

Estimación de áreas urbanas usando imágenes nocturnas del satélite NPP/VIIRS

Sebastián Pinto¹, Enrique S. Puliafito^{1,2}

¹ Universidad Tecnológica Nacional, Facultad Regional Buenos Aires,
Departamento de Ingeniería Industrial, Medrano 951, (C1179AAQ)
Ciudad Autónoma de Buenos Aires, Argentina

² Universidad Tecnológica Nacional, Facultad Regional Mendoza/CONICET, Rodríguez 273, 5500
Mendoza, Argentina

spinto@frba.utn.edu.ar

Recibido el 10 de febrero de 2019, aprobado el 1º de marzo de 2019

Resumen

El uso de los datos que proporcionan los satélites solo tiene como límite a la imaginación del hombre, ejemplo de esto son los trabajos sobre distribución espacial de población y su relación con el producto bruto interno o con el nivel de consumo, también su aplicación para detectar la presencia de población en zonas escasamente pobladas o bien para cuantificar la dispersión de la población en grandes aglomeraciones urbanas. Este trabajo busca establecer una metodología que permita definir los límites de las ciudades a nivel regional (Argentina) a partir de las imágenes satelitales obtenidas por el Suomi National Polar Partnership.

PALABRAS CLAVE: IMÁGENES SATELITALES NOCTURNAS - MANCHA URBANA - LÍMITES URBANOS - PROCESAMIENTO DE IMÁGENES - APRENDIZAJE SUPERVISADO

Abstract

The use of data provided by satellites is only bounded by human imagination, an example of this is the analysis of spatial distribution of the population and its correlation with GDP or consumption level, also on its implementation to detect the presence of people in sparsely populated areas or rather to quantify the distribution of population in large urban agglomerations. This work seeks to establish a methodology to define the boundaries of cities at regional level (Argentina) from satellite imagery through the Suomi National Polar Partnership

KEYWORDS: NIGHTLIGHT SATELLITE IMAGES - URBAN AREA - URBAN BOUNDARIES - IMAGES PROCESSING - SUPERVISED LEARNING

Introducción

Desde que el hombre lanzó los primeros satélites a fines de la década de 1950 el crecimiento de la presencia humana en el espacio fue exponencial. Esta situación es lógica y tiene un motivo: los satélites nos permiten ver aquello que no se ve desde la Tierra, permiten extraer información valiosa para los estados y la humanidad, permiten prevenir catástrofes, medir variaciones de temperatura o salinidad o simplemente observar cómo fluctúa el espesor de la capa de ozono en las distintas partes del globo. Estos instrumentos requieren el desarrollo de nuevas tecnologías que constantemente van desplazando la barrera tecnológica y evolutiva, cada vez a una mayor velocidad. Dentro de las funcionalidades que incluyen los satélites se encuentra la de ser capaces de tomar fotografías, no solo de la tierra "visible" sino también de las emisiones no visibles – ondas infrarrojas, emisiones de metano, radiación electromagnética, entre otras –. En la década de 1960 Estados Unidos comenzó con el Defense Meteorological Satellite Program (DMSP) el cual puso en órbita un atlas de satélites que permitió comenzar a contar con mucha información sobre lo que sucedía en la superficie de la tierra. A fines de los años 1990 se comenzaron a ver las primeras imágenes procesadas de la tierra durante la noche, esto gracias al módulo de Operational Linescan System (OLS) el cual permitía capturar imágenes de baja intensidad de luz y a partir de allí elaborar un atlas del mundo por la noche.

En el año 2011 la NASA lanzó el Suomi National Polar Partnership (SNPP) el cual incorporaba el Visible Infrared Imaging Radiometer Suite (VIIRS) un instrumento que permitió obtener los primeros datos sobre las emisiones de ondas Infrarrojas y a partir de allí desarrollar productos de mayor capacidad que los elaborados a partir del DMSP, permitiendo confeccionar un atlas de la tierra por la noche. Estas ventajas ya han sido analizadas y contrastadas en Elvidge *et al.* (2013).

Este trabajo busca establecer una metodología que permita definir los límites de las ciudades a nivel regional (Argentina) a partir de las imágenes satelitales obtenidas por el SNPP - VIIRS. Para ello se elaboró un algoritmo basado en el

reconocimiento de patrones que permita compensar los efectos de la reflectancia y saturación de los sensores – blooming and saturation – ya que estas distorsiones no permiten visualizar de forma definida estos límites (Small, C., 2003). Conocer los límites de las ciudades tiene varias implicancias: revela el comportamiento humano en lo que respecta a la distribución espacial; permite estimar el tamaño de las "manchas urbanas" y su evolución temporal; distribuir información demográfica – económica – social que se encuentra de forma puntual y que precisa estudiarse en un marco regional; desarrollar política pública contemplando su impacto local, entre muchas otras aplicaciones. En particular este estudio se encuentra dentro del marco del trabajo de investigación Adaptación y mitigación de GEI del sector transporte en Argentina y su impacto regional en la calidad de aire (Puliafito, *et al.* 2015).

Objetivos

El principal objetivo de este trabajo es lograr un método válido que permita extraer de la imagen satelital nocturna georreferenciada de la Argentina el contorno real de las ciudades analizadas. Como referencia vale destacar que en la mayoría de los casos la información georreferenciada disponible sobre ejidos urbanos no coincide o no se ajusta de forma apropiada a la situación real en parte por su permanente evolución en el tiempo, baste simplemente comparar las regiones administrativas respecto de los límites reales de las ciudades para evidenciar que son sólo algunos los casos en donde estos coinciden, mientras que en la mayoría de las regiones urbanas estas fronteras no representan la real superficie de la ciudad. Por ejemplo, la ciudad de Córdoba (Capital), tiene un límite administrativo delimitado por un polígono cuadrado de 24 km de lado (576 km²) mientras que la superficie aproximada de la ciudad con su aglomerado es de tan solo 256 km². Desde el punto de vista metodológico se aborda desde un enfoque orientado al aprendizaje supervisado debido a que se han demostrado inconsistencias cuando el límite se calcula a partir de un umbral de intensidad ya que ese método puede llevar a subvalorar o sobrevalorar los límites de la urbanización según las condiciones económico/sociales de la región analizada (Small, *et al.*, 2005; Cao, *et al.*, 2009).

Una de las ventajas que posee este enfoque es que no se ve distorsionado por la saturación de los píxeles de la imagen, ya que al no estimar datos demográficos/económicos a partir de la intensidad de los mismos el análisis no se ve afectado por los problemas que causan la saturación en intensidad y color a los píxeles de la muestra. Por el contrario, en este trabajo se afronta el problema del efecto de blooming que se da por la dispersión de la radiación de luz que se produce en la tierra sumado a la refracción que se genera en la atmósfera.

Metodología

Datos

Para este trabajo se cuenta con los siguientes conjuntos de datos:

- Imagen Geotiff *dnb.tif* (Day-Night Band) descargada desde NASA Earth Observatory and NOAA National Geophysical Data Center, la misma "was acquired over 9 days in April 2012 and 13 days in October 2012. It took satellite 312 orbits and 2.5 terabytes of data to get a clear shot of every parcel of Earth's land surface and islands".¹ FileSize: 49651429. Format: 'tif'.

Height: 13500px. Width: 13500px. BitDepth: 8. ColorType: 'truecolor'. ModelType: 'ModelTypeGeographic'. GCS: 'WGS 84'. Datum: 'World Geodetic System 1984'. Ellipsoid: 'WGS 84'. SemiMajor: 6378137. SemiMinor: 6.3568e+06. PM: 'Greenwich'. UOMAngle: 'degree'.

- Archivo ESRI Shapefile *roads.shp* (Data/Maps Copyright 2015 Geofabrik GmbH and OpenStreetMap Contributors) descargado desde la web *Geofabrik.de*² y confeccionado por la *OpenStreetMap Foundation* y su comunidad de colaboradores. Este archivo es usado como referencia para determinar los límites reales de las ciudades ya que es un atlas de todas las calles, rutas, autopistas y otros caminos de menor jerarquía de la Argentina, es decir, refleja de forma correcta la forma de las ciudades. Bounding-Box: -73.181W -55.035S; -53.525W -21.558S. ShapeType: 'PolyLine'. NumFeatures: 599565.

- Archivo ESRI Shapefile *010_Ejidos_Urbanos.shp* (Instituto Geográfico Nacional de la República Argentina) descargado desde la web del IGN³. Este archivo contiene polígonos que representan la superficie de los ejidos urbanos de las distintas ciudades argentinas y se usará



Fig. 1. Ejemplo de recortes de imagen



Fig. 2. Ejemplo de extracción píxel por píxel de la información RGB



Fig. 3. Extracción de clases para la ciudad de Paraná

para comparar los resultados obtenidos por este proyecto en conjunto al *shapefile roads.shp*. *BoundingBox: -72.894W -54.832S; -53.642W -21.940S. ShapeType: 'Polygon'. NumFeatures: 2386.*

Pre-procesamiento de los datos

Debido al tamaño de la imagen y la gran cantidad de memoria que requeriría para ser procesada entera – ya que abarca toda la Argentina – este trabajo se debió realizar circunscripto al área que rodea a una serie de ciudades elegidas para este análisis, esto implicó la creación de recortes de la imagen satelital alrededor de las mismas tal como se puede observar en Figura 1.

Para el procesamiento era necesario poder contar con la información de cada pixel de la imagen ya que es a través de los píxeles que se puede clasificar si ese punto pertenece a la ciudad o no, es por esto que las imágenes RGB satelitales se descompusieron en una matriz compuesta en sus filas por los distintos píxeles y donde sus columnas representaban el valor de cada color para ese pixel, 3 columnas, una para el Rojo (R) otra para el Verde (G) y otra para el Azul (B) (Figura 2).

Los algoritmos de aprendizaje supervisado requieren que se les suministre un conjunto de entrenamiento, es decir, en conjunto de datos en los que se conoce la etiqueta de clase, en este caso el valor es 1 si pertenece al interior de la ciudad y (-1) si no pertenece. Para generar el entrenamiento se destinaron las imágenes suburbanas de Junín y Paraná. En estas ciudades se extrajeron dos polígonos definidos

visualmente, uno para la categoría "ciudad" y otro para la categoría "no ciudad" de acuerdo a la densidad de calles obtenidas en el archivo.

La Figura 3 muestra este procedimiento para la ciudad de Paraná. Luego para el conjunto de evaluación se utilizaron las imágenes suburbanas sin alteraciones ni indicadores adicionales, porque se busca que sobre ellas sea el algoritmo el que clasifique qué puntos (píxeles) pertenecen a la categoría "ciudad" y qué puntos no.

Métodos de clasificación

Para la clasificación de los píxeles se adoptaron dos métodos: por un lado el método de k-vecinos más cercanos (KNN por sus siglas en inglés) el cual consiste en un método sencillo que clasifica un punto nuevo en función del conjunto de puntos más cercanos que encuentra: primero mide la distancia entre el nuevo punto y todos los del conjunto de entrenamiento; luego selecciona a los k más cercanos; por último pondera la etiqueta que poseen estos k vecinos más cercanos y en función de esto le otorga la etiqueta al punto nuevo, es un método relativamente sencillo de implementar, con un bajo costo computacional y muy efectivo cuando la dimensionalidad del conjunto es baja – en nuestro caso: 3 dimensiones –. El segundo método utilizado es el de *Support Vector Machines* (SVM) (Cristianini and Shawe-Taylor, 2000) el cual es un método sofisticado basado en la teoría estadística del aprendizaje. El algoritmo del SVM⁴ puede ser formulado como el siguiente problema de optimización:

⁴ Cristianini, N., Shawe-Taylor, J., 2000. An Introduction to Support Vector Machines: and Other Kernel-based Learning Methods. Cambridge Univ Pr.

$$\min_w \frac{1}{2} w^T \cdot w + C \cdot \sum_{n=1}^N \xi_n$$

sujeto a

$$y_i (\langle w^T, x_i \rangle + b) \geq 1 - \xi_n \quad \wedge \quad \xi_n \geq 0$$

donde desde el enfoque dual de optimización la solución puede ser escrita como

$$d(x, \alpha', b') = \text{sign} \left(\sum_{sv} \alpha_i' \cdot y_i \cdot \langle x, x_i \rangle + b' \right) \text{ aplicando transformación no lineal}$$

$$d(x, \alpha', b') = \text{sign} \left(\sum_{sv} \alpha_i' \cdot y_i \cdot \langle \phi(x), \phi(x_i) \rangle + b' \right) \text{ el cual puede ser calculado a través del "kernel trick"}$$

$$\langle \phi(x), \phi(x_i) \rangle = k(x, x_i) \text{ y finalmente } d(x, \alpha', b') = \text{sign} \left(\sum_{sv} \alpha_i' \cdot y_i \cdot k(x, x_i) + b' \right)$$

$$\text{usando kernel gaussiano } k(x, x_i) = \exp \left\{ -\frac{1}{2\sigma^2} \cdot \|x - x_i\|^2 \right\}$$

En líneas generales, lo que busca este método es minimizar las diferencias al cuadrado en un espacio de mapeo de mayor dimensionalidad. Este planteo genera una transformación de la función de mapeo $\phi(x)$ hacia un espacio de dimensión infinita, conocido como espacio de Hilbert, donde el conjunto de datos es linealmente separable por un hiperplano. Se seleccionó un kernel gaussiano dado que se considera una buena aproximación inicial y posee una respuesta suave. Entonces existen dos parámetros ajustables del (σ, C)

Donde:

σ es el ancho de banda del kernel gaussiano y C el costo de penalización.

Al minimizar la relación $\frac{1}{2} w^T \cdot w$ lo que se busca es maximizar el margen entre los hiperplanos frontera de ambos conjuntos – el conjunto de los valores que pertenecen a la clase 1 del conjunto de valores que pertenecen a la clase (-1) –.

Para la determinación de los parámetros (σ, C, K) se realizó un proceso de validación cruzada utilizando el set de entrenamiento de la información extraída de la ciudad de Paraná y como conjunto de validación la información extraída de la ciudad de Junín, esto permite encontrar los parámetros óptimos para los clasificadores que maximizan su eficacia.

Reconstrucción de la imagen

Así como para la construcción de los conjuntos de entrenamiento y prueba se descompuso la imagen en una matriz que contenía los pixeles ahora se debe, en función de la etiqueta otorgada por el clasificador, reconstruir la imagen con el resultado. Para esto se realiza una nueva imagen (imagen*), que mantiene las proporciones y georreferenciación de la imagen original, donde para los valores iguales a (1) se le otorga un color RGB = [255, 255, 255] – blanco – y para los valores iguales a (-1) un color RGB = [0, 0, 0] – negro –. Debido a que esta imagen ficticia no se puede utilizar para construir nuevamente un geotiff – por la menor cantidad de valores que posee – la imagen final (final) surge de la diferencia entre la imagen resultado y la imagen original:

$$\text{final}(i, j) = \text{imagen}^*(i, j) - \text{test}(i, j) -$$

donde:

(i, j) son los pixeles de la imagen

Discusión

En función de los resultados se puede observar visualmente que el algoritmo logra el propósito esperado, con un resultado ajustado al *shapefile* Ejidos_urbanos.shp tal como se puede apreciar en la Figura 4.

Como el resultado visual no puede ser tomado como una medida objetiva de "ajuste" se pensó un método a través del cual se pudiese cuantifi-

car la diferencia entre los distintos sets de datos que se disponen – roads.shp, resultado del algoritmo e información del IGN –. Para lograr esto se compararon y contrastaron tanto las áreas de los polígonos analizados así como sus centroides (o centros de masa).

A partir de los resultados del análisis de estos dos clasificadores podemos apreciar que la distancia entre los centroides de ambos es considerablemente baja – unos 380 metros en promedio – esto indica que ambos distribuyen el área de forma homogénea. A su vez el clasificador por KNN estima en promedio un área de ciu-

dad un 16% menos que el SVM, esto puede deberse a la lógica subyacente en la cual se basa el método de KNN, mostrando resultados muy interesantes donde llega a detectar tan solo 1 píxel ocupado por un gran parque como zona de no ciudad, esto indica que posee una gran capacidad de aprendizaje y un gran nivel de detalle (caso de la zona de parque alrededor de la planta de tratamiento de líquidos cloacales en Córdoba Capital).

Para la comparación se elaboraron dos indicadores – trabajados de a pares –: por un lado, una diferencia de áreas (entre los *shapes* arrojados


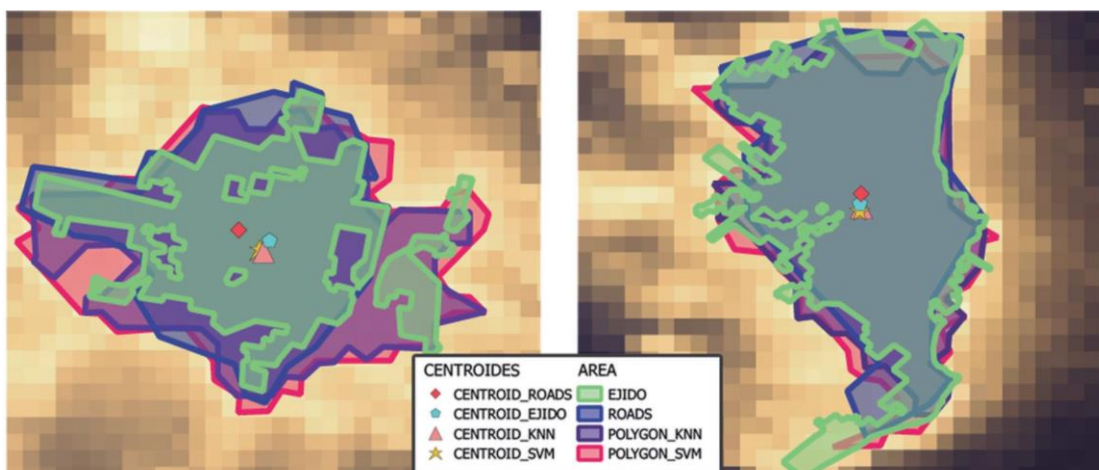


Fig. 4. Comparación visual de los resultados entregados por los clasificadores. a) Córdoba, b) Chajarí, c) Mar del Plata, d) Mendoza, e) Rosario, f) San Luis y g) San Miguel de Tucumán



Detalle de polígonos resultantes de la clasificación y sus centroides para la ciudad de Tucumán

Detalle de polígonos resultantes de la clasificación y sus centroides para la ciudad de Mar del Plata

Fig. 5. Detalle de clasificación y centroides

por el clasificador frente a los utilizados como referencias provenientes del IGN y del proyecto *OpenStreetMap*), y por el otro una comparación de distancias entre baricentros (de los mismos *shapes*). Excluyendo la clasificación de Mendoza, debido a que la zona urbana se encuentra compuesta por pequeños municipios adyacentes, y esto repercute de forma directa sobre qué es considerado ciudad y qué no, se puede observar que el clasificador KNN proporciona polígonos tan solo un 15% por encima de la su-

perficie considerada a partir del *shapefile roads.shp*, y donde el clasificador por SVM lleva esta cifra a alrededor del 39% en promedio.

En la mayoría de los casos ambos clasificadores proporcionaron regiones urbanas superiores al *shapefile* de *roads.shp* y muy superiores al *shapefile* de *Ejidos_urbanos.shp*, demostrando principalmente la escasa correlación que posee este último frente a la superficie real de las ciudades. El análisis de la distancia entre baricentros arroja

Tabla 1. Distancia entre centroides

Ciudad	Distancia entre centroides				
	KNN vs Roads	KNN vs Ejidos	SVM vs Roads	SVM vs Ejidos	KNN vs SVM
	km	km	km	km	km
Chajari, Entre Rios	1.03	0.94	1.10	1.03	0.14
Cordoba Capital, Cordoba	0.95	1.31	0.50	0.81	0.86
Mar del Plata, Buenos Aires	0.62	0.16	0.81	0.34	0.19
Mendoza Capital, Mendoza	3.17	1.91	3.68	2.38	0.50
Rosario, Santa Fe	2.64	1.27	3.07	1.39	0.43
San Luis Capital, San Luis	1.49	0.86	1.38	1.19	0.34
San Miguel de Tucuman, Tucuman	1.39	0.54	1.24	0.58	0.17
Media	1.61	1.00	1.68	1.10	0.38
Desvío	94.3%	56.6%	120.4%	66.7%	25.4%
Media sin Mendoza	1.35	0.85	1.35	0.89	0.36

Tabla 2. Áreas totales por shapefile y variación entre los clasificadores y las superficies de referencia

Ciudad	Área Urbana				Diferencia entre ellas					Media	Desvío
	KNN km2	SVM km2	roads.shp km2	Ejido_urbano.shp km2	KNN vs Roads %	KNN vs Ejidos %	SVM vs Roads %	SVM vs Ejidos %	KNN vs SVM km2		
Chajari, Entre Rios	6.75	9.26	10.32	7.95	-34.6%	-15.1%	-10.3%	16.5%	-0.27	8.57	1.56
Cordoba Capital, Cordoba	292.03	356.22	241.83	222.99	20.8%	31.0%	47.3%	59.7%	-0.18	278.27	59.58
Mar del Plata, Buenos Aires	118.08	130.41	125.86	125.03	-6.2%	-5.6%	3.6%	4.3%	-0.09	124.85	5.09
Mendoza Capital, Mendoza	259.74	311.02	121.91	128.34	113.1%	102.4%	155.1%	142.3%	-0.16	205.25	94.90
Rosario, Santa Fe	258.01	303.91	189.56	138.08	36.1%	86.9%	60.3%	120.1%	-0.15	222.39	73.26
San Luis Capital, San Luis	56.26	68.84	35.18	28.58	59.9%	96.9%	95.7%	140.9%	-0.18	47.22	18.63
San Miguel de Tucuman, Tucuman	143.58	165.37	121.28	91.40	18.4%	57.1%	36.4%	80.9%	-0.13	130.41	31.62
Media					29.63%	50.50%	55.45%	80.69%	-16.81%		
Desvío					47.5%	48.4%	56.3%	56.8%	5.5%		
Media sin Mendoza					15.73%	41.85%	38.83%	70.41%	-16.86%		

conclusiones mucho más interesantes y robustas, ya que muestra una gran cercanía entre los baricentros de ambos clasificadores frente a los otros dos *datasets*.

Sin embargo, es en las ciudades más pequeñas donde se encuentra la menor distancia entre los baricentros de los clasificadores, permitiendo suponer que ambos se han desviado en forma proporcional frente a los otros shapefiles. La Figura 5 muestra en detalle esta situación: en la ciudad de Tucumán la distancia entre el baricentro del polígono resultado del KNN y el de SVM es de aproximadamente 170 metros, mientras que en Mar del Plata esta distancia ronda los 190 metros.

En la Tabla 1 se proporcionan todos los resultados obtenidos, revelando esta característica de la clasificación en las ciudades más pequeñas. Es interesante remarcar que, nuevamente, Mendoza presenta los valores de desvío más elevados y es aquí donde juega un rol fundamental el enfoque administrativo al momento de definir, desde nuestro punto de vista, que consideraremos zona urbana de aquella suburbana, y es porque esta diferenciación se ve reflejada tanto en el *shapefile roads.shp* como en *Ejidos_urbanos.shp*. Algo similar sucede en la zona de Rosario, donde la distancia entre baricentros aumenta considerablemente, debiéndose fundamentalmente a que en los *shapefile de roads.shp* y *Ejidos_urbanos.shp* se encuentran de forma separada la zona de Rosario, San Lorenzo y el gran Rosario; mientras que para los clasificadores esto es un único aglo-

merado urbano, asignándole toda la superficie – de marcada distribución Norte-Sur – a este polígono y por ende variando significativamente la posición de su baricentro. En la Tabla 2 se resume el tamaño del área asignada a la ciudad según cada clasificador, por lo general ambos clasificadores arrojan superficies mayores a las actuales, esto es mayormente debido a que durante la clasificación se considera toda la extensión de la mancha urbana interconectada, mientras que los otros *shapefiles* o están concebidos desde un enfoque administrativo (*Ejidos_urbanos.shp*) o bien como la frontera estrictamente vial (*roads.shp*).

A modo de resumen se adjuntan las Figuras 6 y 7. En la Figura 6 se resumen, para cada ciudad, las áreas que le asigna cada polígono, evidenciando una mayor superficie para ambos clasificadores frente a las fuentes de referencia. La Figura 7 muestra la variación, para cada ciudad y para cada comparador, de un ratio que pondera la distancia entre los centroides respecto del área media estimada de esa ciudad. Esto permite poner en perspectiva los resultados obtenidos: evidencia una mayor tasa de dispersión en las ciudades más pequeñas, esto puede tener una explicación relacionada con la definición de los sensores si bien debería correrse análisis posteriores para profundizar en los motivos. A su vez, en todos los casos se demuestra una caída de este ratio para la distancia entre los centroides de cada clasificador, indicando que la exactitud de ambos es similar.

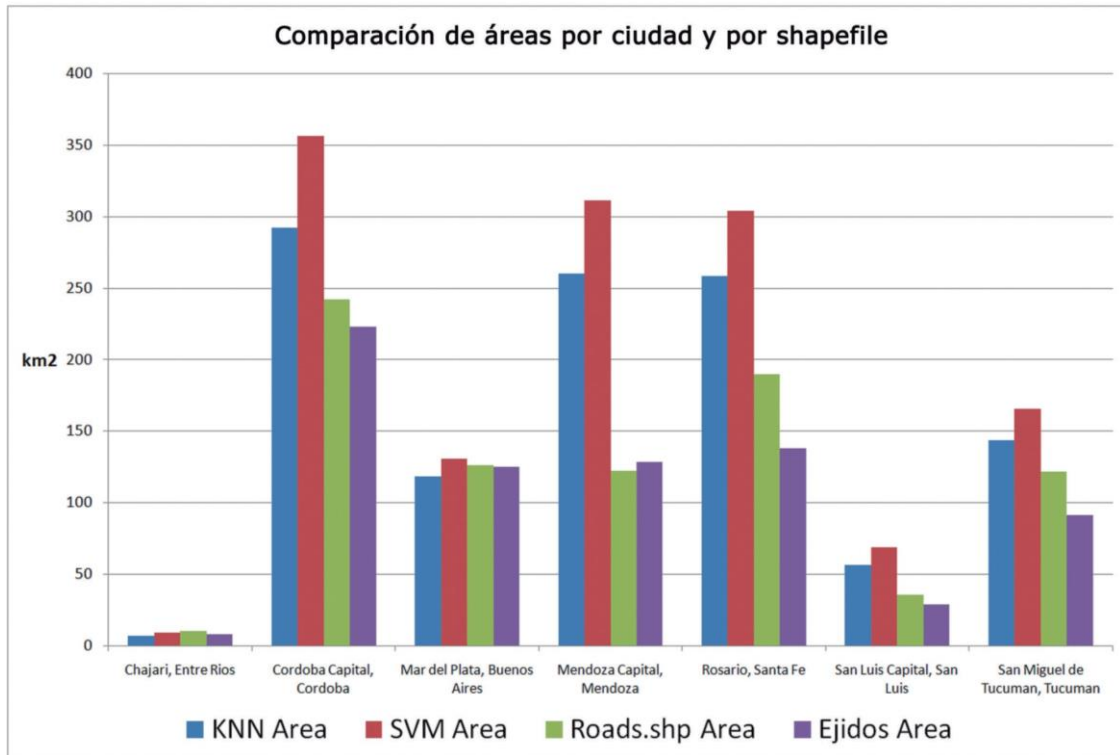


Fig. 6. Comparación gráfica entre la superficie estimada para cada ciudad

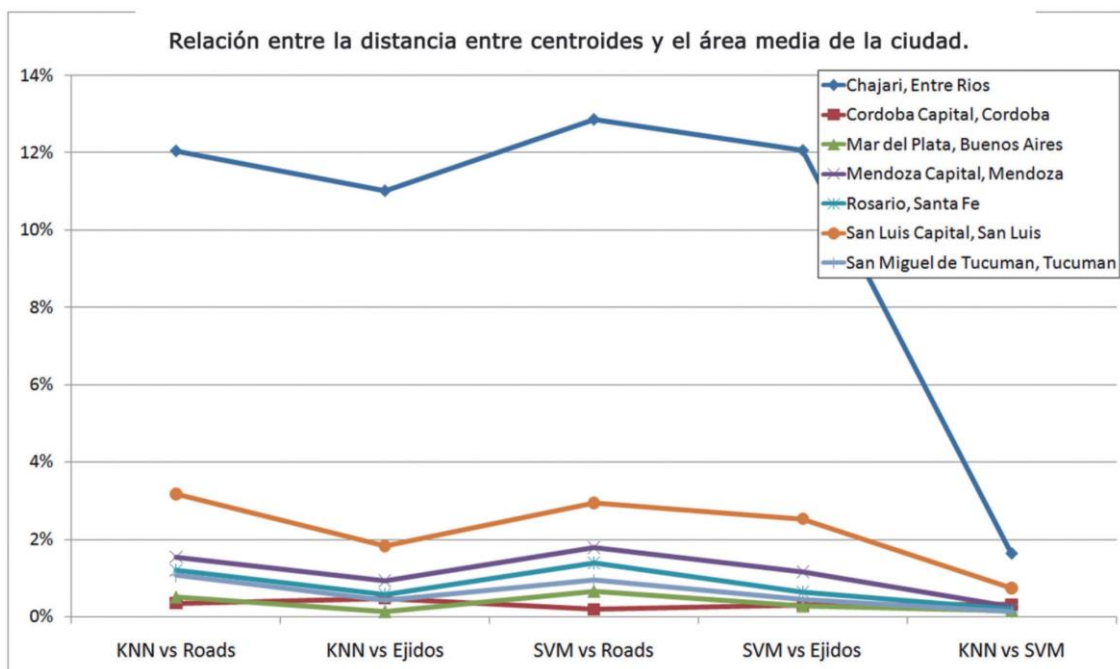


Fig. 7. Ratio de proporcionalidad - Distancia entre centroides sobre la superficie promedio de la ciudad

Conclusiones

A partir de este trabajo se ha podido observar la importancia de las imágenes satelitales nocturnas de alta resolución así como la posibilidad de extender este enfoque y aplicarlo a la correlación de estos resultados con datos demográficos, sociales y económicos.

Se ha podido demostrar que la implementación de estos dos métodos de aprendizaje supervisado – KNN y SVM – permiten discriminar los límites de una ciudad, conservando en las grandes ciudades un buen ajuste de su baricentro frente a los datasets actualmente disponibles. Este ajuste es aún más apreciable de forma visual, donde se observa que las imágenes resultado responden de forma ajustada al contorno de las ciudades, incluso clasificando zonas puntuales en la mínima resolución de 1 píxel.

Los resultados numéricos que surgen de comparar las imágenes clasificadas – y por consiguiente las regiones poligonales que arrojan – frente a los dataset actuales permiten suponer que es posible utilizar estos resultados

de forma correcta para determinar los límites de las ciudades a nivel regional, reforzando el potencial y las posibilidades que ofrece el uso de imágenes satelitales a escala local, permitiendo contar con un dataset de mayor fidelidad y, principalmente, más robusto.

Agradecimientos

Los autores agradecen a la Universidad Tecnológica Nacional y al Consejo Nacional de Investigaciones Científicas y Técnicas por apoyar las actividades de esta investigación. Este trabajo es parte de los proyectos UTN IFI PID 1799 y 1487 y CONICET PIP 112 201101 00673 y PICT 2012-1021.

Referencias

- AMARAL, S.; CÂMARA, G.; VIEIRA MONTEIRO, A.M.; QUINTANILHA, J.A. y ELVIDGE, C.D., (2003). Estimating population and energy consumption in Brazilian Amazonia using DMSP night-time satellite data. *Computers, Environment and Urban Systems*, 29, 179-195.
- CAO, X.; CHEN, J.; IMURA, H. y HIGASHI, O., (2009). A SVM-based method to extract urban áreas from DMSP-OLS and SPOT VGT data. *Remote Sensing of Environment*, 113, 2205–2209.
- CHING, J.; HERWEHE, J. y SWALL, J., (2005). On joint deterministic grid modeling and sub-grid variability conceptual framework for model evaluation. *Atmospheric Environment*, 40, 4935–4945.
- DOLL, C.N.H.; MULLER, J.P. y MORLEY, J.G., (2005). Mapping regional economic activity from night-time light satellite imagery. *Ecological Economics*, 57, 75– 92.
- ELVIDGE, C.D.; BAUGH, K.; ZHIZHIN, M. y CHI HSU, F., (2013). Why VIIRS data are superior to DMSP for mapping night-time lights. *Proceedings of the Asia-Pacific Advanced Network*, 35, 62-69.
- IMHOFF, M. L.; LAWRENCE, W. T.; STUTZER, D. C. y ELVIDGE, C. D., (1997). A technique for using composite DMSP-OLS "City Lights" satellite data to map urban área. *Remote Sensing of Environment*, 61, 361–370.
- LEVIN, N. y DUKE, Y., (2012). High spatial resolution night-time light images for demographic and socio-economic studies. *Remote Sensing of Environment*, 119, 1–10.
- MA, T.; ZHOU, Y.; ZHOU, C.; HAYNIE, S.; PEI, T. y XU, T., (2015). Night-time light derived estimation of spatio-temporal characteristics of urbanization dynamics using DMSP/OLS satellite data. *Remote Sensing of Environment*, 158, 453–464.
- PULIAFITO, S.E., ALLENDE, D., PINTO, S., CASTESANA, P., (2015). High resolution inventory of GHG emissions of the road transport sector in Argentina. *Atmospheric Environment*, 101, 303-311.
- RAUPACH, M.R., RAYNER, P.J., PAGET, M., (2009). Regional variations in spatial structure of nightlights, population density and fossil-fuel CO2 emissions. *Energy Policy*, 38, 4756–4764.
- SMALL, C., (2003). High spatial resolution spectral mixture analysis of urban reflectance. *Remote Sensing of Environment*, 88, 170-186.
- SMALL, C., POZZI, F., ELVIDGE, C.D. (2005). Spatial analysis of global urban extent from DMSP-OLS night lights. *Remote Sensing of Environment*, 96, 277 – 291.