

Análisis comparativo entre las máquinas de vectores soporte y el clasificador de máxima probabilidad para la discriminación de cubiertas de suelo

J. P. Argañaraz*^{1,2}, I. Entraigas²

¹ *Becario de estudio, Comisión de Investigaciones Científicas de la Provincia de Buenos Aires*

² *Instituto de Hidrología de Llanuras «Dr. Eduardo J. Usunoff»
(UNCPBA, CIC, Municipalidad de Azul)*

Resumen

El mapeo de los tipos de cubierta de suelo es una de las aplicaciones más comunes de la teledetección. A tal efecto, las imágenes Landsat TM resultan de gran utilidad por su adecuada resolución espacial, espectral, temporal y accesibilidad. Una de las formas más empleadas para extraer información temática a partir de imágenes satelitales es la clasificación supervisada y la estrategia para aplicarla puede diferir desde el algoritmo de asignación seleccionado, el número de bandas incluidas y el tamaño de las áreas de entrenamiento. El objetivo del presente trabajo fue comparar clasificaciones realizadas con un algoritmo tradicional paramétrico: el de máxima probabilidad (MLC) y uno no paramétrico de uso relativamente reciente: las máquinas de vectores soporte (SVM), utilizando tres combinaciones de bandas de uso tradicional: 345, 3457, 1-5 y 7 y una combinación de bandas infrarrojas: 457 y distintos tamaños de áreas de entrenamiento. Con ambos algoritmos, las clasificaciones que incluyeron cuatro y seis bandas (combinaciones 3457 y 1-5 y 7, respectivamente) fueron significativamente mejores que con tres bandas (345) pero, en general, no presentaron diferencias entre sí. La combinación 457 demostró ser útil para discriminar cubiertas de suelo, con precisiones comparables a las combinaciones tradicionales. El aumento del tamaño del área de entrenamiento tuvo un impacto diferente en la precisión alcanzada por los clasificadores, dependiendo de la combinación de bandas utilizada y, en todos los casos, se observó la estabilización de la precisión global frente al incremento del tamaño del área de entrenamiento. La combinación 3457 resultó ser la más adecuada para la discriminación de cubiertas de suelo, optimizando la relación entre el número de bandas incluido y la precisión global obtenida. En general, las SVM tuvieron mejor desempeño que MLC con la combinación de tres bandas, mientras que con cuatro y seis bandas las diferencias no fueron significativas.

Palabras clave: clasificación supervisada, clasificador de máxima probabilidad, máquinas de vectores soporte, tamaño del área de entrenamiento, combinación de bandas, Landsat TM

Abstract

Land cover mapping is one of the most common applications of remote sensing. For that purpose Landsat TM imagery is of great usefulness due to its appropriate spatial, spectral and temporal resolution and accessibility. One of the most used ways of extracting thematic information from satellite imagery is supervised classification and the strategy to apply it may differ as to the classification algorithm, number of bands included and the size of the training set. The objective of the present article was to compare classifications made with a traditional parametric algorithm: the maximum likelihood classifier (MLC) and a non parametric and of relatively recent application: the support vector machines (SVM), with three traditional band combinations: 345, 3457, 1-5 and 7, and an infrared band combination: 457, testing different training set sizes. Using both classifiers, the classifications obtained with both four and six bands (combinations 3457 and 1-5 and 7, respectively) were significantly

* Autor para la correspondencia: argajuan@yahoo.com.ar

Recibido: 11-11-10; Aceptado: 06-09-11.

better than with three bands (345), however, in most cases there were no differences between them. The 457 combination proved to be useful to characterize land covers, showing precisions comparable to traditional band combinations. Increasing training size had a different effect on the precision reached by the classifiers, depending on the band combinations used and, in every case, a stabilization of the global precision was observed with an increase in the training size. Combination 3457 was the most appropriate to land cover discrimination, optimising the relationship between the number of bands included and the global precision obtained. In general, SVM had better performance than MLC with the three band combination, whereas with four and six bands differences were not significant.

Keywords: supervised classification, maximum likelihood classifier, support vector machines, training size, band combination, Landsat TM

Introducción

El mapeo de los recursos naturales reviste gran importancia para la generación de información acerca de las cantidades existentes, estado o calidad de los mismos y su distribución en el espacio. Estos estudios resultan de gran valor ya que sientan las bases para analizar la estructura del paisaje, planificar el uso del territorio y proponer medidas para el manejo y conservación de los recursos, entre otras aplicaciones (Matteucci, 1979; 1998).

Los grandes avances tecnológicos de las últimas décadas en la capacidad de procesamiento de las computadoras y en el campo de la percepción remota permiten la realización de este tipo de estudios sobre grandes superficies (escala de paisaje, región y hasta global) a partir del uso de imágenes satelitales. Uno de los métodos más utilizados para transformar los datos contenidos en estas imágenes en información temática es la clasificación digital y el mapeo de los distintos tipos de cubiertas de suelo es uno de los principales usos de estas tecnologías. Las estrategias a seguir para la obtención de estos mapas son numerosas y comprenden la selección del tipo de sensor, el método de clasificación (supervisado, no supervisado o mixto), el algoritmo (paramétrico o no paramétrico), los conjuntos de bandas y/o combinaciones de ellas y el número de imágenes (clasificaciones unitemporales o multitemporales), entre otras (Chuvieco, 2002; Hall *et al.*, 1995; Jensen, 1996). Las elecciones realizadas sobre cada uno de estos aspectos dependen principalmente de los objetivos del trabajo y de la disponibilidad de recursos.

Uno de los sensores más ampliamente utilizados con estos fines es el Landsat Thematic Mapper (TM) por su buena resolución espacial, espectral, temporal y accesibilidad de las imágenes (Chuvieco, 2002). El conjunto de bandas utilizadas para el mapeo de cubiertas de suelo a partir de imágenes multiespectrales es variable. En mu-

chos casos se opta por la combinación de las bandas 345 de Landsat (rojo *R*, infrarrojo cercano *IRC* e infrarrojo medio *IRM*, respectivamente) o sus análogas de otras plataformas (Foody y Mather, 2004; Foody *et al.*, 2006; Guerschman *et al.*, 2003; Wolter *et al.*, 1995), en otros, se incluye además la banda 7 (*IRM*) (Herrera *et al.*, 2009; Vogelmann *et al.*, 1998) y en muchos casos, se considera la totalidad de las bandas reflexivas de Landsat, incluyendo también las correspondientes a las regiones del azul y verde (Demaría *et al.*, 2008; Herrera *et al.*, 2005; Huang *et al.*, 2002; Oommen *et al.*, 2008; Waske y Benediktsson, 2007). En los artículos mencionados, la selección de la combinación de bandas incluida en las clasificaciones respondió a resultados de investigaciones previas, a la falta de disponibilidad de otras bandas o, en algunos casos, no se manifestó una justificación.

Por otro lado, los métodos de clasificación supervisados son frecuentemente utilizados cuando se tiene cierto conocimiento previo del área de estudio. En ellos, se definen *a priori* áreas representativas de cada una de las clases que componen la leyenda, denominadas áreas de entrenamiento, cuyas características espectrales son utilizadas para entrenar el clasificador (Chuvieco, 2002; Jensen, 1996). El algoritmo de máxima probabilidad (Maximum Likelihood Classifier, MLC) es uno de los más utilizados para tal fin y pertenece al conjunto de los métodos supervisados paramétricos, es decir, que asume la normalidad de los datos (Oommen *et al.*, 2008). Sin embargo, los problemas asociados al no cumplimiento de este supuesto motivaron la búsqueda de alternativas no paramétricas (Foody y Mather, 2004). En los últimos años, las máquinas de vectores soporte (Support Vector Machines, SVM) han captado la atención de la comunidad científica por su potencialidad y, en muchos casos, han demostrado tener un mejor desempeño que otros clasificadores, tanto paramétricos como no paramétricos (Belousov *et al.*, 2002; Her-

mes *et al.*, 1999; Huang *et al.*, 2002; Melgani y Bruzzone, 2004).

Asimismo, la fase de entrenamiento en una clasificación supervisada reviste gran importancia, ya que la cantidad y calidad de los datos empleados para entrenar al clasificador incide en gran medida en la precisión del mapa obtenido (Foody y Mathur, 2006; Foody *et al.*, 2006). Los píxeles que componen la muestra de entrenamiento de cada clase deben ser representativos de la población de píxeles que compone dicha clase (Chen y Stow, 2002; Muchoney y Strahler, 2002). Por ello, las áreas de entrenamiento deben ser lo suficientemente grandes y estar distribuidas de tal forma que la heterogeneidad natural de la respuesta espectral de cada clase sea comprendida (Mather, 2004). Con la finalidad de satisfacer estos requerimientos, Mather (2004) propuso volúmenes de 30p por clase (siendo p el número de bandas incluidas en la clasificación) para entrenar al clasificador. El efecto del tamaño del área de entrenamiento en la precisión ha sido investigado por numerosos autores y, en general, a un aumento en el volumen de datos de entrenamiento le corresponde un aumento en la precisión (Foody y Mathur, 2004; Pal y Mather, 2003), aunque en algunos casos se alcanzó un valor constante (Van Niel *et al.*, 2005) o, inclusive, negativo (Oommen *et al.*, 2008) a partir de cierto tamaño del área de entrenamiento.

Por ello, teniendo en cuenta la variedad de estrategias posibles al momento de mapear las cubiertas de suelo y la necesidad de evaluarlas cuando se pretende generar este tipo de información, el objetivo del presente trabajo fue comparar el desempeño de un clasificador paramétrico tradicional como es el MLC y uno no paramétrico de gran potencial, según la bibliografía, como son las SVM, empleando diferentes conjuntos de bandas del sensor TM y distintos tamaños de áreas de entrenamiento. Es preciso destacar que este trabajo contempla sólo algunas de las alternativas conocidas para clasificar cubiertas de suelo a partir de clasificaciones digitales, pero que las posibilidades comprenden una lista más extensa.

Materiales y Métodos

Área de estudio

El estudio se circunscribe a la zona llana de la cuenca del Arroyo del Azul (Figura 1). La cuenca se ubica en el centro de la provincia de Buenos Aires, Argentina, entre los 58° 51' y 60° 10'



Figura 1. Ubicación relativa de la cuenca del Arroyo del Azul (en gris se destaca el área de estudio).

de longitud oeste y 36° 09' y 37° 19' de latitud sur, en la denominada Depresión del Salado. La zona más llana de la cuenca se extiende aguas abajo de la ciudad de Azul ocupando una superficie aproximada de 3.750 km², con una pendiente regional muy baja (0,1 %, Usunoff *et al.*, 1999). Según la clasificación de Thornthwaite, el clima es subhúmedo-húmedo, mesotermal con poca o nula deficiencia de agua (en símbolos se expresa: C₂B₂r) (período 1901-1985). La temperatura media anual es de 14°C y la precipitación anual media es de 894 mm, con excesos desde Mayo a Noviembre (Sala *et al.*, 1987). La región está sometida a inundaciones periódicas de intensidad y duración variables, en función de factores topográficos, edáficos y climáticos (Insausti *et al.*, 2005). Esto, sumado a la baja aptitud de los suelos limita la actividad agropecuaria, permitiendo la conservación de las características relativamente naturales de los pastizales del área (Soriano *et al.*, 1992). Según Vervoort (1967), el área de estudio estaba ocupada principalmente por pajonales de *Paspalum quadrifarium* o *Paspaleum*. Esta gramínea forma matas altas y densas que componen poblaciones puras que constituyen mosaicos alternando con flechillares y praderas húmedas o saladas. Actualmente, el pajonal ha sufrido un retroceso en su extensión por la aplicación de herbicidas, quemas y laboreo, en pos de mejorar su receptividad ganadera (Latterra *et al.*, 1998).

Selección y pre-procesamiento de imágenes satelitales

Las clasificaciones se realizaron a partir de una imagen Landsat 5 TM. Estas imágenes son muy utilizadas para confeccionar cartografía te-

mática por su buena resolución espacial (30 m de píxel en las bandas reflexivas), espectral (3 bandas en el visible, 1 en el infrarrojo cercano, 2 en el infrarrojo medio y 1 en el infrarrojo térmico de menor resolución espacial), temporal (16 días de revisita) y accesibilidad de las imágenes (Chuvieco, 2002). La imagen utilizada corresponde a la escena 225/85 y fue tomada el 18/10/2009. La misma fue corregida radiométricamente a valores de reflectividad al tope de la atmósfera según Chander *et al.* (2007) y luego corregida geométricamente utilizando una imagen base Landsat 7 ETM+ pancromática del 15/10/2000 georeferenciada utilizando las cartas topográficas del IGM 1:50.000 (Proyección Gauss-Krüger, Datum Campo Inchauspe, Elipsoide Internacional de 1924), con 27 puntos de control y un error RMS < 1 píxel.

Clasificación digital

A partir de la observación de la imagen satelital y viajes al área de estudio, se identificaron 7 clases de cubiertas de suelo (Tabla 1). Las clases que presentaron límites nítidos, como es el caso de los Cuerpos de agua, Montes y Urbanizaciones, se mapearon mediante interpretación visual y digitalización en pantalla (ver Argañaraz y Entraigas, 2010), con la finalidad de simplificar el análisis digital. La comparación de los clasificadores de interés, el de máxima probabilidad y las máquinas de vectores soporte se realizó para la discriminación de las clases restan-

tes: Cultivo estival, Cultivo invernal, Campo natural y Pajonal.

El clasificador de máxima probabilidad es un algoritmo paramétrico que supone la distribución normal de los valores de los píxeles de cada clase. De esta forma, cada tipo de cubierta puede ser descrita por una función de probabilidad y los píxeles a clasificar se asignan a aquella clase que maximice dicha función. Este algoritmo es uno de los más empleados en teledetección por su robustez (Chuvieco, 2002).

Las máquinas de vectores soporte, en cambio, no requieren de la estimación de la distribución de los datos para la asignación de los píxeles, sino que utilizan un criterio «geométrico» basado en el concepto de maximización de margen entre clases (Melgani y Bruzzone, 2004). En el caso de dos clases linealmente separables, las SVM identifican el hiperplano óptimo de separación entre clases en el espacio multidimensional (en una clasificación, la dimensión esta dada por el número de bandas incluidas en el análisis), basados en los datos de entrenamiento. El hiperplano óptimo es aquel que maximiza la distancia entre el hiperplano y los datos de entrenamiento más cercanos. En la mayoría de los casos, sin embargo, las clases no son linealmente separables y las SVM transforman los datos de entrenamiento a un espacio vectorial de mayores dimensiones a través de un kernel, donde se puede establecer un hiperplano de separación lineal. En este estudio, se utilizó un kernel gaussiano denominado Función de Base Radial (RBF), que es considerado como una primera elección razonable (Hsu *et al.*, 2009). Este kernel requiere la determinación de dos pa-

Tabla 1. Descripción de los tipos de cubiertas de suelo en la cuenca baja del Arroyo del Azul.

Tipo de cubierta	Descripción
Campo natural (CN)	Incluye potreros abandonados que con los años han sido dominados por especies espontáneas, nativas o naturalizadas (León <i>et al.</i> , 1979), pastizales naturales y pasturas implantadas. Generalmente pastoreados.
Cultivo estival (CE)	Potreros destinados al cultivo de girasol, maíz y soja, principalmente (en sus primeros estadios en la imagen del 18/10/2009).
Cultivo invernal (CI)	Principalmente trigo y en menor medida avena y otras especies para forraje. Algunos potreros son luego utilizados para hacer soja de segunda.
Pajonal (PJ)	Pajonales abiertos de <i>Paspalum quadrifarium</i> , generalmente sometidos a pastoreo y a fuego (ocasionalmente), y pajonales casi puros que forman matas altas y densas.
Cuerpos de agua	Incluye el Arroyo del Azul, sus tributarios y otros cursos de carácter temporario, además de las áreas bajas e inundables, con agua en forma temporaria o permanente.
Montes	Incluye arboledas de origen antrópico, generalmente asociadas a bordes de caminos y cascos de chacras y estancias.
Áreas urbanizadas	Comprende parte de la ciudad de Azul y la localidad de Cacharí.

rámetros C y γ . El primero es una constante que penaliza los errores de clasificación, es decir, los píxeles situados en el «lado equivocado» del hiperplano, y el segundo es un parámetro inversamente proporcional a la amplitud del kernel. Cuando C y γ son altos, hay una tendencia a que el hiperplano se sobreajuste a los datos de entrenamiento, dando como resultado que el clasificador no generalice bien y se incremente el error al momento de discriminar los píxeles restantes de la imagen. La determinación de los valores óptimos de estos parámetros se realizó mediante una validación cruzada con 10 subconjuntos, utilizando el software R Development Core Team (2010), paquete «e1071» (Dimitriadou *et al.*, 2010), donde se evalúan pares (C , γ) y se selecciona aquel que menor error presenta. Los intervalos considerados fueron $C \in [2^{-5}, 2^{15}]$ y $\gamma \in [2^{-15}, 2^3]$, según lo recomendado por Hsu *et al.* (2009).

Si bien las SVM fueron diseñadas para clasificaciones binarias, existen distintas estrategias para aplicarlas en clasificaciones múltiples, como suele ocurrir en análisis de teledetección. En este trabajo se utilizó la denominada «uno contra uno» (*one against one*), que mostró ser superior a otras estrategias (Hsu y Lin, 2002). En ella, a cada píxel se le aplican tantas SVM como pares de clases existen $[T(T-1)/2]$, donde T es el número de clases. De cada comparación, la clase favorecida obtiene un voto y la clase que más votos obtiene es la que se asignará al píxel (Foody y Mathur, 2004).

En cuanto a la selección de bandas a incluir en las clasificaciones, se analizaron cuatro combinaciones, teniendo en cuenta las más frecuentemente utilizadas para la discriminación de cubiertas de suelo: 345, 3457 y 1-5 y 7, que en adelante serán referidas como clasificaciones de tres, cuatro y seis bandas, respectivamente y la combinación de bandas infrarrojas 457, en función de las diferencias observadas en las firmas espectrales de las cubiertas de suelo a discriminar.

El mapa final de clases se obtuvo aplicando un filtro mediano (3×3) y luego un operador morfológico (*clumping classes*) (3×3), a fin de eliminar píxeles aislados (Chuvieco, 2002).

El software utilizado para el pre-procesamiento y clasificación de la imagen fue ENVI 4.4 (*ITT Corporation Visual Information Solution*).

Verdad de campo y verificación de resultados

Se tomaron 497 puntos de control con GPS ProMark 3, entre Octubre y Diciembre de 2009, utilizando las rutas y caminos vecinales como

transectas de muestreo, procurando la representación de la heterogeneidad del paisaje. Cada punto de control se digitalizó como un polígono de un área aproximada de 3×3 píxeles, que posteriormente fue rasterizado. A fin de evitar que las clasificaciones se vieran influenciadas por la selección de los datos de entrenamiento y evaluación, así como los problemas asociados a la autocorrelación espacial de los píxeles cercanos, los conjuntos utilizados en ambas etapas se obtuvieron mediante un muestreo estratificado al azar (Foody *et al.*, 2006; Mather, 2004; Oommen *et al.*, 2008). En primer término, se estableció un conjunto con el 30 % del total de píxeles de verdad de campo (1.596 píxeles), que se utilizó para la evaluación de todas las clasificaciones, superando el mínimo de 50 píxeles por clase recomendado por Congalton (1991). Con el 70 % de píxeles restantes, se conformaron seis conjuntos representando el 2,5, 5, 10, 30, 50 y 70 % del total de píxeles, que se utilizaron para entrenar los clasificadores y así evaluar la influencia de los tamaños del área de entrenamiento en las clasificaciones. Estos conjuntos son referidos en adelante como t2,5 (135 píxeles), t5 (270 píxeles), t10 (540 píxeles), t30 (1.596 píxeles), t50 (2.668 píxeles) y t70 (3.779 píxeles), respectivamente. La selección de las áreas de entrenamiento mediante un muestreo estratificado, es decir, considerando la proporción de clases, tuvo mejores resultados que cuando el número de píxeles fue uniforme para todas las clases (Huang *et al.*, 2002). El entrenamiento de ambos clasificadores con idénticos conjuntos de datos y la posterior evaluación con un único set de píxeles, diferentes de los de entrenamiento, permite asegurar que las diferencias de precisión en las clasificaciones se deben a los procesos de asignación de los píxeles, es decir, al algoritmo utilizado (Foody, 2004, Oommen *et al.*, 2008).

La precisión de las clasificaciones se evaluó mediante una matriz de confusión, en donde las columnas contienen la información de referencia tomada en campo y las filas, la generada por la clasificación. A partir de estas matrices se calcularon las precisiones globales (PG) de cada clasificación, consideradas como el porcentaje de píxeles correctamente clasificados (sumatoria de la diagonal principal) respecto del total de píxeles utilizado en la evaluación (Congalton, 1991). Una de las ventajas de las matrices de confusión es que permiten identificar los conflictos entre categorías y, de esta forma, conocer la exactitud alcanzada para cada una de las clases (Chuvieco, 2002). Para ello, la precisión de cada clase se calculó a través de las precisiones del productor (PP) y del usuario (PU). La primera representa el por-

centaje de cubierta real incluida en la clasificación y la segunda, el porcentaje del mapa que no se corresponde con la realidad (Congalton, 1991).

Comparación de clasificaciones

Para lograr una comparación objetiva de la precisión de los mapas temáticos se deben tener en cuenta criterios estadísticos (Foody, 2004). Para ello, se utilizó la prueba de McNemar (Agresti, 2007) sin corrección por continuidad, a fin de evaluar la significancia estadística de las diferencias en la precisión de las clasificaciones. Esta prueba se puede utilizar cuando las matrices de confusión se obtienen a partir del mismo conjunto de datos y, por lo tanto, no son independientes. Si bien el coeficiente kappa ha sido frecuentemente utilizado en este tipo de comparaciones, no resulta conveniente puesto que requiere independencia entre las muestras (Foody, 2004). Además, en la actualidad se desalienta su uso para evaluar la precisión y comparar mapas debido a que no indica cuál es la fuente del error y, particularmente, a la carencia de utilidad de comparar la precisión de una clasificación con la potencialmente obtenida por azar, ya que este no es un criterio válido para la confección de un mapa (Pontius y Millones, 2011).

La prueba de McNemar es no paramétrica y requiere la confección de una matriz de 2×2 (Tabla 2). Donde f_{11} y f_{22} es el número de píxeles clasificados correctamente e incorrectamente por ambas clasificaciones, respectivamente; f_{12} es el número de píxeles correctamente clasificados por la clasificación 1 e incorrectamente clasificados por la clasificación 2 y f_{21} es el número de píxeles correctamente clasificados por la clasificación 2 pero incorrectamente clasificados por la clasificación 1.

La prueba se basa en el estadístico de la prueba normal estándar:

$$Z = \frac{f_{12} - f_{21}}{\sqrt{f_{12} + f_{21}}} \quad [1]$$

Tabla 2. Matriz 2×2 para la comparación de clasificaciones digitales utilizando la prueba de McNemar

Clasificación del píxel	Clasificación 2		
	Correcto	Incorrecto	Σ
Clasificación 1			
Correcto	f_{11}	f_{12}	
Incorrecto	f_{21}	f_{22}	
Σ			

El cuadrado de Z sigue una distribución Chi-cuadrado (X^2) con un grado de libertad (Agresti, 2007) y la evaluación de la significancia de las diferencias se basa en la comparación del X^2 estimado con los valores tabulados.

Resultados y discusión

En total se realizaron 48 clasificaciones, 24 para cada algoritmo y 6 para cada combinación de bandas, correspondientes a los seis tamaños de áreas de entrenamiento. En términos generales, las clasificaciones fueron muy buenas, con precisiones globales entre 83 % y 90 % (Tabla 3, Tabla 7).

Efecto de la combinación de bandas

Las precisiones globales para las clasificaciones de tres bandas con el algoritmo MLC estuvieron entre 83,4 y 87,8 %. Al incorporar la banda 7, la precisión aumentó entre 4 y 5 % aproximadamente, fundamentalmente debido a una menor superficie de cultivos estivales y campo natural clasificada como pajonal (Tabla 6). La inclusión de las bandas 1 y 2 (clasificación de seis bandas) sólo produjo un incremento menor a 1,5 % respecto de la clasificación de cuatro bandas, alcanzando valores entre \approx 89 y 90 % (Tabla 3). En cuanto a SVM, las precisiones globales para las clasificaciones de tres bandas estuvieron entre 83,0 y 87,6 %, con incrementos menores a 2,7 % al incorporar la banda 7, impulsado por la menor confusión de las clases CE y CN con PJ, al igual que con MLC. Cuando las bandas 1 y 2 fueron incluidas en la clasificación las diferencias fueron muy pequeñas, generalmente disminuyendo la precisión en décimas.

Las pruebas de McNemar indicaron que las clasificaciones de tres bandas presentaron diferencias significativas con las clasificaciones de cuatro y seis bandas para los seis tamaños de áreas de entrenamiento, tanto para MLC como para SVM (Tabla 4). Similares resultados reportaron Huang *et al.* (2002), con un aumento significativo en la precisión global para los dos algoritmos al incluir todas las bandas reflexivas de Landsat TM. Por otro lado, la precisión lograda clasificando con cuatro y seis bandas no reveló diferencias significativas, con excepción de MLC para t5 y SVM para t50, lo que indica que la banda 7 es la que aporta la información adicional de mayor utilidad para la dis-

Tabla 3. Precisión global (%) de las clasificaciones realizadas con MLC y SVM sobre distintos conjuntos de bandas y diferentes tamaños de áreas de entrenamiento y el valor de Chi-cuadrado de la prueba de McNemar utilizada para su comparación. Las diferencias significativas se indican como ** $P < 0,01$; *** $P < 0,001$. 3B: tres bandas, 4B: cuatro bandas, 6B: seis bandas

Número de bandas	Set de entrenamiento	MLC	SVM	Chi-cuadrado
3B	t2,5	87,78	85,46	9,8**
	t5	83,40	82,96	0,1
	t10	84,21	87,09	11,3***
	t30	84,15	87,22	10,1**
	t50	84,08	87,34	11,4***
	t70	84,65	87,59	9,6**
4B	t2,5	89,54	86,47	15,3***
	t5	87,53	84,40	9,4**
	t10	88,72	88,53	0,1
	t30	88,28	89,66	3,0
	t50	89,35	90,04	0,9
	t70	89,35	89,66	0,2
6B	t2,5	89,47	86,53	19,5***
	t5	89,16	84,52	21,1***
	t10	89,35	88,35	2,0
	t30	88,85	89,35	0,3
	t50	90,04	89,16	1,2
	t70	89,97	89,53	0,3

criminación de las cubiertas de suelo de interés, respecto de las bandas 1 y 2. El análisis de las firmas espectrales de las clases explica este resultado, ya que las diferencias entre los tipos de cubierta discriminados son mayores en la banda 7 que en las bandas 1 y 2 (Figura 2). Por ello, la combinación de cuatro bandas (3457) sería la más adecuada para la identificación y mapeo de cubiertas de suelo en el área de estudio, al proveer la mayor precisión con el

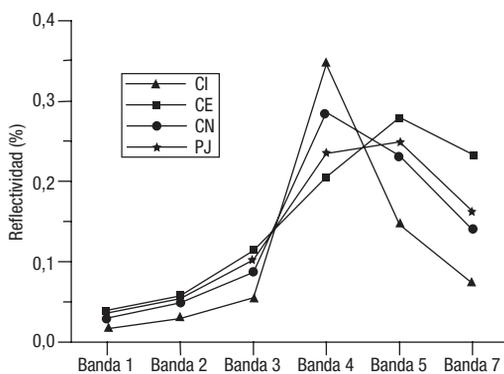


Figura 2. Firmas espectrales de las cubiertas de suelo de la cuenca baja del Arroyo del Azul correspondientes a la imagen Landsat TM 225/85 del 18/10/2009.

menor número de bandas posibles y así evitar el mayor volumen de cálculo que implica el uso de mas bandas, sin que ello mejore la discriminación de cubiertas. Al respecto, otros trabajos también utilizaron información proveniente de estas bandas para la discriminación de cubiertas de suelo (Johansen y Phinn, 2006; Voguelmann *et al.*, 1998) y tipos de prácticas agrícolas (van Deventer *et al.*, 1997), reconociendo así su utilidad para esta tarea.

Huang *et al.* (2002) sugieren que con un menor número de variables (bandas), las SVM pueden ser menos exitosas al intentar transformar las superficies de separación complejas del espacio vectorial de dimensiones original a una superficie lineal en el espacio transformado. Sin embargo, la mejora significativa en la precisión obtenida al incluir una sola banda adicional (banda 7) indicaría la importancia de la información contenida en las bandas incluidas en el análisis, más allá del número de variables en sí mismo. Este incremento en la precisión al incluir la banda 7 reafirma la utilidad de la inclusión de las bandas del infrarrojo medio para la discriminación de cubiertas de suelo, al igual que lo reportado por Thenkabail *et al.* (2003) y van Aardt y Wynne (2001).

Tabla 4. Valores de Chi-cuadrado de la prueba de McNemar resultantes de las comparaciones de clasificaciones realizadas con distintos conjuntos de bandas. Las diferencias significativas se indican como: * $P < 0,05$; ** $P < 0,01$; *** $P < 0,001$

		MLC		SVM	
		4B	6B	4B	6B
3B	t2,5	13,5***	6,7**	4,0*	4,7*
	t5	36,3***	55,7***	10,8**	12,3***
	t10	43,9***	51,7***	10,8**	8,7**
	t30	44,6***	46,5***	22,7***	15,6***
	t50	63,0***	70,0***	27,6***	8,9**
	t70	50,7***	57,8***	14,9***	13,9***
4B	t2,5		0,0		0,0
	t5		9,4**		0,3
	t10		2,0		0,3
	t30		1,2		2,8
	t50		2,7		5,2*
	t70		2,3		0,3

Efecto del tamaño del área de entrenamiento

Las clasificaciones de tres bandas no mostraron diferencias significativas con el aumento del tamaño del área de entrenamiento para MLC a partir de t5 (Tabla 5), donde las diferencias en la precisión global fueron menores a 1,3 % (Tabla 3). Esto coincide con lo reportado por Van Niel *et al.* (2005), en que la precisión alcanzó un valor relativamente estable a partir de aumentos en el tamaño del área de entrenamiento por encima de 3 a 5p (siendo p el número de bandas), que es considerablemente superado por t5. La clasificación con t2,5, en cambio, sí resultó significativamente diferente de las obtenidas con áreas

de entrenamiento de mayor tamaño, aunque ésta reportó mejores precisiones. Si bien este resultado no sería el esperado, otros autores también hallaron valores de precisión sin una tendencia clara al aumentar el volumen de datos de entrenamiento clasificando con MLC (ver Huang *et al.*, 2002).

En las clasificaciones de cuatro bandas, los resultados no muestran una tendencia clara entre el volumen de datos de entrenamiento y la precisión para MLC, mientras que las clasificaciones de seis bandas parecen compensar estas diferencias ya que, en general, no hay variación significativa en las precisiones (Tabla 5). Esto podría indicar que se había alcanzado el valor de precisión estable obtenido por Van Niel *et al.* (2005). Sin

Tabla 5. Valores de Chi-cuadrado de la prueba de McNemar resultantes de las comparaciones de clasificaciones realizadas con distintos tamaños de áreas de entrenamiento. Las diferencias significativas se indican como: * $P < 0,05$; ** $P < 0,01$; *** $P < 0,001$

		3B		4B		6B										
		t5	t10	t30	t50	t70	t5	t10	t30	t50	t70	t5	t10	t30	t50	t70
MLC	t2,5	25,0***	20,7***	20,5***	22,5***	16,2***	8,1**	1,4	4,0*	0,1	0,1	0,2	0,0	0,6	0,5	0,5
	t5		0,9	1,2	0,9	2,8		3,0	1,8	8,8**	7,9**		0,1	0,3	2,5	2,2
	t10			0,0	0,1	0,6			0,6	1,3	1,2			0,7	1,3	1,1
	t30				0,0	1,8				8,3**	6,4*				7,1**	6,8**
	t50					3,5					0,0					0,1
SVM	t2,5	10,1**	6,0*	14,5***	14,5***	23,1***	9,6**	7,4**	28,0***	30,9***	27,4***	8,8**	7,7**	27,0***	22,1***	27,4***
	t5		23,7***	25,7***	30,3***	32,2***		29,8***	44,7***	50,6***	43,6***		23,4***	38,3***	36,0***	40,0***
	t10			0,1	0,2	0,7			4,2*	6,6*	4,2*			4,1*	2,9	5,1*
	t30				0,1	1,8				1,4	0,0				0,8	0,5
	t50					0,9					1,3					0,2

embargo, las mejoras en la precisión al incrementar el tamaño de muestra de t30 a t50 y t70 sí fueron significativas, revelando la posibilidad de obtener aumentos de importancia en la precisión aún para conjuntos de entrenamiento de 50p y 75p por clase, que es lo que representa t50 para las clasificaciones de seis y cuatro bandas respectivamente.

El efecto del tamaño del área de entrenamiento en las clasificaciones con MLC ha sido estudiado por otros autores y los resultados son disímiles. Waske y Benediktsson (2007) obtuvieron un aumento en la precisión al incrementar el volumen de datos de entrenamiento, clasificando las seis bandas reflexivas de Landsat TM (con mejoras en la precisión aún para muestras de entrenamiento correspondientes a 25p y 50p por clase). Oommen *et al.* (2008) obtuvieron un valor estable o decreciente en la precisión al aumentar el tamaño del área de entrenamiento, mientras que Huang *et al.* (2002) no observaron una tendencia clara entre la precisión y el tamaño del área de entrenamiento.

En cuanto a SVM, las clasificaciones con t2,5 y t5 para las tres combinaciones de bandas utilizadas alcanzaron precisiones significativamente menores que con las áreas de entrenamiento de mayor volumen. Este resultado también se observó para t10 en las clasificaciones de cuatro y seis bandas, con excepción de t50 para 6B. Esto se podría explicar porque las muestras más grandes (t30, t50 y t70) contienen más píxeles situados en el límite de clases, siendo éstos los que determinan el hiperplano óptimo de separación entre las mismas (Foody y Mathur, 2004; Huang *et al.*, 2002). Sin embargo, el hecho de que no se verifique esta diferencia en las clasificaciones con t10 y tres bandas sugiere que la información adicional contenida en las combinaciones de cuatro y seis bandas está influenciando este resultado.

Otros autores también reportaron una estabilización de la precisión al emplear volúmenes de datos crecientes para entrenar las SVM en la clasificación de las bandas reflexivas de una imagen Landsat TM para discriminar clases litológicas (Oommen *et al.*, 2008) y cubiertas de suelo (Waske y Benediktsson, 2007). En cambio, Huang *et al.* (2002) obtuvieron valores crecientes de precisión frente al aumento del tamaño del área de entrenamiento.

A pesar de la menor precisión obtenida con los volúmenes de entrenamiento mas pequeños, la exactitud obtenida para todas las combinaciones de bandas fue muy buena, al igual que lo reportado en numerosos estudios que utilizan SVM entrenadas con volúmenes menores al valor de 30p por clase que recomienda Mather (2004) (Be-

lousov *et al.*, 2002; Foody y Mathur, 2004; 2006; Foody *et al.*, 2006). Los buenos resultados obtenidos con ambos clasificadores indican la posibilidad de discriminar cubiertas de suelo en forma precisa aún con volúmenes de datos de entrenamiento relativamente pequeños, siendo esto de gran interés ya que muchas veces la toma de datos en campo requiere de la disponibilidad de recursos y puede presentar dificultades de tipo logístico.

Las diferencias no significativas entre las clasificaciones entrenadas con t50 y t70 para MLC y que se hace extensiva a t30 para SVM, sugieren un límite en la utilidad de la información aportada por un incremento en la cantidad de datos de entrenamiento.

Efecto del algoritmo

Cuando la clasificación se realizó con el set de tres bandas, las SVM tuvieron un desempeño significativamente mejor que MLC para los tamaños de áreas de entrenamiento a partir de t10, con incrementos en las precisiones globales del orden del 2,5 y 3,5 % (Tabla 3). Con t2,5, MLC mostró mejor desempeño, mientras que con t5 no se encontraron diferencias significativas entre ambos clasificadores. En las clasificaciones con cuatro y seis bandas, las diferencias se acentuaron a favor de MLC para t2,5 y t5, con incrementos significativos de precisión, mayores a 3 %. En cambio, las diferencias de precisión no fueron significativas (<1 %) a partir de t10. De manera similar, Hermes *et al.* (1999) obtuvieron este mismo margen de diferencia entre clasificaciones realizadas con SVM y MLC sobre una imagen Landsat, entrenando con un volumen de datos mayor a 2200 píxeles. Estas diferencias no significativas sugieren que los tamaños de áreas de entrenamiento a partir de t10, en conjunción con la regiones del espectro comprendidas por los datos de entrenamiento cuando se incluyeron cuatro y seis bandas, satisfacen los requerimientos necesarios para entrenar ambos algoritmos, es decir, la caracterización de la función de probabilidad de cada clase que utiliza MLC y los píxeles de borde entre categorías que emplean las SVM para determinar el hiperplano óptimo de separación. Contrariamente, en Huang *et al.* (2002) el mejor desempeño de SVM sobre MLC aumentó al incluir un mayor número de bandas, independientemente del tamaño del área de entrenamiento utilizado, mientras que Oommen *et al.* (2008) reportaron un mejor desempeño de SVM sobre MLC utilizando el mismo set de bandas que en este trabajo.

Por otro lado, la consideración de la precisión a nivel de clases puede mostrar diferencias entre los algoritmos y, de esta forma, influenciar la selección de un clasificador u otro, en función de los propósitos del usuario. A modo de ejemplo, si se comparan las matrices de confusión de ambos algoritmos, realizadas a partir de cuatro bandas y el set de entrenamiento t70 (Tabla 6), se puede observar que MLC identifica con mayor exactitud que SVM las clases cultivo invernadero (CI) y pajonal (PJ), con diferencias de PP de $\approx 14\%$ y 22% respectivamente, aunque la correspondencia del mapa con la realidad es menor con el primer clasificador, siendo las diferencias de PU de $\approx 6\%$ y 13% respectivamente. Por ello, si se tuviera especial interés en el relevamiento de la superficie de cultivos invernaderos, se podría optar por el clasificador de máxima probabilidad, aunque a nivel global las diferencias de precisión no sean significativas.

Desempeño de la combinación de bandas del infrarrojo

Las precisiones obtenidas con la combinación de bandas infrarrojas estuvieron entre 83 y 89 % para ambos clasificadores (Tabla 7), indicando el potencial de esta combinación para discriminar cubiertas de suelo a partir de clasificaciones digitales. A nivel de algoritmos, SVM mostró mejores resultados que MLC en la mayoría de los casos, con diferencias en la precisión global entre 4 y 5,5 %; mientras que las diferencias no fueron significativas para los conjuntos de entrenamiento más pequeños (Tabla 7). El comportamiento de ambos clasificadores presentó la misma tendencia que para las combinaciones de bandas tradicionales: MLC mostró precisiones del productor y del usuario altas para todas las clases, excepto para pajonal donde PU fue menor al 50 %, mientras que SVM también presentó valores altos de PP y PU para todas las clases, excepto para pajonal, donde la detección fue sólo del 55 % de la superficie real (Tabla 6).

Al comparar las clasificaciones infrarrojas con las de tres y cuatro bandas, MLC no mostró diferencias significativas con las clasificaciones de tres bandas, mientras que cuando se incluyó la banda 3 (R), la precisión global fue hasta 5,5 % mayor. Por el contrario, el desempeño de las SVM fue significativamente mejor para la combinación infrarroja que para la de tres bandas tradicional, en la mayoría de los casos; mientras que no hubo diferencias significativas entre las clasificaciones 457 y las de cuatro bandas, con ex-

cepción de t5 (Tabla 7). Estos resultados demuestran que el uso de un bajo número de variables (bandas) no es limitante para que SVM establezca la superficie de separación en el espacio transformado, como sugieren Huang *et al.* (2002), sino que es más importante la información que aportan las bandas. Por otro lado, los valores de precisión obtenidos con las bandas infrarrojas, comparables a las combinaciones de uso tradicional, ponen en evidencia la capacidad de discriminar cubiertas de suelo a partir de la respuesta espectral debida a la estructura celular y contenido de humedad de la hoja (Infrarrojo cercano y medio) (Chuvieco, 2002). Así, se demuestra que esta combinación no sólo es útil para identificar áreas quemadas y humedales (Castaneda *et al.*, 2005; Dorrego *et al.*, 2009), sino también, cubiertas vegetales.

Conclusiones

Tanto el algoritmo de máxima probabilidad como las máquinas de vectores soporte tuvieron un buen desempeño para la discriminación de cubiertas de suelo en la zona llana de la cuenca del Arroyo del Azul a partir de una imagen Landsat TM, alcanzando precisiones globales mayores o iguales a 83 %.

La combinación que incluyó las bandas del rojo, infrarrojo cercano y las dos bandas del infrarrojo medio (3457) resultó ser la más adecuada al optimizar la relación entre el número de bandas utilizado y la precisión global obtenida, siendo ésta semejante para ambos clasificadores. La inclusión de la banda 7 aumentó en forma significativa la precisión, respecto de la combinación 345, mientras que la incorporación de las bandas 1 (azul) y 2 (verde), no aportó información adicional significativa para la identificación de las clases de interés.

La combinación de bandas infrarrojas (457) demostró una utilidad igual o superior que las combinaciones de bandas tradicionalmente empleadas para discriminar cubiertas de suelo, constituyendo así una alternativa válida para su uso en clasificaciones digitales que persigan esta finalidad.

El efecto del tamaño del área de entrenamiento fue diferente para los dos clasificadores y estuvo relacionado con el número de bandas incluido. Las máquinas de vectores soporte tuvieron mejores desempeños con tamaños de áreas de entrenamiento mayores para todas las combinaciones de bandas. Con MLC, en cambio, los resultados no mostraron una tendencia clara,

Tabla 6. Matrices de confusión para clasificaciones con tres combinaciones de bandas utilizando MLC y SVM entrenadas con t70 (3B = tres bandas, 4B = cuatro bandas y 6B = seis bandas). PG: Precisión global, PP: precisión del productor, PU: precisión del usuario

3B-MLC	Verdad de campo				Σ	PU (%)
	CE	CI	CN	PJ		
CE	197	0	5	4	206	95,6
CI	0	175	23	0	198	88,4
CN	2	7	831	27	867	95,5
PJ	46	0	131	148	325	45,5
Σ	245	182	990	179	1.596	
PP (%)	80,4	96,1	83,9	82,7		

PG: 84,65%

4B-MLC	Verdad de campo				Σ	PU (%)
	CE	CI	CN	PJ		
CE	207	0	10	3	220	94,1
CI	0	175	15	0	190	92,1
CN	8	7	895	27	937	95,5
PJ	30	0	70	149	249	59,8
Σ	245	182	990	179	1.596	
PP (%)	84,5	96,1	90,4	83,2		

PG: 89,35%

6B-MLC	Verdad de campo				Σ	PU (%)
	CE	CI	CN	PJ		
CE	220	0	7	3	230	95,6
CI	0	171	12	0	183	93,4
CN	4	9	898	29	940	95,5
PJ	21	2	73	147	243	60,5
Σ	245	182	990	179	1.596	
PP (%)	89,8	94,0	90,7	82,1		

PG: 89,97%

457-MLC	Verdad de campo				Σ	PU (%)
	CE	CI	CN	PJ		
CE	211	0	8	2	221	95,5
CI	0	171	17	0	188	91,0
CN	8	11	822	24	865	95,0
PJ	26	0	143	153	322	47,5
Σ	245	182	990	179	1.596	
PP (%)	86,1	94,0	83,0	85,5		

PG: 85,02%

3B-SVM	Verdad de campo				Σ	PU (%)
	CE	CI	CN	PJ		
CE	195	0	3	8	206	94,7
CI	0	161	2	0	163	98,8
CN	20	21	963	92	1.096	87,9
PJ	30	0	22	79	131	60,3
Σ	245	182	990	179	1.596	
PP (%)	79,6	88,5	97,3	44,1		

PG: 87,59%

C: 16, γ : 1

4B-SVM	Verdad de campo				Σ	PU (%)
	CE	CI	CN	PJ		
CE	209	0	5	3	217	96,3
CI	0	149	3	0	152	98,0
CN	15	33	963	66	1.077	89,4
PJ	21	0	19	110	150	73,3
Σ	245	182	990	179	1.596	
PP (%)	85,3	81,9	97,3	61,5		

PG: 89,66%

C: 2, γ : 4

6B-SVM	Verdad de campo				Σ	PU (%)
	CE	CI	CN	PJ		
CE	207	0	5	3	214	96,3
CI	0	149	2	0	151	98,7
CN	18	33	963	66	1.079	89,2
PJ	20	0	20	110	150	73,3
Σ	245	182	990	179	1.596	
PP (%)	84,5	81,9	97,3	61,5		

PG: 89,54%

C: 4, γ : 2

457-SVM	Verdad de campo				Σ	PU (%)
	CE	CI	CN	PJ		
CE	211	0	2	3	216	97,7
CI	0	145	2	0	147	98,6
CN	25	37	966	77	1.105	87,4
PJ	9	0	20	99	128	77,3
Σ	245	182	990	179	1.596	
PP (%)	86,1	79,7	97,6	55,3		

PG: 89,03%

C:2, γ : 2

Tabla 7. Precisión global (%) de las clasificaciones 457 y valores de Chi-cuadrado de la prueba de McNemar resultantes de la comparación entre algoritmos para esta combinación y entre las clasificaciones 457 y las de tres y cuatro bandas. Las diferencias significativas se indican como * $P < 0,05$; ** $P < 0,01$; *** $P < 0,001$. 3B: tres bandas, 4B: cuatro bandas

Número de bandas	Set de entrenamiento	MLC	SVM	Chi-cuadrado				
				MLC-SVM	MLC-3B	MLC-4B	SVM-3B	SVM-4B
457	t2,5	87,84	86,47	2,8	0,0	10,6**	1,9	0,0
	t5	84,65	83,02	2,0	2,7	19,2***	0,0	9,7**
	t10	83,27	88,72	29,4***	2,0	58,7***	6,1*	0,1
	t30	84,46	88,97	21,2***	0,2	33,5***	7,4**	2,3
	t50	84,71	89,22	20,6***	1,0	47,2***	7,7**	2,6
	t70	85,02	89,03	17,5***	0,4	42,9***	4,4*	1,6

en concordancia con los resultados disímiles reportados por otros autores, y las precisiones obtenidas con el conjunto de entrenamiento de menor tamaño (t2,5) fueron mayores o iguales a las alcanzadas con los conjuntos de mayor tamaño. Esto indica que no se necesitan grandes volúmenes de datos de entrenamiento para obtener clasificaciones de buena precisión, sino que la información contenida brinde lo necesario al clasificador para discriminar las cubiertas de interés. La estabilización de la precisión obtenida para ambos clasificadores frente al aumento del tamaño del área de entrenamiento, indica una cota en la influencia que tiene este aspecto de la clasificación.

El desempeño de ambos algoritmos en la discriminación de cubiertas de suelo estuvo relacionado con la combinación de bandas y con el tamaño del área de entrenamiento. En general, MLC dio mejores precisiones que SVM para los sets de entrenamiento de menor tamaño. En los conjuntos restantes, por el contrario, las SVM mostraron un mejor desempeño que MLC para la combinación 345, mientras que al incorporar la banda 7, estas diferencias en la precisión global no resultaron significativas.

Este estudio comparativo constituye un aporte de valor para quienes tienen como objetivo la discriminación de cubiertas de suelo a partir de sensores remotos, debido a los diversos factores puestos en consideración en el mismo y por contar con un abundante volumen de datos de verdad de campo, lo que le otorga un grado de validez considerable a los resultados alcanzados. Los rangos de precisiones obtenidos, tanto a nivel global como de clase, para las distintas combinaciones de variables utilizadas en este estudio indica la importancia de analizar distintas alternativas al momento de discriminar cubiertas

de suelo mediante clasificación digital de imágenes satelitales. Asimismo, se recomienda el reporte de las alternativas analizadas en las publicaciones científicas ya que aportaría información de interés para otros estudios.

Agradecimientos

El presente trabajo fue parcialmente financiado con fondos otorgados por la Secretaría de Ciencia, Arte y Tecnología de la Universidad Nacional del Centro de la Provincia de Buenos Aires y la Comisión de Investigaciones Científicas de la provincia de Buenos Aires. Los autores agradecen a los técnicos del Instituto de Hidrología de Llanuras «Dr. Eduardo J. Usunoff», Enrique Queupán y Joaquín Rodríguez por su colaboración en los trabajos de campo.

Referencias

- AGRESTI, A. 2007. *An introduction to categorical data analysis*, segunda edición, New Jersey, Wiley-Interscience, 394 pags.
- ARGAÑARAZ, J. P. & ENTRAIGAS, I. 2010. Análisis de los tipos de cubiertas de suelo en la cuenca baja del Arroyo del Azul (Buenos Aires, Argentina) a partir de imágenes Landsat 5 TM. En: VARNI, M., ENTRAIGAS, I. & VIVES, L. (Eds.) *Hacia la gestión integral de los recursos hídricos en zonas de llanuras*. Tomo II, Mar del Plata, Editorial Martin, 623-630.
- BELOUSOV, A. I., VERZAKOV, S. A. & VON FRESSE, J. 2002. A flexible classification approach with optimal generalisation performance: support vector machines. *Chemometrics and Intelligent Laboratory Systems*. 64: 15-25.

- CASTANEDA, C., HERRERO, J. & CASTERAD, M. A. 2005. Landsat monitoring of playa-lakes in the Spanish Monegros desert. *Journal of Arid Environments*. 63: 497-516.
- CHANDER, G., MARKHAM, B. L. & BARSİ, J. A. 2007. Revised Landsat-5 Thematic Mapper radiometric calibration. *IEEE Geoscience and Remote Sensing Letters*. 4 (3): 490-494.
- CHEN, D. & STOW, D. 2002. The effect of training strategies on supervised classification at different spatial resolutions. *Photogrammetric Engineering & Remote Sensing*. 68 (11): 1155-1161.
- CHUVIECO, E. 2002. *Teledetección ambiental*, Barcelona, Ariel, 586 pags.
- CONGALTON, R. G. 1991. A review of assessing the accuracy of classifications of remote sensed data. *Remote Sensing of Environment*. 37: 35-46.
- DEMARÍA, M. R., AGUADO SUÁREZ, I. & STEINAKER, D. F. 2008. Reemplazo y fragmentación de pastizales pampeanos semiáridos en San Luis, Argentina. *Ecología Austral*. 18: 55-70.
- DIMITRIADOU, E., HORNIK, K., LEISCH, F., MEYER, D. & WEINGESSEL, A. 2010. e1071: Misc Functions of the Department of Statistics (e1071), TU Wien. R package version 1.5-24. <http://CRAN.R-project.org/package=e1071>
- DORREGO, X., ALVAREZ, G., RECONDO, C., CABO, C., MARTINEZ, S. & RAMIL, P. 2009. Cartografía histórica de zonas quemadas en Galicia mediante el empleo de la teledetección. En: MONTESINOS ARANDA, S. & FERNANDEZ FORNIOS, L. (Eds.). *Teledetección: Agua y desarrollo sostenible*. XIII Congreso de la Asociación Española de Teledetección. 285-288.
- FOODY, G. M. 2004. Thematic map comparison: evaluating the statistical significance of differences in classification accuracy. *Photogrammetric Engineering & Remote Sensing*. 70 (5): 627-633.
- FOODY, G. M. & MATHUR, A. 2004. A relative evaluation of multiclass image classification by support vector machines. *IEEE Transactions on Geoscience and Remote Sensing*. 42 (6): 1335-1343.
- FOODY, G. M. & MATHUR, A. 2006. The use of small training sets containing mixed pixels for accurate hard image classification: training on mixed spectral responses for classification by a SVM. *Remote Sensing of Environment*. 103: 179-189.
- FOODY, G. M., MATHUR, A., SANCHEZ-HERNANDEZ, C. & BOYD, D. S. 2006. Training set size requirements for the classification of a specific class. *Remote Sensing of Environment*. 104: 1-14.
- GUERSCHMAN, J. P., PARUELO, J. M., DI BELLA, C., GIALLORENZI, M. C. & PACIN, F. 2003. Land cover classification in the Argentine Pampas using multi-temporal Landsat TM data. *Int. J. Remote Sensing*. 24 (17): 3381-3402.
- HALL, F. G., TOWNSHEND, J. R. & ENGMAN, E. T. 1995. Status of remote sensing algorithms for estimation of land surface state parameters. *Remote Sensing of Environment*. 51: 138-156.
- HERMES, L., FRIEAUFF, D., PUZICHA, J. & BUHMANN, J. M. 1999. Support vector machines for land usage classification in Landsat TM imagery. *Proc. IGARSS*, 1: 348-350.
- HERRERA, L. P., GÓMEZ HERMIDA, V., MARTÍNEZ, G. A., LATERRA, P. & MACEIRA, N. 2005. Remote sensing assessment of *Paspalum quadrifarium* grasslands in the Flooding Pampa, Argentina. *Rangeland Ecol. Manage.* 58: 406-416.
- HERRERA, L. P., LATERRA, P., MACEIRA, N. O., ZELAYA, K. D. & MARTÍNEZ, G. A. 2009. Fragmentation status of tall-tussock grassland relicts in the Flooding Pampa, Argentina. *Rangeland Ecol. Manage.* 62: 73-82.
- HUANG, C., DAVIS, L. S. & TOWNSHEND, J. R. G. 2002. An assessment of support vector machines for land cover classification. *Int. J. Remote Sensing*. 23 (4): 725-749.
- HSU, C. W., CHANG, C. C. & LIN, C. J. 2009. A practical guide to support vector classification. National Taiwan University. Disponible en <http://www.csie.ntu.edu.tw/~cjlin>. Última actualización: 19 de Mayo de 2009.
- HSU, C. W. & LIN, C. J. 2002. A comparison of methods for multiclass support vector machines. *IEEE Transactions on Neural Networks*. 13 (2): 415-425.
- INSAUSTI, P., CHANETON, E. J. & GRIMOLDI, A. A. 2005. Las inundaciones modifican la estructura y dinámica de la vegetación en los pastizales de la Pampa Deprimida. En: OESTERHELD, M., AGUIAR, M. R., GHERSA, C. M. & PARUELO, J. M. (Eds.). *La heterogeneidad de la vegetación de los agroecosistemas*, Buenos Aires, Editorial de la Facultad de Agronomía, Universidad de Buenos Aires, 253-269.
- JENSEN, J. R. 1996. *Introductory digital image processing*, Segunda edición, New Jersey, Prentice Hall, 318 pags.
- JOHANSEN, K. & PHINN, S. 2006. Mapping structural parameters and species composition of riparian vegetation using IKONOS and Landsat ETM+ data in australian tropical savannahs. *Photogrammetric Engineering & Remote Sensing*. 72 (1): 71-80.
- LATERRA, P., VIGNOLIO, O. R., HIDALGO, L. G., FERNÁNDEZ, O. N., CAHUÉPÉ, M. A. & MACEIRA, N. O. 1998. Dinámica de pajonales de paja colorada (*Paspalum* spp.) manejados con fuego y pastoreo en la Pampa Deprimida Argentina. *Ecotrópicos*. 11 (2): 141-149.
- LEÓN, R. J. C., BURKART, S. E. & MOVIA, C. P. 1979. *Relevamiento fitosociológico del pastizal del norte de la Depresión del Salado (Partidos*

- de Magdalena y Brandsen, Pcia. de Bs. As.). Vegetación de la República Argentina, Serie Fito-geográfica 17. Buenos Aires, INTA, 90 pags.
- MATHER, P. M. 2004. *Computer processing of remotely-sensed images: an introduction*, Tercera edición, Chichester, John Wiley & Sons, 442 pags.
- MATTEUCCI, S. D. 1979. *Análisis regional de la vegetación y el ambiente del Estado de Falcón. I. Metodología*, Falcón, Publicaciones del Departamento de Investigación, Instituto Universitario de Tecnología de Coro, Venezuela, 145 pags.
- MATTEUCCI, S. D. 1998. El análisis regional desde la ecología. En: MATTEUCCI, S. D. & BUZAI, G. D. (Eds.). *Sistemas ambientales complejos: herramientas de análisis espacial*, Buenos Aires, Eudeba, 117-150.
- MELGANI, F. & BRUZZONE, L. 2004. Classification of hyperspectral remote sensing images with support vector machines. *IEEE Transactions on Geoscience and Remote Sensing*. 42 (8): 1778-1790.
- MUCHONEY, D. M. & STRAHLER, A. H. 2002. Pixel- and site-based calibration and validation methods for evaluating supervised classification of remotely sensed data. *Remote Sensing of Environment*. 81: 290-299.
- OOMMEN, T., MISRA, D., TWARAKAVI, N. K. C., PRAKASH, A., SAHOO, B. & BANDOPADHYAY, S. 2008. An objective analysis of support vector machine based classification for remote sensing. *Math. Geosci.* 40: 409-424.
- PAL, M. & MATHER, P. M. 2003. An assessment of the effectiveness of decision tree methods for land cover classification. *Remote Sensing of Environment*. 86: 554-565.
- PONTIUS, R. G. Jr. & MILLONES, M. 2011. Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment. *International Journal of Remote Sensing*. En prensa.
- R DEVELOPMENT CORE TEAM. 2010. R: *A language and environment for statistical computing*. R Foundation for Statistical Computing, Vienna, Austria. ISBN 3-900051-07-0, URL <http://www.R-project.org>.
- SALA, J. M., KRUSE, E. & AGUGLINO, R. 1987. *Investigación hidrológica de la Cuenca del Arroyo Azul, Prov. de Bs. As.*, Informe 37, La Plata, CIC, 235 pags.
- SORIANO, A., LEÓN, R. J. C., SALA, O. E., LAVADO, R. S., DEREGIBUS, V. S., CAHUÉPÉ, M. A., SCAGLIA, O. A., VELÁZQUEZ, C. A. & LEMCOFF, J. F. 1992. Río de la Plata grasslands. En: COUPLAND, R. T. (Ed.). *Natural grasslands: introduction and western hemisphere. Ecosystems of the World 8A*, Netherlands, Elsevier, 367-407.
- THENKABAIL, P. S., HALL, J., LIN, T., ASHTON, M. S., HARRIS, D. & ENCLONA, E. A. 2003. Detecting floristic structure and pattern across topographic and moisture gradients in a mixed species Central African forest using IKONOS and Landsat-7 ETM+ images. *International Journal of Applied Earth Observation and Geoinformation*. 4: 255-270.
- USUNOFF, E., VARNI, M., WEINZETTEL, P. & RIVAS, R. 1999. Hidrogeología de grandes llanuras: la pampa húmeda argentina. *Boletín Geológico y Minero*. 110 (4): 391-406.
- VAN AARDT, J. A. N. & WYNNE, R. H. 2001. Spectral separability among six southern tree species. *Photogrammetric Engineering & Remote Sensing*. 67 (12): 1367-1375.
- VAN DEVENTER, A. P., WARD, A. D., GOWDA, P. H. & LYON, J. G. 1997. Using thematic mapper data to identify contrasting soil plains and tillage practices. *Photogrammetric Engineering & Remote Sensing*. 63 (1): 87-93.
- VAN NIEL, T. G., McVICAR, T. R. & DATT, B. 2005. On the relationship between training sample size and data dimensionality: Monte Carlo analysis of broadband multi-temporal classification. *Remote Sensing of Environment*. 98: 468-480.
- VERVOORST, F. B. 1967. *Las comunidades vegetales de la Depresión del Salado (Prov. de Bs. As.). La vegetación de la República Argentina*, Serie Fito-geográfica N° 7. Buenos Aires, INTA, 262 pags.
- VOGELMANN, J. E., SOHL, T. L., CAMPBELL, P. V. & SHAW, D. M. 1998. Regional land cover characterization using Landsat Thematic Mapper data and ancillary data sources. *Environmental Monitoring and Assessment*. 51: 415-428.
- WASKE, B. & BENEDIKTSSON, J. A. 2007. Fusion of support vector machines for classification of multisensor data. *IEEE Transactions on Geoscience and Remote Sensing*. 45 (12): 3858-3866.
- WOLTER, P. T., MLADENOFF, D. J., HOST, G. E. & CROW, T. R. 1995. Improved forest classification in the Northern lake states using multi-temporal Landsat imagery. *Photogrammetric Engineering & Remote Sensing*. 61 (9): 1129-1143.