

Discriminación del sistema de labranza mediante el uso de imágenes Landsat en el Norte de Buenos Aires

Caride, Constanza^a; Paruelo, José María^a

^(a) Laboratorio de Análisis Regional y Teledetección. IFEVA Facultad de Agronomía UBA-CONICET
Av. San Martín 4453, C1417DSE, Buenos Aires, ARGENTINA

RESUMEN

Cuantificar la superficie bajo diferentes sistemas de labranza es el primer paso en la evaluación de los impactos de la agricultura sobre el ambiente. A partir de imágenes Landsat se identificó la superficie dedicada a maíz y soja (campaña 04-05). En esta área se estimó, mediante clasificaciones supervisadas con diferentes bandas, la superficie bajo siembra directa (SD) y labranza convencional (LC). Presentaron precisiones significativamente mayores las clasificaciones que incluyeron la banda del infrarrojo medio (B5). Para la zona se estimó una superficie bajo SD del 69% y bajo LC del 31%.

Palabras claves: evaluación de clasificaciones, agricultura, servicios ecosistémicos.

ABSTRACT

To quantify the area under different tillage practices is a first step in the evaluation of the agriculture impact on the ecosystem. Landsat images were used to identify the area cultivated with maize and soybean (04-05 campaign). Supervised classifications were made on this area with different band combinations to estimate the surface under no-till (NT) and conventional tillage (CT). Supervised classifications including the mid infrared band (B5) provided significant higher precisions. A 69% of the total area was classified as NT and the other 31% as CT.

Keywords: classification evaluation, agriculture, ecosystem services

Introducción

Uno de los mayores efectos de la agricultura sobre los ecosistemas de pastizal es la liberación a la atmósfera de carbono que formaba parte de la materia orgánica (MO) (Burke et al., 1989). La cantidad liberada depende de múltiples factores, entre ellos del tipo de labranza. Las labores de preparación del suelo afectan de forma directa el balance de carbono de los cultivos. Los sistemas de labranza mínima («siembra directa», SD), por ejemplo, reducen las emisiones de CO₂ atmosférico respecto de la labranza convencional al reducir la tasa de descomposición de la materia orgánica (Kern y Jonson, 1993; Lyon et al., 1996; West y Post,

2002; Steinbach y Alvarez, 2005). Por otra parte el sistema de labranza afectará también la magnitud de las pérdidas por erosión hídrica y/o eólica. El sistema de siembra directa, al dejar mayor proporción del suelo cubierto con rastrojo que la labranza convencional, actuaría disminuyendo las pérdidas de suelo respecto a otros sistemas (McCool et al.1997; Clérico y García Préchac 2001; Fu et al. 2006; Mickelson et al. 2001). Los efectos positivos de la SD sobre la infiltración de agua, uno de los factores que mediaría el efecto de la SD sobre la tasa de erosión, no serían, sin embargo, generalizables debido a cambios en la estructura del suelo (Sasal et al. 2006).

La Pampa Ondulada es una de las regiones de Argentina con mayor tradición agrícola (Soriano et al., 1991; Viglizzo et al., 2001). Los suelos de esta región han sufrido una importante reducción del contenido de MO y un aumento de la erosión hídrica (Viglizzo, 1994). La SD comienza a difundirse en la década del 70 como una alternativa para el control de la degradación de los suelos. Desde entonces la superficie sometida a este tipo de labranza aumentó lentamente hasta principios de la década de los '90. A partir de ese momento y por factores principalmente económicos, la SD experimentó una fuerte expansión. Las estimaciones disponibles indican que en la campaña 2004/2005, esta ocupa una superficie de 19.460.000 has en todo el país (AAPRESID, 2006).

¿Cuál es la superficie sometida a distintos tipos de labranza? ¿Cuál es el arreglo espacial de las áreas manejadas bajo LC y SD? En este trabajo evaluamos una alternativa metodológica basada en sensores remotos para la descripción cuantitativa de la superficie dedicada a distintos manejos.

La factibilidad de la discriminación de labores mediante el uso de sensores remotos hiper y multi espectrales ha sido documentada (Daughtry et al. 2004; Haché et al. 2007; Yang et al. 2003). Para su aplicación regional, varios trabajos han realizado clasificaciones del tipo de labranza con imágenes de los satélites Landsat comparando distintos métodos de clasificación y obteniendo resultados con diferentes grados de precisión (South 2004; Brickleyer, 2006). Sin embargo, además del algoritmo utilizado para realizar la clasificación, hay otros factores como el número y combinación de bandas que determinan su precisión pero que han sido menos considerados en la discriminación de sistemas de labranza con imágenes satelitales multiespectrales.

Los objetivos de este trabajo son entonces: 1) determinar cuáles son las bandas que mayor aporte hacen a la discriminación del tipo de labranza e identificar qué número y combinación de las mismas tienen mayor precisión, y 2) hacer una estimación espacialmente explícita de la superficie dedicada a la siembra directa en maíz y soja de la campaña 04/05.

Materiales y métodos

Área de estudio

El área de estudio está ubicada al Norte de la Provincia de Buenos Aires y se corresponde con la escena Landsat Path 226 Row 084 (Fig. 1). Esta ocupa parte de las eco-regiones denomi-

nadas Pampa Ondulada, Pampa Inundable y Pampa Interior (Soriano et al., 1991). Este área, perteneciente a la Región Pampeana, es una de las principales zonas de producción de granos del país debido a que sus suelos profundos y con altos contenidos de MO, además de un clima propicio, le brindan un alto potencial de rendimiento (Hall et al. 1992). En la actualidad la actividad predominante es la agricultura continua quedando solo con vegetación espontánea de pastizal las terrazas de ríos y arroyos y las áreas bajas inundables.




Fig 1. Área de estudio correspondiente a la escena Landsat 226-84 y eco-regiones presentes en la misma.

Imágenes y datos de campo

Las imágenes Landsat 5 TM fueron geométrica y radiométricamente corregidas obteniéndose información georreferenciada de reflectancia en superficie (la banda térmica no se utilizó en el análisis por su menor resolución espacial).

Se realizó para la campaña 04-05 una clasificación supervisada con 3 imágenes (25/09/04, 30/12/04 y 04/03/05), utilizando el algoritmo Maximum likelihood (Lillesand and Kiefer 1994). En ella se discriminaron los principales tipos de cobertura presentes en la zona (lagunas, ciudades, recursos forrajeros, trigo-soja2da, maíz y soja) mediante la metodología propuesta por Guerschman et al. (2003). La precisión total de la clasificación fue de 90,34%, y el estadístico Kappa de 0,87. Las precisiones del productor y usuario fueron 94.52-94.71 para soja y de 89.35-95.57 para maíz respectivamente. Estas precisiones son sumamente aceptables teniendo en cuenta el objetivo de la clasificación. A partir de esta clasificación se generó una máscara de todo lo que no fuera cultivo de verano de primera ocupación con el fin de aplicarla para el análisis de lotes aún no sembrados de maíz y soja. Para discriminar tipos de labranza se utilizó la imagen del 25/9. En esta fecha los cultivos aún no han emergido o aún no se han sembrado (el maíz en la zona se siembra a fines de septiem-

bre-principios de octubre y la soja de primera ocupación a fines de octubre-principios de noviembre). Los datos de campo fueron obtenidos mediante un relevamiento con GPS de la zona de estudio durante los meses de septiembre y octubre del 2004. En el relevamiento se obtuvo una muestra de sistemas de labranza de 327 unidades de las cuales el 72 % corresponden a SD y el 28% restante a LC. Las observaciones de campo se dividieron al azar para entrenar y evaluar el algoritmo en un 70% y 30% respectivamente. El procesamiento de las imágenes se realizó con ENVI 4.1 (Research Systems, Inc. Copyright © 2004).

Análisis de la información

Para identificar las bandas más asociadas a los tipos de labranza se realizó un Análisis de Componentes Principales (PCA), asumiéndose una distribución multinormal de las mismas. De los resultados de este análisis se tomaron, para utilizar en el estudio, las bandas que tenían mayor correlación con los primeros 4 autovectores.

Con las bandas seleccionadas mediante los PCAs se realizaron clasificaciones supervisadas – Maximum likelihood – de todas las combinaciones posibles de bandas. La precisión de las clasificaciones se estimó mediante una matriz de confusión (Congalton 1991) y el coeficiente Kappa (Cohen 1960). Debido a que las muestras para evaluar las clasificaciones eran las mismas, y por lo tanto no son independientes, se utilizó como test de significancia el test de aleatorización propuesto por Leeuw et al. (2006). Una vez seleccionada la clasificación que mejor precisión entregaba se procedió a calcular la superficie cubierta con cada una de las clases de labranzas y su intersección con cada uno de los cultivos relevados. Para el análisis de la información se utilizó el software R 2.4.1 (R development Core Team, Inc. Copyright © 2006).

Resultados y discusión

Selección de bandas

Las bandas que mayor correlación tuvieron con los primeros 4 autovectores fueron las correspondientes al rojo (B3), infrarrojo cercano (B4), e infrarrojo medio (B5 y B7). Esto se corresponde con las bandas utilizadas en la mayoría de los índices de cobertura de rastrojo encontrados en la bibliografía (McNairn y Protz, 1993; Birad et al., 1995; Qi et al., 2002; Bannari et al., 2000) donde las bandas del azul (B1) y el verde (B2) generalmente no son utilizadas.

La banda 5 fue la que hizo el mayor aporte a la discriminación en el primer PC (0.69) que explicó el 68% de la variabilidad total (Fig. 2).




Fig 2. Análisis de componentes principales. CP 1 vs. CP 4. En negro los lotes en convencional y en gris los lotes en directa.

De las clasificaciones realizadas todas las combinaciones de bandas tuvieron precisiones mayores al 85%. La combinación de bandas con mejor precisión (Precisión total + Coeficiente Kappa) incluyó las 4 bandas (4b) identificadas en el PCA (Tabla 1). La precisión de esta clasificación fue mayor que la correspondiente a aquella en donde se usaron todas las bandas (6b). Algunas clasificaciones con 2 y 3 bandas tuvieron mejor precisión que las obtenidas a partir de 6 bandas. Varios trabajos muestran que la mayor precisión no está necesariamente asociada a clasificaciones con el máximo número de bandas (Bruzzone & Serpico 2000; Murakami 2004; Haché et al. 2007). La remoción de alguna de las 4 bandas que generaron la mejor clasificación disminuyó la precisión en grados variables dependiendo de las bandas eliminadas. Se observó una mayor reducción de la precisión cuando la banda 5 no es utilizada (Tabla 1) Dentro de las combinaciones de tres bandas la que tuvo mayor precisión fue la combinación 3, 4 y 5 y de dos bandas la combinación 5 y 7 (Tabla 1).

Tabla 1. Valores de precisión total y Kappa para la combinación de las diferentes bandas.

Bandas	Precisión total (%)	Kappa coef
3y4	91.25	0.7759
3y5	95.96	0.8966
3y7	87.54	0.6851
4y5	97.64	0.9378
4y7	89.56	0.7447
5y7	97.64	0.9399
3,4y5	97.64	0.9384
3,4y7	91.25	0.7740
3,5y7	97.31	0.9299
4,5y7	97.31	0.9299
4b	97.98	0.9474
6b	96.63	0.9123

El test de aleatorización mostró que no hubo diferencias significativas entre las clasificaciones realizadas con 4 y 6 bandas (Tabla 2). La clasificación de mayor precisión (4b) no es significativamente diferente de las clasificaciones en que la banda 5 participa, ya sea junto a una o dos bandas más. (Tabla 2).

Varios trabajos señalan que los residuos y el suelo desnudo son espectralmente similares en las longitudes de onda del visible y el infrarrojo cercano lo que dificulta su discriminación en estos rangos. (Baird y Baret, 1997; Aase y Tanaka 1991). Daughtry 2006 señala que debido a esto se han hecho intentos para mejorar la estimación mediante la generación de índices que incorporan las bandas Landsat correspondientes al infrarrojo medio pero estos tienen poca correlación con el porcentaje de suelo cubierto por los residuos. Tanto el contenido de humedad como las características del suelo y el grado de descomposición de los rastrojos influyen en la discriminación del tipo de labranza

(Aase y Tanaka 1991; Nagler et al. 2000; Daughtry 2001).

Daughtry et al. 2004 señala que la presencia de agua disminuye la reflectancia en todas las longitudes de onda tanto de los residuos como de los suelos. Ellos también observaron que los cambios de reflectancia asociados al contenido de humedad de los suelos son menores en suelos oscuros que en suelos claros. Así, los residuos pueden ser más claros o más oscuros que los suelos dependiendo del tipo y contenido de humedad de cada uno. Aase y Tanaka 1991 estimando la cobertura de residuos sobre diferentes suelos concluyeron que la estimación es mejor en suelos oscuros o húmedos que en suelos claros o secos. Según Nagler et al. (2000), los residuos remanentes luego de la cosecha generalmente tienen mayor reflectancia que el suelo pero a medida que estos se humedecen y descomponen su reflectancia puede pasar a ser menor.

Tabla 2. Significancia del test de aleatorización (%), comparando las clasificaciones realizadas con diferente combinación de bandas

Bandas	3y4	3y5	3y7	4y5	4y7	5y7	3,4y5	3,4y7	3,5y7	4,5y7	4b	6b
3y4	-	-	5	-	-	5	5	-	-	-	5	-
3y5		1	-	-	-	-	-	-	-	-	-	-
3y7			1	-	-	1	1	-	1	1	1	1
4y5				5	-	-	-	5	-	-	-	-
4y7					5	-	-	-	5	5	5	5
5y7						5	-	5	-	-	-	-
3,4y5							5	-	-	-	-	-
3,4y7								5	-	-	5	-
3,5y7									5	-	-	-
4,5y7										5	-	-
4b											5	-
6b												5

Para la zona analizada se estima que el contenido de humedad en ese momento era bajo, al menos en superficie, debido a que no se registraron precipitaciones durante las dos semanas anteriores a la adquisición de la imagen (SAGPyA). Los suelos presentes en la zona son oscuros como consecuencia de su contenido de MO y los residuos evaluados tienen entre 4 y 6 meses desde la cosecha. Los valores de reflectancia promedio de los datos de campo utilizados muestran que los residuos tuvieron mayores valores que los suelos en todas las bandas analizadas, observándose la mayor diferencia en la banda 5.

La discriminación del sistema de labranza a partir de la diferencia de reflectancia en la banda 5 del sensor TM podría deberse entonces a las características de los suelos de la región y

a que, aún después de varios meses en el campo, la reflectancia de los rastrojos no disminuyó lo suficiente como para llegar a los valores similares a los del suelo. En suelos húmedos disminuirían las reflectancias de ambos pero sería necesario evaluar en que medida afecta esto la capacidad de discriminación.

Quantificación de la superficie bajo «siembra directa»

La clasificación de labranzas con mayor precisión (4 bandas - Tabla 1) indica que la superficie manejada bajo siembra directa fue, en la escena considerada, de 1.056.703 ha lo que representa un 69.57% del área analizada. El 30.43% restante (462.182 ha) por lo tanto se clasificó como manejada con labranza convencional (Fig. 3)




Fig 3. Clasificación supervisada –maximum likelihood– de sistemas de labranzas con la combinación 4b (Tabla 2). En negro los lotes bajo labranza convencional y en gris los lotes bajo siembra directa.

Al cruzar la clasificación de sistemas de labranza con la de tipos de cobertura, se observó que en las áreas dedicadas a soja la siembra directa ocupa un 72.54%. En el caso de maíz el área con SD es de 63.63%. Según estimaciones de la Secretaría de Agricultura, Ganadería, Pesca y Alimentación (SAGPyA), para toda la provincia de Buenos Aires la superficie de soja de primera ocupación bajo siembra directa esa campaña fue de 68.3% y de 53% para el maíz. Tanto la clasificación obtenida como las estimaciones de la SAGPyA concuerdan en que la soja tiene mayor porcentaje de su superficie bajo siembra directa que el maíz, pero la diferencia entre cultivos que resulta de la clasificación es menor. Esto podría deberse tanto a los errores en las metodologías de estimación como a la diferente resolución de análisis ya que el área estudiada representa solo una porción de la provincia.

La implementación de relevamientos de tipo de labranza mediante sensores remotos posibilita la realización de estimaciones objetivas y con un error estimable. Además, el hecho de que la información sea espacialmente explícita permite estudios de, por ejemplo, estructura del paisaje. La metodología empleada en este trabajo debe ser evaluada en años con diferentes condiciones ambientales para confirmar su utilidad como herramienta censal ya que, como se mencionó anteriormente, el contenido de humedad puede afectar la discriminación.

Conclusiones

En el presente trabajo se demostró la importancia de la banda 5 del sensor TM, correspondiente al infrarrojo medio para la discriminación del tipo de labranza en la zona. Su presencia en el análisis mejora la precisión de las clasificaciones de manera significativa con respecto a las que no la incluyen.

También se observó la viabilidad de realizar clasificaciones, mediante el uso de imágenes Landsat, del tipo de labranza a nivel regional en el norte de Buenos Aires. Los resultados de las clasificaciones fueron sumamente satisfactorios.

Agradecimientos

Los autores agradecen a Marcos Texeira por su colaboración en la realización del trabajo, a la CONAE quien proveyó las imágenes y a la Fundación YPF y el CONICET por la financiación otorgada. Agradecemos también la ayuda del Inter-American Institute for Global Change Research (IAI, CRN II 2031), apoyado por la the U.S. National Science Foundation (grant GEO-0452325).

Referencias

- AAPRESID 2006 <http://www.apresid.org.ar>
- Aase, J. K. & Tanaka, D. L. 1991. Reflectances from four wheat residue cover densities as influenced by three soil backgrounds. *Agron. J.* 83:753-757.
- Baird F. & Baret F. 1997. Crop residue estimation using multi band reflectance. *Remote Sensing of Environment*, 59: 530-536.
- Bannari, A., Haboudane, D., McNairn H. & Bonn F. 2000. Modified Soil Adjusted Crop Residue Index (MSACRI): A new index for mapping crop residue. *Geoscience and Remote Sensing Symposium, 2000. Proceedings. IGARSS 2000. IEEE 2000 International.* 2936-2938 vol.7
- Biard, F., Bannari, A. & Bonn, F., 1995. SACRI (Soil Adjusted Corn Residue Index): un indice utilisant le proche et le moyen infrarouge pour la détection des résidus de cultures de maïs. 17th Canadian Symposium on Remote Sensing. Canadian Remote Sensing Society, Ottawa, Canada, pp. 417–423.
- Bricklemyer, R. S.; Lawrence R. L., Miller P. R. & Battogtokh N. 2006. Predicting tillage practices and agricultural soil disturbance in north central Montana with Landsat imagery. *Agriculture, Ecosystems and Environment* 114, 210-216
- McNairn, H. & Protz, R., 1993. Mapping corn residue cover on agricultural fields in Oxford

- Bruzzone, L. & Serpico, S. B. 2000 A technique for feature selection in multiclass problems. *Int J Remote Sens* 21:549–563
- Burke, I.C., Yonker, C.M., Parton, W.J., Cole, C.V., Flach, K. & Schimel, D.S. 1989. Texture, climate and cultivation effects on soil organic matter content in US Grassland soils. *Soil Sci. Soc. Am. J.* 53: 800-805.
- Cohen, J. 1960. A Coefficient of Agreement for Nominal Scales. *Educational and Psychological Measurement*, Vol 20, Nro 1: 37-46
- Congalton, R., 1991. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sens. Environ.* 37, 35–46.
- Daughtry, C. S. T., 2001. Discriminating crop residues from soil by shortwave infrared reflectance. *Agron. J.* 93, 125–131.
- Daughtry, C. S. T., Doraiswamy, P. C., Hunt E. R. Jr., Stern A. J., McMurtrey III J. E & Prueger J. H. 2006. Remote sensing of crop residue cover and soil tillage intensity. *Soil & Tillage Research* Volume 91: 101-108
- Daughtry, C. S. T., Hunt, E. R. Jr. & McMurtrey III, J. E. 2004. Assessing crop residue cover using shortwave infrared reflectance. *Remote Sensing of Environment*, 90: 126 - 134.
- de Leeuw, J. Jia, H., Yang, L., Liu, X., Schmidt, K. & Skidmore, A. K., 2006. Comparing accuracy assessments to infer superiority of image classification methods. *International Journal of Remote Sensing*, 27, pp. 223-232.
- ENVI 4.1 Research Systems 2004 ENVI: The Environment for Visualizing Images. 4990 Pearl East Circle Boulder, CO 80301, USA <http://www.RSInc.com/envi>
- Gao, B. C. (1996). NDWI—a normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, 58, 257– 266.
- Guerschman, J. P., Paruelo, J. M., Di Bella, C. M., Giallorenzi, M. C. & Pacýn, F., 2003. Land cover classification in the Argentine Pampas using multi-temporal LANDSAT TM data. *Int. J. Remote Sens.* 24, 3381–3402.
- Haché C., Shibusawa S., Sasao A., Suhama T. & Sah B. P. 2007. Field-derived spectral characteristics to classify conventional and conservation agricultural practices. *Computers and electronics in Agriculture* 57: 47-61.
- Hall, A.J., Rebella, C.M., Ghera, C.M. & Culot, J.-Ph., 1992. Field crop systems of the Pampas. In: Pearson, C.J. (Ed.), *Ecosystems of the World, Field Crop Ecosystems*. Elsevier, Amsterdam, pp. 413–450.
- County, Ontario, using Thematic Mapper. *Canadian Journal of Remote Sensing* 19, 152–159.
- Murakami T. 2004. Seasonal variation in classification accuracy of forest-cover types examined by a single band or band combinations. *Eurasian J For Res* 9:211–215
- Nagler, P. L., Daughtry, C. S. T., & Goward, S. N. 2000. Plant litter and soil reflectance. *Remote Sensing of Environment*, 71(2), 207–215.
- Qi, J., Marsett, R., Heilman, P., Biedenbender, S., Moran, M.S., Goodrich, D.C. & Weltz, M., 2002. RANGES improves satellitebased information and land cover assessments in Southwest United States. *EOS Trans. Am. Geophys. Union* 83 (51), 601–606.
- R 2.4.1 Development Core Team 2006. 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>.
- SAGPyA 2007 <http://www.sagpya.gov.ar>
- Soriano, A., León, R.J.C., Sala, O.E., Lavado, R.S., Deregibus, V.A., Cauhepé, M.A., Scaglia, O.A., Velázquez, C.A. & Lemcoff, J.H. 1991. Rio de la Plata grasslands. In: Couplant, R.T. (Ed.), *Natural Grasslands, Ecosystems of the World*. Elsevier, Amsterdam, pp 367–407.
- South S.; Jianguo Q. & Lusch D. P. 2004. Optimal classification methods for mapping agricultural tillage practices. *Remote Sensing of Environment* 91: 90-97
- Viglizzo E. F., Pordomingo A. J., Castro M. G., Lértora F.A. & Bernardos J. N. 1994. Scale-dependent controls on ecological functions in agroecosystems of Argentina. *Agriculture, Ecosystems and Environment* 101: 39–51
- Viglizzo, E.F., Lértora, F.A., Pordomingo, A.J., Bernardos, J.N., Roberto, Z.E. & Del Valle, H., 2001. Ecological lessons and applications from one century of low external-input farming in the pampas of Argentina. *Agric. Ecosyst. Environ.* 81: 65–81.
- Yang C., Prasher S. O., Enright P., Madramootoo C., Burgess M., Goel P. K., & Callum I. 2003. Application of decision tree technology for image classification using RS data. *Agricultural Systems* 76; 1101–1117