

ANÁLISIS DE TEXTURA APLICADO A LA DETERMINACIÓN DEL USO DEL SUELO EMPLEANDO IMÁGENES SATELITALES LANDSAT 8 OLI. ESTUDIO DE CASO: PARTIDO DE ADOLFO ALSINA (ARGENTINA)

Fabián Marini

Instituto Nacional de Tecnología Agropecuaria - INTA. Agencia de Extensión Bahía Blanca de la Estación Experimental Bordenave. San Andrés 800 - Campus Universitario. Bahía Blanca, Buenos Aires, Argentina.

marini.fabian@inta.gob.ar

Resumen

Se aplicaron diferentes medidas de textura para determinar el uso del suelo en el partido de Adolfo Alsina (Buenos Aires, Argentina). Para ello, se realizó un estudio multitemporal empleando las bandas del rojo e infrarrojo cercano de imágenes satelitales Landsat 8 OLI. Se obtuvo la matriz de co-ocurrencia de niveles de grises (GLCM) considerando ocho medidas de textura y cuatro tamaños de ventanas de píxeles. Para discriminar cada categoría se emplearon los clasificadores Máxima Verosimilitud y Máquinas de Soporte Vectorial. Para evaluar la clasificación se empleó una matriz de confusión. Ambos clasificadores arrojaron los mejores resultados para el parámetro de Media ($P > 90\%$ y $K > 0,88$) y en menor grado para el de Homogeneidad. Los porcentajes de píxeles bien clasificados por categoría también indican que la Media ofrece los mejores resultados para todas las clases ($P > 86\%$).

Palabras clave: Textura, Uso del suelo, Landsat 8, Matriz de co-ocurrencia.

Abstract

Different texture measures were applied to determine the land cover in the Adolfo Alsina department (Buenos Aires province, Argentina). A multitemporal study using red and near-infrared bands of Landsat 8 OLI satellite images was developed. A grey level co-occurrence matrix (GLCM) was obtained based in eight measures associated with four window sizes. Two classification methods were applied to discriminate categories: Maximum Likelihood and Support Vector Machines. A confusion matrix was developed to evaluate the performance of the classification. Both classification methods resulting in the best accuracy for Mean ($P > 90\%$ and $K > 0,88$) and Homogeneity. The accuracies for the different classes show better results for Mean for all the categories ($P > 86\%$).

Keywords: Texture, Land cover, Landsat 8, Co-occurrence matrix.

Introducción

El empleo de imágenes satelitales constituye desde hace décadas un insumo fundamental en la evaluación de recursos naturales, así como en aplicaciones agrícolas y forestales. En el caso particular de la determinación del uso del suelo en ambientes heterogéneos, la utilización de dichos insumos para la discriminación de los diferentes usos no siempre resulta tarea sencilla. Tales dificultades quedan

especialmente expuestas en el caso de los cultivos en virtud de que estos suelen presentar diferentes estados fenológicos, así como diversidad en las fechas de siembra y en la tecnología empleada. Para subsanar estos inconvenientes durante la clasificación de imágenes satelitales, los métodos habituales se han basado en la respuesta espectral individual de cada píxel. En tal sentido, en la República Argentina se ha empleado con eficacia el Índice de Diferencia Normalizada de Vegetación (Normalized Difference Vegetation Index - NDVI). Diversos autores como Vazquez et al. (2006), Volante et al. (2005), Marini (2016) y Marini y Ángeles (2016) han utilizado con éxito este parámetro para determinar diferentes usos del suelo.

No obstante, una alternativa posible y poco explorada en la determinación del uso del suelo es considerar la clasificación de imágenes satelitales en un contexto espacial. El resultado de la clasificación de un píxel puede diferir al ser estudiado de manera aislada de cuando se consideran también sus vecinos (Presutti, 2004). De esta manera, al considerar la información contenida en la vecindad de cada píxel merced el cálculo de diferentes medidas estadísticas (Homogeneidad, Entropía, Contraste, etc.), pueden generarse nuevas imágenes de textura para ser empleadas en la clasificación de la imagen (Bähr, 1991). Una de las posibles definiciones de textura refiere a la heterogeneidad espacial de una determinada cubierta y al contraste espacial entre los elementos que la componen (Chuvieco, 2010). Este parámetro se presenta como la rugosidad o suavidad de los tonos de gris, observándose las texturas más lisas cuanto más similares sean dichos tonos (Santamaría y Aldalur, 2014).

En el caso de la determinación del uso del suelo empleando imágenes satelitales mediante un análisis de textura, pueden citarse, entre otros, los trabajos de Erenner & Düzgün (2009), Lu et al. (2012) o Jia et al. (2014). No obstante, dicha metodología también ha sido aplicada en estudios urbanos (Lu & Qihao, 2005; Mhangara & Odindi, 2013; Zhang et al., 2014), así como en la determinación de biomasa y biodiversidad (Lu & Mateus, 2005; Acevedo et. al., 2008; Kelsey & Neff, 2014), discriminación de Rocas (Dong & Leblon, 2004; Wei et al., 2016) o en la detección de un cultivo en particular (Pesaresi, 2008; Yayusman & Nagasawa, 2015).

En base a lo expuesto, el objetivo del presente trabajo es aplicar la potencialidad de las diferentes medidas de textura en la discriminación de diferentes coberturas vegetales con el fin de determinar el uso del suelo en el partido de Adolfo Alsina (Buenos Aires, Argentina) para la campaña agrícola 2017/ 2018. Dicho partido se halla emplazado en la Región Pampeana Argentina, en donde el sector agropecuario constituye uno de los principales recursos de la economía del país, tanto como generador de divisas provenientes de las exportaciones como proveedor del mercado interno. La importancia de este tipo de estudios en áreas con estas características radica en que el conocimiento del uso de la tierra facilita la estimación de la producción agrícola y de los requerimientos de insumos que esta demanda (fertilizantes, pesticidas, maquinarias, mano de obra). En tal sentido, la teledetección facilita el conocimiento global de vastas regiones merced a la cobertura espacial de los diversos satélites (Borrás et al., 2017).

Área de estudio

El partido de Adolfo Alsina se encuentra localizado en el Centro-Oeste de la provincia de Buenos Aires (Figura 1). Su superficie asciende a 585954 has., siendo su principal localidad la ciudad cabecera, Carhué, que cuenta con 9660 hab. Otras localidades menores son Rivera (3217 hab.) y Villa Maza (1748 hab.) La población total del partido es de 17072 hab. (INDEC, 2011).




Figura 1: Localización del partido de Adolfo Alsina

El clima del área ha sido definido como semiárido templado (Campi et al., 2001). La temperatura media anual es de 15,2 °C, siendo enero, con una temperatura media de 21 °C, el mes más caluroso y julio, con una media de 7 °C, el mes más frío. El período de ocurrencia de las heladas es de 220 días, con una temperatura mínima absoluta media anual de -6,2 °C. La precipitación media anual es de 770 mm, registrándose los valores mensuales promedio más elevados durante los meses de marzo y de noviembre. En ocasiones, estos llegan a triplicar a los valores mensuales promedio del semestre invernal (INTA, 2011).

Adolfo Alsina se halla atravesado en sentido NE-SO por una depresión conocida como Sistema de las Encadenadas. La misma se encuentra conformada por un rosario de lagunas de drenaje endorreico con declive hacia el SO (Figura 1). Dicha depresión delimita dos diferentes ambientes: a) Al Norte, una planicie arenosa suavemente ondulada que alterna sectores planos con cadenas medianosas de baja altura. Los suelos de esta planicie son profundos, sin limitaciones a la penetración radical de los cultivos y de bajo contenido en materia orgánica. Entre sus limitaciones se hallan la capacidad de retener agua, la erosión eólica y su rápida permeabilidad (INTA, 1989). b) Hacia el Sur se encuentra una planicie inclinada que conecta la depresión central con el pedemonte de las sierras del Sistema de Ventania. Esta planicie puede a su vez dividirse en dos sectores: el NE, de vías de drenaje integradas y sedimentos de textura franca con desagüe hacia las lagunas y el SO, que conforma una planicie elevada con drenaje menos integrado y cubierta por sedimentos de textura franco-arenosa con abundancia de carbonato de calcio. La presencia de lagunas y salitrales aislados da lugar a mesetas flanqueadas por pendientes suaves. Al Sur de la depresión

central los suelos presentan limitaciones a la profundidad de enraizamiento de los cultivos, a la capacidad de retener agua y al riesgo de erosión eólica debido a la textura de sus horizontes superficiales (INTA, 1989).

El sistema productivo, otrora ganadero-agrícola, ha ido incrementado su proporción de agricultura (Nevani, 2007; SIIA, 2012). Como ocurrió en la mayor parte de la región pampeana argentina, esto obedeció a un mayor desarrollo tecnológico basado en cultivos transgénicos, en la incorporación de la siembra directa y en el incremento del empleo de fertilizantes, plaguicidas y agricultura de precisión (Satorre, 2005). Las razones de dicha expansión fueron principalmente económicas, concentrándose en el cultivo de la soja (*Glicine max*). Este cambio trajo aparejada una simplificación estructural y funcional de los sistemas productivos (Viglizzo et al., 2006; Aizen et al., 2009). Existen también otros cultivos estivales de significativo desarrollo, tales como el girasol (*Heliantus agnus*), el maíz (*Zea mays*) y en menor medida el sorgo granífero (*Sorghum bicolor*). Entre los cultivos invernales de cosecha se destaca el trigo (*Triticum aestivum*) seguido por la avena (*Avena sativa*).

La ganadería bovina, de ciclo completo y en menor grado de cría, se basa en pasturas con alfalfa (*Medicago sativa*) y en gramíneas perennes y cultivos forrajeros invernales como la avena (*Avena sativa*) o estivales como el sorgo forrajero (*Sorghum sp*) y el maíz para el mismo fin. En áreas muy arenosas las pasturas están compuestas por pasto llorón (*Eragrostis cúrvara*) y en sectores inundables por agropiro (*Agropirum elongatum*).

Metodología

Imágenes satelitales empleadas

Se utilizaron imágenes satelitales Landsat 8 OLI. Las escenas fueron obtenidas de la página de la NASA destinada a tal fin (<http://glovis.usgs.gov>) y luego fueron procesadas utilizando la proyección UTM 20 Sur (datum WGS 1984). El partido de Adolfo Alsina se halla comprendido enteramente dentro de la escena Landsat 8 OLI 227-086. De dicha escena y teniendo en cuenta la ausencia de nubes, se seleccionaron ocho fechas de pasaje del satélite: Año 2017: 19 de agosto, 6 de octubre, 22 de octubre, 23 de noviembre y 25 de diciembre. Año 2018: 10 de enero, 11 de febrero y 15 de marzo. De cada imagen satelital se emplearon las porciones del espectro electromagnético del rojo (banda 4) e infrarrojo cercano (banda 5), ya que son las que mayor información aportan respecto al estado de la vegetación. De hecho y por tal motivo, ambas bandas han sido ampliamente empleadas para el cálculo del Índice Normalizado de Diferencia de Vegetación o NDVI (Rouse et al., 1974). Una vez seleccionadas dichas bandas, se las agrupó en una única multibanda (*stacking*) que integra las distintas fechas escogidas sobre la que luego se aplicaron los métodos de clasificación.

Las diferentes fechas fueron seleccionadas teniendo en cuenta aquellas que mejor representasen la evolución de los distintos estados fenológicos. Esto obedece a que en áreas heterogéneas, la existencia de diferentes cultivos con diversas fechas de siembra implica que no alcance con una sola fecha para separarlos entre sí. De hecho, la máxima discriminación entre cultivos tiene lugar durante las diferentes etapas del crecimiento, por lo que se impone la aplicación de imágenes multitemporales (Murthy, 2003).

Recopilación de datos en el terreno

Se llevó a cabo un trabajo de campo consistente en una recorrida del partido de Adolfo Alsina en donde se georreferenciaron 222 lotes con diferentes usos del suelo. La finalidad de este relevamiento fue la de obtener verdades de campo para ser posteriormente utilizadas como polígonos de entrenamiento a emplearse en la evaluación de la clasificación final. De esta manera, los lotes georreferenciados con ayuda de un GPS fueron agrupados en las siguientes categorías: 1) soja, 2) girasol, 3) maíz (cultivos de verano de cosecha), 4) sorgo (forrajero y granífero), 6) trigo, 7) cebada (cultivos de invierno de cosecha), 8) uso forrajero (involucra tanto pasturas implantadas como pastizales naturales de buen desarrollo y verdes de invierno) y 9) no laboreado (engloba a lotes que no evidenciaron manejo alguno durante la presente campaña agrícola). La tabla 1 presenta el número de áreas de entrenamiento (ROIs) y la cantidad total de píxeles por categoría empleadas para validar cada clasificador utilizado.

	Trigo	Cebada	No Laboreado	Uso Forrajero	Soja	Maíz	Sorgo	Girasol
RoIs	32	10	24	16	43	45	11	41
Píxeles	2642	892	1728	1200	4227	4040	638	3720

Tabla 1: Cantidad de ROIs y de píxeles por categoría utilizada para validar los distintos métodos de clasificación.

Métodos de clasificación

En primer lugar, se enmascararon en forma manual las diferentes localidades que conforman el partido. En el caso de las lagunas y cuerpos de agua menores, se los discriminó empleando una clasificación No Supervisada mediante el método Isodata (Datos Auto Asociados Iterativamente). Posteriormente, se generaron las imágenes de textura a partir del cálculo de la matriz de co-ocurrencia – GLCM (Haralick et al., 1973). En el caso del presente estudio, se consideraron ocho medidas de textura: Media, Varianza, Homogeneidad, Contraste, Disimilaridad, Entropía, Segundo Momento Angular y Correlación. Asimismo, se consideraron cuatro distintos tamaños de ventanas de píxeles: 5x5, 7x7, 9x9 y 11x11.

Para discriminar cada categoría se emplearon dos clasificadores: el método de Máxima Verosimilitud (Maximum Likelihood - MLC) y el de Máquinas de Soporte Vectorial (Support Vector Machines - SVM). El MLC ha sido uno de los clasificadores paramétricos más empleados en teledetección (Foody et al. 1992; Jia et al. 2011), asumiendo una determinada distribución estadística para cada clase valiéndose de un modelo probabilístico. Por su parte el SVM es uno de los clasificadores no paramétricos más utilizado en determinación del uso del suelo con imágenes satelitales en virtud de sus muy buenos resultados (Jia et al. 2012; Pal & Foody 2012). El mismo se basa en la búsqueda de un hiperplano espacial que divida al conjunto de datos en dos subconjuntos durante la fase de entrenamiento (Duda & Hart 1973). Finalmente, se empleó un árbol de decisión cuyos sucesivos logaritmos fueron orientados a seleccionar las categorías mejor discriminadas durante las dos clasificaciones supervisadas mencionadas anteriormente.

Técnicas de evaluación de los resultados

Para evaluar la precisión de cada clasificación realizada se generó una matriz de confusión, en donde se compara el mapa obtenido de la clasificación de las imágenes satelitales con las verdades de campo. De dicha matriz se derivan diferentes mediciones de precisión de la clasificación, entre las que pueden citarse:

Precisión global (P): Se obtiene de dividir el total de píxeles correctamente clasificados sobre el total de píxeles correspondientes a las verdades de campo (Jensen, 1986). Los resultados de la clasificación efectuada serán mejores cuanto más cercano al 100 % sea el valor de P.

Coefficiente Kappa global (K): Calcula el grado de ajuste entre la imagen clasificada y la realidad observada en el terreno (Bishpo et al., 1975). Los valores de K cercanos a 1 indican un excelente acuerdo entre la realidad observada y el mapa obtenido. De acuerdo a Landis & Koch (1977), se han establecido márgenes de referencia para los distintos valores de Kappa. Ellos son: 0 a 0,2: insignificante; 0,2 a 0,4: bajo; 0,4 a 0,6: moderado; 0,6 a 0,8: bueno y mayor a 0,8: muy bueno.

Resultados

Las tablas 2 y 3 presentan el porcentaje de precisión (P) e índice Kappa resultante de la matriz de confusión de los clasificadores MLC y SVM aplicados al agrupamiento (stacking) multitemporal de las bandas del rojo e infrarrojo cercano. En el caso del primero de dichos algoritmos (Tabla 2), se desprende que los parámetros de Media y en menor medida el de Homogeneidad son los que ofrecen los mejores resultados para todos los tamaños de ventana. Esto se evidencia principalmente en la Media, en donde los valores de P superan en todos los casos el 90 %, con K mayores a 0,88. A medida que el tamaño de la ventana se amplía, los resultados mejoran para los parámetros de Entropía y en menor grado Segundo Momento Angular.

Ventana	Medida	P	K
5x5	Media	90,413	0,8841
	Varianza	38,100	0,3061
	Homogeneidad	73,001	0,6783
	Entropía	68,237	0,6242
	Correlación	25,616	0,1409
	Disimilaridad	59,518	0,5272
	Segundo Momento	46,134	0,3800
	Contraste	35,274	0,2745
7x7	Media	92,300	0,9068
	Varianza	46,013	0,3878
	Homogeneidad	80,200	0,7627
	Entropía	78,088	0,7383
	Correlación	29,199	0,2017
	Disimilaridad	67,442	0,6159
	Segundo Momento	55,847	0,4867
	Contraste	42,995	0,3523
9x9	Media	92,520	0,9094
	Varianza	49,349	0,4229
	Homogeneidad	82,373	0,7884
	Entropía	82,044	0,7848
	Correlación	40,904	0,3121
	Disimilaridad	70,235	0,6471

	Segundo Momento	82,044	0,7848
	Contraste	56,609	0,4621
11x11	Media	94,172	0,9293
	Varianza	57,970	0,5134
	Homogeneidad	87,910	0,8542
	Entropía	86,769	0,8408
	Correlación	44,010	0,3557
	Disimilaridad	75,991	0,7139
	Segundo Momento	67,294	0,6151
	Contraste	53,394	0,4616

Tabla 2: Precisión y Kappa para las ocho medidas de textura de la matriz de co-ocurrencia obtenidas mediante el clasificador MLC.

Ventana	Medida	P	K
5x5	Media	87,323	0,8459
	Varianza	48,888	0,3580
	Homogeneidad	76,760	0,7157
	Entropía	78,658	0,7388
	Correlación	36,190	0,1967
	Disimilaridad	63,090	0,5432
	Segundo Momento	67,019	0,5929
	Contraste	51,166	0,3900
7x7	Media	88,311	0,8579
	Varianza	54,206	0,4274
	Homogeneidad	81,858	0,7785
	Entropía	83,125	0,7939
	Correlación	42,451	0,2846
	Disimilaridad	66,745	0,5894
	Segundo Momento	70,098	0,6326
	Contraste	56,406	0,4584
9x9	Media	89,595	0,8735
	Varianza	55,298	0,4424
	Homogeneidad	82,928	0,7917
	Entropía	83,789	0,8020
	Correlación	56,609	0,4621
	Disimilaridad	67,947	0,6053
	Segundo Momento	70,690	0,6403
	Contraste	56,609	0,4621
11x11	Media	90,479	0,8842
	Varianza	60,231	0,5052
	Homogeneidad	85,359	0,8214
	Entropía	86,061	0,8298

Correlación	32,491	0,1376
Disimilaridad	72,468	0,6614
Segundo Momento	75,135	0,6954
Contraste	60,835	0,5156

Tabla 3: Precisión y Kappa para las ocho medidas de textura de la matriz de co-ocurrencia obtenidas mediante el clasificador SVM.

Del mismo modo, al aplicar el algoritmo SVM (Tabla 3) se obtienen resultados similares al MLC, aunque con valores de P y K -en líneas generales- levemente inferiores. En tal sentido, el valor de P sólo supera el 90 % al emplear la Media con una ventana de 11x11 píxeles. Por tal motivo, se seleccionaron las cuatro variables de textura que mejores resultados ofrecieron: Media, Homogeneidad, Entropía y Segundo Momento Angular.

La tabla 4 presenta los porcentajes de píxeles bien clasificados para cada categoría empleada resultante de la matriz de confusión del clasificador MLC. Dichos porcentajes presentan valores en general superiores o cercanos al 90 % para la medida de Media. Tal resultado se verifica en todas las categorías, incluso en aquellas de ciclo fenológico muy similar como el trigo y la cebada. En el caso de la Homogeneidad, se advierte una mayor variación en la discriminación de categorías. Para las ventanas de 5x5 píxeles, sólo la soja y la cebada superan el 80 % de píxeles bien clasificados. El resto de las categorías supera el 71 %, con excepción del maíz (57 %). No obstante, se evidencia una mejora en la discriminación a medida que se incrementa la dimensión de la ventana empleada. De tal manera, el porcentaje de píxeles correctamente discriminados llega a superar el 90 % en el caso de la cebada, la soja y el uso forrajero, e incluso alcanza el 80 % para el maíz empleando la ventana de 11x11 píxeles.

La mejora en los resultados conforme aumenta el tamaño de la ventana empleada también se observa para las medidas de Entropía y Segundo Momento Angular, aunque con porcentajes de discriminación más discretos. La ventana de 11x11 presenta una óptima separación para las cuatro categorías, oscilando entre 79 % para el maíz y 92 % para la soja al emplear la Entropía. En cambio, para la medida de Segundo Momento Angular, a excepción de la cebada y del uso forrajero, los mejores porcentajes de píxeles bien clasificados se obtienen empleando la ventana de 9x9. No obstante, dichos porcentajes son inferiores a los obtenidos en la medida anterior.

Categoría	Tamaño de Ventana	Media	Homogeneidad	Entropía	Seg. Momento
Trigo	5x5	93,22	71,46	65,18	36,26
	7x7	95,04	79,07	77,48	46,67
	9x9	95,99	81,34	83,80	83,80
	11x11	96,44	88,19	87,17	62,34
Cebada	5x5	93,27	81,05	73,21	54,93
	7x7	95,40	86,66	84,75	71,52
	9x9	95,18	89,69	88,79	88,79
	11x11	97,09	93,16	91,26	89,24
No laboreado	5x5	93,63	71,88	62,85	39,93

	7x7	93,87	79,98	78,24	34,28
	9x9	93,06	84,49	84,61	84,69
	11x11	94,21	92,48	92,59	68,87
Uso Forrajero	5x5	86,75	76,25	77,75	79,42
	7x7	90,58	84,75	85,58	83,00
	9x9	93,00	88,50	88,67	88,67
	11x11	93,17	92,75	90,08	90,75
Soja	5x5	90,44	84,84	76,41	51,36
	7x7	92,64	90,92	85,76	59,76
	9x9	94,30	95,29	88,98	88,68
	11x11	95,01	92,75	92,26	67,49
Maíz	5x5	90,42	57,28	57,70	35,42
	7x7	91,96	68,39	68,25	47,82
	9x9	90,74	70,57	71,11	71,11
	11x11	94,21	80,37	79,60	62,20
Sorgo	5x5	91,54	77,12	77,43	51,41
	7x7	94,04	79,15	81,82	68,65
	9x9	96,24	83,07	86,03	86,05
	11x11	96,71	85,11	90,44	79,78
Girasol	5x5	87,93	74,30	67,98	46,53
	7x7	89,49	78,87	75,78	52,28
	9x9	88,41	79,97	79,76	79,76
	11x11	90,75	84,11	83,90	60,78

Tabla 4: Porcentajes de píxeles correctamente clasificados por categoría para cuatro medidas de textura (Media, Homogeneidad, Entropía y Segundo Momento) utilizando el clasificador MLC.

Los porcentajes de píxeles correctamente clasificados por categoría reflejados en la matriz de confusión resultante de emplear el clasificador SVM (Tabla 5) arrojan ciertas similitudes con el clasificador MLC, aunque con resultados inferiores. La Media es la medida que mejor discrimina cada categoría, aunque para la cebada, el uso forrajero y los lotes no laboreados, el porcentaje de píxeles bien clasificados no alcanza el 90 % en ninguna de las ventanas empleadas. En la Homogeneidad también se verifica una disimilaridad entre las categorías discriminadas. En esta medida, los porcentajes más altos de píxeles bien clasificados se han detectado para el trigo, la soja, el maíz y el girasol, generalmente superando el 80 %. Asimismo, y al igual que con el clasificador MLC, también se verifica una mejor separabilidad en la medida en que se incrementa el tamaño de la ventana de píxeles. De hecho, para las cuatro categorías mencionadas anteriormente, tales porcentajes superan el 90 % empleando ventanas de 11x11 píxeles.

	Tamaño de Ventana	Media	Homogeneidad	Entropía	Seg. Momento
Trigo	5x5	91,33	83,57	83,54	73,54
	7x7	90,84	88,19	86,56	76,91

	9x9	92,01	88,12	88,04	77,59
	11x11	91,90	90,35	91,98	93,19
Cebada	5x5	68,72	51,79	53,81	27,91
	7x7	69,84	55,83	63,57	29,26
	9x9	72,76	57,40	69,96	27,24
	11x11	74,10	59,75	65,58	24,10
No laboreado	5x5	71,30	38,19	47,45	29,63
	7x7	71,88	49,19	53,70	31,94
	9x9	71,53	50,35	49,77	33,45
	11x11	75,69	58,22	54,28	37,04
Uso Forrajero	5x5	76,08	63,00	60,00	33,65
	7x7	79,00	73,08	71,33	48,33
	9x9	83,00	78,00	73,33	58,17
	11x11	84,42	77,67	74,75	65,17
Soja	5x5	93,92	90,09	90,92	87,89
	7x7	94,80	93,16	93,78	88,05
	9x9	96,38	93,23	93,80	89,45
	11x11	96,69	94,94	94,63	92,48
Maíz	5x5	88,79	76,14	77,90	65,54
	7x7	89,93	82,05	82,70	69,13
	9x9	90,89	84,21	83,47	67,72
	11x11	91,66	86,58	87,40	72,55
Sorgo	5x5	76,96	53,92	62,23	35,27
	7x7	80,09	63,01	65,20	42,32
	9x9	81,97	67,40	71,00	44,98
	11x11	82,13	66,00	68,65	53,76
Girasol	5x5	88,98	80,75	84,14	74,52
	7x7	90,05	84,19	87,45	76,34
	9x9	90,43	84,09	86,53	75,22
	11x11	91,88	87,85	89,60	80,48

Tabla 5: Porcentajes de píxeles correctamente clasificados por categoría para cuatro medidas de textura (Media, Homogeneidad, Entropía y Segundo Momento) utilizando el clasificador SVM.

La medida Entropía sólo evidencia óptimos resultados para el trigo, la soja, el girasol y el maíz. Los porcentajes llegan a superar el 90 % a medida que se incrementa el tamaño de la ventana, con un máximo de 94 % en para soja. En el caso del Segundo Momento Angular, los porcentajes son aún inferiores, siendo la soja (hasta 92 %) y el trigo (máximo de 93 %) las únicas categorías bien discriminadas. A diferencia del clasificador anterior, los mejores porcentajes de píxeles bien clasificados se obtienen empleando la ventana de 11x11, a excepción de la cebada. Sin embargo, los valores son notoriamente inferiores a los que arroja el algoritmo MLC para esta medida de textura.

En base a los resultados anteriores, se decidió trabajar con las ventanas móviles de 11x11, ya que se consideró la dimensión más adecuada en concordancia con los porcentajes de píxeles bien clasificados por categoría. En tal sentido, la medida elegida fue la Media. De esta manera, se elaboró un árbol de decisión seleccionando las clases mejor discriminadas por cada uno de los dos métodos empleados. Para la confección de dicho algoritmo se seleccionaron las categorías trigo, cebada, maíz, no laboreado, uso forrajero y sorgo obtenidas por el método MLC y las clases soja y girasol provenientes del clasificador SVM. La Tabla 6 presenta la matriz de confusión resultante de aplicar este árbol de decisión que combina ambos métodos de clasificación. La tasa de exactitud global (P) fue de 95,41 % y el índice Kappa de 0,9444.

	Trigo	Cebada	No Laboreado	Uso Forrajero	Soja	Maíz	Sorgo	Girasol
Trigo	97,40	1,46	3,26	1,37	0	1,13	0	0,66
Cebada	0,11	97,09	0	0	0	0,15	0	0
No Laboreado	0,46	0	94,87	0,42	0	0	1,57	0,49
Uso Forrajero	1,26	0,9	1,17	95,56	0	1	0,78	0,49
Soja	0	0	0	0	97,45	2,45	0	3,09
Maíz	0,34	0,55	0	2,65	1,26	94,57	0,94	3,24
Sorgo	0,31	0	0,7	0	0,31	0,15	96,71	0
Girasol	0,12	0	0	0	0,98	0,55	0	92,03

Tabla 6: Matriz de confusión resultante de aplicar el árbol de decisión sobre los resultados de los clasificadores MLC y SVM aplicados sobre la Media.

Los valores de P y K de dicha clasificación son mayores a cualquiera de los obtenidos en las Tablas 2 y 3 aplicando las ocho mediciones de textura y las cuatro dimensiones de ventanas utilizando los clasificadores MLC y SVM. Asimismo, los porcentajes de píxeles bien clasificados para cada categoría (en negrita) son iguales o superiores a los expuestos en las Tablas 4 y 5 para las cuatro mejores medidas de textura detectadas (Media, Homogeneidad, Entropía y Segundo Momento Angular). En base a estos resultados, la Figura N° 2 presenta el uso del suelo en Adolfo Alsina para la campaña 2017/ 2018 como producto de aplicar el árbol de decisión final.

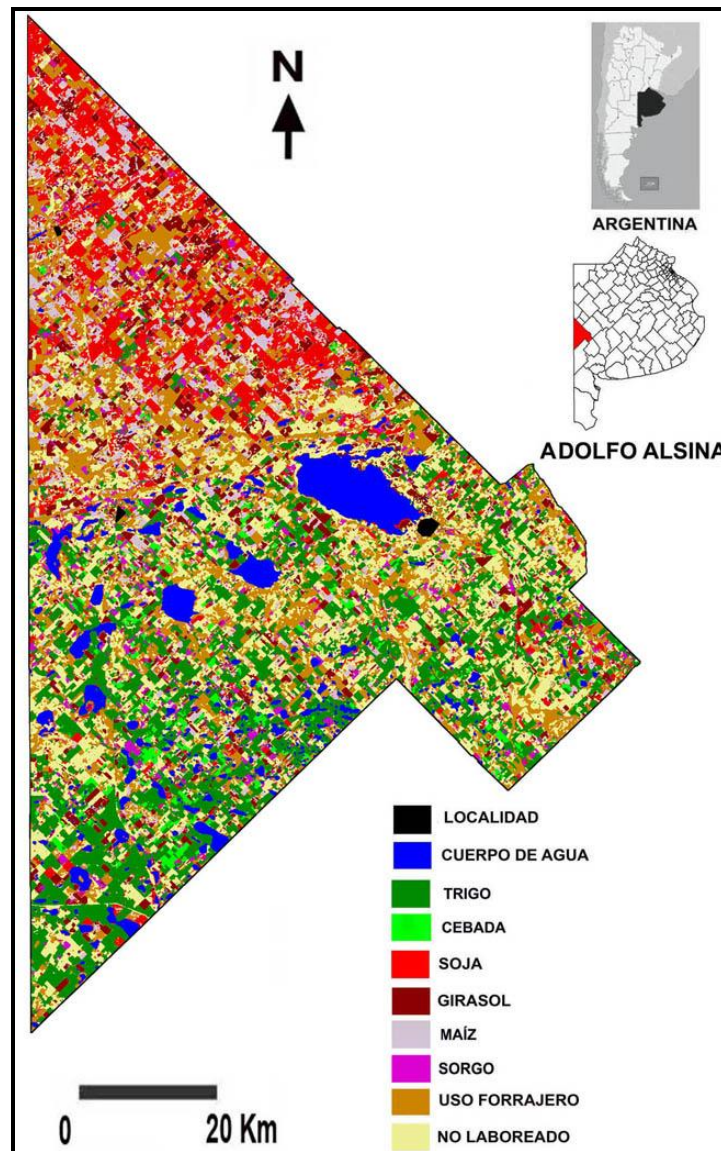


Figura 2: Uso del suelo en Adolfo Alsina (campaña 2017/ 2018) empleando el árbol de decisión sobre las categorías mejor discriminadas.

Conclusiones

El análisis de textura aplicado a la determinación del uso del suelo proporcionó resultados dispares para cada una de las medidas de la matriz de co-ocurrencia. De las ocho variables evaluadas, cuatro de ellas arrojaron los mejores resultados, aunque con distintos grados de confiabilidad. En orden de exactitud en la clasificación, ellas fueron Media, Homogeneidad, Entropía y Segundo Momento Angular. No obstante, sólo la primera de ellas proporcionó óptimos porcentajes de píxeles bien clasificados para todas las categorías seleccionadas. Las restantes presentan medidas de precisión disímiles para cada clase, siendo la Homogeneidad la mejor de estas tres.

Los algoritmos de clasificación MLC y SVM empleados han demostrado ser viables para discriminar entre categorías, especialmente el primero de ellos. Un aspecto importante durante la evaluación del procedimiento de generación de imágenes de textura fue la definición del tamaño de ventana a considerar. En tal sentido, a medida que el tamaño de la misma se amplía, se observaron los mejores resultados, especialmente para la de 11x11 píxeles. La determinación del uso del suelo con mejores medidas de precisión en la evaluación final de la clasificación se obtuvo utilizando la Media, seleccionando las clases mejor discriminadas por los métodos MLC y SVM mediante un árbol de decisión y empleando la ventana de 11x11.

Referencias

Acevedo, J.A.A., Duque Londoño, R.A. y Valencia Hernández, G.M. Análisis de textura en imágenes de satélite en el ámbito de la biodiversidad y la estructura en un bosque de los Andes Colombianos. *Gestión y Ambiente*, 2008, Volumen 11 - N° 3.

Aizen, M.A., Garibaldi L.A y Dondo, M. Expansión de la soja y diversidad de la agricultura argentina. *Ecología Austral*, 2009. 19: p. 45-54.

Bähr, H.P. Procesamiento digital de imágenes: Aplicaciones en Fotogrametría y Teledetección, GTZ, Eschborn, Alemania, 428 pp., 1991.

Bishop, Y., Fienberg, S. & Holland, P. Discrete multivariate analysis. Theory and practice. Cambridge, MIT Press, 1975.

Borrás, J., Delegido, J., Pezzola, A., Pereira, M., Morassi, G. y Camps Valls, G. Clasificación de usos del suelo a partir de imágenes Sentinel-2. *Revista Española de Teledetección* N° 48, 2017, España.

Campi, E., Lorda, H. y Bellini Saibene, Y. Boletín Informativo AgroRADAR N° 6, 7, 8 y 9. Edición del Convenio INTA - Bolsa de Cereales y Cámara Arbitral de Cereales de Bahía Blanca, 2001.

Chuvieco, E. Teledetección ambiental. Editorial Ariel, Barcelona. España, 2010, 590 pp.

Dong, P. & Leblon, B. Rock unit discrimination on Landsat TM, SIR-C and Radarsat images using spectral and textural information. *International Journal of Remote Sensing* 25, N° 18, 2004, p. 3745–3768.

Duda, R.O. & Hart, P.E. Pattern classification and scene analysis. New York, 1973. NY: Wiley.

Erener, A. & Düzgün, H.S. A methodology for land use change detection of high resolution pan images based on texture analysis. *Italian Journal of Remote Sensing*, 2009. 41 (2): 47-59.

Foody, G.M., Campbell, N.A., Trodd, N.M. & Wood, T.F. Derivation and applications of probabilistic measures of class membership from the maximum-likelihood classification. *Photogrammetric Engineering and Remote Sensing*, 1992. 58: 1335–1341.

Haralick, R.M., Shanmugam, K. & Dinstein, I. Textural features for image classification. IEEE Transactions on Systems, Man, and Cybernetics, 1973. 3: p. 610–621.

INDEC - Instituto Nacional de Estadísticas y Censos. Censo, 2010. Disponible en https://www.indec.gov.ar/ftp/cuadros/poblacion/censo2010_tomo1.pdf, 2011.

INTA - Instituto Nacional de Tecnología Agropecuaria. Mapa de Suelos de la Provincia de Buenos Aires. Instituto de Suelos, 1989.

INTA - Instituto Nacional de Tecnología Agropecuaria. Datos de precipitación y temperatura de las distintas estaciones meteorológicas del área de influencia de la Estación Experimental Bordenave, 2011. Disponible en <https://inta.gov.ar/documentos/informacion-agrometeorologica>

Jensen, J.R. Introductory digital image processing. New Jersey, 1986, Prentice-Hall.

Jia, K., Wu, B.F., Tian, Y.C, Zeng, Y. & Li, Q.Z. Vegetation classification method with biochemical composition estimated from remote sensing data. International Journal of Remote Sensing, 2011, 32: p. 9307–9325.

Jia, K., Li, Q.Z., Tian, Y.C., Wu, B.F., Zhang, F.F. & Meng, J.H. Crop classification using multi-configuration SAR data in the North China Plain. International Journal of Remote Sensing, 2012, 33: p. 170–183.

Jia, K., Wei, X., Gu, X., Yao, Y., Xie, X. & Li, B. Land cover classification using Landsat 8 Operational Land Imager data in Beijing, China, 2014. Geocarto International 29.

Kelsey, K.C. & Neff, J.C. Estimates of Aboveground Biomass from Texture Analysis of Landsat Imagery. Remote Sensing 6, 2014, p. 6407-6422.

Landis, J.R. & Koch, G.G. The measurement of observer agreement for categorical data". Biometrics 33 (1), 1977, p. 159 -174.

Lu, D. & Mateus, B. Exploring TM Image Texture and its Relationships with Biomass Estimation in Rondônia, Brazilian Amazon, 2005.

Lu, D. & Qihao, W. Urban Classification Using Full Spectral Information of Landsat ETM+ Imagery in Marion County, Indiana, 2005. Photogrammetric Engineering and Remote Sensing 71.

Lu, D., Batistella, M., Li, G., Moran, E., Hetrick, D., Da Costa Freitas, C., Viera Dutra, L. & Siqueira Santana, S. J. Land use/cover classification in the Brazilian Amazon using satellite images. Pesq. agropec. bras., Brasília, 2012, v.47, N° 9, p.1185-1208.

Marini, M.F. Mapeo y discriminación de cultivos de verano en el partido de Coronel Suárez empleando imágenes satelitales Landsat 8 OLI. Octavo Congreso de la Ciencia Cartográfica- Instituto Geográfico Nacional, 2016. Capital Federal, 2 al 4 de noviembre.

Marini, M. F. Y Ángeles, G. R. Discriminación de diferentes cultivos de verano en el partido de Guaminí utilizando imágenes satelitales Landsat 8 OLI. Terceras Jornadas de Tecnología de Información Geográfica del Sur Argentino, 2016. Bahía Blanca, Argentina, 24 al 26 de Agosto.

Mhangara, P. & Odini, J. Potential of texture-based classification in urban landscapes using multispectral aerial photos. South African Journal of Science, 2013, vol.109, N° 3-4, Pretoria.

Murthy, C.S., Raju, P.V. & Badrinath, K.S. Classification of wheat crop with multitemporal images: performance of maximum likelihood and artificial neural networks". International Journal of Remote Sensing, 2003, 24, p. 4871-4890.

Nevani, R. Principales Cambios en la Actividad Ganadera de la Provincia de Buenos Aires. Tesis de licenciatura en Economía. Mar del Plata, Argentina, 2007. Universidad Nacional de Mar del Plata.

Pal, M. & Foody, G.M. Evaluation of SVM, RVM & SMLR for accurate image classification with limited ground data. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2012, 5: p. 1344–1355.

Pesaresi, M. Textural analysis of coca plantations using 1-meter-resolution remotely-sensed data. Measurement of Cultivation and Production of Coca Leaves and Derivates United Nations Office on Drugs and Crime (UNODC), 2008. Bogota, Colombia, 25-28 November.

Presutti, M. La matriz de co-ocurrencia en la clasificación multiespectral: tutorial para la enseñanza de medidas texturales en cursos de grado universitario. 4ª Jornada de Educação em Sensoriamento Remoto no Âmbito do Mercosul - São Leopoldo, 2004. RS, Brasil.

Rouse, J.W., Haas, R.H., Schell, J.A., Deering, D.W. & Harlan, J.C. Monitoring the vernal advancement of retrogradation of natural vegetation, 1974. NASA/OSFC. Final Report. Oreenbello MD.

Santamaría, M. Y Aldalur, B. Enfoque estadístico de análisis de textura: su aplicación a la clasificación de un ortofotomosaico del valle de inundación del Arroyo Naposta Grande, GeoFocus, 2014, N° 14, p.55-67.

Satorre, E. Cambios tecnológicos en la agricultura actual. La transformación de la agricultura argentina, Ciencia Hoy. Oesterheld, M. (Ed.), 2005, p. 24-31.

SIIA - Sistema Integrado de Información Agropecuaria. Estadísticas de Producción Agrícola. Ministerio de Agricultura de la Nación, 2012. Disponible en <http://www.siiia.gov.ar>

Vazquez, P., Masuelli, S. y Platzeck, G. Determinación de patrones espectrales para distintos usos del suelo en ambientes heterogéneos. Ediciones. INTA, 2006, Publicación Técnica N° 1, 34 pp.

Viglizzo, E.F., Frank, F., Bernardos, J. y De Buschiazzi, C.S. A Rapid Method For Assessing the Environmental Performance of Commercial Farms in the Pampas of Argentina. Environmental Monitoring and Assessment, 2006, 117: p. 109-134.

Volante, J.N., Bianchi, A., Paoli, Y., Noe, Y. y Helena, H. Análisis de la dinámica del uso del suelo del Noroeste Argentino mediante teledetección y SIG, 2005. Disponible en [Http://www.inta.gov.ar/prorenea/zonadescarga/uso_suelo/Analisis de la dinamica del uso del suelo.pdf](http://www.inta.gov.ar/prorenea/zonadescarga/uso_suelo/Analisis_de_la_dinamica_del_uso_del_suelo.pdf)

Yayusman, L.F. & Nagasawa; R. ALOS-Sensor data integration for the detection of smallholder's oil palm plantation in Southern Sumatra, Indonesia. J. JASS, 2015, 31(2): p. 27-40.

Wei, J., Liu, X. & Liu, J. Integrating Textural and Spectral Features to Classify Silicate-Bearing Rocks Using Landsat 8 Data. Applied Science 6, 2016, 283 pp.

Zhang, J., Li, P. & Jinfei, W. Urban Built-Up Area Extraction from Landsat TM/ETM+ Images Using Spectral Information and Multivariate Texture, 2014. Remote Sensing 6.