

I CONGRESO NACIONAL DE TECNOLOGÍAS DE LA INFORMACIÓN GEOGRÁFICA Y IV REUNIÓN DE USUARIOS DE TECNOLOGÍAS DE LA INFORMACIÓN GEOGRÁFICA DEL NEA. Laboratorio de Tecnologías de la Información Geográfica. Facultad de Humanidades, Resistencia, Chaco, 2011.

EXTRACCIÓN Y ANÁLISIS DE SUPERFICIES URBANAS CONSTRUIDAS EMPLEANDO IMÁGENES LANDSAT 5 (TM).

Linares, Santiago; Tisnés, Adela.

Cita:

Linares, Santiago; Tisnés, Adela (2011). *EXTRACCIÓN Y ANÁLISIS DE SUPERFICIES URBANAS CONSTRUIDAS EMPLEANDO IMÁGENES LANDSAT 5 (TM)*. I CONGRESO NACIONAL DE TECNOLOGÍAS DE LA INFORMACIÓN GEOGRÁFICA Y IV REUNIÓN DE USUARIOS DE TECNOLOGÍAS DE LA INFORMACIÓN GEOGRÁFICA DEL NEA. Laboratorio de Tecnologías de la Información Geográfica. Facultad de Humanidades, Resistencia, Chaco.

Dirección estable: <https://www.aacademica.org/adela.tisnes/28>

ARK: <https://n2t.net/ark:/13683/p0dA/w2B>



Esta obra está bajo una licencia de Creative Commons.
Para ver una copia de esta licencia, visite
<https://creativecommons.org/licenses/by-nc-nd/4.0/deed.es>.

Acta Académica es un proyecto académico sin fines de lucro enmarcado en la iniciativa de acceso abierto. Acta Académica fue creado para facilitar a investigadores de todo el mundo el compartir su producción académica. Para crear un perfil gratuitamente o acceder a otros trabajos visite: <https://www.aacademica.org>.

EXTRACCIÓN Y ANÁLISIS DE SUPERFICIES URBANAS CONSTRUIDAS EMPLEANDO IMÁGENES
LANDSAT 5 (TM)
EXTRACTION AND ANALISYS OF BUILD URBAN USING LANDSAT IMAGES 5 (TM)

Prof. Santiago Linares

Prof. Adela Tisnes

Docentes-Investigadores. Centro de Investigaciones Geográficas, Facultad de Ciencias Humanas
(UNCPBA). Becarios CONICET

Resumen

En este trabajo se presenta una aplicación del procesamiento digital de imágenes satelitales Landsat 5 TM con el objetivo de identificar superficies urbanas construidas y características constructivas predominantes en el área urbana y complementaria de la ciudad de Tandil (Argentina) para los años 1989 y 2006.

Se describen algunos procedimientos de calibración radiométrica y clasificación que permitirán, posteriormente, extraer superficies con distintas densidades y características de edificación mediante un análisis de mezclas espectrales. Este procedimiento es posible en la actualidad gracias a la disponibilidad de bibliotecas espectrales teóricas que recogen la reflectividad característica de una amplia variedad de materiales predominantes en áreas urbanas y suburbanas.

El resultado del trabajo permitió detectar diferentes densidades y tipologías constructivas, conocer la magnitud y forma de la expansión urbana en diferentes momentos, a la vez que constituyó un procedimiento con amplias posibilidades de generalización, ya que se basa en imágenes y firmas espectrales de libre acceso y vasta cobertura territorial y temporal.

Palabras claves: expansión urbana, firmas espectrales urbanas, análisis de mezclas espectrales, teledetección.

Keywords: urban sprawl, urban spectral signatures, spectral mixture analysis, remote sensing.

Introducción

Uno de los temas de investigación y desarrollo más significativos en el campo de las Tecnologías de la Información Geográfica en el contexto actual, es sin duda el desarrollo de técnicas avanzadas de procesamiento de imágenes satelitales que puedan ser utilizadas para obtener información exhaustiva, precisa, periódica y de fácil actualización sobre los espacios urbanos. Los avances en este tema se vieron revitalizados al aprovechar las ventajas de los sensores comerciales de muy alta resolución espacial¹

¹ Si bien estas fuentes representan nuevas posibilidades, también presagian nuevos problemas y escollos para brindar soluciones rápidas a necesidades urgentes. Es común observar que gran parte de los especialistas en teledetección emplean la mayor parte de su esfuerzo para intentar aprovechar las nuevas fuentes de información producida en cada avance tecnológico, y no tantos dedican esfuerzo en buscar soluciones operacionales prácticas a requerimientos cotidianos que surgen desde diversos ámbitos de la sociedad, posibles de responder mediante la utilización de recursos disponibles (Donnay *et al.* 2001). De hecho, en el caso concreto de las cubiertas urbanas, las ventajas de una mayor resolución espacial es positiva cuando se realiza una interpretación

(IKONOS, GeoEye-1, Quickbird, WorldView-2, EROS B, etc.), pero también a través de la creciente disponibilidad de fuentes de datos alternativas, tales como SAR (*Synthetic Aperture Radar*) y LIDAR (*Light Detection and Ranging* o *Laser Imaging Detection and Ranging*).

Más allá de las nuevas fuentes de datos disponibles que suponen un avance en la temática, existen una serie de preocupaciones metodológicas de la teledetección aplicada al análisis urbano que aún se encuentran en su fase experimental, dentro de ellas se destacan dos cuestiones: 1) buscar procedimientos de clasificación que infieran usos del suelo, 2) análisis de morfología urbana para el planeamiento y gestión territorial.

La primera preocupación surge por las deficiencias al inferir usos del suelo en base a información de coberturas suelo; es así que superficies con valores de reflectancia espectral idénticos pueden corresponder a muy diferentes usos y funciones urbanas². En este sentido, las investigaciones en la actualidad pretenden, en primer lugar, mejorar la calidad de clasificaciones, tanto en términos del número de clases individuales como en la precisión con la que cada una de ellas se puede identificar y, en segundo lugar, lograr que las tipologías de uso del suelo se puedan representar en firmas espectrales categóricas en concordancia con los nomencladores jurídicos-administrativos utilizados para planificar y gestionar el espacio urbano.

Los intentos de superación han avanzado en varios sentidos, pudiendo señalar entre ellos, el uso de probabilidades a priori o a posteriori de una clasificación (Mesev *et al.* 2001); aplicación de algoritmos de clasificación denominados "Blandos" como la clasificación borrosa (Lee, 2006); procedimientos de segmentación de imágenes (Schöpfer *et al.* 2010); utilización de datos espaciales auxiliares (Weng, 2010); combinación de datos espectrales con medidas de la forma y textura urbana (Ackermann y Mering, 2007); técnicas de fusión de datos (Ranchin y Wald, 2010) técnicas de análisis hiperespectral (Robert y Herold, 2005) y empleando redes neuronales artificiales (Lourenço *et al.* 2005).

El segundo tema, considera que un mapa de uso del suelo generado mediante una clasificación temática de una imagen satelital no constituye el producto final en sí; más bien debe ser considerado como un punto de partida para la planificación y gestión de una ciudad. Un enfoque común es esta línea consiste en el análisis de evolución espacial de las diferentes categorías de uso del suelo (Residencial Intensivo, Residencial Extensivo, Industrial, Transporte, etc.), y su posterior aplicación inmediata y práctica para detectar y regular la expansión desmedida y cambios de usos perjudiciales para la comunidad, fin último de los planes de desarrollo territorial (Molina y Chuvieco, 1997; Recio *et al.*, 2003; Vidal *et al.* 2009).

También resulta útil relacionar las clases con el comportamiento de una variable urbana en particular, siendo la más generalizada la población. Una aplicación simple en este caso consiste en la reasignación de la cifras de población a las clases obtenidas, en base a la información almacenada en las unidades censales correspondientes (Langford *et al.* 1990). Este procedimiento permite corregir los errores de las

visual, mientras que, cuando se realiza una interpretación digital, este incrementó de resolución produce efectos negativos, incrementando excesivamente la heterogeneidad interna en algunas categorías (Green, 2000; Chuvieco, 2010).

² A diferencia de aquellas no urbanas, donde es posible obtener una relación directa entre la respuesta espectral de los dos principales componentes de los ecosistemas terrestres (agua y vegetación) y el uso correspondiente.

cifras netas densidad (provocado por la asignación de población a áreas discretas artificiales), mediante la elaboración de mapas dasimétricos (Bielecka, 2005; Sleeter y Gould, 2007). También, si se asume que hay una estrecha relación entre las diferentes categorías de uso de suelo residencial por un lado y diferentes densidades de población por otro, este procedimiento resulta muy útil de aplicar en áreas de estudio sin disponibilidad de un censo oficial (Lo, 1995).

En base a la información del uso del suelo y densidades de población correspondiente, es posible generar superficies de densidad. En este caso, se trata de transformar una distribución espacial discreta a continua. Esto a menudo se lleva a cabo haciendo pasar una ventana móvil al conjunto de la imagen. El procedimiento, que es similar en muchos aspectos a la aplicación de un filtro paso bajo, proporciona un modelo de densidad de población frecuentemente utilizado para generar una superficie potencial de la población para análisis socioeconómicos (Martin, 1996; Thurstain-Goodwin, 2000).

De los antecedentes expuestos queda claro que una de las virtudes innegables de la teledetección aplicada a espacios urbanos es la idoneidad para conocer la extensión, magnitud y evolución del área construida de una ciudad, los desafíos en la actualidad pretenden ir más allá, intentando obtener información pormenorizada sobre la diferenciación de coberturas en su interior, inferencia sobre las densidades de los asentamientos y caracterización de los distintos usos del suelo.

Este trabajo persigue varios objetivos simultáneos, en principio, pretende discriminar entre superficies urbanas y no urbanas, luego detectar y calcular el área urbana construida, posteriormente inferir los elementos característicos de las coberturas del suelo urbano y, finalmente conocer la evolución y distribución de superficie construida entre los años 1989-2006. Para tal fin se emplea un método híbrido que combina métodos de clasificación no supervisada y supervisada e integra Sistemas de Información Geográfica y Teledetección. Las imágenes empleadas son las adquiridas por el sensor Landsat 5 TM, cuya disponibilidad espacial y temporal, como así también las posibilidades de acceso gratuito, favorecen la generalización del procedimiento propuesto, haciéndolos fácilmente replicable a diferentes áreas de estudio.

Metodología

La extracción y análisis de superficies urbanas construidas se realizó para la ciudad de Tandil (provincia de Buenos Aires, Argentina), empleando como máscara de análisis los límites correspondientes al área urbana y complementaria definida por el Plan de Desarrollo Territorial del Municipio de Tandil (PDT)³. El área urbana es la destinada a asentamientos humanos intensivos y, con ello, a la implantación densa de la residencia y de diversas actividades y usos, como los equipamientos, las actividades terciarias y las de producción compatible, así como a la dotación de infraestructuras y equipamientos para servir a la edificación existente o por construir. Por su parte, el área complementaria, circundante o adyacente al área

³ Registrado bajo la ordenanza Nro. 9865, a partir de la cuál se rige la planificación y gestión (urbana y rural) del Municipio de Tandil, estableciendo los principios y las estrategias de actuación territorial, los programas y proyectos de acción, regulando el uso, ocupación, subdivisión y equipamiento del suelo y determinando el sistema de gestión territorial.

urbana, constituye la transición entre ésta y el área rural, y representa una reserva para la expansión del área urbanizada. Entre ambas, alcanzan una superficie de 10.155 ha.

Elección de la escena y Pre-Procesamiento

Se utilizaron dos imágenes Landsat 5 TM, con fecha 27 de Octubre de 1989 y 26 de Octubre de 2006, escena Path 225 y Row 86. Las imágenes fueron seleccionadas de modo que representen similares condiciones atmosféricas, para ello se ha indagado previamente acerca de los datos meteorológicos históricos de la escena, cuyos datos se encuentran disponibles en: http://www.tutiempo.net/clima/Tandil_Aerodrome/876450.htm.

Posteriormente se procedió a la calibración radiométrica de las imágenes (Chander *et al*, 2009; Chuvieco, 2010) mediante el módulo de corrección *Radiance* del programa Idrisi Los Andes (Eastman, 2006). Éste consiste en la conversión de los números digitales a valores de radiancia, considerando los coeficientes de calibración disponibles para el satélite y las fechas utilizadas. La información acerca de los parámetros de calibración de los sensores (L_{\min} y L_{\max}) se encuentra disponible en el *header* de la imagen, o bien puede extraerse de Chander *et al*, 2009. La ecuación que relaciona los números digitales (ND) de las imágenes con la radiancia es:

$$L = \left(\frac{L_{\max} - L_{\min}}{255} \right) ND + L_{\min} \quad (1)$$

donde L es la radiancia expresada en $Wm^{-2} sr^{-1}$.

Debido a que se pretende realizar comparaciones entre imágenes de diferentes fechas y emplear firmas espectrales teóricas para analizar el área de estudio, es necesario realizar también una corrección atmosférica para reducir el efecto de la neblina y gases de la atmósfera en cada momento y estandarizar los valores a reflectancias. Una de las maneras de realizar este procedimiento es mediante el módulo *Atmosc* del citado programa, utilizando los datos del *header* de las imágenes Landsat en bruto. En esta ocasión se utilizó el Modelo de Sustracción de Objetos Oscuros (Chávez, 1996), que postula que la bruma atmosférica incrementa los ND en áreas de las imágenes de agua limpia, profunda y calma, donde por las características físicas deben presentar valores de reflectancia muy próxima a cero. La diferencia entre el valor teórico y el almacenado por el sensor se sustrae en cada banda, para todos los píxeles de la escena, efectuando de esa manera la corrección.

En el módulo *Atmosc* se carga cada banda por separado, con los siguientes datos: L_{\min} y L_{\max} para la banda (expresados en $mW cm^{-2} sr^{-1} \mu m^{-1}$, milliWatts por centímetro cuadrado por estereoradian y por micrón), elevación del sol, ángulo de la imagen, punto medio de la longitud de onda de cada banda, valores de ND de cuerpos oscuros presentes en la imagen. Para el ND del objeto oscuro se buscan los valores en las áreas de reflectancia cero conocidas, como las aguas profundas. Así, mediante el modelo se estima el espesor de los aerosoles y su efecto en la dispersión *Rayleigh*, especialmente en las primeras bandas, con

el beneficio agregado de que compensa las variaciones en las producciones solares según el momento del año y el ángulo de elevación solar (Chuvienco, 2010). La fórmula propuesta quedaría como:

$$\rho_k = \frac{D\pi(L_{sen,k} - L_{a,k})}{E_{o,k} \cos \theta_i \tau_{k,i}} \quad (2)$$

donde D es el factor corrector de la distancia Tierra-Sol, $L_{sen,k}$ corresponde a la radiancia espectral recibida por el sensor en la banda k , $L_{a,k}$ es la radiancia atmosférica debida a la dispersión y se estimaría a partir del valor mínimo o de un objeto de reflectividad nula, $E_{o,k}$ es la irradiancia solar en el techo de la atmósfera (para esa banda del espectro), θ_i es el ángulo cenital del flujo incidente y $\tau_{k,i}$ es la transmisividad atmosférica que afecta al rayo incidente.

Procedimientos de extracción de información temática

Como se mencionaba anteriormente, uno de los objetivos de este trabajo, es clasificar superficies construidas y características constructivas predominantes en el área urbana y complementaria de la ciudad de Tandil (Argentina).

Para ello se aplicó un método de clasificación, que en teledetección, no es más que un caso particular del problema general de clasificar N individuos procedentes de una muestra en un conjunto de $M < N$ clases, en función de una serie de K variables (X_1, X_2, \dots, X_k). Este problema se resuelve en dos fases:

1. Determinación del número de clases y de las propiedades de estas en relación a las K variables.
2. Asignar a cada uno de los N individuos a una de las M clases utilizando una regla de decisión, basada en las propiedades de los individuos y las clases en relación a las K variables.

Para este caso particular de aplicación, el conjunto de variables, está representado por la reflectividad en cada una de las bandas seleccionadas.

La determinación de los conglomerados (*clusters*), puede hacerse a partir de dos criterios principales, cuya diferencia principal estriba en el conocimiento previo o no del grupo al cual pertenece cada observación.

En una clasificación supervisada se parte de un conjunto de clases conocido a priori. Es decir, existe un conjunto de observaciones clasificadas en un conjunto de clases dado, y se conoce la clase a la que cada observación pertenece. Para esta clasificación, existen dos fases bien diferenciadas: la primera, en la que se desarrolla o crea una o varias reglas de decisión (diseño del clasificador), y luego, el proceso de clasificación en sí.

En una clasificación no supervisada se dispone de un conjunto de observaciones, pero se desconoce el número de clases en que es razonable particionarlo, así como a qué clase pertenece cada observación. A su vez, se hace necesario determinar el número de clases que queremos establecer, para dejar que las defina un procedimiento estadístico. Este proceso de clasificación, es notablemente más complejo que el anterior, debido a que se desconocen las clases naturales, y queda afectado a la habilidad para seleccionar

que dependerá de las características que representan al objeto y de la metodología de clasificación empleada.

Comúnmente, ambas clasificaciones, se aplican de manera complementaria. En primer lugar, se aplica una clasificación no supervisada, para obtener una primera idea de los agrupamientos posibles de la distribución. En segundo lugar, y haciendo uso de la información obtenida en el primer paso, se aplica la clasificación supervisada.

Siguiendo este esquema y en base a la información contenida en las bandas espectrales 1, 2, 3, 4, 5 y 7 de las imágenes Landsat 5 TM escogidas, se aplicó inicialmente, un método de clasificación no supervisada. Se obtendrán entonces una x cantidad de conglomerados (*clusters*), conformados por píxeles con comportamiento espectral homogéneo, y así extraer las clases temáticas de interés. Este procedimiento se llevó a cabo mediante la herramienta Iso Cluster del SIG ArcGis 9.3.

La herramienta Iso Cluster utiliza un procedimiento modificado de optimización iterativa de agrupación. El algoritmo separa la información contenida en las bandas espectrales (observaciones) en la cantidad de clases especificadas inicialmente por el usuario. Este algoritmo realiza agrupamientos de manera iterativa, durante cada iteración todas las muestras se asignan a los centros de los conglomerados existentes y los nuevos medios se vuelven a calcular para cada clase.

En ArcGis 9.3 la operación Iso cluster se ejecuta cargando las bandas individuales de una escena. En éste es posible especificar el número de clases máximo que se quiere obtener, el número de iteraciones del proceso, el número mínimo de observaciones por clase y el intervalo de muestreo. El número de clases que debe especificarse, es el número máximo de grupos que pueden resultar del proceso de agrupamiento. Sin embargo, el número de grupos en el archivo de salida, puede no ser el mismo que el número especificado, esto puede suceder cuando:

- Los valores medios de los datos del conglomerado inicial no se distribuyen uniformemente. En algunas gamas de valores de las observaciones, la frecuencia de apariciones de estos grupos pueden estar al lado de ninguno. Consecuentemente, algunos de las medias de los grupos predefinidos pueden no tener chance de absorber más observaciones.
- Los grupos conformados por menos observaciones que las indicadas por clase, serán eliminados al final de las iteraciones.
- Los grupos se funden con conglomerados vecinos cuando los valores estadísticos son similares; luego entonces, los grupos se vuelven estables. Algunos pueden estar tan cercanos a otros, y poseer estadísticas tan similares, que mantenerlos separados, sería una división de datos innecesaria.

El número de clases que se desea obtener, deberá ser lo suficientemente grande como para garantizar que, después de ejecutar el número determinado de iteraciones, la migración de las celdas o las observaciones de un grupo a otro es mínima, y por lo tanto, los grupos se estabilizan y quedan conformados los conglomerados finales.

En este trabajo los parámetros que se indican para ejecutar el proceso con las 6 bandas seleccionadas, son los siguientes: 30 clases, 500 iteraciones para generar una firma espectral estadística, 20 como mínimo de clases y un intervalo de muestreo de 10.

Con este algoritmo, se intentará determinar las características de los grupos naturales de celdas en el espacio multidimensional, y guardará los resultados en un archivo de salida de tipo ASCII. Como se mencionaba anteriormente, esta función es la más utilizada para las clasificaciones no supervisadas. El archivo de firma resultante, de con extensión GSG (*Output signature file*) se emplea como entrada para obtener un mapa de clases no supervisadas mediante la función *Maximum Likelihood Classify*.

Clasificación no supervisada según máxima verosimilitud

Para obtener un mapa temático de clases homogéneas se emplea la herramienta *MLClassify*. Esta herramienta se basa en dos principios: 1) Las celdas en cada muestra de clase en el espacio multidimensional se distribuyen normalmente y 2) el teorema de Bayes de la toma de decisiones.

El clasificador de máxima verosimilitud tiene en cuenta tanto las varianzas y covarianzas de las firmas de clase para la asignación de cada celda a una de las clases representadas en el archivo de firma GSG. Con el supuesto de que la distribución de una muestra de clase es normal, una clase puede ser caracterizada por el vector de medias y la matriz de covarianza. Teniendo en cuenta estas dos características se calculan las probabilidades para asignar las observaciones a cada una de las clases predefinidas.

Cuando una clasificación de máxima verosimilitud se lleva a cabo mediante ArcGis 9.3, dos parámetros pueden ser especificados:

a. Parámetro *Reject fraction*: Esta opción permite conocer los niveles de confianza de la clasificación. El número de niveles de confianza total es de 14, donde el primer nivel de confianza, codificado como 1, consiste en seleccionar aquellas celdas con la distancia más corta a cualquier vector de medias almacenada en el archivo de firmas de entrada, por lo tanto, la clasificación de estas celdas tiene la mayor certeza. Las celdas que comprenden el segundo nivel de confianza (valor de la celda 2) se clasificarían si el valor de rechazo es de 0.99 o menos. El nivel más bajo de confianza (valor de la celda 14) muestra las celdas que tendrán la mayor probabilidad de ser mal clasificadas. Las celdas de este nivel no serán clasificadas cuando el valor de rechazo sea de 0.005 o más.

Para este análisis puntual, la proporción de celdas que no serán clasificadas para evitar la asignación incorrecta a cada clase serán de 0,05%. Por lo tanto, elimina ese porcentaje de valores anómalos o dudosos para que no deforme la clase.

b. Parámetro *A priori probability weighting*: Especifica la probabilidad o pesos a priori de las clases representadas en el archivo de firmas GSG. La opción **EQUAL** indica que todas las clases tendrán la misma probabilidad a priori de captar celdas. **SAMPLE** determina que la probabilidad a priori será proporcional al número de celdas para cada clase en el archivo de firma GSG. La opción **FILE** permite leer las ponderaciones a priori de cada clase desde un archivo ASCII previamente elaborado por el usuario.

Como resultado de aplicar estos parámetros, se obtuvo una capa raster que clasificó todos los píxeles de la imagen en 26 categorías, de las cuales se extraerán aquellas que pertenecen al área urbana de la ciudad de Tandil.

Esta extracción de clases urbanas, se realiza a partir de un análisis visual. En primer lugar, se convierte la capa raster de clases a capa de puntos (*Conversion Tools/From Raster to Point*), para luego, a partir de la utilización de la herramienta *Export to KML*, exportar la capa obtenida a Google Earth y contrastar la distribución de cada clase con la cobertura real observada en la imagen satelital de alta resolución (imagen QuickBird © DigitalGlobe Inc., del 15 de Enero de 2007, disponible en © 2010 Google Earth). Se seleccionan así aquellas clases que estén claramente superpuestas sobre usos de suelo urbano, que para nuestro análisis específico estarían representadas por las clases 10, 17, 19, 20, 23, 24, 25 y 26.

Partiendo de estas clases urbanas y mediante el mismo procedimiento fue posible identificar cuales de estas clases urbanas se encontraban construidas (20, 23, 24, 25 y 26) y cuales no (10, 17, 19). En la Figura 1 se presentan algunos ejemplos del análisis visual correspondiente.

FIGURA 1. Clases urbanas construidas y no construidas



Fuente: elaboración propia en base a imagen QuickBird © DigitalGlobe Inc., del 15 de Enero de 2007, disponible en ©2010 Google Earth.

Clasificación supervisada y edición de firmas espectrales

Las clasificaciones supervisadas, a diferencia del anterior método de clasificación, puede ser definida como un proceso en que píxeles de identidad conocida, ubicados dentro de las áreas de trabajo seleccionadas, se utilizan para clasificar píxeles de identidad desconocida. En esta clasificación, se realizan generalmente las siguientes etapas: 1) Etapa de entrenamiento (en este caso fue reemplazada por el procesamiento de clasificación no supervisada); 2) Selección del algoritmo de clasificación adecuado y clasificación y 3) Operaciones de post-clasificación.

En nuestro trabajo se optó por editar y optimizar las firmas individuales de las clases obtenidas, de tal modo que sirvan como parámetros para reclasificar la imagen multispectral de origen, es decir para realizar una clasificación supervisada.

Se seleccionaron así la totalidad de los píxeles de cada una de las clases de manera individual y se extrajeron muestras de reflectancia para cada una de las bandas de la imagen Landsat 5 TM. Usando el histograma de cada clase, fue posible eliminar aquellas observaciones que se encontraban extremadamente alejadas de la media, o, dicho de otra manera, que compartían menos características que el resto de los valores seleccionados. Se optó en este trabajo por eliminar el 5% de las observaciones menos representativas para elaborar las nuevas firmas espectrales de clase.

Como resultado se obtienen valores medios (media) y umbrales (máximos y mínimos) de reflectancia para cada clase en cada una de sus bandas, siendo posible de esta manera elaborar un archivo de firmas espectrales que permita posteriormente ejecutar una clasificación, y así poder realizar comparaciones y análisis de evolución histórica de cada clase.

Análisis lineal de mezclas espectrales sobre clases urbanas

La señal registrada por el sensor en cada píxel, representa una mezcla de reflectancias de varias coberturas puras, y en el espacio urbano esta heterogeneidad de coberturas por unidad de superficie se incrementa más aún. Es así que para alcanzar una mejor interpretación de cada una de las clases obtenidas mediante el procedimiento descrito anteriormente, resulta muy útil realizar un análisis lineal de mezclas espectrales (en inglés *Spectral Mixture Analysis*).

Este análisis permite calcular, para cada clase, la proporción ocupada por cada una de las cubiertas que lo integran y obtener así información sub-píxel sobre el área de estudio. Se asume para este procedimiento, que:

- Las mezclas no son lineales
- La proporción de cada componente puro (F_i) debe estar entre 0 y 1: $0 \leq F_{i,j,m} \leq 1$ (3)
- No existe negatividad en la solución: $\sum_{m=1,p} F_{i,j,m} = 1$ (4)
- No hay influencia de cubiertas vecinas.

En este contexto se admite que en cada píxel mezclado o mixto, la radiancia total constituye una combinación lineal de la radiancia individual de los componentes puros, en proporción a la superficie que ocupan. El concepto puede sintetizarse en la expresión (Chuvieco, 2010, p.368):

$$\rho_{i,j,k} = \sum_{m=1,p} F_{i,j,m} \rho_{m,k} + e_{i,j} \quad (5)$$

donde, $\rho_{i,j,k}$ indica la reflectividad observada en el píxel i,j en la banda k ; $F_{i,j,m}$ es la proporción del componente m en ese píxel i,j para cada uno de los p componentes puros; $\rho_{m,k}$ corresponde a la reflectividad característica de ese componente m en la banda k , y $e_{i,j}$ representa el error asociado a la estimación de las proporciones en cada píxel i,j .

Así, el total de las proporciones correspondientes a los componentes individuales presentes, equivale a la superficie del píxel.

Para conocer las respuestas espectrales de los componentes puros en cada una de las clases (denominados “miembros terminales” o en inglés *endmembers*), fue necesario recurrir a una serie de bibliotecas espectrales. Estas bibliotecas almacenan colecciones de espectros, habitualmente tomados en laboratorio, bajo condiciones controladas, que intentan recoger la reflectividad característica de una amplia variedad de materiales terrestres.

Son varios los núcleos de investigación que disponen de dichas bibliotecas, dentro de los cuales, empleamos por su vasto contenido sobre coberturas urbanas las siguientes:

Nombre: USGS Spectroscopy Lab

Web: <http://speclab.cr.usgs.gov/spectral.lib06/ds231/datatable.html>

Nombre: JPL (jet propulsión laboratory) - ASTER

Web: <http://speclib.jpl.nasa.gov>

Nombre: Santa Barbara urban spectral libraries

Web: <http://www.geogr.uni-jena.de/~c5hema/spec/sburbspectable.htm>

Finalmente, obtenidas las respuestas espectrales de los componentes puros de cada clase, fue posible realizar una reconstrucción de la reflectividad mezclada que capta el sensor para cada una de las longitudes de onda tenidas en cuenta en el análisis, es decir, para las bandas 1, 2, 3, 4, 5 y 7 de Landsat 5 TM. Esta reconstrucción fue realizada de manera inductiva a partir del conocimiento del terreno en base a la construcción de gráficos lineales que permiten comparar las firmas espectrales de las clases obtenidas, las de cada uno de los componentes puros observados en cada clase y los promedios ponderados entre ellos que representan la reconstrucción de la reflectancia que capta el sensor. A modo de ejemplo se muestra en la Figura 2 el procedimiento mencionado aplicado para la clase 24, correspondiente a barrios residenciales de alta densidad cuyas viviendas poseen techos de tejas rojas o marrón-rojizas.


FIGURA 2. Análisis lineal de mezclas espectrales

Barrios con Techo de Tejas rojas						
Clase	B1	B2	B3	B4	B5	B6
Clase 24	0.1351	0.1426	0.1492	0.2826	0.3092	0.2531
Red tile Roof	0.06	0.08	0.175	0.3	0.58	0.57
Concrete road	0.235	0.265	0.255	0.255	0.225	0.228
Green Vegetation (grassland)	0.018	0.048	0.03	0.39	0.16	0.05
Old White paint	0.385	0.4	0.415	0.415	0.395	0.25
Old Asphalt road, fair condition	0.1	0.118	0.12	0.125	0.155	0.14
Red paint	0.009	0.009	0.5	0.52	0.43	0.23
Older concrete sidewalk	0.2	0.27	0.3	0.37	0.385	0.385
Bare soil (construction site)	0.09	0.125	0.16	0.225	0.375	0.385
Parking Lot	0.062	0.065	0.07	0.075	0.075	0.075
Tree	0.0640	0.0891	0.0519	0.5007	0.3049	0.1500
Promedio	0.10659775	0.13646935	0.1567889	0.2653577	0.308485	0.2764961

Obtención de firmas espectrales de componentes puros



Clase 24



Barrios residenciales con techo de tejas rojas o marrón-rojizas: 45% asfalto, 20% tejas rojas, 20% vereda de baldosa de concreto y 15% arboles

Fuente: elaboración personal

A partir de la identificación de las coberturas puras en cada una de las clases y su representación proporcional por unidad de superficie, fue posible realizar un re-ajuste espectral en cada clase, permitiendo mejorar la clasificación e interpretación de coberturas y usos del suelo urbano en los diferentes períodos considerados.

Estimación de la exactitud de la clasificación

En un sentido estricto, ninguna clasificación puede considerarse completa hasta que su grado de exactitud sea evaluado. El grado de exactitud puede definirse como el grado de concordancia entre las clases asignadas por el clasificador y sus ubicaciones correctas según los datos recolectados en tierra o clasificados previamente haciendo uso de otras metodologías, y considerados como datos de referencia. Este procedimiento construiría en realidad sólo una evaluación de la calidad de la selección de las áreas de entrenamiento. También podría recurrirse a una validación cruzada basada en comparaciones con los resultados de otros clasificadores.

El instrumento más usual para evaluar la exactitud de una clasificación es la matriz de confusión, también llamada matriz de error o de contingencia. Esta es una matriz cuadrada de $n \times n$ filas y columnas, en la que n representa el número de clases. Dicha matriz muestra la relación entre dos series de medidas

correspondientes al área de estudio. La primera serie corresponde a datos de referencia adquiridos de observaciones de campo, inspección de estadísticas, interpretación de fotos aéreas y otras fuentes similares. La segunda corresponde a la categorización de los píxeles realizada por el clasificador para las clases de interés. En una matriz de confusión las columnas corresponden a los datos de referencia, mientras que las filas corresponden a las asignaciones del clasificador. A partir de una matriz de confusión pueden deducirse varios índices relativos a la exactitud de la clasificación (Chuvienco, 2010, p. 501).

En la Figura 3 se presenta una matriz de confusión simple, únicamente compuesta por dos categorías, construido y no construido. Los valores en las columnas representan las clases reales obtenidas de una fuente de información auxiliar, como es el catastro digital urbano de la ciudad de Tandil, y que posee información sobre la superficie construida por manzana para el año 2006⁴. En las filas aparecen las clases obtenidas tras la clasificación. La diagonal de esta matriz cuadrada expresa el número de puntos de verificación en donde se produce acuerdo entre las dos fuentes (mapa y realidad), mientras los marginales suponen errores de asignación. La relación entre el número de puntos correctamente asignados (diagonal) y el total expresa la fiabilidad total global del mapa, que para nuestro caso es de 82,4%. Los errores de omisión en columnas indican tipos de cubiertas reales que no se incluyeron en el mapa de clases obtenido, siendo 6,1% para manzanas con construcciones y 28,4% para manzanas sin construcciones; mientras que los residuales en filas, es decir los errores de comisión, implican cubiertas del mapa que no se ajustan a la realidad, siendo 14,1% para construido y 50% para no construido.

FIGURA 3. Matriz de confusión. Clasificación de imagen Landsat 5 TM e información auxiliar del catastro urbano de Tandil (2006)

	<i>Construido</i>	<i>No construido</i>	<i>Total</i>	<i>Exactitud usuario</i>	<i>Error comisión</i>
<i>Construido</i>	1156	189	1345	85.9%	14.1%
<i>No construido</i>	75	75	150	50.0%	50.0%
<i>Total</i>	1231	264	1495		
<i>Exactitud productor</i>	93.9%	71.6%			
<i>Error omisión</i>	6.1%	28.4%			

Fuente: elaboración personal


⁴ Cabe destacar, que esta información auxiliar utilizada, no se encuentra disponible para toda el área de estudio, sino, sobre el 39,9% de su superficie (1492 manzanas). Se debe mencionar que la muestra final con la que se está trabajando, no es probabilística, debido a que, inicialmente los casos seleccionados para conformarla, no tuvieron igual chance de ser seleccionados (se toman intencionalmente puntos que se encuentran localizados en determinado lugar del área mencionada). Y, por otro lado, tampoco fueron elegidos por medio de un método probabilístico de selección.

Cálculo y evolución de la superficie urbana construida (1989 - 2006)

Finalmente, detectadas las clases que representan áreas urbanas construidas y conociendo el error aproximado de nuestra clasificación, es posible, calcular la superficie edificada en los diferentes momentos considerados, y también, conocer la evolución de la ocupación del suelo durante el período.

Para calcular la superficie total construida solo resta multiplicar la superficie que representa cada *pixel* (resolución espacial Landsat 5 TM 30m = superficie por *pixel* 900 m²) por el total de celdas que componen las clases 20, 23, 24, 25 y 26. De esta manera, la superficie construida para 1989 resulta de multiplicar 14.221 x 900 m² = 12.798.900 m², mientras que para 2006 sería 19.982 x 900m² = 17.983.800 m² (Figura 4). Estos resultados permiten deducir posteriormente la evolución de la construcción durante el periodo 1989-2006, que sería en este caso de 5.184.900 m².

FIGURA 4. Cálculo y evolución de superficie urbana construida
Área urbana y complementaria de Tandil (1989-2006)



Fuente: elaboración personal

Conclusión y discusión

En principio, resulta interesante destacar que los cálculos sobre el área y evolución de superficies construidas, e identificación de las principales formas y densidades de construcción, se convierte en una técnica de gran utilidad para la planificación y gestión del uso del suelo urbano.

El hecho de trabajar con imágenes gratuitas con amplia distribución geográfica y temporal, y de contar con firmas espectrales generalizables, permite aplicar los procedimientos descritos a diferentes áreas de estudio y periodos considerados.

Más allá de los fines de este trabajo, podrían señalarse otras utilidades de extraer áreas urbanas construidas, algunas de ellas serían: el ajuste de las unidades administrativas de recolección de información de los organismos oficiales de estadísticas y censos (ej. radios censales); la obtención de insumos básicos para la realización de proyecciones sobre la expansión urbana; la evaluación y seguimiento de los impactos provocados por los planes de ordenamiento territorial implantados y, también podría emplearse para detectar y controlar la expansión irregular e ilegal en las periferias urbanas.

Sin embargo, la evaluación de los procedimientos descriptos, puede ser optimizada significativamente si se corrigen tres aspectos comentados en este trabajo. Uno, referido a la fuente de datos auxiliar empleada para evaluar la clasificación de las imágenes Landsat 5 TM. Esta fuente de datos suministrada por la Municipalidad de Tandil, se presenta como deficiente y desactualizada en cuanto a la información disponible, por lo tanto, omite gran parte de las construcciones existentes en la ciudad, reflejando un alto valor de comisión en la matriz de confusión. Este problema se origina más que nada, por la falta de declaración de las construcciones por parte de los propietarios, aunque, es de público conocimiento, que a partir de la implantación de políticas públicas específicas al respecto, este sub-registro se redujo considerablemente en la actualidad.

Otro de los errores existentes proviene de las diferencias entre las unidades espaciales para validar la información. Las manzanas provenientes del catastro urbano de Tandil poseen una superficie de 16.900 m², mientras que los píxeles de las imágenes empleadas es de 900 m². Esta diferencia es aún mayor si consideramos las parcelas que se encuentran en el área complementaria de la ciudad (y son justamente aquellas áreas en las que aparecen mayormente los errores de clasificación). Por lo tanto, o se debería ajustar el tamaño de las unidades de origen a las empleadas para la contrastación, o bien se debería buscar otras fuentes alternativas.

Finalmente, la evaluación mediante una matriz de confusión desagrupada por clase debería considerarse para detectar específicamente cuáles de ellas son las que inciden en forma gravitante en los errores de clasificación presentados.

Bibliografía

Ackermann, G. y Mering, C. (2007). Extracción de áreas construidas a partir del análisis de imágenes satelitales SPOT. Rivas, R. *et al.* (Eds). Teledetección. Hacia un mayor entendimiento de la dinámica global y regional. UNCPBA. p. 369-376.

Bielecka, E. (2005). A dasymetric population density map of Poland. Institute of Geodesy and Cartography. International Cartographic Conference, ICC 2005. Disponible en: <http://www.cartesia.org/geodoc/icc2005/pdf/oral/TEMA5/Session%209/ELZBIETA%20BIELECKA.pdf>

Chuvienco, E. (2010), Teledetección Ambiental. La observación de la tierra desde el espacio. Editorial Planeta, S. A. Barcelona. (Edición actualizada). 591 p.

Green, K. (2000). Selecting and Interpreting High-Resolution Images. Journal of Forestry, Society of American Foresters. Volume 98, Number 6, 1. p. 37-40.

Herold, M. y Roberts, D. (2005). Mapping asphalt road conditions with hyperspectral remote sensing. 3rd International Symposium Remote Sensing and Data Fusion Over Urban Areas (URBAN 2005). ISPRS. Disponible en: http://www.isprs.org/proceedings/XXXVI/8-W27/herold_roberts.pdf

Langford, M.; Unwin, D.J., y Maguire, D.J. (1990). Generating improved population density maps in an integrated GIS, en Proceedings of EGIS'90, EGIS Foundation (Amsterdam: EGIS Foundation). p. 651-660.

Lee, S. (2006). Landsat ETM sub-pixel analysis of urban landscape using fuzzy c-means clustering and differentiated impervious surface classes. American Society for Photogrammetry and Remote Sensing, Annual Conference. Bethesda, Maryland, USA. 7 p. Disponible en: <http://www.asprs.org/publications/proceedings/reno2006/0084.pdf>.

Lo, C.P. (1995). Automated population and dwelling unit estimation for high resolution satellite imagery: A GIS approach. International Journal of Remote Sensing, 16. p. 17-34.

Lourenço, J; Ramos, L.; Ramos, R.; Santos, H.; Fernandes, D. (2005). Urban areas identification through clustering trials and neural networks. 14 European Colloquium on Theoretical and Quantitative Geography, Tomar, Portugal. 11 p. Disponible en: http://repositorium.sdum.uminho.pt/bitstream/1822/4628/1/Lourenco_CI_7_2005.pdf

Martin, D. (1996). Geographic Information Systems: Socioeconomic Applications. Routledge, London. p. 208.

Mesev, V.; Gorte, B.; Longley, P. (2001). Modified Maximum-Likelihood Classification Algorithms and their Application to Urban Remote Sensing. Donnay, J-P.; Barnsley, M.; Longley, P. (eds.). Remote Sensing and Urban Analysis. Taylor and Francis. Londres, Inglaterra. p. 62-83.

Molina, G. y Chuvieco, E. (1997). Detección del crecimiento urbano en la ciudad de Maracaibo (Venezuela) mediante análisis multitemporal de imágenes MSS y TM. Casanova J. L. y Sanz, J. (Eds.). Teledetección: usos y aplicaciones. Valladolid, Universidad de Valladolid. p. 361-368.

Ranchin, T. y Wald, L. (2010). Data Fusion in Remote Sensing of Urban and Suburban Areas. Rashed, Tarek; Jürgens, Carsten (Eds.). Remote Sensing of Urban and Suburban Areas. Series: Remote Sensing and Digital Image Processing, Vol. 10. Springer. p. 193-218. Disponible en: <http://www.springerlink.com/content/978-1-4020-4371-0#section=710578&page=1&locus=0>

Recio, J., Pardo, J., Ruiz, L., Fernández, A. y Córcoles, P. (2003). Detección y cartografiado de los procesos de expansión urbana mediante técnicas combinadas de teledetección y SIG. IX Conferencia Iberoamericana de SIG, Cáceres, 24-26 Septiembre 2003. p. 1-14.

Schöpfer, E.; Lang, S.; Strobl, J. (2010). Segmentation and Object-Based Image Analysis. Rashed, Tarek; Jürgens, Carsten (Eds.). Remote Sensing of Urban and Suburban Areas. Series: Remote Sensing and Digital Image Processing, Vol. 10. Springer. p. 181-192. Disponible en: <http://www.springerlink.com/content/978-1-4020-4371-0#section=710577&page=1&locus=6>

Sleeter, R.; y Gould, M. (2007). Geographic information system software to remodel population data using dasymetric mapping methods. U.S. Geological Survey Techniques and Methods 11-C2, 15 p. Disponible en: <http://pubs.usgs.gov/tm/tm11c2/>

Thurstain-Goodwin, M. y Unwin, D. (2000). Defining and delineating the central areas of towns for statistical monitoring using continuous surface representations, CASA Working Paper Series 18, University College London. Disponible en: <http://eprints.ucl.ac.uk/1363/1/paper18.pdf>

Vidal, A.; Moreno, M. y Llopis, M. (2009). Clasificación por objetos en imagen aérea de alta resolución para detección de cambios en zona urbana. Teledetección: Agua y desarrollo sostenible. XIII Congreso de la Asociación Española de Teledetección. p. 549-552.

Weng, Q. (2010). Remote Sensing and GIS Integration: Theory, Methods, and Applications. The McGraw-Hill Companies, USA. p. 416