Aplicación de tecnologías geoespaciales para el análisis de la Seguridad Alimentaria y Nutricional en la ciudad de Córdoba, Argentina

Por Mgter. Eliana Marina Alvarez Di Fino

Presentado ante la Facultad de Matemática, Astronomía y Física y el Instituto de Altos Estudios Espaciales Mario Gulich como parte de los requerimientos para la obtención del grado de

MAGISTER EN APLICACIONES ESPACIALES DE ALERTA Y RESPUESTA TEMPRANA A EMERGENCIAS

UNIVERSIDAD NACIONAL DE CÓRDOBA

Junio, 2020

©IG-CONAE 2020 ©FaMAF-UNC 2020

DIRECTORA

Dra. María Daniela Defagó

Escuela de Nutrición, FCM, UNC, Argentina INICSA-CONICET

CO-DIRECTOR

Dr. Carlos Marcelo Scavuzzo

IG-CONAE, Argentina



Esta obra está bajo una Licencia Creative Commons Atribución-CompartirIgual 4.0 Argentina.

Abstract

Food and Nutrition Security (FNS) exists when all people, at all times, have physical, social and economic access to sufficient, safe and nutritious food to meet their dietary needs and food preferences for an active and healthy life. Current nutritional epidemiological situation reflects FNS lack: increased prevalence of excess malnutrition (overweight, obesity and associated diseases), coexisting with deficit malnutrition (caloric-protein malnutrition, micronutrients lack: hidden malnutrition). Neighborhood where people live plays an important role in the distribution and frequency of diseases; so geospatial technologies could contribute to communities FNS analysis. The aim of this work was to explore the capacity of geospatial technologies for the study of FNS in the city of Córdoba, during 2013.

To identify the characteristics of socially vulnerable neighborhoods, an unsubstantiated classification was performed using the spatial and spectral characteristics of an SPOT 5 image. Spatial pattern of two neighborhoods of the city of Córdoba with very different social characteristics that are next to each other was analyzed: Villa Urquiza and Urca-Ampliación Urca. Then, descriptive variables of the environment were defined as: bare soil index, distance to the peri-urban area, distance to water bodies. Malnutrition, overweight and obesity, anemia and foodborne illnesses prevalence data registered in the Centers of Primary Health Care of the Municipal Health were used. Generalized Linear Models technique was used to analyze relationship between prevalence of these diseases and the environment characterized by the variables provided by remote sensing. 2D-variogram algorithm for anisotropic data was programmed using IDL language to study malnutrition, overweight and obesity, anemia and foodborne prevalence variability.

Seven classes were identified that highlight differences between both neighborhoods: Villa Urquiza (higher social vulnerability) has a higher percentage of classes 16, 21 and 25. While classes 27, 28, 29 and 30 were more frequent in Urca and Ampliación-Urca (lower social vulnerability) Models obtained explain a small percentage of the variability in the prevalence of the diseases studied: 24% of Malnutrition; 9% of Overweight and obesity; 11% of Foodborne Diseases and 23% of Anemia. Therefore, these models are not sufficient to explain the dynamics of the behavior of the diseases of interest, therefore they are not able to predict the risk only with these explanatory variables. This is due to the complexity of factors involved in the development of these diseases. Finally, 2D semivariogram identified a marked spatial pattern in the prevalence of overweight - obesity and anemia In the first case, there was a greater variability in east-west direction, while the variability in the prevalence of anemia was greater in a north-south direction. In both cases, the most distant areas of the city had maximum variation.

Keywords: Food and nutrition security, geomatics, spatial epidemiology

Resumen

La Seguridad Alimentaria y Nutricional (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. La situación epidemiológica nutricional actual refleja la carencia de SAN en la población: aumento de la prevalencia de malnutrición por exceso (sobrepeso, obesidad y enfermedades asociadas), coexistiendo con la malnutrición por déficit (desnutrición calórico-proteica, carencia de micronutrientes: desnutrición oculta). El entorno donde habitan las personas juega un rol importante en la distribución y frecuencia de las enfermedades; por lo cual las tecnologias geoespaciales podrian contribuir al análisis de la SAN de las comunidades. El propósito de este trabajo fue *Explorar la capacidad de las tecnologias geoespaciales para el estudio de la SAN en la ciudad de Córdoba, durante el año 2013*.

Para identificar las características de barrios socialmente vulnerables, se realizó una clasificación no supervisada utilizando las características espaciales y espectrales de una imagen SPOT 5. Se analizó el patrón espacial de dos barrios con características sociales muy diferentes que se encuentran uno al lado del otro: Villa Urquiza y Urca-Ampliación Urca. Luego se definieron variables descriptivas del entorno como: índice de suelo desnudo, distancia al área periurbana, distancia a los cursos de agua. Se utilizaron datos de prevalencia de desnutrición, sobrepeso y obesidad, anemia y Enfermedades transmitidas por alimentos, registradas en los Centros de Atención Primaria de la Salud Municipales. La técnica de Modelos Lineales Generalizados fue utilizada para analizar la relación entre la prevalencia de dichas enfermedades y el entorno caracterizado por las variables provistas por el sensado remoto. Por último, utilizando lenguaje IDL se programó un semivariograma direccional (2D) para analizar la dependencia espacial de la prevalencia de las enfermedades de interés.

Se identificaron 7 clases que resaltar las diferencias entre ambos barrios: Villa Urquiza (vulnerbilidad social mayor) presenta un mayor porcentaje de clases 16, 21 y 25. Mientras que las clases 27, 28, 29 y 30 son más frecuentes en Urca y Ampliación Urca (menor vulnerabilidad social). Los modelos obtenidos explican un pequeño porcentaje de la variabilidad de la prevalencia de las enfermedades estudiadas: un 24% para el caso de Desnutrición; 9% para Sobrepeso y obesidad; 11% para las Enfermedades Transmitidas por Alimentos y un 23% en el caso de Anemia. Por lo cual dichos modelos no son suficientes para explicar la dinámica del comportamiento de las enfermedades de interés, por lo tanto no son capaces de predecir el riesgo solo con estas variables explicativas. Esto se debe a la complejidad de factores que intervienen en el desarrollo de estas enfermedades. El semivariograma 2D diseñado identificó un marcado patrón espacial en la prevalencia de sobrepeso obesidad y anemia. En el primer caso, se observó una mayor variabilidad de prevalencia de en dirección esteoeste, mientras que la variabilidad de la prevalencia de anemia es mayor en dirección norte-sur. En ambos casos, las áreas mas distantes de la ciudad presentan la máxima variación.

Palabras clave: Seguridad alimentaria nutricional, geomática, epidemiología espacial

Agradecimientos

Este trabajo de investigación, no sólo refleja un camino profesional y académico recorrido (y el que queda por recorrer), sino también una vez más... que el entorno importa. Y me detengo aquí: en el protagonismo del entorno social como catalizador del *impulso vital*, que nos ayuda a crear.

Gracias eternas...

- ...A mi familia, siempre incondicional.
- ...A Marcelo Scavuzzo, por guiarme en este camino siempre con la palabra justa, contención y cariño.
- ...A Daniela Defagó, por acompañarme en esta aventura como una verdadera hermana alfa.
- ...A todos los amigos del Instituto Gulich: docentes, no docentes, compañeras y compañeros de la maestría; por aprendizajes compartidos, charlas y risas; condimentos necesarios de su mística.
- ...A la familia que me dio la Escuela de Nutrición: Adri, Nilda, Marianita, Lucy y Moni; por su apoyo y confianza.
 - ...A las Autoridades de CONAE y de la UNC, que hacen posible el desarrollo de la Maestría.
 - ...Al Tribunal Evaluador, por sus valiosos aportes.
 - ...Al equipo de Cátedra, en especial a Romi B y Romi D, por permitirnos seguir jugando.
 - ...A la Dra. Verónica Moreno, por estar siempre dispuesta a ayudar.
 - ...Al Dr. Fernando Álvarez, "guardián del hilo en el carretel".
- ...A mis amigas y amigos: los de acá y los de allá, los hoy y los de siempre, por demostrar cada día que la amistad no entiende de tiempos ni de espacios.
 - ...A mi yo del pasado, por haberse atrevido.

"Tiempo, espacio y causalidad no son mas que metáforas del conocimiento gracias a las cuales interpretamos las cosas" F. Nietzsche.

Tabla de Contenidos

1.	Mot	ivación		1
	1.1.	Objetiv	vos	2
2.	Mar	co Teór	rico	3
	2.1.	Tecnol	ogías geoespaciales	3
		2.1.1.	Sistemas de Posicionamiento Globlal	3
		2.1.2.	Sensado Remoto	3
		2.1.3.	Sistemas de Información Geográfica	5
		2.1.4.	Análisis Espacial	5
	2.2.	Seguri	dad Alimentaria y Nutricional	6
		2.2.1.	Concepto y situación actual	6
		2.2.2.	La Malnutrición como expresión de la Inseguridad Alimentaria y Nutricional (IAN) .	8
		2.2.3.	Seguridad Alimentaria y Nutricional (SAN) y urbanización	9
	2.3.	Aplica	ción de Tecnologías geoespaciales en el estudio de la SAN	9
3.	Área	a de esti	udio y materiales	13
	3.1.	Descri	pción general del área de estudio	13
	3.2.	Materi	ales	14
		3.2.1.	Datos epidemiológicos	14
		3.2.2.	Imágenes Satelitales	14
		3.2.3.	Datos ambientales	15
4.	Disc	riminac	ción de áreas urbanas según vulnerabilidad social a través del Sensado Remoto	19
	4.1	Introdi	ucción	19

TABLA DE CONTENIDOS

	4.2.	Métodologías empleadas en la identificación de áreas urbanas socialmente vulnerables	19
	4.3.	Metodología	20
		4.3.1. Uso de suelo de la ciudad de Córdoba	20
		4.3.2. Discriminación de áreas urbanas según estrato social	21
	4.4.	Resultados	22
		4.4.1. Uso de suelo de la ciudad de Córdoba	22
		4.4.2. Discriminación de áreas urbanas según vulnerabilidad social	23
	4.5.	Discusión	25
5.	Mod	lelos predictivos de enfermedades vinculadas a la IAN	27
	5.1.	Introducción	27
		5.1.1. Efectos del barrio sobre la salud, la alimentación y la nutrición	27
	5.2.	Metodología	28
	5.3.	Resultados	28
		5.3.1. Análisis exploratorio de los datos	28
		5.3.2. Modelado para Desnutrición	31
		5.3.3. Modelado para Sobrepeso y Obesidad	32
		5.3.4. Modelado para Enfermedades Transmitidas por los Alimentos (ETAs)	32
		5.3.5. Modelado para Anemia	33
		5.3.6. Desarrollo de mapas de riesgo	33
	5.4.	Discusión	36
6.	Aná	lisis Espacial aplicado a la Epidemiología Nutricional	39
	6.1.	Introducción	39
	6.2.	El Semi-Variograma como herramienta de la Epidemiología Nutricional	40
	6.3.	Materiales y Métodos	41
	6.4.	Resultados	42
		6.4.1. Datos Isotrópicos	42
		6.4.2. Datos Aleatorios de prevalencia y distribución espacial	43
		6.4.3. Prevalencia Aleatoria	43
		6.4.4. Incremento monótono de la prevalencia	44
		6.4.5. Prevalencia de Desnutrición	44

TABLA DE CONTENIDOS

Bi	bliogı	afía		53
Pr	oduce	cion cie	ntifica derivada de la tesis	51
7.	Con	clusion	es es	49
	6.5.	Discus	ión	47
		6.4.8.	Prevalencia de ETAs	46
		6.4.7.	Prevalencia de Anemia	46
		6.4.6.	Prevalencia de Sobrepeso y Obesidad	45

Índice de figuras

2.1.	Componentes involucrados en el Sensado Remoto (RS) [Chuvieco, 2010]	4
2.2.	Dimensiones de la SAN y sus principales determinantes	7
3.1.	Distribución de los Centros de Salud Municipales de la ciudad de Córdoba, Argentina (2013). Composición en color Imagen Landsat 8, Bandas Infrarrojo de onda corta 2 (2,11 – 2,29μ), Infrarrojo de onda corta 1 (1,57 – 1,65μ) y Rojo (0,64 – 0,67μ)	13
3.2.	Distribución espacial de los CAPS bajo estudio y prevalencia anual de las enfermedades de interés. Córdoba, 2013	14
3.3.	Valores de NSI para la ciudad de Córdoba, 2013	16
3.4.	Buffer de distancia a los cursos de agua, expresado en metros. Ciudad de Córdoba, 2013	16
3.5.	Buffer de distancia al área periurbana de la ciudad de Córdoba, expresado en metros.Año 2013	17
4.1.	Imagen Spot 5 (banda verde), de una pequeña parte de la ciudad de Córdoba, cubriendo el sector que incluye a los barrios Villa Urquiza y Urca-Ampliación Urca	22
4.2.	Uso de suelo de la ciudad de Córdoba (Clasificación supervisada SVM). Córdoba, Argentina, 2013	23
4.3.	Resultados clasificación no supervisada K-means de la imagen multicapa. Córdoba, Argentina.	24
5.1.	Histogramas de los casos de cada enfermedad de interés, cada 10.000 habitantes. Córdoba, 2013	29
5.2.	Matriz de correlación de las variables bajo estudio	30
5.3.	Riesgo de prevalencia de Sobrepeso y Obesidad, asociado a las características de los barrios. Ciudad de Córdoba, 2013	34
5.4.	Riesgo de prevalencia de ETAs, asociado a las características de los barrios. Ciudad de Córdoba, 2013	35
5.5.	Riesgo de prevalencia de anemia, asociado a las características de los barrios. Ciudad de Córdoba, 2013	36

ÍNDICE DE FIGURAS

6.1.	Semivariograma isotrópico típico	40
6.2.	Semivariograma 2D isotrópico	42
6.3.	Semivarograma 2D: Datos aleatorios	43
6.4.	Semivarograma 2D: Prevalencia aleatoria	43
6.5.	Semivarograma 2D: Incremento monótono de la prevalencia	44
6.6.	Semivarograma 2D: Prevalencia de Desnutrición	45
6.7.	Semivarograma 2D: Prevalencia de Sobrepeso y Obesidad	45
6.8.	Semivarograma 2D: Prevalencia de Anemia	46
6.9.	Semivarograma 2D: Prevalencia de ETAs	46

Índice de tablas

3.1.	Principales características de las imágenes SPOT 5	15
4.1.	Clases de cobertura de suelo mas representativas de cada barrio	24
4.2.	Características espaciales asociadas a las clases de cobertura identificadas	24
5.1.	Características epidemiológicas basales de los Centros de Atención Primaria de Salud (CAPS) municipales bajo estudio	28
5.2.	Variables explicativas para cada modelo de prediccion de enfermedades	30
5.3.	Resumen del modelo obtenido para Desnutrición	31
5.4.	Resumen del modelo obtenido para Sobrepeso y Obesidad	32
5.5.	Resumen del modelo obtenido para ETAs	33
5.6.	Resumen del modelo obtenido para Anemia	33

Lista de acrónimos

SAN Seguridad Alimentaria y Nutricional

AVHRR Advanced Very High Resolution Radiometer

CAPS Centros de Atención Primaria de Salud

CONAE Comisión Nacional de Actividades Espaciales

ETAs Enfermedades Transmitidas por los Alimentos

EVI Índice de Vegetación mejorado

FAO Food and Agricultural Organization

FEWS Famine Early Warning System

GIEWS Global Information and Early Warning System

GIS Sistemas de Información Geográfica

GLM Modelos Lineales Generalizados

GLCM Matriz de Co-ocurrencia de Niveles de Grises

GPS Sistemas de Posicionamiento Global

IAN Inseguridad Alimentaria y Nutricional

INDEC Instituto nacional de Estadísticas y Censos

MODIS Espectrorradiómetro de imágenes de media resolución

NASA National Aeronautics and Space Administration

NBI Necesidades Básicas Insatisfechas

NDVI Índice de Vegetación de Diferencia Normalizada

NOAA National Oceanic and Atmospheric Administration

NSI Índice Normalizado de Suelo

NDSI Índice de Nieve

NDWI Índice Diferencial de Agua Normalizado

ODS Objetivos de Desarrollo Sostenible

ÍNDICE DE TABLAS

ONU Organizacion de las Naciones Unidas

RS Sensado Remoto


SPOT Satellite Pour l'Observation de la Terre

VIIRS Visible Infrared Imaging Radiometer Suite

USAID United States Agency for International Development

USDA United States Department of Agriculture

USGS United States Geological Service



Motivación

La humanidad es impensable sin la comida. La alimentación es un fenómeno complejo, pero elemental, ya que es una necesidad de subsistencia. Son múltiples y dinámicos los aspectos que a lo largo de la historia han determinado -y determinan-, qué comer (o la posibilidad de comer), cuánto, cómo, dónde y con quien; es decir el contexto de decisión alimentaria. El mismo es de caracter espacial y temporal y define nuestro patrón alimentario, impactando directamente sobre nuestra nutrición y por ende nuestra salud.

La malnutrición - por déficit o por exceso- es una de las principales problemáticas que afectan a la salud pública a nivel mundial. El derecho a no sufrir hambre ni malnutrición es reconocido como básico dentro de los Derechos Humanos, y los estados tienen el deber de garantizarlo. Es decir, es un derecho individual, pero de responsabilidad colectiva. En este contexto, los intentos por erradicar el hambre, han llevado a la comunidad mundial a desarrollar distintos enfoques que permitan entender la complejidad de dicha problemática. Es así que en 1974, en la Conferencia Mundial sobre la Alimentación, surge el concepto de Seguridad Alimentaria, entendiendo que era posible alcanzarla, garantizando una suficiente producción y disponibilidad de alimentos. Este enfoque Malthusiano fue superado al incorporar otros aspectos que subyasen al fenómeno alimentario-nutricional: acceso económico, a recursos productivos, a servicios básicos, de salud, educación, calidad ambiental, exposición a eventos climáticos adversos, aspectos socioantropológicos, la sustentabilidad, entre otros. De este modo la mirada de la Seguridad Alimentaria fue enriqueciéndose, dando paso a la Seguridad Alimentaria y Nutricional (SAN).

La SAN atraviesa la totalidad de la vida humana, ya que está presente en su dimensión biológica, sociociocultural y ambiental. Ello puede verse reflejado en los Objetivos de Desarrollo Sostenible (ODS), propuestos por el Programa de las Naciones Unidas para el Desarrollo (PNUD/ONU) en el año 2015 para poner fin a la pobreza, proteger el planeta y garantizar que todas las personas gocen de paz y prosperidad para 2030.

Este escenario plantea nuevos desafíos de acción para todos los actores sociales: gobierno, sector privado y sociedad civil. Además, es fundamental diseñar estrategias integrales, que articulen la mirada de todas las disciplinas involucradas en el sistema alimentario nutricional. Aquí cobran vital importancia las tecnologías geoespaciales, ya que permiten una mirada global, obteniendo datos uniformes y confiables. Articulados con datos epidemiológicos, económicos y sociales, permiten abordar las dimensiones de la SAN, identificando factores de riesgo que aumentan la vulnerabilidad de las poblaciones, así como los factores protectores. De esta manera será posible diseñar sistemas de alerta para prevenir y/o mitigar situaciones de Inseguridad Alimentaria y Nutricional (IAN), ante amenazas de diversa naturaleza.

Por último, es importante destacar que entre los objetivos fundamentales del Plan Nacional Espacial, se encuentra la Observación de la Tierra para el aprovechamiento eficiente e innovativo de la información obtenida desde el espacio, con el desarrollo de aplicaciones requeridas por la sociedad, utilizando la información disponible, tanto de misiones de terceros con bajada de datos en territorio nacional, como de misiones propias, agregando valor a la información primaria para su uso y distribución.

En este marco se reconocen tres áreas estratégicas: ambiental, productiva y social. La SAN involucra las tres


áreas; por lo cual el desarrollo de productos que permitan su estudio a través de tecnologías espaciales, no solo contribuiría a la exploración y creación de nuevos conocimientos, sino tambien a la creación de herramientas para la toma de decisiones basadas en evidecia científica destinadas a la gestión de políticas de salud pública.

1.1. Objetivos

El objetivo general del presente trabajo fue *Explorar la capacidad de las tecnologías geoespaciales para el estudio de la Seguridad Alimentaria y Nutricional en la ciudad de Córdoba, durante el año 2013.*

Para ello se plantearon los siguientes objetivos específicos:

- Caracterizar la SAN a través de variables provistas por el Sensado Remoto
- Diseñar una metodología basada en el procesamiento de imágenes para la identificación de barrios socialmente vulnerables.
- Desarrollar modelos predictivos de enfermedades alimentario nutricionales indicadoras de alteraciones en la SAN.
- Analizar la dependencia espacial de la prevalencia de enfermedades vinculadas a alteraciones de la SAN.



Marco Teórico

2.1. Tecnologías geoespaciales

El término tecnologías geoespaciales es utilizado para describir un conjunto de herramientas utilizadas para la obtención, procesamiento, almacenamiento, análisis y representación de datos centrados en un contexto geográfico, temporal y espacial [Chuvieco, 2010]. En los últimos años, dichas tecnologías han brindado un nuevo enfoque de análisis en distintas disciplinas, destacando sus aportes en las ciencias de la salud. A continuación se descriiben las herramientas mas utilizadas.

2.1.1. Sistemas de Posicionamiento Globlal

Los Sistemas de Posicionamiento Global (GPS) permiten determinar el posicionamiento tridimensional de objetos estáticos o en movimiento en el espacio y el tiempo, en cada lugar del globo, en todas las condiciones meteorológicas y de forma continua. Están basados en la recepción de señales de radiofrecuencia emitidas desde satélites de telecomunicaciones artificiales. La estación terrestre debe estar equipada con una antena y un receptor: su grado de complejidad y costo dependen del nivel de precisión de medición necesario para determinar las coordenadas geocéntricas (WGS84) de cualquier punto de la superficie de la Tierra [Gomarasca, 2010].

2.1.2. Sensado Remoto

La teledetección o RS -por sus siglas en inglés-, hace referencia a la obtención de información de la superficie terrestre, utilizando imágenes adquiridas a través de sensores ubicados en plataformas satelitales o aerotransportados, capaces de medir la radiación electromagnética reflejada o emitida por los objetos ubicados en la superficie terrestre, a diferentes longitudes de onda [Press, 2011].

A continuación se describen los componentes que integran un sistema de teledetección [Chuvieco, 2010] (Fig. 2.1):

Fuente de energía. Es el origen de la radiación electromagnética que detecta el sensor. Se habla de teledetección de tipo pasiva, cuando se trata de una fuente externa al sensor (por ejemplo, el sol); y activa cuando el haz energético es emitido por el propio sensor.

Cubierta terrestre. Distintos tipos de cobertura de suelo (vegetación, agua, suelo desnudo, edificaciones, etc.) que reflejan la energía proveniente de la fuente y/o emiten su propia energía.

Sistema sensor. Formado por el sensor y la plataforma que lo sostiene. Capta la energía reflejada (o emitida) por la superficie terrestre, la codifica, almacena y envía al sistema de recepción.

Sistema de recepción. Recibe la información enviada por la plataforma, se realizan los primeros procesamientos de las imágenes.

Intérprete. Convierte los datos en información temática de interés.

Ususario final. Analiza, procesa y aplica la información obtenida. Es en éste punto dónde el dato obtenido se transforma en información de utilidad para dar respuesta a una necesidad concreta.




Figura 2.1: Componentes involucrados en el RS [Chuvieco, 2010].

Una característica fundamental de los sensores, que determinará su aplicación, es la habilidad para discriminar información de detalle. Es decir la capacidad del sensor para identificar distintos objetos, número y anchura de bandas del espectro que abarca, variaciones de energía y cadencia temporal, en otras palabras, su Resolución espacial, espectral, radiométrica y temporal [Chuvieco, 2010]. A continuación se describe cada una de ellas:

Resolución Espacial. Hace referencia al objeto mas pequeño que se puede distinguir en una imagen. El rango de resolución espacial de los sensores que actualmente se encuentran en funcionamiento, oscila entre 1 y 5 m^2 . Esta característica está intimamente ligada a la capacidad de interpretación de la imagen, ya que cuanto menor sea el tamaño del píxel, menor será la probabilidad de que este formado por distintas cubiertas terrestres.

Resolución Espectral. Esta característica está determinada por el número y anchura de las bandas espectrales que puede discriminar el sensor. En la figura se ilustran como se distribuyen las bandas en el espectro electromagnético según su longitud de onda. En este sentido un sensor con mayor resolución espectral podrá caracterizar espectralmente las cubiertas terrestres. Las bandas que se utilizan con mayor frecuencia son: el espectro visible, Infrarrojo Cercano, Infrarrojo Medio, Infrarrojo Lejano o Térmico y Micro-ondas.

Resolución Radiométrica. Indica la sensibilidad del sensor para detectar variaciones en la radiancia espectral que recibe. La imagen resultante refleja los datos recogidos por el sensor, los cuales son codificados en un formato binario (bits). De este modo la resolución radiométrica refleja el número de niveles digitales utilizados para expresar dichos datos. Cuanto mayor sea la resolución radiometrica, el nivel de detalle de la información será mayor, lo cual permitirá una mejor interpretación de imágenes.

Resolución Temporal. Este concepto se refiere a la frecuencia de cobertura que proporciona el sensor, a la periodicidad con la que éste adquiere imágenes de la misma región de la superficie terrestre. Ello está determinado fundamentalmente por las características orbitales [Chuvieco, 2010].

El RS presenta numerosas cualidades que lo convierten en una técnica complementaria al trabajo de campo, de gran valor ya que brinda una perspectiva panorámica del objeto de estudio, a través de una fuente homogénea y exhaustiva (cubre todo el territorio) de datos para todo el planeta. Además permite realizar observaciones con un enfoque multiescala y multi espectral, sin alterar la cobertura de la tierra; es posible obtener información con un amplio rango de cobertura y nivel de detalle, posibilitando extender las observaciones de ámbitos locales a globales.

2.1.3. Sistemas de Información Geográfica

Los Sistemas de Información Geográfica (GIS)-por sus siglas en inglés: Geographic Information Systemhacen referencia a un conjunto de herramientas que permiten recopilar, almacenar, recuperar cuando es necesario, transformar y mostrar datos espaciales del mundo real, con un fin específico [Burrough y McDonnell, 1998]. A través de los GIS es posible representar fénomenos del mundo real, en términos de:

- Posición con respecto a un sistema de coordenadas conocido.
- Atributos de interés en cada posición.
- Interrelaciones espaciales entre sí.

2.1.4. Análisis Espacial

El análisis espacial o geoestadística comprende un conjunto de herramientas y técnicas que sirven para analizar y predecir los valores de una variable que se muestra distribuida en el espacio de manera continua. Debido a su aplicación orientada al GIS, también podría definirse como las estadísticas relacionadas con los datos geográficos, por lo que también se conoce como estadísticas espaciales [García, 2004].

El desarrollo de los GIS y técnicas geoestadísticas, asi como la disponibilidad de datos de salud e indicadores de calidad ambiental, han facilitado la incorporación de la dimensión espacial a la mirada clásica de la distribución de las enfermedades y sus determinantes. Así, la epidemiología espacial describe y analiza las variaciones geográficas en la enfermedad con respecto a los factores de riesgo demográficos, ambientales, de comportamiento, socioeconómicos, genéticos e infecciosos [Elliott y Wartenberg, 2004]. En este sentido, como parte del componente del patrón observado, la ubicación donde un evento fue registrado puede proporcionar información en cuanto a las causas que desencadenan ese evento [Waller y Gotway, 2004].

Por lo tanto, la geoestadística aplicada a la epidemiología nutricional podría proporcionar diferentes enfoques analíticos a los propuestos por la epidemiología tradicional, respondiendo preguntas relacionadas con los entornos alimentarios, la distribución geográfica, el agrupamiento de enfermedades y la disponibilidad de alimentos saludables, accesibles económicamente.

2.2. Seguridad Alimentaria y Nutricional

2.2.1. Concepto y situación actual

En el mundo se producen suficientes alimentos para alimentar a toda la población. Sin embargo, el hambre y la malnutrición, por déficit o exceso, son las problemáticas mas difíciles que enfrenta la humanidad desde sus orígenes [Tansey, 2011]. En este marco, en la década del '70, la Food and Agricultural Organization (FAO) de las Naciones Unidas, propulsó el concepto de Seguridad Alimentaria. Desde entonces, este concepto ha evolucionado, incorporando progresivamente diferentes dimensiones de análisis conforme la propia dinámica de la problemática alimentaria reconocía distintos enfoques.

En sus inicios, la SAN era sinónimo de políticas vinculadas al aumento de la producción y la productividad agroalimentaria en un renovado intento por asegurar flujos de alimentos suficientes y regulares. En los años '80, tornó hacia el problema del acceso -económico- a los alimentos. Este momento fue coincidente con el paradigma de desnutrición calórico-proteica -el "hambre"- y el auge de programas de distribución directa de alimentos a la población mas empobrecida. Luego, ya en los '90 el concepto de "hambre" fue progresivamente reemplazado por el de desnutrición "oculta", denominación que reciben ciertas manifestaciones de carencias de micronutrientes que no necesariamente se reflejan en un cuadro de desnutrición calórico-proteica. Las personas, aún pobres, no necesariamente comen poco pero sí de manera desequilibrada, de forma tal que las manifestaciones de hambre agudo son menores que otras formas de malnutrición: la talla disminuida en los niños, diferentes carencias de nutrientes esenciales y -más recientemente- el sobrepeso y obesidad [Britos, 2008a].

En la actualidad, se reconoce que la expresión SAN representa de manera integral la problematica alimentaria y nutricional ya que involucra todos los aspectos y actores que forman parte de los sistemas alimentarios. Por lo tanto se dice que un país, una comunidad, una familia tiene SAN,

cuando todas las personas tienen en todo momento acceso físico, social y económico a alimentos inocuos, cuyo consumo es suficiente en términos de cantidad y calidad para satisfacer sus necesidades y preferencias alimentarias, y se sustenta en un marco de saneamiento, servicios sanitarios y cuidados adecuados que les permiten llevar una vida activa y sana FAO [2011a].

Por lo tanto para analizar la SAN, es necesario abordar las 4 dimensiones que la componen:

Disponibilidad de alimentos. Existencia de cantidades suficientes de alimentos de calidad adecuada, a nivel local o nacional, teniendo en cuenta la producción, las importaciones, el almacenamiento y la ayuda alimentaria.

Acceso a los alimentos. Acceso económico y social a los alimentos disponibles en el mercado como así también a los medios de producción (agua, insumos, tecnología, conocimientos, etc.)

Utilización biológica. Los alimentos consumidos deben responder tanto a las necesidades nutricionales, como así también al patrón alimentario y preferencias. Además se debe considerar, la inocuidad de los alimentos y la distribución intrafamiliar. La utilización biológica hace referencia al uso individual de los alimentos (ingestión, absorción y utilización de nutrientes). Una inadecuada utilización biológica puede tener como consecuencia la desnutrición y/o la malnutrición. Así, el agua potable, sanidad y atención médica, son fundamentales para lograr un estado de bienestar nutricional en el que se satisfagan todas las necesidades fisiológicas [FAO, 2011b].

Estabilidad. Hace referencia a la capacidad de una población, hogar o individuo para cubrir las variciones estacionales o cíclicas, que pudieran afectar la disponibilidad y/o el acceso a los alimentos. Las situaciones que podrían afectar la estabilidad estan asociados a las campañas agrícolas, tanto por la falta de producción de alimentos en momentos determinados del año o eventos adversos tales como inundaciones, erupciones volcánicas, etc, como así tambien por el acceso a recursos de las poblaciones.

Es decir, la SAN está determinada por aspectos socioculturales, económicos, políticos, ambientales, biológicos y geográficos, entre otros. En la Figura 2.2 se describen los principales determinantes que influyen en los pilares de la SAN [FAO, 2011a].



Figura 2.2: Dimensiones de la SAN y sus principales determinantes

Por otro lado, existen distintas amenazas (principalmente de origen climático, socioeconómico y sanitario), que pueden impactar en uno o más pilares disminuyendo la SAN. Esto desencadenaría una situación de IAN caracterizada por acceso incierto o nulo a alimentos nutricionalmente adecuados y socialmente aceptables. El grado de IAN dependerá de la intensidad del impacto y de la vulnerabilidad de la población afectada.

Para caracterizar los niveles de IAN que pueden presentarse en la población, el *United States Department of Agriculture (USDA)* estableció los siguientes niveles:

- **Baja SAN**: Anteriormente se denominaba *IAN sin hambre*. Hace referencia a aquellos hogares en los que se informa una baja calidad, variedad o adecuación de la dieta. Pero no se reporta una reduccion en la ingesta de alimentos.
- Muy baja SAN: Hace referencia a aquellos hogares en los que el patrón de consumo de alimentos se vio interrumpido, evidenciando una reducción de la ingesta de alimentos. En este caso, la IAN es acompañada por el hambre.

En Argentina, la disponibilidad de alimentos excede los requerimientos nutricionales de la población [FAO, 2015]. Sin embargo, la Encuesta Nacional de Nutrición (Ministerio de Salud de la Nación, 2019) consolidó y corroboró resultados de estudios previos: en niños pre-escolares el exceso de peso triplica o más la frecuencia de bajo peso y baja talla. Más aún, muchos de ellos con exceso de peso y aparentemente sanos tienen baja talla, anemia por deficiencia de hierro o ingestas insuficientes de calcio, vitamina C o algunos ácidos grasos esenciales (por ejemplo los de la familia omega 3). En la población escolar los problemas son los mismos -con excepción de la anemia-, de forma tal que la mitad de la población que llega a la adultez continúa con sobrepeso u obesidad y sus enfermedades relacionadas (diabetes, hipertensión, enfermedades cardiovasculares, ciertos tipos de cáncer, entre otras)[Secretaría de Gobierno de Salud, 2019; Britos, 2008b]. Este panorama epidemiológico limita el desarrollo potencial de las sociedades, con grandes costos en términos sanitarios y humanos [FAO, 2011a; Elgart et al., 2010].

Además de esta situación, se observó con mayor frecuencia en sectores socioeconómicos mas vulnerables [Secretaría de Gobierno de Salud, 2019; Britos, 2008b]. Así la situación de la SAN en Argentina, refleja lo expresado por Teubal (1989):

"...Si bien se trata de un problema complejo y multidimensional, es fundamentalmente un problema de acceso a la alimentación, de falta de capacidad de adquirir o acceder a los alimentos por parte de determinados sectores sociales...Por consiguiente constituye un problema socioeconómico y político, un problema estructural inherente al modelo económico instaurado en el país y a la evolución que ha tenido en él nuestro sistema alimentario" [Teubal, 1989].

La SAN en Argentina se encuentra fuertemente asociada a la estratificación socio-económica y las Necesidades Básicas Insatisfechas (NBI) de los hogares. En el año 2011, la IAN afectaba al 24,5 % de hogares correspondientes a estratos sociales muy bajo y al 28,4 % de hogares con NBI severo mientras que solo el 1,2 % de los hogares de estratos sociales medio alto y el 8 % de hogares sin NBI presentaron IAN [Salvia et al., 2012].

Por lo cual las dimensiones de la SAN mas vulnerables son el acceso y la utilización biológica de los alimentos. No obstante, en un contexto de cambio climático, todos las dimensiones de la SAN se ven potencialmente afectadas, ya que los eventos adversos tales como sequías, inundaciones, tormentas severas, etc., afectan en forma negativa los sistemas productivos (disminuyendo su capacidad productiva y aumentando las pérdidas post-cosecha), además impacta en los medios de subsistencia de los hogares, la disponibilidad de agua potable y la inocuidad alimentaria, exacerbando los riesgos y vulnerabilidades socioeconómicos [FAO, 2016].

2.2.2. La Malnutrición como expresión de la IAN

Durante las últimas décadas, los cambios rápidos en los niveles y la composición de los patrones alimentarios y de actividad (o inactividad) física en las sociedades de transición están relacionados con los cambios socioeconómicos y demográficos [Popkin, 2001]. Estos cambios han conducido a una transición epidemiológica nutricional caracterizada por un aumento en la prevalencia de enfermedades crónicas no transmisibles (enfermedades cardiovasculares y ciertos tipos de cáncer) y factores de riesgo asociados (obesidad, dislipemias, hipertensión, entre otros). Por otro lado, aunque la prevalencia de desnutrición se ha reducido en algunas regiones, ha sido reemplazada por diferentes formas de malnutrición crónica, caracterizadas por déficit de nutrientes como vitamina A, zinc y hierro, que dan lugar a un nuevo tipo de enfermedad: la Desnutrición oculta.

Esta situación plantea una IAN paradójica: la coexistencia de enfermedades por carencia y por exceso. La obesidad y la desnutrición coexisten en una misma región, en una misma familia (madres obesas con hijos desnutridos) y en una misma persona (obesidad con retraso de crecimiento, anemia, etc) [Oyhenart et al., 2017].

La obesidad en la pobreza está asociada a una situación de desnutrición durante los primeros años de vida, incluso durante la vida intrauterina. Esta carencia desencadena una respuesta de adaptación al deficit energético que, en sucesivas etapas de mayores ingestiones, pueden producir como resultado un aumento de peso. En estos casos, la obesidad se relaciona con ingesta energética superior a las necesidades y deficiente en nutrientes esenciales, como aminoácidos y micronutrientes [Pedraza, 2009; Dhurandhar, 2016]. Los pobres seleccionan alimentos pobres en fibras y ricos en carbohidratos complejos, azúcares y grasas (especialmente ácidos grasos trans, ácidos grasos saturados y colesterol) que, aunque les impiden gozar de una nutrición adecuada, satisfacen su apetito, se integran bien a su patrón de consumo tradicional y a sus pautas de comensalismo. El consumo de comidas rápidas, caracterizadas por una elevada densidad energética y baja calidad nutricional, presenta gran influencia en estos contextos [Aguirre, 2006].

Por lo tanto, la complejidad de la expresión de la IAN, hace visible la necesidad de estudiar los aspectos que subyasen y definen la SAN, ya que repercuten de manera directa la epidemiología nutricional.

2.2.3. SAN y urbanización

Desde la finalización de la Segunda Guerra Mundial, el mundo experimenta un crecimiento poblacional sin precedentes. Según el reporte elaborado por el Fondo de Población de las Naciones Unidas, en 2016, la población mundial llegó a 7400 millones de personas [Kollodge, 2016]. Dicho crecimiento es acompañado por una transición demográfica y urbana: actualmente más de la mitad de la población vive en áreas urbanas y se espera que para el año 2050, el 66% de la población mundial se concentre en las ciudades [United Nations y Social Affairs, 2015].

Este escenario plantea nuevos desafíos para garantizar la SAN: a medida que las ciudades crecen se necesita no sólo mayor disponibilidad de alimentos de calidad, sino también, servicios de saneamiento ambiental, acceso a servicios de salud, vivienda digna, educación y empleos. La SAN en áreas urbanas depende principalmente de la capacidad de compra de los hogares. Por lo cual, es fundamental fortalecer los nexos entre las áreas urbanas y rurales, reconociendo la importancia del rol de la agricultura urbana y periurbana en la garantía de la SAN.

Por otro lado, en un contexto donde la población urbana es predominante, surge el concepto de Entornos Alimentarios, definidos en términos de acceso geográfico a los alimentos en una comunidad o vecindario, las experiencias de los consumidores dentro de los puntos de venta de alimentos, los servicios y la infraestructura en entornos institucionales, o la información disponible sobre los alimentos [Glanz et al., 2005]. Así, los Entornos Alimentarios Saludables, proporcionan un acceso equitativo a alimentos saludables. Las frutas y verduras frescas y los alimentos integrales están disponibles en una variedad de puntos de venta minorista y de servicio de alimentos, y hay opciones más saludables disponibles para los alimentos preparados y preenvasados. Además, brindan oportunidades para la producción de alimentos y fortalecimiento de las redes de distribución de alimentos, así como programas comunitarios e infraestructura para apoyar una alimentación saludable [Rideout et al., 2015].

En los últimos años ha cobrado relevancia el estudio de los efectos de los barrios sobre la salud de sus residentes, y particularmente el impacto sobre la alimentación y nutrición. Diversos autores hacen visible la necesidad de considerar no sólo las características individuales sino también las características de los grupos o contextos a los que pertenecen los individuos para comprender la distribución de la salud y la enfermedad [Dubowitz et al., 2012; Mayer et al., 2014; Diez Roux y Mair, 2010]. Así, las áreas residenciales han surgido como potenciales contextos relevantes porque poseen atributos tanto físicos como sociales que podrían afectar la salud de las personas.

2.3. Aplicación de Tecnologías geoespaciales en el estudio de la SAN

Tradicionalmente, la aplicación de tecnologías geoespaciales para el estudio de la SAN se ha orientado al abordaje de aspectos relacionados con la producción agrícola, factor determinante de la disponibilidad alimentaria. Concretamente se ha centrado en la evaluación del estado de salud de la vegetación para estimar así el rendimiento de los cultivos, y posibilitar la generación de alertas ante situaciones de escasez de alimentos.

Desde la década de los '80, las generaciones de los satélites de la National Oceanic and Atmospheric Administration (NOAA), han estudiado las características fisiológicas de los cultivos. Hasta el año 2011, la serie de sensores Advanced Very High Resolution Radiometer (AVHRR), se utilizaron como herramienta en la planificación agrícola, la previsión y el monitoreo de la sequía y la estimación de rendimientos, con una resolución espacial media. Justice y colaboradores (1985), utilizaron el Índice de Vegetación de Diferencia Normalizada (NDVI) para evaluar los cambios fenológicos en la vegetación que ocurridos durante las estaciones tanto a nivel global como subcontinental (África, América del Sur y Asia Oriental) [Justice et al., 1985]. Históricamente, las sequías han sido identificadas como la causa principal de las emergencias alimentarias, diversos trabajos dan cuenta de ello utilizando y datos de NDVI de NOAA y datos de precipitación para evaluar el impacto de la sequía sobre la producción agrícola en África [Helldén y Eklundh, 1988; Johnson et al., 1993]. A partir de 2012, se incorpora a la nueva generación de satélites NOAA, el instrumento Visible Infrared Imaging Radiometer Suite (VIIRS), a bordo del satélite Suomi National Polar Orbiting Partnership (S-NPP). Las características del sensor de alta resolución (1 km²) permitió mejorar la detección temprana de sequías, monitoreando la inten-

sidad, duración, área, origen e impactos; intentando así estimar y predecir la escasez de alimentos. Desde 2018, gracias a los satélites operacionales J1-/VIIRS (NOAA-20) es posible realizar una evaluación y seguimiento de los cultivos a una resolución de 0.5 km² [Kogan et al., 2019].

Gracias al desarrollo de estas tecnologías, distintas agencias internacionales crearon sistemas de monitoreo y alerta temprana ante situaciones de IAN.

En 1975, a partir de las necesidades identificadads en la Cumbre Mundial de la alimentación, la FAO desarrolló el Global Information and Early Warning System (GIEWS), con el fin de advertir sobre cualquier crisis de escasez alimentaria inminente, sequías y hambre a nivel individual o subregional para que las agencias de ayuda y las organizaciones de donantes puedan planificar intervenciones oportunas y evitar el sufrimiento en los países afectados. En particular, GIEWS utiliza Espectrorradiómetro de imágenes de media resolución (MODIS), AVHRR/NOAA, para obtener índices de vegetación y estimación de precipitaciones [Hielkema y Snijders, 1994; Minamiguchi, 2005].

Luego del sufrimiento de hambrunas en Africa y el este de Asia, la United States Agency for International Development (USAID) creó en 1985 -con apoyo de la NOAA, la United States Geological Service (USGS) y la National Aeronautics and Space Administration (NASA)- el Famine Early Warning System (FEWS), a fin de proveer de información objetiva a los tomadores de decisiones. A través de su geo-server es posible acceder a información para el monitoreo de las sequías, y la planificación de las intervenciones alimentarias. Dicho sistema utiliza productos obtenidos de AVHRR/NOAA, MODIS, Landsat, Sentinel y Satellite Pour l'Observation de la Terre (SPOT), tales como: NDVI, Índice de Vegetación mejorado (EVI), Índice de Nieve (NDSI), Índice Diferencial de Agua Normalizado (NDWI), evapotranspiración, niveles de clorofila del océano y estimación de precipitaciones. Con estos datos se construyen modelos agro-meteorológicos para evaluar el estado de los cultivos [Brown, 2008].

Ambos sistemas no sólo abordan la disponibilidad de alimentos, sino que los datos ambientales provistos por la teledetección se analizan junto con los datos socioeconómicos (medios de subsistencia, comercio y mercado) para determinar el impacto de estas variables sobre el acceso económico a los mismos [Minamiguchi, 2005; Brown, 2008].

Gracias a la disponibilidad de sensores con alta resolución espacial, diversos autores destacan la aplicación de imágenes satelitales en el estudio de la disponibilidad alimentaria en escala urbana. Kemelin (2001) utilizó una serie temporal de imágenes de alta resolución del satélite IKONOS para el estudio de la dinámica de la agricultura urbana en Ouagadougou y Burkina Faso [Kemeling, 2001]. Por otro lado, Chen (2007), utilizó imágenes de Landsat para describir el impacto del proceso de urbanización en China y su impacto sobre las áreas destinadas al cultivo de alimentos de proximidad [Chen, 2007]. Asimismo, Pandey y Seto (2015), evaluaron la pérdida de áreas periurbanas detinadas a la producción de alimentos como consecuencia del avance de la frontera de urbanización, entre 2001 y 2010. En este caso, utilizaron series de tiempo de NDVI obtenido de MODIS, y de imágenes nocturnas (Nigthtime Ligth Series) provistas por el Programa de Satélites Meteorológicos de Defensa - Sistema Operacional Linescan (DMSP-OLS) - NOAA para caracterizar la dinámica urbana y la rural [Pandey y Seto, 2015].

Como se mencionó anteriormente, la SAN de los hogares urbanos depende fuertemente de la capacidad de compra de los mismos, es decir, del acceso económico a los alimentos. Un estudio conducido por Brown y Kshirsagar (2015) analizó la variación de los precios en los mercados locales, debido a anomalías climáticas locales y la variación de los precios en el mercado internacional. A partir de datos de NDVI obtenido de MODIS se caracterizó el impacto de eventos climáticos adversos en la producción primaria local. De esta manera se determinó que el precio de los alimentos en el mercado local, son más sensibles al los efectos de los eventos climáticos adversos en las cercanías de las comunidades que al cambio en los precios del mercado internacional [Brown y Kshirsagar, 2015].

Lopez Carr y colaboradores (2015), estudiaron la relación entre la malnutrición infantil y el cambio climático. En esa contribución mostraron que la vulnerabilidad 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 [López-Carr et al., 2015]. Asimismo Johnson y colaboradores (2013), utilizaron MODIS para estudiar cómo el bosque nativo influye en la utilización biológica. Los bosques desempeñan un importante papel de aprovi-

sionamiento, 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 [Johnson et al., 2013].

En Somalia, Kinyoki et al. (2016) realizaron un estudio para predecir los niveles y patrones de retraso del crecimiento infantil en una resolución espacial alta utilizando los datos de encuestas oficiales disponibles y covariables ambientales: precipitación, Índice de Vegetación Mejorado (EVI), temperatura, distancia a las principales fuentes de agua y urbanización. Los resultados muestran que la tasa de retraso del crecimiento en Somalia es espacial y temporalmente heterogénea, y las precipitaciones y la vegetación son los principales impulsores de estas variaciones [Kinyoki et al., 2016].

Por otro lado, existe evidencia de la contribución de las tecnologías geoespaciales para el análisis de Entornos Alimentarios Saludables. Mendes et al. (2013) en Brasil y Lakes and Burkart (2016) en Berlin, evaluaron variables individuales y variables dentro del entorno construido y social por su posible asociación con sobrepeso y obesidad en una población urbana. En ambos estudios, a partir de datos georreferenciados se construyeron mapas y se observó una variación intraurbana de la prevalencia de dicha enfermedad, dependiente de la vulnerabilidad social y de la mayor disponibilidad de comercios expendedores de çomida chatarra"(fast food) [Mendes et al., 2013; Lakes y Burkart, 2016]. Siguiendo esta perspectiva de análisis, en Corea, Kim et al. (2016), aplicaron técnicas de interpolación geoestadísticas, para identificar áreas de dificil acceso (físico y económico) a alimentos saludables y frescos; concepto que se conoce como *Food deserts* [Kim et al., 2016].

Por lo anteriormente expuesto, se puede concluir que las tecnologias geoespaciales permiten descubrir como es la interacción entre las distintas dimensiones que construyen los sistemas alimentarios y que impactan en el proceso salud - enfermedad. Si bien, el uso tradicional de estas herramientas se ha centrado en el abordaje de la disponibilidad alimentaria, en los últimos años se ha demostrado su potencial para el abordaje integral de la SAN.

Capítulo 3

Área de estudio y materiales

3.1. Descripción general del área de estudio

El presente trabajo se realizó en la ciudad de Córdoba, Argentina, capital de la provincia homónima. Sus coordenadas centrales son las siguientes: 31°24'38.3"S - 64°11'33.8"O (Fig.3.1).

Según el último Censo nacional, realizado en el año 2010, Córdoba es la segunda ciudad más poblada del país, con un total de 1.330.023 habitantes. La misma está compuesta por 483 barrios y 59 asentamientos. Aproximadamente el 6% de los hogares presenta al menos una Necesidad Básica Insatisfecha: hacinamiento crítico, tipo de vivienda inconveniente, condiciones sanitarias deficitarias, inasistencia escolar de menores de 6 a 12 años o incapacidad de subsistencia (datos procesados con Redatam +Sp).




Figura 3.1: Distribución de los Centros de Salud Municipales de la ciudad de Córdoba, Argentina (2013). Composición en color Imagen Landsat 8, Bandas Infrarrojo de onda corta 2 (2,11 – 2,29μ), Infrarrojo de onda corta 1 (1,57 – 1,65μ) y Rojo (0,64 – 0,67μ)

3.2. Materiales

3.2.1. Datos epidemiológicos

Los datos epidemiológicos fueron aportados por la Dirección Municipal de Atención Primaria de Salud y corresponden a 79 CAPS. Se trabajó con el número de casos de enfermedades alimentario-nutricionales como: desnutrición, sobrepeso y obesidad, ETAs, y anemia, registrados durante el año 2013, así como el total de personas que asistieron a cada CAPS. Se estableció un área de cobertura de cada CAPS de 1 kilómetro a la redonda. En la Fig.3.2 se presenta la distribución espacial de los CAPS y la prevalencia de las enfermedes mencionadas.




Figura 3.2: Distribución espacial de los CAPS bajo estudio y prevalencia anual de las enfermedades de interés. Córdoba, 2013

3.2.2. Imágenes Satelitales

Se utilizó una imágen multiespectral del satélite SPOT 5, provista por la Comisión Nacional de Actividades Espaciales Comisión Nacional de Actividades Espaciales (CONAE), con fecha de adquisición en enero de 2013. Este satélite de alta resolución espacial provee imágenes multiespectrales, constituidas por 4 bandas espectrales (verde, rojo, infrarrojo cercano e infrarrojo medio), con una resolución espacial de 10 metros. Mientras que la

banda pancromática presenta una resolución espacial de 5 metros. En la Tabla 3.1 se describen las características de las imágenes provistas por dicho sensor.

SPOT 5: características de principales				
Banda	Longitud de onda(µm)	Resolución espacial (m)		
Pancromática	0,48 - 0,71	5		
Verde	0,50 - 0,59	10		
Rojo	0,61 - 0,6	10		
Infrarrojo cercano	0,78 - 0,89	10		
Infrarrojo medio	1,58 - 1,75	10		

Tabla 3.1: Principales características de las imágenes SPOT 5. Fuente: https://spot.cnes.fr/en/SPOT/index.htm

3.2.3. Datos ambientales

A partir de la información - espectral y espacial- de la imagen satelital, se construyeron variables que permitieran realizar una descripción ambiental de la ciudad. Así, se obtuvieron las siguientes variables:

Índice Normalizado de Suelo (NSI): Este índice propuesto por Roger y Kearney, destaca las áreas construidas y suelos desnudos (valores cercanos a 1), dado que estas superficies son más reflectivas en el Infrarrojo de onda corta (SWIR) que en el Infrarrojo cercano (IRC). Se obtiene a través de la siguiente ecuación:

$$NSI = \frac{(SWIR - IRC)}{(SWIR + IRC)} \tag{3.1}$$

Como puede observarse en la Figura 3.3, los valores mas elevados se observaron en las zonas con urbanización densa (construcciones edilicias) y aquellas áreas libres de vegetación. Mientras que en la periferia de la ciudad se encontraron valores elevados en áreas destinadas a cultivos y que en el momento de la adquisición de la imagen, las mismas presentaban suelo desnudo.




Figura 3.3: Valores de NSI para la ciudad de Córdoba, 2013

Distancia a los cursos de agua: A partir de una capa vectorial de los cursos de agua permanentes y no permanentes, provista por el proyecto MAPEAR, se creó un buffer de distancia de 1000 mts. A dicha capa vectorial, se agregaron cuerpos de agua de interés como las lagunas de la Estación Depuradora de Aguas Residuales de Bajo Grande (Figura 3.4).




Figura 3.4: Buffer de distancia a los cursos de agua, expresado en metros. Ciudad de Córdoba, 2013

Distancia al área periurbana: En este trabajo el área periurbana es concebida como la interfase donde se atenúan o disminuyen varios servicios del sistema urbano, como agua potable, electricidad, desagües pluviales, pavimento, recolección de residuos, sanidad, cloacas; y también se atenúan servicios ecológicos que provee el campo como la capacidad de absorber dióxido de carbono, de fijar energía solar en forma de energía química, reciclar nutrientes, controlar el balance de poblaciones animales y vegetales, evitando la exposición de plagas, regular los flujos de agua, atemperar los extremos climáticos, etc. Pero el proceso ecológico más importante del área periurbana consiste en que se carga continuamente de productos del metabolismo de la ciudad, hasta llegar a la saturación (humo, efluentes, contaminantes, basurales, etc.). En síntesis, el área periurbana puede entenderse como un espacio donde se acumulan discontinuidades de servicios urbanos y rurales, y dónde se concentran metabolitos de difícil y lenta digestión y dilución [Morello, 2000]. Para establecer la distancia al área periurbana de la ciudad, se creó un buffer de 1000 metros (Figura 3.5).





Figura 3.5: Buffer de distancia al área periurbana de la ciudad de Córdoba, expresado en metros. Año 2013



Discriminación de áreas urbanas según vulnerabilidad social a través del Sensado Remoto

4.1. Introducción

Como se mencionó en el Capítulo 2, la pobreza es uno de los determinantes principales de la SAN en áreas urbanas, ya que no sólo impacta en el acceso a una alimentación adecuada, sino también en el acceso a servicios de salud y saneamiento ambiental, los cuales influyen en la utilización de los alimentos. En áreas urbanas, la expresión de la pobreza se ve reflejada en el surgimiento y expansión de barrios vulnerables. Según el programa UN-Habitat de Naciones Unidas, actualmente un cuarto de la población urbana mundial vive en barrios vulnerables como asentamientos informales con construcciones edilicias precarias, o zonas con falta de acceso a agua segura y/o saneamiento ambiental adecuado [UN-Habitat, 2016]. La ciudad de Córdoba no es ajena a esta realidad. De acuerdo al último Censo Nacional de población, hogares y viviendas (2010) existe un total de 59 asentamientos informales en los que viven 27.446 personas. Además, aproximadamente el 60% de los barrios residenciales presentan viviendas inadecuadas, ya sea debido a su construcción precaria o a falta de servicios de saneamiento.

Es importante comprender que los barrios socialmente vulnerables, no desaparecen por medio de la remoción sino de la transformación. Por lo cual se hace visible la necesidad de desarrollar metodologías eficaces, capaces de brindar información de manera rápida y accesible acerca de su ubicación, extensión, características ambientales, población que la habita, etc [Kuffer et al., 2016].

Por lo cual, en este capítulo se desarrolló un método que combina el análisis de textura y la clasificación semiautomática y se analizó su capacidad de discriminación de áreas de distintos estratos sociales (bajo y medio-alto) de la ciudad de Córdoba.

4.2. Métodologías empleadas en la identificación de áreas urbanas socialmente vulnerables

En las últimas décadas, gracias al desarrollo sensores capaces de adquirir imágenes de alta resolución espacial y espectral, y el avance de metodologías en el procesamiento de imágenes, el SR se convirtió en una potente herramienta para el estudio de los usos de suelo, la planificación urbana y gestión de servicios básicos. Diversos autores han evaluado la capacidad del SR para identificar asentamientos informales. Es posible cuantificar las características espaciales de los elementos de cobertura de la tierra, tales como tejados, suelo y vegetación, para servir como indicadores para la identificación tanto de áreas de barrios marginales como de

áreas residenciales asociadas con un mayor nivel socioeconómico [Weeks et al., 2007]. Así, trabajos previos sugieren los siguientes indicadores para el estudio de áreas urbanas de distintos estratos sociales: vegetación, calles (material, dimensiones, conectividad), geomorfología del terreno, textura, proximidad a áreas de riesgos, orientación de las casas, proximidad al centro de la ciudad y servicios sociales, tamaño y forma de las viviendas, materiales de los techos [Owen y Wong, 2013b].

De esta manera, los métodos más utilizados para la identificación de barrios socialmente vulnerables son [Kuffer et al., 2016]:

- Interpretación visual de imágenes
- Enfoque basado en objetos
- Análisis de textura/morfología

Si bien la interpretación visual de imágenes de alta resolución espacial sigue siendo utilizada para la detección de áreas marginales, el desarrollo de métodos de procesamiento de imágenes ha cobrado gran importancia ya que permite por un lado, optimizar las capacidades de las imágenes de media resolución y además diseñar métodos de identificación semiautomáticos.

El análisis de imágenes basado en objetos es el método más utilizado [Kuffer et al., 2016]. Consiste en la extracción de las características de la vivienda y realiza estimaciones basadas en la forma, tamaño y espacio entre objetos. No obstante, presenta limitaciones en la identificación de áreas de estratos sociales más bajos, tales como: líneas continuas de techos, pixelado incorrecto de los contornos de las edificaciones y separaciones incorrectas de la vivienda debido a diversos materiales en un mismo techo. Además, este método requiere de la personalización de las reglas de entrenamiento, por lo cual limita la aplicación del mismo en áreas geográficas más grandes [Owen y Wong, 2013b; Kuffer et al., 2016].

Por otro lado, la aplicación del análisis de las características de la textura de una imagen, es decir la distribución espacial de la variación de tonos de una banda determinada, ha sido ampliamente utilizado en ambientes urbanos para aumentar la separabilidad de diferentes usos de suelo, presentando gran efectividad en la extracción de barrios vulnerables [Pesaresi y Benediktsson, 2001; Stasolla y Gamba, 2007]. El método de análisis de textura propuesto por Haralick y cols (1973) utiliza el método Matriz de Co-ocurrencia de Niveles de Grises (GLCM), para obtener medidas de textura como la entropía, media, varianza, contraste y asimetría. El GLCM consiste en un histograma bidimensional de niveles de gris para un par de píxeles separados por una distancia determinada. Resumiendo así, la frecuencia relativa con la cual un tono gris aparece con una relación espacial específica con otro tono gris de la imagen [Haralick et al., 1973]. La entropía ha sido aplicada como indicador de barrios marginales, ya que los mismos presentan una alta variación tonal [Yeh y Li, 2001; Zhang y Kukadia, 2005; Azar et al., 2010]. El contraste es otra medida de textura que evalúa la variación de brillo respecto a píxeles vecinos. Altos contrastres denotan una gran diferencia de intensidad respecto a los píxeles vecinos y una mayor variedad de materiales de superficie, formas y tamaños. Por ejemplo, áreas urbanas marginales, con presencia de basureros presentan un alto contraste[Owen y Wong, 2013a]. Además, el análisis de textura GLCM permite la adopción de métodos de clasificación no supervisada potenciando así la capacidad de discriminación de áreas urbanas en dos clases [Stasolla y Gamba, 2007].

4.3. Metodología

4.3.1. Uso de suelo de la ciudad de Córdoba

Como primer paso, se analizó el uso de suelo de la ciudad de Córdoba. Para ellos, tal como se mencionó en el capítulo 3, se trabajó con una imagen multiespectral del satélite SPOT 5. Se utilizó el programa QGis 2.8, el cual cuenta con el plug-in *Sensum Earth Observation Tools*, y utiliza librerías de Orfeo Tool Box. Además, con el fin crear una imagen que permita una mejor interpretación visual, se realizó un *pansharpening* entre la imágen pancromática y las multiespectralees. A partir de esta imagen se realizó una clasificación supervisada,

utilizando el método *lib SVM*, el cual está basado en el algoritmo *Support Vector Machine (SVM)*. Un algoritmo basado en SVM construye un modelo capaz de predecir si un punto nuevo (cuya categoría desconocemos) pertenece a una categoría o a la otra. Como en la mayoría de los métodos de clasificación supervisada, los datos de entrada (los puntos) son vistos como un vector p-dimensional. El SVM busca un hiperplano que separe de forma óptima a los puntos de una clase de la de otra, que eventualmente han podido ser previamente proyectados a un espacio de dimensionalidad superior. En ese concepto de *separación óptima* es donde reside la característica fundamental de las SVM: este tipo de algoritmos buscan el hiperplano que tenga la máxima distancia (margen) con los puntos que estén más cerca de él mismo. Por eso también a veces se les conoce a las SVM como clasificadores de margen máximo. De esta forma, los puntos del vector que son etiquetados con una categoría estarán a un lado del hiperplano y los casos que se encuentren en la otra categoría estarán al otro lado [Pontil y Verri, 1997].

Las clases de interés definidas para este trabajo fueron las siguientes:

- Cultivos
- Vegetación (árboles, arbustos, bosque)
- Urbanización
- Cuerpos de agua
- Suelo expuesto

4.3.2. Discriminación de áreas urbanas según estrato social

Luego, se aplicó un método que combina el análisis de textura GLCM y la clasificación no supervisada y se analizó su capacidad de discriminación de barrios correspondientes a estratos sociales medio-alto y bajo. Para ello, se estudiaron en detalle las características de los patrones espaciales de dos vecindarios con características sociales muy diferentes, pero espacialmente cercanos unos de otros: Villa Urquiza (vulnerabilidad social media-alta) y Urca - Ampliación Urca (vulnerabilidad social baja) (Fig. 4.1). Según datos del último censo nacional, el 15 % de los hogares situados en el barrio Villa Urquiza presenta por lo menos un indicador de privación, en otras palabras, se trata de un hogar con Necesidades básicas Insatisfechas (NBI). Por otro lado, en los barrios Urca y Ampliación Urca existe solamente un 1,5 % de hogares con NBI [INDEC, 2012].

Para evaluar los parámetros ambientales en esta área se decidió explotar la imagen SPOT 5 utilizando características espectrales y espaciales para su clasificación. Específicamente, las características de textura basadas en el método GLCM. A partir de la Banda Verde se calcularon las siguientes medidas de textura: *rango de datos, Media, Varianza, Entropía y Asimetría*; cabe destacar que pueden obtenerse resultados similares si estas texturas se calculan a partir de las otras bandas multiespectrales. Para explotar la resolución espacial fina de la imagen, se consideró una ventana de procesamiento muy pequeña (5x5 píxeles). Todas las capas de textura generadas se apilaron a la imagen original con sus cuatro bandas, y se realiza una clasificación no supervisada con el algoritmo de *K-means*. El umbral de separación entre clases establecido, fue de 5%. De hecho, no se consideró ninguna estrategia supervisada, ya que en este caso un píxel no representa una cobertura de suelo sino una estructura espacial. En su lugar, para poder captar los detalles requeridos para los mapas de cobertura de tierra urbana, el número de clases se estableció en el número relativamente grande de 30. A partir de esta clasificación, se examinó el porcentaje de cada clase en cada barrio, estableciendo así su capacidad de discriminación.




Figura 4.1: Imagen Spot 5 (banda verde), de una pequeña parte de la ciudad de Córdoba, cubriendo el sector que incluye a los barrios Villa Urquiza y Urca-Ampliación Urca

4.4. Resultados

4.4.1. Uso de suelo de la ciudad de Córdoba

En la Figura 4.2 puede observarse la distribución de las distintas clases de usos de suelo en la ciudad de Córdoba. Este método resulta ser muy efectivo como primer acercamiento al análisis del uso de suelo ya que logra discriminar las clases entrenadas. No obstante, es necesario optimizar el método de clasificación, combinando otras técnicas de procesamiento, ya que se encontraron ciertas limitaciones:

- Las sombras son clasificadas como agua: Este hecho se puede observar principalmente en barrios con edificaciones elevadas.
- Las zonas con cesped (canchas de fútbol, parques, etc) son clasificadas como cultivos.
- Distinta clasificación en función del material de construcción de los techos: pudiendo ser clasificados como urbanización o suelo expuesto.

Cabe destacar que a través de este método no fue posible separar la clase urbana en distintas subclases, como por ejemplo zonas residenciales de distinto estrato social o zonas industriales. Además, al tratarse de imágenes satelitales, su uso está limitado por la presencia de nubosidad, ya que las áreas cubiertas por nubes son clasificadas como agua.




Figura 4.2: Uso de suelo de la ciudad de Córdoba (Clasificación supervisada SVM). Córdoba, Argentina, 2013.

4.4.2. Discriminación de áreas urbanas según vulnerabilidad social

En la Figura 4.3 se presentan los resultados de la clasificación no supervisada de la imagen multicapa formada por las características de textura y las cuatro bandas originales. En la misma se resaltan las diferencias entre los barrios utilizados como sitios de prueba. En la Tabla 4.1 se presentan los porcentajes de las clases de cobertura de tierra más encontradas en los dos vecindarios. En Villa Urquiza hay un mayor porcentaje de las clases 16, 21 y 25, mientras que las clases 27, 28, 29 y 30 son más frecuentes en Urca y Ampliación Urca.

La variación en los valores de abundancias de clase en cada uno de los barrios examinados evidencia las diferencias existente respecto a los patrones espectrales y espaciales de los elementos urbanos en cada una de las dos áreas. Por lo tanto, se demuestra que una clasificación de una imagen provista por el sensado remoto puede convertirse en una herramienta de discriminación útil, pero la información adecuada (es decir, las características texturales) es muy importante y debe tenerse en cuenta.




Figura 4.3: Resultados clasificación no supervisada K-means de la imagen multicapa. Córdoba, Argentina.

Porcentaje de píxeles de las clases de cobertura de suelo más representativas de 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 %		

Tabla 4.1: Clases de cobertura de suelo mas representtivas de cada barrio.

Una comparación de estas clases con el paisaje urbano ayudó a identificar las características espaciales que representa cada una de ellas. omo puede observarse en la Tabla 4.2, la clase 25 se asocia con áreas de suelo desnudo (mas abundante en Villa Urquiza), mientras que en Urca y Ampliación Urca ésta clase está relacionada con techos de teja de ladrillo. La clase 28 se asocia principalmente a la vegetación como árboles y arbustos en áreas residenciales ya lo largo del río, mientras que la clase 30 se refiere a calles pavimentadas. Las clases 27 y 29 indican principalmente bordes y, por lo tanto, están relacionadas con la distribución espacial de la zona residencial, mientras que las clases 16 y 21 se asocian con interfaces desordenadas entre edificios pequeños y calles.

Clases	Características espaciales asociadas
16 y 21	Interfaces desordenadas entre edificios pequeños y calles
25	Techos de teja de ladrillo; Suelo desnudo
27 y 29	Distribución espacial de la zona residencial
28	Vegetación
30	Calles pavimentadas

Tabla 4.2: Características espaciales asociadas a las clases de cobertura identificadas


4.5. Discusión

En este capítulo se abordaron dos metodologías aplicadas a una imagen SPOT 5 a fin de determinar su capacidad para identificar barrios socialmente vulnerables. En el caso de la clasificación supervisada que utiliza el algoritmo SVM, si bien se identificaron distintas coberturas de suelo como, urbana, vegetación, suelo expuesto, cultivos y agua, no fue posible profundizar en las características de las áreas urbanas. Esto pudo ser debido a que este algoritmo es más eficiente cuando se aplica a imágenes de muy alta resolución, como es el caso de las imagenes QuickBird, pudiendo extraer areas urbanas más vulnerables [Dahmani et al., 2014; Huang et al., 2015].

Por otro lado, los resultados obtenidos en este capítulo, si bien son preliminares, demuestran que la metodología propuesta que combina el analisis de textura y la clasificación no supervisada, es capaz de detectar áreas con características socioeconómicas disímiles, y por lo tanto grupos con mayor o menor vulnerabilidad social. Estos hallazgos son consistentes con los resultados obtenidos por Zang y colaboradores (2003), quienes a partir de la banda pancromática de SPOT evaluaron la eficacia del método de clasificación (supervisada y no superviada) combinado con distintas medidas del método GLCM, para identificar 3 áreas de la ciudad de Beijing: antigua, externa y con construcciones bajas. En este trabajo las medidas de textura se calcularon a partir de una ventana de 7x7; y determinaron que la media junto con otra medida de textura (entropía, homogeneidad, desviación estándar, asimetría, segundo momento angular, contraste, correlación) [Zhang et al., 2003]. Basile y colaboradores (2012) también destacan el aporte del método GLCM en la precisión de la clasificación de imágenes pancromáticas de alta resolución espacial (QuickBird) para la identificación de tres áreas urbanas: construcciones, calles y vegetación. Además sostienen que la aplicación de análisis de componentes principales a las medidas de textura maximiza la información obtenida [Basile Giannini et al., 2012].

Respecto a las características de los barrios mas vulnerables, se encontró que presentan mayor presencia de suelo expuesto, interfases desordenadas entre pequeños edificios y calles. Es importante destacar que si bien las características físicas que definen un barrio vulnerable, varían en a nivel global y regional, diversos autores destacan características más frecuentes, suceptibles de ser identificadas a través de la teledetección: geometría de las construcciones (techos pequeños y heterogéneos), alta densidad, patrones irregulares entre calles y construcciones, materiales de construcción de los techos y características ambientales del entorno [Novack y Kux, 2010; Owen y Wong, 2013b; Duque et al., 2015; Huang et al., 2015]. Respecto a este último punto, si bien no existe un consenso acerca de las características del ambiente donde se ubican estos barrios, diversos autores señalan que generalmente se encuentran en áreas que presentan mayor riesgo ante eventos adversos como inundaciones, deslizamientos, etc [Tanner et al., 2009; Ballesteros, 2010; Awadall, 2013].

Por lo anteriormente expuesto, si bien el análisis de textura combinado con métodos de clasificación automática, permite alcanzar un nivel de precisión suficiente para la construcción de mapas de cobertura de suelo en áreas urbanas de manera simple y accesible [Puissant et al., 2005; Stasolla y Gamba, 2009]. Es importante destacar que en zonas con una alta densidad de construcciones y diversidad de materiales, será necesario contar con imágenes de muy alta resolución espacial y espectral tales como Worldview-2 y 3, a fin de evitar píxeles con información de distintas coberturas. Por lo cual es vital realizar una primera aproximación para determinar las características urbanas del área de estudio, y adaptar así la metodología. Por último, es necesario explorar otras herramientas complementarias como la Segmentación basada en Objetos y Machine Learning para mejorar la eficacia en la identificación de áreas socialmente vulnerables, y contar con datos socioeconómicos de los hogares, actualizados, para validar dicha metodología.



Modelos predictivos de enfermedades vinculadas a la IAN

5.1. Introducción

Las decisiones basadas en evidencia son esenciales para garantizar que las políticas de salud brinden programas y servicios de calidad, eficientes y efectivos. La construcción de modelos es una estrategia utilizada para comprender la dinámica de un fenómeno observado, dando cuenta no sólo cuales son los aspectos involucrados en la variación de dicho fenómeno, sino también de su relación. Los modelos matemáticos constituyen una herramienta valiosa que permiten brindar mayor información sobre la dinámica de fenómenos de interés. Su aplicación en temas de la salud pública, se remonta a principios del siglo XX, destacando los aportes de Ross (1911), Kermack y McKendrick, quienes establecieron modelos de transmisión de enfermedades infecciosas [Bacaër, 2011; Kermack y McKendrick, 1927]. Los modelos matemáticos pueden ayudarnos a predecir el curso de una epidemia dentro de una población; pueden también ser una herramienta útil para detectar los umbrales de población mas allá de los cuales existe el riesgo de una epidemia [Esteva et al., 1991]. Por tales motivos, fueron incorporados como una herramienta en los sistemas de vigilancia epidemiológica, ya que permiten identificar los patrones de las enfermedades y su propagación, esto permite identificar óptimos para implementar acciones prevención y de mitigación [Moghadas, 2006].

5.1.1. Efectos del barrio sobre la salud, la alimentación y la nutrición

El *lugar* constituye una de las variables explicativas de la distribución y frecuencia de las enfermedades. En las últimas décadas, distintas investigaciones han estudiado cómo los entornos donde habitan las personas afectan su salud [Diez Roux y Mair, 2010]. Este aporte que brinda la epidemiología ecosocial, sostiene que el contexto residencial interactúa con las características individuales y familiares influyendo en su salud. En otras palabras, la salud de las comunidades es el reflejo del entrecruzamiento de las circunstancias sociales y los procesos biológicos, a nivel espacial y temporal [Arcaya et al., 2016]. En la literatura se destacan las siguientes características de los barrios, que influyen en el la salud de sus residentes: pobreza, cohesión social, caminabilidad, ambiente alimentario, contaminación del aire, violencia, percepción de peligro, segregación étnica, uso del suelo, transporte, acceso a centros de salud y diseño urbano [Diez Roux y Mair, 2010; Arcaya et al., 2016; White et al., 2012; Handy et al., 2002].

Como se desarrolló en el Capítulo 2, las enfermedades vinculadas a la IAN, responden a factores de distinta naturaleza; siendo el contexto residencial un aspecto influyente en la prevalencia y distribución de las mismas. Resultados obtenidos por Chung et al. (2012) destacan el efecto de la caminabilidad de los barrios en la reduccion de la IAN, ya que podría promover la accesibilidad a puntos de venta de alimentos asequibles [Chung et al., 2012]. Por su parte, Jackson et al. (2019) encontraron que los hogares de barrios violentos y con un

bajo capital social presentan mayor IAN [Jackson et al., 2019]. En un estudio realizado en Canadá, Australia, Escocia, Portugal y Nueva Zelanda se encontró una asociación positiva entre el nivel socioeconómico de los barrios y el consumo de frutas y vegetales, es decir que en barrios de estratos sociales más altos el consumo de frutas y vegetales era mayor que en aquellos de estratos sociales más bajos [Ball et al., 2015]. Estos resultados son coherentes con los obtenidos por Olabiyi y MacInttyre (2016) quienes encontraron que en los barrios cuyo contexto socioeconómico es más vulnerable, la IAN de sus residentes es mayor [Olabiyi y McIntyre, 2016]. En otras palabras, puede haber algo en vivir en un barrio desfavorecido que aumenta el riesgo de IAN más allá del nivel de desventaja de una familia [Kimbro et al., 2012].

Es importante mencionar que en los estudios mencionados, para caracterizar el contexto residencial, se trabajó con datos de censos oficiales, y encuestas a nivel individual. Además los modelos estadísticos predictivos se realizaron a través de regresiones logísticas.

En el presente capítulo se propone desarrollar modelos predictivos de riesgo de enfermedades vinculadas a la IAN: sobrepeso y obesidad, desnutrición, anemia y ETAs, utilizando variables provistas por tecnologías geoespaciales como variables explicativas de la prevalencia de dichas enfermedades para luego desarrollar mapas de riesgo para la ciudad de Córdoba.

5.2. Metodología

Se realizó un análisis exploratorio de los datos para evaluar su distribución y la correlación entre las variables independientes y dependientes. Las variables explicativas provistas por el RS utilizadas para caracterizar el ambiente fueron: el NSI, distancia al área periurbana, distancia a cursos de agua, las clases 1; 2; 12; 13; 15; 16; 21; 25; 27; 28; 29 y 30, obtenidas en el capítulo 4. El análisis estadístico fue realizado a través del software R. Luego se desarrollaron mapas de riesgo para la ciudad de Córdoba mediante los software ENVI versión 4.8 y QGIS 2.8.6-Wien.

5.3. Resultados

5.3.1. Análisis exploratorio de los datos

La Tabla 5.1 describe las características epidemiológicas basales de la población bajo estudio. Se observa que la media de número de casos de Desnutrición fue de 2 ± 4 cada 10.000 habitantes. Mientras que en el caso de Sobrepeso y obesidad fue de 38 ± 58 casos. Las ETAs y Anemia presentaron una media de 192 ± 62 y 115 ± 83 casos cada 10.000 habitantes, respectivamente.

Casos cada 10.000 habitantes			
Desnutrición	2 (±4)		
Sobrepeso y Obesidad	38 (±58)		
ETAs	$192 (\pm 62)$		
Anemia	115 (±83)		

Tabla 5.1: Características epidemiológicas basales de los CAPS municipales bajo estudio. Fuente: Dirección Municipal de Atención Primaria de Salud. Córdoba, Argentina

La Figura 5.1 indica la distribución de frecuencia de los casos para cada enfermedad, en todos lo casos se observa ausencia de normalidad en su distribución. Por tal motivo y teniendo en cuenta que se trata de conteos de casos, se decidió utilizar la técnica de Modelos Lineales Generalizados (GLM).




Figura 5.1: Histogramas de los casos de cada enfermedad de interés, cada 10.000 habitantes. Córdoba, 2013

En la Figura 5.2 se puede obvervar la matriz de correlación de las variables bajo estudio. Para cada enfermedad (variable dependiente), se seleccionaron las variables independientes con las que presenta mayor correlación. Y para evitar redundancia en la información, se descartaron variables independientes con alta correlación (mayor a 0.8). De este modo se construyeron los modelos de prediccion para cada enfermedad. La Tabla 5.2 describe las variables utilizadas para construir cada modelo.




Figura 5.2: Matriz de correlación de las variables bajo estudio

Variables explicativas para cada modelo de predicción		
	Clase 12	
Desnutrición	Clase 27	
Desnutricion	NSI	
	Periurbano	
	Clase 1	
	Clase 13	
	Agua	
	NSI	
ahranasa v Ohasidad	Periurbano	
obrepeso y Obesidad	Clase 13	
	Clase 28	
	Clase 29	
	Anemia	
ETAs	NSI	
	Clase 12	
	NSI	
	Clase 12	
Anemia	ETAs	
менна	Agua	
	Clase1	

Tabla 5.2: Variables explicativas para cada modelo de prediccion de enfermedades

5.3.2. Modelado para Desnutrición

La Tabla 5.3 presenta los valores de los coeficientes y desviaciones correspondientes al modelo obtenido. Se especifica en cada caso el p-valor obtenido en cada caso, es decir, la probabilidad de obtener, por azar, una diferencia tan grande o mayor de la observada, cumpliéndose que no haya diferenciareal en la población de la que proceden las muestras. Así, por convenio suele establecerse que si este valor de probabilidad es menor del 5% (0,05) es lo suficientemente improbable que se deba al azar. Si es mayor del 5%, no existiría la confianza necesaria como para poder negar que la diferencia observada sea obra del azar.

La variable distancia al área periurbana es negativa, es decir que las personas que viven en los barrios más cercanos a dicha área están mas expuestos a desarrollar desnutrición. En el modelo aparece la clase 1 (p<0,05), la cual representa extensas áreas destinadas a uso agrícola, que presentan suelo desnudo. Estas áreas se encuentran en el área periurbana de la ciudad, y su mayor presencia, incrementaría la prevalencia de desnutrición. Por otro lado, si bien, en el modelo, el NSI presenta valores negativos, al comparar la imagen correspondiente al NSI y la resultante del proceso de clasificación realizado en el capítulo 4, los píxeles que representan la clase 1, reflejan los valores mas altos de NSI.

En este modelo, aparece además la Clase 12 (p<0.05), la cual está asociada las fronteras entre diferentes texturas en áreas agrícolas. La misma se encuentra distribuida en el area periurbana, en interfaces entre zonas con cultivo vigoroso y suelo desnudo, calles o construcciones. Presenta valores positivos, por lo cual los barrios que se encuentran en dichas áreas tienen un incremento en el riesgo de Desnutrición.

La Clase 27, la cual está relacionada con el orden de distribución espacial de las construcciones, y es más frecuente en barrios de estratos sociales más elevados. Se puede observar que el coeficiente para dicha variable es negativo, es decir que los barrios socialmente menos vulnerables presentan un menor riesgo de prevalencia de Desnutrición.

La clase 13, representa interfaces entre diferentes texturas de suelo desnudo, sin construcciones, en áreas donde el suelo presenta variaciones en su morfología, por ejemplo en áreas montañosas.

DESNUTRICIÓN						
Coeficiente p-valor						
Intercept	1.17	0.012				
Clase 12	41.982	0.019				
Clase 27	-4.645	0.111				
NSI	-0.855	0.842				
Periurbano	-0.790	0.284				
Clase 1	36.049	0.002				
Clase 13	-6	0.377				
Devianza Modelo Nulo	405.69					
Devianza Residual	306.43					

Tabla 5.3: Resumen del modelo obtenido para Desnutrición.

Para evaluar la bondad de ajuste de los modelos de regresión lineal (simple o múltiple) se utiliza el coeficiente de determinación, tambien conococido como R^2 . Dicho estadístico representa el porcentaje de variación de la variable respuesta que es explicada por su relación con una o más variables predictoras. En general, cuanto mayor es el valor de dicho coeficiente, mejor es el ajuste del modelo a los datos.

En los modelos GLM no existe el \mathbb{R}^2 , no obstante es posible cuantificar la variabilidad explicada por el modelo (D^2) comparando la Devianza del modelo Nulo con la Devianza Residual:

$$D^{2} = \frac{(DevianzaModeloNulo - DevianzaResidual)}{(DevianzaModeloNulo)} \times 100 \tag{5.1}$$

Para el modelo de Desnutrición, $D^2 = 24\%$, es decir el modelo explicaría un 24% de la prevalencia de Desnutrición en la ciudad de Córdoba.

5.3.3. Modelado para Sobrepeso y Obesidad

La tabla 5.4 sintetiza los parámetros obtenidos en este modelo.

Se puede observar que la distancia a los cursos de agua (p<0.05) presenta valores negativos. Por otro lado el NSI (p<0.05) presenta valores positivos. Lo mismo sucede con la Clase 28 (p<0.05), asociada principalmente a la vegetación como árboles y arbustos en áreas residenciales y a lo largo del río. La clase 29 (p=0.05), la cual hace referencia a la distribución espacial de zonas residenciales de estratos sociales más elevados, presenta un coeficiente negativo. La clase 13, relacionada con bordes entre diferentes texturas de areas destinadas a la agricultura, presenta valores negativos, estadísticamentes significativos (p<0,05). Por último, la distancia al periurbano si bien presenta valores positivos cercanos a cero, no es estadísticamente significativo (p=>0.05).

Por lo tanto, la prevalencia de sobrepeso y obesidad será mayor en los barrios alejados de areas agrícolas, cercanos a cursos de agua, con un alto NSI y con presencia de vegetación.

SOBREPESO Y OBESIDAD			
	Coeficiente	p-valor	
Intercept	4.838	<2e-16	
Agua	-0.4806	4.9e-10	
NSI	2.7424	0.0055	
Periurbano	0.00738	0.9435	
Clase 13	-16.5739	<2e-16	
Clase 28	2.3483	0.0088	
Clase 29	-18.1715	<2e-16	
Devianza Modelo Nulo	3919.5	<u> </u>	
Devianza Residual	3581.4		

Tabla 5.4: Resumen del modelo obtenido para Sobrepeso y Obesidad.

Al analizar la D^2 , se observa que el modelo es capaz de explicar un 9% de la variabilidad de la prevalencia de sobrepeso y obesidad.

5.3.4. Modelado para ETAs

La Tabla 5.5 sintetiza los resultados obtenidos en el GLM para ETAs.

La Clase 12, presenta valores positivos, mientras que el coeficiente correspondiente al NSI, es negativo. Ambos son estadísticamente significativos (p<0.05). Por lo cual los barrios que se encuentran mas próximos a áreas destinadas a cultivos, y con un bajo NSI, es decir (menor cantidad de areas con suelos desnudo, o construcciones, pavimento, etc.) presentarán mayor riesgo de desarrollar ETAs.

ETAs					
Coeficiente p-valor					
Intercept	5.1969	<2e-16			
Clase 12	5.73e-08				
NSI -2.0679 1.23e-					
Devianza Modelo Nulo	1616.7				
Devianza Residual	1481				

Tabla 5.5: Resumen del modelo obtenido para ETAs.

Este modelo presenta una $D^2 = 11$, por lo cual explica el 11 % de la variabilidad de la prevalencia de ETAs.

5.3.5. Modelado para Anemia

En la tabla 5.6 se resumen los resultados del modelo obtenido.

Todas las variables de este modelo son estadísticamente significativas (p<0.05). La Clase 12 y la Clase 1 presentan coeficientes positivos. Mientras que los coeficientes correspondientes a la distancia a cursos de agua y el NSI son negativos.

Así, la prevalencia de Anemia sería mayor en barrios cercanos a cursos de agua y áreas destinadas a cultivo, con grandes extensiones de suelo desnudo, que presenten además bajos valores de NSI.

ANEMIA					
Coeficiente p-valor					
Intercept	4.94329	<2e-16			
Clase 12	36.61273	<2e-16			
Agua	-0.5723	<2e-16			
NSI	-1.7757	2.95e-05			
Clase 1	17.9151	<2e-16			
Devianza Modelo Nulo	4626				
Devianza Residual	3564.5				

Tabla 5.6: Resumen del modelo obtenido para Anemia.

Este modelo explicaría el 23 % de la variabilidad de la prevalencia de Anemia en la ciudad de Córdoba.

5.3.6. Desarrollo de mapas de riesgo

A partir de los modelos obtenidos para Anemia, ETAs y Sobrepeso y Obesidad, se desarrollaron mapas de riesgo para la ciudad de Córdoba. Es decir las áreas de la ciudad que serían más susceptibles para el desarrollo de las enfermedades mencionadas, si sólo consideraramos las variables provistas por la geomática, que se abordaron en este trabajo.

Cabe destacar que para el caso de desnutrición no se realizó el mapa de riesgo debido al bajo número de centros de salud que reportaron casos.

Para la construcción de los modelos se utilizó la función logarítmica como enlace, por lo cual la función resultante para el modelo de Sobrepeso y obesidad es expresada en las siguientes ecuaciones:

$$log(Riesgo\ de\ Sobrepeso\ y\ Obesidad) = 4,83 + (-0,48) \times Agua + 2,74 \times NSI \\ + 0,007 \times Periurbano + (-16,57) \times Clase\ 13 \\ + 2,34 \times Clase\ 28 + (-18,17) \times Clase\ 29$$

Riesgo de Sobrepeso y Obesidad =
$$\exp(4,83) \times \exp(-0,48 \times Agua) \times \exp(2,74 \times NSI)$$

 $\times \exp(0,007 \times Periurbano) \times \exp(-16,57 \times Clase\ 13)$
 $\times \exp(2,34 \times Clase\ 28) \times \exp(-18,17 \times Clase\ 29)$

La Figura 5.3 representa las áreas de la ciudad de Córdoba que presentan mayor riesgo de desarrollo de Sobrepeso y Obesidad. Se puede observar que la zona central de la ciudad, la cual posee mayor densidad poblacional, es la que presenta mayor riesgo. Al alejarse de dicha área el riesgo disminuye.




Figura 5.3: Riesgo de prevalencia de Sobrepeso y Obesidad, asociado a las características de los barrios. Ciudad de Córdoba, 2013

Respecto al riesgo de desarrollo de ETAs, la función que representa al modelo, se describe a continuación:

$$log(Riesgo\ de\ ETAs) = 5,19 + (11,72) \times Clase\ 12 + (-2,06) \times NSI$$

Riesgo de ETAs =
$$\exp(5.19) \times \exp(11.72 \times Clase\ 12) \times \exp(-2.06 \times NSI)$$

El mapa resultante se puede observar en la Figura 5.4. En este caso, el área periurbana es la que presenta el riesgo más elevado. En general, el norte y el sur de la ciudad presentan las áreas más vulnerables.




Figura 5.4: Riesgo de prevalencia de ETAs, asociado a las características de los barrios. Ciudad de Córdoba, 2013

Por último, se representa la función y los parámetros que describen el modelo de riesgo de Anemia:

$$log(Riesgo\ de\ Anemia) = 4,94 + (-0,57) \times Agua + (-1,77) \times NSI$$
$$+ (36,61) \times Clase\ 12 + 17,91 \times Clase\ 1$$

Riesgo de Anemia =
$$\exp(4.94) \times \exp(-0.57 \times Agua) \times \exp(1.77 \times NSI)$$

 $\times \exp(36.61 \times Clase\ 12) \times \exp(17.91 \times Clase\ 1)$

En la Figura 5.5 se puede observar que las zonas con mayor riesgo son aquellas que se encuentran cercanas al área periurbana. Mientras que las áreas cercanas a cursos de agua presentan un riesgo moderado. En general el menor riesgo se observa en aquellos lugares que se encuentran alejados del área periurbana y los cursos de agua.




Figura 5.5: Riesgo de prevalencia de anemia, asociado a las características de los barrios. Ciudad de Córdoba, 2013

5.4. Discusión

En el presente Capítulo se propuso elaborar modelos predictivos que a través de variables provistas por la geomática permitan identificar aquellas áreas de la ciudad que presentan mayor riesgo de las enfermedades bajo estudio. Para describir el contexto físico donde habitan las personas se utilizaron variables obtenidas mediante el procesamiento de imagenes propuesto en el capítulo 4, junto con: la distancia a cursos de agua, área periurbana y NSI.

Es importante destacar que no existen antecedentes que aborden el entorno comunitario a través de este tipo de variables. Los estudios previos que abordaron el contexto residencial, como determinante de enfermedades vinculadas a la alimentación y nutrición, utilizaron variables como: distancia a puntos de venta de alimentos de diversa naturaleza o densidad de los mismos, tiempo de trayecto hasta ellos, alternativas de transporte disponibles, caminabilidad, espacios verdes disponibles, cohesión social, violencia y/o índice de criminabilidad, pobreza, acceso a servicios de salud [Diez Roux y Mair, 2010; Arcaya et al., 2016; White et al., 2012; Handy et al., 2002].

Los modelos obtenidos explican un pequeño porcentaje de la variabilidad de la prevalencia de las enfermedades estudiadas: un 24% para el caso de Desnutrición; 9% para Sobrepeso y obesidad; 11% para las ETAs y un 23% en el caso de Anemia. Por lo cual dichos modelos no son suficientes para explicar la dinámica del comportamiento de las enfermedades de interés, por lo tanto no son capaces de predecir el riesgo sólo con estas variables explicativas. Esto se debe a la complejidad de factores que intervienen en el desarrollo de estas enfermedades, no sólo de distinta naturaleza (socioeconómica, cultural, ambiental, biológica) sino también a las


complejas relaciones entre ellos, en los múltiples niveles de análisis (individual, familiar y comunitario). Exploraron el mismo análisis a múltiples escalas y descubrimos que usar un modelo ajustado para "descubrir"la dimensión espacial es problemático. En resumen, existe una brecha entre la comprensión de cómo el medio ambiente influye en la salud y las técnicas de modelado estadístico espacial [Spielman y Yoo, 2009].

No obstante, considerando que los modelos sólo contemplan variables provistas por el sensado remoto, resulta interesante el aporte de las mismas para explicar su influencia en la variabilidad de la prevalencia de dichas enfermedades. Haciendo visible que desde un enfoque epidemiológico, el *lugar* donde vivimos, importa.

Por lo cual ante los resultados obtenidos es posible identificar limitaciones para este estudio, como por ejemplo: la disponibilidad de datos de prevalencia sólo de centros de salud municipales, dejando de lado los centros de atención primaria provinciales y hospitales de mayor complejidad. Por otro lado, es necesario incorporar datos al análisis que permitan caracterizar al entorno alimentario de los barrios (disponibilidad y acceso de alimentos) y aquellas características del entorno que impactan en la salud de las personas (espacios para recreacion y actividad física, seguridad, calidad ambiental, disponibilidad de acciones de promoción de la salud y prevención de enfermedades).

Desde otra perspectiva es posible identificar nuevos desafíos como la utilización de métodos superadores a los modelos de regresión, los cuales son los tradicionalemente utilizados en estudios de entornos alimentarios comunitarios [Olabiyi y McIntyre, 2016; Kimbro et al., 2012]. En los últimos años, se ha destacado la utilidad de *Modelos basados en agentes*, los cuales son son representaciones informáticas de sistemas que consisten en una colección de microentidades discretas que interactúan y cambian en pasos de tiempo discretos que dan lugar a macrosistemas. Los *agentes* son entendidos como microentidades, es decir son cualquier cosa que altere su comportamiento en respuesta a los aportes de otros agentes y del medio ambiente [Bonabeau, 2002].

Esta metodología se ha adoptado cada vez más en las ciencias sociales y geográficas para investigar los procesos que involucran interacciones entre unidades heterogéneas e interacciones dinámicas entre unidades y entornos, incluidos los procesos que conducen al patrón espacial de una variedad de resultados a nivel individual [Auchincloss y Diez Roux, 2008]. En otras palabras constitutyen un novedoso enfoque para analizar como es la interacción de los individuos y el contexto donde habitan.



Análisis Espacial aplicado a la Epidemiología Nutricional

6.1. Introducción

Los procesos de salud y enfermedad de los individuos y poblaciones representan un fenómeno multicausal, atravesado por determinantes de distinta naturaleza. En 1974, Marc Lalonde describió los grandes determinantes de salud de las personas y las poblaciones, marcando un hito en la salud pública. Ellos son:

Medio Ambiente. Relacionado a los factores ambientales físicos, biológicos, de contaminación atmosférica, de contaminación química, tanto del suelo, agua y aire, y los factores socioculturales y psicosociales relacionados con la vida en común.

Estilos de vida. Relacionados con los hábitos personales y de grupo de la alimentación, actividad física, adicciones, conductas peligrosas o temerarias, actividad sexual, utilización de los servicios de salud, etc.

Biología humana. Relacionado a aspectos genéticos y con la edad de las personas.

Atención sanitaria. Es decir, la calidad, accesibilidad y financiamiento de los servicios de salud que atienden a los individuos y poblaciones [Lalonde, 1974].

En este contexto, el análisis espacial contribuye a la comprensión de las variaciones de la enfermedad a nivel local, ya que puede observarse como es la relación entre los determinantes de la salud, tanto desde un enfoque espacial como temporal.

Como se describió en el Capítulo 2, es necesario estudiar el comportamiento epidemiológico desde diferentes enfoques. En este contexto, el desarrollo de los GIS y la aplicación de geoestadísticas ha dado un nuevo impulso al análisis de la distribución espacial aplicada a la epidemiología.

La geoestadística comprende un conjunto de herramientas y técnicas con el objetivo de analizar y predecir los valores de una variable que se muestra distribuida en el espacio o de manera continua. Debido a su aplicación orientada a GIS, también podría definirse como las estadísticas relacionadas con los datos geográficos, por lo que también se conoce como estadísticas espaciales [García, 2004].

La epidemiología espacial se refiere a la descripción y análisis de las variaciones geográficas en Enfermedad con respecto a factores de riesgo demográficos, ambientales, de comportamiento, socioeconómicos, genéticos e infecciosos [Souris, 2019; Ostfeld et al., 2005].

Los avances en GIS, metodologías estadísticas y disponibilidad de información de alta resolución sobre salud y medio ambiente con referencia geográfica han creado nuevas oportunidades para investigar factores

ambientales y de otro tipo al explicar las variaciones geográficas locales en la enfermedad [Elliott y Wartenberg, 2004; Giorgi et al., 2018].

Por lo tanto, la geoestadística aplicada a la epidemiología nutricional podría proporcionar diferentes enfoques analíticos para complementar aquellos propuestos por la epidemiología tradicional, respondiendo preguntas relacionadas con el entorno alimentario y el acceso a alimentos saludables, la distribución geográfica de enfermedades y sus factores de riesgo, patrones espaciales de distribución de la enfermedad.

6.2. El Semi-Variograma como herramienta de la Epidemiología Nutricional

Como se mencionó en el capítulo 2, uno de los atributos fundamentales del análisis espacial es la posibilidad de estudiar la autocorrelación espacial de los datos: las observaciones más cercanas tienden a ser más parecidas que las observaciones más alejadas. En geoestadística este concepto de autocorrelación es cuantificado a través de la función de Semivariograma, la cual relaciona la semivarianza con el vector **h** conocido como "lag"[Waller y Gotway, 2004]. La ecuación (6.1)la define como la diferencia cuadrada esperada entre dos valores de datos separados por un vector de distancia **h** [Gringarten y Deutsch, 2001].

$$\gamma(\mathbf{h}) = \frac{1}{2} E\{ [Z(\mathbf{x}) - Z(\mathbf{x} + \mathbf{h})]^2 \}$$
 (6.1)

Dónde: $\gamma(\mathbf{h})$ es la semivarianza para todas las muestras localizadas en el espacio separado por el intervalo de distancia \mathbf{h} ; E es el número total de pares de muestras separados por un intervalo de distancia \mathbf{h} ; $\mathbf{Z}(\mathbf{x})$ es el valor de la variable en el sitio \mathbf{x} ; $\mathbf{Z}(\mathbf{x}+\mathbf{h})$ el otro valor muestral separado del anterior por una distancia \mathbf{h} desde \mathbf{x} . Es importante destacar que se trata de un proceso intrínsicamente estacionario, y como tal es una función del "spatial lag", $\mathbf{h} = \mathbf{x} - \mathbf{u}$, pero no de las ubicaciones \mathbf{x} y \mathbf{u}

De este modo, se determinará la autocorrelación que poseen los pares de puntos y a partir de que distancia el par de puntos deja de ser similar.

La Figura 6.1 representa un semivariograma isotrópico típico, en la cual se describe la relación entre la semivarianza versus la distancia **h**, dónde:

$$\mathbf{h} = ||h||,$$




Figura 6.1: Semivariograma isotrópico típico

Se puede observar que el evento analizado presenta continuidad y variabilidad espacial. Esta curva comienza en 0, y si las observaciones que se encuentran mas próximas entre sí son más parecidas que con aquellas que están mas alejadas, la semivarianza aumenta a medida que aumenta la distancia que las separa. Por consiguiente, el incremento de la variabilidad entre pares de observaciones, a medida que aumenta la distancia, refleja una disminución de la autocorrelación espacial. En este caso el semivariograma se estabiliza a un valor constante (umbral), cuando supera un intervalo de distancia. Superado este intervalo de distancia, las observaciones no estarán espacialmente autocorrelacionadas, reflejando una constante semivarianza entre los pares de observaciones. En el caso de que el fenómeno sea de caracter anisotrópico, es decir que el valor de la variación de las observaciones no es la misma para todas las direcciones, se debería realizar un gráfico como el representado en la Figura 6.1 para cada dirección. Por otro lado, en el caso de que no existiera autocorrelación espacial, el semivariograma sería una línea horizontal.

Por lo anteriormente expuesto, a través de funciones básicas como el semivariograma, es posible estudiar la continuidad espacial de los fenómenos, identificando la forma en que varían en todas las direcciones del espacio y, por lo tanto, describiendo patrones espaciales. La propuesta de este trabajo es analizar la dependencia espacial de las enfermedades relacionadas con los determinantes nutricionales y alimentarios, como la desnutrición, el sobrepeso y la obesidad, la anemia y las ETAs.

6.3. Materiales y Métodos

Como se mencionó anteriormente, generalmente en el análisis de autocorrelación espacial, se asume un comportamiento isotrópico de las variables, por lo que el valor de **h**, con sentido y dirección se reemplaza por su norma, de este modo el variagrama se representa por una curva como se ilustrada en la 6.1. Para explorar la dependencia espacial de un fenómeno anisotrópico, es necesario construir una curva para cada dirección, o en otras palabras, un Variograma 2D.

En el presente trabajo, se analizó la dependencia espacial de las enfermedades de interés (desnutrición, sobrepeso y obesidad, anemia y ETAs). Como primer paso se realizó un análisis exploratorio de los datos y se encontró que tienen un comportamiento anisotrópico. Ello significa que la variación del valor de la prevalencia no es la misma en todas las direcciones.

Por lo tanto, utilizando el software IDL, se programó un script capaz de construir un semivariograma direccional. Adicionalmente para generar el variograma 2D con los datos de prevalencia, se elaboraron diferentes variogramas considerando situaciones predefinidas: datos isotrópicos, valores aleatorios de prevalencia, valores aleatorios de prevalencia y distribución espacial y prevalencias con valores monótonos crecientes.

A continuación se presenta el algoritmo utilizado para calcular el semivariograma 2D. La variables *xdat*; *ydat* representan las coordenadas geográficas expresadas en UTM. Mientras que la variable *dat*, hace referencia a los valores de prevalencia para cada Centro de Salud.

```
hist2d= fltarr (21,21)
count2d=fltarr (21,21)

for hx =0,20 do begin
    for hy =0,20 do begin

VAR=0
NUMVAR=0

for i =0,dim-1 do begin
    for j=0,dim-1 do begin

if ( dx(i,j) ge hx-10 and dx(i,j)
    lt hx+1-10) and (dy(i,j) ge hy-10
    and dy(i,j) lt hy+1-10) then begin
```

```
VAR=VAR+ abs(dd(i,j))
numvar=numvar+1
endif

endfor
endfor
count2d(hx,hy)=numvar
if numvar gt 0 then begin
hist2d(hx,hy)=VAR/numvar
endif
endfor
endfor
endfor
```

6.4. Resultados

Se obtuvieron diferentes variogramas direccionales, que analizan el comportamiento de las variables, a través de dos dimensiones: norte-sur, este-oeste. Al interpretar un Variograma 2D, es importante tener en cuenta que expresan la distancia entre puntos en el norte-sur, y dirección este-oeste, y no puntos geográficos de la ciudad. A continuación se presentan los semivariogramas obtenidos para cada caso de estudio.

6.4.1. Datos Isotrópicos

La Figura 6.2 muestra el semivariograma de una variable con comportamiento isotrópico. Por lo tanto, la varianza aumenta de igual magnitud a medida que aumenta la distancia, independientemente de su dirección.




Figura 6.2: Semivariograma 2D isotrópico

6.4.2. Datos Aleatorios de prevalencia y distribución espacial

En la Figura 6.3 se observa el variograma calculado con datos aleatorios. En este caso, si bien se observa que la variabilidad es mayor entre el norte y el sur de la ciudad, es necesario explorar la asignación aleatoria de la ubicación para determinar la influencia del ambiente en la distribución de la enfermedad.




Figura 6.3: Semivarograma 2D: Datos aleatorios

6.4.3. Prevalencia Aleatoria

Además se realizó un variograma conservando la distribución espacial de los centros de salud, pero asignando un valor aleatorio de prevalencia. En este caso, en la Figura 6.4 se puede observar que no existe un patrón espacial, lo cual indica la ausencia de dependencia espacial.




Figura 6.4: Semivarograma 2D: Prevalencia aleatoria

6.4.4. Incremento monótono de la prevalencia

La Figura 6.5 ilustra el variograma resultante, al asignar valores de prevalencia que aumentan monótonamente en cada centro de salud. Por lo tanto, se observa una mayor variabilidad entre los centros de salud a los que se asignaron valores más bajos y más altos (este-oeste).




Figura 6.5: Semivarograma 2D: Incremento monótono de la prevalencia

6.4.5. Prevalencia de Desnutrición

En este caso, al observar la Figura 6.6 no es posible identificar un patrón espacial capaz de explicar el comportamiento de la enfermedad. Este resultado puede deberse al bajo número de centros de salud en los que informaron casos de desnutrición. Además, los 27 centros de salud que registran casos de malnutrición están distribuidos de manera uniforme en la ciudad.




Figura 6.6: Semivarograma 2D: Prevalencia de Desnutrición

6.4.6. Prevalencia de Sobrepeso y Obesidad

En la Figura 6.7 se observa una mayor variabilidad sobre el sobrepeso y la prevalencia de obesidad entre el este y el oeste de la ciudad. Además, la variabilidad en dirección norte-sur es baja. Este resultado es consistente con las características sociodemográficas de la ciudad, ya que según los datos obtenidos del censo realizado en 2010 por el Instituto nacional de Estadísticas y Censos (INDEC), el porcentaje de hogares con NBI es mayor en el barrios ubicados en el este y sureste de la ciudad con respecto a aquellos que se encuentran en el oeste y noroeste [INDEC, 2012].




Figura 6.7: Semivarograma 2D: Prevalencia de Sobrepeso y Obesidad

6.4.7. Prevalencia de Anemia

La Figura 6.8 demuestra que la variabilidad de la prevalencia de anemia aumenta en dirección norte-sur. Asimismo, la mayor variabilidad es en dirección noreste-sureste. Además, la variabilidad de prevalencia es más baja en la dirección este - oeste. En cierto sentido su distribución espacial parece complementaria a la anterior.




Figura 6.8: Semivarograma 2D: Prevalencia de Anemia

6.4.8. Prevalencia de ETAs

En la Figura 6.9 se puede observar que la variabilidad de la prevalencia de ETAs es mayor en dirección este-oeste. La variabilidad de prevalencia es más baja en la dirección norte-sur.




Figura 6.9: Semivarograma 2D: Prevalencia de ETAs

6.5. Discusión


En este capítulo se analizó la dependencia espacial de enfermedades con componente alimentario nutricional. Para ellos se desarrolló de un variograma capaz de analizar la variabilidad espacial de los datos anisotrópicos. Luego, se evaluó la eficacia del algoritmo desarrollado, sometiendolo a distintos escenarios: datos isotropicos, incremento monótono, datos aleatorios de prevalencia y de distribución espacial de los centros de salud.

A través de esta herramienta se identificó un marcado patrón espacial en la prevalencia de sobrepeso - obesidad y anemia. En el primer caso, se observó una mayor variabilidad de prevalencia de sobrepeso y obesidad en dirección este-oeste, mientras que la variabilidad de la prevalencia de anemia es mayor en dirección norte-sur. En ambos casos, las áreas más distantes de la ciudad es la que presenta la máxima variación. Esto es consistente con la vulnerabilidad social de los vecindarios ubicados en las áreas periurbanasde la ciudad, reflejada por los datos oficiales de NBI [INDEC, 2012]. Ambas enfermedades son una gran preocupación para la salud pública debido al aumento de su prevalencia. Según los datos oficiales de la 4° Encuesta Nacional de Factores de Riesgo (2019), el 66,1% de la población tiene sobrepeso [INDEC, 2019], y la anemia es un problema frecuente en toda la población, con especial énfasis en los niños menores de un año y las mujeres embarazadas [Secretaría de Gobierno de Salud, 2019].

Estudios anteriores han utilizado el análisis espacial para evaluar la autocorrelación espacial, detectar clústers y, por lo tanto, comprender la distribución de la prevalencia de problemas de salud [Insaf y Talbot, 2016; Tu et al., 2012; Qin et al., 2019]. Sin embargo, no se han encontrado antecedentes que analicen patrones espaciales a través de variogramas anisotrópicos. Ello hace visible la necesidad de continuar con esta línea de investigación, incorporando los datos de prevalencia a los centros de salud provinciales y aplicando otras técnicas de geoestadística.

Este estudio proporciona una base importante para futuras investigaciones para comprender los determinantes conductuales, demográficos, socioeconómicos y ambientales de la epidemiología de la nutrición desde una perspectiva espacial.

El presente capítulo fue sometido a evaluación por pares (referato) en la XVIII Reunión de Trabajo en Procesamiento de la Información y Control - RPIC 2019, y aprobado para su publicación en la IEEE.



Conclusiones

El presente trabajo, destaca la contribución de las tecnologías geoespaciales para el estudio de la SAN en áreas urbanas, superando el enfoque tradicional que se centraba en la disponiblidad alimentaria. A través de las mismas es posible caracterizar los entornos donde habitan las personas, los cuales son actores importantes en la epidemiología, particularmente en la epidemiología nutricional. Porque *dónde* vivimos, importa.

De este modo, se constató que a través de una metodología que combina el análisis de textura y la clasificación no supervisada aplicadas a una imagen SPOT 5, es posible reconocer áreas de la ciudad de Córdoba con características socioeconómicas disímiles; facilitando la identificación de barrios socialmente más vulnerables, y por lo tanto suceptibles a sufrir IAN. Luego, teniendo en cuenta dichas características junto con otras variables provistas por la geomática (NSI, distancia al área periurbana y cursos de agua) se construyeron modelos predictivos de enfermedades vinculadas a la IAN (Desnutrición, sobrepeso y obesidad, anemia y ETAs). Al contemplar sólo variables provistas por la geomática, los modelos obtenidos explican un pequeño porcentaje de la variabilidad de la prevalencia de las enfermedades analizadas, por lo cual no son capaces de predecir el riesgo sólo con estas variables explicativas. No obstante su valor radica en el enfoque novedoso utilizado para analizar como es la interacción de las personas y el contexto donde viven. En este sentido, a través del desarrollo de un variograma para datos anisotrópicos fue posible identificar la existencia de un marcado patrón espacial en la prevalencia de Sobrepeso-obesidad y anemia.

A partir de los resultados obtenidos, y teniendo en cuenta las limitaciones del trabajo, quedan planteadas nuevas proyecciones:

- Incorporar datos epidemiológicos de los centros de salud provincial, evaluaciones nutricionales realizadas en escuelas, etc. Considerando en cada caso el método utilizado para realizar los diagnósticos.
- Incorporar variables que permitan caracterizar la disponibilidad de alimentos en los barrios, su costo, distancias a los puntos de venta, lugares públicos para realizar actividad física y juego libre, iniciativas (públicas y privadas) orientadas a la promoción de la salud y prevención de enfermedades, vulnerabilidad social de los hogares, amenazas asociadas al cambio climático.
- Profundizar el análisis de la metodología propuesta en el Capítulo 4 de manera que permita describir los entornos físicos de distintos tipos de barrios, en distintas ciudades.
- Utilizar redes neuronales y estrategias de simulación para desarrollar modelos predictivos capaces de reflejar las complejas relaciones entre las variables que influyen en el desarrollo de enfermedades vinculadas a la IAN.
- Analizar los factores que influyen en la variabilidad de la prevalencia de las enferemedades analizadas en el Capítulo 6.

Por último, este trabajo, además de contribuir a la generación de nuevos conocimientos para el desarrollo de productos que -de acuerdo al espíritu del Plan Nacional Espacial-, den respuesta a necesidades sentidas

de la comunidad, fortalece el trabajo transdisciplinario y el rol de los profesionales de la nutrición. Ya que, a través de la geomática aborda el estudio de la salud de las comunidades con herramientas innovadoras en la epidemiologia nutricional clásica.

Produccion cientifica derivada de la tesis

Los resultados de esta tesis fueron publicados en las siguientes revistas con referato:

- Alvarez Di Fino, E.M. (2017). Application of geospatial technologies for analysis of cardiometabolic diseases related to food and nutrition. Ann Nutr Metab;71(suppl 2):1–1433.
- Alvarez Di Fino, E.M., Defagó M.D., Scavuzzo, C.M. (2019). Spatial analysis applied to nutritional epidemiology. XVIII Workshop on Information Processing and Control (RPIC).

Bibliografía

- Patricia Aguirre. *Obesidade e pobreza: um novo desafio à saúde pública*, capítulo Aspectos socioantropológicos da obesidade na pobreza, páginas 12–26. Peña, M and Bacallao, J, 2006.
- Mariana C Arcaya, Reginald D Tucker-Seeley, Rockli Kim, Alina Schnake-Mahl, Marvin So, y SV Subramanian. Research on neighborhood effects on health in the united states: a systematic review of study characteristics. *Social Science & Medicine*, 168:16–29, 2016.
- Amy H Auchincloss y Ana V Diez Roux. A new tool for epidemiology: the usefulness of dynamic-agent models in understanding place effects on health. *American journal of epidemiology*, 168(1):1–8, 2008.
- HI Awadall. Health effect of slums: A consequence of urbanization. Scholarly J Med, 3(1):7–14, 2013.
- D Azar, J Graesser, R Engstrom, J Comenetz, RML Leddy Jr, NG. Schechtman, y T Andrews. Spatial refinement of census population distribution using remotely sensed estimates of impervious surfaces in haiti. *International Journal of Remote Sensing*, 31:5635 –5655, 2010. doi: http://dx.doi.org/10.1080/01431161. 2010.496799.
- Nicolas Bacaër. Ross and malaria (1911). En *A Short History of Mathematical Population Dynamics*, páginas 65–69. Springer, 2011.
- Kylie Ball, Karen E Lamb, Claudia Costa, Nicoleta Cutumisu, Anne Ellaway, Carlijn BM Kamphuis, Graciela Mentz, Jamie Pearce, Paula Santana, Rita Santos, et al. Neighbourhood socioeconomic disadvantage and fruit and vegetable consumption: a seven countries comparison. *International journal of behavioral nutrition and physical activity*, 12(1):68, 2015.
- Marife M Ballesteros. Linking poverty and the environment: Evidence from slums in philippine cities. Technical report, PIDS Discussion Paper Series, 2010.
- Massimiliano Basile Giannini, Pasquale Merola, y Alessia Allegrini. Texture analysis for urban areas classification in high resolution satellite imagery. *Applied Remote Sensing Journal*, 2:65–71, 01 2012.
- Eric Bonabeau. Agent-based modeling: Methods and techniques for simulating human systems. *Proceedings of the national academy of sciences*, 99(suppl 3):7280–7287, 2002.
- S Britos. Seguridad alimentaria nutricional: 3 ejes para repasar el concepto. *Centro de Estudios sobre Nutrición Infantil (CESNI)*, 2008a. URL http://biblioteca.cesni.org.ar/references/50059a4a9e3d98078c95f214.
- Sergio Britos. Hambre, seguridad alimentaria, obesidad y políticas públicas en la Argentina reciente. *Observatorio Social. No. 19*, páginas 4–11, 2008b. URL http://www.observatoriosocial.com.ar/images/pdf_revistas/revi_19.pdf.
- Molly E Brown. Famine early warning systems and remote sensing data. Springer Science & Business Media, 2008.

- Molly E. Brown y Varun Kshirsagar. Weather and international price shocks on food prices in the developing world. *Global Environmental Change*, 35:31 40, 2015. ISSN 0959-3780. doi: https://doi.org/10.1016/j.gloenvcha.2015.08.003. URL http://www.sciencedirect.com/science/article/pii/S0959378015300248.
- P Burrough y R McDonnell. Spatial information systems and geostatistics. *P. Burrough*, & R. McDonnell, *Principles of Geographical Information Systems*, 333, 1998.
- Jie Chen. Rapid urbanization in china: A real challenge to soil protection and food security. *Catena*, 69(1): 1–15, 2007.
- Wai Ting Chung, William T Gallo, Nancy Giunta, Maureen E Canavan, Nina S Parikh, y Marianne C Fahs. Linking neighborhood characteristics to food insecurity in older adults: The role of perceived safety, social cohesion, and walkability. *Journal of Urban Health*, 89(3):407–418, 2012.
- E. Chuvieco. Teledetección ambiental. Barcelona, Editorial Ariel, 2010.
- R Dahmani, A Ait Fora, y A Sbihi. Extracting slums from high-resolution satellite images. *Int. J. Eng. Res. Dev*, 10:1–10, 2014.
- Emily J. Dhurandhar. The food-insecurity obesity paradox: A resource scarcity hypothesis. *Physiology & Behavior*, 162:88 92, 2016. ISSN 0031-9384. doi: https://doi.org/10.1016/j.physbeh.2016.04.025. URL http://www.sciencedirect.com/science/article/pii/S0031938416301615. Proceedings of the SSIB 2015 Annual Meeting.
- Ana V. Diez Roux y Christina Mair. Neighborhoods and health. *Annals of the New York Academy of Sciences*, 1186(1):125-145, 2010. doi: 10.1111/j.1749-6632.2009.05333.x. URL https://nyaspubs.onlinelibrary.wiley.com/doi/abs/10.1111/j.1749-6632.2009.05333.x.
- Tamara Dubowitz, Madhumita Ghosh-Dastidar, Christine Eibner, Mary E Slaughter, Meenakshi Fernandes, Eric A Whitsel, Chloe E Bird, Adria Jewell, Karen L Margolis, Wenjun Li, et al. The women's health initiative: the food environment, neighborhood socioeconomic status, bmi, and blood pressure. *Obesity*, 20 (4):862–871, 2012.
- Juan C. Duque, Jorge E. Patino, Luis A. Ruiz, y Josep E. Pardo-Pascual. Measuring intra-urban poverty using land cover and texture metrics derived from remote sensing data. *Landscape and Urban Planning*, 135: 11 21, 2015. ISSN 0169-2046. doi: https://doi.org/10.1016/j.landurbplan.2014.11.009. URL http://www.sciencedirect.com/science/article/pii/S0169204614002692.
- J Elgart, G Pfirter, y L Gonzalez. Obesity in Argentina: epidemiology, morbidity, mortality and economic impact. *Rev Argent Salud Pública*, 1:6–12, 2010.
- Paul Elliott y Daniel Wartenberg. Spatial epidemiology: current approaches and future challenges. *Environmental health perspectives*, 112(9):998–1006, 2004.
- Lourdes Esteva, GUULÍRMO GÓMEZ JUAN HERNÁNDEZ, y MARCO ZEPbDA. Matemáticas y epidemiología. *Ciencias*, 24:57–63, 1991.
- FAO. Final report: Evaluation of fao's role and work in nutrition. Technical report, FAO Office of Evaluation, MB663., 108th Programme Committee and UN Scaling Up Nutrition (SUN), 2011a. URL http://www.fao.org/docrep/meeting/026/MD776E.pdf.
- FAO. Seguridad Alimentaria y Nutricional. Conceptos Basicos. Programa Especial para la Seguridad Alimentaria (PESA), Centroamerica. Proyecto Food Facility Honduras. FAO, 2011b. URL http://www.fao.org/3/a-at772s.pdf.
- FAO, editor. Panorama de la Inseguridad Alimentaria en Latinoamérica y el Caribe. FAO, 2015. URL http://www.fao.org/3/a-i4636s.pdf.

- FAO, editor. Cambio climático y seguridad alimentaria y nutricional América Latina y el Caribe. Food and Agricultural Organization, 2016. URL http://www.fao.org/fileadmin/user_upload/rlc/docs/Cambioclimatico.pdf.
- FJ Moral García. Aplicación de la geoestadística en las ciencias ambientales. Revista Ecosistemas, 13(1), 2004.
- Emanuele Giorgi, Peter J. Diggle, Robert W. Snow, y Abdisalan M. Noor. Geostatistical methods for disease mapping and visualisation using data from spatio-temporally referenced prevalence surveys. *International Statistical Review*, 86(3):571–597, 2018. doi: 10.1111/insr.12268. URL https://onlinelibrary.wiley.com/doi/abs/10.1111/insr.12268.
- Karen Glanz, James F Sallis, Brian E Saelens, y Lawrence D Frank. Healthy nutrition environments: concepts and measures. *American journal of health promotion*, 19(5):330–333, 2005.
- Mario A. Gomarasca. Basics of geomatics. *Applied Geomatics*, 2(3):137–146, Sep 2010. ISSN 1866-928X. doi: 10.1007/s12518-010-0029-6. URL https://doi.org/10.1007/s12518-010-0029-6.
- Emmanuel Gringarten y Clayton V."Deutsch. Teacher's aide variogram interpretation and modeling. *Mathematical Geology*, 33(4):507–534, May 2001. doi: 10.1023/A:1011093014141. URL https://doi.org/10.1023/A:1011093014141.
- Susan L Handy, Marlon G Boarnet, Reid Ewing, y Richard E Killingsworth. How the built environment affects physical activity: views from urban planning. *American journal of preventive medicine*, 23(2):64–73, 2002.
- R Haralick, K Shanmugam, y I. Dinstein. Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, 3(6):610 621, 1973.
- U Helldén y L Eklundh. National drought impact monitoring-a NOAA NDVI and precipitation data study of Ethiopia. *Lund Studies in Geography, Ser. C. General, Mathematical and Regional Geography*, 1988.
- Jelle U Hielkema y FL Snijders. 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, 1994.
- X. Huang, H. Liu, y L. Zhang. Spatiotemporal detection and analysis of urban villages in mega city regions of china using high-resolution remotely sensed imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 53(7):3639–3657, July 2015. doi: 10.1109/TGRS.2014.2380779.
- INDEC. Censo nacional de población, hogares y viviendas 2010. Technical Report 1, Instituto Nacional de Estadísticas y Censos, Buenos Aires, Argentina, 10 2012.
- Secretaria de Salud de la Nacion INDEC. 4*grad* encuesta nacional de factores de riesgos: resultados preliminares. Technical Report 1, Instituto Nacional de Estadísticas y Censos, Secretaria de Salud, Buenos Aires, Argentina, 4 2019.
- Tabassum Z Insaf y Thomas Talbot. Identifying areas at risk of low birth weight using spatial epidemiology: A small area surveillance study. *Preventive medicine*, 88:108–114, 2016.
- Dylan B Jackson, Kecia R Johnson, Michael G Vaughn, y Marissa E Hinton. The role of neighborhoods in household food insufficiency: Considering interactions between physical disorder, low social capital, violence, and perceptions of danger. *Social Science & Medicine*, 221:58–67, 2019.
- GE Johnson, VR Achutuni, y S Thiruvengadachari. 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. *Springer US*, 1993.
- Kiersten B Johnson, Anila Jacob, y Molly E Brown. 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, 2013.

- Christopher O Justice, JRG Townshend, BN Holben, y et CJ Tucker. Analysis of the phenology of global vegetation using meteorological satellite data. *International Journal of Remote Sensing*, 6(8):1271–1318, 1985.
- I Kemeling. *Mapping Urban and Peri-Urban Agricultural Areas in Ouagadougou, Burkina Faso*. Tesis de Doctorado, Centre for Geo-Information: Wageningen, 2001.
- William Ogilvy Kermack y Anderson G McKendrick. A contribution to the mathematical theory of epidemics. *Proceedings of the royal society of london. Series A, Containing papers of a mathematical and physical character*, 115(772):700–721, 1927.
- Dohyeong Kim, Chang Kil Lee, y Dong Yeon Seo. Food deserts in korea? a gis analysis of food consumption patterns at sub-district level in seoul using the knhanes 2008-2012 data. *Nutrition research and practice*, 10 (5):530–536, 2016.
- Rachel T Kimbro, Justin T Denney, y Sarita Panchang. Individual, family, and neighborhood characteristics and children's food insecurity. *Journal of Applied Research on Children: Informing Policy for Children at Risk*, 3(1), 2012.
- Damaris K Kinyoki, Ngianga-Bakwin Kandala, Samuel O Manda, Elias T Krainski, Geir-Arne Fuglstad, Grainne M Moloney, James A Berkley, y Abdisalan M Noor. Assessing comorbidity and correlates of wasting and stunting among children in somalia using cross-sectional household surveys: 2007 to 2010. *BMJ Open*, 6 (3), 2016. ISSN 2044-6055. doi: 10.1136/bmjopen-2015-009854. URL https://bmjopen.bmj.com/content/6/3/e009854.
- Felix Kogan, Wei Guo, y Wenze Yang. Drought and food security prediction from noaa new generation of operational satellites. *Geomatics, Natural Hazards and Risk*, 10(1):651–666, 2019. doi: 10.1080/19475705. 2018.1541257.
- Richard Kollodge, editor. Estado de la población Mundial 2016. UNFPA, 2016.
- M Kuffer, A Pfeffer, y R Sliuzas. Slums from space 15 years of slum mapping using remote sensing. *Remote Sens*, 8(455), 2016. doi: 10.3390/rs8060455.
- Tobia Lakes y Katrin Burkart. Childhood overweight in berlin: intra-urban differences and underlying influencing factors. *International journal of health geographics*, 15(1):12, 2016.
- Marc Lalonde. A new perspective on the health of canadians. www. phac-aspc. gc. ca/ph-sp/phdd/pdf/perspective. pdf, 1974.
- David López-Carr, Kevin M Mwenda, Narcisa G Pricope, Phaedon C Kyriakidis, Marta M Jankowska, John Weeks, Chris Funk, Gregory Husak, y Joel Michaelsen. A spatial analysis of climate-related child malnutrition in the lake victoria basin. En 2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), páginas 2564–2567. IEEE, 2015.
- Victoria L Mayer, Amy Hillier, Marcus A Bachhuber, y Judith A Long. Food insecurity, neighborhood food access, and food assistance in philadelphia. *Journal of Urban Health*, 91(6):1087–1097, 2014.
- Larissa L Mendes, Helena Nogueira, Cristina Padez, Maria Ferrao, y Gustavo Velasquez-Melendez. Individual and environmental factors associated for overweight in urban population of brazil. *BMC Public Health*, 13 (1):988, 2013.
- Naoki Minamiguchi. The application of geospatial and disaster information for food insecurity and agricultural drought monitoring and assessment by the fao giews and asia fivims. En *Workshop on Reducing Food Insecurity Associated with Natural Disasters in Asia and the Pacific*, volumen 27, página 28, 2005.
- Seyed M Moghadas. Gaining insights into human viral diseases through mathematics. *European journal of epidemiology*, 21(5):337–342, 2006.

- Jorge Morello. Funciones del sistema periurbano: el caso de buenos aires. *Universidad Nacional de Mar del Plata, Centro de Investigaciones Ambientales*, 2000.
- T. Novack y H. J.H. Kux. Urban land cover and land use classification of an informal settlement area using the open-source knowledge-based system interimage. *Journal of Spatial Science*, 55(1):23–41, 2010. doi: 10.1080/14498596.2010.487640. URL https://doi.org/10.1080/14498596.2010.487640.
- Olayemi Olabiyi y Lynn McIntyre. Neighborhood matter: Variation in food insecurity not explained by household characteristics. Technical report, 2016.
- Richard S. Ostfeld, Gregory E. Glass, y Felicia Keesing. Spatial epidemiology: an emerging (or re-emerging) discipline. *Trends in Ecology & Evolution*, 20(6):328 336, 2005. ISSN 0169-5347. doi: https://doi.org/10.1016/j.tree.2005.03.009.
- K Owen y D. Wong. Exploring structural differences between rural and urban informal settlements from imagery: the basureros of cobán. *Geocarto International*, 28(7):562 –581, 2013a. doi: 10.1080/10106049. 2012.734533.
- KK Owen y DV Wong. An approach to differentiate informal settlements using spectral, texture, geomorphology and road accessibility metrics. *Applied Geography 38*, 38:107 118, 2013b.
- Evelia Edith Oyhenart, Silvia Lucrecia V Dahinten, Luis María Forte, y Bárbara Navazo. Composición corporal en relación al sobrepeso ya la obesidad. un estudio en niños residentes en diferentes áreas geográficas de argentina. *Nutrición Clínica y Dietética Hospitalaria*, 2017.
- Bhartendu Pandey y Karen C. Seto. Urbanization and agricultural land loss in india: Comparing satellite estimates with census data. *Journal of Environmental Management*, 148:53 66, 2015. ISSN 0301-4797. doi: https://doi.org/10.1016/j.jenvman.2014.05.014. URL http://www.sciencedirect.com/science/article/pii/S0301479714002540. Land Cover/Land Use Change (LC/LUC) and Environmental Impacts in South Asia.
- Dixis Figueroa Pedraza. Obesidad y pobreza: marco conceptual para su análisis en latinoamérica. *Saúde e Sociedade*, 18:103–117, 2009.
- M Pesaresi y JA Benediktsson. A new approach for the morphological segmentation of high-resolution satellite imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 39(2):309–320, 2001.
- M Pontil y A Verri. Properties of support vector machines. MIT Press Journal, 10(4):955 –974, 1997.
- Barry M Popkin. The nutrition transition and obesity in the developing world. *The Journal of nutrition*, 131 (3):871S–873S, 2001.
- The Guiford Press, editor. *Introduction to remote sensing*. Campbell, J and Wynne, R, 5ta edición edition, 2011.
- A Puissant, J Hirsch, y C Weber. 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, 2005.
- Wenzhe Qin, Lu Wang, Lingzhong Xu, Long Sun, Jiajia Li, Jiao Zhang, y Hui Shao. An exploratory spatial analysis of overweight and obesity among children and adolescents in shandong, china. *BMJ Open*, 9(8), 2019. ISSN 2044-6055. doi: 10.1136/bmjopen-2018-028152. URL https://bmjopen.bmj.com/content/9/8/e028152.
- Karen Rideout, Catherine L Mah, y Leia Minaker. Food environments: an introduction for public health practice. *National Collaborating Centre for Environmental Health British Columbia Centre for Disease Control: Vancouver, BC, Canada*, 2015.
- A Salvia, I Tuñón, y B Musante. La inseguridad alimentaria en la Argentina: Hogares urbanos, año 2011. Universidad Católica Argentina, 2012. URL http://www.uca.edu.ar/uca/common/grupo68/files/Informe_Inseguridad_Alimentaria___doc_de_trabajo_.pdf.

- Secretaría de Gobierno de Salud. 2da encuesta Nacional de Nutrición y Salud. documento de resultados 2019. Technical report, Ministerio de Salud y Desarrollo Social. Presidencia de la Nación, 2019. URL http://www.msal.gob.ar/images/stories/bes/graficos/0000001565cnt-ennys2_resumen-ejecutivo-2019.pdf.
- Marc Souris. *Epidemiology and Geography: Principles, Methods and Tools of Spatial Analysis*. John Wiley & Sons, 03 2019. ISBN 9781786303608. doi: 10.1002/9781119528203.
- Seth E Spielman y Eun-hye Yoo. The spatial dimensions of neighborhood effects. *Social science & medicine*, 68(6):1098–1105, 2009.
- M Stasolla y P Gamba. Exploiting spatial patterns for informal settlement selection in arid environments using optical spaceborne data. *Stilla U et al (Eds) PIA07. International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 36 (3/W49A), 2007.
- Mattia Stasolla y Paolo Gamba. Humanitarian aids using satellite technology. En *Space Technologies for the Benefit of Human Society and Earth*, páginas 431–451. Springer, 2009.
- Thomas Tanner, Tom Mitchell, Emily Polack, y Bruce Guenther. Urban governance for adaptation: assessing climate change resilience in ten asian cities. *IDS Working Papers*, 2009(315):01–47, 2009.
- G Tansey. Reworking the global food system. Cross, R., & Societies, R. C.. World disaster report 2011: Focus on hunger and malnutrition., 2011.
- M Teubal. Hambre y alimentación en Argentina. Realidad Económica. IADE. No. 89, páginas 85-103, 1989.
- Wei Tu, Stuart Tedders, y Jie Tian. An exploratory spatial data analysis of low birth weight prevalence in georgia. *Applied Geography*, 32(2):195 207, 2012. ISSN 0143-6228. doi: https://doi.org/10.1016/j.apgeog. 2011.06.001.
- UN-Habitat. Urbanization and development: Emerging futures. world cities report 2016. Technical report, United Nations Human Settlements Programme., 2016.
- Department of Economic United Nations y Population Division Social Affairs. World urbanization prospects: The 2014 revision. Technical report, United Nations, 2015.
- Lance A Waller y Carol A Gotway. *Applied spatial statistics for public health data*, volumen 368. John Wiley & Sons, 2004.
- JR Weeks, A Hill, D Stow, A Getis, y Fugate D. Can we spot a neighborhood from the air? defining neighborhood structure in [accra, ghana]. *GeoJournal*, 69(1-2):9–22, 2007.
- Kellee White, Jennifer S Haas, y David R Williams. Elucidating the role of place in health care disparities: the example of racial/ethnic residential segregation. *Health services research*, 47(3pt2):1278–1299, 2012.
- AGO Yeh y X Li. Measurement and monitoring of urban sprawl in a rapidly growing region using entropy. *Photogrammetric Engineering and Remote Sensing*, 67:83 90, 2001.
- M Zhang y N Kukadia. Metrics of urban form and the modifiable areal unit problem. *Transportation Research Record: Journal of the Transportation Research Board*, 1902:71 –79, 2005.
- Q. Zhang, J. Wang*, P. Gong, y P. Shi. Study of urban spatial patterns from spot panchromatic imagery using textural analysis. *International Journal of Remote Sensing*, 24(21):4137–4160, 2003. doi: 10.1080/0143116031000070445. URL https://doi.org/10.1080/0143116031000070445.