéndose por ello a un subconjunto de patrones de entrenamiento, tal que, cuando es empleado para clasificar todo el conjunto de patrones de entrenamiento, con la regla 1NN, garantiza que el 100% de asignación sea correcta.

El procedimiento crea dos subconjuntos, uno con aquellas muestras que mejor describen a cada clase y otro con las muestras que son redundantes, y que al final es desechado. El conjunto consistente ha quedado conformado con las muestras que se retienen, el cual es un subconjunto condensado que puede ser usado en la fase de clasificación de patrones desconocidos. El algoritmo de Hart intenta alcanzar un subconjunto tan pequeño como le sea posible, pero como ha dicho su propio autor, el subconjunto consistente más pequeño no siempre se obtiene. En la Figura 7 se muestra la interfaz que contiene al método, antes y después de aplicado. La salida que se ofrece es de dos tipos: una nueva matriz de aprendizaje / control, y/o su correspondiente archivo de coordenadas, con aquellas muestras del subconjunto optimizado. En la actualidad se está en una etapa de validación de los resultados que son obtenidos con este método.

Efectividad del clasificador. Matriz de Confusión

El interpretador tiene necesidad de conocer la calidad del proceso de clasificación de la imagen en términos de los errores que ha cometido el clasificador, al confundir las muestras de una clase con las de otra, y por tanto, conocer qué clases han sido mejor y peor identificadas. Con los resultados de la clasificación se construye la denominada Matriz de Confusión de las clases (Figura 8). Se le llama así porque recoge los conflictos que se presentan entre las categorías. Se trata de una matriz bidimensional, en donde las filas son ocupadas por las clases de referencia, y las columnas por las categorías deducidas de la clasificación. Ambas tienen el mismo número y significado y se trata de una matriz cuadrada de tamaño “n x n”, donde “n” indica el número de categorías.

La diagonal expresa el número de puntos clasificados donde se produce un total acuerdo entre las dos fuentes (imagen y clasificación), mientras que los marginales suponen errores de asignación. La relación entre el número de puntos correctamente asignados y el total expresa la fiabilidad o efectividad global de la imagen clasificada (ET = 94.78). Los residuales en las filas indican tipos de cubierta que no se incluyeron en esa clase (error de omisión), mientras que los residuales en las columnas implican cubiertas de la imagen que no se ajustan a la realidad preconcebida (error de comisión).

Los “errores de omisión” (filas) indican el número de píxeles que, perteneciendo a una determinada categoría, no fueron incluidos en ella. Por su parte, los “errores de comisión” (columnas) expresan el número de píxeles que se incluyeron en una determinada categoría perteneciendo realmente a otra.

Los errores de “omisión” y “comisión” expresan dos enfoques del mismo problema. Los primeros se refieren a una definición imperfecta de la categoría y los segundos, a una delimitación excesivamente amplia. Desde otro punto de vista, algunos autores hablan de exactitud del usuario y del productor. La primera está en relación inversa con los errores de omisión, mientras la segunda lo está con los de comisión. De la matriz de confusión no sólo se conoce la cantidad de puntos que nuestra clasificación asignó correctamente, sino también la fiabilidad para cada una de las clases y las principales confusiones entre ellas.

El Índice de Kappa o coeficiente de conformidad de capa, es una medida de la exactitud de la clasificación y su varianza es usada, en la comunidad de teledetección, para realizar pruebas estadísticas de diferencias significativas (Hudson y Ramm, 1987). Cuando la efectividad global ET es elevada se corresponde con un valor elevado del Índice de Kappa, aunque no es una relación lineal.

Si se realizaron correctamente las fases de muestreo, de pre-procesamiento de las muestras de aprendizaje / control y la fase del entrenamiento (caso de redes neuronales), la mayor parte de estas confusiones ya habrían sido detectadas, pero aquí se ofrece una medición mucho más explícita de estos problemas. A partir de estos datos, puede orientarse el empleo de otros métodos de clasificación, el empleo de imágenes de otras fechas, o el de bandas auxiliares (relieve, suelos, descriptores de textura), con el objeto de facilitar un documento suficientemente certero.

Métodos más comúnmente empleados en el proceso de verificación de campo

Como se ha dicho con anterioridad, el resultado casi siempre esperado de un proceso de clasificación es un mapa temático, que contiene la distribución espacial de distintas coberturas terrestres de acuerdo con la leyenda adoptada en el proyecto. Hay que partir del hecho real de que en todo proceso clasificatorio, es el analista el responsable de seleccionar las muestras de las clases, de escoger el clasificador más apropiado y de interpretar los resultados. Todos estos procesos son susceptibles de errores no solo en el orden subjetivo, sino también de orden objetivo (calidad de los datos, rigurosidad del método empleado, etc). Por eso, no deberíamos afirmar que un mapa temático

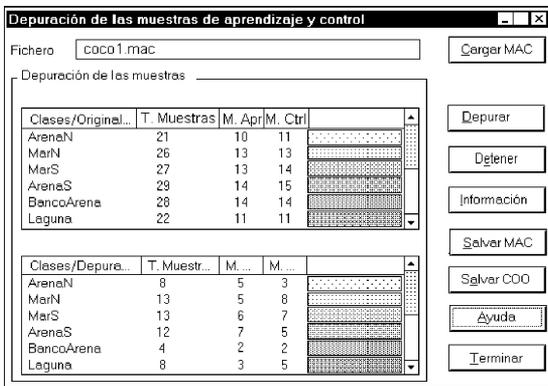


Figura 7. Interfaz para la depuración y limpieza de la Matriz de Aprendizaje Control mediante el algoritmo de Hart

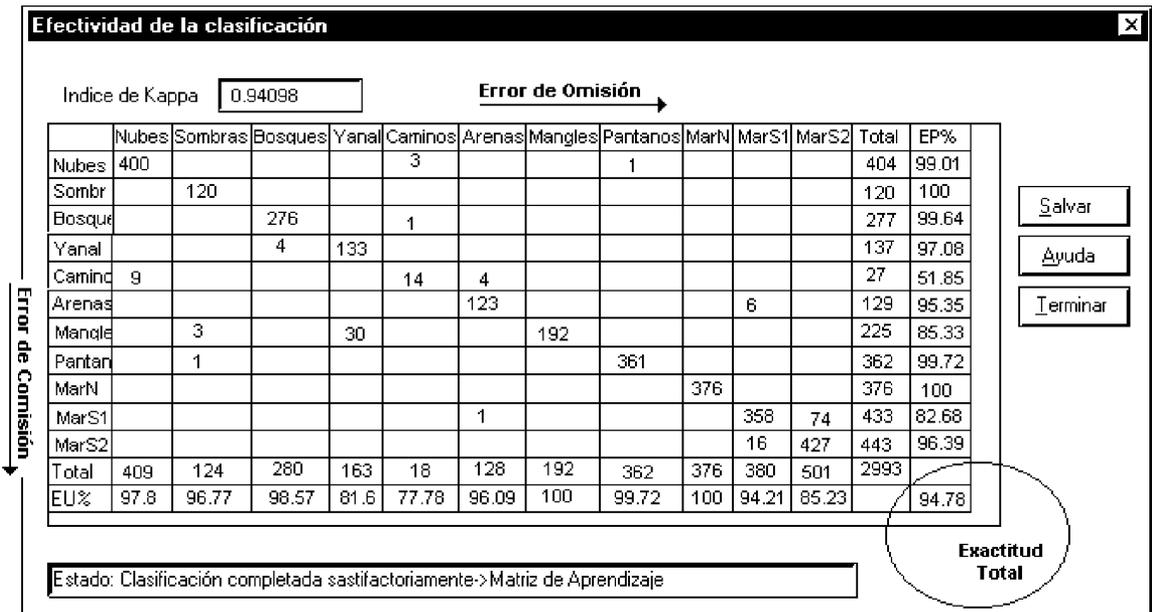


Figura 8. Estructura de la Matriz de Confusión.

obtenido por estas técnicas, sea completamente confiable. Debido a ello, resulta obligado aplicar algún procedimiento de validación, que permita evaluar la magnitud de ese error y a partir de él, valorar la calidad final del trabajo y su posibilidad real de aplicación práctica. Según Chuvieco (1995), la estimación de la exactitud alcanzada por el mapa puede realizarse por tres criterios básicos: (i) Comparando el inventario de la clasificación con el obtenido con otras fuentes convencionales plenamente fiables, tales como, estadísticas oficiales, cartografía de detalle; etc., (ii) Estudiando la fiabilidad obtenida al clasificar las áreas de entrenamiento, para comprobar si se ajustan correctamente a las categorías que pretenden definir y (iii) Seleccionando ciertas áreas de verificación para las que se cuenta con la cubierta realmente presente en el suelo.

El primer criterio es muy común en la comprobación de casi todos los documentos cartográficos, pudiéramos agregar que es un método sencillo, práctico y universal, aunque su grado de fiabilidad suele estar muy influido por la calidad del documento que se toma como paradigma, de ahí su relatividad. El segundo criterio, se ha desarrollado profusamente a la luz del desarrollo de modernos modelos estadístico-matemáticos muy poderosos y por las técnicas y capacidades computacionales hoy disponibles. Precisamente en Cuba algunos softwares de PDI (García, 1997; Gil et al., 2000), permi-

ten realizar este tipo de análisis, incluso antes de obtener los mapas definitivos. De esta manera, los criterios de fiabilidad alcanzados mediante el análisis de matrices de aprendizaje y control, constituyen una verdadera herramienta de diagnóstico para mejorar las clasificaciones, con el consiguiente ahorro de recursos que presupone una comprobación en el terreno. El tercer criterio, es sin dudas el más completo y robusto. Consiste en seleccionar, con posterioridad a la clasificación, una serie de áreas “test” que permitan obtener una medida independiente de la coincidencia entre el mapa obtenido y la verdad-terreno. A partir de la realización del muestreo, puede construirse una tabla o matriz de confusión, en donde se resuman los acuerdos y desacuerdos entre las clases del mapa y del terreno. Esta matriz de hecho, se analiza estadísticamente, con el fin de obtener una serie de medidas sobre la fiabilidad del trabajo global y para cada una de las categorías. Como la medida de la fiabilidad es función de un muestreo, su valor real se mueve entre unos márgenes, tanto más próximos al valor medio cuanto mayor sea el tamaño de la muestra y menor el grado de error.

Precisamente por ello, es imprescindible definir previamente una estrategia para realizar el muestreo de campo teniendo en cuenta los siguientes elementos: (i) métodos de selección de la muestra (ii) tamaño y distribución de la muestra, y (iii) nivel de confianza otorgado a la verificación.

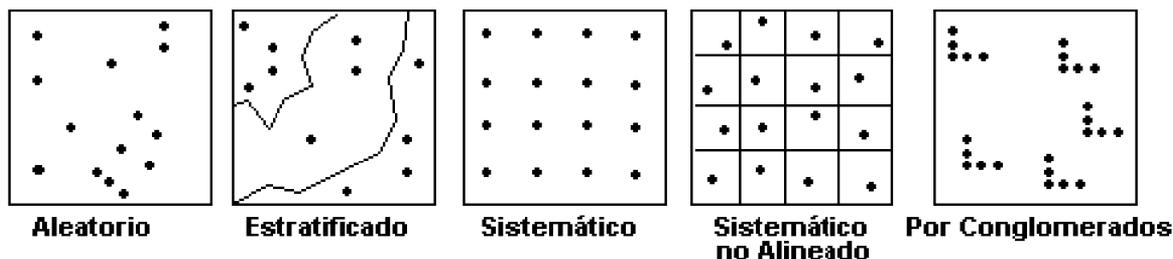


Figura 9. Tipos de muestreo de campo para verificar “in situ” el resultado de la clasificación. Tomado de Chuvieco, 1995.

Los tipos de muestreo de campo más ampliamente difundido en la actualidad son: Aleatorio Simple; Aleatorio Estratificado; Sistemático; Sistemático no alineado y Por Conglomerados (Congalton, 1988; Rosenfeld, 1982), citados por Chuvieco, E. (1995). (Figura 9).

En el *Aleatorio Simple*, los elementos a verificar se eligen de tal forma en que todos cuenten con la misma probabilidad de ser seleccionados, y que la elección de uno no influya en la del siguiente. Gracias a este carácter probabilístico, este muestreo es el más sólido estadísticamente, aunque sus desventajas radican en los elevados costos por el desplazamiento y en la existencia de cierta probabilidad de no recoger adecuadamente la variación espacial presente en la imagen clasificada. En el *Aleatorio Estratificado*, la muestra se toma dividiendo la población en regiones o estratos, de acuerdo a una variable auxiliar (altitud, por ejemplo). Su ventaja fundamental radica en que aporta información sobre subconjuntos de la población y en la posibilidad de reducir el error de muestreo si la variable auxiliar se elige correctamente, mientras que su desventaja consiste en que resulta más difícil de diseñar que el anterior. En el muestreo *Sistemático* la muestra se distribuye a intervalos regulares, a partir de un centro de origen señalado al azar. Su ventaja principal radica en garantizar un muestreo sistemático íntegro de la superficie a verificar, sin embargo esto acarrea serias limitaciones al permitir estimaciones erróneas si existiera algún tipo de patrón periódico en el área observada, como puede ser la geometría de las parcelas. Por otra parte, no garantiza una estimación probabilística, por cuanto no existe aleatoriedad en la selección de las muestras. El *Sistemático no Alineado*, se puede considerar como una variante del anterior, producto de la variación de una de las dos coordenadas de manera aleatoria. Esto permite introducir el factor aleatoriedad, a la vez que reduce el error debido a

la periodicidad, todo ello, contemplando intacta la revisión completa de todo el territorio. El muestreo *Por Conglomerados*, como su nombre lo indica consiste en seleccionar en un punto escogido aleatoriamente dentro del territorio, un grupo de observaciones, en lugar de muestras independientes, de acuerdo a un esquema diseñado previamente. El hecho de contar con grupos de muestras, tiene la ventaja de reducir los gastos de transporte, pero es complejo en su realización y menos precisos que los anteriores.

Un problema que hay que resolver antes de proceder al diseño del muestreo, consiste en determinar el tamaño que tendrá la muestra, es decir “la cantidad de sitios de muestreo en el campo”. El modelo matemático adoptado para este caso, se da en la fórmula siguiente, capacitada para medir una variable binomial (acierto-error).

$$n = \frac{z^2 p q}{E^2}$$

Donde n, es el número (tamaño) de la muestra; z es la abcisa de la curva normal para un nivel determinado de probabilidad; p es el porcentaje de aciertos estimados; q, el de errores ($q = 1 - p$) y E es el nivel permitido de error. El valor de p y q puede estimarse a partir de datos auxiliares o simplemente igualarse a 50.

Una vez seleccionado el método y habiendo determinado el tamaño de la muestra, el paso siguiente es localizar los puntos de verificación en el mapa temático. De acuerdo con nuestra experiencia, el diseño del muestreo es un trabajo conjunto donde participa el analista que tuvo a su cargo la clasificación temática, así como el resto de los miembros del equipo del proyecto que tendrá a su cargo la verificación “in situ” de las muestras. Este grupo debe incluir especialistas en el tema objeto de la clasificación (botánicos, geólogos, forestales,

etc), especialistas en la técnica de posicionamiento global (GPS) y otros encargados de la parte de aseguramientos (transporte, comunicaciones, etc). En este "trabajo de mesa", sobre el mapa temático, se van colocando, con el símbolo seleccionado, cada uno de los sitios a verificar de acuerdo al criterio del equipo de trabajo. Simultáneamente se llena un modelo o registro que contiene el listado de todos los sitios a visitar, sus coordenadas geográficas obtenidas directamente de la imagen clasificada y georreferenciada, el orden en que se visitarán éstos, la fecha y hora de la visita, la clase existente en el terreno de acuerdo a la leyenda adoptada, las coordenadas GPS adquiridas en el terreno, y otras observaciones. Este registro se prepara durante el trabajo preliminar y se utiliza tanto en la fase de preparación en gabinete, como luego durante la visita al terreno. Posteriormente, todos los puntos situados se trasladan a un mapa topográfico homólogo (de la misma región y escala). Este mapa es el que se lleva al terreno para la verificación y no el mapa - imagen con la clasificación, pues permite un mejor discernimiento de los elementos topográficos, y lo más importante, evita que el especialista se deje influenciar por la cartografía temática elaborada por él mismo, favoreciendo la efectividad de su verificación.

Como ya se mencionó, durante la visita al terreno, la localización de los puntos se realiza de acuerdo a un orden previamente seleccionado tomando en cuenta las características topográficas, las distancias desde los puntos de partida, los aseguramientos disponibles, etc. Un papel importante lo desempeñan los equipos GPS, que trabajando en modo de ruta, facilitarán el acercamiento y ubicación exacta hasta el sitio que marca el centro de coordenadas de la muestra. Una vez en este sitio, se procede a llenar el resto de los datos que se incluyen en el registro, entre ellos, el nombre de la clase real (verdad terreno) y otros datos de interés. Posteriormente se realiza el trabajo de gabinete, donde se confecciona la matriz de confusión a partir de los criterios mapa-verdad terreno, y se evalúa la efectividad global y para cada una de las clases. Si el resultado no es favorable, habrá que desplegar una nueva estrategia de clasificación (separación de clases, agrupamiento de subclases, etc).

Un aspecto de suma importancia a tener en cuenta durante la verificación, es el relacionado con el tiempo que media entre la adquisición de la imagen y el momento de la verificación, pues si éste es muy distante, lógicamente se presentarán cambios en la ocupación del suelo, sobre todo en aquellos tipos de

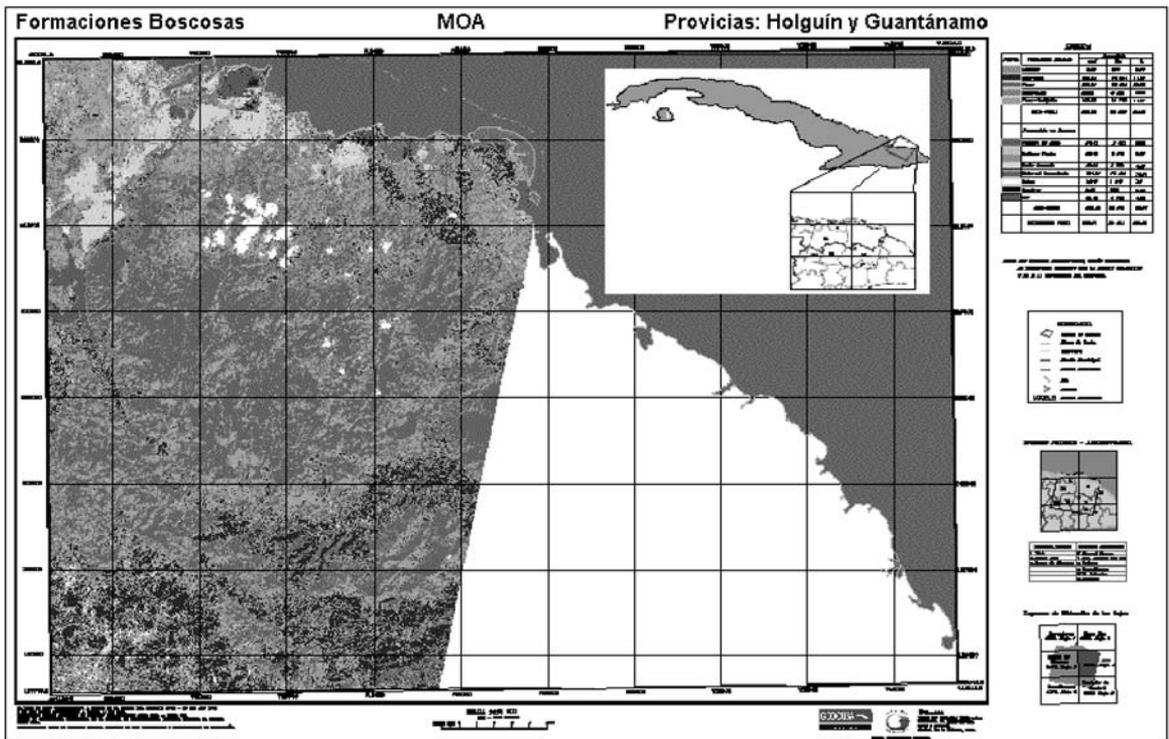
cubiertas susceptibles de variar aceleradamente, como suele ocurrir en algunos cultivos agrícolas, por lo cual se pueden introducir errores de comisión importantes en el momento de obtener la información "in situ".

Documento Temático Final

El documento temático final o Mapa Temático consta de dos tipos de informaciones: básica y complementaria. La información básica está conformada por la clasificación temática, que contiene las diferentes clases espectrales definidas de acuerdo a la leyenda de categorías adoptada para el proyecto y por la información cartográfica, que conforman el conjunto de capas vectoriales diseñados de acuerdo a la escala de representación. Estos últimos elementos son los que le aportan el verdadero contenido cartográfico a un mapa temático. Sin ellos estaríamos en presencia de un marco cartográfico soportando una imagen clasificada y georreferenciada de fondo. El mapa temático consta además de la información complementaria, que es un conjunto de informaciones literales, numéricas y atributos, que se colocan en los distintos espacios marginales, los cuales permiten interpretar el contenido temático del mismo. Estos datos garantizan el conocimiento de la información referente a las clases, su representación, sus valores porcentuales de ocupación territorial, sus caracteres espectrales y cromáticos, etc.

Existe además, otro conjunto de informaciones técnicas sobre los datos de partida, que se toman en cuenta durante la confección del mapa: las instituciones participantes, las leyes cartográficas utilizadas para la construcción de la base matemática del mapa, las escalas y sus patrones gráficos, los esquemas de ubicación de la hoja cartográfica que se representa y las adyacentes, así como el título, la nomenclatura y el nombre común de la misma.

En la actualidad, la construcción de un mapa temático en Cuba a partir de imágenes de satélites, abarca tres grandes grupos de procesos que según Ponvert-Delisle (2001), son los siguientes: (i) Procesamiento Digital de Imágenes (PDI); (ii) Procesamiento Cartográfico Digital y (iii) Comprobación y Verificación de la exactitud cartográfica. Mediante el grupo de procesos (i), se trabaja sobre la imagen dato, para corregirla geométricamente, extraer la información espectral y agruparla en clases obteniéndose una nueva imagen o clasifi-



* **Figura 10.** Mapa Temático Forestal a escala 1:100.000 de la región de Moa, NE de Cuba, usando una imagen SPOT multiespectral clasificada con el método supervisado de Mínima Distancia a la Media implementado en el software Tn Estudio donde se obtuvo una efectividad total del 86%.

cación digital que conforma la información temática. Aplicando los Procedimientos de cartografía digital, se extraen las capas vectoriales de la propia imagen o de otras fuentes cartográficas tradicionales (mapas topográficos y catastrales), mediante procesos de digitalización y vectorización y posteriormente se agencia dicho contenido cartográfico a la información temática y de esa manera convertirla en un mapa con todas las de la ley. En este grupo de procesos se aborda también el diseño, la edición y la salida más apropiados. Con el conjunto de procesos (iii), se logra como ya se señaló antes comprobar la veracidad de la información temática contenida en dicho mapa a partir de diferentes procedimientos y darle credibilidad y valor de uso al documento. En la Figura 10, se muestra un prototipo de mapa temático obtenido aplicando esta tecnología para acometer el inventario forestal de la región montañosa al norte de Holguín en el oriente cubano.

Este resultado está siendo utilizado por las autoridades forestales del Ministerio de la Agricultura cubano.

CONCLUSIONES

La clasificación digital de imágenes es un conjunto de procedimientos de amplia repercusión práctica en variadas disciplinas de la actividad científica y económica de la sociedad actual. Su carácter automatizado no resta importancia a la participación del hombre, encargado de organizar todos los procesos que conducen hasta la imagen clasificada, su interpretación y su representación en un documento final de fácil manejo. No todo está resuelto aún, hay que estudiar procedimientos que mejoren la selección de las imágenes a utilizar, así como métodos para el proceso de muestreo y su depuración, la implementación de medidas de semejanza que se adecuen al contenido informativo de la imagen, lo que no excluye el análisis inteligente del dato digital. El hombre continúa el desarrollo de nuevas tecnologías para adquirir, almacenar y procesar, cada vez un número mayor de bandas espectrales con el objetivo de mejorar la precisión del documento final, de ahí la necesidad

Todas las figuras precedidas de asterisco se incluyen en el cuadernillo anexo de color

de continuar desarrollando métodos de procesamiento que se ajusten al carácter hiperespectral de estos datos. En Cuba se hace un aporte muy modesto programando nuevos softwares que abarquen la temática de la clasificación de imágenes y se desarrollan aplicaciones con imágenes aéreas, espaciales y de vídeo. Los primeros resultados de las investigaciones realizadas acerca de la combinación de rasgos de tonos y de textura indican la necesidad de profundizar en el desarrollo de estos enfoques. En nuestro país los campos que tradicionalmente han utilizado las técnicas de clasificación de imágenes han sido aquellos vinculados a las ciencias de la tierra y la medicina. En el presente se continúa el esfuerzo, incluido éste, por difundir estas tecnologías mediante cursos de postgrado y maestrías en universidades y en centros de investigaciones como el nuestro.

BIBLIOGRAFÍA

- BARANDELA, R. 1987. The Nearest Neighbour rule: an empirical study of its methodological aspects, Tesis de Doctorado, Berlin.
- CHIDANANDA – GOWDA, K. y KRISHNA, G. 1979. The Condensed Nearest Neighbour Rule using the Concept of Mutual Nearest Neighbourhood. *IEEE Transaction on Information Theory*, No. 25., 4: 488-490.
- CHUVIECO, E. 1995. *Fundamentos de Teledetección Espacial*. Madrid, España, Editorial RIALP, S.A, 430 p.
- CONGALTON, R.G., y MEAD R.A. 1983. A Quantitative Method to Test for Consistency and Correctness in Photo interpretation. *Photogrammetry Engineering and Remote Sensing*. 49(1): 69–74 .
- CORTIJO, F., PÉREZ DE LA BLANCA, N.1996. Image Classification using non – parametric Classifier and Contextual Information. *International Archive of Photogrammetry and Remote Sensing Vienna*. Vol. XXXI, Part B3, 120-130.
- CROSTA, A. P. 1992. Procesamiento Digital de Imágenes de Sensoramiento Remoto. Instituto de Geociencias, Departamento de Metalogenese e Geoquímica, Biblioteca Central – UNICAMP, Brasil, 170 p.
- EBERHART, R.C. y DOBBINS R. W. 1990. *Neural Network PC Tools A Practical Guide*. Academic Press, San Diego, California 92101, 414 p.
- ENVI Tutorials #2 1998. Multispectral Classification.
- GARCÍA, E. B. 1997. Empleo de las redes neuronales artificiales en la clasificación de imágenes multispectrales de teledetección. Tesis presentada en opción al grado científico de Doctor en Ciencias Técnicas, GEOCUBA, Ciudad de La Habana.
- GIL, J. L. 1996a. Procedimientos para el análisis de textura en imágenes. Un estudio. Tesis presentada en opción al título de Master en Informática Aplicada a la Ingeniería y la Arquitectura, ISP-JAE, La Habana, Cuba, pp. 103.
- GIL, J. L., VALDÉS J. J., HITTA, R., MORENO L. 1995. Guía metodológica para usar las redes neuronales (Modelo Backpropagation) en el reconocimiento supervisado de imágenes. Dos ejemplos. En: Memorias Conferencia Internacional CIMAF 95, I Taller de Reconocimiento de Patrones, p. 90, La Habana, Cuba.
- GIL, J. L. y VEGA, M. 1996b. Estado actual del análisis de textura en imágenes. En: Memorias de COMPAC 96, CEDISAC, Ciudad Habana. ISBN-959 237-024-9.
- GIL, J. L. y VEGA, M. 1997a. Métodos cuantitativos de análisis de textura en imágenes. En: Memorias VIII Simposio Latinoamericano de Percepción Remota. Venezuela.
- GIL, J. L. y VEGA, M. 1997b. Evaluación del espectro de textura en la caracterización de la información espacial de las imágenes pancromáticas aéreas. En: Memorias VIII Simposio Latinoamericano de Percepción Remota. Venezuela.
- GIL, J. L. y VEGA, M., E. GARCÍA, R. SÁNCHEZ, L. JIMÉNEZ. 2000. Software Tn Estudio V2.0: Integration of digital image processing tools with pattern recognition to support the remote sensing studies. *International Archives of Photogrammetry and Remote Sensing*. Vol. XXXIII, Part B2, pp. 213-219. Amsterdam.
- HART, P. E. 1968. The Condensed Nearest Neighbour Rule. *IEEE Transaction on Information Theory*, . 14:515 –516.
- HUANG, Y. S., LIU, K. y SUEN, C. Y. 1995. A New Method of Optimising Prototypes for nearest Neighbour Classifier Using a Multi – layer Network. *Pattern Recognition Letters*. 16: 77-82.
- HUDSON, W. D.; RAMM, C. W. 1987. Correct Formulation of the Kappa Coefficient of Agreement. *Photogrammetric Engineering and Remote Sensing* 53(4): 421-422.

- MATTER, P. M. 1987. Pre-processing of training data for Multispectral Image Classification. Proc. 13th, Annual Conference of Remote Sensing Society, Nottingham.
- PONVERT-DELISLES, D. R. 2001. Tesis en Opción al grado científico de Doctor en Ciencias Técnicas “Metodología para realizar la caracterización espectral y cromática de las coberturas terrestres en Cuba”, GEOCUBA, La Habana, Cuba.,100 p.
- PONVERT-DELISLES, D. R., GIL J. L., SÁNCHEZ R., ALVAREZ O., AGÜERO B. 2000. El primer inventario forestal de la República de Cuba realizado con imágenes SPOT-XS. (en preparación).
- PREPARATA, F. P., SHAMOS, M. I 1985. *Computational Geometry an introduction*. Springer – Verlag, New York, 391 p.
- ROSENFELD, A., y KAK A. 1982. *Digital Picture Processing*. Academic Press Inc., Vol 1 y 2, 435 y 349 pp.
- VALDÉS, J. J., GIL J. L., GARCÍA A., PAREDES R., HITA R. 1993. DIPSY V1.0 Sistema de procesamiento y análisis de imágenes digitales. En: Memorias Taller de Inteligencia Artificial Santiago de Cuba.
- WASSERMAN, P. D. 1989. *Neural Computing. Theory and Practice*. Van Nostrand Reinhold, New York, 230 p.