



Explorando el uso de herramientas de sensores remotos y tecnologías geoespaciales aplicadas al problema multidimensional de la seguridad alimentaria

Exploring the use of remote sensing tools and geospatial technologies applied to the multidimensional food security problem

Explorando o uso de ferramentas de sensoriamento remoto e tecnologias geoespaciais aplicadas ao problema multidimensional da segurança alimentar

Eliana Marina Álvarez Di Fino [†] ^{1,2}, Carlos Matias Scavuzzo ^{1,2,3}, Micaela Natalia Campero ^{1,2,3*}, Carlos Marcelo Scavuzzo ¹, María Daniela Defagó ^{2,3,4}

Received: Oct/12/2021 • Accepted: May/19/2022 • Published: Nov/1/2022


Resumen

[Objetivo] El objetivo de este estudio fue analizar qué papel pueden jugar las tecnologías de teledetección para estudiar los factores multidimensionales que influyen en la seguridad alimentaria y nutricional (SAN), en Córdoba Argentina. **[Metodología]** El área de estudio comprende la ciudad de Córdoba, Argentina. Se obtuvieron datos epidemiológicos de la prevalencia de bajo peso, sobrepeso y obesidad (malnutrición) durante el 2013 de 23 centros de atención primaria de la ciudad. Se exploraron las condiciones ambientales de los centros en un radio de 1000 m. Se clasificaron imágenes SPOT 5, se utilizaron características espectrales y espaciales y se evidencia cómo una clasificación no supervisada puede dar información para describir la dimensión social y el acceso económico a los alimentos. Se realizó una regresión lineal multivariante para examinar la relación entre la prevalencia de malnutrición y las variables ambientales y espaciales, derivadas de las imágenes SPOT. **[Resultados]** Los resultados de la clasificación no supervisada de imágenes muestran la diferencia en el patrón espectral-espacial de los barrios, evidencian cómo una simple clasificación de imágenes de satélite puede convertirse en una herramienta de discriminación útil. Se obtienen análisis de regresión múltiple con R² ajustados de 0,70 y

* Corresponding author

Eliana Marina Álvarez Di Fino [†], ✉ mddefago@unc.edu.ar,  <https://orcid.org/0000-0001-5039-9177>

Carlos Matias Scavuzzo, ✉ matiascavuzzo@fcm.unc.edu.ar,  <https://orcid.org/0000-0002-1717-3923>

Micaela Natalia Campero, ✉ mncampero@fcm.unc.edu.ar,  <https://orcid.org/0000-0001-7821-4293>

Carlos Marcelo Scavuzzo, ✉ scavuzzo@conae.gov.ar,  <https://orcid.org/0000-0003-0905-6361>

María Daniela Defagó, ✉ mddefago@unc.edu.ar,  <https://orcid.org/0000-0002-8878-3067>

1 Instituto de Altos Estudios Espaciales “Mario Gulich”, Comisión Nacional de Actividades Espaciales, Universidad Nacional de Córdoba, Falda del Cañete, Argentina.

2 Escuela de Nutrición, Facultad de Ciencias Médicas, Universidad Nacional de Córdoba, Córdoba, Argentina.

3 Consejo Nacional de Investigaciones Científicas y Técnicas, Córdoba, Argentina.

4 Instituto de Investigaciones en Ciencias de la Salud (INICSA-CONICET), Universidad Nacional de Córdoba, Argentina.



0,6435 respectivamente para desnutrición, y sobrepeso y obesidad. A partir de los modelos obtenidos, se construyen mapas continuos de prevalencia. **[Conclusiones]** El método propuesto en este trabajo puede discriminar socialmente diferentes áreas relacionadas con la SAN. Es innovador y necesario aprovechar las herramientas de teledetección y las tecnologías geoespaciales, en nuestra región, aplicadas a la SAN.

Keywords: Seguridad alimentaria; teledetección; tecnologías geoespaciales; cartografía de riesgos.

Abstract

[Objective] The aim of this study was to analyze which role remote sensing technologies can play to study multidimensional factors influencing the Food and Nutrition Security (FNS), in Córdoba Argentina. **[Methodology]** The study area includes the city of Córdoba, Argentina. Epidemiological data on the prevalence of underweight, overweight, and obesity (malnutrition) in 2013 were obtained from 23 primary health care centers in the city. The environmental conditions of the surroundings of the health centers were explored within a radius of 1000m. SPOT 5 images were classified using spectral and spatial features and we show how a non-supervised classification can give information to describe the social dimension and economic access to food. In addition, a multivariate stepwise linear regression was performed to examine the relation between the prevalence of malnutrition and the environmental and spatial variables, derived from the SPOT image, proposed. **[Results]** The results of the unsupervised image classification show the difference in the spectral-spatial pattern of neighborhoods showing how a simple satellite image classification can become a useful discrimination tool. Multiple regression analyses with adjusted R² of 0.70 and 0.6435 respectively are obtained for undernutrition, and overweight, and obesity. On the basis of the obtained models, continuous maps of prevalence are built. **[Conclusions]** The method proposed in this work can discriminate socially different areas related to FNS. It is innovative and necessary to take advantage of remote sensing tools and geospatial technologies, in our region, applied to FNS.

Keywords: Food Security; remote sensing; geospatial technologies; risk mapping

Resumo

[Objetivo] O objetivo deste estudo foi analisar o papel que as tecnologias de sensoriamento remoto podem desempenhar no estudo dos fatores multidimensionais que influenciam a segurança alimentar e nutricional (SAN) em Córdoba, Argentina. **[Metodologia]** A área de estudo compreende a cidade de Córdoba, Argentina. Dados epidemiológicos sobre a prevalência de baixo peso, sobrepeso e obesidade (desnutrição) durante 2013 foram obtidos de 23 centros de atenção primária à saúde da cidade. As condições ambientais dos locais foram exploradas dentro de um raio de 1000 m. As imagens do SPOT 5 foram classificadas e as características espectrais e espaciais utilizadas, e o que se mostra é como uma classificação sem supervisão pode fornecer informações para descrever a dimensão social e o acesso econômico aos alimentos. A regressão linear multivariada foi realizada para examinar a relação entre a prevalência da desnutrição e as variáveis ambientais e espaciais derivadas das imagens de SPOT. **[Resultados]** Os resultados da classificação da imagem não supervisionada mostram a diferença no padrão espectral-espacial dos bairros, evidenciando como uma simples classificação da imagem de satélite pode se tornar uma ferramenta útil de discriminação. São obtidas as análises de regressão múltipla com R² ajustado de 0,70 e 0,6435 respectivamente para desnutrição, sobrepeso e obesidade. Os mapas de prevalência contínua são construídos a partir dos modelos obtidos. **[Conclusões]** O método proposto neste trabalho



pode discriminar socialmente diferentes áreas relacionadas à SAN. É inovador e necessário tirar proveito de ferramentas de sensoriamento remoto e tecnologias geoespaciais, em nossa região, aplicadas à SAN.

Palavras-chave: Segurança alimentar; sensoriamento remoto; tecnologias geoespaciais; mapeamento de risco.

Introducción

Si bien el mundo tiene la capacidad de producción de alimentos suficientes para toda la población, el hambre y la malnutrición, ya sea por exceso o por déficit, constituyen los problemas más importantes que afronta la humanidad (Knight, 2011). En este contexto, la definición de seguridad alimentaria y nutricional (SAN) ha evolucionado durante las últimas décadas y surge como un derecho humano a la alimentación adecuada (Bianchi & Szpak, 2016). La SAN existe cuando todas las personas, en todo momento, tienen acceso físico, social y económico a alimentos suficientes, inocuos y nutritivos para satisfacer sus necesidades y preferencias alimenticias para una vida activa y saludable (Traoré et al., 2012). La expresión SAN representa, de manera integral, la problemática alimentaria y nutricional, debido a que involucra todos los aspectos y actores que forman parte de los sistemas alimentarios; es por ello que su análisis se hace con base en sus cuatro dimensiones que la determinan: disponibilidad, accesibilidad, estabilidad y utilización biológica de los alimentos.

Por el contrario, la inseguridad alimentaria (IAN) se manifiesta de dos maneras: por exceso (sobrepeso, obesidad y enfermedades asociadas) o deficiencia (desnutrición, déficit de micronutrientes). Más aún, en una ciudad, una familia o una persona pueden reflejar ambas formas de IAN

(Ashe & Sonnino, 2013; Popkin & Gordon-Larsen, 2004).

En Argentina, como en muchos países de Latinoamérica, la disponibilidad de alimentos excede los requerimientos nutricionales de la población (Smith et al., 2017). Sin embargo, la situación epidemiológica nutricional actual refleja la carencia de SAN en la población; presenta, en los sectores sociales más vulnerables, una alta prevalencia de desnutrición y de sobrepeso (Britos, 2008; Linetzky et al., 2011). La desnutrición persistente tiene consecuencias a largo plazo y limita el desarrollo potencial de una sociedad, con costos en términos sanitarios y humanos (Elgart et al., 2010; Traoré et al., 2012).

En este escenario, en donde el entorno que habitan las personas juega un rol importante en la distribución y frecuencia de las enfermedades, las tecnologías geoespaciales podrían contribuir al análisis de la SAN de las comunidades.

Marco teórico

Tradicionalmente, la aplicación de tecnologías geoespaciales para el estudio de la SAN se ha orientado a abordar cuestiones tendientes a la dimensión de disponibilidad (y vinculada a la estabilidad) de la SAN, particularmente relacionadas con la producción de alimentos y, por ende, centradas en la agricultura. En el pasado, el sensor Advanced Very High Resolution Radiometer



(AVHRR) del satélite de National Oceanic and Atmospheric Administration (NOAA) se ha utilizado en la planificación agrícola, la previsión y el monitoreo de la sequía y la estimación de rendimientos. Asimismo, Justice y colaboradores en 1985 (Justice et al., 1985), utilizaron el Normalized Difference Vegetation Index (NDVI) para evaluar los cambios fenológicos en la vegetación, ocurridos durante las estaciones tanto a nivel global como subcontinental (África, América del Sur y Asia Oriental). Más aún, en un contexto de cambio climático, históricamente las sequías han sido imputadas como la causa principal de las emergencias alimentarias. En esta línea (Helldén & Eklundh, 1988; Johnson et al., 1993), se utilizan datos de NDVI de NOAA y precipitación para evaluar el impacto de la sequía sobre la producción agrícola en África. Más recientemente, el trabajo de Kogan (Kogan et al., 2015), hace uso de las nuevas características del sensor Visible Infrared Imaging Radiometer Suite (VIIRS) mejorando la detección temprana de sequías, monitoreando la intensidad, duración, área, origen e impactos; intentando así estimar y predecir la escasez de alimentos. Cabe destacar que este conjunto de radiómetros de imágenes visibles e infrarrojas es particularmente útil, ya que cuenta con el potencial de generar imágenes de 22 bandas incluyendo día/noche y un canal visible diseñado para obtener imágenes de la tierra y atmósfera en todas las condiciones, ya sea con iluminación solar, lunar o externa insignificante (Lee et al., 2006).

Referido también a la misma dimensión de disponibilidad y, particularmente relacionado con la agricultura urbana, Kemelin (Kemeling, 2001) utilizó una serie temporal de imágenes de alta resolución (obtenidas del satélite IKONOS) para el

estudio de la dinámica de la agricultura urbana en Ouagadougou y Burkina Faso. En adición, Chen (Chen, 2007) utilizó imágenes de Landsat para describir el impacto del proceso de urbanización en China y sus consecuencias sobre las áreas destinadas al cultivo de alimentos. Más aún, con base en el surgimiento del satélite Sentinel 2, cuya misión facilitó información útil para las prácticas agrícolas y forestales y para gestionar la seguridad alimentaria, con mejoras en la resolución (10-20 m) y la revisita (5 días) (Sepulcre Canto et al., 2014); Valero y colaboradores (Valero et al., 2015) desarrollaron un sistema de clasificación supervisada con el objetivo de construir un mapeo dinámico de áreas cultivadas.

Por último y con un enfoque más operativo, la Organización de las Naciones Unidas para la Agricultura y la Alimentación (FAO) ha utilizado datos de teledetección satelital de baja resolución para monitorear el desarrollo de la vegetación y las lluvias en grandes áreas casi en tiempo real a través del proyecto ARTEMIS (Hielkema & Snijders, 1994). En este sentido, el Global Information and Early Warning System on Food and Agriculture (GIEWS) de la FAO sobre alimentación y agricultura (<http://www.fao.org/giews/background/en/>) es uno de los principales usuarios de los datos de ARTEMIS. Este monitorea el suministro y demanda de alimentos para todos los países del mundo, de forma continua, y proporciona alertas de escasez inminente de alimentos, sequías y hambre a nivel nacional o subregional. En particular, GIEWS utiliza fuertemente las imágenes satelitales de coberturas de nubes, NDVI y condiciones de cultivos (Minamiguchi, 2005).

De acuerdo con lo anteriormente dicho, el aporte de las tecnologías geoespaciales al estudio de la disponibilidad (y



estabilidad) alimentaria es sólido e histórico. No obstante, las dimensiones de la SAN más vulnerables, y menos abordadas, son el acceso y la utilización biológica de los alimentos; más aún en países de medianos y bajos ingresos en donde la SAN se vincula a la estratificación socioeconómica y las necesidades básicas insatisfechas (NBI) (Salvia et al., 2012; FAO, 2016).

Vinculado a estas últimas dimensiones mencionadas, es pertinente destacar que la Agencia de los Estados Unidos para el Desarrollo Internacional (USAID) diseñó el Sistema de alerta temprana contra la hambruna, en 1986, para proporcionar información sobre la seguridad alimentaria de las comunidades en regiones semiáridas. Este usa datos de vegetación obtenidos de AVHRR/NOAA, MODIS y Satellite Pour l'Observation de la Terre (SPOT), además de la precipitación. Con estos datos se construyen modelos agrometeorológicos para evaluar el estado de los cultivos (Brown, 2008). Este sistema no solo aborda la disponibilidad de alimentos, sino que los datos ambientales provistos por teledetección se analizan junto con los datos socioeconómicos (medios de subsistencia, comercio y mercado) para determinar el impacto de estas variables sobre la SAN.

Asimismo, López Carr y colaboradores (López-Carr et al., 2015) estudiaron la relación entre la malnutrición infantil y el cambio climático. En esa contribución mostraron que la vulnerabilidad general al retraso en el crecimiento del niño es mayor en las áreas que experimentan un aumento en la precipitación junto con un cambio negativo en el índice de vegetación. En esta dirección, Johnson y colaboradores (Johnson et al., 2013) utilizaron MODIS para estudiar cómo el bosque nativo influye en la utilización biológica. Los

bosques desempeñan un importante papel de aprovisionamiento, específicamente en términos de disponibilidad y calidad del agua. Sus resultados demuestran una asociación entre la cobertura forestal y disminución en la prevalencia de diarrea infantil.

Más aún, y en adición al estudio de las últimas dimensiones mencionadas, un claro ejemplo de geomática en aplicaciones específicas sobre pobreza y vulnerabilidad socioeconómica es la utilización de redes neuronales convolucionales y sensado remoto en el que las intensidades de luz nocturna se utilizan como un proxy, a partir de imágenes diurnas, aprendiendo simultáneamente características útiles para la predicción de la pobreza (Xie et al., 2016).

Esta breve revisión sobre el uso de sensores remotos aplicados a la seguridad alimentaria deja en evidencia que gran parte de las experiencias previas apuntan a utilizar la información satelital para abordar la producción agrícola, como principal determinante de la disponibilidad de alimentos. Recientemente y en menor medida, algunas experiencias muestran el potencial de estas herramientas para estudiar otros factores que influyen en el acceso a los alimentos y la utilización biológica (Johnson et al., 2013; López-Carr et al., 2015). En este marco, el objetivo principal de este estudio es explorar el papel de la teledetección y las herramientas geoespaciales para estudiar los factores que influyen en la SAN (y particularmente en sus dimensiones de accesibilidad y utilización biológica) en un marco multidimensional. Con estos fines y a modo de ejemplo, se abordará lo propuesto evaluando aspectos de la SAN en la ciudad de Córdoba, un área urbana con más de 1,5 millones de habitantes en la parte central de Argentina.



Metodología

Se tomó como área de estudio la Ciudad de Córdoba, capital de la provincia de Córdoba, Argentina. Considerando que las prevalencias de malnutrición son la manifestación de la IAN, se obtuvieron datos epidemiológicos del año 2013 (de prevalencia de obesidad y sobrepeso y desnutrición) provenientes de 23 centros de atención primaria de la ciudad. La distribución espacial de estos mismos se presenta en las Figuras 1 y 2. Para cada centro de salud se calculó un área de interés con un radio de 1000 m, a fin de explorar las condiciones ambientales en su entorno.

Para identificar las características de barrios socialmente vulnerables, se realizó una clasificación no supervisada utilizando las características espaciales y espectrales de una imagen multiespectral SPOT 5. Esta imagen (con fecha de adquisición en enero de 2013 y proporcionada por la Comisión Nacional de Actividades Espaciales – CONAE-) posee una resolución de 10 metros con cuatro bandas espectrales en verde (0,50 - 0,59 μm), rojo (0,61 - 0,68 μm), infrarrojo cercano (0,78 - 0,89 μm) e infrarrojo medio (1,58 - 1,75 μm).

Estrato social

En primera instancia, se abordó el estudio del estrato social, utilizado para describir aspectos sociales y el acceso económico a los alimentos (dimensión accesibilidad y utilización biológica de la SAN). Para ello, se analizaron en detalle las características del patrón espacial de dos barrios con características socioeconómicas y edilicias muy diferentes que se encuentran uno al lado del otro (Ver Figura 3): Villa Urquiza (estrato social medio bajo) y Urca-Ampliación Urca (clase social alta).




Figura 1. *Distribución espacial de los centros de salud. El tamaño de cada círculo representa la prevalencia de desnutrición informada en 2013.*

Fuente: Elaboración propia.




Figura 2. *Distribución espacial de los centros de salud. El tamaño de cada círculo representa la prevalencia de sobrepeso y obesidad informada en 2013.*

Fuente: Elaboración propia.

De acuerdo con los atributos de la imagen SPOT 5 mencionada, se calcularon las características de textura en base al uso de niveles de grises de la matriz de coocurrencia (GLCM) (rango, media, varianza, entropía y sesgo) aplicadas a la banda verde



(se obtienen resultados similares si la textura se calcula a partir de las otras bandas) (Hall-Beyer, 2017). Para conservar la alta resolución espacial de la imagen, se aplicó una ventana de procesamiento pequeña (5 x 5 píxeles). Este subconjunto de características, basado en una estadística de coocurrencia entre píxeles, representa una herramienta “fácil de usar” para extraer información sobre la estructura urbana que, como se podrá observar, está fuertemente relacionada con los estratos socioeconómicos. Posteriormente, las capas de textura se apilaron a las cuatro bandas imagen original, y sobre esta imagen de ahora 9 bandas se realizó una clasificación no supervisada (30 clases) con el algoritmo K-means (Peña Zamalloa, 2021). De hecho, no es posible desarrollar una estrategia supervisada cuando se busca clasificar una imagen donde ahora un píxel no representa una simple cobertura sino una estructura espacial. Finalmente se examinó el porcentaje de cada clase presente en cada vecindario y de esta manera su potencial de discriminación.

Modelado de la desnutrición y obesidad

En segunda instancia, se exploró la existencia de relaciones estadísticamente significativas entre la prevalencia de desnutrición, obesidad y sobrepeso y las variables geoespaciales obtenidas de la imagen.

Específicamente, además de la clasificación descrita en la sección anterior, se incluyeron variables ambientales como NDVI, el índice de suelos normalizado (NSI) y la distancia a los cuerpos de agua y a los cultivos.

Tomando la prevalencia de desnutrición y la obesidad (variables respuesta) y las variables de paisaje propuestas anteriormente (porcentaje de cada clase alrededor

del centro de salud y el valor medio de NDVI, NSI, distancia al agua y distancia a los cultivos) como predictores, se realizó una regresión lineal múltiple. La adopción de esta metodología está basada en experiencias previas de trabajos que relacionen variables derivadas de satélite con aspectos vinculados a la salud/epidemiología (Andreo et al., 2009; Jerrett et al., 2010; Ra et al., 2012; Rotela et al., 2011).



Figura 3. Imagen SPOT 5 (banda verde), de una pequeña parte de la ciudad de Córdoba, cubre el sector que incluye los barrios Villa Urquiza y Urca-Ampliación Urca.

Fuente: elaboración propia.

Con el propósito de realizar un modelado sólido, se verificó la distribución (normalidad) de cada variable, así como las relaciones bivariadas entre ellas; cumpliendo de esta manera con el supuesto de la parsimonia en la ejecución del modelo final. Para el modelo multivariado resultante, se seleccionaron las clases más presentes en la ciudad, las que mostraron mejor correlación univariada y aquellas con mayor capacidad de discriminación entre los estratos sociales. Finalmente, según el modelo estadístico obtenido, se construyó un modelo espacial



continuo de desnutrición y obesidad para el área de estudio en cuestión.

Para abordar el problema de la estabilidad del modelo, se consideró entrenar y encontrar el modelo N-1 repetidamente utilizando todos los N puntos de entrenamiento menos uno, y se examinó la variabilidad de los coeficientes del modelo. Así, si los modelos poseen los mismos coeficientes, se afirma que el modelo es estable. Asimismo, se valoraron los supuestos de normalidad de los residuos, independencia, homocedasticidad y colinealidad dentro del modelo propuesto a fines de dar validez al modelo.

Análisis y resultados

Discriminación de barrios según estrato social

Los resultados de la clasificación no supervisada de la imagen (incluidas las características de textura y las bandas originales) se presentan en la Figura 4. Esta muestra como las clases obtenidas pueden resaltar las diferencias entre los dos barrios. En la Tabla 1, se incluye el porcentaje de cada clase (solo para aquellas que mostraron diferencia significativa $-p < 0,05-$ entre los dos barrios). En Villa Urquiza (estratos sociales inferiores) hay un mayor porcentaje de clases 16, 21, 25 y 30. Mientras que las clases 27, 28, 29 y 30 son más frecuentes en Urca y Ampliación Urca (estratos sociales altos).

De la observación de la Figura 4 y la Tabla 1, queda en evidencia que la clasificación de la imagen satelital realizada (incluyendo texturas) puede convertirse en una herramienta de discriminación útil; en este sentido ambas muestran la diferencia en el patrón espectral-espacial de los barrios en cuestión. En términos del paisaje urbano, la clase 25 está relacionada con áreas de suelo

desnudo; por su parte la clase 28 está asociada principalmente a vegetación como árboles y arbustos en áreas residenciales a lo largo del río, mientras que la clase 30 está relacionada con calles pavimentadas. Las clases 27 y 29 identifican principalmente bordes y, por lo tanto, están relacionadas con la distribución espacial y la gestión del área residencial, mientras que las clases 16 y 21 están asociadas con interfaces desordenadas entre casas y calles.




Figura 4. Resultado de la clasificación por K-means, incluyendo las bandas de textura. Zona de la ciudad que incluye a los barrios Villa Urquiza (abajo) y Urca-Ampliación y Urca (arriba).

Fuente: Elaboración propia.

Análisis multivariado

Siguiendo la metodología descrita brevemente en la sección anterior, se desarrollaron dos modelos de regresión múltiple, considerando como variables independientes la desnutrición aguda en un caso y la obesidad y el sobrepeso en el otro. En ellos se utilizaron como variables explicativas la media alrededor de un buffer centrado en cada centro de salud de la distancia al agua, cultivos, NDVI, NSI, además del porcentaje de cada clase.



Para el caso de la desnutrición, las variables significativas ($p < 0,05$) encontradas fueron: distancia de cultivo, las clases: 1, 2, 12, 13 y NSI. El modelo obtenido está representado por:

$$\begin{aligned} & \text{Prevalencia de Desnutrición} \\ & = 0,0009950 + \text{Crop distance} \times (-0,0010086) \\ & + \text{Class 1} \times (-0,0001362) + \text{Class 2} \times (-0,0002478) \\ & + \text{Class 12} \times 0,0012918 + \text{Class 13} \times 0,0001502 \\ & + \text{NSI} \times (0,0023863) \end{aligned}$$

Tabla 1
Porcentaje de píxeles de las clases más representativas para cada barrio

Clase	Urca - Ampliación Urca	Villa Urquiza
16	1.2 %	11.3 %
21	3.7 %	14.3 %
25	14.9 %	25.8 %
27	28.3 %	17.7 %
28	14.8 %	3.3 %
29	6.7 %	2.2 %
30	21.1 %	4.6 %

Fuente: Elaboración propia.

Este modelo produjo un valor de R2 ajustado de 0,70 y un valor de p de 0,00198. Esta asociación es moderada y estadísticamente significativa. Siguiendo el procedimiento de interpretación estándar, es posible decir que aproximadamente tres cuartas partes de la variabilidad de la desnutrición podrían explicarse por las variables geoespaciales de sensores remotos mencionadas. En este modelo aparecen las clases 1 y 2 relacionadas con suelo desnudo en áreas agrícolas y las clases 12 y 13 asociadas a las fronteras entre diferentes texturas en áreas agrícolas. De acuerdo con este modelo, la prevalencia de desnutrición aumenta en áreas cercanas a los cultivos, en áreas con mayor presencia de NSI.

Por otro lado, en el caso de obesidad y sobrepeso, las variables significativas fueron: distancia de cuerpos de agua, las clases:

15, 16, 25, 30 y NSI y la siguiente ecuación representa el modelo:

$$\begin{aligned} & \text{Prevalencia de sobrepeso y obesidad} \\ & = -0,02314 - (2,764 \times 10^{-5}) \times \text{Water bodies distance} \\ & + (1,393 \times 10^{-3}) \times \text{Class 15} + (5,531 \times 10^{-4}) \times \text{Class 16} \\ & + (9,566 \times 10^{-4}) \times \text{Class 25} + (6,199 \times 10^{-4}) \times \text{Class 30} \\ & - 0,1741 \times \text{NSI} \end{aligned}$$

En este modelo aparece la clase 15 asociada a las fronteras entre vegetación y otras cubiertas de suelo como agua, construcciones urbanas o suelo desnudo. El modelo sugiere que las prevalencias de sobrepeso y obesidad aumentan en las zonas urbanas con alto NSI. La variable NSI tiene más influencia que la abundancia de clases y la distancia a cuerpos de agua. Este modelo produce un R2 ajustado de 0,64 y un valor de p de 0,00054. Esta asociación es moderada y estadísticamente significativa. En este caso, se encuentra un modelo con la capacidad de explicar el 64 % de la variabilidad de los datos de obesidad y sobrepeso utilizando las variables geoespaciales distancia de cuerpos de agua, NSI, y las clases 15, 16, 25 y 30.

Los modelos estadísticos obtenidos se aplicaron al área total, para así obtener mapas continuos de desnutrición y obesidad y sobrepeso para toda la ciudad. Estos productos se presentan en las Figuras 5 y 6.




Figura 5. Mapa continuo de desnutrición modelado. Córdoba 2013.

Fuente: Elaboración propia.

Conclusiones

Tal como se describió anteriormente, las contribuciones de las tecnologías geoespaciales en estudios de la seguridad alimentaria poseen un énfasis en variables ambientales que influyen principalmente en la disponibilidad de alimentos, y muy poco se relacionan con la utilización biológica y el acceso a los alimentos. Así, el objetivo de este estudio fue, además de presentar aquella revisión, explorar la capacidad de herramientas geoespaciales para estudiar algunos otros factores que influyen en la seguridad alimentaria nutricional en las zonas urbanas de América Latina, tomando como caso la ciudad de Córdoba, Argentina.

Está claro el carácter regional de esta cuestión, en el sentido de que los determinantes de la SAN en África no son necesariamente los mismos que en países de América del Sur. Entonces, el posible rol o contribución de sensores remotos podría ser muy diferente en una región u otra del planeta. De esta manera, el presente trabajo

es pionero en el enfoque interdisciplinario para aprovechar las herramientas de tele-detección y las tecnologías geoespaciales, en nuestra región, aplicadas a la SAN. Hay una gran experiencia regional en aplicaciones espaciales en áreas ambientales (calidad de agua, forestación, incendios, etc.) (Arganaraz et al., 2018; da Costa Almeida et al., 2009; Ribeiro et al., 2008; Sousa et al., 2013), y en particular a la salud humana (epidemiología panorámica), en enfermedades transmitidas por vectores como chagas, leishmaniasis y dengue (Andreo et al., 2014; Arboleda & Peterson, 2009; Espinosa et al., 2016; Parra-Henao, 2010; Polop et al., 2008; Porcasi et al., 2006; Salomón et al., 2006), pero esta contribución es un esfuerzo para iniciar el camino en el campo de la seguridad alimentaria.

Los resultados preliminares obtenidos muestran que el método propuesto puede discriminar áreas socialmente diferentes (por lo tanto, menos o más vulnerables), relacionadas con el SAN. El análisis de texturas, en combinación con métodos de clasificación automática, permiten obtener un mapeo de coberturas en áreas urbanas (Puissant et al., 2005), de una manera simple y accesible. Además, a partir de los resultados presentados, se puede observar que la prevalencia de la desnutrición y el sobrepeso-obesidad están asociados a las variables de paisaje incluidas en este estudio. Los modelos pueden explicar aproximadamente el 60-70 % de la variabilidad espacial de las variables nutricionales examinadas, y se han verificado asociaciones entre estos datos de prevalencia con los estratos sociales (representados por clases) y las variables ambientales. Además, el mapa continuo de desnutrición generado (Figura 5) puede representar, en una forma aceptable, el patrón espacial observado por los datos de campo



discretos (Figura 1). En el caso del mapa sobrepeso-obesidad (Figura 6), tiene más problemas para representar el patrón más complejo de los datos reales presentados en la Figura 2 (de hecho, este modelo tiene también un R2 menor).




Figura 6. *Mapa continuo de obesidad y sobrepeso modelado. Córdoba 2013.*
Fuente: Elaboración propia.

Adicionalmente, se estimó la estabilidad y validez del modelo (solo para el caso de desnutrición) utilizando múltiples conjuntos de datos para la regresión. Se evidenció que los coeficientes cambian en menos de 0,5 % alrededor de la media, y la capacidad predictiva, cuantificada mediante el error medio cuadrático medio, fue de aproximadamente el 15 %. De acuerdo con estos resultados, podemos decir que el modelo es muy estable y el rendimiento es razonable, pero puede no ser suficiente para algunas aplicaciones. Para mejorar el modelo, ya que aquí se utilizó una regresión lineal, se podrían explorar otros enfoques como por ejemplo, un análisis de regresión logística o análisis discriminante, pensando en los datos como categóricos.

En los últimos tiempos han crecido las investigaciones que relacionan las características ambientales de los vecindarios y la salud, especialmente referidas a los patrones urbanos y el comportamiento alimentario y la actividad física (Charreire et al., 2014). Así, se han estudiado características como la urbanización, la transitabilidad, las actividades sociales y la seguridad de los peatones, y se ha demostrado su asociación con las características específicas del vecindario y la incidencia en enfermedades cardiovasculares (Pereira et al., 2012; Villeneuve et al., 2011). De acuerdo con esto, el modelo obtenido en este trabajo sugiere que la urbanización sería un determinante importante de la prevalencia de sobrepeso y obesidad. Por el contrario, la prevalencia de la desnutrición obtenidos aquí aparece como mayor en los barrios periféricos de estrato social bajo.

Aunque los estudios mencionados anteriormente resaltan las contribuciones de tecnologías innovadoras en epidemiología nutricional, el conocimiento de su efectividad es aún limitado (Defagó et al., 2009; Illner et al., 2012). Destaca que, de acuerdo con la bibliografía disponible, la investigación presentada en este trabajo es el primer estudio en América Latina que utiliza tecnologías de teledetección para abordar la SAN con un enfoque multidimensional. Los resultados de este trabajo mostraron un gran potencial de estas tecnologías en el campo de la SAN. Sin embargo, es necesario refinar aún más la implementación actual y validar el método para identificar áreas socialmente vulnerables. Además, se podrían incluir otras herramientas más relacionadas con el campo del análisis espacial para encontrar relaciones y patrones espaciales que generen información complementaria sobre los



determinantes ambientales de la prevalencia de estas cuestiones en la población.

Agradecimientos

Queremos agradecer y homenajear a la primera autora de este trabajo, la Mgter. Eliana Marina Álvarez Di Fino, por su contribución al manuscrito y al área en cuestión. La recordaremos siempre con mucho cariño y respeto.

Queremos agradecer también al director del Instituto de Altos Estudios Espaciales “Mario Gulich” (Comisión Nacional de Actividades Espaciales-Universidad Nacional de Córdoba), el Dr. Marcelo Scavuzzo, por el apoyo institucional y acompañamiento brindado al equipo.

Conflicto de intereses

Los autores no declaran conflicto de intereses.

Declaración de contribuciones de los autores

Todos los autores declaran que la versión final de este manuscrito fue leída y aprobada.

El porcentaje total de contribución para la conceptualización, preparación y corrección de este manuscrito fue de la siguiente manera: E.A.D. 20 %, M.D.D. 20 %, M.N.C. 20 %, C.M.S. 20 %, C.M.S. 20 %.

Declaración de disponibilidad de datos

Declaración de disponibilidad de datos no aplica, debido a que en este estudio no fue creada o analizada información nueva.

Referencias

- Andreo, V., Neteler, M., Rocchini, D., Provensal, C., Levis, S., Porcasi, X., ... & Polop, J. (2014). Estimating Hantavirus risk in southern Argentina: a GIS-based approach combining human cases and host distribution. *Viruses*, 6(1), 201-222. <https://doi.org/10.3390/v6010201>
- Andreo, V., Provensal, C., Scavuzzo, M., Lamfri, M., & Polop, J. (2009). Environmental factors and population fluctuations of Akodon azarae (Muridae: Sigmodontinae) in central Argentina. *Austral Ecology*, 34(2), 132-142. <https://doi.org/10.1111/j.1442-9993.2008.01889.x>
- Arboleda, S., & Peterson, A. T. (2009). Mapping environmental dimensions of dengue fever transmission risk in the Aburrá Valley, Colombia. *International journal of environmental research and public health*, 6(12), 3040-3055. <https://doi.org/10.3390/ijerph6123040>
- Arganaraz, J., Lighezzolo, A., Clemoveki, K., Bridera, D., Scavuzzo, J., & Bellis, L. (2018). Operational meteorological fire risk system based on space information for Chaco Serrano. *IEEE Latin America Transactions*, 16(3), 975-980. <https://doi.org/10.1109/TLA.2018.8358681>
- Ashe, L. M., & Sonnino, R. (2013). At the crossroads: new paradigms of food security, public health nutrition and school food. *Public health nutrition*, 16(6), 1020-1027. <https://doi.org/10.1017/S1368980012004326>
- Bianchi, E. & Szpak, C. (2016). Seguridad Alimentaria y el Derecho a la Alimentación Adecuada. *Revista brasileira de estudos jurídicos*, 11(2), 37-45.
- Britos, S. (2008). Hambre, seguridad alimentaria, obesidad y políticas públicas en la Argentina reciente. *Revista Observatorio Social*, (19).
- Brown, M. E. (2008). Famine early warning systems and remote sensing data. *Springer Science & Business Media*.
- Charreire, H., Mackenbach, J. D., Ouasti, M., Lakerfeld, J., Compennolle, S., Ben-Rebah, M., ... & Oppert, J. M. (2014). Using remote sensing to define environmental characteristics related to physical activity and dietary behaviours: a systematic review (the SPOTLIGHT project). *Health & place*, 25, 1-9. <https://doi.org/10.1016/j.healthplace.2013.09.017>
- Chen, J. (2007). Rapid urbanization in China: A real challenge to soil protection and food security.



- Catena*, 69(1), 1-15. <https://doi.org/10.1016/j.catena.2006.04.019>
- da Costa Almeida, A., Barros, P. L. C., Monteiro, J. H. A., & da Rocha, B. R. P. (2009). Estimation of aboveground forest biomass in Amazonia with neural networks and remote sensing. *IEEE Latin America Transactions*, 7(1), 27-32. <https://doi.org/10.1109/TLA.2009.5173462>
- Defagó, M. D., Perovic, N. R., Aguinaldo, C. A., & Actis, A. B. (2009). Desarrollo de un programa informático para estudios nutricionales. *Revista Panamericana de Salud Pública*, 25, 362-366. <https://doi.org/10.1590/S1020-49892009000400011>
- Elgart, J. F., Pfirter, G., Gonzalez, L., Caporale, J. E., Cormillot, A., Chiappe, M. L., & Gagliardino, J. J. (2010). Obesidad en Argentina: epidemiología, morbimortalidad e impacto económico. *Revista Argentina de Salud Pública*, 1.
- Espinosa, M., Weinberg, D., Rotela, C. H., Polop, F., Abril, M., & Scavuzzo, C. M. (2016). Temporal dynamics and spatial patterns of *Aedes aegypti* breeding sites, in the context of a dengue control program in Tartagal (Salta province, Argentina). *PLoS neglected tropical diseases*, 10(5), e0004621. <https://doi.org/10.1371/journal.pntd.0004621>
- FAO. (2016). *Cambio climático y seguridad alimentaria y nutricional América Latina y el Caribe*. Food and Agricultural Organization. http://www.fao.org/fileadmin/user_upload/rlc/docs/Cambioclimatico.pdf.
- Hall-Beyer, M. (2017). Practical guidelines for choosing GLCM textures to use in landscape classification tasks over a range of moderate spatial scales. *International Journal of Remote Sensing*, 38(5), 1312-1338. <https://doi.org/10.1080/01431161.2016.1278314>
- Helldén, U., & Eklundh, L. (1988). National Drought Impact Monitoring-A NOAA NDVI and precipitation data study of Ethiopia. Lund Studies in Geography, Ser. C. General, Mathematical and Regional Geography, 15.
- Hielkema, J. U., & Snijders, F. L. (1994). Operational use of environmental satellite remote sensing and satellite communications technology for global food security and locust control by FAO: The ARTEMIS and DIANA systems. *Acta Astronautica*, 32(9), 603-616. [https://doi.org/10.1016/0094-5765\(94\)90071-X](https://doi.org/10.1016/0094-5765(94)90071-X)
- Illner, A. K., Freisling, H., Boeing, H., Huybrechts, I., Crispim, S. P., & Slimani, N. (2012). Review and evaluation of innovative technologies for measuring diet in nutritional epidemiology. *International journal of epidemiology*, 41(4), 1187-1203. <https://doi.org/10.1093/ije/dys105>
- Jerrett, M., Gale, S., & Kontgis, C. (2010). Spatial modeling in environmental and public health research. *International journal of environmental research and public health*, 7(4), 1302-1329. <https://doi.org/10.3390/ijerph7041302>
- Johnson, G. E., Achutuni, V. R., Thiruvengadachari, S., & Kogan, F. (1993). The role of NOAA satellite data in drought early warning and monitoring: selected case studies. In *Drought assessment, management, and planning: Theory and case studies* (pp. 31-47). Springer, Boston, MA. https://doi.org/10.1007/978-1-4615-3224-8_3
- Johnson, K. B., Jacob, A., & Brown, M. E. (2013). Forest cover associated with improved child health and nutrition: evidence from the Malawi Demographic and Health Survey and satellite data. *Global Health: Science and Practice*, 1(2), 237-248. <https://doi.org/10.9745/GHSP-D-13-00055>
- Justice, C. O., Townshend, J. R. G., Holben, B. N., & Tucker, E. C. (1985). Analysis of the phenology of global vegetation using meteorological satellite data. *International Journal of Remote Sensing*, 6(8), 1271-1318. <https://doi.org/10.1080/01431168508948281>
- Kemeling, I. (2001). *Mapping Urban and Peri-Urban Agricultural Areas in Ouagadougou, Burkina Faso*. Centre for Geo-Information, Wageningen, The Netherlands.
- Knight, L. (2011). World Disaster Report 2011: Focus on hunger and malnutrition. In World Disaster Report 2011: Focus on hunger and malnutrition. International Federation of Red Cross and Red Crescent Societies (IFRC).
- Kogan, F., Goldberg, M., Schott, T., & Guo, W. (2015). Suomi NPP/VIIRS: improving drought watch, crop loss prediction, and food security. *International Journal of Remote Sensing*, 36(21), 5373-5383. <https://doi.org/10.1080/01431161.2015.1095370>
- Lee, T. E., Miller, S. D., Turk, F. J., Schueler, C., Julian, R., Deyo, S., Dills, P., & Wang, S. (2006). The NPOESS VIIRS day/night visible sensor.



- Bulletin of the American Meteorological Society*, 87(2), 191-200. <https://doi.org/10.1175/BAMS-87-2-191>
- Linetzky, B., Morello, P., Virgolini, M., & Ferrante, D. (2011). Resultados de la primera encuesta nacional de salud escolar: Argentina, 2007. *Archivos argentinos de pediatría*, 109(2), 111-116.
- López-Carr, D., Mwenda, K. M., Pricope, N. G., Kyriakidis, P. C., Jankowska, M. M., Weeks, J., ... & Michaelsen, J. (2015). A spatial analysis of climate-related child malnutrition in the Lake Victoria Basin. In *2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)* (pp. 2564-2567). IEEE. <https://doi.org/10.1109/IGARSS.2015.7326335>
- Minamiguchi, N. (2005). The application of geospatial and disaster information for food insecurity and agricultural drought monitoring and assessment by the FAO GIEWS and Asia FIVIMS. In *Workshop on Reducing Food Insecurity Associated with Natural Disasters in Asia and the Pacific* (Vol. 27, p. 28).
- Parra-Henao, G. (2010). Geographic information systems and remote sensing. Applications in vector-borne diseases. *CES Medicina*, 24(2), 75-89.
- Peña Zamalloa, G. R. (2021). Clasificación espacial del suelo urbano por el valor especulativo del suelo e imágenes MSI satelitales usando K-MEANS, Huancayo, Perú. *Urbano (Conceptión)*, 24(44), 70-83. <https://doi.org/10.22320/07183607.2021.24.44.06>
- Pereira, G., Foster, S., Martin, K., Christian, H., Boruff, B. J., Knuiman, M., & Giles-Corti, B. (2012). The association between neighborhood greenness and cardiovascular disease: an observational study. *BMC public health*, 12(1), 1-9. <https://doi.org/10.1186/1471-2458-12-466>
- Polop, F., Provensal, M. C., Lamfri, M., Scavuzzo, M., Calderón, G., & Polop, J. (2008). Environmental variables in the incidence of the Argentine Hemorrhagic Fever (AHR). *Ecological Research*, 23, 217-225. <https://doi.org/10.1007/s11284-007-0371-2>
- Popkin, B. M., & Gordon-Larsen, P. (2004). The nutrition transition: worldwide obesity dynamics and their determinants. *International journal of obesity*, 28(3), S2-S9. <https://doi.org/10.1038/sj.ijo.0802804>
- Porcasi, X., Catalá, S. S., Hrellac, H., Scavuzzo, M. C., & Gorla, D. E. (2006). Infestation of rural houses by *Triatoma infestans* (Hemiptera: Reduviidae) in southern area of Gran Chaco in Argentina. *Journal of medical entomology*, 43(5), 1060-1067. <https://doi.org/10.1093/jmedent/43.5.1060>
- Puissant, A., Hirsch, J., & Weber, C. (2005). The utility of texture analysis to improve per-pixel classification for high to very high spatial resolution imagery. *International Journal of Remote Sensing*, 26(4), 733-745. <https://doi.org/10.1080/01431160512331316838>
- Ra, P. K., Nathawat, M. S., & Onagh, M. (2012). Application of multiple linear regression model through GIS and remote sensing for malaria mapping in Varanasi District, INDIA. *Health Science Journal*, 6(4), 731.
- Ribeiro, H. M. C., da Costa Almeida, A., Rocha, B. R. P. D., & Krusche, A. V. (2008). Water quality monitoring in large reservoirs using remote sensing and neural networks. *IEEE Latin America Transactions*, 6(5), 419-423. <https://doi.org/10.1109/TLA.2008.4839111>
- Rotela, C. H., Spinsanti, L. I., Lamfri, M. A., Contigiani, M. S., Almirón, W. R., & Scavuzzo, C. M. (2011). Mapping environmental susceptibility to Saint Louis encephalitis virus, based on a decision tree model of remotely sensed data. *Geospatial health*, 6(1), 85-94. <https://doi.org/10.4081/gh.2011.160>
- Salomón, O. D., Orellano, P. W., Lamfri, M., Scavuzzo, M., Dri, L., Farace, M. I., & Quintana, D. O. (2006). Phlebotominae spatial distribution associated with a focus of tegumentary leishmaniasis in Las Lomitas, Formosa, Argentina, 2002. *Memórias do Instituto Oswaldo Cruz*, 101, 295-299. <https://doi.org/10.1590/S0074-02762006000300013>
- Salvia, A., Tuñón, I., Musante, B. (2012) *La inseguridad alimentaria en la Argentina: Hogares urbanos, año 2011*. Universidad Católica Argentina. http://www.uca.edu.ar/uca/common/grupo68/files/Informe_Inseguridad_Alimentaria__doc_de_trabajo_.pdf.
- Sepulcre Canto, G., Waldner, F., Radoux, J., Valero, S., Inglada, J., Hagolle, O., ... & Defourny, P. (2014). How to think global: Exploring different alternatives for global cropland classification in the framework of the project Sentinel 2 Agriculture. In *The 4th International*



- Symposium on Recent Advances in Quantitative Remote Sensing: RAQRS'IV.*
- Smith, M. D., Kassa, W., & Winters, P. (2017). Assessing food insecurity in Latin America and the Caribbean using FAO's food insecurity experience scale. *Food policy*, 71, 48-61. <https://doi.org/10.1016/j.foodpol.2017.07.005>
- Sousa, W. R. N., Couto, M. S., Castro, A. F., & Silva, M. P. S. (2013). Evaluation of desertification processes in ouricuri-pe through trend estimates of times series. *IEEE Latin America Transactions*, 11(1), 602-606. <https://doi.org/10.1109/TLA.2013.6502869>
- Traoré, M., Thompson, B., & Thomas, G. (2012). Sustainable nutrition security. Restoring the bridge between agriculture and health. Food and Agriculture Organisation of the United Nations, Rome, Italy.
- Valero, S., Morin, D., Inglada, J., Sepulcre, G., Arias, M., Hagolle, O., ... & Defourny, P. (2015). Processing Sentinel-2 image time series for developing a real-time cropland mask. In 2015 *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)* (pp. 2731-2734). IEEE. <https://doi.org/10.1109/IGARSS.2015.7326378>
- Villeneuve, P. J., Goldberg, M. S., Burnett, R. T., van Donkelaar, A., Chen, H., & Martin, R. V. (2011). Associations between cigarette smoking, obesity, sociodemographic characteristics and remote-sensing-derived estimates of ambient PM_{2.5}: results from a Canadian population-based survey. *Occupational and environmental medicine*, 68(12), 920-927. <https://doi.org/10.1136/oem.2010.062521>
- Xie, M., Jean, N., Burke, M., Lobell, D., & Ermon, S. (2016, March). Transfer learning from deep features for remote sensing and poverty mapping. In *Thirtieth AAAI Conference on Artificial Intelligence*.



Explorando el uso de herramientas de sensores remotos y tecnologías geoespaciales aplicadas al problema multidimensional de la seguridad alimentaria (Eliana Marina Álvarez Di Fino †, Carlos Matias Scavuzzo, Micaela Natalia Campero, Carlos Marcelo Scavuzzo ¹, María Daniela Defagó) *Uniciencia* is protected by [Attribution-NonCommercial-NoDerivs 3.0 Unported \(CC BY-NC-ND 3.0\)](https://creativecommons.org/licenses/by-nc-nd/3.0/)