

Caracterización ambiental de la cobertura urbana para evaluar la distribución de ovitrampas de monitoreo de *Aedes aegypti*

Por ***Carla Rodriguez Gonzalez***

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

MAGISTER EN APLICACIONES DE INFORMACIÓN ESPACIAL

UNIVERSIDAD NACIONAL DE CÓRDOBA

Mayo, 2022

©IG-CONAE 2022

©FaMAF-UNC 2022

DIRECTOR

Dra. Verónica Andreo

Instituto de Altos Estudios Espaciales Mario Gulich, Córdoba, Argentina.



Esta obra está bajo una Licencia internacional Creative Commons:

<http://creativecommons.org/licenses/by/4.0/>

Agradecimientos

Esta tesis fue posible gracias a la contribución de muchas personas que me acompañaron a lo largo de este camino y aportaron conocimientos, experiencia, calidez humana y paciencia.

A mi familia, por el apoyo y amor de siempre, por aconsejarme cada vez que lo necesité y acompañarme de cerca en cada decisión. Por ser mis referentes y sostén.

A mi mentora y directora de tesis, Vero, quien guió y revisó detalladamente este trabajo. Gracias por acompañarme desde el primer día, por la paciencia y dedicación, por enseñarme una forma tan metódica y prolija de trabajar, contagiarme las ganas de superar cualquier problema y llevar la bandera del software libre.

Al Marce, por abrirme las puertas del Gulich más de una vez, por confiar en mí y valorar a las personas por sobre todas las cosas. Gracias por guiarme estos años y marcar un camino posible, en el que hoy me siento tan cómoda y segura.

A todo el equipo de docentes, Santi, Almen, Caro, Gastón, Juan, Ana, etc etc. y a todes mis compas de la MAIE que a pesar de las circunstancias y de una pandemia de por medio, supieron acompañar y compartir durante todo el recorrido, acortando las distancias. Aprendí muchísimo de todes y cada uno de ustedes. En especial a Eli y Yelvis, por tantas horas de trabajo, risas y nervios compartidos.

Al Instituto Gulich y a la Universidad Nacional de Córdoba, que hacen posible esta maestría y forman profesionales de diversos campos en el uso de técnicas de aplicaciones espaciales. Y a CONAE, por brindarme una beca y la posibilidad para continuar mi formación y crecimiento profesional.

A toda la comunidad del IG, por el apoyo y el cariño desde la primera vez que llegue al instituto, por hacerme parte de esta gran familia.

A mis amis de toda la vida, del manto y de la facu, por ser una hermosa red contenedora, de escape a cualquier problema y compañía de tantas alegrías.

Gracias.

Resumen

Aedes aegypti es el principal vector de los virus del dengue, chikungunya y zika, que juntos han provocado en la última década la mayor tasa de enfermedad y mortalidad entre los virus emergentes y/o re-emergentes en las Américas. La vigilancia vectorial constituye una herramienta clave para la prevención y el control de estas enfermedades. En este contexto, una adecuada distribución de sensores de oviposición dentro de una ciudad proporcionará información oportuna y precisa para orientar las acciones de salud pública. Bajo el supuesto de que la variabilidad ambiental determinará diferentes probabilidades de presencia y actividad de los mosquitos, el objetivo de esta tesis fue caracterizar la cobertura urbana de la ciudad de Córdoba teniendo en cuenta cuatro criterios de organización espacial (barrios, radios censales, polígonos de salud y grilla) para determinar una distribución óptima de la red de ovitrampas en función de la variabilidad ambiental y que a la vez considere el riesgo potencial de transmisión de dengue. Para ello, primero se clasificó una imagen de muy alta resolución (VHR) a partir de dos enfoques supervisados: uno basado en píxeles con Google Earth Engine y otro basado en objetos (GEOBIA) con GRASS GIS. A continuación, se estimaron varias métricas de paisaje y se realizó un análisis de agrupamiento o *clustering* con *k-means* para determinar grupos de polígonos ambientalmente similares sobre la ciudad. Tras diferentes pruebas, se definieron 3 clusters para los barrios, 4 para los radios y grilla y 5 para los polígonos de salud. Por último, distribuimos 150 ovitrampas sobre la ciudad en función de los grupos ambientales definidos y comparamos esta distribución con la utilizada por el Ministerio de Salud (arbitraria), una aleatoria, una en función de la incidencia de dengue y otra sistemática. Se observó que la distribución de sensores utilizada por el Ministerio de Salud es la de menor representación ambiental de la ciudad para todos los criterios de organización. En cambio, las distribuciones estratificadas por *clusters* e incidencia a nivel de radios censales y polígonos de salud fueron las mejores opciones ya que cubren adecuadamente la variabilidad ambiental detectada sobre la ciudad y consideran los casos de dengue del brote pasado. Como propuestas futuras, podrían analizarse los tiempos de recorridos y rutas para llegar a cada sitio, con el fin de diseñar un sistema más operativo para los técnicos encargados de la distribución y revisión semanal de ovitrampas.

Palabras clave: Dengue, Sensado remoto urbano, GEOBIA, Ecología del paisaje, Clustering espacial

Abstract

Aedes aegypti is the main vector of Dengue, Chikungunya and Zika viruses, which together have caused the highest rate of disease and mortality among emerging and/or re-emerging viruses in the Americas in the last decade. Vector surveillance is a key tool for prevention and control of these diseases. In this context, a proper distribution of sensors within a city will provide timely and precise information to guide public health actions. Under the assumption that environmental variability will determine different probabilities of mosquito presence and activity, the objective of this thesis was to characterise the urban coverage of Córdoba city taking into account four spatial organisation criteria (neighbourhoods, census tracts, health polygons and grid) in order to determine an optimal distribution of the ovitrap network according to environmental variability while considering the potential risk of dengue transmission. For this, a very high resolution (VHR) image was first classified using two supervised approaches: a pixel-based approach with Google Earth Engine and an object-based (GEOBIA) approach with GRASS GIS. Then, several landscape metrics were estimated and performed a *k-mean* clustering to determine groups of environmentally similar polygons over the city. After different tests, 3 clusters were defined for neighbourhoods, 4 for census tracts and grid and 5 for health polygons. Finally, we distributed 150 ovitraps over the city according to the defined environmental clusters and compared this distribution with the one used by the Ministry of Health (arbitrary), a random one, one according to dengue incidence and a systematic one. It was observed that the sensor distribution used by the Ministry of Health is the least environmentally representative of the city for all organisational criteria. In contrast, the distributions stratified by *clusters* and incidence at the level of census tracts and health polygons were the best options since they adequately cover the environmental variability detected over the city and consider the dengue cases of the past outbreak. As future proposals, the travel times and routes to reach each site could be analysed in order to design a system more operative for the technicians in charge of the distribution and weekly revision of ovitraps.

Keywords: Dengue fever, Urban remote sensing, GEOBIA, Landscape ecology, Spatial clustering

Índice de Contenidos

1. Introducción	1
1.1. Presentación del problema y motivación	1
1.2. Hipótesis	5
1.3. Objetivos	5
1.3.1. Objetivo general	5
1.3.2. Objetivos específicos	5
1.4. Descripción de la presentación de tesis	6
2. Marco teórico	8
2.1. Sensado remoto: principios y fundamentos	8
2.1.1. Sensado remoto en áreas urbanas	10
2.1.1.1. Técnicas de sensado remoto aplicadas en áreas urbanas	13
2.2. Mosquitos urbanos de importancia epidemiológica	14
2.2.1. Vigilancia entomológica de <i>Aedes aegypti</i>	14
2.3. Caracterización de ambientes urbanos	17
2.3.1. Desde el sensado remoto	17
2.3.2. Desde la ecología del paisaje	18
2.3.2.1. Métricas del paisaje	19
3. Clasificaciones de áreas urbanas basadas en píxeles y en objetos	21

3.1.	Introducción	21
3.2.	Materiales y métodos	23
3.2.1.	Área de estudio	23
3.2.2.	Imagen satelital	24
3.2.3.	Pre-procesamiento	26
3.2.3.1.	Cálculo de índices espectrales y texturales	26
3.2.3.2.	Máscara de cobertura urbana	27
3.2.4.	Definición de verdad de campo (VC) y clases de cobertura del suelo	29
3.2.5.	Algoritmo de clasificación	30
3.2.5.1.	Clasificación basada en píxeles	30
3.2.5.2.	Clasificación basada en objetos	30
3.2.6.	Evaluación de la precisión de las clasificaciones	35
3.3.	Resultados	36
3.3.1.	Clasificación basada en píxeles	36
3.3.2.	Clasificación basada en objetos (OBIA)	39
3.3.3.	Comparación de clasificaciones	42
3.4.	Discusión	44
3.5.	Conclusión	45
4.	Caracterización de la variabilidad ambiental urbana	46
4.1.	Introducción	46
4.2.	Materiales y métodos	47
4.2.1.	Métricas del paisaje	47
4.2.1.1.	<i>Landscapemetrics</i>	48
4.2.2.	Análisis de agrupamiento espacial o <i>Clustering</i>	51
4.2.2.1.	Método de agrupamiento k-means	51
4.2.2.2.	Estimación del número óptimo de clusters	53
4.2.2.3.	Descripción de clusters	54
4.2.2.4.	Validación interna de clusters	54
4.3.	Resultados	55

4.3.1.	Métricas del paisaje	55
4.3.2.	Análisis de agrupamiento espacial	55
4.3.2.1.	Estimación del número óptimo de clusters	55
4.3.2.2.	Validación interna de clusters	59
4.3.2.3.	Generación y análisis de <i>clusters</i>	60
4.4.	Discusión	77
5.	Distribución de ovitrampas para el Sistema de Monitoreo de la Ciudad de Córdoba: su relación con la variabilidad ambiental y la incidencia de Dengue	80
5.1.	Introducción	80
5.2.	Materiales y métodos	82
5.2.1.	Datos entomológicos: distribución de ovitrampas	82
5.2.2.	Datos epidemiológicos: distribución de casos de Dengue	82
5.2.3.	Datos poblacionales y cálculo de incidencia	83
5.2.4.	Análisis de la distribución de ovitrampas	83
5.3.	Resultados	88
5.3.1.	Distribución de casos de dengue y su relación con los distintos grupos ambientales	88
5.3.2.	Análisis de distribución de ovitrampas	89
5.3.2.1.	Estimación del número de ovitrampas por estrato	89
5.3.2.2.	Cantidad de ovitrampas y área de cobertura por <i>cluster</i>	90
5.4.	Discusión	94
6.	Discusión y conclusión final	96
	Anexos	120
A.	Anexo del capítulo 3	120
B.	Anexo del capítulo 4	129
C.	Anexo del capítulo 5	136

Índice de figuras

1.1. Distribución mundial de dengue. Organización Mundial de la Salud, 2016.	2
1.2. Casos confirmados de dengue por semana epidemiológica. Total del país. Temporadas 2015-2016 y 2019-2020. Fuente: Elaboración propia del Área de Vigilancia de la Salud de la Dirección Nacional de Epidemiología sobre la base de información proveniente del Sistema Nacional de Vigilancia de la Salud (SNVS2.0).	2
1.3. Criaderos artificiales de <i>Aedes aegypti</i> . Fuente: Revista semana  	3
1.4. Diagrama general con las principales etapas de la tesis.	7
2.1. Esquema de los componentes de un sistema de sensado remoto. Obtenido de Chuvieco et al. (2002)	9
2.2. Espectro electromagnético. Ilustración obtenida de Wikipedia, autor: Horst Frank, Jailbird (2007).	10
2.3. Imágenes satelitales de alta resolución espacial de zonas urbanas. Fuente (a): Pléiades Imagery User Guide (October 2012 – V 2.0). Fuente (b): QuickBird Satellite Image Gallery.	12
2.4. Relación entre los objetos considerados y la resolución espacial: (a) baja resolución: los píxeles son significativamente mayores que los objetos, se necesitan técnicas de sub-píxeles. (b) resolución media: los tamaños de los píxeles y de los objetos son del mismo orden, las técnicas píxel a píxel son adecuadas. (c) alta resolución: los píxeles son significativamente más pequeños que los objetos, se necesita la regionalización de los píxeles en grupos de píxeles y finalmente de objetos.	13

2.5. (a) Mosquito <i>Ae. aegypti</i> hembra alimentándose de sangre humana. Fotografía de James Gathany/CDC. (b) Ovitrapa.	15
2.6. Mapa global de la distribución prevista de <i>Ae. aegypti</i> . El mapa representa la probabilidad de aparición (de 0 azul a 1 rojo) a una resolución espacial de 5 km × 5 km. Kraemer et al. 2015  	15
2.7. Unidades básicas en ecología del paisaje. Fuente: Arizona’s Riparian Áreas.	19
3.1. Área de estudio en la ciudad de Córdoba (Argentina).	24
3.2. Detalle de bandas espectrales del satélite Pléiades en una región de la Ciudad de Córdoba.	25
3.3. Zoom de bandas multiespectrales y pancromática de Pléiades antes y después del pansharpening.	26
3.4. Flujo de trabajo para el pre-procesamiento de la imagen Pléiades.	26
3.5. Detalle de índices espectrales y texturales generados.	28
3.6. Mapa de la ciudad de Córdoba con puntos de verdad de campo.	29
3.7. Detalle de mosaicos generados con el algoritmo <i>Canny</i> para la imagen Pléiades.	31
3.8. Detalle de segmentaciones obtenidas variando el valor de <i>umbral</i> de similitud.	32
3.9. Flujo de trabajo para clasificación basada en objetos.	34
3.10. Mapa de cobertura urbana obtenido con la clasificación basada en píxeles. .	37
3.11. Detalle de clasificación basada en píxeles en distintas regiones del área de estudio.	38
3.12. Mapa de cobertura urbana obtenido con la clasificación basada en objetos. .	40
3.13. Detalles de productos obtenidos de la cadena de procesamiento de OBIA. En la parte superior detalles en RGB, al medio la segmentación y en la parte inferior las clasificaciones.	41
3.14. Importancia de variables para Random forest para ambas clasificaciones. . .	42
3.15. Comparación de precisión del productor entre ambas clasificaciones.	43
3.16. Comparación de precisión del usuario entre ambas clasificaciones.	43
3.17. Comparación de clasificaciones. Del lado izquierdo se muestran dos detalles de la Ciudad en RGB, al medio la clasificación basada en píxeles, y del lado derecho la clasificación basada en objetos.	44

4.1. Visualización de un paisaje de ejemplo (a) utilizando las funciones de utilidad <code>show_patches()</code> (b) y <code>show_cores()</code> (c) para una clase seleccionada. Figura extraída de Hesselbarth et al (2019)	49
4.2. Capas vectoriales utilizadas para los análisis de agrupamiento espacial.	52
4.3. Diversidad y Entropía de Shannon para los cuatro criterios de organización espacial de la Ciudad de Córdoba. (a) y (e) para Radios censales, (b) y (f) para Barrios, (c) y (g) para Polígonos de salud y; (d) y (h) para la Grilla.	56
4.4. Índice de agregación e Información mutua para los cuatro criterios de organización espacial de la Ciudad de Córdoba. (a) y (e) para Radios censales, (b) y (f) para Barrios, (c) y (g) para Polígonos de salud y; (d) y (h) para la Grilla.	57
4.5. Gráficos de sedimentación obtenidos con los métodos Silhouette y Gap.	58
4.6. Gráficos de sedimentación obtenidos con el método Elbow para determinar el número óptimo de clusters.	59
4.7. Agrupamiento por <i>k-means</i> basado en métricas a nivel de paisaje para los radios censales de la Ciudad de Córdoba. El agrupamiento se realizó incluyendo las métricas mencionadas en la Tabla 4.1 a nivel de paisaje y el valor de <i>k</i> fue fijado en 4 en base a la observación de los gráficos de sedimentación obtenidos.	61
4.8. Mapa obtenido a partir del análisis de agrupamiento espacial por <i>k-means</i> a nivel de paisaje para los radios censales de la Ciudad de Córdoba.	61
4.9. Agrupamiento por <i>k-means</i> para los barrios de la Ciudad de Córdoba. El agrupamiento se realizó incluyendo las métricas mencionadas en la Tabla 4.1 a nivel de paisaje y el valor de <i>k</i> fue fijado en 3 en base a la observación de los gráficos de sedimentación obtenidos.	62
4.10. Mapa obtenido a partir del análisis de agrupamiento espacial por <i>k-means</i> para los barrios de la Ciudad de Córdoba.	62
4.11. Agrupamiento por <i>k-means</i> para los polígonos de salud de la Ciudad de Córdoba. El agrupamiento se realizó incluyendo las métricas mencionadas en la Tabla 4.1 a nivel de paisaje y el valor de <i>k</i> fue fijado en 5 en base a la observación de los gráficos de sedimentación obtenidos.	63
4.12. Mapa obtenido a partir del análisis de agrupamiento espacial por <i>k-means</i> para los polígonos de salud de la Ciudad de Córdoba.	63
4.13. Agrupamiento por <i>k-means</i> para la Grilla de la Ciudad de Córdoba. El agrupamiento se realizó incluyendo las métricas mencionadas en la Tabla 4.1 a nivel de paisaje y el valor de <i>k</i> fue fijado en 4 en base a la observación de los gráficos de sedimentación obtenidos.	64

4.14. Mapa obtenido a partir del análisis de agrupamiento espacial por <i>k-means</i> para la grilla generada de la Ciudad de Córdoba	64
4.15. Boxplots de métricas estimadas a nivel de paisaje en función de los cuatro grupos ambientales obtenidos para los Radios censales de la Ciudad de Córdoba.	66
4.16. Boxplots de índices NDVI, NDWI y proporciones de clases obtenidas en función de los cuatro grupos ambientales obtenidos para los Radios censales de la Ciudad de Córdoba.	67
4.17. Boxplots de métricas estimadas a nivel de paisaje en función de los tres grupos ambientales obtenidos para los barrios de la Ciudad de Córdoba.	69
4.18. Boxplots de índices NDVI, NDWI y proporciones de clases obtenidas en función de los tres grupos ambientales obtenidos para los barrios de la Ciudad de Córdoba.	70
4.19. Boxplots de métricas del paisaje estimadas a nivel de paisaje en función de los cinco grupos ambientales obtenidos para los Polígonos de salud de la Ciudad de Córdoba.	72
4.20. Boxplots de índices NDVI, NDWI y proporciones de clases obtenidas en función de los cinco grupos ambientales obtenidos para los Polígonos de salud de la Ciudad de Córdoba.	73
4.21. Boxplots de métricas del paisaje estimadas a nivel de paisaje en función de los cuatro grupos ambientales obtenidos para la grilla de la Ciudad de Córdoba.	75
4.22. Boxplots de índices NDVI, NDWI y proporciones de clases obtenidas en función de los cuatro grupos ambientales obtenidos para la grilla de la Ciudad de Córdoba.	76
5.1. Distribución anterior (2017-2019) y actual (2020-actual) de ovitrampas del Ministerio de Salud para el sistema de monitoreo de <i>Aedes aegypti</i> de la Ciudad de Córdoba.	82
5.2. Casos autóctonos de dengue durante el 2020. Fuente: Ministerio de Salud de la provincia de Córdoba.	83
5.3. Técnicas de muestreo probabilísticas: a) Aleatorio simple; b) Aleatorio estratificado; c) Sistemático en rejilla rectangular; d) Sistemático en rejilla polar; e) zig-zag; f) Diagonal; g) Circular; h) Grilla. Fuente: Torri et al. (2017).	84
5.4. Detalle de <i>buffers</i> generados, con un radio de 150 metros, para el cálculo del área de cobertura de las ovitrampas. Imagen área de la ciudad de Córdoba, adquirida en 2016 con una resolución espacial de 20 cm. (Fuente: IGN)	86

5.5. Workflow implementado para el cálculo del área cubierta por ovitrampa según cada tipo de distribución.	87
5.6. Mapas de tasas de incidencia de dengue en la Ciudad de Córdoba, a partir de datos de casos de dengue y la estimación poblacional del producto demográfico de WorldPop.	89
5.7. Distribuciones de ovitrampas en la ciudad de Córdoba.	92
5.8. Mapas de distribución estratificada de ovitrampas según cada criterio de organización espacial de la Ciudad de Córdoba: por cluster, por incidencia y por la combinación de ambas.	93
6.1. Distribución de ovitrampas para la Ciudad de Córdoba en función de <i>clusters</i> ambientales e incidencia de dengue por polígonos de salud.	97
B.1. Agrupamiento por <i>k-means</i> a nivel de clase para los radios censales de la Ciudad de Córdoba. El agrupamiento se realizó incluyendo las métricas mencionadas en la Tabla 4.1 a nivel de clase y el valor de <i>k</i> fue fijado en 3 en base a la observación de los gráficos de sedimentación obtenidos.	132
B.2. Mapa obtenido a partir del análisis de agrupamiento espacial por <i>k-means</i> a nivel de clase para los radios censales de la Ciudad de Córdoba.	132
B.3. Agrupamiento por <i>k-means</i> a nivel de clase para los barrios de la Ciudad de Córdoba. El agrupamiento se realizó incluyendo las métricas mencionadas en la Tabla 4.1 a nivel de clase y el valor de <i>k</i> fue fijado en 3 en base a la observación de los gráficos de sedimentación obtenidos.	133
B.4. Mapa obtenido a partir del análisis de agrupamiento espacial por <i>k-means</i> a nivel de clase para los barrios de la Ciudad de Córdoba.	133
B.5. Agrupamiento por <i>k-means</i> a nivel de clase para los polígonos de thiesen de la Ciudad de Córdoba. El agrupamiento se realizó incluyendo las métricas mencionadas en la Tabla 4.1 a nivel de clase y el valor de <i>k</i> fue fijado en 4 en base a la observación de los gráficos de sedimentación obtenidos.	134
B.6. Mapa obtenido a partir del análisis de agrupamiento espacial por <i>k-means</i> a nivel de clase para los polígonos de thiesen de la Ciudad de Córdoba.	134
B.7. Agrupamiento por <i>k-means</i> a nivel de clase para la Grilla de la Ciudad de Córdoba. El agrupamiento se realizó incluyendo las métricas mencionadas en la Tabla 4.1 a nivel de clase y el valor de <i>k</i> fue fijado en 3 en base a la observación de los gráficos de sedimentación obtenidos.	135
B.8. Mapa obtenido a partir del análisis de agrupamiento espacial por <i>k-means</i> a nivel de clase para la Grilla de la Ciudad de Córdoba.	135

C.1. Porcentaje de ovitrampas por <i>cluster</i> de Radios censales para cada tipo de distribución analizado.	137
C.2. Porcentaje de ovitrampas por <i>cluster</i> de Barrios para cada tipo de distribución analizado.	138
C.3. Porcentaje de ovitrampas por <i>cluster</i> de polígonos de salud para cada tipo de distribución analizado.	139
C.4. Porcentaje de ovitrampas por <i>cluster</i> de grilla para cada tipo de distribución analizado.	140

Índice de tablas

2.1. Ejemplos de algunos de los sensores de alta resolución.	11
2.2. Sensores de resolución media.	12
2.3. Métodos de vigilancia de <i>Ae. aegypti</i> recopilados por Barrera et. al (2016).	16
3.1. Bandas espectrales del satélite Pléiades.	24
3.2. Verdad de campo y clases de cobertura del suelo.	29
3.3. Interpretación del coeficiente Kappa.	35
3.4. Mediciones de precisión del clasificador RF a nivel de píxeles. OA : Precisión global. Kappa como coeficiente de rango 0 a 1. PP : Precisión del productor; PU : Precisión de usuario.	36
3.5. Matriz de confusión para la clasificación basada en objetos. OA : Precisión global en%; Kappa como coeficiente de rango 0 a 1. PP : Precisión del productor; PU : Precisión de usuario.	39
4.1. Métricas del paisaje estimadas a nivel de clase y paisaje, disponibles en el paquete <i>landscapemetrics</i> del software R.	49
4.2. Descripción de las métricas de paisaje estimadas.	50
4.3. Comparación de la estimación del número de <i>clusters</i> en función de diferentes métodos.	59
4.4. Medidas de validación interna para el análisis de agrupamiento para Radios censales, Barrios, Polígonos de salud y Grilla de la ciudad de Córdoba.	60

4.5. Media aritmética para cada métrica del paisaje, índices NDVI, NDWI y proporción de cada clase por <i>cluster</i> para Radios censales.	65
4.6. Media aritmética para cada métrica del paisaje, índices NDVI, NDWI y proporción de cada clase por <i>cluster</i> para los barrios.	68
4.7. Media aritmética para cada métrica del paisaje, índices NDVI, NDWI y proporción de cada clase por <i>cluster</i> para los polígonos de salud.	71
4.8. Media aritmética para cada métrica del paisaje, índices NDVI, NDWI y proporción de cada clase por <i>cluster</i> para la grilla.	74
5.1. Cantidad y porcentaje de casos de dengue por <i>cluster</i> según cada capa.	88
5.2. Área (km ²) y porcentaje de superficie total cubierto por <i>cluster</i> según cada capa. Los <i>clusters</i> resaltados en gris claro se ubican en el centro y periferia de la ciudad de Córdoba, y fueron los <i>clusters</i> seleccionados para las diferentes distribuciones de ovitrampas.	90
5.3. Cantidad de ovitrampas y área de cobertura (km ²) por <i>clusters</i> según cada criterio de distribución. <i>Dist_Ac</i> : Distribución 2020-actual, <i>Dist_An</i> : Distribución 2017-2019, <i>Dist_Az</i> : Distribución al azar, <i>Dist_Sist</i> : Distribución sistemática, <i>Dist_E_Cl</i> : Distribución estratificada por <i>clusters</i> , <i>Dist_E_In</i> : Distribución estratificada por incidencia, <i>Dist_E_Cl_In</i> : Distribución estratificada por <i>clusters</i> e incidencia.	91

Acrónimos

CAPÍTULO 1

Introducción

1.1. Presentación del problema y motivación

Los mosquitos se encuentran entre los insectos vectores más importantes ya que transmiten los agentes causantes de algunas de las enfermedades infecciosas más peligrosas del mundo: la malaria, el dengue, la fiebre del Valle del Rift y la fiebre del Nilo Occidental (FNO). En América, *Aedes aegypti* es el principal vector de los virus dengue (DENV), chikungunya (CHIKV) y zika (ZIKV), que en conjunto en la última década han dado lugar a la mayor tasa de enfermedad y mortalidad entre los virus emergentes y/o re-emergentes (1; 2; 3).

El dengue es una enfermedad de distribución mundial y, de acuerdo con las estimaciones de la Organización Mundial de la Salud (OMS), más de la mitad del planeta vive en zonas de riesgo de infección, especialmente en las regiones tropicales y subtropicales (Figura 1.1). Los brotes de esta enfermedad ejercen una enorme carga para las poblaciones, los sistemas de salud y las economías en la mayoría de los países tropicales (4). En el año 2019, la Organización Panamericana de la Salud (OPS) alertó sobre el inicio de un nuevo ciclo epidémico de dengue en las Américas, con un incremento significativo de casos en varios territorios de la región (5). Durante ese mismo año, se registraron las mayores cifras históricas de dengue superando en un 30% las del año epidémico 2015.

En el año 2020, entre las semanas epidemiológicas 1 y 21 (10 de junio), se reportaron 1.645.678 casos de arbovirosis en las Américas. Correspondieron a dengue el 96% de los reportes, es decir 1.600.000 casos, seguido por 37.279 casos de chikungunya y 7.452 de zika (6). Brasil, Paraguay y Bolivia fueron los países limítrofes que presentaron el mayor número de casos de dengue. En la Argentina, durante ese año, se registró el brote más importante de dengue de la historia del país, tanto respecto al número de casos, como a la extensión geográfica y temporal (Figura 1.2). Desde de la temporada 2008-2009 hasta la actualidad, el dengue se propagó más allá de las zonas tropicales y subtropicales del norte, y llegó a zonas templadas del centro del país, como Córdoba, donde se detectó la primera transmisión autóctona en 2009 (7).

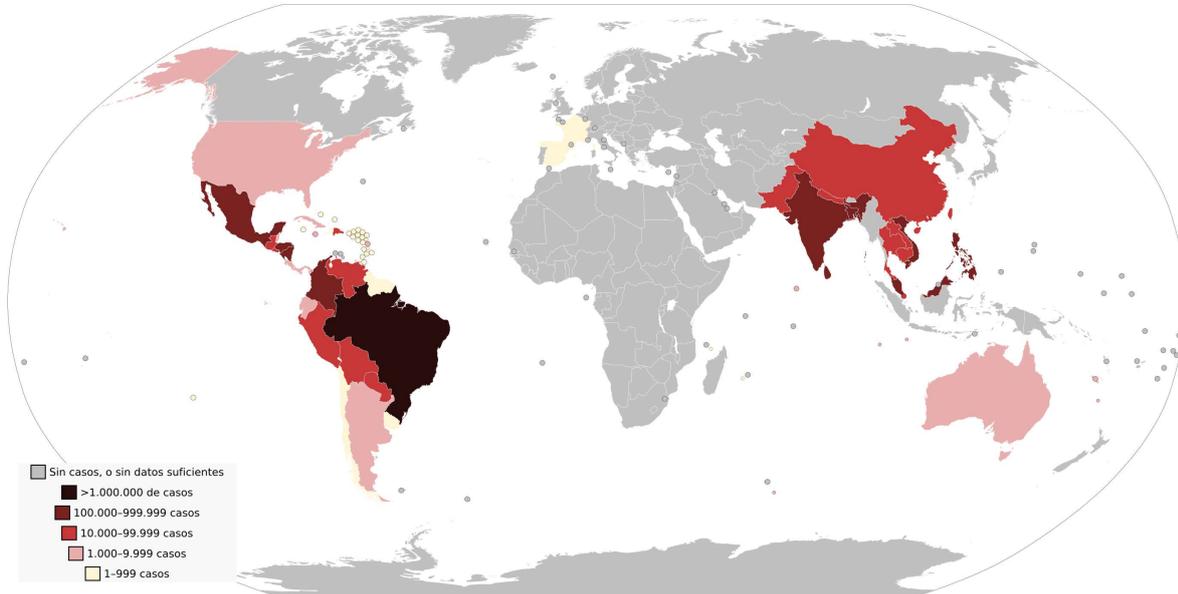


Figura 1.1: Distribución mundial de dengue. Organización Mundial de la Salud, 2016.

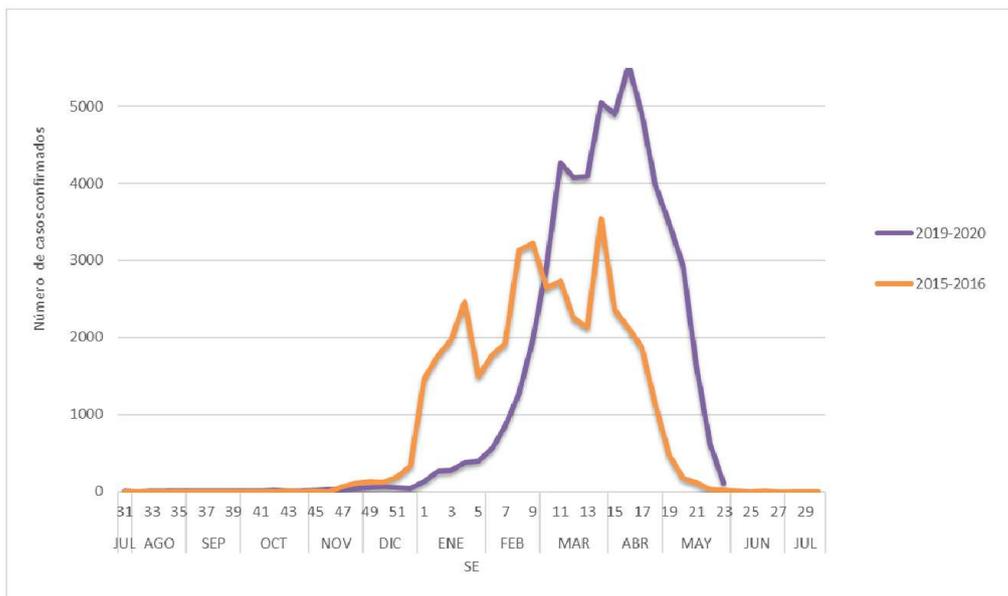


Figura 1.2: Casos confirmados de dengue por semana epidemiológica. Total del país. Temporadas 2015-2016 y 2019-2020. Fuente: Elaboración propia del Área de Vigilancia de la Salud de la Dirección Nacional de Epidemiología sobre la base de información proveniente del Sistema Nacional de Vigilancia de la Salud (SNVS2.0).

El avance del dengue hacia la región centro del país obedece a una multiplicidad de causas, tanto ambientales, como sociales y económicas. Debido a que esta enfermedad sólo puede persistir donde están presentes los vectores y, ante la falta de estrategias antivirales o vacunas específicas (8), comprender y mapear las distribuciones globales y locales de los vectores y los determinantes ambientales de sus rangos es esencial para la planificación de la salud pública. Los factores ambientales asociados al avance del dengue están ampliamente relacionados con el cambio climático que genera un progresivo aumento de temperatura, en especial en zonas templadas, y favorece el desarrollo vectorial (9). Los cambios de frecuencia de ciclos de sequía y humedad también impactan en la dinámica estacional de los vectores, prolongando las estaciones de transmisión de enfermedades (10). Por otra parte, las causas de tipo social como las migraciones, el hacinamiento y las condiciones inapropiadas de higiene y vivienda, también contribuyen a la expansión y establecimiento del vector (11; 12) al generar hábitats propicios para su desarrollo.

Ae. aegypti es considerada una especie invasiva y oportunista debido a su gran potencial de propagación y adaptación a nuevos entornos (13), especialmente los creados por cambios en la forma en la que los seres humanos habitan el planeta. Otros de los rasgos asociados con su éxito de invasión son los huevos resistentes a la desecación, la eclosión escalonada en el tiempo y el comportamiento de las hembras para distribuir los huevos de un ciclo gonadotrófico en varios contenedores, garantizando que al menos una parte de la descendencia sobreviva y se reproduzca (14).

Naturalmente esta especie se desarrolla en el agua acumulada en cavidades de plantas como huecos de los árboles (15), sin embargo, con el paso del tiempo se ha adaptado a zonas urbanas, adquiriendo la capacidad de criarse en micro-ambientes artificiales (16). Estos micro-ambientes comprenden un grupo de ambientes acuáticos con características ecológicas distintivas: son de tamaño pequeño; soportan un bajo número de especies; dependen del aporte externo de materia orgánica como fuente de energía; son temporarios y usualmente la presencia de predadores es menos frecuente (17). Se considera que estos mosquitos pueden reproducirse en cualquier contenedor donde caiga agua de lluvia o se almacene agua, aunque prefieren principalmente los criaderos al aire libre. Se han encontrado larvas en un gran número de contenedores artificiales, como neumáticos usados, latas y frascos de vidrio. Dentro de las viviendas humanas, los floreros, los recipientes con plantas acuáticas y los bebederos para animales domésticos también son potenciales criaderos (Figura 1.3) (18).



Figura 1.3: Criaderos artificiales de *Aedes aegypti*. Fuente: [Revista semana](#)

Debido a que los mosquitos son organismos poiquilotérmicos, buscan zonas de sombra durante el día para evitar la desecación y el calor severo (19). Esto sugiere que los hábitats de descanso diurno de estos organismos suelen estar asociados a la vegetación, que proporciona sombra y, por tanto, un microclima más fresco que el de las zonas abiertas, como el suelo desnudo y los espacios edificados (20).

El nicho ambiental que ocupa *Ae. aegypti* puede expresarse geográficamente identificando las condiciones ambientales que requiere este vector para reproducirse y mantener una población a largo plazo. El estudio de la distribución de los lugares de cría dentro de las zonas urbanas es un requisito clave para evaluar el riesgo de transmisión del dengue (21). Además, un seguimiento minucioso de las poblaciones de vectores permite identificar las alteraciones en las distribuciones y las fluctuaciones en las densidades de las especies de vectores permitiendo (re)evaluar los programas de prevención.

En este sentido, las herramientas de sensado remoto pueden ser de gran valor para la caracterización de condiciones ambientales que favorecen el desarrollo tanto de vectores como de los ciclos biológicos de las enfermedades que transmiten (22), permitiendo identificar, al menos en parte, las condiciones de hábitat más apropiadas en un área geográfica bajo estudio. Asimismo, el sensado remoto provee datos de cobertura global, tomados de manera sistemática, a diferentes resoluciones espaciales y a intervalos regulares. De esta forma, el procesamiento digital de imágenes permite apoyar, de manera ágil y fiable, los procesos de toma de decisiones en la planificación y gestión ambiental urbana (23), como así también en la distribución de sensores de monitoreo y vigilancia de mosquitos por parte de las autoridades de salud pública.

La información derivada de sensores remotos, en articulación con los sistemas de información geográfica (SIG), se ha vuelto esencial para el mapeo de la distribución espacial de enfermedades como malaria, filariasis, dengue, chikungunya y leishmaniasis visceral (24; 25; 26). Específicamente, en un marco interinstitucional entre la Comisión Nacional de Actividades Espaciales (CONAE) y el Ministerio de Salud de Argentina, han habido iniciativas para modelar la evolución temporal y espacial de las poblaciones de vectores y generar mapas de riesgo utilizando variables ambientales obtenidas de sensores remotos, fundamentalmente enfocadas en estudios y desarrollos sobre Chagas (27; 28), dengue (29; 30; 31; 32), leishmaniasis (33), fiebre hemorrágica Argentina y hantavirus (34; 35).

Numerosos estudios han abordado la distribución de *Ae. aegypti* y sus determinantes ambientales. La mayoría de ellos se han centrado en escalas globales y regionales utilizando principalmente predictores climáticos y datos de sensado remoto (36; 37; 38; 39). Diferentes estudios también han cartografiado su distribución a escala local en zonas urbanas, elaborando mapas estáticos o únicos que, o bien consideran solo un par de meses de vigilancia, o bien agregan un año completo (o varios años) de datos de mosquitos (40; 41; 42). Para la Ciudad de Córdoba, Estallo et al. 2018 (42) generaron un mapa de riesgo del vector que identifica los hábitats aptos para *Ae. aegypti* y, por tanto, el riesgo de transmisión de dengue. Por otro lado, dado que se requiere información operativa, detallada y oportuna dentro de cada temporada para decidir cuándo y dónde intensificar la vigilancia o intervenir con actividades de control, Andreo et al. 2021a (31), generaron y analizaron mapas multitemporales de *Ae. aegypti* y propusieron un flujo de trabajo operativo que puede actualizarse fácilmente con la entrada de nuevos datos de mosquitos y ambientales.

En este contexto, dada la importancia epidemiológica de este vector en nuestra región, desde el año 2017, las autoridades del Ministerio de Salud de la provincia de Córdoba, al igual que otras áreas urbanas de Argentina y América Latina, iniciaron un monitoreo semanal de la actividad de oviposición de *Ae. aegypti*. El programa se implementa mediante la distribución de ovitrampas en diferentes barrios de la ciudad. Esta técnica es una de las más implementadas para la vigilancia del vector, y su planificación requiere tanto de una buena gestión gubernamental como de la participación comunitaria. Analizar en donde se deben colocar ovitrampas constituye una etapa fundamental de los programas de vigilancia ya que de ello depende la imagen/información que se obtendrá luego sobre la actividad de los mosquitos en la ciudad. Dado que las ciudades constituyen ambientes complejos y heterogéneos, en donde diferentes zonas están caracterizadas por distintos ambientes físicos y humanos, se puede generar un patrón heterogéneo en la distribución del vector y por consiguiente, en el riesgo para la salud de la población (43). Hasta el momento, sin embargo, no se han generado estudios que vinculen la variabilidad ambiental de un lugar con la distribución de los sensores de monitoreo de oviposición del vector. Por esto, y como contribución al programa de vigilancia de *Ae. aegypti*, la presente tesis de maestría propone considerar la variabilidad ambiental existente en la Ciudad de Córdoba, a partir de análisis de imágenes satelitales de muy alta resolución espacial, para determinar la distribución de las ovitrampas del sistema de monitoreo aéreo.

1.2. Hipótesis

La estimación de diferentes variables ambientales a partir de información provista por sensores remotos podrá utilizarse para agrupar ambientalmente la Ciudad de Córdoba en un conjunto más reducido de categorías o *clusters*. Esta estructuración, permitirá determinar una distribución óptima de ovitrampas que represente la variabilidad ambiental existente.

1.3. Objetivos

1.3.1. Objetivo general

Caracterizar ambientalmente la cobertura urbana de la ciudad de Córdoba a fin de determinar una distribución óptima para la red de ovitrampas que refleje la variabilidad ambiental espacial y a la vez considere el riesgo potencial de transmisión de dengue.

1.3.2. Objetivos específicos

1. Evaluar las aproximaciones de clasificación basadas en píxeles y en objetos para obtener mapas de cobertura urbana para la ciudad de Córdoba a partir de técnicas de aprendizaje automático y una imagen de muy alta resolución espacial;
2. Caracterizar ambientalmente la ciudad de Córdoba a través de métricas de paisaje y definir grupos utilizando cuatro criterios diferentes de organización espacial (Radios censales, Barrios, polígonos de Thiessen por centros de salud y una Grilla de celdas arbitraria);

3. Evaluar la distribución actual de ovitrampas del sistema de monitoreo de *Aedes aegypti* de la ciudad de Córdoba, en cuanto a la representación de distintos grupos ambientales;
4. Analizar la distribución de los casos del último brote de Dengue y su relación con los grupos ambientales obtenidos y;
5. Analizar distintos criterios de distribución de ovitrampas y proponer una distribución óptima, considerando alternativas que maximicen la variabilidad ambiental y consideren la incidencia de dengue en el pasado brote.

1.4. Descripción de la presentación de tesis

El presente trabajo de tesis se ha organizado en función de los objetivos específicos propuestos. La Figura 1.4 muestra un diagrama general con las principales etapas de la tesis. En el capítulo 2 se presentan brevemente los conceptos básicos de sensado remoto en general y, en particular, el sensado remoto de áreas urbanas, *Aedes aegypti* y sus técnicas de monitoreo y control, así como también, conceptos generales de ecología del paisaje y la configuración espacial de sus elementos. Luego, en el capítulo 3 se describe brevemente el área de estudio y se evalúan diferentes metodologías de clasificación supervisada de imágenes satelitales de alta resolución. En el capítulo 4 se caracteriza la variabilidad ambiental urbana de la ciudad de Córdoba y se describen las diferentes métricas del paisaje utilizadas para generar el agrupamiento espacial. Posteriormente, en el capítulo 5 se proponen diferentes distribuciones de ovitrampas para la ciudad de Córdoba teniendo en cuenta distintos criterios y considerando los grupos ambientales obtenidos en el capítulo anterior. Por último, en el capítulo 6 se establecen las consideraciones finales y conclusiones de la tesis.

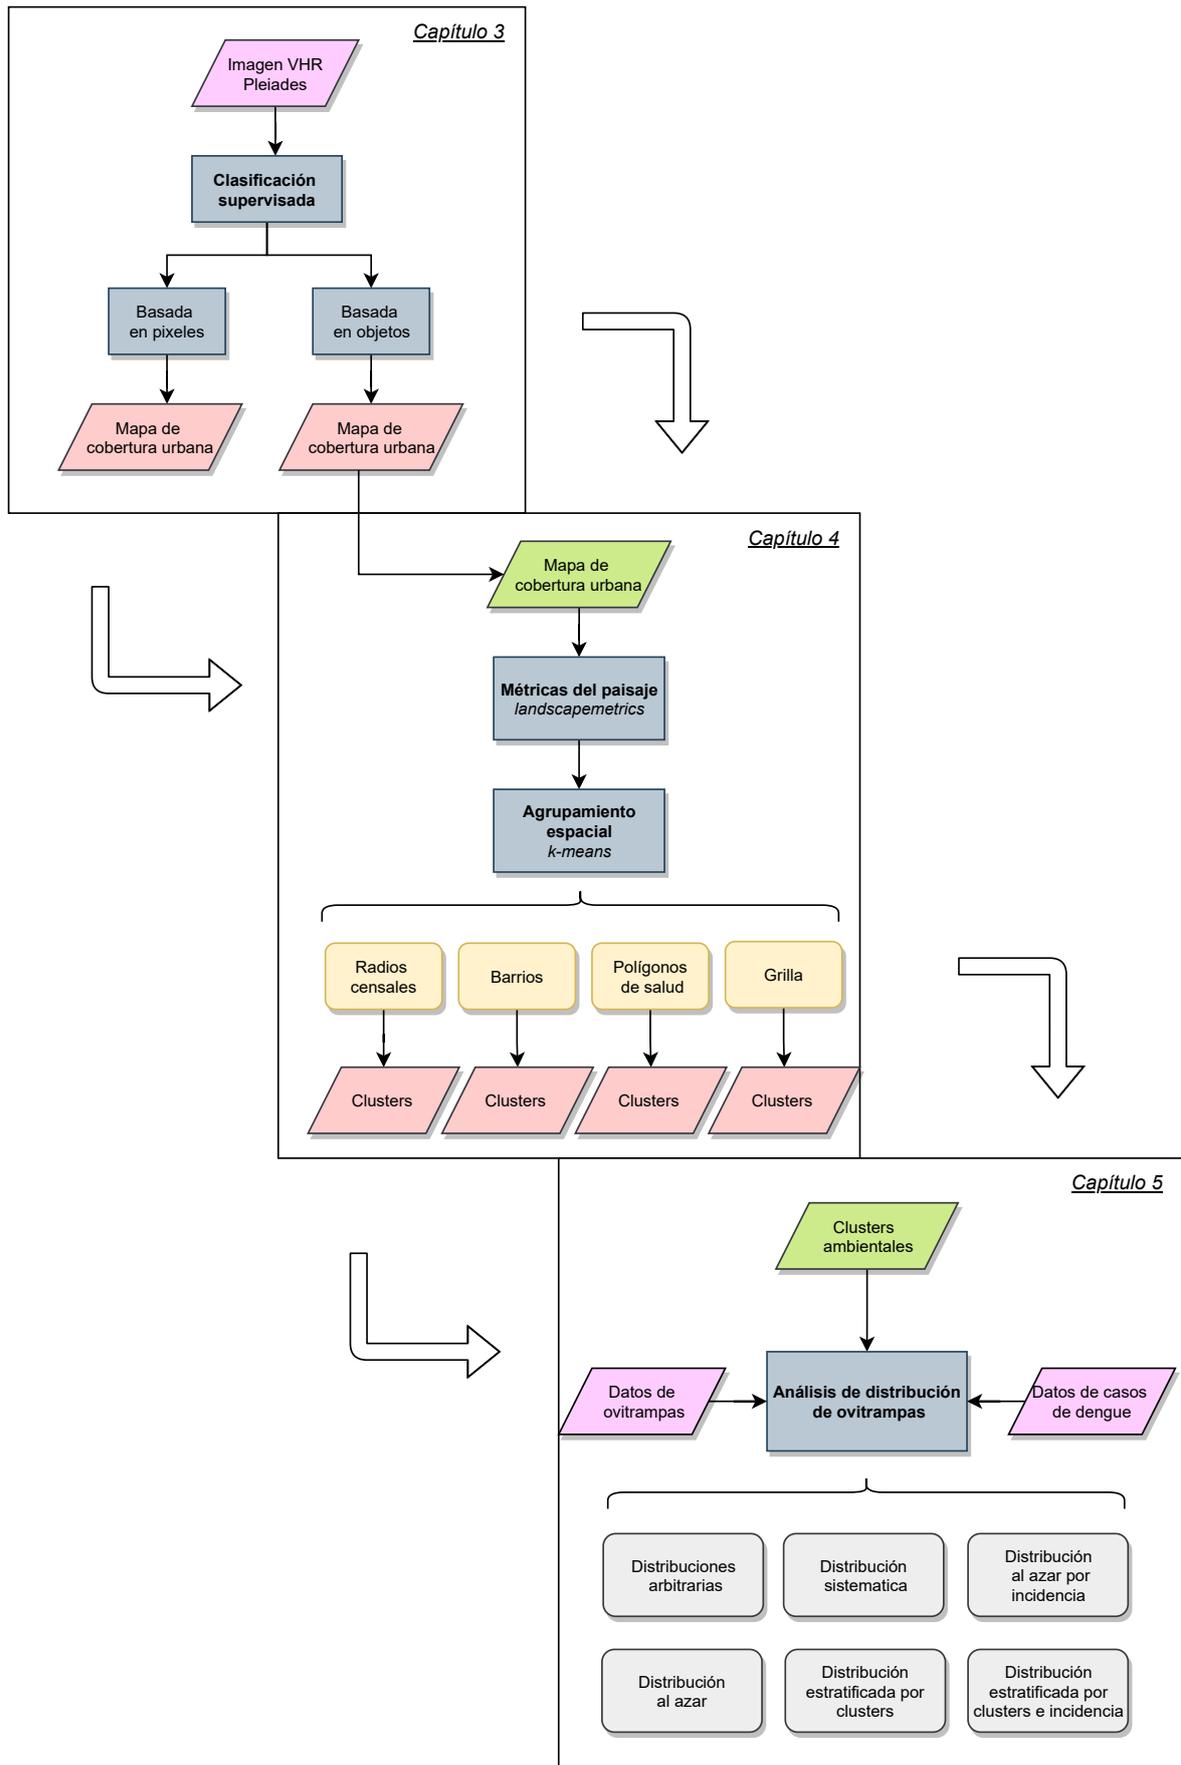


Figura 1.4: Diagrama general con las principales etapas de la tesis.

CAPÍTULO 2

Marco teórico

2.1. Sensado remoto: principios y fundamentos

El sensado remoto (o *remote sensing*) hace referencia a la técnica empleada para adquirir información sobre un objeto o fenómeno sin hacer contacto físico con él (44), a través de sensores ubicados en plataformas aerotransportadas (aviones tripulados o no tripulados - UAV) o aeroespaciales (satélites) (45). Los fundamentos físicos del sensado remoto se basan en la medida de la radiación electromagnética emitida o reflejada por los objetos, como respuesta a la incidencia de una radiación natural (luz solar) o artificial (radar). El principal objetivo del sensado remoto consiste en entender cómo la energía electromagnética interactúa con la superficie y así extraer información relevante para diferentes aplicaciones a partir de imágenes procesables. Un mejor entendimiento del funcionamiento de la Tierra motivan la evolución permanente de las técnicas y aplicaciones del sensado remoto e incrementan la demanda en la mejora de la precisión y fiabilidad de los datos obtenidos mediante el sensado remoto.

Un sistema de sensado remoto consta de los siguientes elementos (ver Figura 2.1) (46):

1. Fuente de energía: es el origen de la radiación que detecta el sensor. Este origen puede ser externo, donde la principal fuente es el sol; o propia emitida por el mismo sistema.
2. Medio de propagación: a través del cuál viaja la energía y la información.
3. Cubierta terrestre: que recibe la energía proveniente de la fuente y la refleja, aunque también puede emitir su propia energía.
4. Sistema sensor: compuesto por el sensor y la plataforma que lo sostiene.
5. Sistema de recepción: donde se recibe la información transmitida por la plataforma.
6. Intérprete: que convierte esos datos recibidos en información temática de interés.
7. Usuario final: que analiza el producto fruto de la interpretación.

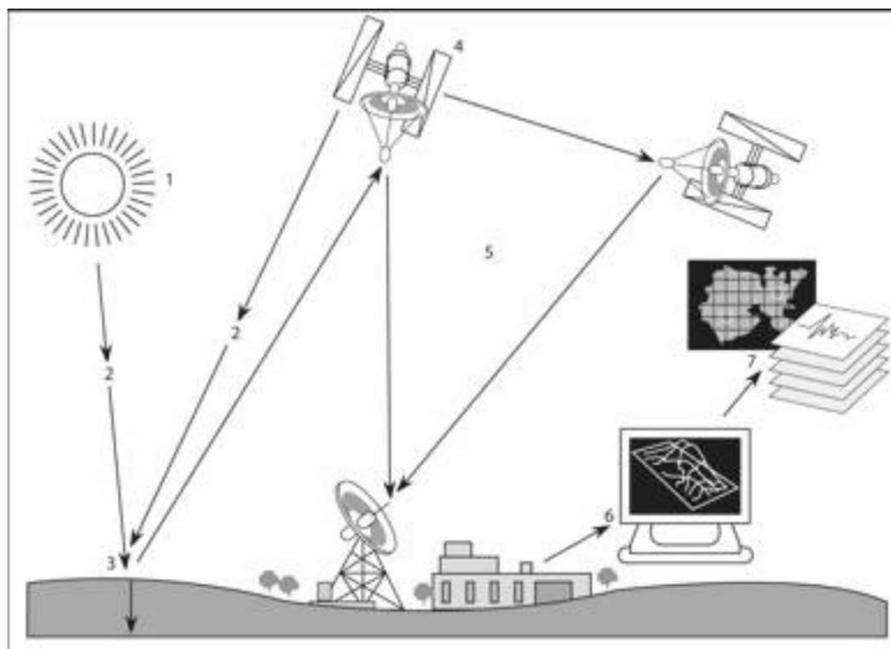


Figura 2.1: Esquema de los componentes de un sistema de sensor remoto. Obtenido de Chuvieco et al. (2002)

La energía electromagnética es un tipo de energía que se transmite por el espacio a través de ondas. Tanto la longitud de onda como la frecuencia permiten clasificar los diferentes tipos de energía electromagnética, recibiendo todos, en conjunto, el nombre de espectro electromagnético (Figura 2.2). Cada porción del espectro recibe un nombre de acuerdo al rango de longitud de onda considerada. Desde el punto de vista del sensor remoto conviene destacar una serie de bandas o regiones que son las más utilizadas en las tecnologías actuales:

- Espectro visible (λ de 0,4 a 0,7 μm): Es la única radiación electromagnética que pueden captar nuestros ojos coincidiendo con la máxima emisión de radiación solar. Dentro de ella suelen distinguirse tres bandas elementales, azul ($\lambda = 0,4\text{-}0,5 \mu\text{m}$), verde ($\lambda = 0,5\text{-}0,6 \mu\text{m}$) y rojo ($\lambda = 0,6\text{-}0,7 \mu\text{m}$).
- Infrarrojo cercano - IRC (de λ 0,7 a 1,3 μm): Es de especial importancia por su capacidad para discriminar masas vegetales y concentraciones de humedad.
- Infrarrojo medio (λ de 1,3 a 8 μm): En esta región se entremezclan los procesos de reflexión de luz solar y emisión de la superficie terrestre. Se divide en dos bandas: la primera está comprendida entre 1,3 y 2,5 μm se denomina infrarrojo de onda corta (SWIR) y se utiliza para determinar el contenido de humedad en la vegetación o en los suelos. La segunda se ubica en torno a los 3,7 μm , se conoce como infrarrojo medio (IRM) y es determinante para la detección de focos de alta temperatura.
- Infrarrojo lejano o térmico – IRT (λ de 8 a 14 μm): incluye la porción emisiva del espectro terrestre, en donde se detecta el calor proveniente de la mayor parte de las cubiertas terrestres.
- Microondas – MW (λ más de 1mm): son de gran interés por ser un tipo de energía bastante transparente a las nubes.

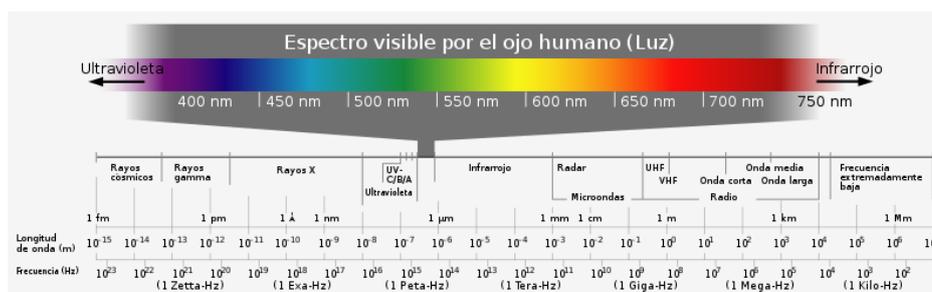


Figura 2.2: Espectro electromagnético. Ilustración obtenida de Wikipedia, autor: Horst Frank, Jailbird (2007).

Una de las características fundamentales de los sensores remotos es la capacidad de discernir objetos o detalles de un determinado tamaño en las imágenes captadas, lo que se conoce como resolución de un sensor. La elección de la resolución de los datos obtenidos por sensores remotos es crítica para la decisión sobre el tipo de imágenes a usar conforme al propósito de la investigación que se quiera llevar a cabo. La resolución de un sensor implica por lo menos cuatro manifestaciones:

- **Resolución Espacial:** indica el nivel de detalle que ofrece una imagen, determina la superficie terrestre que es representada en un pixel y se mide en metros sobre el terreno. Un pixel (*picture element*) es la menor unidad de la que está compuesta una imagen, representada por una matriz de pixeles o celdas.
- **Resolución Espectral:** es el rango de longitudes de onda en los que cada sensor es capaz de captar la energía reflejada/emitada por la superficie. En otras palabras, indica el número y ancho de las bandas espectrales que puede discriminar el sensor. Un sensor será tanto más idóneo cuanto mayor número de bandas proporcione, ya que facilita la caracterización espectral de las distintas cubiertas.
- **Resolución Temporal:** es la periodicidad con la que el sensor adquiere imágenes de la misma porción de la superficie. También se la denomina tiempo de revisita.
- **Resolución Radiométrica:** indica la sensibilidad del sensor para detectar variaciones en la radiancia espectral que recibe, expresadas en niveles digitales (ND). Así, algunos sensores pueden caracterizar 256 niveles, otros 1024, otros 65536, etc.

Las imágenes obtenidas por los satélites ofrecen una perspectiva única y particular de la Tierra, sus recursos y el impacto humano sobre ella. Los sensores remotos han demostrado ser una importante fuente de información para un gran número de aplicaciones, entre las que cabe citar la planificación urbana, vigilancia del medio ambiente, gestión y manejo de cultivos, prospección petrolífera, exploración minera, usos del suelo, localización de bienes raíces, entre otras.

2.1.1. Sensado remoto en áreas urbanas

El sensado remoto de áreas urbanas ha ido evolucionando constantemente en los últimos cincuenta años. Con los primeros mapas de cobertura de suelo urbano generados a partir de la misión Gemini y Apolo en 1965 (47), el sensado remoto urbano se basaba principalmente en la interpretación de fotografías aéreas. En 1972, el lanzamiento de Landsat-1 (originalmente llamado *Earth Resources Technology Satellite 1*), revolucionó el sensado remoto urbano y lo

hizo pasar de sensado remoto aéreo a satelital. La serie de satélites Landsat ha sido el "estándar de oro" para el sensado remoto urbano con numerosas aplicaciones (48; 49). Debido a su resolución espacial media, han permitido captar varios tipos de desarrollos urbanos y su continuidad a largo plazo. Desde 1982, la banda térmica incluida en los sensores Landsat 4–8 comenzó a proporcionar mediciones consistentes de la temperatura de la superficie terrestre, utilizadas para los estudios de islas de calor urbanas (50). En 1999, el lanzamiento de satélites comerciales de muy alta resolución espacial (0,5–5 m), como IKONOS y QuickBird ha estimulado aún más la investigación en áreas urbanas (51; 52). Estos satélites proporcionan imágenes con una resolución espacial similar a la de las fotos aéreas, de forma sistemática y con una amplia cobertura de la superficie de la Tierra. A partir del mismo año, con el lanzamiento del sensor MODIS (de resolución media), se pudieron obtener mapas globales de zonas urbanas (53).

Aunque la mayoría de los estudios de sensado remoto urbano se basan en sensores ópticos y térmicos diurnos de muy alta resolución (Very High Resolution o VHR en inglés), hay otros sensores que también proporcionan observaciones únicas de las características urbanas, como los sensores de luces nocturnas, LiDAR y RADAR. Los sensores de luces nocturnas pueden medir la luz antropogénica por la noche, que se corresponde con las extensiones urbanas y con determinadas actividades humanas (54). Además, el sistema LiDAR proporciona nuevas mediciones de las características tridimensionales de la infraestructura urbana, aunque la mayoría de los estudios se realizan a escala de ciudades (55). Los datos RADAR se han utilizado para cartografiar el crecimiento urbano desde el lanzamiento del Satélite Europeo de Sensado Remoto 1 (ERS-1) en 1991, pero la mayoría de los estudios son aplicaciones a pequeña escala. Sin embargo, con el lanzamiento de nuevos satélites RADAR en las últimas décadas (como TerraSAR-X, TanDEM-X y Sentinel-1), está surgiendo la cartografía urbana a escala continental y global (56). Además, algunos estudios recientes sugieren que los datos RADAR y ópticos son complementarios entre sí, y el uso combinado de ambos puede proporcionar resultados más precisos para la cartografía urbana (57).

A continuación, en las Tablas 2.1 y 2.2 se presentan algunos sensores de resolución espacial alta y media actuales utilizados para cartografiar áreas urbanas, obtenidos de Zhu et al. (2019) (58). La Figura 2.3 muestra dos imágenes satelitales de alta resolución espacial en zonas urbanas a modo de ejemplo.

Tabla 2.1: Ejemplos de algunos de los sensores de alta resolución.

Satélite/Sensor	Origen	Desde	Hasta	Resolución espacial
GeoEye 1	USA	2008	Activo	0.41
WorldView 2 *	USA	2009	Activo	0.46
WorldView 1 *	USA	2007	Activo	0.5
Pléiades 1A y 1B *	Francia	2011/2012	Activo	0.5
QuickBird *	USA	2001	2014	0.6
EROS B	Israel	2006	Activo	0.7
IKONOS *	USA	1999	2015	1.0
OrbView-3 *	USA	2003	2007	1.0
KOMPSAT-3	Corea del sur	2012	Activo	1.0
SPOT 6 y 7	Francia – Bélgica	2012	Activo	1.5
EROS A1	Israel	2000	2016	1.8
ZiYuan3 01-02	China	2012	Activo	2.1
C-BERS-4A *	China – Brasil	2019	Activo	2.7
RapidEye *	USA	2008	2020	5.0

*La resolución espacial corresponde al modo pancromático en metros cuadrados.

Tabla 2.2: Sensores de resolución media.

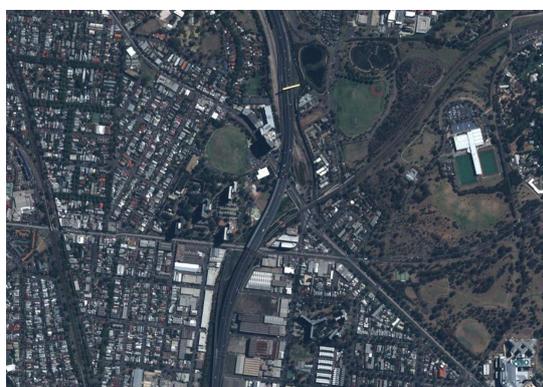
Satélite/Sensor	Origen	Desde	Hasta	Resolución espacial
RadarSat-2 **	Canadá	2007	Activo	8 / 10
Sentinel-2 **	ESA	2015	Activo	8 / 10
Landsat-7 *	USA	1999	Activo	15
Landsat-8	USA	2013	Activo	15
Terra (Aster)	USA – Japón	1999	Activo	15
Almaz-1	Rusia	1991	1992	15
JERS-1 **	Japón	1992	1998	18
ERS-2	ESA	1991	2011	20
ERS-1	ESA	1991	2011	30

*La resolución espacial corresponde al modo pancromático en metros cuadrados.

** Sensores activos del tipo RADAR.

Las zonas urbanas constituyen sistemas humano–ambientales multiespaciales acoplados. Por su propia naturaleza, los sistemas urbanos son heterogéneos y vinculan sistemas ecológicos, físicos y socio-económicos a través de escalas espaciales (59). Como tales, los esfuerzos por separarlos en varios componentes o categorías siempre serán limitados, y no es posible hacer delineaciones absolutas de lo puramente social o biofísico. Además, los entornos urbanos varían considerablemente en todo el mundo, así como dentro de determinadas ciudades o regiones urbanas (58).

Una de las principales contribuciones del sensado remoto al conocimiento de ambientes urbanos hasta la fecha ha sido la de caracterizar, medir y cartografiar las zonas urbanas de forma coherente, permitiendo obtener información de su entorno. En lugar de basarse en el tamaño o la densidad de la población, las zonas urbanas se cartografiaban en función de las características físicas de la superficie del terreno (por ejemplo, la cantidad de superficie impermeable o la superficie construida). Una de las primeras aplicaciones de datos satelitales en áreas urbanas consistió en el uso de datos multiespectrales para diferenciar la cobertura del suelo urbano de la agricultura y los bosques (60; 61), para discriminar las texturas urbanas de las zonas rurales circundantes utilizando datos RADAR (62; 63), y para estimar la población y las densidades urbanas (64; 65). Asimismo, y en paralelo a su desarrollo, los datos de sensado remoto se han utilizado ampliamente para rastrear la expansión urbana (66; 67), para determinar los factores que impulsan la demanda de suelo urbano (68) y para prever el futuro crecimiento urbano (69).



(a) Pleiades - 0.5 metros



(b) Quickbird - 0.6 metros

Figura 2.3: Imágenes satelitales de alta resolución espacial de zonas urbanas. Fuente (a): Pléiades Imagery User Guide (October 2012 – V 2.0). Fuente (b): QuickBird Satellite Image Gallery.

2.1.1.1. Técnicas de sensado remoto aplicadas en áreas urbanas

Una de las etapas iniciales en el estudio de ambientes urbanos consiste en generar mapas clasificados a partir de imágenes VHR, representando las categorías de cobertura del suelo (*Land cover* en inglés o *LC*). La mayoría de los métodos de procesamiento de imágenes desarrollados desde principios de los años 70 se basaron en clasificaciones de píxeles individuales utilizando el concepto de un espacio de características multidimensional (70). Estas metodologías basadas en píxeles utilizan la información espectral almacenada en las bandas de la imagen y clasifican dichos píxeles en función de las similitudes espectrales con las clases de cobertura del suelo predefinidas (71). Si bien estas técnicas están bien desarrolladas y tienen variantes sofisticadas, como clasificadores suaves (*soft classifiers*), clasificadores sub-píxel y técnicas de mezcla espectral, se reconoce que tienen limitaciones y no alcanzan resultados precisos cuando se trabaja con imágenes de muy alta resolución espacial (por ejemplo, (72)).

Los nuevos sensores de alta resolución aumentan significativamente la variabilidad espectral dentro de las clases y, por lo tanto, disminuyen la precisión potencial de un enfoque de clasificación puramente basado en píxeles. Una vez que la resolución espacial es más fina que el objeto de interés típico (por ejemplo, árboles individuales, masas forestales, campos agrícolas, etc.) los objetos se componen de muchos píxeles y es conveniente considerar los patrones espaciales que se crean, en lugar de analizar estadísticamente los píxeles individuales (73; 74; 75). La Figura 2.4 presenta de forma esquemática la relación entre la resolución espacial y el objeto considerado (obtenida de Blaschke T. (2010) (76)).

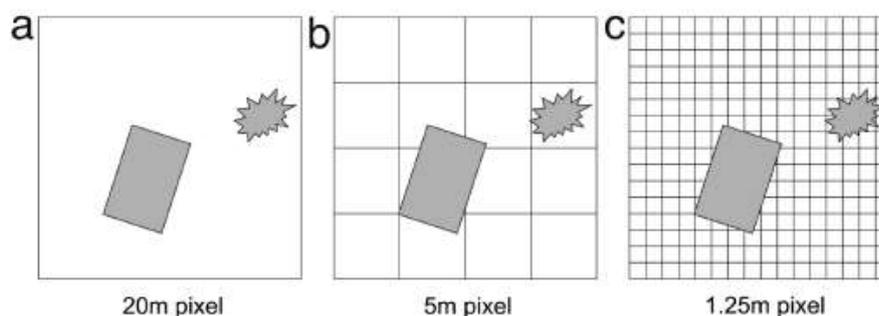


Figura 2.4: Relación entre los objetos considerados y la resolución espacial: (a) baja resolución: los píxeles son significativamente mayores que los objetos, se necesitan técnicas de sub-píxeles. (b) resolución media: los tamaños de los píxeles y de los objetos son del mismo orden, las técnicas píxel a píxel son adecuadas. (c) alta resolución: los píxeles son significativamente más pequeños que los objetos, se necesita la regionalización de los píxeles en grupos de píxeles y finalmente de objetos.

El análisis de imágenes basado en objetos geográficos (GEOBIA) (77; 76) resulta una técnica que puede ayudar a superar los problemas mencionados cuando se trabaja con imágenes VHR. GEOBIA es un modelo no supervisado que detecta objetos mediante la agrupación de píxeles similares en un mismo segmento (i.e., objeto). Esta técnica utiliza segmentos en lugar de píxeles como unidad de procesamiento.

La cartografía de la cobertura y el uso del suelo con GEOBIA se ha demostrado en contextos de sensado remoto agrícola, forestal, urbano y de riesgos naturales, entre otros (78). GEOBIA funciona generalmente organizando una imagen en objetos (grupos de píxeles vecinos que representan objetos geográficos del mundo real) y examinando esos objetos según sus características espectrales, texturales, geométricas y contextuales (79). Luego, estas características se utilizan para clasificar las imágenes, es decir, para etiquetarlas según el objeto geográfico que representan, que puede ser una clase de cobertura/uso del suelo (por ejemplo, urbano) o una categoría de objeto (por ejemplo, construcciones, arboles).

2.2. Mosquitos urbanos de importancia epidemiológica

Los ambientes urbanos ofrecen una amplia variedad de potenciales focos de cría de mosquitos. En nuestro continente, el principal vector urbano es *Aedes aegypti*, que fue responsable de la transmisión urbana en América de la Fiebre Amarilla a fines del siglo XIX y principios del XX (80).

Ae. aegypti (Figura 2.5) es una especie originaria de África Occidental que fue introducida en América con la primera llegada de los europeos (81). Es un mosquito de hábitos domésticos y se lo encuentra principalmente en aglomeraciones urbanas. A principios del siglo XX *Ae. aegypti* se hallaba en casi todo el continente. Hasta la década de 1950 alcanzó una distribución mundial entre los 35° S y 45 ° N. En el año 1934, en América, se inició una intensa campaña continental de erradicación dirigida por la OPS (80) que logró restringir su distribución a Venezuela, países de Centroamérica, Caribe y sur de los Estados Unidos. En nuestro país, el vector se consideró erradicado entre las décadas de 1950 y 1960. Sin embargo, la discontinuidad en los sistemas de vigilancia condujo a una reinfestación paulatina. Desde su reaparición en 1986 en el norte del país, ha estado en constante expansión hacia el sur y el oeste. Durante la última década se ha detectado su presencia en el norte de las provincias de La Pampa y Río Negro, y el centro-sur de la provincia de Buenos Aires (82; 83). La Figura 2.6 muestra un mapa de distribución global del vector obtenido por Kraemer et al. 2015 (37).

En la actualidad, el control del vector se ha vuelto más difícil debido a la urbanización, el crecimiento de la población y la falta de aplicación de programas de vigilancia y control (84; 85). Las condiciones ambientales de los entornos con recursos limitados, como infraestructuras y saneamiento deficiente, también contribuyen al establecimiento del vector. Las intervenciones de control vectorial pueden distinguirse en métodos químicos, biológicos y ambientales (84). En cuanto a los métodos biológicos y químicos, se han revisado sistemáticamente con resultados variables (86). Las estrategias de control de vectores que pretenden reducir la cría y la proliferación de mosquitos mediante modificaciones del entorno son fundamentales. Estos métodos pueden implicar el vaciado o la destrucción de los contenedores de agua, la limpieza de los posibles lugares de cría de los vectores, la aplicación de estrategias de gestión de residuos, la realización de campañas de limpieza en la comunidad y la instalación de suministro de agua por tuberías (84). Una de las ventajas de estos enfoques es que no conllevan el riesgo de contaminación y toxicidad ambiental y no son vulnerables al desarrollo de resistencia biológica, como ocurre con muchos larvicidas (87).

2.2.1. Vigilancia entomológica de *Aedes aegypti*

Los programas de vigilancia entomológica de *Ae. aegypti* en el mundo tienen los siguientes objetivos en común: 1) determinar cambios en la distribución geográfica del mosquito, 2) obtener medidas relativas de sus poblaciones a lo largo del tiempo, 3) evaluar la cobertura y el impacto de las intervenciones anti vectoriales, y 4) monitorear la susceptibilidad y la resistencia de las poblaciones a los principales insecticidas usados en el control vectorial (88). Recientemente se incorporó la vigilancia de arbovirus en mosquitos adultos, con el objetivo de detectar oportunamente áreas de riesgo de transmisión (presencia de mosquitos infectados) desencadenando una respuesta inmediata y anticipada en la toma de decisiones para el control (88).

Existen varios métodos que se utilizan para determinar la abundancia de *Ae. aegypti* a escala local. La Tabla 2.3 resume algunos métodos de vigilancia recopilados por Barrera et al. (2016) (89). En particular, se puede destacar el método con trampas de oviposición u ovitrampas dado que es uno de los más efectivos y utilizados en los programas de vigilancia gubernamentales. Las ovitrampas aprovechan el hecho de que las hembras grávidas de *Ae. aegypti* ponen sus huevos en contenedores artificiales. Un muestreo adecuado requiere una captura regular (semanal) en lugares fijos, representativos de los tipos de hábitat presentes en la comunidad. La interpretación de los datos de las ovitrampas puede requerir precaución, porque las ovitrampas compiten con los hábitats larvarios naturales y las estimaciones de las encuestas de oviposición pueden no reflejar con precisión la abundancia de hembras grávidas en algunas condiciones. Por ejemplo, los índices de oviposición pueden estar sesgados después de las campañas de reducción de la fuente cuando las hembras grávidas encuentran menos hábitats adecuados y ponen una mayor proporción de huevos en las ovitrampas confundiendo la evaluación de los esfuerzos de control (90). Sin embargo, las ovitrampas (Figura 2.5) tienen varias ventajas, entre ellas que son baratas, se despliegan fácilmente y no son invasivas. Un pequeño número de ovitrampas suele ser suficiente para determinar la presencia del vector; menos de 100 ovitrampas pueden estimar de forma fiable la abundancia en un gran barrio urbano (91). Además, los datos de las ovitrampas son fáciles de analizar; suelen expresarse como el porcentaje de ovitrampas positivas (ovitrampas con huevos).



Figura 2.5: (a) Mosquito *Ae. aegypti* hembra alimentándose de sangre humana. Fotografía de James Gathany/CDC. (b) Ovitrapa.

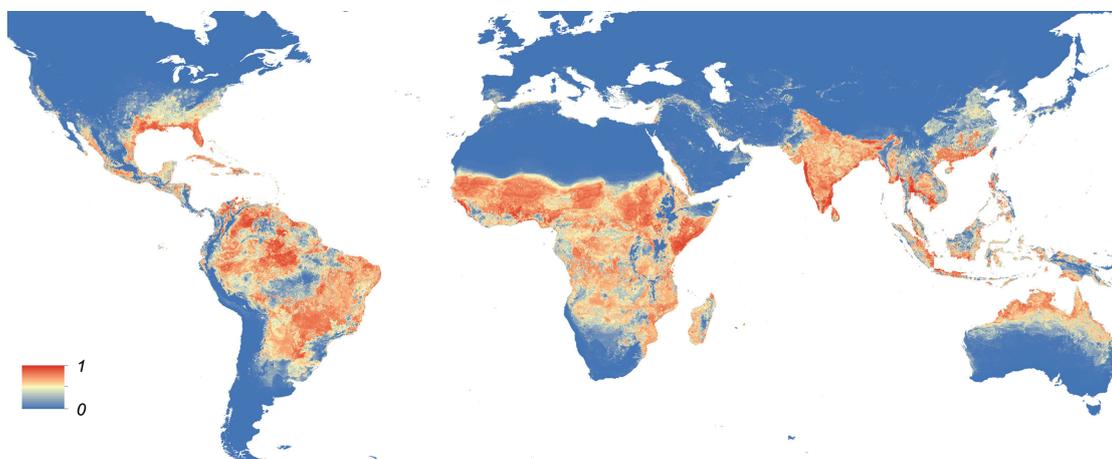


Figura 2.6: Mapa global de la distribución prevista de *Ae. aegypti*. El mapa representa la probabilidad de aparición (de 0 azul a 1 rojo) a una resolución espacial de 5 km \times 5 km. [Kraemer et al. 2015](#)

Tabla 2.3: Métodos de vigilancia de *Ae. aegypti* recopilados por Barrera et. al (2016).

Índices aedicos / larvarios	
Índice de casas	Es el porcentaje de viviendas y otras edificaciones (comercios, iglesias, etc.) donde se haya encontrado, al menos, un recipiente con fases inmaduras (recipientes positivos) comparado con el número total de casas visitadas (positivas y negativas).
Índice de recipientes	Es el porcentaje de recipientes positivos en relación con el número total de recipientes que contengan agua (con especímenes inmaduros y sin ellos).
Índice de Breteau	Es el número de recipientes positivos por cada 100 casas investigadas. También se puede calcular un índice de Breteau para cada tipo de recipiente.
Estimadores de densidad absoluta	
Muestro de pupas	El número de pupas por recipiente y por casa da una idea de la cantidad total de mosquitos. La densidad promedio por vivienda se puede extrapolar multiplicando por el número de viviendas en la localidad.
Método de marcación, liberación y recaptura de mosquitos adultos	El método consiste en marcar y liberar un lote de mosquitos adultos para luego intentar recapturarlos y determinar qué porcentaje de los individuos capturados tiene la marca.
Recolección con aspiradores de mosquitos en reposo	Debido a que la mayoría de las hembras de <i>Ae. aegypti</i> tiende a reposar dentro de las casas, el uso de aspiradores bucales o electromecánicos permite efectuar una adecuada estimación de su población por unidad de área (vivienda). Si se aspira toda la vivienda, se puede extrapolar el número de mosquitos por casa al total de viviendas en la zona de estudio.
Estimadores de densidad relativa	
Trampas de oviposición	Las ovitrampas son pequeños recipientes de metal, vidrio o plástico, generalmente de color oscuro, que contienen agua y un sustrato (madera, papel para la germinación de semillas, tela, gel vegetal) donde los mosquitos hembra ponen sus huevos. El número medio de huevos por ovitrampa puede utilizarse para estimar la abundancia de mosquitos adultos.
Hembras atraídas con cebo humano	La captura de hembras de <i>Ae. aegypti</i> en el momento de intentar picar a un humano inmóvil es un método muy sensible que revela la presencia del mosquito en el lugar y proporciona una estimación de su densidad relativa.
Trampas para mosquitos adultos	Existen varias trampas que usan un motor eléctrico y aspas para crear succión y atrapar mosquitos adultos atraídos por superficies de color oscuro o que usan sustancias químicas como atrayentes (como las trampas BG-Sentinel). Otras trampas, capturan en forma pasiva, utilizando embudos, pegamento para insectos o insecticidas. En estas trampas se usa el agua o una infusión de heno como atrayente, en forma parecida a las ovitrampas.

En Argentina, mediante la detección de la actividad de oviposición con ovitrampas y a través de la identificación de sitios de cría mediante el relevamiento de índices aélicos, se han evaluado los patrones de distribución espacial del vector a escala de microhábitat (distintos sectores dentro de cementerios), y a escala local (distintos sectores dentro de ciudades) (92). A escala de microhábitat, la presencia de inmaduros de esta especie en cementerios de Buenos Aires se asoció positivamente a sitios de cría rodeados por vegetación, y de baja exposición al sol (93; 94), así como también con una proporción menor de superficie edificada (95). A escala local, los patrones de infestación observados para el mosquito en distintas localidades estarían relacionados inversamente con el grado de urbanización. Así, en la ciudad de Buenos Aires, se observó un mayor nivel de infestación por *Ae. aegypti* en zonas periféricas, con edificaciones de baja altura, disponibilidad de recipientes para el desarrollo de inmaduros, y presencia de vegetación para resguardo de los adultos. Por el contrario, en zonas comerciales, con elevada densidad de edificios y abundante población humana, el nivel de infestación por el vector fue menor (96; 97). En la Ciudad de Córdoba, se obtuvieron resultados similares, sectores con un elevado número de huevos correspondieron a barrios residenciales con construcciones bajas y con amplias extensiones de espacios verdes (98; 31). En la ciudad de Orán (Salta), una elevada concentración de huevos de *Ae. aegypti* fue detectada en las zonas sur y centro-este, próximas a plantaciones de bananeros, gomerías, como así también al cementerio municipal (99).

En este marco, teniendo en cuenta que los patrones de distribución espacial de *Ae. aegypti* en los entornos urbanos son heterogéneos y responden a las preferencias del mismo a las diferentes condiciones de vegetación, temperatura, disponibilidad de sitios de cría, entre otros factores; la selección de sitios de colocación de ovitrampas para los programas de vigilancia debería considerar la variabilidad ambiental presente en el lugar. De esta forma, cubriendo representativamente las diferentes regiones de una ciudad, se pueden determinar los sectores de mayor preferencia del vector y, por lo tanto, concentrar los esfuerzos de monitoreo, y control cuando sea necesario, en esos lugares.

2.3. Caracterización de ambientes urbanos

2.3.1. Desde el sensado remoto

Los sensores remotos proveen de observaciones útiles para el monitoreo de las condiciones ambientales favorables para el éxito reproductivo, desarrollo, dispersión y supervivencia de vectores urbanos (92). Si bien las diferentes especies de mosquitos no pueden observarse directamente con las imágenes satelitales, los datos procedentes de sensores remotos proveen una aproximación que toma en cuenta las relaciones y las interacciones entre diferentes elementos del ecosistema, bajo el supuesto de que la dinámica poblacional es conducida por elementos ambientales tales como la temperatura, la precipitación, la humedad, la vegetación, la cobertura y el uso del suelo, así como la configuración espacial de los mismos (92).

Los índices espectrales de vegetación explotan el hecho de que la vegetación saludable tiene una reflectancia baja en el espectro visible (rojo) debido a que los pigmentos fotosintéticos en los tejidos de las plantas absorben la luz en esa longitud de onda y reflejan fuertemente en el infrarrojo cercano. El Índice Normalizado de Vegetación (NDVI) es el índice espectral de vegetación más usado para inferir parámetros ecológicos asociados a enfermedades como la Fiebre del valle de Rift (FVR) en Kenya (100), para predecir patrones espaciales y temporales

de la población de mosquitos y el riesgo de transmisión de FVR (101), en estudios de malaria en África (102), y de estructura de comunidades de mosquitos (103) entre otros. La mayoría de los estudios donde se utiliza el NDVI puntualizan en la vegetación como un recurso necesario para la supervivencia, refugio y desarrollo de los mosquitos adultos. Otro índice no tan utilizado es el NDWI, que maximiza la reflectancia del agua al utilizar longitudes de onda del verde. Este índice ha sido utilizado para identificar piscinas descuidadas, como posibles sitios de cría de mosquitos (104).

Así, las asociaciones entre las variables ambientales derivadas de satélites y los datos de presencia y/o abundancia de los mosquitos son usadas para identificar y caracterizar los diferentes hábitats de estos insectos. Investigaciones recientes en nuestro país (42; 105; 31), Estados Unidos (106; 107), y partes de África (108; 109) han utilizado imágenes de alta resolución, y a veces LIDAR, para monitorear las variables ambientales para predecir la distribución de los mosquitos y crear mapas de probabilidad. Este tipo de estudios también han demostrado cómo las mismas condiciones ambientales que causan las islas de calor urbanas pueden causar una mayor incidencia de enfermedades transmitidas por mosquitos. En Sao Paulo, por ejemplo, las islas de calor urbanas, mapeadas con datos de temperatura de la superficie terrestre, demostraron tener más casos de dengue (110). Los estudios de distribución del riesgo tienen como objetivo proporcionar a los responsables de la toma de decisiones urbanas la información que necesitan para tratar de controlar las poblaciones de mosquitos y mitigar los brotes.

Comprender los mecanismos urbanos que subyacen a la transmisión de enfermedades infecciosas es esencial para los sistemas de alerta temprana y el control. El sensado remoto ha demostrado ser una herramienta prometedora para la cartografía de barrios marginales al diferenciar entre las texturas de los entornos construidos formales e informales (111; 112). Estas contribuciones pueden ayudar a identificar comunidades para intervenciones específicas. Además de cartografiar la distribución del riesgo, el sensado remoto urbano se ha combinado con datos demográficos para comprender cómo las poblaciones humanas han interactuado con los vectores de la enfermedad, y entre sí, para influir en la progresión de la epidemia. Por ejemplo, un estudio cartografió los cambios temporales del riesgo de transmisión de la malaria en Dakar (Senegal) y descubrió que la urbanización disminuía el riesgo de transmisión de la malaria (113).

2.3.2. Desde la ecología del paisaje

Los ambientes urbanos constituyen paisajes antrópicos modificados por el hombre. Desde un enfoque ecológico, los paisajes se componen de elementos físicos, bióticos y culturales. El estudio de mismos se puede realizar a diferentes escalas, desde la de un domicilio hasta la de un continente; y en el contexto del estudio de vectores urbanos, suele ser necesario porque la dinámica de las enfermedades que transmiten es afectada por variables que operan a una variedad de escalas de paisaje (114).

En términos generales, las unidades morfológicas y estructurales que componen los paisajes están relacionadas desde un punto de vista funcional, al producirse entre ellas intercambios de energía, materiales, organismos, información, etc. En los ambientes urbanos, la sociedad es la variable ecológica dominante en la determinación de la configuración del paisaje y, en consecuencia, de las implicaciones funcionales que se generan, tanto en un momento dado como en su evolución a lo largo del tiempo (115).

El elemento base para la interpretación de los paisajes es el concepto de mosaico (*mosaic*), que está compuesto por todo un conjunto de elementos: los parches (*patches*), los corredores (*corridors*) y la matriz (*matrix*) (Figura 2.7).

Los *parches* son las diferentes unidades morfológicas que se pueden diferenciar en el territorio. Los *corredores* son las conexiones existentes entre unos fragmentos y otros. Los corredores han de facilitar la denominada *conectividad*, es decir, la capacidad de los organismos para desplazarse entre fragmentos separados de un determinado tipo de hábitat (116; 117). La *matriz* es el complejo formado por fragmentos y corredores. Desde un punto de vista funcional, una correcta interpretación de la matriz requiere de la determinación del elemento dominante. El elemento dominante es el que ocupa una mayor superficie, está mejor conectado y acaba desempeñando un papel fundamental en la dinámica del paisaje.

La diferenciación de los elementos morfológicos que componen los paisajes permite la valoración cuantitativa para analizar la situación en un momento dado, así como la evaluación de los cambios a lo largo del tiempo y su incidencia paisajística, ecológica, etc.

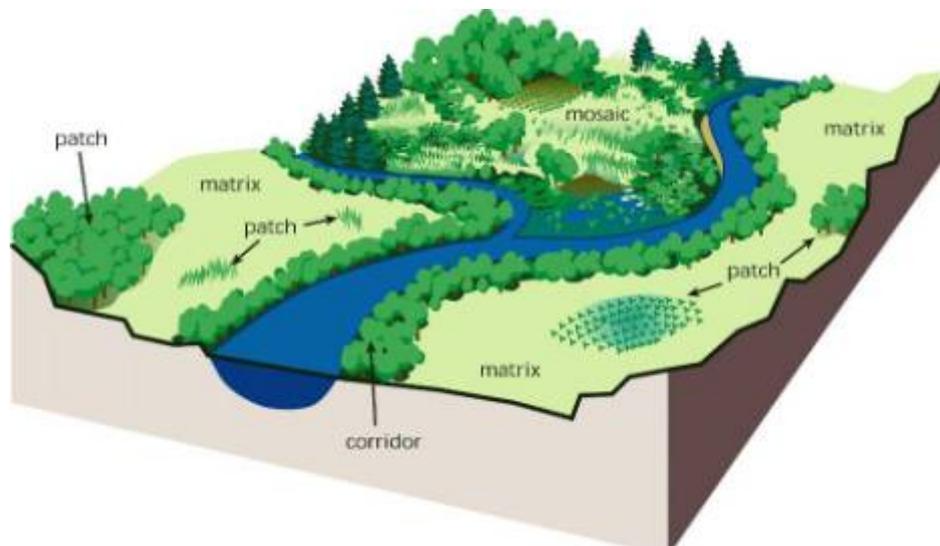


Figura 2.7: Unidades básicas en ecología del paisaje. Fuente: Arizona's Riparian Áreas.

2.3.2.1. Métricas del paisaje

La estructura de los paisajes, tanto sus propiedades de *composición* (tipos de elementos que forman parte del paisaje) como *configuración* (disposición espacial de dichos elementos), puede ser cuantificada mediante el uso de Sistemas de Información Geográfica (118) y de un conjunto de métricas o índices derivados de los principios de la ecología del paisaje (119; 120).

Estas métricas pueden aportar información, por ejemplo, sobre la proporción de un determinado uso en un paisaje o sobre la superficie ocupada por una clase de cobertura en particular (como edificios y árboles). Esta información consiste únicamente en un conjunto de valores numéricos, que por sí solos, no tienen un valor determinante. Sin embargo, desde el punto de vista de su valor comparativo, los resultados de dichos índices pueden aportar una información muy valiosa acerca de la evolución y cambios que tienen lugar en un paisaje determinado, o a la hora de comparar diferentes paisajes y diferentes parches dentro de un paisaje.

La fragmentación, forma, aislamiento, conectividad, compacidad y elongación son indicadores que se utilizan para medir las características espaciales útiles en identificar y definir las propiedades espaciales de varios tipos de paisajes (121; 122; 123), especialmente los urbanos (124). Este tipo de métricas aportan nuevas posibilidades de análisis de los patrones de ocupación (125), las formas de ocupación urbana (126), escenarios futuros (127) y modelos de simulación (128). Varios trabajos utilizaron estos índices del paisaje como un instrumento útil en la planificación y el seguimiento de los procesos de cambio del paisaje en las ciudades desde el punto de vista urbano (127; 129; 130).

En particular, Albrieu-Llinás et al. 2018 (105), utilizaron variables macro-ambientales y algunas métricas del paisaje, como el índice de diversidad de Shannon, para generar agrupamientos ambientales por barrios de la ciudad de Clorinda (Formosa) con el fin de estudiar la evolución temporal del número de casas infestadas con estados inmaduros de *Ae. aegypti*. Tomando como antecedente este estudio, y por lo anteriormente expuesto en relación a la necesidad de incluir la variabilidad ambiental en la elección de sitios de muestreo de *Ae. aegypti*, la presente tesis pretende estimar diferentes métricas del paisaje y generar agrupamientos espaciales a partir de las mismas para conocer la configuración espacial de los elementos que componen la ciudad de Córdoba y caracterizarla ambientalmente.

Clasificaciones de áreas urbanas basadas en píxeles y en objetos

3.1. Introducción

La cobertura de suelo (*Land cover* en inglés o *LC*), se refiere a las coberturas biológicas o físicas presentes sobre la superficie de la tierra (131). En particular, la información sobre la cobertura del suelo urbano tiene implicaciones significativas en el entorno que nos rodea, como los ciclos biogeoquímicos, el microclima local y la planificación urbana (132). Aunque el suelo urbano representa un porcentaje muy pequeño de la superficie terrestre (menos del 1%), concentra el 90% de las actividades económicas mundiales (133). Las áreas urbanas tienen impactos ambientales profundos que se extienden más allá de los límites de la ciudad, incluida la conversión y fragmentación de ecosistemas naturales, pérdida de tierras agrícolas, contaminación del aire, suelo y agua, y reducción de la biodiversidad. Por lo tanto, la información precisa y oportuna sobre la distribución y las características de las áreas urbanas es esencial para una amplia gama de preguntas de investigación relacionadas con el impacto de los seres humanos en el medio ambiente (134).

Tradicionalmente el mapeo de áreas urbanas se realizó a través de estudios de campo, que son muy costosos en cuanto a tiempo y mano de obra. Por lo tanto, no resulta práctico actualizar estos mapas de manera frecuente. En este sentido, los datos de sensado remoto ofrecen ventajas sobre los métodos tradicionales para cartografiar ciudades y monitorear la dinámica del uso del suelo urbano debido a su gran cobertura espacial, alta resolución temporal y amplia disponibilidad (135; 136; 137).

Cuando se extrae información sobre la cubierta del suelo urbano a partir de datos de sensores remotos, los analistas tienden a considerar que la resolución espacial es más importante que la resolución espectral. En otras palabras, es más útil tener una resolución espacial fina (es decir, un tamaño de píxel más pequeño) que una mayor resolución espectral (es decir, mayor número de bandas espectrales). Como se mencionó en el capítulo anterior, a nivel urbano local, la creciente disponibilidad de imágenes de muy alta resolución espacial (*VHR*), ha resultado en un aumento en la extracción de información del suelo urbano con detalles

espaciales más específicos (138; 139; 140). Estos datos de imágenes de resolución más fina o de mayor escala presentan niveles de detalle superiores a los de los sensores precedentes, pero este mayor nivel de detalle puede dar lugar a características urbanas complejas en el dominio espectral (141). Esto se debe a que muchos objetos pequeños se concentran en un área reducida cuando se trata de un espacio urbano, y se hacen cada vez más visibles a medida que la resolución espacial es cada vez más fina. Esta situación puede conducir a una menor precisión en la clasificación de imágenes urbanas. Esto puede no ser el caso de otros entornos, especialmente cuando se trata de otras cubiertas y usos naturales del suelo (pastizales, bosques de hoja perenne, bosques de hoja ancha, pinares manglares, humedales, paisajes desérticos y agricultura).

Existen diferentes metodologías de clasificación para generar mapas de cobertura urbana, los métodos pueden ser supervisados o no supervisados. Los métodos supervisados implican un conocimiento previo sobre el área de estudio y las clases/coberturas de interés, de modo que el algoritmo elegido extrapola las características espectrales de las clases conocidas (muestras de entrenamiento) para otras regiones de la imagen (142). La clasificación no supervisada, por su parte, tiene por objetivo agrupar los casos por su similitud espectral relativa, sin toma de muestras a campo ni conocimiento previo sobre las coberturas (143).

Los métodos tradicionales de clasificación de imágenes basados en píxeles que utilizan propiedades espectrales (144) y/o texturales (145; 146) correlacionadas con el material subyacente, se aplican con frecuencia para extraer información sobre cobertura del suelo urbano. Con estas metodologías suele ocurrir que dentro de un grupo de píxeles clasificados en una dada categoría se encuentran píxeles aislados asignados a otras clases. Este fenómeno es conocido como “sal y pimienta” y se debe a que en el criterio de asignación no se tiene en cuenta a la vecindad entre píxeles, i.e., cada píxel es considerado independientemente. Para solucionar este problema se aplican filtros post clasificación que uniformizan las clases, reasignando los píxeles aislados o poco representativos a las clases vecinas más representativas (46). Uno de los problemas que presenta esta técnica es la decisión sobre los parámetros de filtrado ya que puede obtenerse el efecto deseado en algunas zonas de la imagen, pero ser excesivo o insuficiente en otras.

Una de las principales limitaciones de la cartografía urbana en general es que muchas cubiertas de suelo urbano pueden compartir las mismas o similares respuestas espectrales (por ejemplo, calles o rutas de cemento, estacionamientos de cemento, techos de cemento y otras características superficiales brillantes de la superficie). Si el objetivo es identificar edificios y calles por separado en una imagen de alta resolución, podría preverse que los algoritmos clásicos no serían muy eficaces para realizar el trabajo, ya que muchos techos y calles están hechos de los mismos materiales (147). Por lo tanto, clasificar con precisión las categorías de suelo urbano a partir de datos de imágenes de alta resolución, continúa siendo un desafío a pesar de los importantes avances en la ciencia y la tecnología de la información geográfica (147).

Por otro lado, en los últimos años los métodos de segmentación no supervisados para dividir la imagen y realizar análisis de imágenes basado en objetos geográficos (GEOBIA) han ganado popularidad para determinar coberturas y usos del suelo a partir de imágenes satelitales. GEOBIA consiste en una técnica alternativa a los métodos de clasificación convencionales basados en píxeles, teniendo como unidad básica de análisis a objetos en lugar de píxeles individuales (79; 78; 76). Este método pretende evitar el problema de las celdas cuadradas artificiales como se usan en el método por píxel (148; 149; 76) agrupando una cantidad de píxeles en formas con una representación significativa de los objetos. Las clasificaciones convencionales basadas en píxeles presentan una ineficiente capacidad de análisis de con-

texto. Además, los píxeles de borde o mixtos, representan mezclas de dos o más tipos de coberturas. Esto constituye una de las principales causas de error de asignación y, por consecuencia, la pérdida de exactitud en la cartografía temática generada. El objetivo de OBIA es abordar clases más complejas que se definen por relaciones espaciales y jerárquicas dentro y durante el proceso de clasificación (150), permitiendo explotar gran parte de las dimensiones contenidas en las imágenes, incluyendo aspectos espectrales, espaciales, contextuales, morfológicos y temporales (73). Este tipo de clasificaciones requiere un nivel de procesamiento que resulta más complejo ya que presenta una mayor demanda computacional que los clasificadores por píxel (151). La mayor demanda computacional esta dada principalmente por el paso inicial de la segmentación y en especial, su optimización (152).

En Córdoba, se han generado numerosos mapas de cobertura de suelo evaluando diferentes métodos de clasificación enfocados principalmente en la identificación de zonas agrícolas (153; 154). En particular, Mudele et al. (155) obtuvieron un mapa de vegetación urbana para la Ciudad de Córdoba con imágenes Sentinel-2 basado en la clasificación de píxeles del índice de Vector Espectral de Diferencia Normalizada (*Normalized Difference Spectral Vector* en inglés o *NDSV*), evaluando la precisión de diferentes clasificadores como Random forest (*RF*), árboles de clasificación y regresión (*CART*) y máquinas de soporte de vectores (*SVM*). En este contexto, como primer objetivo de esta tesis se propone evaluar y comparar las aproximaciones de clasificación basadas en píxeles y en objetos para obtener mapas de cobertura urbana para la ciudad de Córdoba a partir de técnicas de aprendizaje automático y una imagen de muy alta resolución espacial.

3.2. Materiales y métodos

3.2.1. Área de estudio

El área de estudio correspondió a la Ciudad de Córdoba capital, de la provincia homónima ubicada en el centro del país. La misma tiene más de 1.300.000 habitantes y una densidad de 2.300 hab/km², cifras que la ubican en el segundo lugar de las ciudades argentinas, detrás de Buenos Aires (156). Tiene una superficie de 576 km² y está ubicada a 31°24' S, 64°11' O, y una elevación de \approx 450 m.s.n.m. (Figura 3.1).

El área urbana representa alrededor del 37% de la superficie de la ciudad, que está rodeada de campos agrícolas y parches de bosque muy pequeños. Para el presente estudio, se trabajó con una máscara urbana para delimitar las zonas de interés, excluyendo los campos agrícolas (ver en sección 3.2.3.2). La ciudad de Córdoba tiene un clima templado, con una temperatura media anual de 17,3 ° C y precipitación media anual de 750-800 mm (157). El invierno es marcadamente seco y la mayor parte de la precipitación ocurre en los meses de verano.

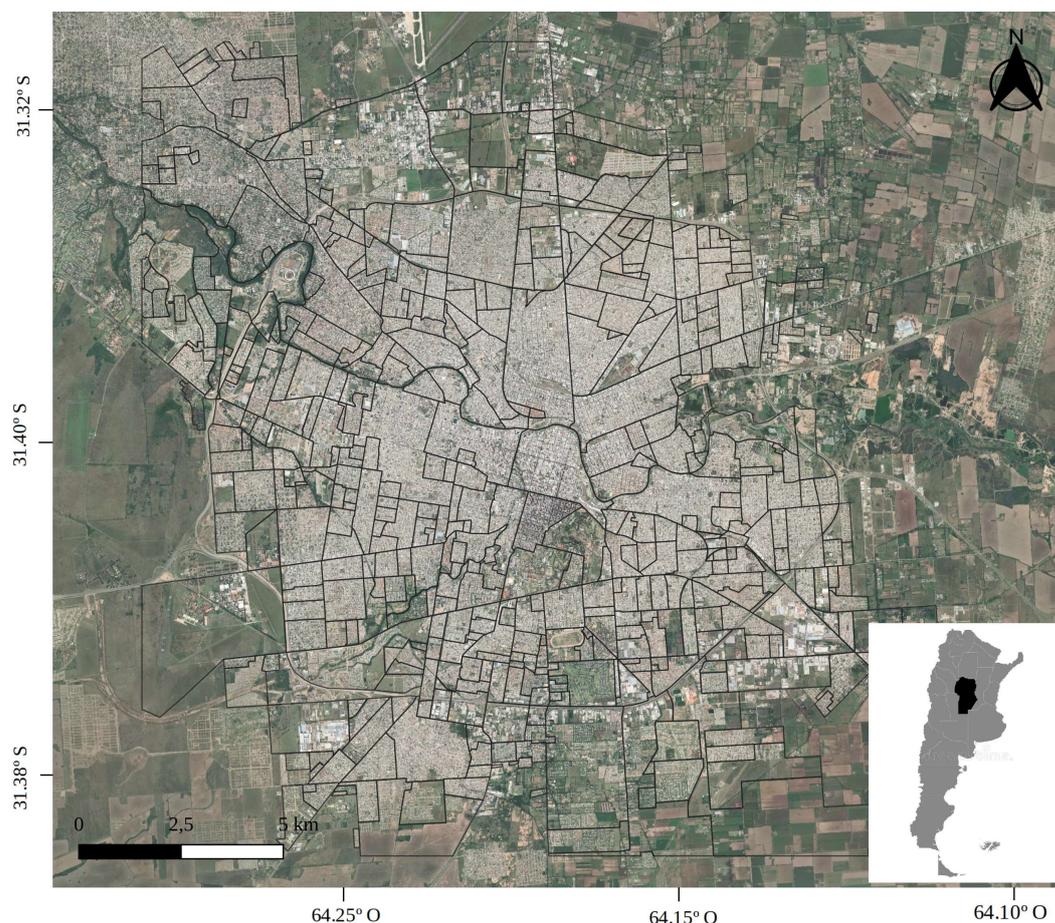


Figura 3.1: Área de estudio en la ciudad de Córdoba (Argentina).

3.2.2. Imagen satelital

Se trabajó con una imagen satelital de alta resolución de la constelación multispectral Pléiades adquirida por CONAE. La imagen fue obtenida el 12 febrero de 2017 y cubre la ciudad de Córdoba. Las imágenes Pléiades consisten en cuatro bandas multispectrales (tres visibles y una en el infrarrojo cercano) con una resolución espacial de 2 m y una banda pancromática con una resolución espacial de 50 cm (ver detalle en la Figura 3.2 y Tabla 3.1).

Tabla 3.1: Bandas espectrales del satélite Pléiades.

Satélite	Pléiades 1A	
Bandas espectrales	Pancromática	470-830 nm
	B0 - Azul	430 – 550 nm
	B1 - Verde	500 – 620 nm
	B2 - Rojo	590 – 710 nm
	B3 - Infrarrojo cercano	740 – 940 nm

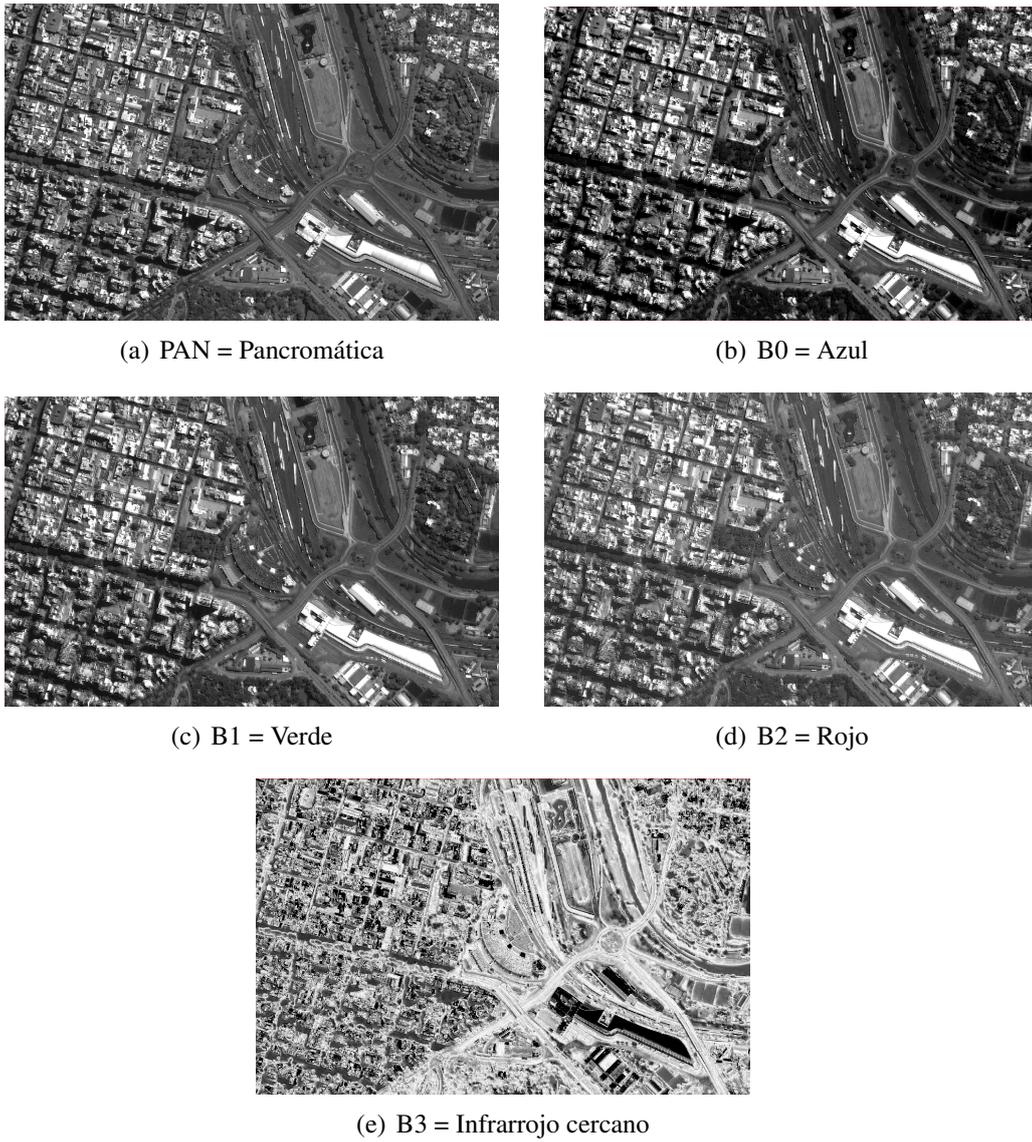


Figura 3.2: Detalle de bandas espectrales del satélite Pléiades en una región de la Ciudad de Córdoba.

3.2.3. Pre-procesamiento

Las bandas de la imagen Pléiades fueron preprocesadas a reflectancia de superficie con el módulo *i.atcorr* (158) del software GRASS GIS 7.8.5 (159). Posteriormente, se realizó un pansharpening o refinado pancromático, utilizando como referencia la banda pancromática de alta resolución. Esta técnica permite combinar la información visual de los datos multispectrales con la información espacial de los datos pancromáticos, dando como resultado un producto de color de 50 cm de resolución (160). La Figura 3.3 muestra un detalle de las bandas multispectrales antes y después del proceso. Para aplicar este método se utilizó el módulo *i.fusion.hpf* (161), basado en la técnica *High-Pass Filter Addition (HPFA)* (162). En la Figura 3.4 se detalla el flujo de trabajo para el pre-procesamiento.

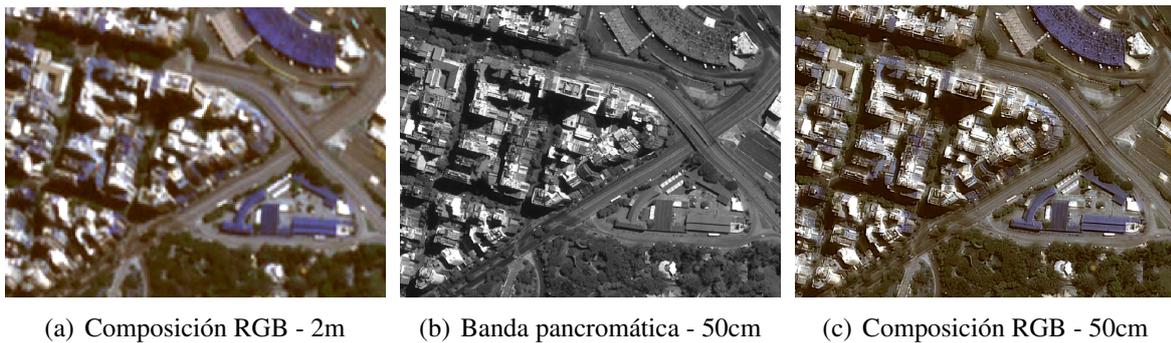


Figura 3.3: Zoom de bandas multispectrales y pancromática de Pléiades antes y después del pansharpening.

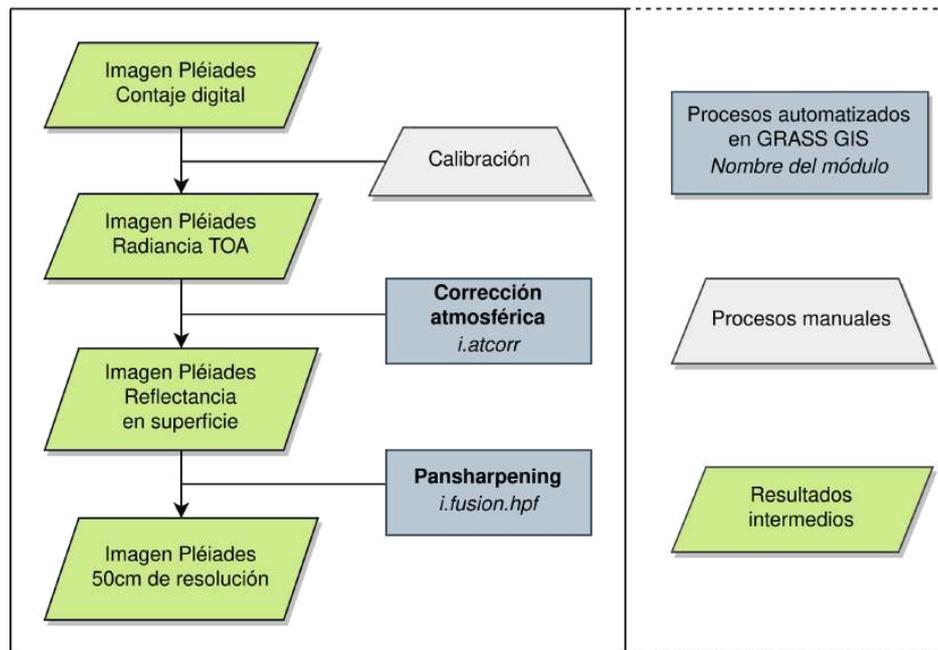


Figura 3.4: Flujo de trabajo para el pre-procesamiento de la imagen Pléiades.

3.2.3.1. Cálculo de índices espectrales y texturales

Para incorporar información espectral adicional a las bandas del satélite en las clasificaciones, se calcularon los Índices de Vegetación (NDVI) (Figura 3.5(a)) y de Agua de Diferencia

Normalizada (NDWI) (Figura 3.5(b)). Además, se calcularon trece índices texturales disponibles en el módulo *r.texture.tiled* (163) de GRASS GIS que utiliza un modelo de textura común basado en la matriz de co-ocurrencia de nivel de gris descrita por Haralick et al. (1973) (citado por (164)). La textura es una característica de las clases específicas de cobertura del suelo en imágenes satelitales. Es particularmente útil en situaciones en las que las diferencias espectrales entre clases son pequeñas, y las mismas se distinguen por su organización sobre el terreno. La figura 3.5 muestra un detalle de los índices generados.

Se calcularon las siguientes medidas de textura:

- Suma Promedio (SA) (Figura 3.5(c)).
- Entropía (Entr): Esta medida analiza la aleatoriedad. Es alta cuando los valores de la ventana en movimiento son disímiles. Es baja, cuando los valores están cerca de 0 o 1, es decir, cuando los píxeles de la ventana local son uniformes (Figura 3.5(d)).
- Diferencia de Entropía (DE) (Figura 3.5(e)).
- Suma de Entropía (SE) (Figura 3.5(f)).
- Varianza (VAR): Una medida de la variación del tono gris dentro de la ventana en movimiento (Figura 3.5(g)).
- Diferencia de Varianza (DV) (Figura 3.5(h)).
- Suma de Varianza (SV) (Figura 3.5(i)).
- Momento Angular (ASM, también llamado Uniformidad): Medida de la homogeneidad local, opuesta de la Entropía. Los valores altos de ASM ocurren cuando los píxeles en la ventana en movimiento son muy similares (Figura 3.5(j)).
- Momento de Diferencia Inversa (IDM, también llamado Homogeneidad): Esta medida se relaciona inversamente con la medida de contraste. Es una medida directa de la homogeneidad local de una imagen digital. Los valores bajos se asocian a una baja homogeneidad y viceversa (Figura 3.5(k)).
- Contraste (Contr): Esta medida analiza el contraste de la imagen (variaciones locales del nivel de gris) como la dependencia lineal de los niveles de gris de los píxeles vecinos (similitud). Típicamente alta, cuando la escala de la textura local es mayor que la distancia (Figura 3.5(l)).
- Correlación (Corr): Esta medida analiza la dependencia lineal de los niveles de gris de los píxeles vecinos. Típicamente alta, cuando la escala de la textura local es mayor que la distancia (Figura 3.5(m)).
- Medidas de información de correlación (MOC-1 y MOC-2) (Figuras 3.5(n) y 3.5(ñ)).

3.2.3.2. Máscara de cobertura urbana

Con el fin de delimitar la zona urbana de interés y discriminarla de las regiones periurbanas con cultivos agrícolas y hortícolas que pudieran generar ruido en la clasificación y confusión con las clases de vegetación urbana, se trabajó con una máscara de cobertura urbana generada por Marinelli en (154) a partir del cálculo de *brillo* de las bandas *RGB* de Sentinel-2 y la binarización del producto con un umbral determinado para las construcciones.

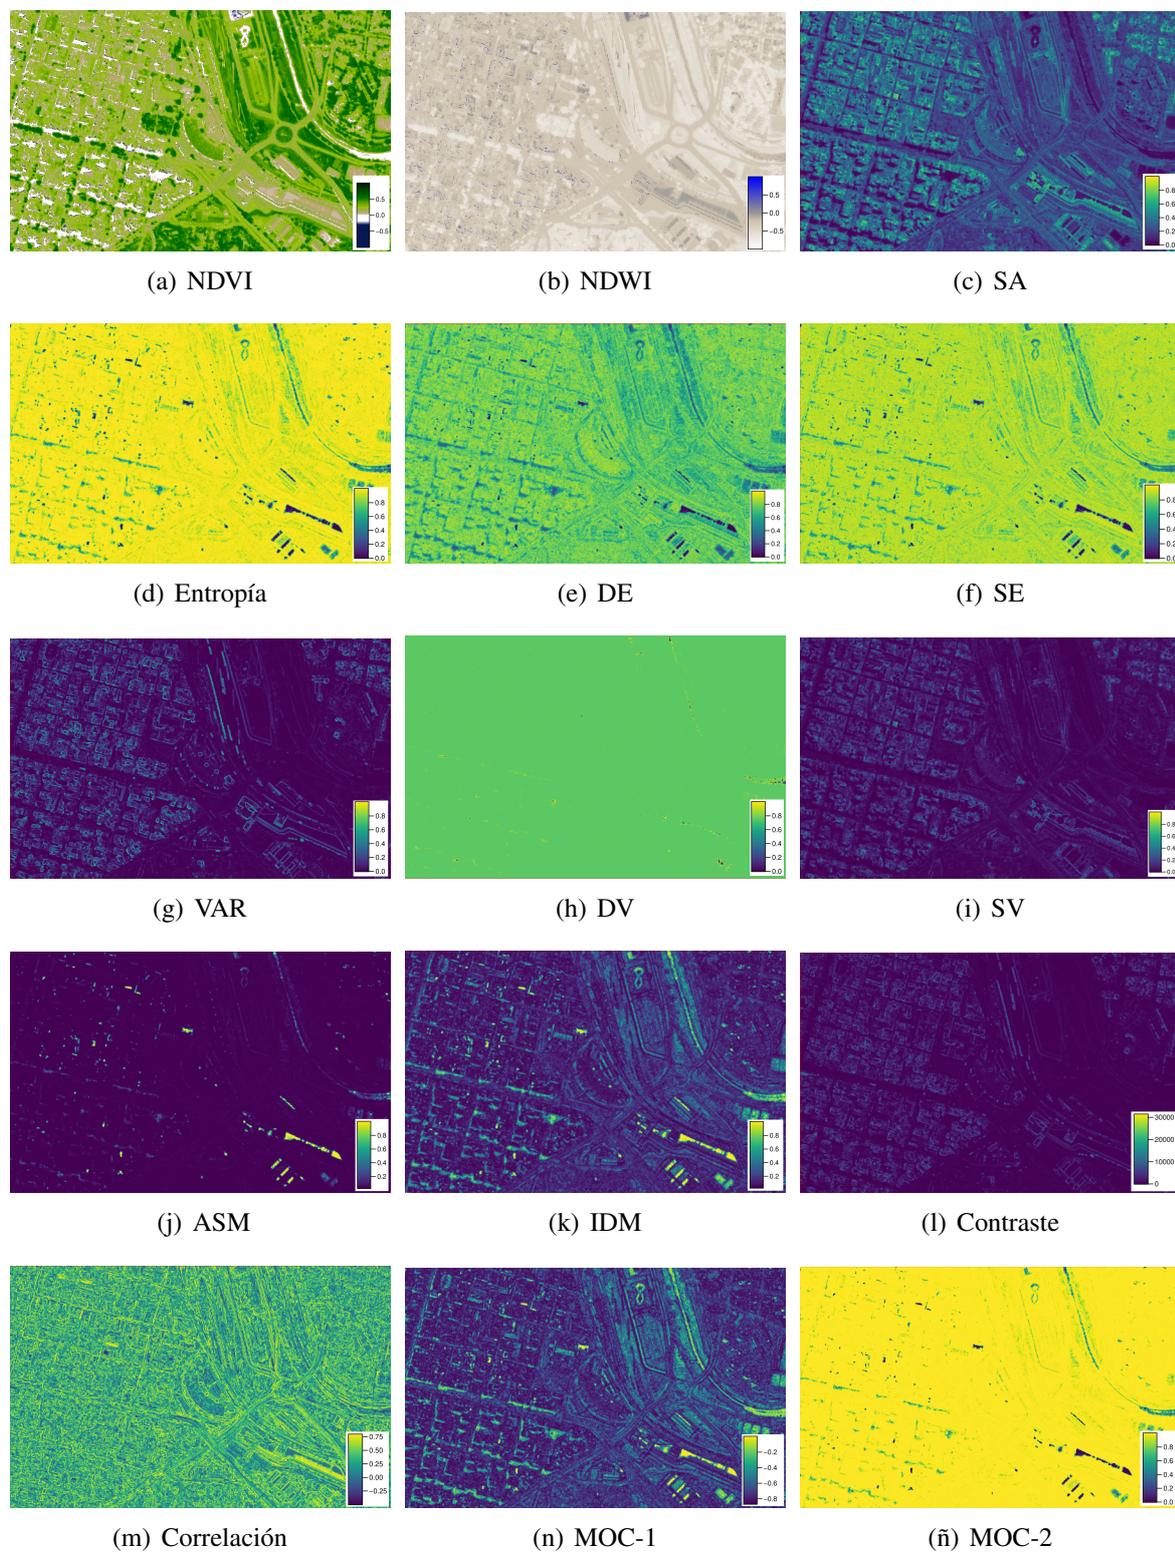


Figura 3.5: Detalle de índices espectrales y texturales generados.

3.2.4. Definición de verdad de campo (VC) y clases de cobertura del suelo

Se realizó la georreferenciación de 3500 puntos de cobertura de suelo como verdad de campo. Los puntos se digitalizaron y procesaron en QGIS 3.20 (165). Se eligieron siete clases de cobertura del suelo: Vegetación alta, Vegetación baja, Agua, Construcciones, Superficies asfaltadas, Suelo desnudo y Sombras (Figura 3.6). La tabla 3.2 resume la cantidad de muestras registradas para cada clase.

Tabla 3.2: Verdad de campo y clases de cobertura del suelo.

Clase	Descripción	Puntos de referencia
1	Vegetación alta	594
2	Vegetación baja	565
3	Agua	248
4	Construcciones	725
5	Superficies asfaltadas	675
6	Suelo desnudo	123
7	Sombras	570
Total:		3500

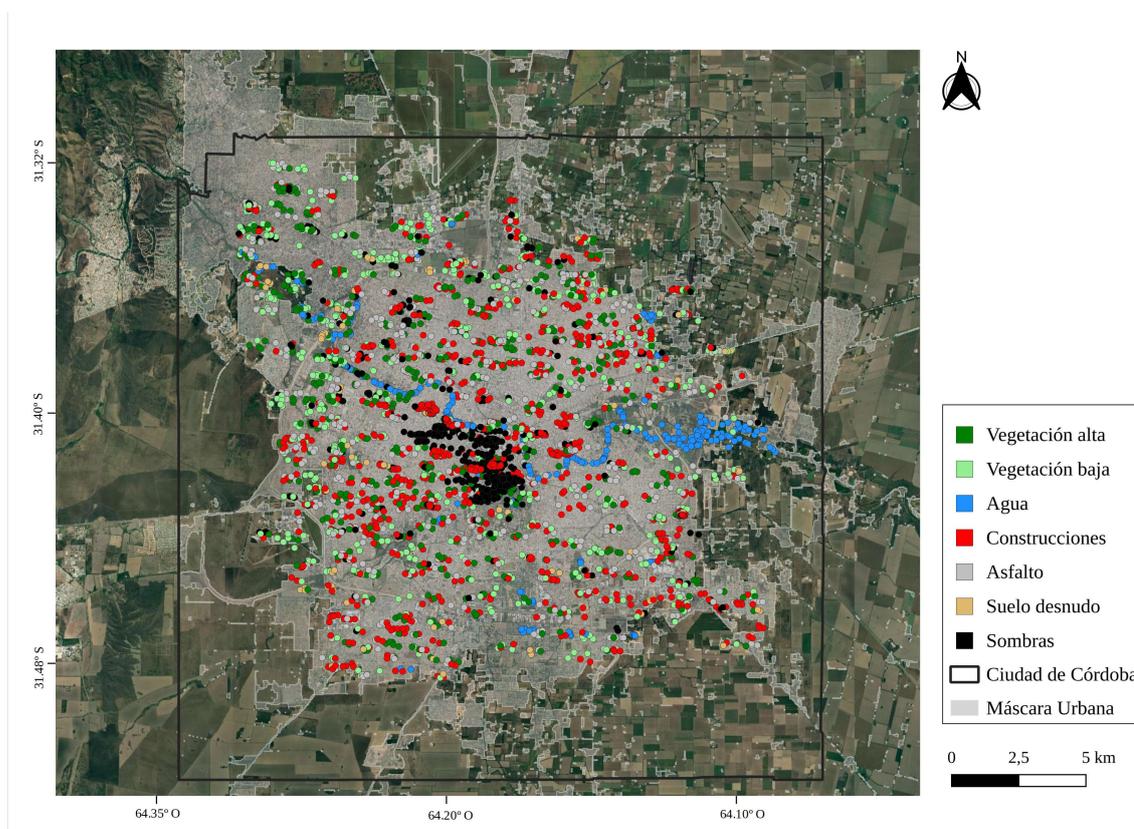


Figura 3.6: Mapa de la ciudad de Córdoba con puntos de verdad de campo.

3.2.5. Algoritmo de clasificación

Se utilizó el algoritmo de clasificación supervisada *Random Forest* (RF) (166), ampliamente utilizado en aplicaciones de sensado remoto debido a la precisión de sus clasificaciones (167; 168; 169; 170). RF es un algoritmo de aprendizaje automático que ajusta iterativamente modelos de árbol de decisión a subconjuntos aleatorios de los datos de entrada y utiliza el resultado combinado para la predicción (171). Es decir, un modelo RF está formado por un conjunto de árboles de decisión individuales, cada uno entrenado con una muestra ligeramente distinta de los datos de entrenamiento generada mediante validación cruzada, k -iteraciones. La predicción de una nueva observación se obtiene agregando las predicciones de todos los árboles individuales que forman el modelo.

3.2.5.1. Clasificación basada en píxeles

Para la clasificación a nivel de píxeles se utilizó el módulo *ee.Classifier.smileRandomForest* del software Google Earth Engine (172). Se utilizaron 200 árboles de decisión y se dividió el conjunto de 3500 píxeles de verdad de campo en 80% como datos de entrenamiento y 20% de validación para evaluar la precisión de la clasificación (ver sección 3.2.6). En el Anexo A.1 se muestra el código en Java implementado para dicha clasificación.

3.2.5.2. Clasificación basada en objetos

GEOBIA se compone de tres etapas principales: (1) segmentación de imágenes, (2) extracción y caracterización de segmentos y (3) clasificación de segmentos. El paso más básico y crítico es la segmentación de imágenes (173; 174; 175); de modo que la precisión de las siguientes etapas depende principalmente de la calidad de la segmentación inicial o delimitación de los objetos de interés (176; 177). A continuación se detalla y describe cada uno de los pasos que se siguieron utilizando el software libre GRASS GIS, teniendo como referencia la propuesta de trabajo de Grippa et al. (178). La Figura 3.9 muestra un esquema del flujo de trabajo implementado. En el Anexo A.2 se muestra el código en *bash* implementado para cada etapa de la clasificación basada en objetos.

Primer etapa: Segmentación

La segmentación de imágenes implica subdividir una imagen en regiones homogéneas (179) que idealmente representan objetos de interés del mundo real, como edificios, árboles, cuerpos de agua y sombras (180; 181). Los segmentos son regiones que se generan por uno o más criterios de homogeneidad en una o más dimensiones (del espacio de una imagen). El espacio n -dimensional sobre el que opera la segmentación está conformado por propiedades específicas tales como la información espectral (color, o *gray level*), texturas, forma, tamaño y topología. La segmentación debe buscar (a) la uniformidad de objetos individuales (homogeneidad intra-segmentos) y (b) una diferencia significativa entre objetos adyacentes (heterogeneidad inter-segmentos) y éstas pueden ser medidas para evaluar y optimizar la segmentación (182).

En la literatura se ha categorizado los diferentes algoritmos de segmentación como: (a) basados en bordes (183), (b) basados en regiones (184), (c) métodos híbridos (185) y (d) métodos semánticos. Para esta tesis se utilizaron tres algoritmos de segmentación: primero uno basado en bordes para la generación de mosaicos: *Canny* (186), luego uno basado en el método *k-means* para la generación de semillas: *i.superpixels.slic* (187), y por último uno basado en regiones para la segmentación de cada mosaico o *tile*: *i.segment*.

a. Generación de mosaicos

Para esta tesis se utilizó el algoritmo de segmentación *Canny* (186) del módulo [i.cutlines](#) (188) para dividir a la imagen en *mosaicos* y generar una macro-segmentación previo a la segmentación final (Figura 3.7). Estos algoritmos primero identifican bordes y luego los unen usando algoritmos de contorno. Asumen que entre los bordes, las propiedades de los píxeles cambian abruptamente. Esos bordes se consideran como límites entre objetos. Según (189) la detección de bordes requiere tres pasos: filtrado (reduce el desenfoque y desplazamiento de los bordes), realce (acentúa los píxeles donde la intensidad cambia, así como lo hace un filtro de bordes) y detección (une los bordes, cierra los límites, elimina los bordes ruidosos).



Figura 3.7: Detalle de mosaicos generados con el algoritmo *Canny* para la imagen Pléiades.

La generación de *mosaicos* como etapa previa a la segmentación tiene como objetivo generar zonas donde se encontrarán distintas morfologías de objetos, por eso también se llama segmentación en zonas morfológicas. La principal ventaja consiste en reducir el área de estudio al momento de realizar la segmentación, permitiendo definir parámetros específicos para cada mosaico generado en áreas reducidas en lugar de elegir un único set de parámetros, lo cual puede mejorar considerablemente el resultado de la segmentación. Además, generando mosaicos se puede paralelizar el proceso de segmentación posterior y reducir el tiempo de procesamiento (152).

b. Parámetros de los algoritmos de segmentación por tile

Los algoritmos de segmentación precisan ciertos parámetros que deben ser suministrados por la/el usuaria/o. La calidad de la segmentación resultante depende de la elección de los mismos. Los parámetros generales son: tamaño mínimo de objeto y umbral de similitud. El *tamaño mínimo* de objeto, es el número de píxeles mínimo de los segmentos. El *umbral* es un valor de similitud entre segmentos que se utiliza para determinar qué objetos (i.e., segmentos) se fusionan. El valor de *umbral* da cuenta de una distancia (Euclídea o Manhattan) en el espacio n-dimensional de características de los segmentos (ej. valores radiométricos). Los valores de distancia más pequeños indican una coincidencia más cercana, con una puntuación de similitud de cero para píxeles idénticos. Durante el procesamiento normal, las combinaciones sólo se permiten cuando la similitud entre dos segmentos es inferior al valor de umbral dado. Sin embargo,

durante la última iteración, los objetos con un número de píxeles menor al tamaño mínimo, se fusionaron con su vecino más similar, incluso si son más disímiles que lo permitido por el umbral (190; 191). El *umbral* debe ser mayor que 0 y menor que 1. Un umbral de 0 permitiría que solo se fusionaran píxeles de valor idéntico, mientras que un umbral de 1 permitiría que todo se fusionara (190).

Por lo general, la selección de los parámetros de segmentación se lleva a cabo mediante un enfoque de "prueba y error" que se basa en la evaluación visual de varios resultados de segmentación y el ajuste gradual de los parámetros. Este método presenta las desventajas de ser subjetivo, tedioso y requerir mucho tiempo. No obstante, existen métodos de optimización que se basan en las medidas descriptas anteriormente de homogeneidad intra-segmento y heterogeneidad inter-segmentos.

Para esta tesis, se utilizó el método de optimización de parámetros de segmentación no supervisada con el módulo *i.segment.uspo* (192) del software GRASS GIS propuesto por (178) para cada mosaico generado en la etapa anterior. Esta herramienta se basa en funciones de optimización que combinan medidas de varianza intra-objeto ponderadas por el tamaño del objeto (193) como una medida de calidad de la homogeneidad intra-segmento, y autocorrelación espacial como medida de calidad de la heterogeneidad entre segmentos (191).

El módulo ejecuta la segmentación a través de un conjunto de parámetros definidos por el usuario: los umbrales y tamaño mínimo de segmento se pueden especificar en una lista o bien, proporcionar valores de inicio, final y paso para cada uno. El valor de inicio de umbral (*start threshold* en inglés) se establece cuando se obtiene una sobre-segmentación (comparada a la deseada, Figura 3.8(a)), y el valor de parada de umbral (*stop threshold* en inglés) se define cuando se genera una sub-segmentación (objetos de distinta clase en un mismo segmento, Figura 3.8(b)). Las pruebas empíricas se siguieron bajo las sugerencias de Momsen (190) que recomienda iniciar con un valor bajo (ej. 0,01) para el umbral. El tamaño mínimo de objeto se estableció teniendo en cuenta el tamaño mínimo de objeto que se pretendió identificar (en este caso, arboles y/o arbustos \simeq 12 píxeles).

Con el fin de reducir la cantidad de píxeles y acelerar el procesamiento del módulo, previamente se agruparon los píxeles similares con el algoritmo de segmentación *i.superpixels.slic* (187), para generar semillas (objetos pequeños), definiendo una compactación de 0,7 y un paso de 0,2, equivalente a la distancia entre los centros de superpíxeles iniciales.

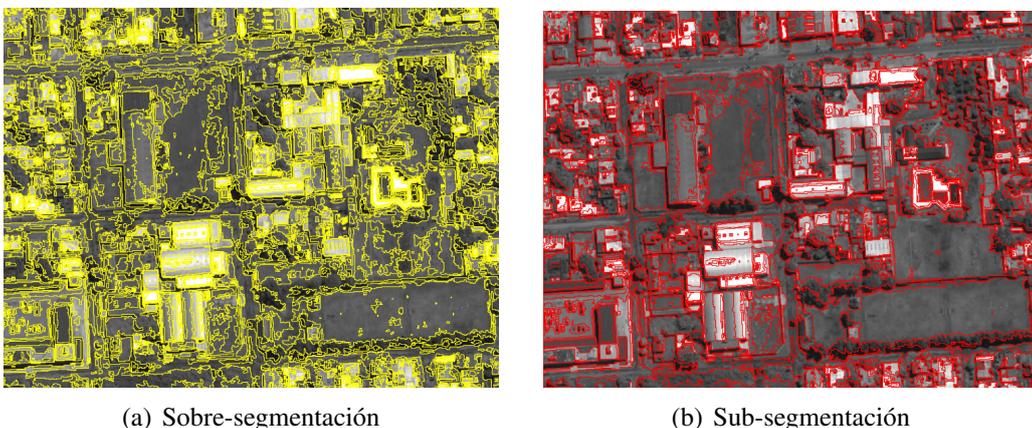


Figura 3.8: Detalle de segmentaciones obtenidas variando el valor de *umbral* de similitud.

Segunda etapa: Caracterización de segmentos

Una vez obtenida la segmentación óptima, las estadísticas de los objetos se calcularon utilizando el complemento [i.segment.stats](#) (194). Esta herramienta calcula tanto las estadísticas espectrales como las estadísticas morfológicas de los objetos. Para acelerar el procesamiento se calcularon las estadísticas de los segmentos para cada mosaico por separado. Se calcularon medidas morfológicas de tamaño y forma: área, perímetro, compacidad en comparación a un cuadrado, compacidad en comparación a un círculo y dimensión fractal. Además, se extrajeron estadísticos de todos los datos espectrales y texturales mencionados en la sección 3.2.2 tales como: mínimo, máximo, rango, media, desvío estándar, mediana, primer cuartil, tercer cuartil y percentil 90. Dichas estadísticas se utilizaron como características en el proceso de clasificación.

Tercer etapa: Clasificación de segmentos

Para la etapa de clasificación se utilizó el complemento [v.class.mlR](#) (195). Este complemento se basa en la utilización de la biblioteca *caret* del software R (196), y permite la clasificación de datos usando diferentes clasificadores como *Support Vector Machine* (SVM), *Random Forest* (RF), *Partición recursiva* (Rpart) y *Clasificadores k-Vecinos más cercanos* (kNN). El mismo ajusta automáticamente los parámetros de los clasificadores mediante la validación cruzada repetida. *Caret* determina automáticamente un conjunto razonable de valores para el ajuste. De forma predeterminada, el módulo crea 10 particiones para la validación cruzada y prueba 10 valores posibles de los parámetros de ajuste. Estos valores se pueden cambiar utilizando, respectivamente, los parámetros de particiones (*partitions*), pliegues (*folds*) y longitud de ajuste (*tunelength*). Las predicciones de clasificadores individuales luego se combinan usando varios tipos de voto mayoritario (*weighting_mode*): voto de mayoría simple sin ponderación, es decir, todos los pesos son iguales (*smv*), voto de mayoría simple ponderada (*swv*), voto mejor-peor ponderado (*bwwv*) y voto mejor-peor cuadrático ponderado (*qbwwv*).

Para esta tesis, al igual que para la clasificación basada en píxeles, se utilizó el modelo de clasificación no paramétrico RF. Como verdad de campo, se extrajo la información de los 3500 puntos georreferenciados (detallados en 3.2.4) y se cubrieron los segmentos caracterizados, para obtener una nueva capa de segmentos categorizados con cada clase. Posteriormente, se dividió el conjunto de segmentos categorizados en 70% para el entrenamiento y 30% para la validación. Con los datos de entrenamiento se generó el modelo de clasificación y posteriormente, se realizó la predicción para cada mosaico inicial con dicho modelo.

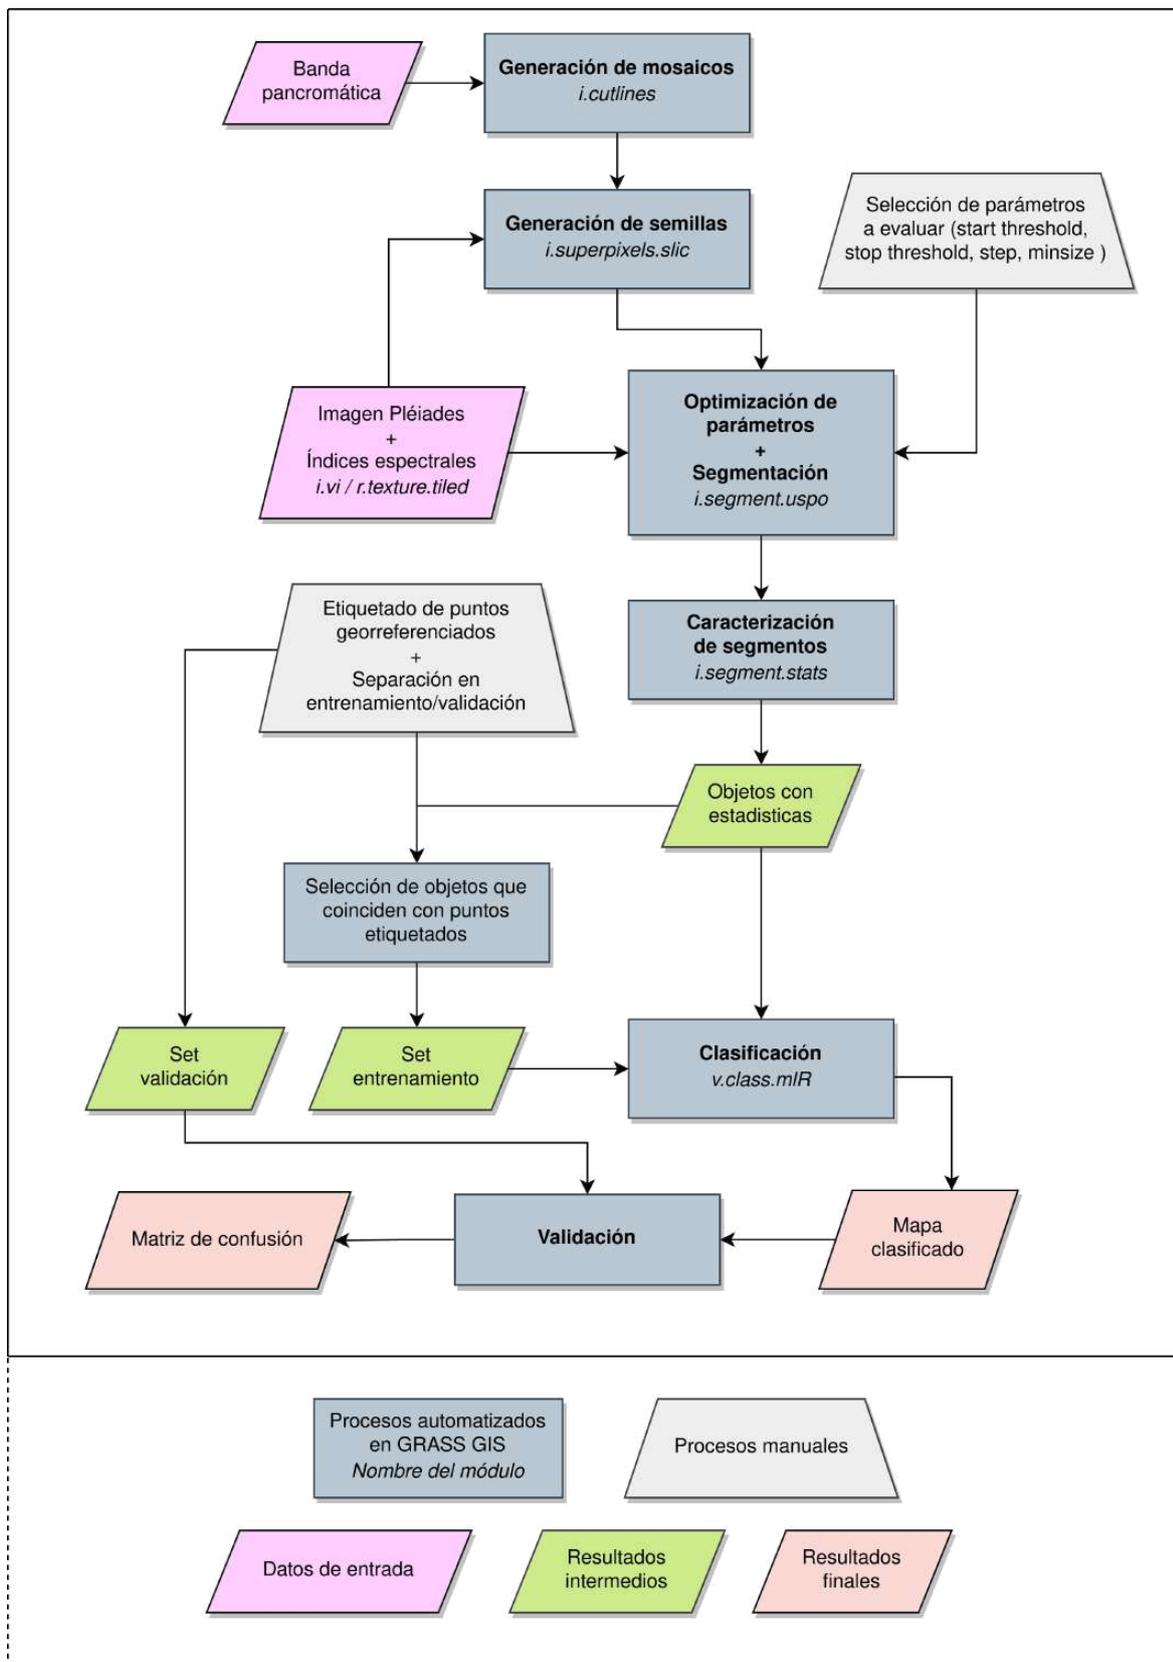


Figura 3.9: Flujo de trabajo para clasificación basada en objetos.

3.2.6. Evaluación de la precisión de las clasificaciones

Para determinar la exactitud de los mapas resultantes, se utilizaron matrices de confusión y se calcularon la Precisión Global (OA por sus siglas en inglés *Overall Accuracy*) y el coeficiente Kappa (κ). La precisión global OA, se calcula con los píxeles correctamente clasificados sobre el total de datos de validación (píxeles). Sus valores se encuentran en el intervalo [0, 1], siendo la clasificación mejor cuanto más se acerque a la unidad (197). El índice de Kappa calcula el acuerdo entre la imagen clasificada y la verdad del terreno, debido únicamente a la exactitud de la clasificación, suprimiendo el acuerdo que cabría esperar simplemente por casualidad (198). Para evaluar la precisión de este último índice se tuvo en cuenta la escala de interpretación propuesta por Monserud et al. (198) (Tabla 3.3).

Además, se calcularon índices por clase como la precisión del productor (PP) y la precisión del usuario (PU) (197). El índice PP calcula la frecuencia con la que las características reales sobre el terreno se muestran correctamente en el mapa clasificado o la probabilidad de que una determinada cobertura del suelo sobre el terreno se clasifique como tal. La precisión del Productor es el complemento del Error de Omisión. $PP = 100\% - \text{Error de Omisión}$. También es el número de sitios de referencia clasificados con precisión dividido por el número total de sitios de referencia para esa clase. El índice PU indica la frecuencia con la que la clase del mapa estará realmente presente sobre el terreno. Esto se denomina fiabilidad. La Precisión del Usuario es el complemento del Error de Comisión, $PU = 100\% - \text{Error de Comisión}$. Se calcula tomando el número total de clasificaciones correctas para una clase concreta y dividiéndolo por el total de filas.

Tabla 3.3: Interpretación del coeficiente Kappa.

Valores K	Clasificación
<0,40	Pobre
0,40 - 0,55	Suficiente
0,55 - 0,70	Buena
0,70 - 0,85	Muy buena
>0,85	Excelente

Finalmente, para se realizó un análisis de ponderación o importancia de variables para cada clasificación. Para la clasificación basada en píxeles, se utilizó el módulo *ui.Chart.feature.byProperty* del software Google Earth Engine. La salida del mismo se representa en un gráfico de importancia vs variables de entrada. En cambio, para clasificación basada en objetos, la importancia de variables se estimó con el módulo [v.class.mlR](#), utilizado para la etapa de clasificación.

3.3. Resultados

3.3.1. Clasificación basada en píxeles

La clasificación por *RF* a nivel de píxeles obtuvo una precisión global por encima del 90% (Tabla 3.4). Teniendo en cuenta la escala de interpretación del coeficiente kappa (Tabla 3.3), dado que se obtuvo un Kappa mayor a 0,85, los resultados podrían considerarse "excelentes".

En relación a las medidas de precisión del usuario y productor para cada clase, los valores estuvieron por encima del 85%. Esto significa que la mayoría de los píxeles de la imagen fueron correctamente asignados a las siete clases correspondientes. Las clases de vegetación alta y baja son dos coberturas que a nivel espectral y en el análisis de contexto pueden resultar similares, aún así los resultados para ambas fueron muy buenos. La clase Vegetación alta se vio afectada solo por algunos falsos positivos (errores de comisión) con píxeles asignados desde las clases Vegetación baja y Sombras. Además, presentó algunos errores por omisión con las clases Vegetación baja y Asfalto. La clase de Agua obtuvo uno de los porcentajes de precisión de productor y usuario más bajos, con errores por comisión y omisión con la clase Sombras, y en menor medida algunos píxeles de Agua fueron asignados erróneamente a Vegetación baja. Las construcciones obtuvieron muy buenas medidas de precisión, con algunos errores por comisión con la clase Asfalto y errores por omisión con la misma clase, Suelo desnudo y Vegetación baja. En relación a la clase Suelo desnudo, presentó la mayor cantidad de errores por omisión con las clases Vegetación baja, Asfalto y Sombras; y comisión con las clases Asfalto y Construcciones. La clase de Sombras, tuvo varios errores de comisión por píxeles asignados de las clases Agua, Asfalto y Suelo desnudo.

Tabla 3.4: Mediciones de precisión del clasificador RF a nivel de píxeles. **OA:** Precisión global. **Kappa** como coeficiente de rango 0 a 1. **PP:** Precisión del productor; **PU:** Precisión de usuario.

Predicción	Verdad de campo						
	Veg. alta	Veg. baja	Agua	Construcciones	Asfalto	Suelo desnudo	Sombras
Veg. alta	110	7	0	0	1	0	0
Veg. baja	7	95	2	0	0	0	0
Agua	0	0	39	0	0	0	5
Construcciones	0	1	0	139	3	1	0
Asfalto	0	1	0	3	135	3	1
Suelo desnudo	0	1	0	0	12	7	1
Sombras	1	0	6	0	0	0	61
PP (%)	94,52	91,92	84,66	95,51	94,36	42,87	94,17
PU (%)	93,18	93,03	89,39	98,09	90,26	57,88	88,00
OA (%)	92,02						
Kappa	0,90						

La Figura 3.10 muestra el mapa de cobertura urbano obtenido para la clasificación basada en píxeles. La Figura 3.11 muestra tres detalles en RGB y la clasificación en distintas regiones de la ciudad. En los detalles de la Figura 3.11(b) y 3.11(f) se puede visualizar una buena precisión para la identificación de vegetación urbana, discriminando vegetación alta y vegetación baja. Asimismo, se observa una buena distinción de las clases Asfalto y Construcciones. Sin embargo, se detecta la clasificación errónea de píxeles como Agua en regiones oscuras donde hay sombras en 3.11(b) y 3.11(d), o canchas de césped (3.11(f)).

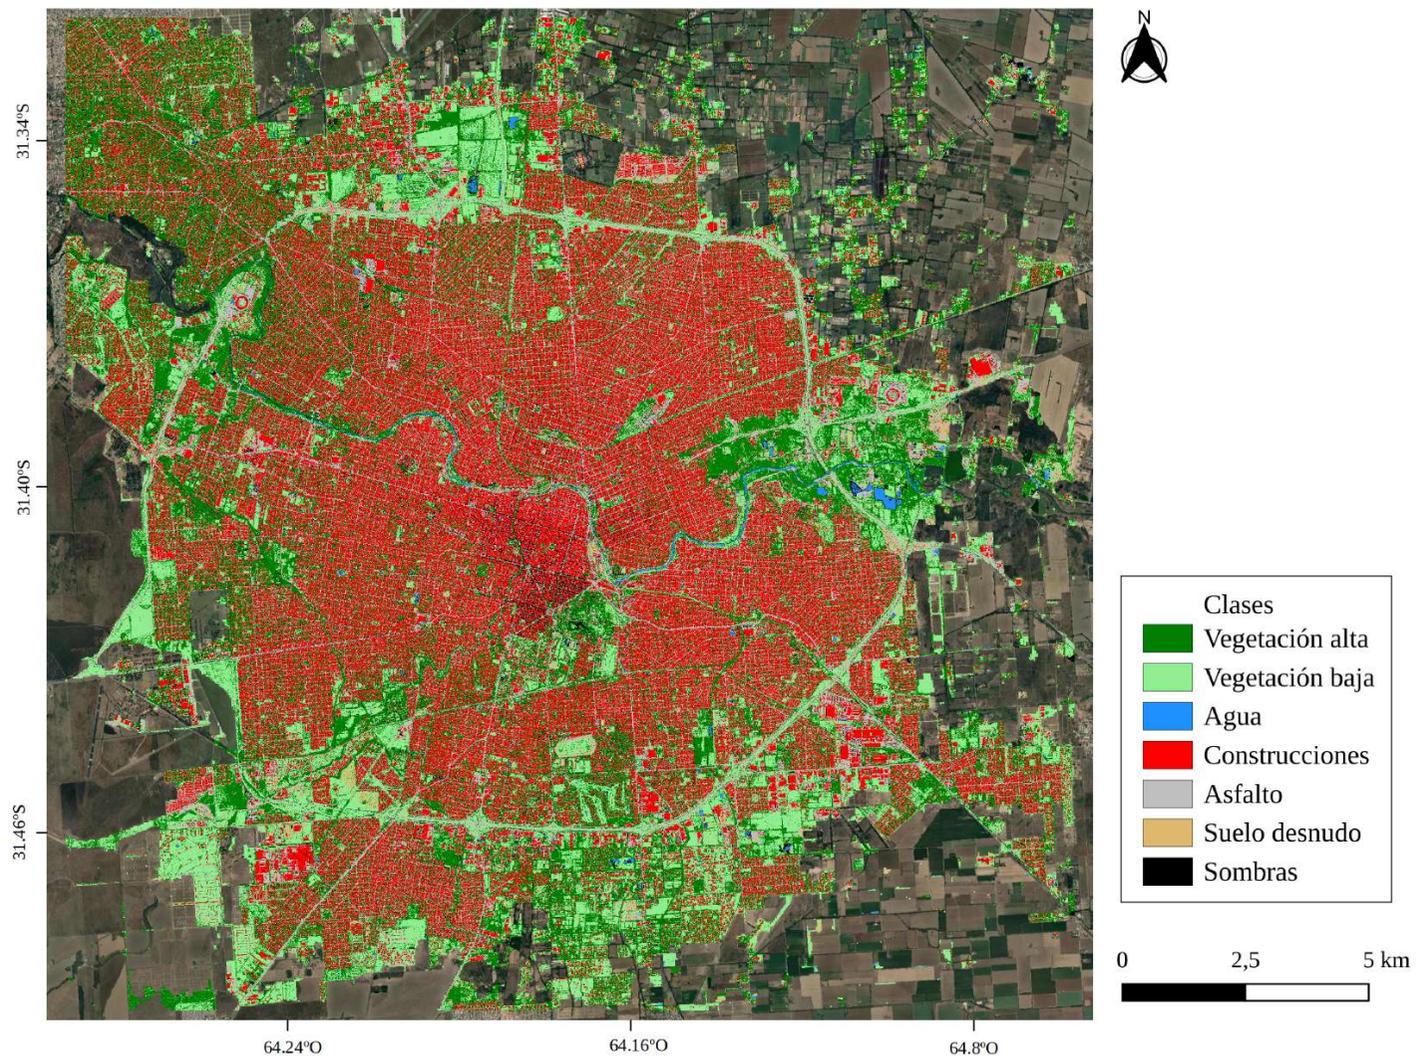


Figura 3.10: Mapa de cobertura urbana obtenido con la clasificación basada en píxeles.



(a) Zoom 1: RGB



(b) Zoom 1: Clasificación de píxeles



(c) Zoom 2: RGB



(d) Zoom 2: Clasificación de píxeles



(e) Zoom 3: RGB



(f) Zoom 3: Clasificación de píxeles

Figura 3.11: Detalle de clasificación basada en píxeles en distintas regiones del área de estudio.

3.3.2. Clasificación basada en objetos (OBIA)

La clasificación basada en objetos obtuvo una precisión global del 97,46 % y un índice Kappa de 0,97 (Tabla 3.5). Al igual que para la clasificación basada en píxeles, siguiendo la escala de interpretación del índice Kappa (Tabla 3.3), los resultados serían 'excelentes'. La Figura 3.12 muestra el mapa de cobertura urbana obtenido para la clasificación basada en objetos.

Las medidas de precisión de las siete clases estuvieron por encima del 90 % (Tabla 3.5). Las clases de Vegetación alta y baja mostraron buenos resultados para diferenciarse del resto de las clases, con valores por encima del 98 % para las precisiones de productor y usuario. La clase Agua, al igual que lo observado en la clasificación basada en píxeles, obtuvo errores por comisión con la clase Sombras. De igual manera, se observó errores por comisión en la clase Construcciones y Asfalto. La clase Suelo desnudo, obtuvo los valores más bajos de precisión, observándose errores por comisión con la clase Asfalto y por omisión con la clase Construcciones, en coincidencia con los obtenidos para la clasificación basada en píxeles.

Tabla 3.5: Matriz de confusión para la clasificación basada en objetos. **OA:** Precisión global en %; **Kappa** como coeficiente de rango 0 a 1. **PP:** Precisión del productor; **PU:** Precisión de usuario.

Predicción	Verdad de campo						
	Veg. alta	Veg. baja	Agua	Construcciones	Asfalto	Suelo desnudo	Sombras
Veg. alta	175	1	1	0	0	0	2
Veg. baja	0	164	0	0	0	2	0
Agua	0	1	69	0	0	0	1
Construcciones	0	0	0	270	0	0	0
Asfalto	0	0	0	6	202	8	1
Suelo desnudo	0	0	0	1	0	26	0
Sombras	0	0	4	0	0	0	167
PP (%)	97,76	98,79	97,18	100	93,08	96,29	97,66
PU (%)	100	98,79	93,24	97,47	100	72,22	97,66
OA (%)	97,46						
Kappa	0,97						

En la Figura 3.13 se muestran dos detalles urbanos en RGB, la segmentación obtenida y la clasificación de dichos segmentos. Si bien la segmentación muestra una mayor cantidad de segmentos que los objetos que se pretendían identificar, en la etapa posterior de clasificación dichos segmentos fueron clasificados como una única clase. En el detalle de la Figura 3.13(a) se observa una buena clasificación del río que atraviesa la ciudad, así como también una buena detección de la vegetación alta y baja en los márgenes del mismo. En la Figura 3.13(b) se visualiza otro detalle urbano con sombras de edificios en color negro, y una buena distinción entre las clases Asfalto y Construcciones.

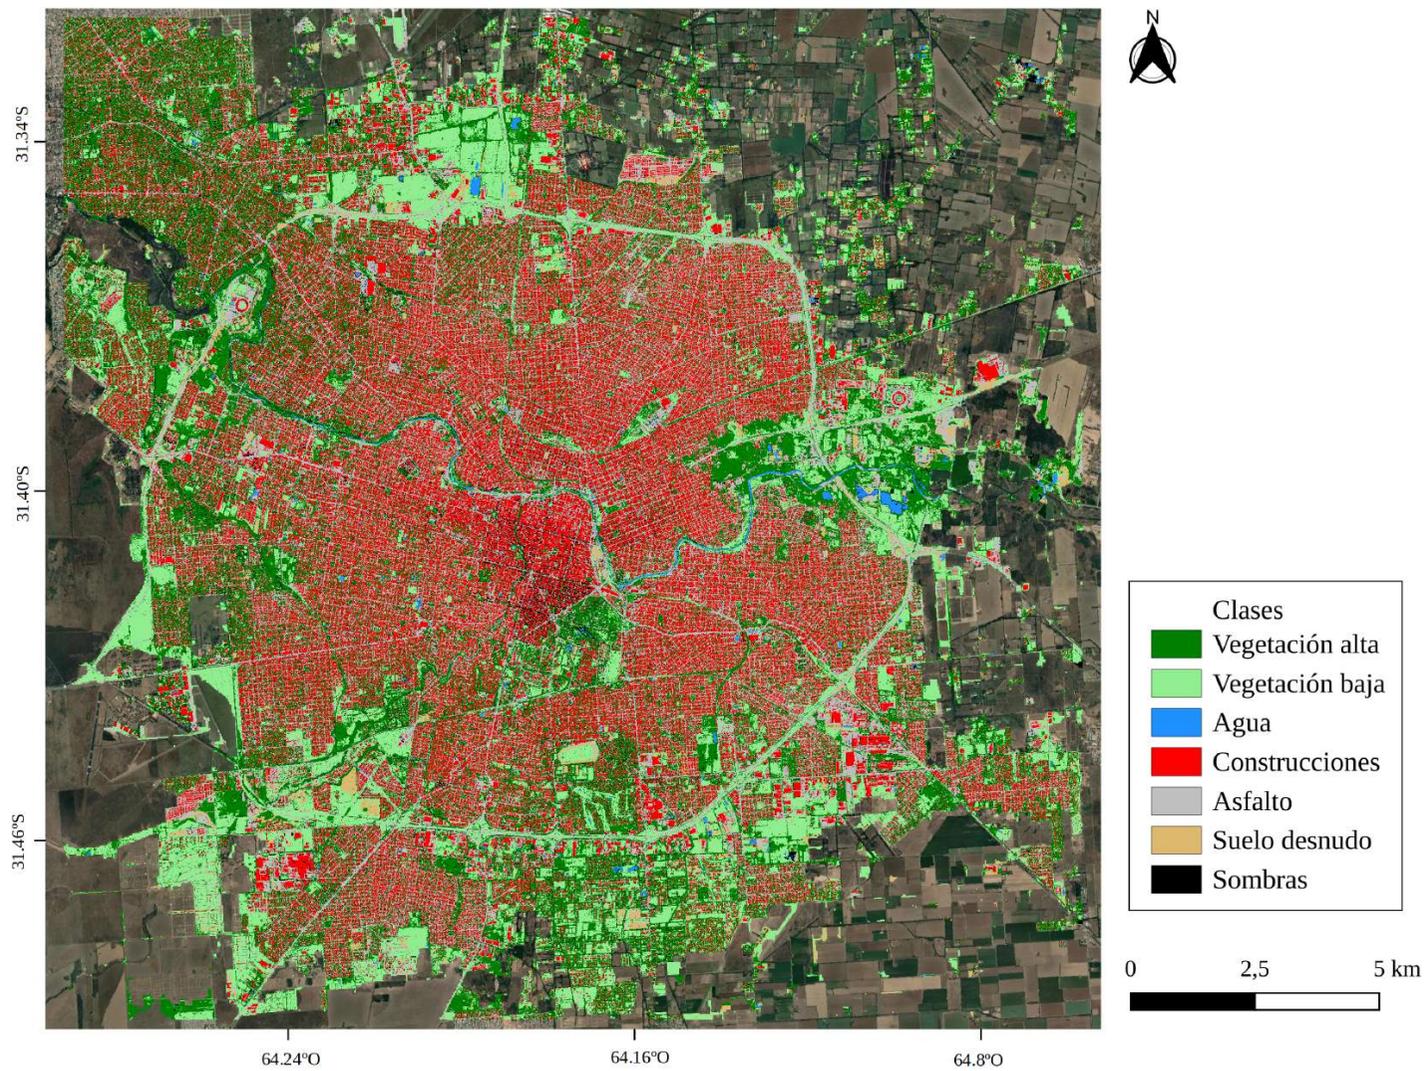


Figura 3.12: Mapa de cobertura urbana obtenido con la clasificación basada en objetos.

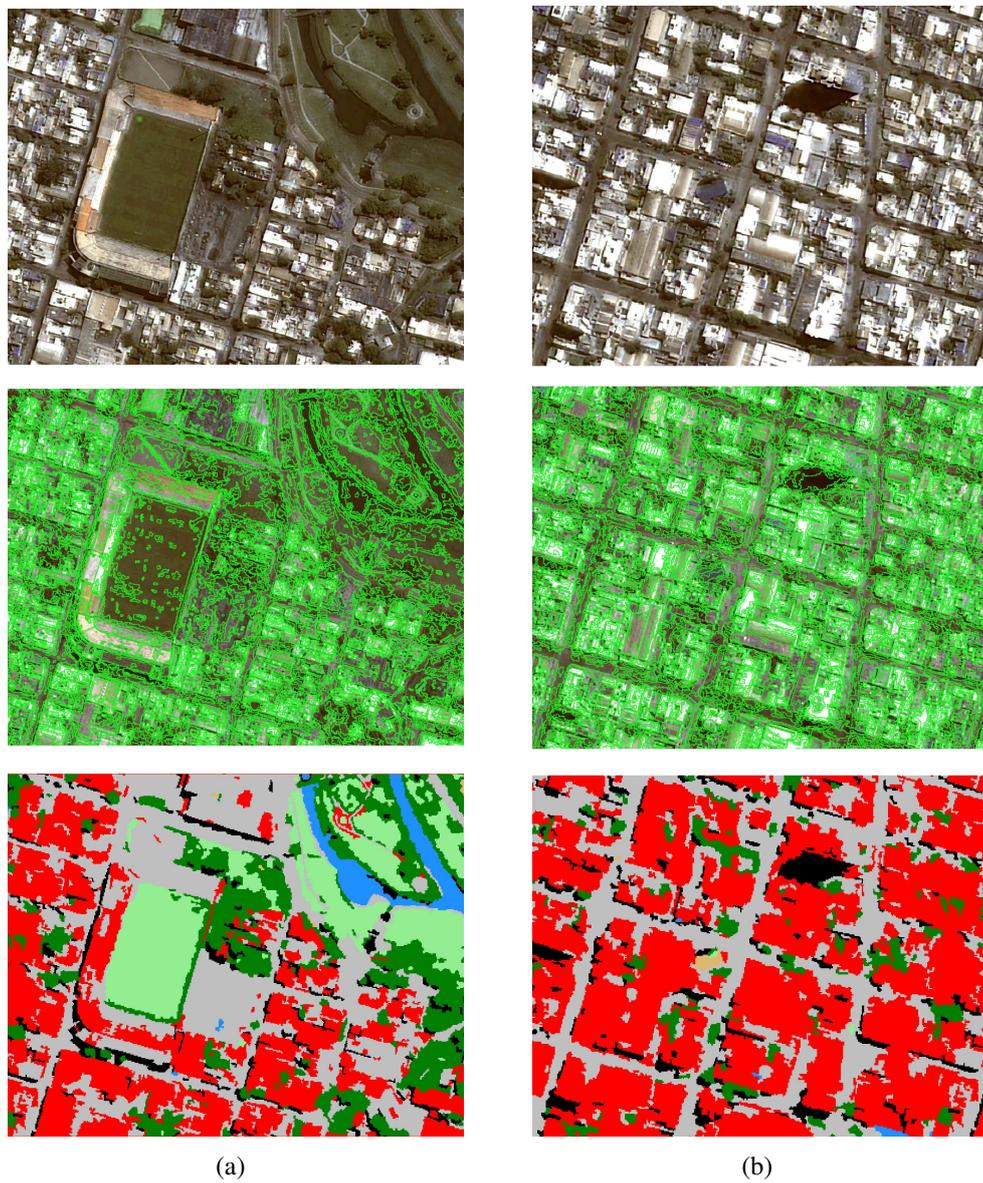


Figura 3.13: Detalles de productos obtenidos de la cadena de procesamiento de OBIA. En la parte superior detalles en RGB, al medio la segmentación y en la parte inferior las clasificaciones.

3.3.3. Comparación de clasificaciones

Analizando las medidas de precisión obtenidas para ambos mapas de cobertura urbana para la ciudad de Córdoba, se puede afirmar que la clasificación basada en objetos fue más precisa que la basada en píxeles. Si bien ambas clasificaciones fueron muy buenas, la clasificación de píxeles obtuvo una precisión del 92 % frente al 97 % de la clasificación basada en objetos. La clasificación basada en píxeles obtuvo un porcentaje mayor de errores por omisión y comisión para las clases Agua y Suelo desnudo (tabla 3.4), mientras que en la clasificación basada en objetos, dichas clases tuvieron una precisión del 97 % y 96 % (tabla 3.5).

La Figura 3.14 muestra la ponderación de la importancia de algunas variables para ambas clasificaciones con RF. Para la clasificación basada en píxeles (en verde), los índices de vegetación NDVI y NDWI tuvieron una mayor importancia que el resto de las variables. Las bandas originales de Pléiades (Tabla 3.1) mostraron una importancia por encima de todos los índices de textura incluidos. Si bien para la clasificación basada en objetos se incluyeron otras variables para caracterizar cada segmento (u objeto), en términos comparativos se analizó la importancia de las mismas variables incluidas en la clasificación anterior. Para GEOBIA, se observó que las variables de mayor importancia fueron la banda ROJO y el NDVI, seguido del índice de textura DV y de las mismas variables de importancia para la clasificación basada en píxeles.

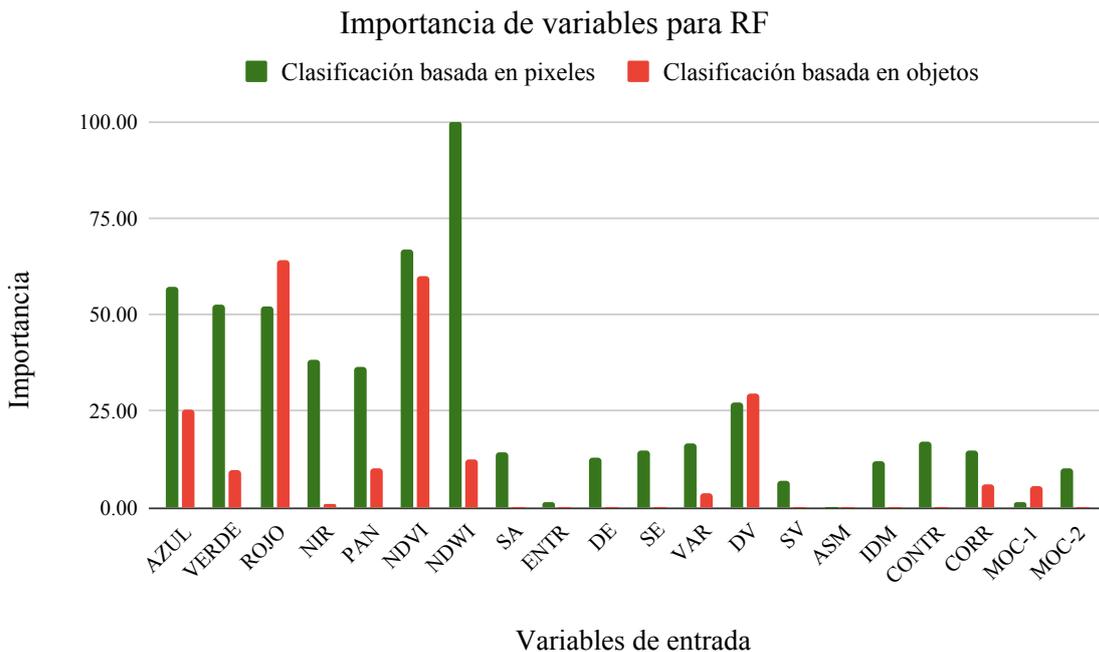


Figura 3.14: Importancia de variables para Random forest para ambas clasificaciones.

Las Figuras 3.15 y 3.16 muestran la comparación de métricas de precisión de usuario y productor por clase para cada clasificación. En términos generales, se observa que la clasificación basada en objetos fue más precisa en ambas métricas para todas las clases. Para ambas clasificaciones, la clase suelo desnudo, mostró los valores más bajos de precisión.

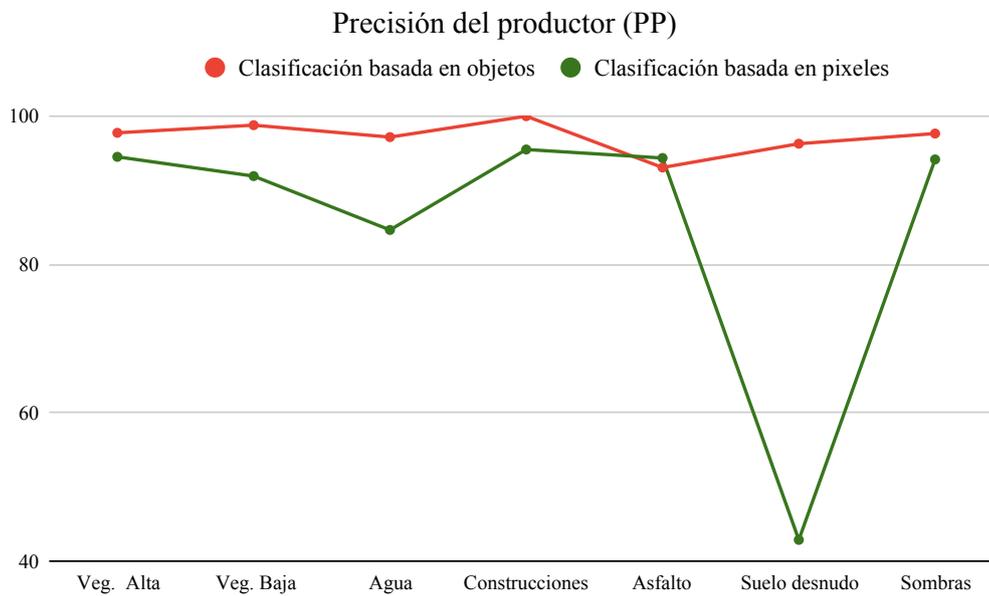


Figura 3.15: Comparación de precisión del productor entre ambas clasificaciones.

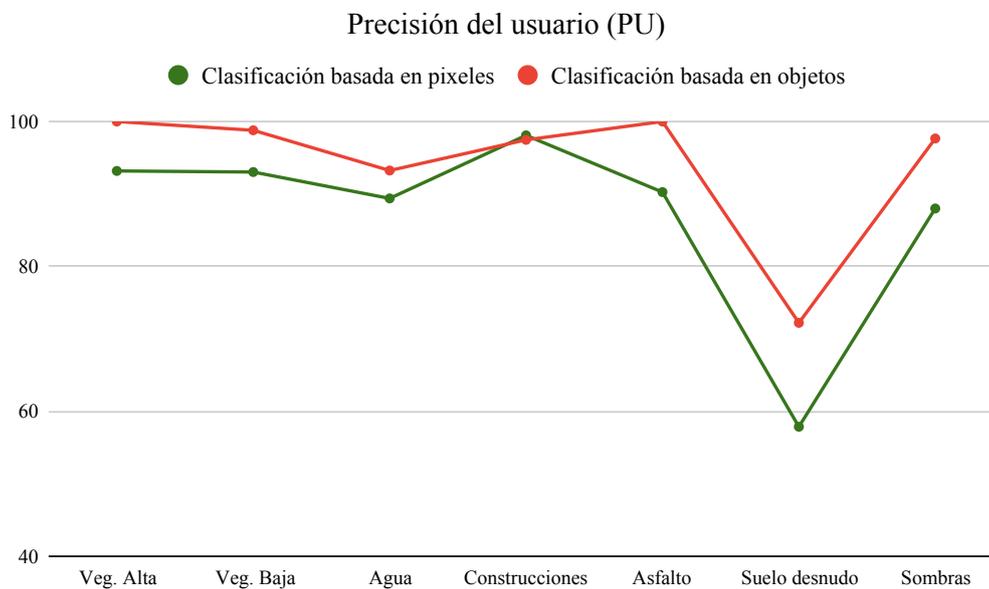


Figura 3.16: Comparación de precisión del usuario entre ambas clasificaciones.

La Figura 3.17 muestra dos detalles de extraídos de las clasificaciones de cobertura urbana obtenidas. La clasificación basada en píxeles presenta un efecto de 'sal y pimienta' comúnmente detectado en este tipo de clasificaciones. En ambas clasificaciones se detecta la clasificación errónea de algunos sectores como agua, en lugar de sombras o vegetación.



Figura 3.17: Comparación de clasificaciones. Del lado izquierdo se muestran dos detalles de la Ciudad en RGB, al medio la clasificación basada en píxeles, y del lado derecho la clasificación basada en objetos.

3.4. Discusión

Los mapas de cobertura de suelo urbano obtenidos a partir de metodologías de clasificación supervisadas basadas en píxeles y en objetos con una imagen de alta resolución representan un aporte a la cartografía de la Ciudad de Córdoba, permitiendo identificar las principales clases de cobertura y constituyendo una fuente de información relevante como punto de partida tanto para esta tesis como para futuros estudios de la ciudad.

En términos generales, ambas clasificaciones obtuvieron valores de precisión global e índice kappa por encima del 90%. Sin embargo, la clasificación basada en objetos obtuvo valores superiores en todas las métricas estimadas y fue más precisa que la clasificación basada en píxeles, ya que algunas clases de cobertura del suelo urbano son espectralmente similares y los enfoques clásicos no tienen en cuenta la disposición espacial de los píxeles. Mediante una evaluación cualitativa (examen visual) de los mapas de cobertura obtenidos, se observa que el mapa generado por el enfoque tradicional basado en píxeles contiene algunos píxeles de clases erróneamente identificados generando un efecto de "sal y pimienta" observado anteriormente en varios estudios que aplicaron esta metodología (147). Por el contrario, el mapa generado por el enfoque OBIA parece más preciso y fiel a la realidad (3.17), con delimitaciones más claras.

En general, para ambas clasificaciones, las clases que mostraron mayor confusión entre sí fueron: Agua–Sombras y Construcciones–Asfalto–Suelo desnudo. Esto era esperable debi-

do a la similitud en sus firmas espectrales, y a la ocurrencia de estos errores en otros trabajos (199). Muchos estudios de clasificaciones en zonas urbanas han considerado la confusión entre cuerpos agua y sombras (200; 201; 202), proponiendo la utilización de diferentes índices de agua para discriminar ambas clases, el NDWI y el NDWI modificado (MNDWI) son los más populares entre los índices existentes (203).

Por otra parte, la presencia de sombras en los entornos urbanos se ha investigado mucho en el sensado remoto. El principal problema causado por las sombras es la reducción o la pérdida total de información en una imagen. La reducción de la información podría conducir a la corrupción de los parámetros biofísicos derivados de los valores de los píxeles, como índices de vegetación (204). La pérdida total de información significa que no se pueden interpretar zonas de la imagen y que no se pueden crear productos de valor añadido, como los modelos digitales del terreno. Por esto, algunos trabajos han desarrollado técnicas específicas para la detección y eliminación de las mismas para reducir los efectos que producen (205; 206; 207). En este caso, se optó por incluir las sombras como una clase de interés, aun cuando su ubicación cambiaría si la imagen se adquiriese en otro horario o con otra inclinación.

La clase Suelo desnudo, presentó los valores más bajos de precisión de usuario para ambas clasificaciones (Figura 3.16) y de productor para la clasificación basada en píxeles (Figura 3.15), esto podría deberse a que fue la clase que tuvo una menor cantidad de datos de verdad de campo en relación al resto de las clases (ver Tabla 3.2) y a la confusión con las clases Construcciones y Asfalto con similar respuesta espectral.

En relación al análisis de ponderación o importancia de variables para Random forest, las variables que mostraron mayor importancia para ambas clasificaciones fueron el índice de vegetación NDVI, las cinco bandas originales de la imagen y el índice de textura DV 3.14. Dicho análisis constituye uno de los diferentes métodos para seleccionar variables (o *feature selection* en inglés) a la hora de clasificar una imagen (208; 209). En las clasificaciones supervisadas, dado que la clase a la que pertenece cada objeto de estudio se conoce, es natural seleccionar a las variables que están más estrechamente relacionadas con las clases; con la finalidad de que el subconjunto de variables seleccionado permita aumentar la calidad clasificación (210). Por lo cual, en una instancia posterior podría repetirse la clasificación para evaluar la precisión de la misma con el subconjunto de variables más relevantes. La selección de un subconjunto de variables a la hora de clasificar una imagen puede ser relevante ya que no sólo podría permitir alcanzar resultados más precisos sino que también podría reducir considerablemente el tiempo de procesamiento (209).

3.5. Conclusión

A partir del presente capítulo se pudieron evaluar dos aproximaciones de clasificación supervisada de imágenes para generar mapas de cobertura urbana. Debido al gran dinamismo que presentan las ciudades en la actualidad, la información relativa a las áreas urbanas queda desfasada rápidamente. Por ello, la disponibilidad de información cartográfica detallada y actualizada de estas zonas es de gran relevancia tanto para la planificación urbana como para numerosos estudios vinculados al ambiente y a la salud de las poblaciones.

Si bien los resultados de ambas metodologías evaluadas fueron muy buenos y obtuvieron una precisión global por encima de lo esperado, se comprobó que el método de clasificación basado en objetos es más preciso y obtiene mejores resultados cuando se trabaja con imágenes de alta resolución en áreas urbanas. Por este motivo, los análisis subsecuentes de esta tesis, estarán basados en la clasificación obtenida a través de la aproximación GEOBIA.

Caracterización de la variabilidad ambiental urbana

4.1. Introducción

Los entornos urbanos varían considerablemente en todo el mundo, así como dentro de determinadas ciudades o regiones urbanas. Aunque la urbanización suele presentarse a menudo como un proceso uniforme, en realidad existen muchos tipos y estilos de urbanización (211; 212; 213). Las ciudades contemporáneas surgen o se transforman sobre la base de muchos factores tales como la industrialización, el avance inmobiliario, la distribución de riquezas, cambios en las políticas gubernamentales, etc. Todos estos factores están condicionados por contextos culturales, históricos, climáticos, ambientales, regionales, geomórficos, económicos y políticos, entre otros. Esta variedad de factores genera una significativa *heterogeneidad* urbana entre y dentro de las ciudades.

Muchos procesos biofísicos y socio-económicos están moldeados por la estructura y forma de las áreas urbanas (214). Por lo tanto, además de la heterogeneidad, la forma (o estructura) urbana desempeña un papel crucial en el funcionamiento del entorno biofísico urbano y su interacción con las actividades humanas, así como también en el establecimiento y desarrollo de vectores de agentes infecciosos que se han adaptado a ambientes urbanos. La forma urbana -el patrón y la configuración espacial del uso del suelo, el transporte y los elementos urbanos diseñados (215)- es crucial para el desarrollo urbano sostenible e inteligente (216). La forma urbana puede caracterizarse por las extensiones urbanas físicas, la disposición de las calles y los edificios, así como la configuración interna de las viviendas y los espacios verdes (215). Además, la dinámica de la forma urbana en las dimensiones horizontal y vertical puede dar forma a muchos procesos biofísicos asociados (214).

En este sentido, el sensado remoto junto con el análisis de patrones de paisaje proporcionan un marco en el que la forma y estructura de los entornos urbanos puede cuantificarse y estudiarse. Las clasificaciones de imágenes satelitales presentadas en el capítulo anterior, constituyen herramientas esenciales para identificar y caracterizar usos y cobertura del suelo y pueden considerarse como un punto de partida para la caracterización, análisis y monitoreo de los cambios en los ambientes urbanos mediante el cálculo de métricas del paisaje. Numerosos estudios han mostrado una relación entre la cobertura de suelo y el paisaje y,

por lo tanto, también entre la cobertura de suelo y las métricas del paisaje y sus cambios (217; 218; 219; 220).

En términos generales, las métricas del paisaje se han utilizado ampliamente como indicadores de la biodiversidad, la calidad del agua y el cambio de la cobertura del suelo, entre otras aplicaciones (221; 222; 223; 224). Estos índices ofrecen un conjunto de herramientas espaciales para analizar paisajes completos y la disposición y propiedades de sus componentes. Asimismo, pueden proporcionar información sobre la fragmentación de los paisajes y las formas de los parches. Mas aun, las métricas del paisaje, proporcionan valores numéricos que permiten describir de forma general ciertas categorías (225). Las métricas del paisaje pueden calcularse para ciertas áreas de interés, permitiendo luego realizar comparaciones entre ellas y agrupar aquellas que presentan características similares. Una metodología implementada para encontrar zonas con configuraciones de paisaje similares es mediante la agrupación de sus elementos. Cardille y Lambois (226) y Partington y Cardille (227) agruparon patrones de cobertura de suelo utilizando la distancia euclidiana entre sus componentes principales calculados a partir de métricas del paisaje. Niesterowicz y Stepinski (228; 229) agruparon los patrones de cobertura del suelo utilizando la divergencia Jensen-Shannon entre las matrices de co-ocurrencia que representan los patrones. En Argentina, Albrieu et al. (105), realizaron un agrupamiento de barrios de la ciudad de Clorinda (Formosa) a partir de variables macro-ambientales derivadas de sensado remoto, para evaluar la dinámica espacio-temporal de criaderos artificiales de *Aedes aegypti*. Más recientemente, Andreo et al. 2021a y b (31), utilizaron algunas métricas del paisaje para asociarlas a la distribución de *Ae. aegypti* y a sus patrones temporales en la ciudad de Córdoba.

En este marco, el objetivo del presente capítulo es caracterizar ambientalmente la ciudad de Córdoba a través de métricas de paisaje y definir grupos ambientales a partir de cuatro criterios diferentes de organización espacial: radios censales, barrios, polígonos de Thiessen por centros de salud y una grilla de celdas definida arbitrariamente.

4.2. Materiales y métodos

4.2.1. Métricas del paisaje

Para cuantificar la *composición* y *configuración* de diferentes clases de cobertura de suelo, se han desarrollado numerosas métricas que se han aplicado ampliamente al análisis de la estructura del paisaje (120; 230; 231). Estas métricas de paisaje se utilizan comúnmente para facilitar las comparaciones entre diferentes paisajes; cuantificar cómo cambian los paisajes a lo largo del tiempo, especialmente en respuesta a diferentes tipos de perturbaciones o presiones en el uso de la tierra; e investigar la relación entre las características del paisaje y otros patrones ecológicos (231).

Según McGarigal y Marks (232; 119) las métricas del paisaje son aplicables en tres niveles:

- a. A nivel de parche (*patch level*): Los cálculos se aplican a cada parche individualmente. Un parche se define como celdas contiguas que pertenecen a la misma clase de cobertura terrestre.
- b. A nivel de clase (*class level*): Los cálculos se aplican a todos los parches de la misma clase, es decir, a aquéllos que tienen el mismo valor o que representan la misma clase

de cobertura de suelo. Adecuado para calcular la superficie que ocupa una determinada cobertura del suelo.

- c. A nivel de paisaje (*landscape level*): Los cálculos se aplican al conjunto del paisaje, es decir, a todos los parches y clases a la vez. Adecuado para determinar el grado de heterogeneidad o de homogeneidad del conjunto del área, entre otras.

Además, según diferentes autores se pueden diferenciar cinco grandes grupos de métricas de paisaje (119; 233):

1. *Métricas de área, superficie, densidad y variabilidad*. Se concentran en las características de dimensión y en el número de parches que conforman el área de estudio. Permiten disponer de una primera aproximación general a las características morfológicas de un determinado paisaje. Por ejemplo: *area, class area, total landscape area, number of patches, mean patch size*.
2. *Métricas de forma*. Están fundamentadas en las características de forma de los parches que constituyen un determinado paisaje, y se basan en la relación entre área y perímetro. Por ejemplo: *Shape Index, Mean Shape Index, Fractal Dimension*.
3. *Métricas ecotono y habitat interior*. Permiten hacer cálculos sobre la amplitud del ecotono, o hábitat de borde, en relación con el hábitat interior. Por ejemplo: *Perimeter, Total Edge, Edge Density, Total Core Area*.
4. *Métricas de distancia, vecindad y conectividad*. Calculan la distancia desde el hábitat de borde y ecotono de un parche hasta el parche más próximo de la misma clase. Se trata de métricas fundamentales para poder valorar el grado de aislamiento o conectividad existente entre los distintos parches. Por ejemplo: *Maximum Distance, Proximity Index, Nearest Neighbor Distance*.
5. *Métricas de diversidad*. Permiten cuantificar la composición del paisaje. Aportan información relevante para poder comparar distintos paisajes o la evolución de un paisaje en diferentes momentos históricos. Por ejemplo: *Shannon's Diversity Index, Simpson's Diversity Index*.

Comúnmente se utilizó el software FRAGSTATS (234) para calcular métricas del paisaje. Publicado por primera vez en 1995, FRAGSTATS fue el primer software en proporcionar una colección extensa de métricas de paisaje y, posteriormente, revolucionó el análisis de patrones de paisaje (235; 230). Sin embargo, actualmente el software R (236), un lenguaje desarrollado originalmente para la computación estadística (www.r-project.org), se utiliza cada vez más para el análisis, modelado y visualización de datos espaciales (237). En particular, el paquete *landscapemetrics* presenta una colección extensa de métricas del paisaje ampliamente utilizadas para el análisis de mapas discretos de cobertura del suelo, incluidas las métricas más utilizadas (238; 239; 240), así como algunas desarrolladas más recientemente (por ejemplo, la entropía conjunta, (241)).

4.2.1.1. *Landscapemetrics*

El paquete *landscapemetrics* comprende funciones para calcular métricas del paisaje utilizando datos ráster como entrada. La versión actual del software incluye métricas en todos

los niveles disponibles (parche, clase y paisaje). Además, las métricas del paisaje se pueden clasificar de acuerdo con las características del paisaje a las que hacen referencia (234; 242). Así, *landscapemetrics* incluye métricas de área y borde, métricas de forma, métricas de área central o núcleo, métricas de agregación, métricas de diversidad y métricas de complejidad. La Figura 4.1 muestra un ejemplo de visualización utilizando diferentes funciones del paquete. La Tabla 4.1 resume las métricas que se estimaron a nivel de clase y paisaje a partir de la clasificación supervisada basada en objetos obtenida en el Capítulo 3 y la Tabla 4.2 muestra una descripción de cada una. En el Anexo B.1 se muestra el código de ejemplo para la estimación de métricas a nivel de clase y paisaje para la grilla.

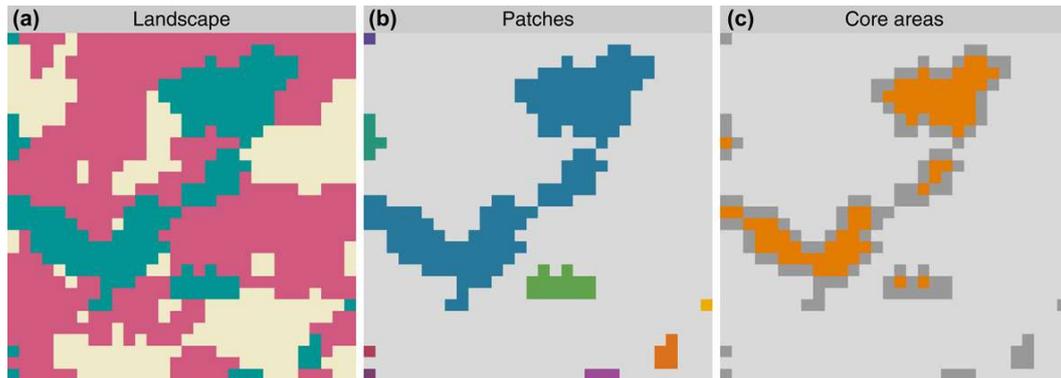


Figura 4.1: Visualización de un paisaje de ejemplo (a) utilizando las funciones de utilidad `show_patches()` (b) y `show_cores()` (c) para una clase seleccionada. Figura extraída de Hesselbarth et al (2019)

Tabla 4.1: Métricas del paisaje estimadas a nivel de clase y paisaje, disponibles en el paquete *landscapemetrics* del software R.

Métrica	Nombre	Tipo de métrica	Nivel	Función	
1	ent	Entropía de Shannon	Complejidad	Paisaje	<i>lsm_l_ent</i>
2	mutinf	Información mutua	Complejidad	Paisaje	<i>lsm_l_mutinf</i>
3	tca	Área central total	Área central	Paisaje	<i>lsm_l_tca</i>
4	ed	Densidad de borde	Área y borde	Paisaje	<i>lsm_l_ed</i>
5	pr	Riqueza de parches	Diversidad	Paisaje	<i>lsm_l_pr</i>
6	shdi	Índice de diversidad de Shannon	Diversidad	Paisaje	<i>lsm_l_shdi</i>
7	ai	Índice de agregación	Agregación	Paisaje	<i>lsm_l_ai</i>
8	division	Índice de división	Agregación	Paisaje	<i>lsm_l_division</i>
9	shape_mn	Índice de forma	Forma	Paisaje	<i>lsm_l_shape_mn</i>
10	contig_mn	Índice de contigüidad	Forma	Paisaje	<i>lsm_l_contig_mn</i>
11	ai	Índice de agregación	Agregación	Clase	<i>lsm_c_ai</i>
12	pd	Densidad de parche	Agregación	Clase	<i>lsm_c_pd</i>
13	area_mn	Área de parche	Área y borde	Clase	<i>lsm_c_area_mn</i>
14	pland	Porcentaje de paisaje	Área y borde	Clase	<i>lsm_c_pland</i>
15	shape_mn	Índice de forma	Forma	Clase	<i>lsm_c_shape_mn</i>
16	contig_mn	índice de contigüidad	Forma	Clase	<i>lsm_c_contig_mn</i>
17	cpland	Porcentaje del área central del paisaje	Área central	Clase	<i>lsm_c_cpland</i>
18	tca	Área central total	Área central	Clase	<i>lsm_c_tca</i>

Tabla 4.2: Descripción de las métricas de paisaje estimadas.

Métrica	Descripción
Entropía de Shannon (ent)	Mide diversidad (complejidad temática) de clases de paisaje.
Información mutua (mutinf)	Elimina la ambigüedad de los tipos de patrones de paisaje caracterizados por el mismo valor de una complejidad general.
Área central total (tca)	Es igual a la suma de las áreas centrales de todos los parches en el paisaje. En otras palabras, el área central de un parche es toda área que no sea un borde. Aumenta, sin límite, a medida que aumentan las áreas de los parches y se simplifican las formas de los mismos.
Porcentaje del área central del paisaje (cpland)	Es el porcentaje de superficie núcleo de clase en relación con la superficie total del paisaje. Debido a que cpland es una medida relativa, es comparable entre paisajes con diferentes áreas totales. Aumenta a medida que aumenta la cantidad de área central, es decir, los parches se vuelven más grandes y tienen una forma bastante simple
Densidad de borde (ed)	Cantidad de perímetro respecto al área total del paisaje. Es la suma total de todos los perímetros de una clase, dividido entre el área total del paisaje.
Área de parche (area_mn)	Resume cada clase como la media de todas las áreas de parche que pertenecen a una clase en particular. Permite describir la composición del paisaje.
Porcentaje de paisaje (pland)	Es el porcentaje del paisaje que está conformado por un tipo de cobertura en el total del paisaje. pland se aproxima a 0 cuando el tipo de cobertura disminuye su área y se acerca a 100 cuando domina el total del paisaje.
Riqueza de parches (pr)	Es una de las medidas más sencillas de diversidad y composición. Sin embargo, por su carácter absoluto, no es comparable entre paisajes con diferentes áreas totales. Es igual a 1 cuando solo hay un parche y aumenta a medida que aumenta el número de clases.
Diversidad de Shannon (shdi)	Medida de diversidad relativa en los parches. Este índice es igual a cero cuando solo hay un parche en el área de estudio y crece a medida que aumentan los parches.
Índice de agregación (ai)	Número de adyacencia de cada clase de cobertura dividido entre el máximo número de adyacencia posibles. Toma un valor de 0 para una mínima agregación y 100 para una máxima agregación.
Índice de división (división)	Mide la probabilidad de que dos celdas seleccionadas al azar no estén ubicadas en el mismo parche. Es igual a 0 si solo hay un parche presente. Se aproxima a 1 si todos los parches de la clase son celdas individuales.
Densidad de parche (pd)	Mide el número de parches por área, permite determinar comparaciones de mosaicos en diferentes tamaño y niveles de fragmentación.
Índice de forma (shape_mn)	Relacionado con el grado de complejidad. Se calcula a partir de la división entre la suma de los perímetros de los parches de una clase y la raíz cuadrada de la suma de las áreas de los parches de la misma clase respecto al número total de parches. Si es 1 significa que todos los parches son de forma circular y a medida que el índice aumenta las formas son más irregulares.
Índice de contigüidad (contig_mn)	Medida de la configuración del borde del parche, y por lo tanto de su forma, que se obtiene evaluando el grado de conectividad estructural de los píxeles en el parche.

4.2.2. Análisis de agrupamiento espacial o *Clustering*

El término *clustering* hace referencia a un amplio abanico de técnicas no supervisadas cuya finalidad es encontrar patrones o grupos (*clusters*) dentro de un conjunto de observaciones. Las particiones se establecen de forma que, las observaciones que están dentro de un mismo grupo son similares entre ellas y distintas a las observaciones de otros grupos. Se trata de un método no supervisado, ya que el proceso ignora la variable respuesta que indica a qué grupo pertenece realmente cada observación (si es que existe tal variable). Esta característica diferencia al *clustering* de las técnicas supervisadas que emplean un set de entrenamiento en el que se conoce la verdadera clasificación de un conjunto de muestras.

Dada la utilidad del *clustering* en disciplinas muy distintas, se han desarrollado multitud de variantes y adaptaciones de sus métodos y algoritmos. Pueden diferenciarse tres grupos principales:

- *Partitioning Clustering*: Este tipo de algoritmos requiere que el usuario especifique de antemano el número de clusters que se van a crear (Ejemplos: *K-means*, *K-medoids*, *CLARA*).
- *Hierarchical Clustering*: Este tipo de algoritmos no requiere que el usuario especifique de antemano el número de clusters (Ejemplos: *agglomerative clustering*, *divisive clustering*).
- Métodos que combinan o modifican los anteriores (Ejemplos: *hierarchical K-means*, *fuzzy clustering*, *model based clustering* y *density based clustering*).

4.2.2.1. Método de agrupamiento k-means

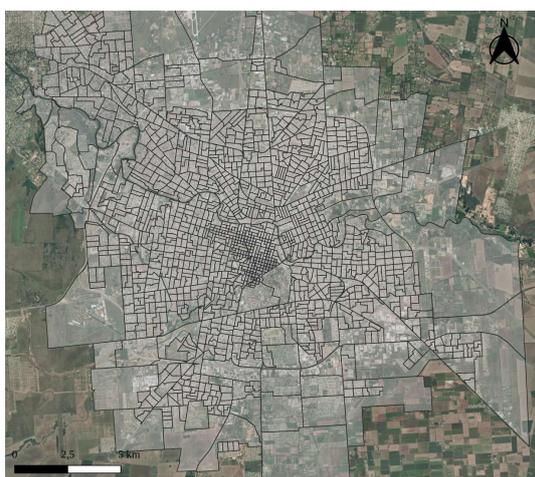
El método *K-means* (243) agrupa las observaciones en k clusters distintos, donde el número k lo determina el analista antes de ejecutar del algoritmo. El algoritmo entonces encuentra los k mejores *clusters*, entendiendo como mejor *cluster* aquel cuya varianza interna (*intra-cluster variation*) sea lo más pequeña posible. En términos generales, el algoritmo puede resumirse como:

1. Definir un total de k centroides al azar.
2. Calcular las distancias de cada uno de los puntos de entrada a los k centroides, y asignar cada punto al centroide cuya distancia sea menor.
3. Actualizar la posición de los k centroides, calculando la posición promedio de todos los puntos que pertenecen a cada clase.
4. Repetir los pasos 2 y 3 hasta que los centroides no cambien de posición y, por lo tanto, las asignaciones de puntos entre clases no cambie.

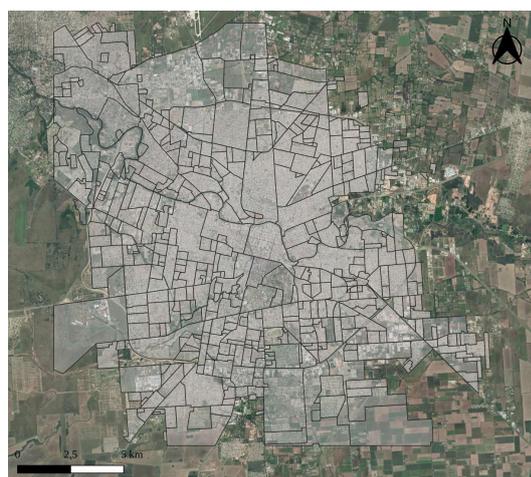
Para esta tesis, haciendo uso de la información ambiental obtenida a partir de la estimación de métricas de paisaje se realizó un análisis de agrupamiento o *clustering* con el método *K-means* teniendo en cuenta cuatro criterios diferentes de organización espacial de la Ciudad de Córdoba (Figura 4.2):

- Radios censales - Censo INDEC 2010.
- Barrios de la Ciudad de Córdoba.
- Polígonos de Thiessen: Generados a partir de la ubicación de centros de salud en toda la ciudad, mediante el módulo *v.voronoi* de GRASS GIS.
- Grilla regular: Generada con el módulo *v.mkgrid* de GRASS GIS, con un tamaño de celda de 1100x1100 m.

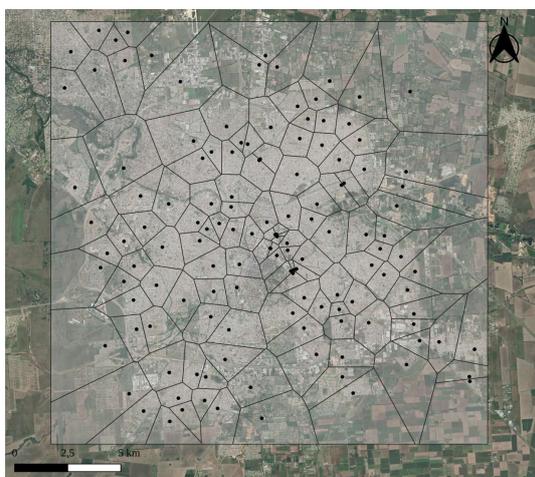
La utilización de diferentes criterios espaciales obedece a diferentes razones. Se decidió generar agrupamientos por radios censales para incorporar datos demográficos de la ciudad. Por otro lado, los barrios se incluyeron en respuesta al criterio adoptado por el Ministerio de Salud de la provincia para distribuir las ovitrampas y los monitoreos larvarios en el sistema de vigilancia de *Ae. aegypti*. Además, se generaron los polígonos de Thiessen (denominados *polígonos de salud*) para tener en cuenta la cobertura y accesibilidad sanitaria, así como también se decidió incorporar un criterio arbitrario dispuesto en celdas mediante una grilla.



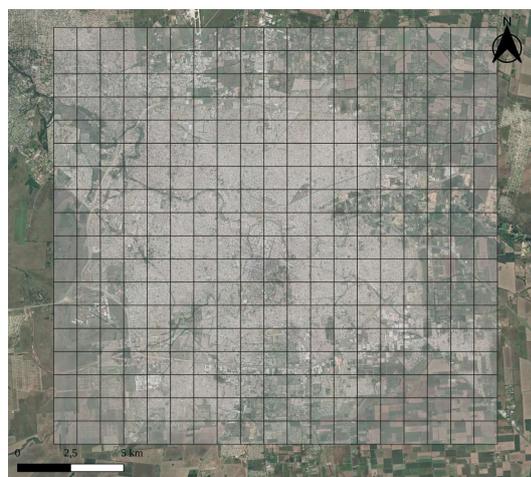
(a) Radios censales



(b) Barrios



(c) Polígonos de salud



(d) Grilla

Figura 4.2: Capas vectoriales utilizadas para los análisis de agrupamiento espacial.

4.2.2.2. Estimación del número óptimo de clusters

Determinar el número óptimo de *clusters* es uno de los pasos más complicados a la hora de aplicar métodos de agrupamiento, sobre todo cuando se trata de *partitioning clustering*, donde dicho número se debe especificar de antemano. No existe una forma única de averiguar el número adecuado de *clusters*. Es un proceso bastante subjetivo que depende en gran medida del tipo de *clustering* empleado y de si se dispone de información previa sobre los datos con los que se está trabajando o conocimiento del área. Por ejemplo, estudios anteriores pueden sugerir o acotar las posibilidades. No obstante, se han desarrollado varias estrategias que ayudan en el proceso. Para esta tesis, se tuvieron en cuenta tres métodos alternativos para determinar el número óptimo de *clusters* (244; 245):

- **Método del codo o *Elbow method*:** Este método sigue una estrategia comúnmente empleada para encontrar el valor óptimo de un hiper-parámetro. La idea general es probar un rango de valores del hiper-parámetro en cuestión, representar gráficamente los resultados obtenidos con cada uno e identificar aquel punto de la curva a partir del cual la mejora deja de ser sustancial (principio de verosimilitud). En los casos de *partitioning clustering*, como por ejemplo K-means, las observaciones se agrupan de una forma tal que se minimiza la varianza total intra-cluster. El método Elbow calcula la varianza total intra-cluster en función del número de clusters y escoge como óptimo aquel valor a partir del cual añadir más clusters apenas consigue mejoría.
- ***Average Silhouette method*:** Muy similar al de Elbow, con la diferencia de que, en lugar minimizar la suma de cuadrados inter-clusters, se maximiza la media de los coeficientes de Silhouette. Este coeficiente cuantifica cómo de buena es la asignación que se ha hecho de una observación comparando su similitud con el resto de observaciones de su *cluster* frente a las de los otros *clusters*. Su valor puede estar entre -1 y 1, siendo valores altos un indicativo de que la observación se ha asignado al *cluster* correcto.
- **Gap statistic method:** Este estadístico compara, para diferentes valores de k , la varianza total intra-cluster observada frente al valor esperado acorde a una distribución uniforme de referencia. La estimación del número óptimo de *clusters* es el valor k con el que se consigue maximizar el estadístico *gap*, es decir, encuentra el valor de k con el que se consigue una estructura de *clusters* lo más alejada posible de una distribución uniforme aleatoria. Este método puede aplicarse a cualquier tipo de análisis de agrupamiento.

Los métodos Elbow, Silhouette y gap no tienen por qué coincidir exactamente en su estimación del número óptimo de *clusters*, pero tienden a acotar el rango de posibles valores (244). Por esta razón es recomendable calcular los tres y en función de los resultados decidir. Para implementar los mismos se utilizó el paquete *factoextra* del software R, mediante la función `fviz_nbclust()` que automatiza cada proceso y genera una representación de los resultados. Este paquete también permite obtener visualizaciones de las agrupaciones resultantes. Si el número de variables (dimensionalidad) es mayor a 2, automáticamente realiza un análisis de componentes principales (PCA) y representa los *clusters* obtenidos en el espacio de las dos primeras componentes principales. En el Anexo B.2 se presenta el código implementado en R para el agrupamiento espacial para la grilla como ejemplo.

4.2.2.3. Descripción de clusters

Se generaron *boxplots* de los grupos o *clusters* obtenidos para cada criterio de organización espacial en función de las métricas del paisaje y otras variables ambientales a los fines de visualizar similitudes y diferencias entre grupos. Asimismo, se estimó la media y el desvío estándar de cada grupo ambiental. Además, para caracterizar los grupos ambientales de manera más precisa e intuitiva se los comparó en función de los índices NDVI y NDWI calculados en la sección 3.2.3.1 y la proporción de cada clase estimada en la sección 3.2.4. Se excluyeron las clases de Agua y Sombras, ya que su distribución no es homogénea en algunas regiones particulares de la Ciudad. Para esto, se utilizaron los módulos [v.rast.stats](#) (246) y [r.zonal.classes](#) (247) del software GRASS GIS.

4.2.2.4. Validación interna de clusters

La idea principal detrás del clustering es agrupar las observaciones de forma que sean similares a aquellas que están dentro de un mismo cluster y distintas a las de otros clusters, es decir, que la homogeneidad (también llamada *compactness* o cohesión) sea lo mayor posible a la vez que lo es la separación entre clusters. Cuantificar y comparar estas dos características es una forma de evaluar el resultado obtenido (244).

Dado que la homogeneidad y la separación siguen tendencias opuestas (a mayor número de clusters la homogeneidad aumenta, pero la separación disminuye), algunos de los índices más frecuentemente empleados para la validación interna de clusters combinan ambas medidas. Las medidas de validación interna que se utilizaron para esta tesis fueron las siguientes (244):

- **Conectividad:** Esta medida refleja hasta qué punto los elementos que se colocan en el mismo grupo también se consideran sus vecinos más cercanos en el espacio de datos o, en otras palabras, el grado de conexión de los grupos. Por lo cual, el valor de conectividad debe minimizarse.
- **Silhouette width:** Cuantifica la precisión en la asignación que se ha hecho de una observación comparando su similitud con el resto de observaciones del mismo *cluster* frente a las de los otros *clusters*. Su valor puede estar entre -1 y 1, siendo valores altos un indicativo de que la observación se ha asignado al *cluster* correcto. Cuando su valor es próximo a cero significa que la observación se encuentra en un punto intermedio entre dos *clusters*. Valores negativos apuntan a una posible asignación incorrecta de la observación.
- **Índice de Dunn:** Este índice identifica que un conjunto de *clusters* sean compactos, con una varianza pequeña entre los miembros del *cluster*, y que éstos estén bien separados de los miembros de otros *clusters*. Un valor más alto del índice de Dunn indica un mejor rendimiento del algoritmo de *clustering*. El índice de Dunn tiene un valor entre cero e infinito, y debe ser lo más alto posible.

4.3. Resultados

4.3.1. Métricas del paisaje

Se calcularon 18 métricas a nivel de clase y paisaje (Tabla 4.1) para las cuatro capas o criterios de organización espacial de la Ciudad de Córdoba. Las Figuras 4.3 y 4.4 muestran 4 métricas a nivel de paisaje, en donde se pueden observar diferencias en distintas regiones de la ciudad. De todas las métricas estimadas, se describen aquí solamente la Diversidad y Entropía de Shannon, el Índice de agregación y la Información mutua porque fueron las que presentaron una mayor variabilidad dentro y fuera de la Ciudad, permitiendo asimismo la identificación de algunos patrones. Los índices de Diversidad y Entropía de Shannon (Figura 4.3) muestran valores intermedios en un anillo alrededor del centro de la ciudad, y valores más bajos en la periferia en los radios censales, los polígonos de salud y la grilla regular. El índice de agregación (Figura 4.4), a diferencia de los dos índices anteriores, muestra un patrón contrario, con valores más altos en la periferia y valores bajos en el área más urbanizada. Para los barrios, el índice de agregación no mostró mayores diferencias, ya que todos los polígonos mostraron valores superiores a 80. El índice de información mutua (Figura 4.4), por su parte, muestra algunas diferencias entre las cuatro capas: los radios censales y los polígonos de salud se diferencian del patrón obtenido para los barrios y la grilla.

4.3.2. Análisis de agrupamiento espacial

A continuación se presentan los resultados obtenidos para el análisis de agrupamiento espacial para cada capa de la Ciudad de Córdoba. Dado que los agrupamientos utilizando métricas a nivel de paisaje mostraron una mayor consistencia y permitieron identificar grupos espaciales más marcados, se muestran únicamente los resultados obtenidos para este nivel de análisis. Los resultados obtenidos a partir de métricas a nivel de clase se incluyeron en el Anexo B.

4.3.2.1. Estimación del número óptimo de clusters

Para estimar el número óptimo de clusters se tuvieron en cuenta los tres criterios descritos en la sección 4.2.2.1. Las Figuras 4.5 y 4.6 muestran los gráficos de sedimentación obtenidos con cada método para las cuatro capas (radios, barrios, polígonos de salud y grilla regular). La Tabla 4.3 resume los valores estimados de k por método y criterio.

El método Silhouette estimó el mismo número de clusters para los radios censales, barrios y la grilla ($k = 2$). El método Gap, por su parte, arrojó números altos ($k = 9 - 10$) en todas las capas, a excepción de los polígonos de salud ($k = 3$). Y por último, para el método del Codo o *Elbow*, en los radios, polígonos de salud y grilla a partir de $k = 5$ no se observó una caída significativa en la suma de cuadrados; mientras que para los barrios, la curva se estabiliza a partir de $k = 3$. Si bien los valores de k estimados a partir de los diferentes criterios no coincidieron, su análisis permitió obtener un rango de valores aproximados a partir de los cuales probar distintos agrupamientos.

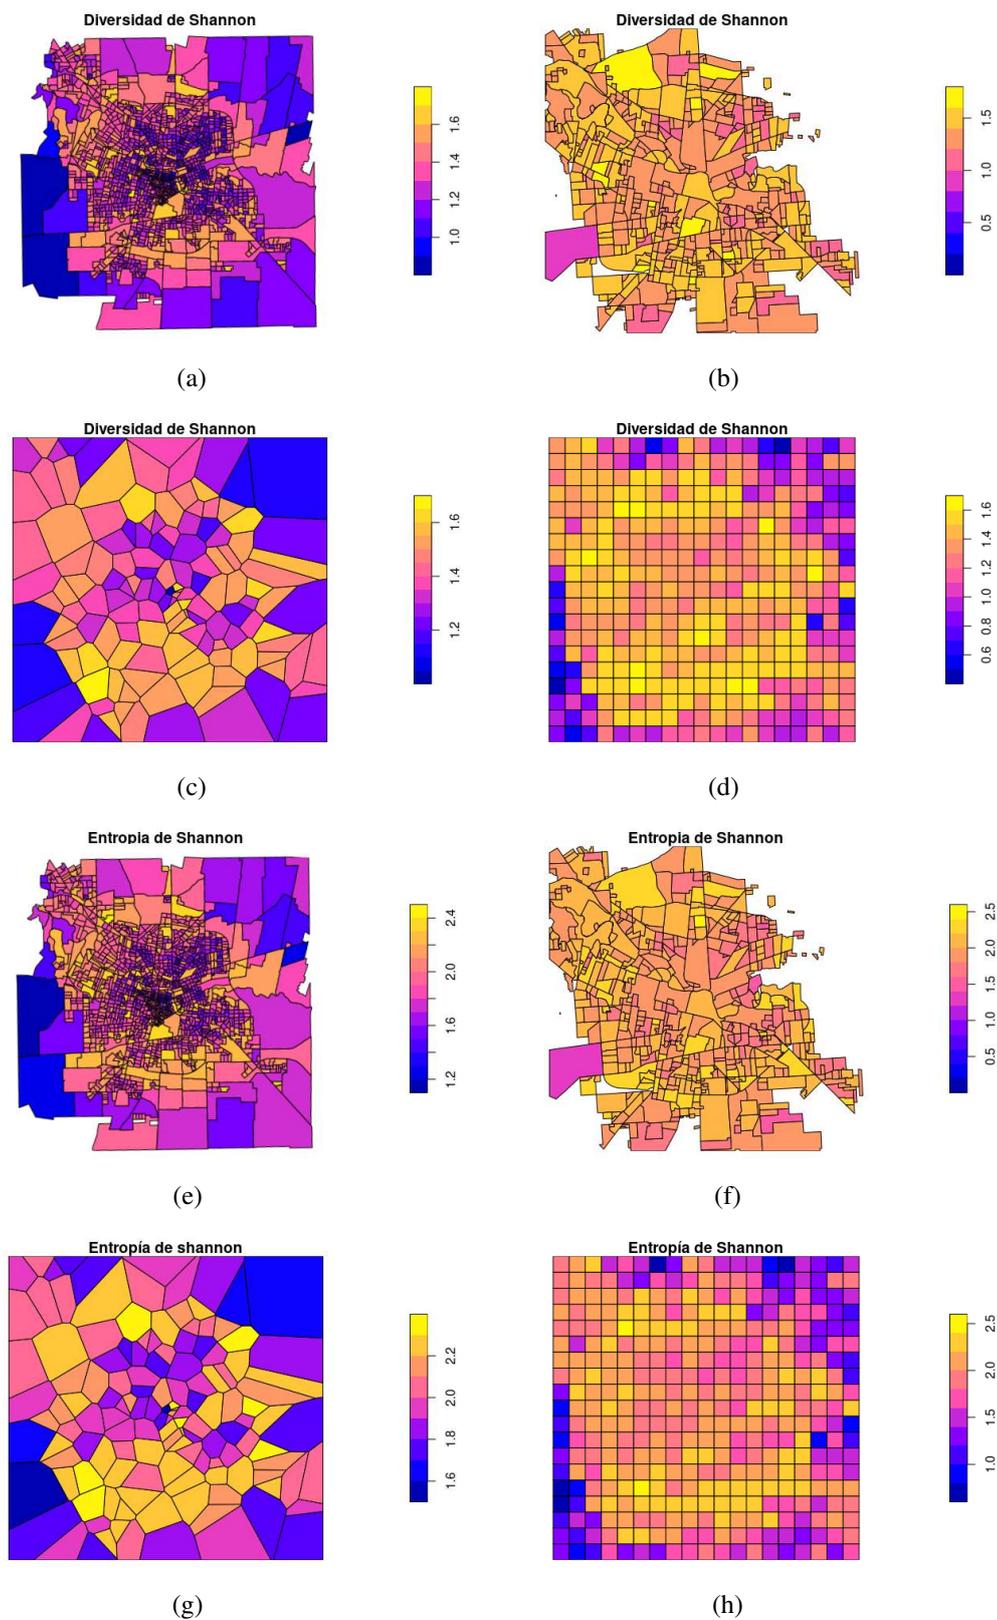


Figura 4.3: Diversidad y Entropía de Shannon para los cuatro criterios de organización espacial de la Ciudad de Córdoba. (a) y (e) para Radios censales, (b) y (f) para Barrios, (c) y (g) para Polígonos de salud y; (d) y (h) para la Grilla.

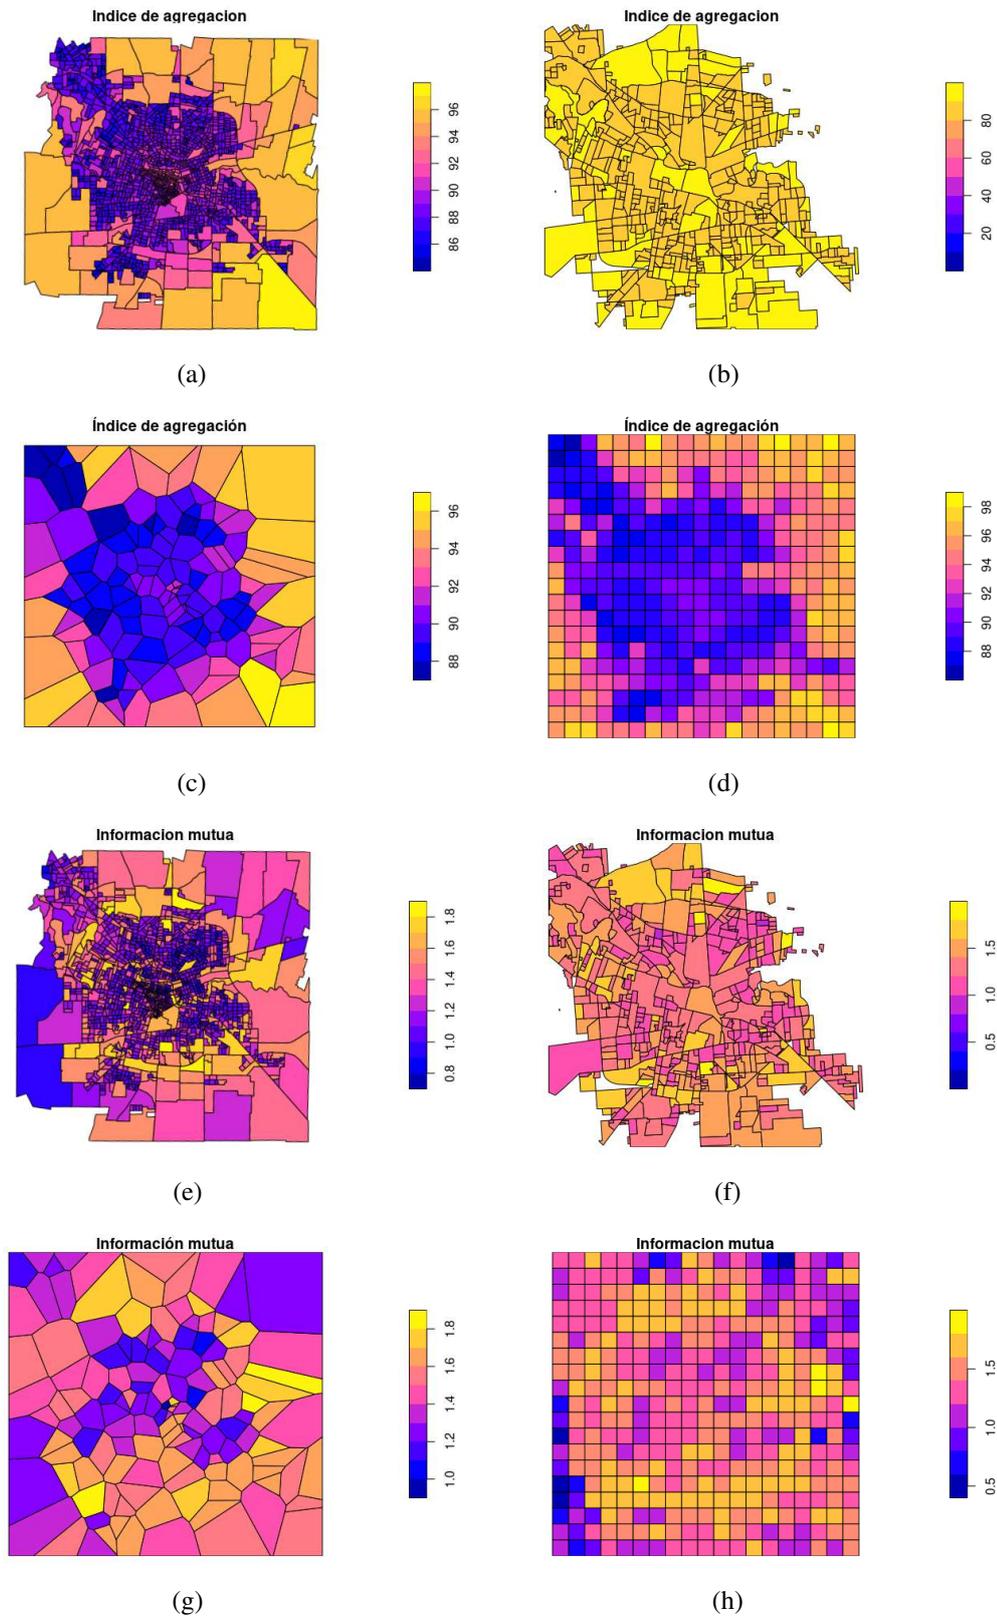
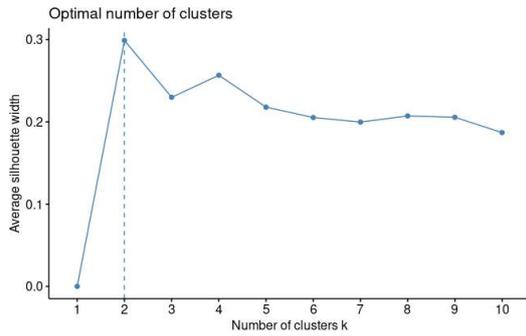
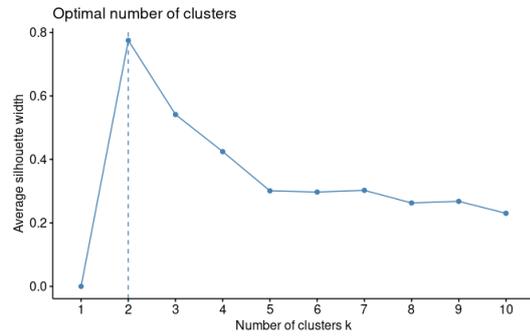


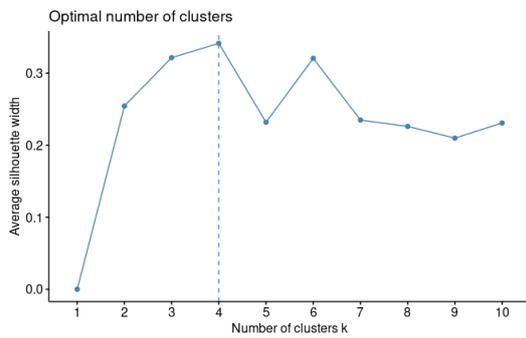
Figura 4.4: Índice de agregación e Información mutua para los cuatro criterios de organización espacial de la Ciudad de Córdoba. (a) y (e) para Radios censales, (b) y (f) para Barrios, (c) y (g) para Polígonos de salud y; (d) y (h) para la Grilla.



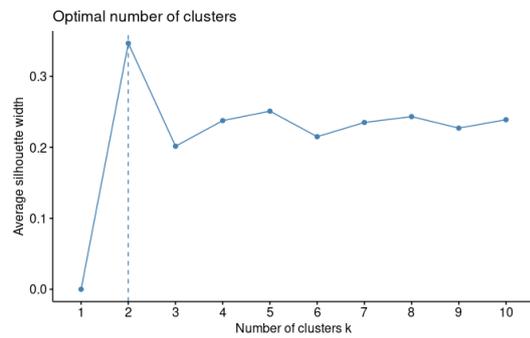
(a) Método Silhouette para radios censales



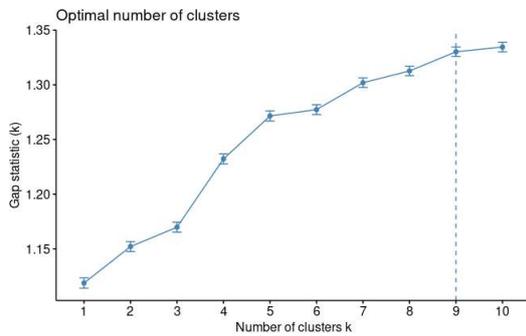
(b) Método Silhouette para barrios



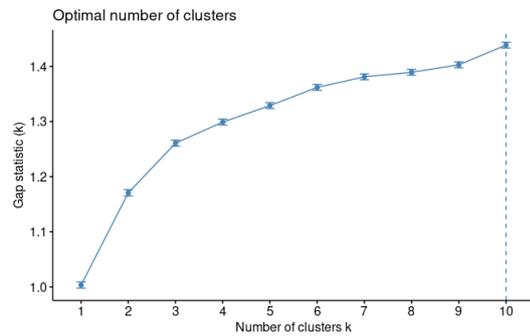
(c) Método Silhouette para polígonos



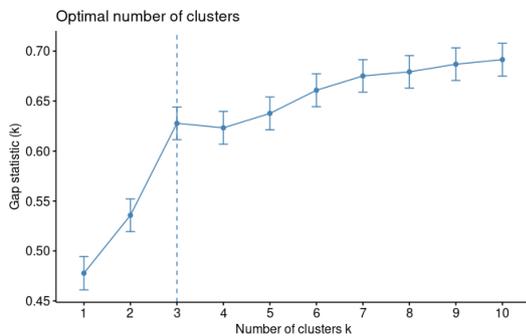
(d) Método Silhouette para la grilla



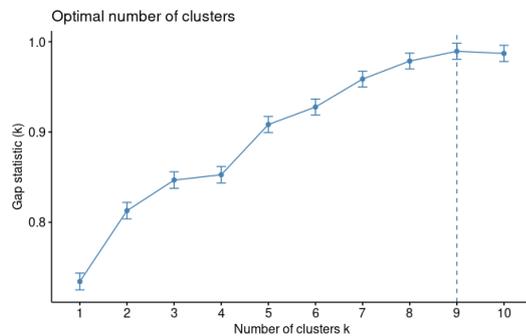
(e) Método Gap para radios censales



(f) Método Gap para barrios



(g) Método Gap para polígonos



(h) Método Gap para la grilla

Figura 4.5: Gráficos de sedimentación obtenidos con los métodos Silhouette y Gap.

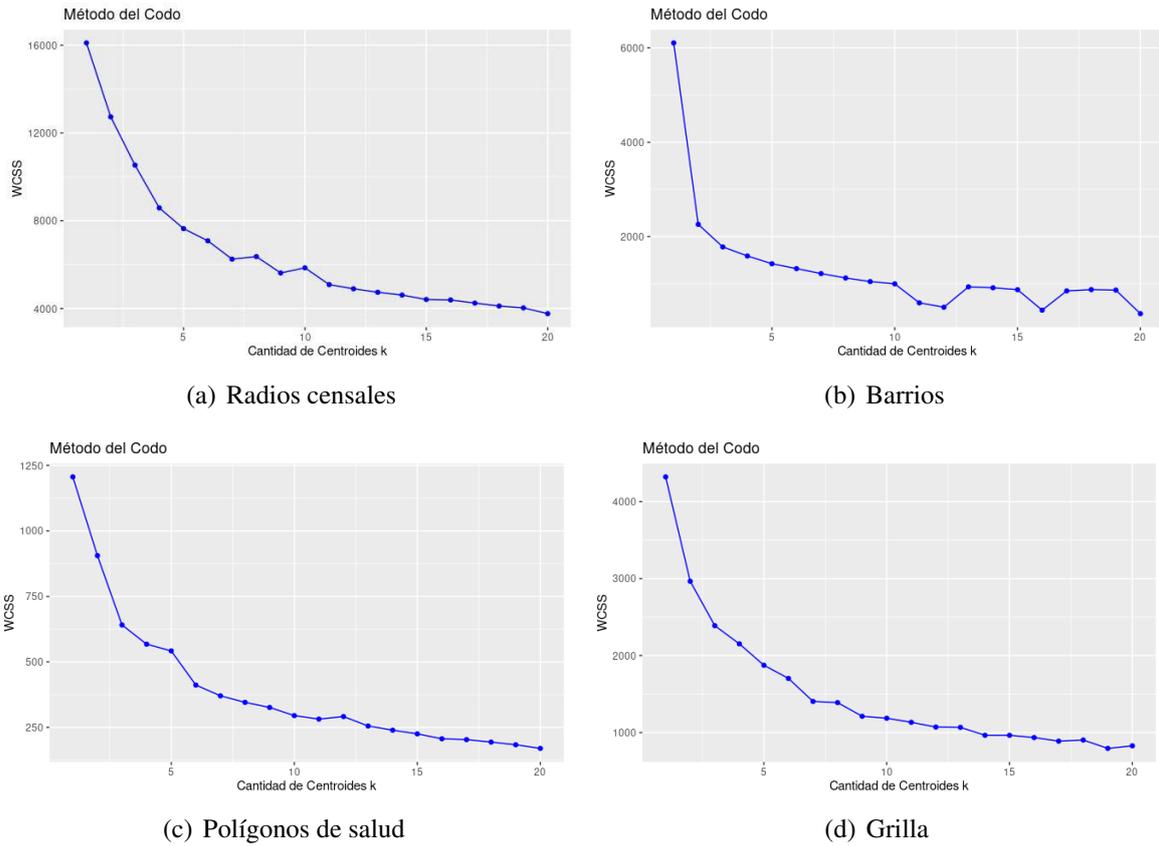


Figura 4.6: Gráficos de sedimentación obtenidos con el método Elbow para determinar el número óptimo de clusters.

Tabla 4.3: Comparación de la estimación del número de *clusters* en función de diferentes métodos.

Estimación del número óptimo de clusters				
Método	Radios censales	Barrios	Polígonos de salud	Grilla
<i>Silhouette</i>	2	2	4	2
<i>Gap</i>	9	10	3	9
<i>Elbow</i>	5	3	5	5

4.3.2.2. Validación interna de clusters

Para la validación interna de los agrupamientos se probaron distintos valores de k o número de *clusters* y se estimaron tres medidas de validación: Conectividad, Dunn y Silhouette width. Si bien el valor de conectividad debe ser bajo, los índices de Silhouette y Dunn deben maximizarse. La tabla 4.4 resume los valores estimados para cada índice, valor de k y criterio de agrupamiento analizado.

En términos generales, la medida de Conectividad tendió a sub-estimar el número de clusters para todas las capas. Los índices Dunn y Silhouette, a excepción de los barrios, estimaron un mayor número de clusters. Para el agrupamiento espacial por radios censales, la Conectividad y el índice de Silhouette coinciden en un valor estimado de 2 *clusters*. En cambio, para el índice Dunn, se estima un valor óptimo de 6 *clusters*. En el caso del agrupamiento por barrios de la ciudad, las tres medidas de validación coinciden en un valor óptimo de 2. Para los polígonos de salud, las estimaciones no coinciden en ninguna de las tres medidas y, para la

grilla, la medida de Conectividad estima un número de $k = 2$ y los índices Dunn y Silhouette coinciden en $k = 5$.

Tabla 4.4: Medidas de validación interna para el análisis de agrupamiento para Radios censales, Barrios, Polígonos de salud y Grilla de la ciudad de Córdoba.

Radios censales					
Número de clusters	2	3	4*	5	6
<i>Conectividad</i>	141.98	263.48	282.03	288.19	428.01
<i>Dunn</i>	0.015	0.016	0.016	0.021	0.015
<i>Silhouette width</i>	0.29	0.23	0.25	0.26	0.22
Barrios					
Número de clusters	2	3*	4	5	6
<i>Conectividad</i>	5.21	16.55	20.42	45.87	40.70
<i>Dunn</i>	0.16	0.06	0.07	0.02	0.03
<i>Silhouette width</i>	0.77	0.56	0.57	0.46	0.52
Polígonos de salud					
Número de clusters	3	4	5*	6	7
<i>Conectividad</i>	27.31	30.72	40.92	77.92	76.19
<i>Dunn</i>	0.09	0.13	0.15	0.07	0.13
<i>Silhouette width</i>	0.27	0.34	0.33	0.25	0.25
Grilla					
Número de clusters	2	3	4*	5	6
<i>Conectividad</i>	41.43	44.94	44.57	49.52	105.91
<i>Dunn</i>	0.03	0.04	0.06	0.07	0.03
<i>Silhouette width</i>	0.34	0.34	0.35	0.35	0.25

* k elegido para esta tesis.

4.3.2.3. Generación y análisis de clusters

Para esta tesis, la elección del número de clusters para cada capa fue determinada a partir de la evaluación de diferentes valores de k . Se determinó que los valores k que incorporaban una alta proporción de la variabilidad entre grupos fuera ajustado a 3 para los barrios de la ciudad, 4 para los radios censales y la grilla, y 5 para los polígonos de salud. Por encima de esos valores de k , no se observaron diferencias significativas en las sumas de cuadrados intra-grupos a medida que se agregaban grupos. Se verificó además, que valores superiores a los elegidos llevaban a arreglos menos parsimoniosos o con alto porcentaje de superposición de los grupos en el espacio de PCA.

Las Figuras 4.7, 4.9, 4.11 y 4.13 muestran los agrupamientos por k -means generados para cada criterio de organización espacial y las Figuras B.8, 4.10, 4.12 y 4.14 muestran la distribución espacial de dichos grupos ambientales en la Ciudad de Córdoba.

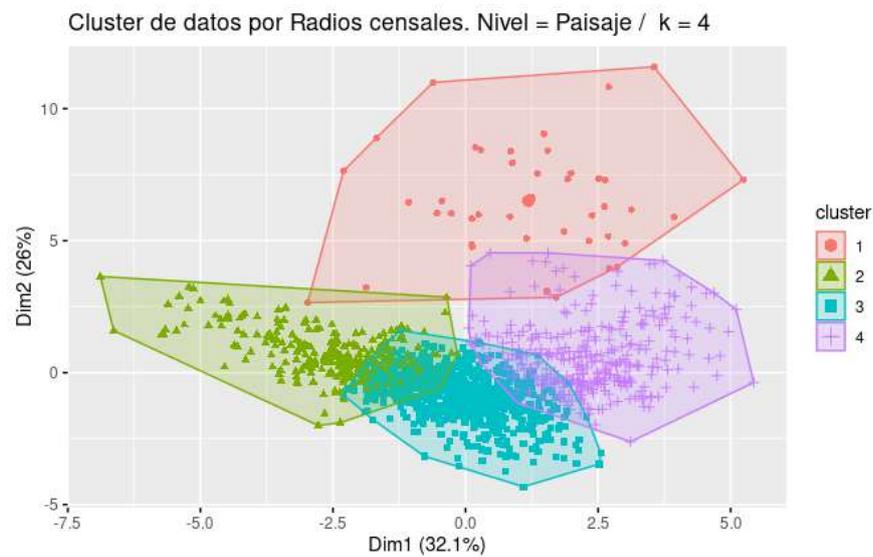


Figura 4.7: Agrupamiento por *k-means* basado en métricas a nivel de paisaje para los radios censales de la Ciudad de Córdoba. El agrupamiento se realizó incluyendo las métricas mencionadas en la Tabla 4.1 a nivel de paisaje y el valor de k fue fijado en 4 en base a la observación de los gráficos de sedimentación obtenidos.

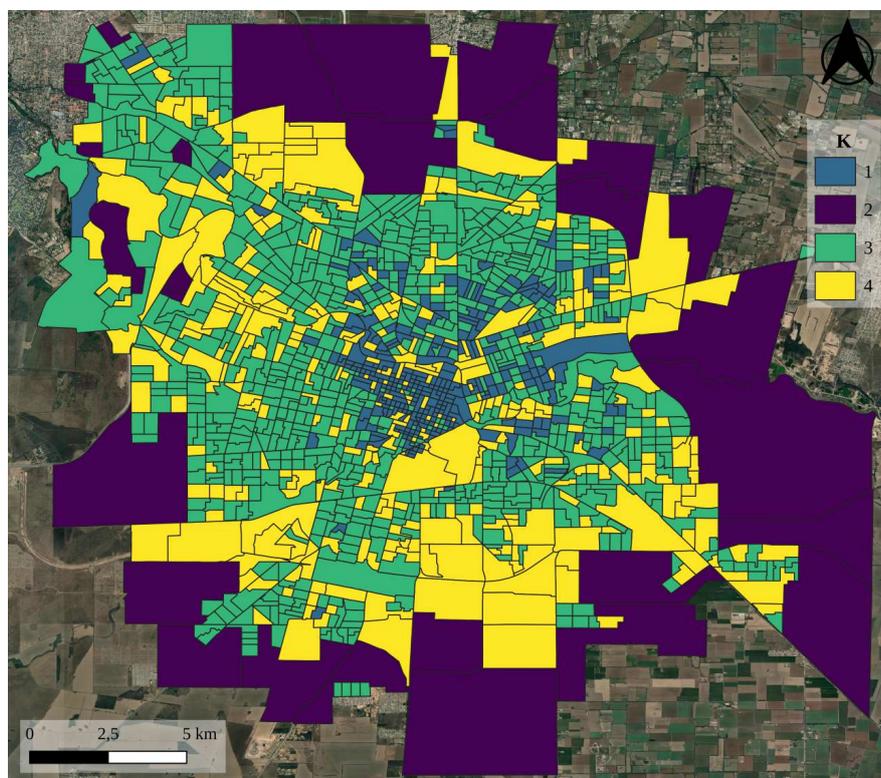


Figura 4.8: Mapa obtenido a partir del análisis de agrupamiento espacial por *k-means* a nivel de paisaje para los radios censales de la Ciudad de Córdoba.

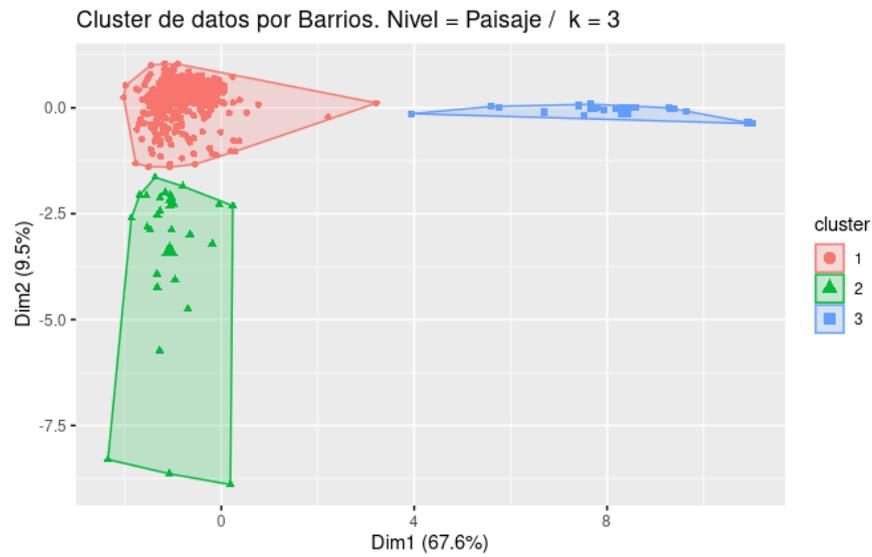


Figura 4.9: Agrupamiento por *k-means* para los barrios de la Ciudad de Córdoba. El agrupamiento se realizó incluyendo las métricas mencionadas en la Tabla 4.1 a nivel de paisaje y el valor de k fue fijado en 3 en base a la observación de los gráficos de sedimentación obtenidos.

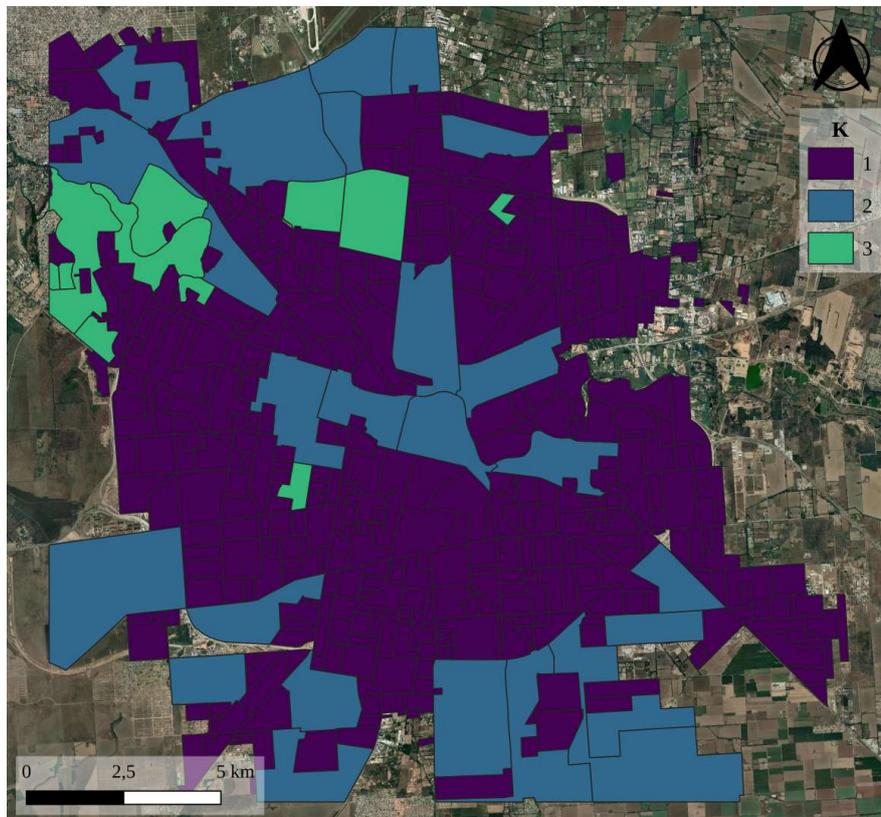


Figura 4.10: Mapa obtenido a partir del análisis de agrupamiento espacial por *k-means* para los barrios de la Ciudad de Córdoba.

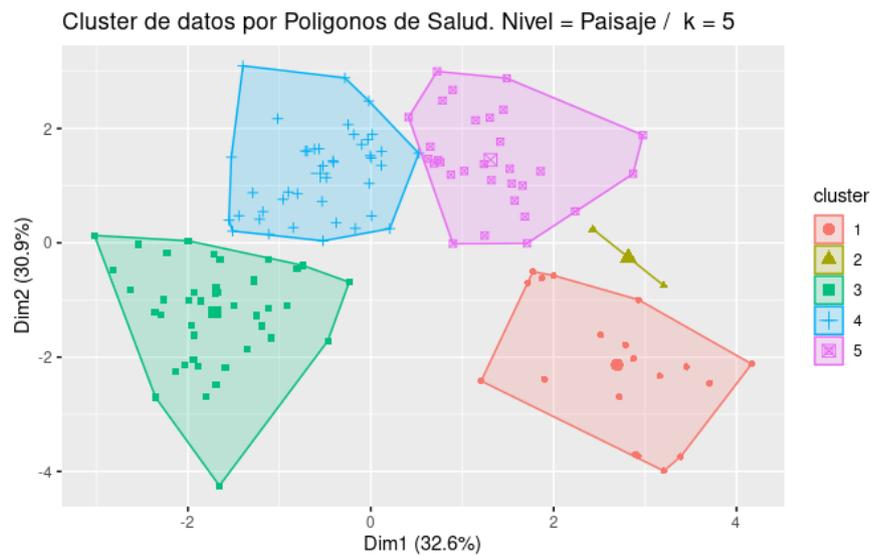


Figura 4.11: Agrupamiento por *k-means* para los polígonos de salud de la Ciudad de Córdoba. El agrupamiento se realizó incluyendo las métricas mencionadas en la Tabla 4.1 a nivel de paisaje y el valor de k fue fijado en 5 en base a la observación de los gráficos de sedimentación obtenidos.

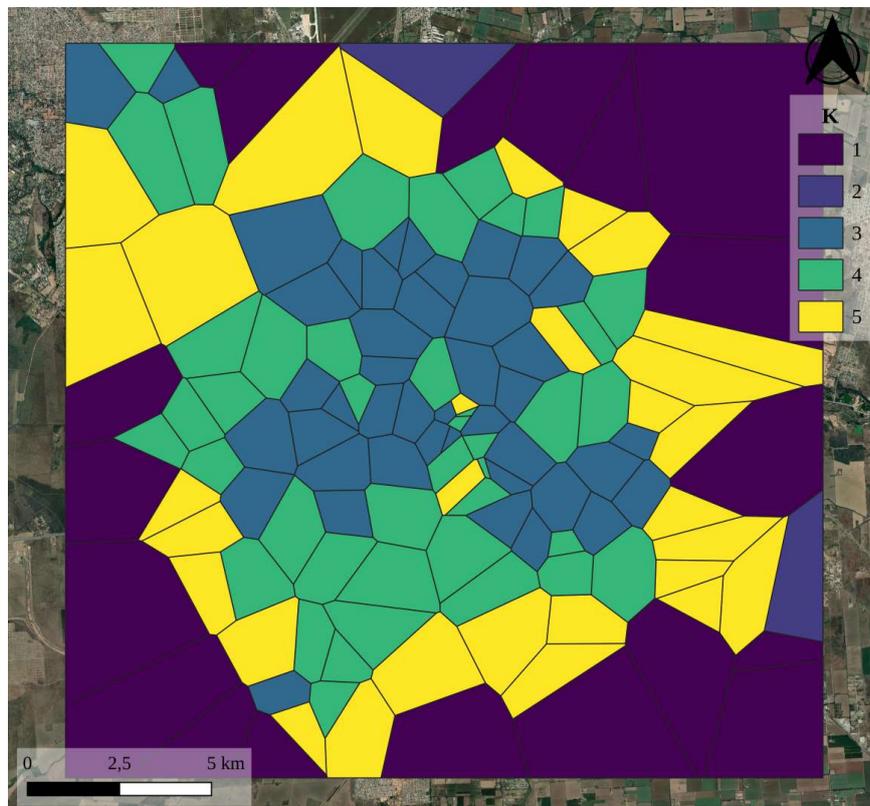


Figura 4.12: Mapa obtenido a partir del análisis de agrupamiento espacial por *k-means* para los polígonos de salud de la Ciudad de Córdoba.

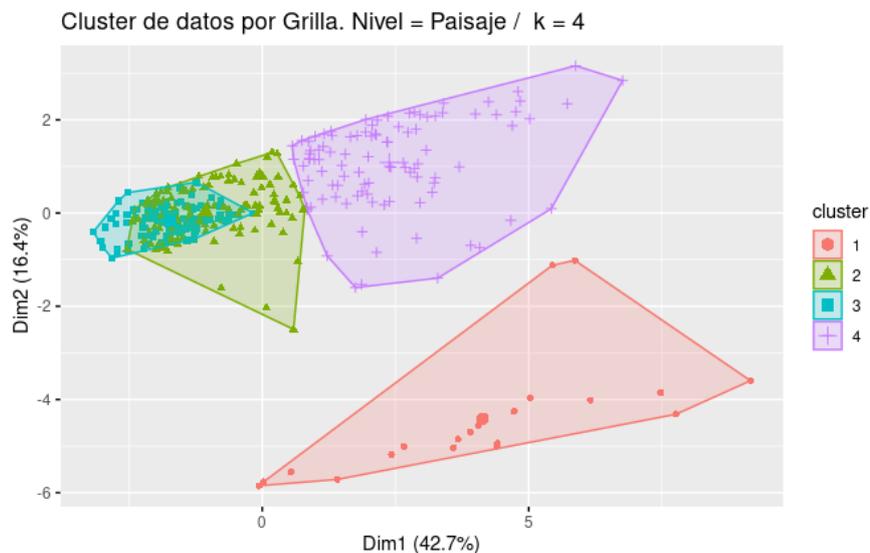


Figura 4.13: Agrupamiento por *k-means* para la Grilla de la Ciudad de Córdoba. El agrupamiento se realizó incluyendo las métricas mencionadas en la Tabla 4.1 a nivel de paisaje y el valor de k fue fijado en 4 en base a la observación de los gráficos de sedimentación obtenidos.

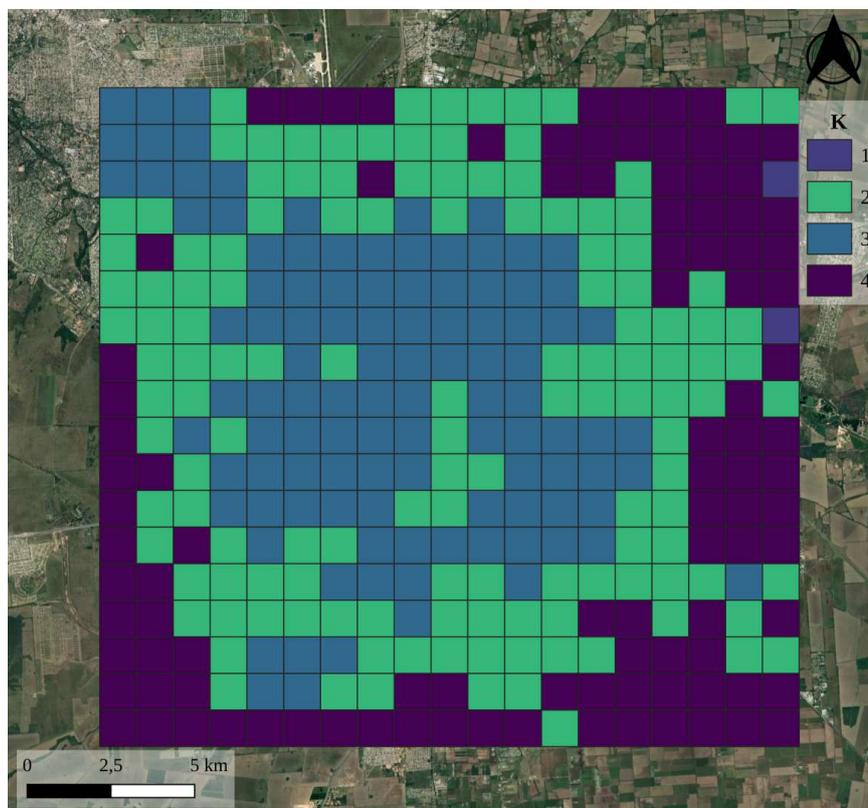


Figura 4.14: Mapa obtenido a partir del análisis de agrupamiento espacial por *k-means* para la grilla generada de la Ciudad de Córdoba

a. Radios censales

De acuerdo al agrupamiento espacial obtenido para los radios censales (Figuras 4.7 y 4.8), el *cluster* 1 representa solo el 6% de la superficie total analizada y agrupa los radios del centro de la ciudad con mayor densidad poblacional. El resto de grupos ambientales ocupan una superficie similar, cercana a los 100 km^2 . El *cluster* 2 corresponde a los radios periféricos de la ciudad, con muy baja densidad poblacional, y los *clusters* 3 y 4 agrupan radios de una densidad media y alta de población. Las Figuras 4.15 y 4.16 muestran los boxplots obtenidos para las métricas de paisaje, índices NDVI y NDWI (calculados en la sección 3.2.3.1), y proporción de clases (derivadas de la clasificación basada en objetos, Figura 3.12) para cada *cluster*. En términos generales, analizando las métricas del paisaje, se observa que el *cluster* 1 presenta los valores más bajos de Entropía y Diversidad de Shannon, Riqueza de parches e Información mutua. Además, debido a su ubicación céntrica en la ciudad, muestra los valores más bajos para el NDVI y proporción de vegetación alta, y la proporción de asfalto más alta (Figura 4.16). El *cluster* 2, posee un índice de agregación superior al resto de los grupos, y presenta el valor más bajo de Densidad de borde. Además, al contrario del *cluster* 1 y por ubicarse en la periferia de la ciudad, posee los valores más altos de NDVI, proporción de vegetación alta y baja, y los valores más bajos de proporción de asfalto y construcciones. Por su parte, el *cluster* 3 presenta valores intermedios en todas las métricas del paisaje analizadas, y junto con los *clusters* 1 y 4 posee una alta proporción de construcciones y asfalto. El último grupo ambiental, el *cluster* 4, presenta la mayor Entropía, Diversidad de Shannon e Información mutua. La Tabla 4.5 resume las medidas estadísticas, media y desvío estándar, para cada métrica analizada por grupo ambiental.

Tabla 4.5: Media aritmética para cada métrica del paisaje, índices NDVI, NDWI y proporción de cada clase por *cluster* para Radios censales.

Cluster	1	2	3	4
Métrica / Media	\bar{x}	\bar{x}	\bar{x}	\bar{x}
Entropía de Shannon	2 ± 0.1	2 ± 0.2	2 ± 0.1	2 ± 0.1
Información mutua	1 ± 0.1	1 ± 0.2	1 ± 0.1	2 ± 0.1
Área central total	5 ± 3	400 ± 300	10 ± 6	40 ± 15
Densidad de borde	2100 ± 200	1100 ± 400	2000 ± 200	2000 ± 300
Riqueza de parches	6 ± 1	7 ± 0.4	7 ± 0.4	7 ± 0.3
Diversidad de Shannon	1 ± 0.1	1 ± 0.2	1 ± 0.1	2 ± 0.1
Índice de agregación	90 ± 1	95 ± 2	90 ± 1	90 ± 2
Índice de división	10 ± 6	11 ± 8	25 ± 16	18 ± 11
Índice de forma	2 ± 0.1	2 ± 0.1	2 ± 0.1	2 ± 0.1
Índice de contigüidad	1 ± 0.1	1 ± 0.01	1 ± 0.01	1 ± 0.01
NDVI	0.2 ± 0.1	0.4 ± 0.03	0.3 ± 0.05	0.3 ± 0.1
NDWI	-0.3 ± 0.05	-0.5 ± 0.03	-0.4 ± 0.05	-0.4 ± 0.1
Vegetación alta	0.1 ± 0.05	0.4 ± 0.2	0.2 ± 0.1	0.3 ± 0.1
Vegetación baja	0	0.4 ± 0.2	0	0
Asfalto	0.5 ± 0.1	0.05 ± 0.03	0.4 ± 0.1	0.2 ± 0.1
Construcciones	0.3 ± 0.1	0.1 ± 0.05	0.3 ± 0.1	0.3 ± 0.1
Suelo desnudo	0	0	0	0

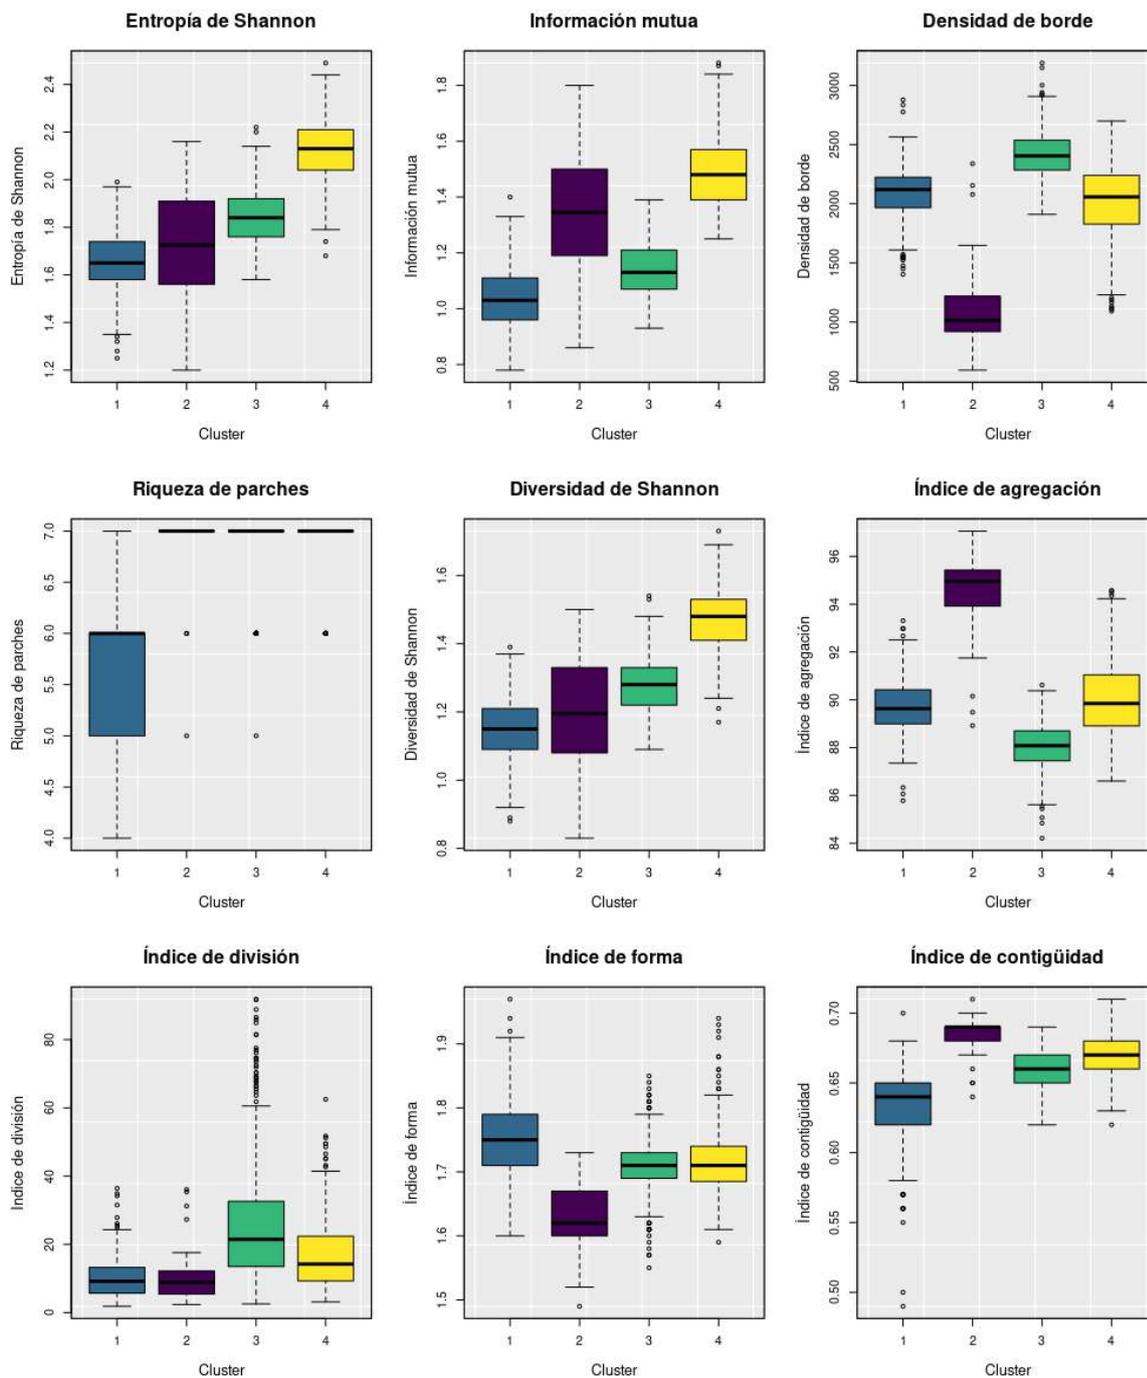


Figura 4.15: Boxplots de métricas estimadas a nivel de paisaje en función de los cuatro grupos ambientales obtenidos para los Radios censales de la Ciudad de Córdoba.

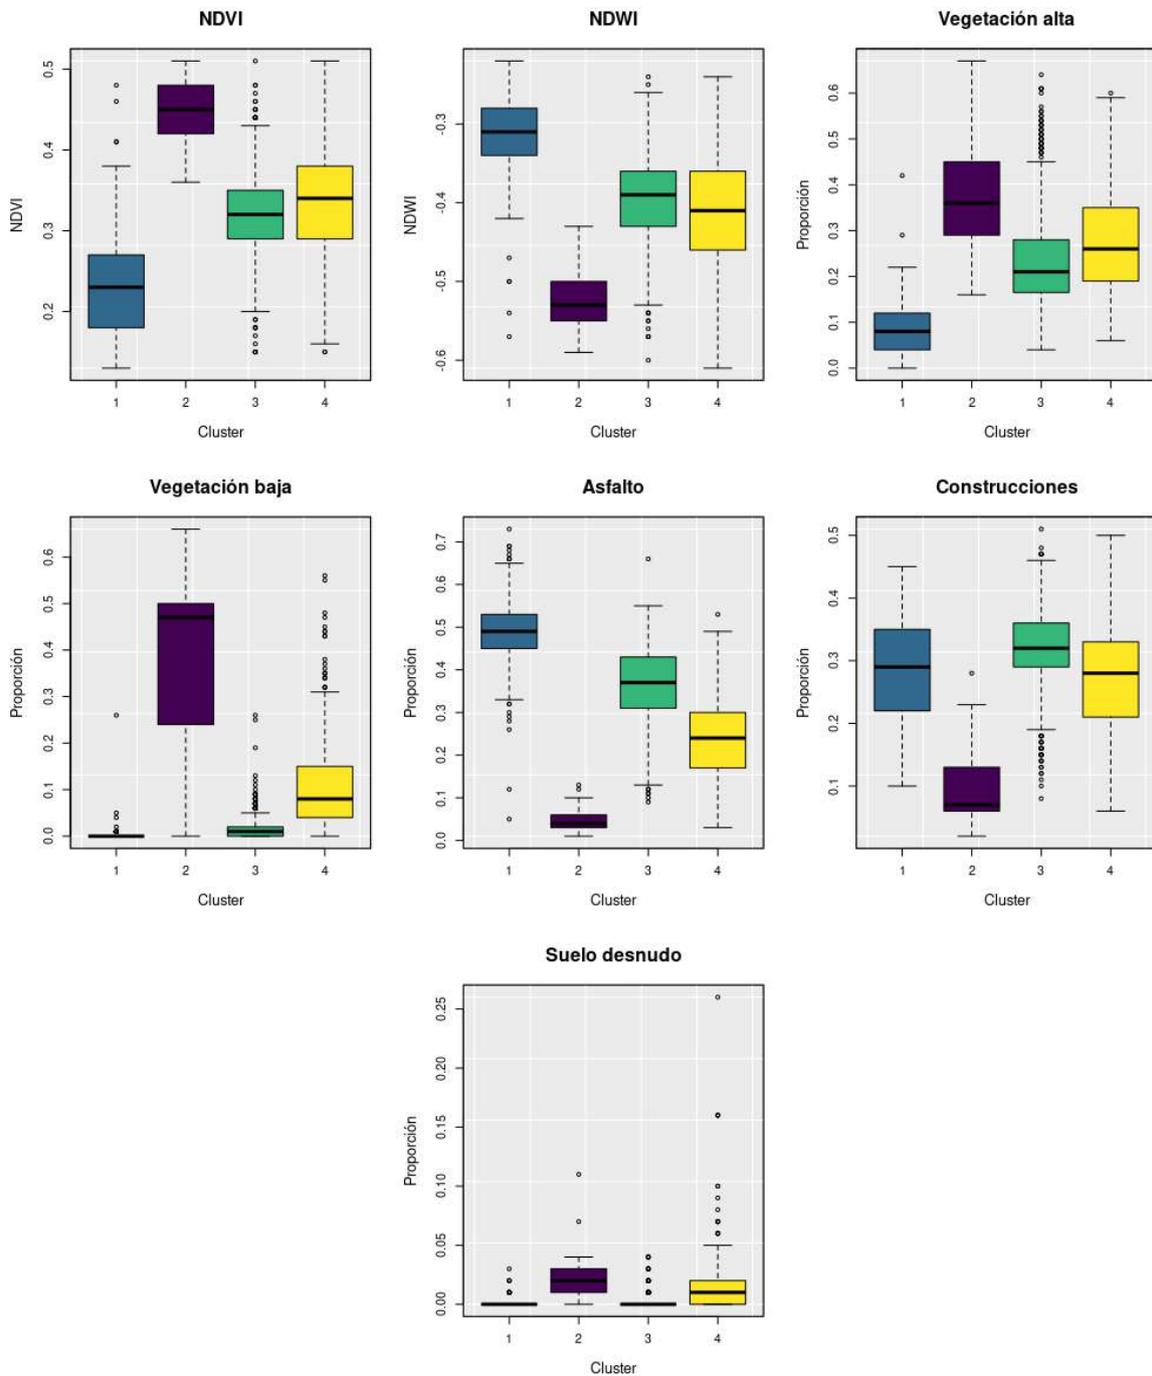


Figura 4.16: Boxplots de índices NDVI, NDWI y proporciones de clases obtenidas en función de los cuatro grupos ambientales obtenidos para los Radios censales de la Ciudad de Córdoba.

b. Barrios

Las Figuras 4.9 y 4.10 muestran los agrupamientos obtenidos para los barrios de la Ciudad de Córdoba. El *cluster* 1 agrupa la mayor cantidad de barrios de la Ciudad, con una densidad media de población. Como se observa en la Tabla 4.6 y en la Figura 4.17, es el grupo que tiene mayor Densidad de borde, y junto con el *cluster* 2 presenta altos valores de Entropía y Diversidad de Shannon, Índice de forma, Contigüidad y Agregación. El *cluster* 2 agrupa 24 barrios, de los cuales 6 se encuentran en el centro de la ciudad con una alta densidad poblacional. Dichos barrios corresponden a: Alto Alberdi, Alberdi, Centro, Alta Córdoba, General Pueyrredon y San Vicente. El resto de los barrios dentro de este cluster se distribuyen en el noroeste y sur de la ciudad. Este grupo ambiental presenta el valor más alto de Información mutua (Figura 4.17). En relación al *cluster* 3, el mismo incluye solo el 2% de la superficie total de barrios analizada, con un único barrio en la zona céntrica de la ciudad (San Rafael). El resto de barrios: Don Bosco, Valle Escondido, Parque Chateau Carreras, Villa Belgrano, Colina del Cerro, Poeta Lugones, Marques de Sobremonte y Ciudad de Juan Pablo II, se encuentran en el noroeste de la ciudad. Este grupo ambiental presenta los valores más bajos en todas las métricas analizadas (Tabla 4.6). En relación al resto de índices y proporciones por clase analizadas (Figura 4.18), no se observan diferencias significativas entre los tres grupos ambientales a nivel de barrios.

Tabla 4.6: Media aritmética para cada métrica del paisaje, índices NDVI, NDWI y proporción de cada clase por *cluster* para los barrios.

Cluster	1	2	3
Métrica / Media	\bar{x}	\bar{x}	\bar{x}
Entropía de Shannon	2 ± 0.2	2 ± 0.2	0.3 ± 0.1
Información mutua	1 ± 0.2	2 ± 0.2	0.2 ± 0.1
Área central total	36 ± 30	350 ± 190	0
Densidad de borde	2220 ± 390	1620 ± 560	200 ± 80
Riqueza de parches	7 ± 0.4	7	2 ± 1
Diversidad de Shannon	1 ± 0.1	1 ± 0.1	1 ± 0.4
Índice de agregación	90 ± 2	90 ± 3	30 ± 15
Índice de división	30 ± 25	24 ± 20	10 ± 5
Índice de forma	2 ± 0.1	2 ± 0.1	1 ± 0.1
Índice de contigüidad	0.7 ± 0.03	0.7 ± 0.01	0.1 ± 0.07
NDVI	0.4 ± 0.1	0.4 ± 0.1	0.4 ± 0.04
NDWI	-0.4 ± 0.06	-0.4 ± 0.06	-0.4 ± 0.06
Vegetación alta	0.3 ± 0.2	0.3 ± 0.1	0.3 ± 0.1
Vegetación baja	0.1 ± 0.1	0.1 ± 0.09	0.1 ± 0.09
Asfalto	0.2 ± 0.1	0.3 ± 0.1	0.3 ± 0.1
Construcciones	0.3 ± 0.2	0.3 ± 0.1	0.3 ± 0.1
Suelo desnudo	0	0	0

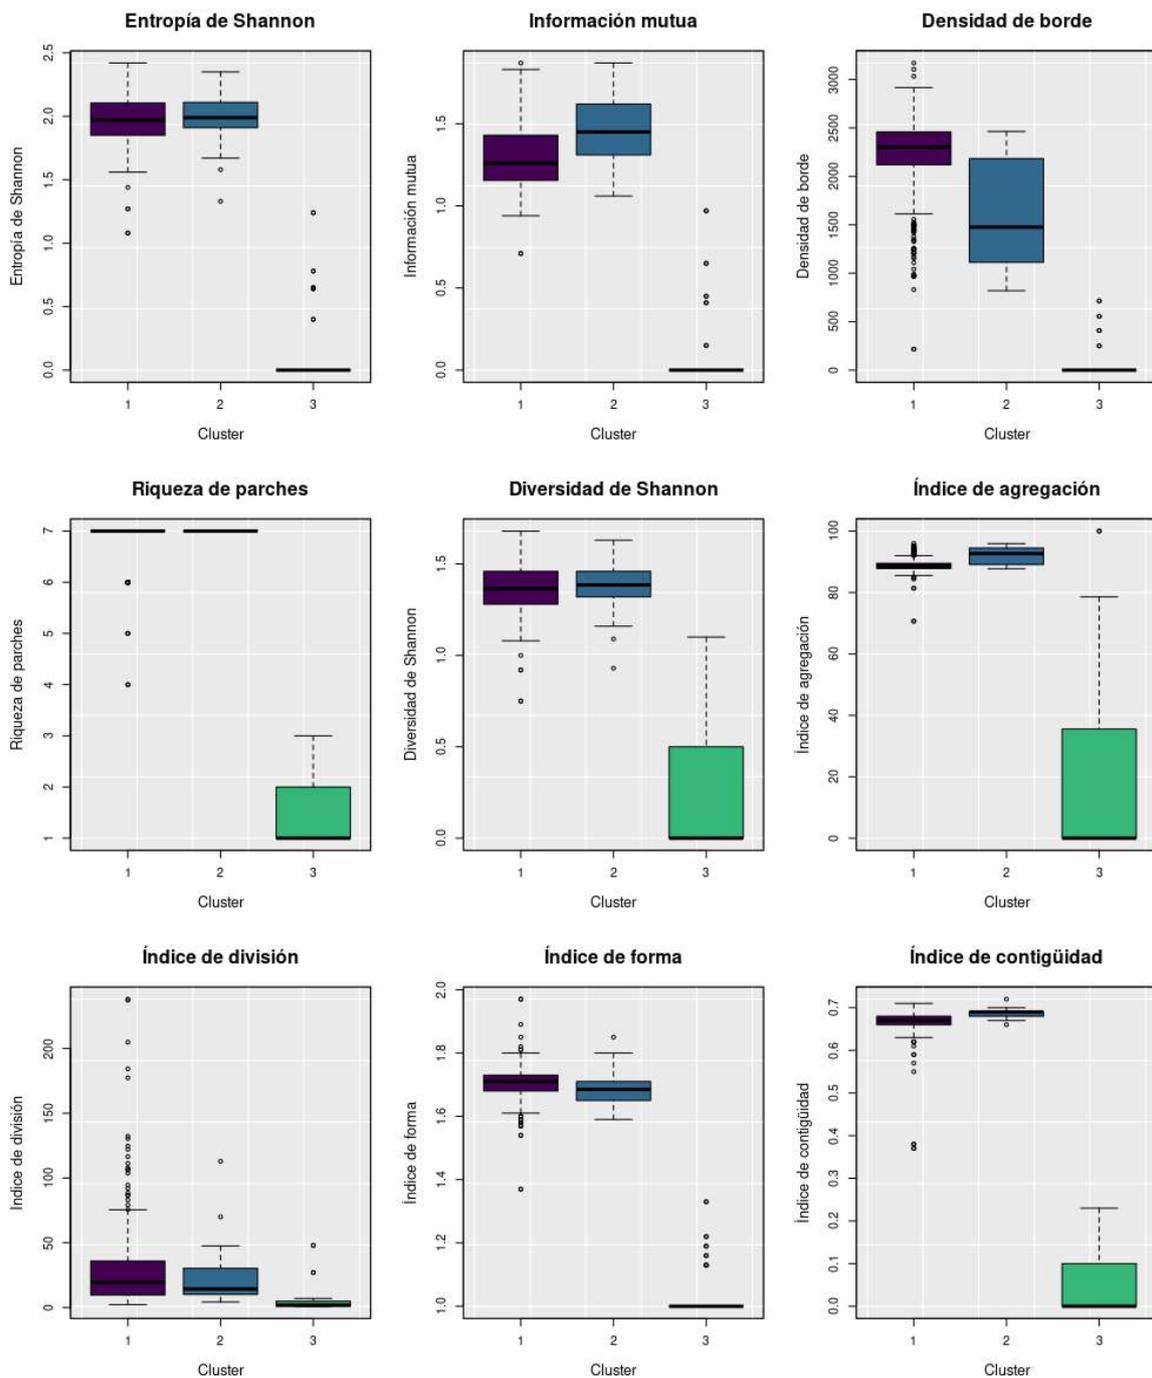


Figura 4.17: Boxplots de métricas estimadas a nivel de paisaje en función de los tres grupos ambientales obtenidos para los barrios de la Ciudad de Córdoba.

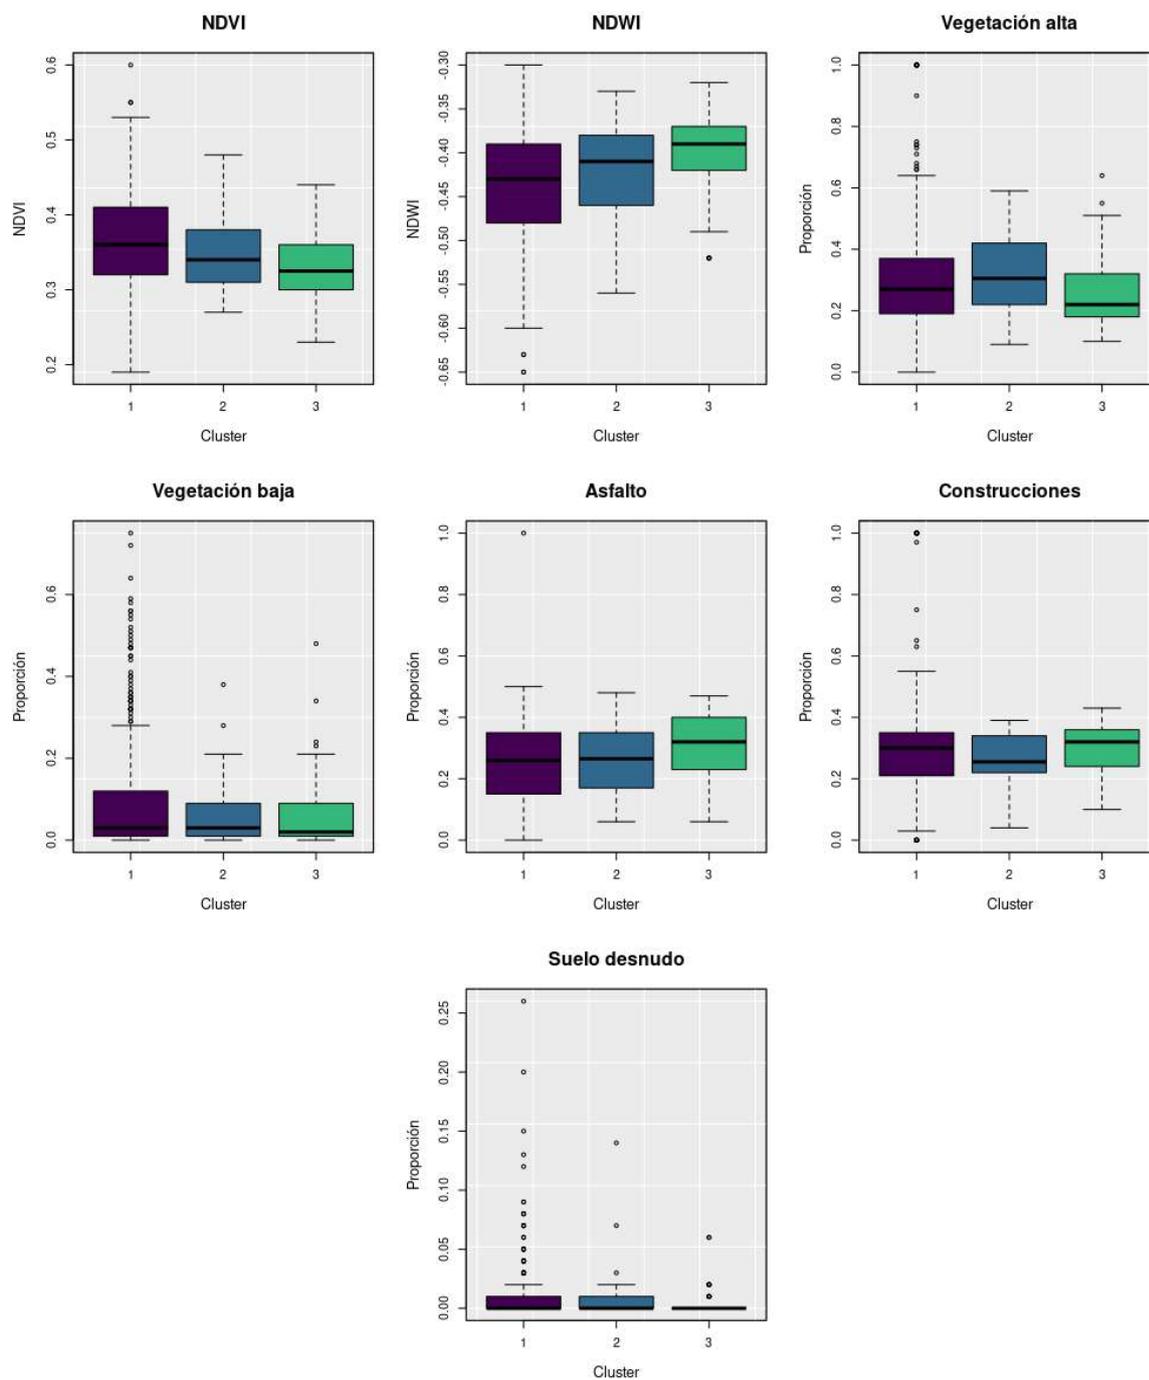


Figura 4.18: Boxplots de índices NDVI, NDWI y proporciones de clases obtenidas en función de los tres grupos ambientales obtenidos para los barrios de la Ciudad de Córdoba.

c. Polígonos de salud

El agrupamiento ambiental obtenido para los polígonos de salud generados en función de la distribución espacial de los centros de salud (Figuras 4.11 y 4.12) muestra un patrón similar al observado para el agrupamiento por radios censales (Figura 4.8).

El *cluster* 1 agrupó casi todos los polígonos de la periferia, correspondientes a zonas de baja densidad poblacional, a excepción de dos polígonos incluidos en el *cluster* 2. Ambos *clusters*, 1 y 2, presentaron los valores más bajos de densidad de borde e índice de forma y los valores más altos para el índice de agregación (Figura 4.19). En relación al índice NDVI y la proporción de vegetación (Figura 4.20), ambos *clusters* mostraron los valores más altos, coincidiendo con lo observado para el *cluster* 2 de radios censales. Dado que ambos grupos ambientales se ubicaron en la periferia de la ciudad, obtuvieron los valores más bajos de proporción de asfalto y construcciones. El *cluster* 3 agrupó polígonos del centro de la ciudad, con una alta densidad poblacional y obtuvo los valores más altos de división, forma y densidad de borde y, los más bajos para el índice de agregación, información mutua, NDVI y proporción de vegetación. Además, es el *cluster* que posee la mayor proporción de asfalto y construcciones, así como también valores altos de NDWI, dado que incluye los dos cursos de agua principales de la ciudad. Los *clusters* 3 y 4, agruparon polígonos de densidad media de población y obtuvieron los valores más altos de Entropía y Diversidad de Shannon, coincidiendo con los *clusters* 3 y 4 de los radios censales (Figura 4.15). En relación a la proporción de suelo desnudo, todos los *clusters* mostraron valores bajos sin diferencias significativas entre sí. La Tabla 4.7 resume las medidas estadísticas, media y desvío estándar, para cada métrica e índice analizado por grupo ambiental.

Tabla 4.7: Media aritmética para cada métrica del paisaje, índices NDVI, NDWI y proporción de cada clase por *cluster* para los polígonos de salud.

Cluster	1	2	3	4	5
Metrica / Media	\bar{x}	\bar{x}	\bar{x}	\bar{x}	\bar{x}
Entropía de Shannon	2 ± 0.1	2 ± 0.1	2 ± 0.1	2 ± 0.1	2 ± 0.1
Información mutua	1 ± 0.1	2 ± 0.03	1 ± 0.1	2 ± 0.1	2 ± 0.1
Área central total	800 ± 500	500000 ± 35000	14500 ± 4000	12000 ± 4000	300 ± 200
Densidad de borde	1100 ± 200	1300 ± 170	2200 ± 200	2100 ± 200	1600 ± 200
Riqueza de parches	7	7	7	7	7
Diversidad de Shannon	1 ± 0.1	1 ± 0.1	1 ± 0.1	2 ± 0.1	2 ± 0.1
Índice de agregación	90 ± 1	90 ± 1	90 ± 1	90 ± 1	90 ± 1
Índice de división	14 ± 7	25 ± 11	52 ± 45	36 ± 22	23 ± 13
Índice de forma	2	2	2	2	2
NDVI	0.5	0.5	0.3	0.3	0.4
NDWI	-0.5 ± 0.02	-0.5 ± 0.03	-0.4 ± 0.05	-0.4 ± 0.04	-0.5 ± 0.03
Vegetación alta	0.3 ± 0.1	0.4 ± 0.2	0.2 ± 0.1	0.3 ± 0.1	0.3 ± 0.1
Vegetación baja	0.3 ± 0.2	0.2 ± 0.3	0.1 ± 0.1	0.1 ± 0.1	0.2 ± 0.1
Asfalto	0.1	0.1	0.3 ± 0.1	0.3 ± 0.1	0.2 ± 0.1
Construcciones	0	0.2 ± 0.1	0.3 ± 0.1	0.3 ± 0.1	0.2 ± 0.1
Suelo desnudo	0	0	0	0	0

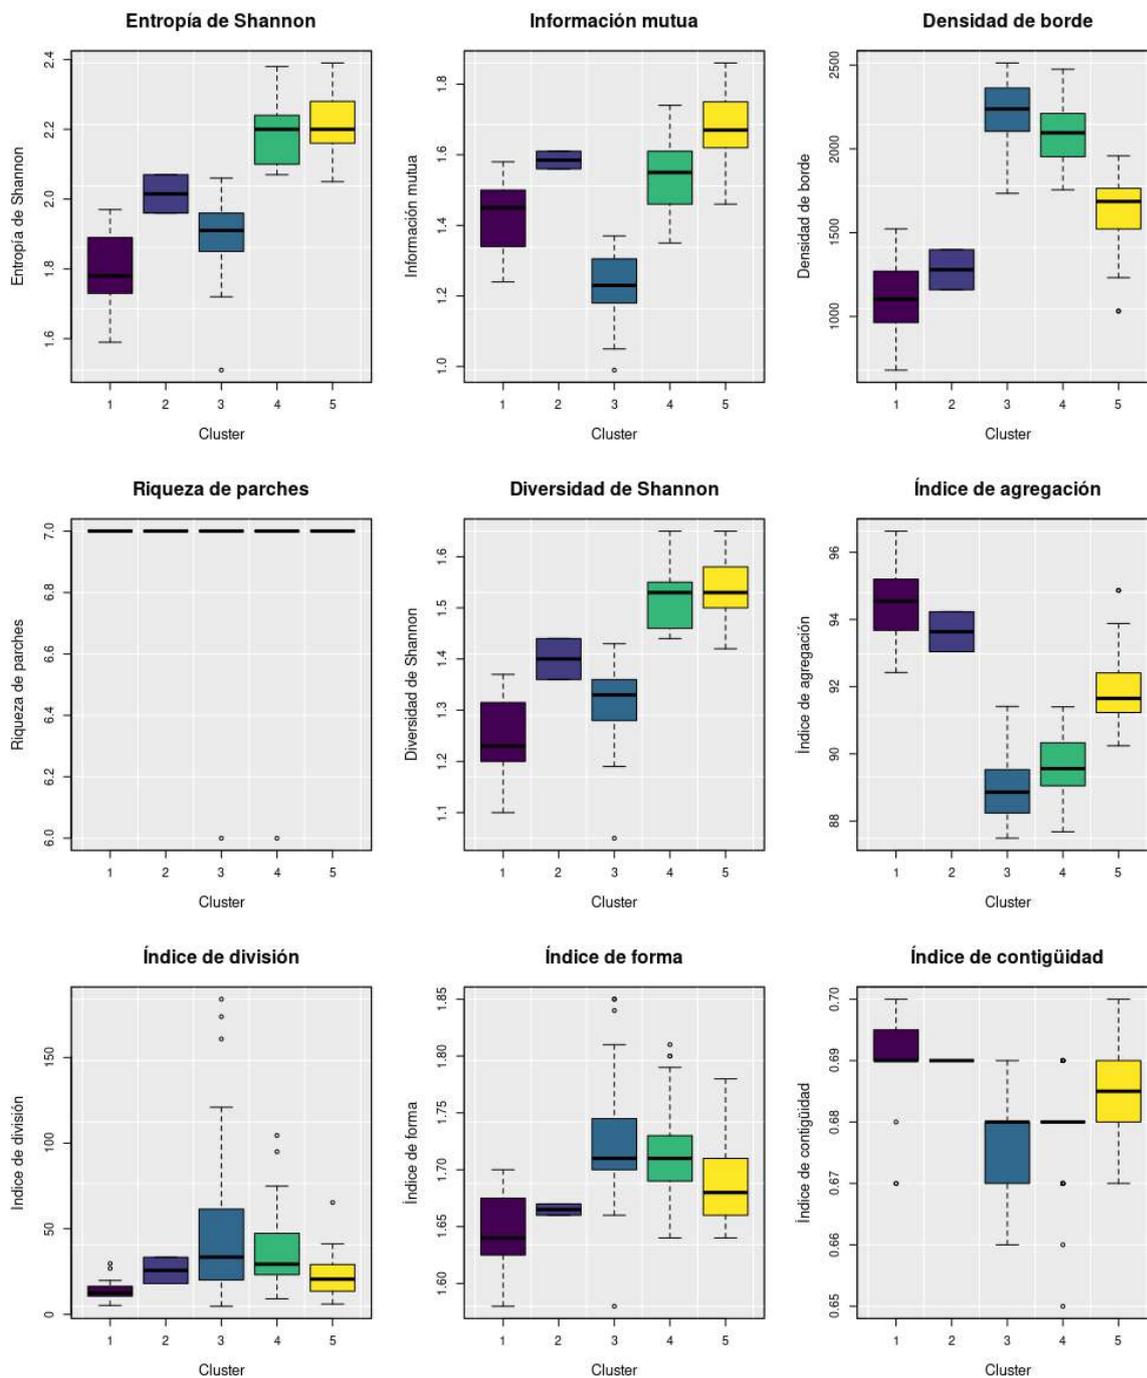


Figura 4.19: Boxplots de métricas del paisaje estimadas a nivel de paisaje en función de los cinco grupos ambientales obtenidos para los Polígonos de salud de la Ciudad de Córdoba.

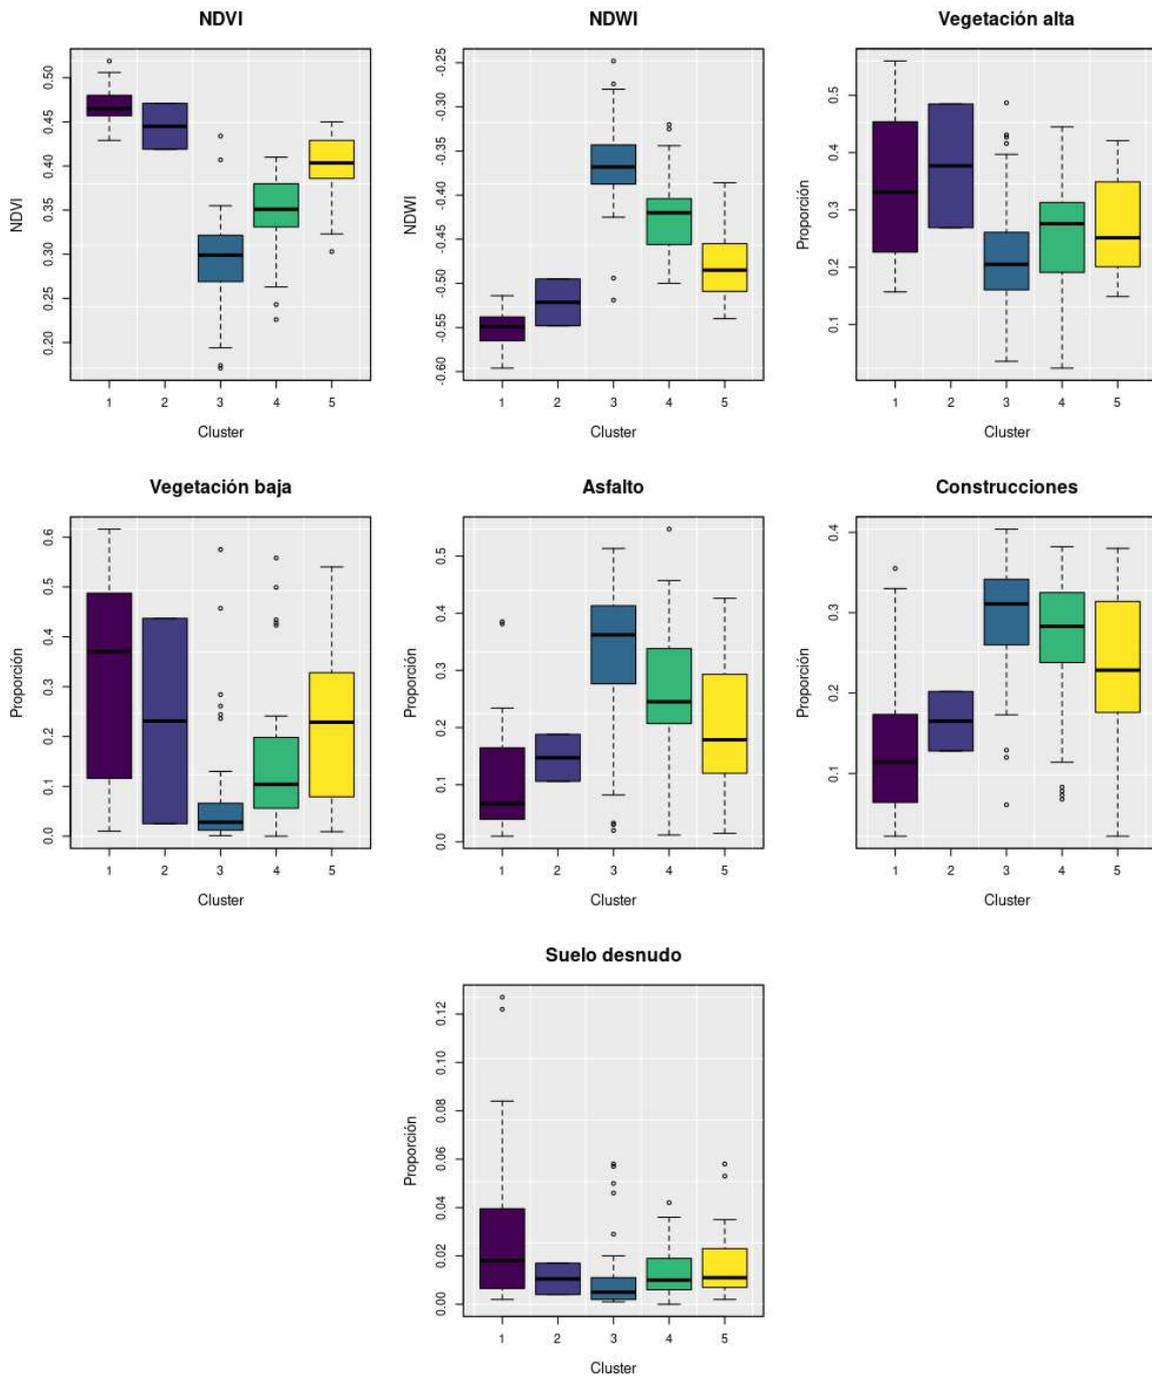


Figura 4.20: Boxplots de índices NDVI, NDWI y proporciones de clases obtenidas en función de los cinco grupos ambientales obtenidos para los Polígonos de salud de la Ciudad de Córdoba.

d. Grilla

De acuerdo al agrupamiento ambiental obtenido para la grilla (Figuras 4.13 y 4.14), se pueden diferenciar cuatro *clusters*. El *cluster* 1 está representado únicamente por dos celdas ubicadas en zonas agrícolas. La Figura 4.21 muestra los valores de cada métrica del paisaje estimada en función de los cuatro grupos ambientales obtenidos. En la misma se puede observar, que el *cluster* 1 presenta los valores más altos en casi todas las métricas: Entropía y Diversidad de Shannon, Información mutua, Densidad de borde e Índices de división y forma. Además, posee los valores más altos de NDVI y proporción de vegetación (Figura 4.22). El *cluster* 2 está representado por celdas ubicadas en los bordes de la Ciudad, con una densidad media de población y valores intermedios para casi todas las métricas e índices. El *cluster* 3, se ubica en el centro y noroeste de la ciudad, presentando los valores más altos de proporción de asfalto y construcciones, y más bajos de vegetación. El *cluster* 4 se ubica en la periferia de la ciudad, al igual que el *cluster* 1, en zonas agrícolas. Este grupo ambiental, presenta los valores más altos de contigüidad y agregación. Sin embargo, cuenta con los valores más bajos de Entropía y diversidad de Shannon, Densidad de borde e Información mutua. La Tabla 4.8 resume las medidas estadísticas, media y desvío estándar, para cada métrica e índice analizado por grupo ambiental.

Tabla 4.8: Media aritmética para cada métrica del paisaje, índices NDVI, NDWI y proporción de cada clase por *cluster* para la grilla.

Cluster	1	2	3	4
Métrica / Media	\bar{x}	\bar{x}	\bar{x}	\bar{x}
<i>Entropía de Shannon</i>	2 ± 0.2	2 ± 0.3	2 ± 0.4	1 ± 0.2
<i>Información mutua</i>	1.5 ± 0.2	1.2 ± 0.2	1.2 ± 0.2	0.8 ± 0.2
<i>Área central total</i>	121 ± 4	117 ± 12	30 ± 2.3	823 ± 42
<i>Densidad de borde</i>	1962 ± 400	935 ± 265	1140 ± 640	580 ± 265
<i>Riqueza de parches</i>	7	7	7	6
<i>Diversidad de Shannon</i>	1.4 ± 0.1	1.1 ± 0.2	1.1 ± 0.2	0.7 ± 0.1
<i>Índice de agregación</i>	90 ± 2	95 ± 1.3	94 ± 3.2	100 ± 1.3
<i>Índice de división</i>	32 ± 30	7 ± 3.3	8.2 ± 6.2	3.2 ± 1.3
<i>Índice de forma</i>	2	2	2	2
<i>Índice de contigüidad</i>	0.7	0.7	0.7	0.7
<i>NDVI</i>	0.6 ± 0.04	0.4 ± 0.04	0.3 ± 0.04	0.5 ± 0.04
<i>NDWI</i>	-0.7 ± 0.04	-0.5 ± 0.05	-0.40 ± 0.05	-0.6 ± 0.04
<i>Vegetación alta</i>	0.5 ± 0.2	0.3 ± 0.1	0.2 ± 0.1	0.4 ± 0.2
<i>Vegetación baja</i>	0.5 ± 0.2	0.3 ± 0.1	0.04 ± 0.04	0.5 ± 0.1
<i>Asfalto</i>	0	0.1 ± 0.1	0.3 ± 0.1	0
<i>Construcciones</i>	0	0	0	0
<i>Suelo desnudo</i>	0	0	0	0

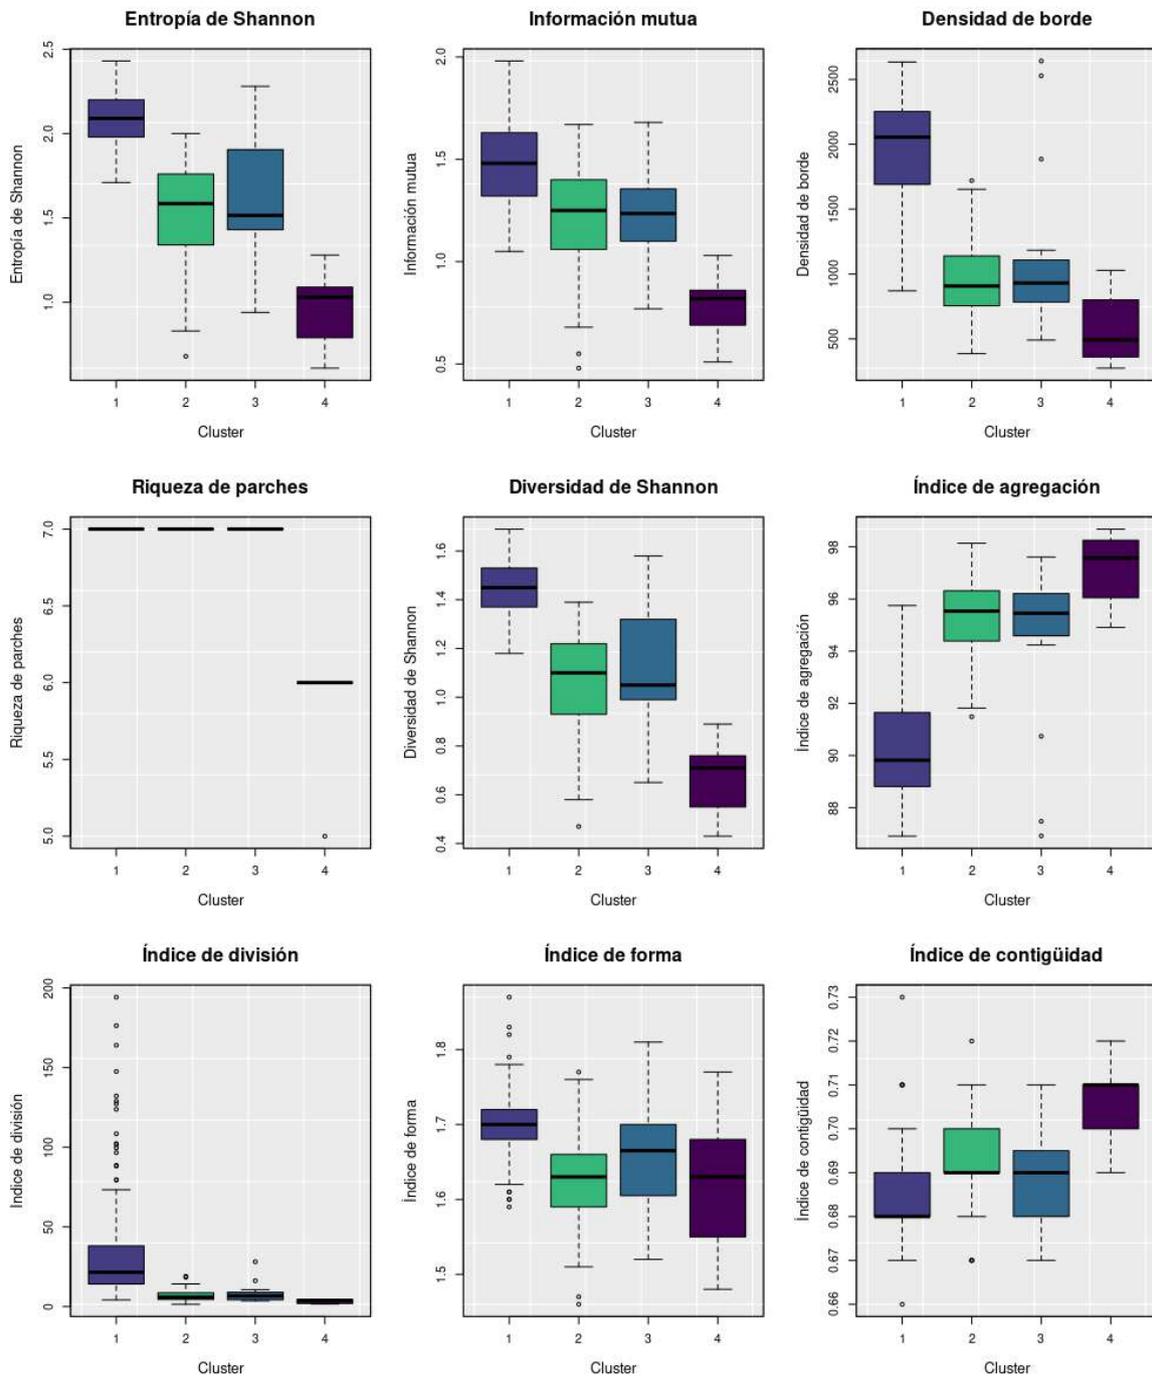


Figura 4.21: Boxplots de métricas del paisaje estimadas a nivel de paisaje en función de los cuatro grupos ambientales obtenidos para la grilla de la Ciudad de Córdoba.

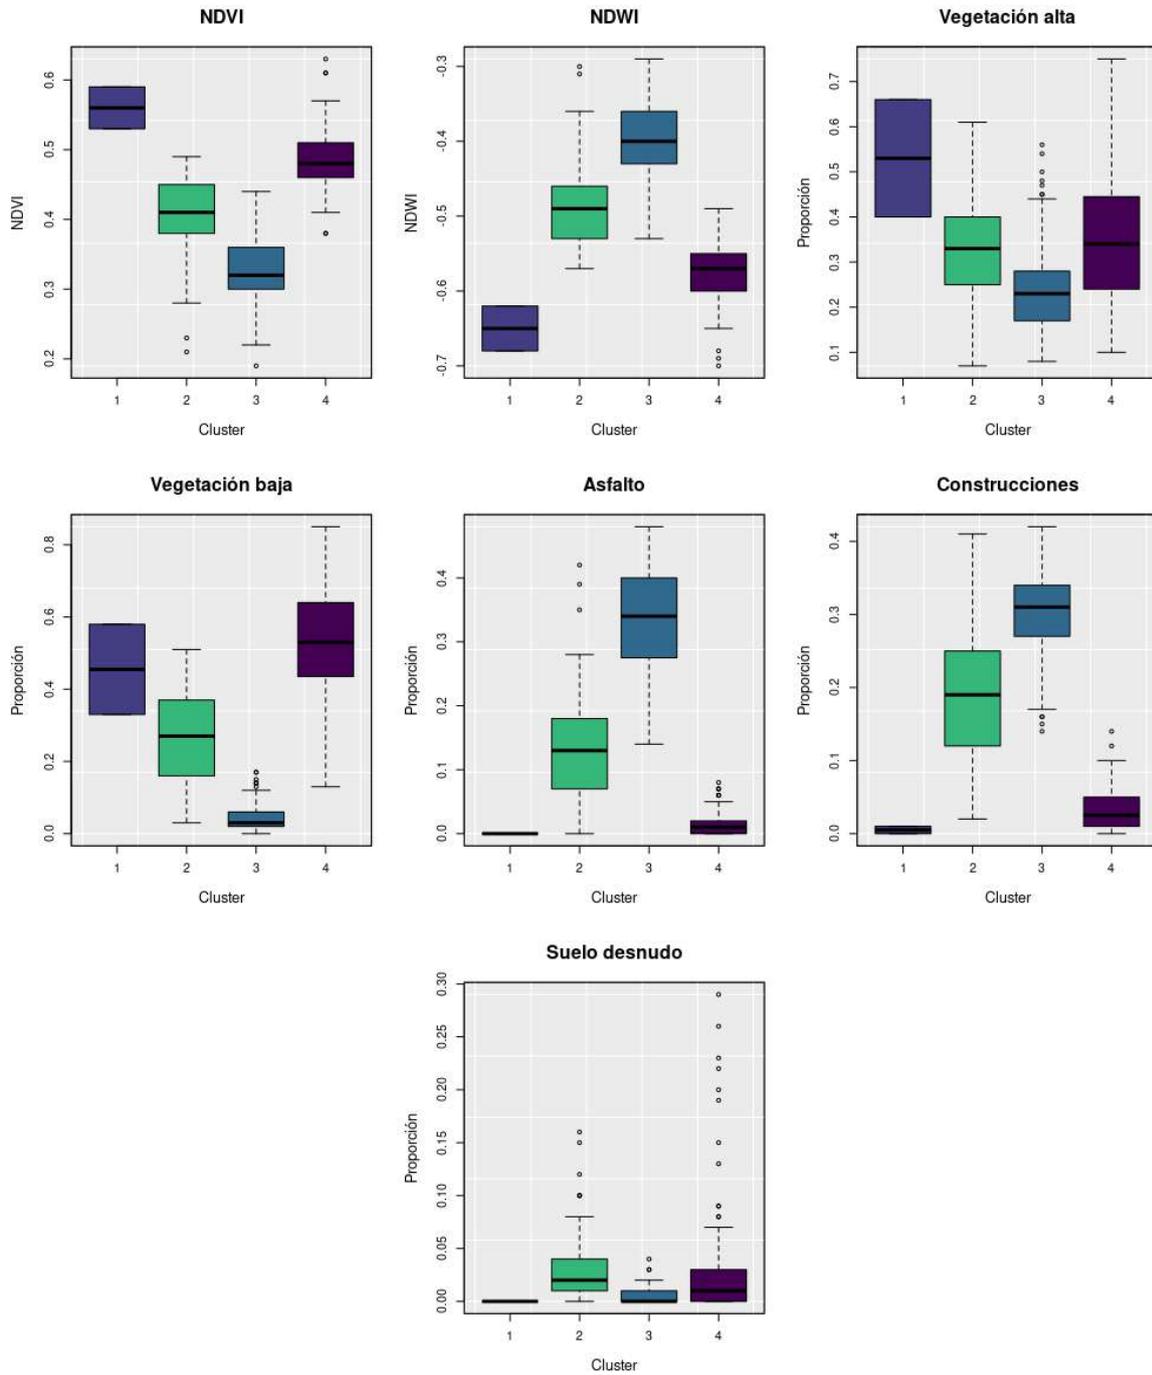


Figura 4.22: Boxplots de índices NDVI, NDWI y proporciones de clases obtenidas en función de los cuatro grupos ambientales obtenidos para la grilla de la Ciudad de Córdoba.

4.4. Discusión

En el presente capítulo, se caracterizó ambientalmente la ciudad de Córdoba a través de la estimación de diferentes métricas del paisaje y se generaron agrupamientos teniendo en cuenta cuatro criterios diferentes de organización espacial. Dado que los agrupamientos realizados con métricas a nivel de paisaje mostraron mayor consistencia que los obtenidos con métricas a nivel de clase se decidió presentar y caracterizar los *clusters* a nivel de paisaje.

En relación a los agrupamientos espaciales, se definió un número de 3 *clusters* para los barrios de la ciudad, 4 *clusters* para los radios censales y grilla de celdas regulares y, 5 *clusters* para los polígonos de salud. En general, los agrupamientos para polígonos de salud y radios censales, mostraron una mayor consistencia y precisión en los *clusters* obtenidos, en relación al análisis de PCA y al análisis visual de los mismos, en concordancia con el conocimiento previo sobre la ciudad. El análisis de PCA para el agrupamiento por *k-means* para los polígonos de salud fue el que mejor separabilidad de componentes obtuvo, diferenciando marcadamente los cinco grupos (Figura 4.11). Sin embargo, el *cluster* 2 de dicha capa solo agrupó 2 polígonos ubicados en regiones periféricas de la ciudad, que podrían agruparse con el *cluster* 1 de características similares (Figura 4.12). De esta forma, en coincidencia con los grupos obtenidos para los radios censales tanto en ubicación como en características, se podría considerar que existen cuatro grupos ambientales de relevancia para la Ciudad de Córdoba.

Los *clusters* por barrios de la ciudad presentaron poca variabilidad de índices y proporción de clases entre sí (Figura 4.18). Esto puede deberse a que los barrios son unidades espaciales a veces arbitrarias que incluyen a su interno diferentes condiciones de urbanización, vegetación y edificación (Figura 4.10), de modo que resulta dificultoso separarlos en grupos definidos. Por otro lado, los grupos ambientales identificados para la grilla, mostraron un claro patrón binario diferenciando lo urbano de lo no-urbano, determinando únicamente dos grupos ambientales dentro de la ciudad (*clusters* 2 y 3). En el análisis de PCA (Figura 4.13) se observa que estos grupos poseen una mayor superposición de puntos y menor separabilidad en el espacio en relación al resto.

Por lo anteriormente expuesto, teniendo en cuenta que el objeto final para caracterizar la Ciudad de Córdoba es aportar en el sistema de monitoreo urbano de *Ae. aegypti*, se considera que los agrupamientos por radios censales y polígonos de salud permiten una mejor descripción ambiental que el resto de capas analizadas, dado que consideran en mayor medida la variabilidad intra-urbana. De esta forma, desde afuera hacia el centro de la ciudad de Córdoba, los cuatro grupos principales podrían caracterizarse de la siguiente manera:

- Un primer grupo ambiental, marcadamente diferente al resto en las afueras de la ciudad representado principalmente por campos agrícolas, con un índice NDVI alto y una alta proporción de vegetación alta y baja. Dicho grupo se representa con el *cluster* 1 de polígonos de salud (Figura 4.12) y 2 de radios censales (Figura 4.8) en color violeta.
- Un segundo grupo intra-urbano, representado por sectores residenciales periféricos. Dicho grupo podría estar agrupando las zonas de crecimiento más recientes de la ciudad, con un índice de vegetación intermedio y una proporción de edificación relativamente baja en relación a otros sectores. Se representa con el *cluster* 5 para polígonos de salud y 4 para radios censales, en color amarillo.
- Un tercer grupo intra-urbano, representado tanto por zonas residenciales como comerciales. Este grupo ambiental, comparte con el anterior una proporción de vegetación

alta y baja intermedia pero presenta un mayor porcentaje de edificación y asfalto. Se representa con el *cluster* 4 para polígonos de salud y 3 para radios censales, en color verde.

- Y finalmente, un cuarto grupo intra-urbano en la zona céntrica de la Ciudad. Este grupo representa los sectores con mayor urbanización, edificación y asfalto de la ciudad, con el índice de vegetación más bajo y las menores proporciones de vegetación alta y vegetación baja. Se representa con el *cluster* 3 para polígonos de salud y 1 para radios censales, en color azul.

Teniendo en cuenta las características y preferencias del vector *Ae. aegypti* a la hora de elegir sitios de ovipostura en un ambiente urbano, el segundo y tercer grupo ambiental cumplirían con los requisitos necesarios para que el mismo se desarrolle. Dado que representan sectores principalmente residenciales y/o comerciales con suficiente vegetación para que el mosquito encuentre lugares de reposo diurnos y una variedad de criaderos artificiales. Por tal motivo, estos grupos podrían ser especialmente considerados a la hora de elegir los sitios de muestreo en el sistema de vigilancia de la Ciudad.

En términos generales, existen numerosos estudios que demuestran la potencialidad de los diferentes algoritmos de agrupamiento para caracterizar los ambientes urbanos. Thomas et al. (2010) (248) utilizaron la dimensión fractal y las curvas de comportamiento escalar para caracterizar las áreas urbanas a partir de la formación de *clusters k-medoid*, demostrando que regiones de ciudad con formas de crecimiento similares se agrupaban conjuntamente. Hamaina et al. (2012) (249) realizaron una caracterización de la forma urbana y del espacio libre usando como único dato la huella de las edificaciones, para un análisis de *clusters* a partir de *self-organized maps*. Gil et al. (2012) (250) utilizaron el algoritmo *k-means* para definir *clusters* de manzana y de segmentos de red vial –calles– a partir de variables de geometría, densidad, forma, uso del espacio público y topología de la red vial. Mientras tanto, Schrimmer y Axhausen (2015) (251) plantearon un análisis de grupos basado en el algoritmo *k-means* para distintas escalas: el tejido urbano, el distrito y el municipio.

A partir de las diferentes metodologías utilizadas en este trabajo se pueden mencionar algunas limitaciones o discrepancias encontradas. Por un lado, la estimación del número óptimo de *clusters* no coincidió entre los tres métodos seleccionados (Tabla 4.3). Esto suele ser esperable y la estimación de diferentes métodos suele estar enfocada en acotar el número de *clusters* probable en lugar de encontrar un número exacto. Si bien en la mayoría de los estudios suele optarse por implementar un único método de estimación, como en Albrieu et al. (2018) (105) que utilizan el método *Elbow* o Shi et al. (2014) (252) que implementan el método de *Silhouette*, en este trabajo se decidió evaluar y comparar diferentes criterios para poder elegir el número de *clusters* con mayor robustez.

Por otro lado, los métodos utilizados para la validación interna, sub-estimaron el número de *clusters* para todas las capas (Tabla 4.4). Algunos estudios muestran que este tipo de medidas de validación no siempre son precisas y, en general, tienden a subestimar el número óptimo de *clusters*. Baarsch y Celebi (2012) en (253) afirman que esto puede deberse a irregularidades en los conjuntos de datos o bien, en el mismo algoritmo *k-means* para encontrar los *clusters*. En este trabajo, las tres medidas de validación definieron un número de 2 *clusters* ambientales para casi todas las capas. Esto puede deberse a que, a grandes rasgos, lo primero que se diferencia en el área de estudio son dos grandes grupos: urbano vs no-urbano, debido a sus marcadas diferencias tanto en métricas como en índices de vegetación. Sin embargo, dado que nuestro mayor interés radica en la diferenciación de grupos al interno de la cobertura urbana, flexibilizamos estos criterios para poder distinguir grupos intra-urbanos.

Como consideraciones finales y propuestas futuras, para caracterizar aún mejor la composición y estructura de la Ciudad de Córdoba, se podrían incorporar nuevas métricas del paisaje e índices como variables de entrada para generar los agrupamientos. Por otro lado, en esta tesis se evaluó únicamente el algoritmo de agrupamiento *k-means*, dado que su uso está fuertemente consolidado y establecido en trabajos anteriores de agrupamientos espaciales. Sin embargo, se podrían evaluar y considerar otros algoritmos de agrupamiento como agrupamientos jerárquicos (en inglés *Hierarchical Clustering*) o GeoPAT2 (254).

Distribución de ovitrampas para el Sistema de Monitoreo de la Ciudad de Córdoba: su relación con la variabilidad ambiental y la incidencia de Dengue

5.1. Introducción

La vigilancia de *Aedes aegypti* consiste en establecer cuántos mosquitos existen en un lugar y tiempo determinados, y en la captura de especímenes para examinar sus propiedades (tamaño, condición fisiológica, sexo) y determinar el grado de resistencia a insecticidas, el origen de la sangre ingerida o la presencia de virus. Una aplicación importante de la vigilancia o monitoreo es la evaluación del impacto de las actividades de control en la reducción de la población de mosquitos y el cálculo del umbral de densidad de mosquitos requerido para que exista transmisión de arbovirus. Además, permite establecer si una nueva especie de vectores ha invadido un área (por ejemplo, *Ae. albopictus*) (89).

Existen varios métodos para determinar la distribución y abundancia de *Ae. aegypti* en un área dada (89). Algunos utilizan índices derivados de datos sobre la presencia o ausencia del vector (índices larvarios como el de casas, el de recipientes o el de Breteau). Otros permiten estimar la densidad absoluta (como el método de marcación, liberación y recaptura, aspiración de mosquitos dentro y fuera de las casas, muestreo de pupas), y otros estiman la densidad relativa (ovitrampas, hembras atraídas con cebo humano, trampas para mosquitos adultos).

Una de las técnicas más implementadas para la vigilancia y el monitoreo de poblaciones de mosquitos es mediante la distribución de ovitrampas. Estos dispositivos son envases pequeños de metal, plástico o vidrio, normalmente pintados de negro. Se les añade agua o infusión de heno como atrayente para las hembras grávidas y un sustrato para recibir los huevos (paleta de madera, tela, papel de germinación) (255). Las ovitrampas se examinan una vez por semana para evitar que se conviertan en criaderos de *Ae. aegypti*; se colocan en lugares sombreados y protegidos de la lluvia, de manera que los huevos no eclosionen antes de la recolección. Además, las ovitrampas pueden tratarse con *Bacillus thuringiensis israelensis* para evitar que se desarrollen las larvas y emerjan adultos, lo cual permite, además, prolongar

el tiempo de inspección de la trampa por más de una semana (256). Algunas de las ventajas de las ovitrampas como método para evaluar la abundancia relativa de *Ae. aegypti* es su bajo costo, la facilidad para colocarlas fuera de las casas, lo cual evita tener que entrar en ellas, y su fácil mantenimiento. Los datos que se derivan de este método son el número de huevos por ovitrampa y el porcentaje de trampas positivas (al menos un huevo por trampa).

El número de ovitrampas que se requiere para lograr estimaciones adecuadas de la oviposición varía entre 30 y 100, dependiendo del área de estudio. Algunos programas de control usan entre una y cuatro ovitrampas por manzana o cuadra (257). Aunque no siempre es el caso, en algunos estudios de campo se han evidenciado relaciones significativas y positivas entre el número de huevos por ovitrampa y la incidencia del dengue (258; 259).

Existen diferentes técnicas de muestreo para distribuir ovitrampas en un área de estudio (260). La elección de la misma puede ser arbitraria, por conveniencia y accesibilidad a las viviendas o bien, responder a algún patrón en particular. Algunas de estas técnicas de muestreo posibles a implementar son el muestreo aleatorio, en donde la selección o distribución de muestras se deja completamente al azar; el muestreo por estratos, en donde se consideran grupos homogéneos teniendo en cuenta alguna/as variables y se distribuyen muestras de manera proporcional al área de cada grupo o bien un muestreo arbitrario/sistemático en forma de grilla que divide el área de interés en celdas de igual tamaño (260).

En la Ciudad de Córdoba, desde el año 2017 se implementa un programa de vigilancia y monitoreo de *Ae. aegypti* mediante la distribución de ovitrampas en diferentes barrios de la ciudad. Originalmente, la distribución de las mismas se organizó en cinco regiones particulares de la ciudad (noroeste, noreste, centro, sureste y suroeste). En el 2020, con el inicio de la pandemia por Covid-19, la revisión de las ovitrampas se vio dificultada por falta de personal y acceso a las viviendas, por lo que se cambió su distribución y se redujo el total de ovitrampas de 150 a 100. En este marco, teniendo en cuenta que hasta el momento nunca se evaluó qué tan representativa de la variabilidad ambiental presente en la ciudad es la distribución de ovitrampas, siendo que dicha variabilidad puede influir en la distribución del vector, los objetivos del presente capítulo son:

1. Evaluar la distribución actual de ovitrampas del sistema de monitoreo de *Aedes aegypti* de la ciudad de Córdoba en cuanto a la representación de distintos grupos ambientales obtenidos en el capítulo anterior;
2. Analizar la distribución de los casos del último brote de Dengue y su relación con los grupos ambientales obtenidos y;
3. Analizar distintos criterios de distribución de ovitrampas y proponer una nueva distribución, considerando alternativas que maximicen la variabilidad ambiental y consideren la incidencia de dengue en el pasado brote de 2020.

5.2. Materiales y métodos

5.2.1. Datos entomológicos: distribución de ovitrampas

Los datos entomológicos se obtuvieron a partir del proyecto de vigilancia y monitoreo de *Ae. aegypti* del Ministerio de Salud de la provincia en la Ciudad de Córdoba. Los mismos consisten en datos georreferenciados de dos tipos de distribuciones de ovitrampas: la distribución correspondiente al periodo 2017-2019 de 150 ovitrampas, y la distribución actual (2020-presente) de 100 ovitrampas (Figura 5.1). Las casas con ovitrampas se ubican a más de 150 metros de distancia entre sí, y cada una cuenta con una ovitrampa en el patio delantero, generalmente en lugares sombreados y debajo o cerca de arbustos o macetas con plantas.

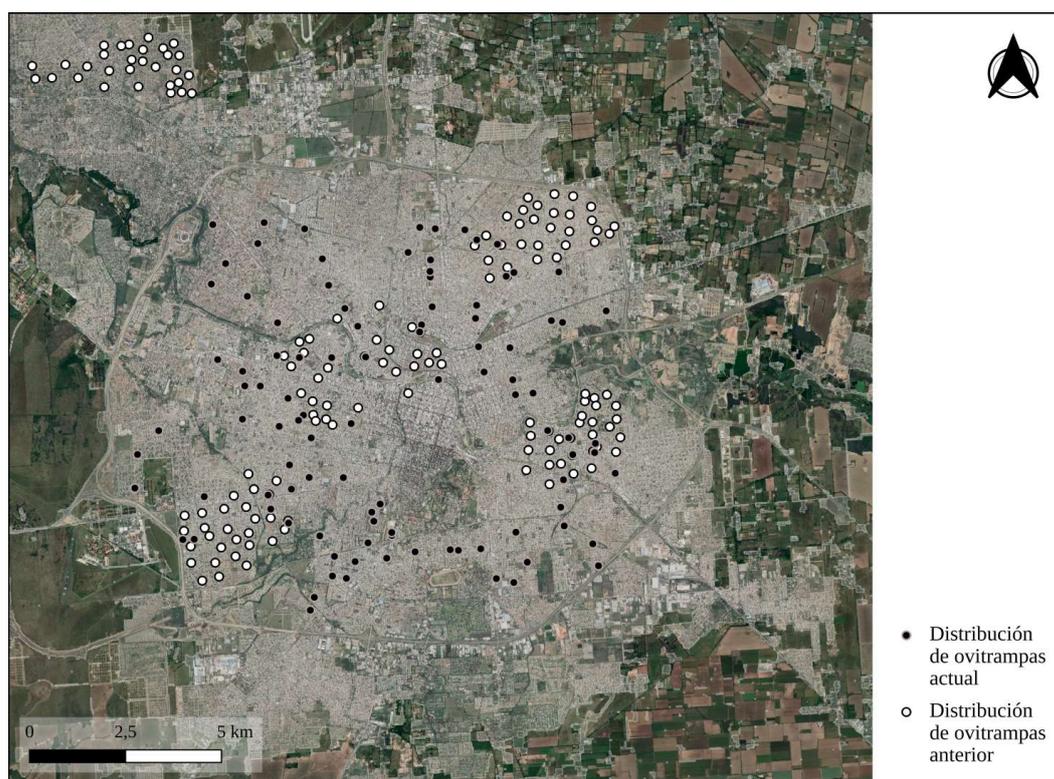


Figura 5.1: Distribución anterior (2017-2019) y actual (2020-actual) de ovitrampas del Ministerio de Salud para el sistema de monitoreo de *Aedes aegypti* de la Ciudad de Córdoba.

5.2.2. Datos epidemiológicos: distribución de casos de Dengue

La ubicación de los casos de dengue importados y autóctonos de la Ciudad de Córdoba fue provista por las autoridades sanitarias de la provincia (Figura 5.2). En total, hubo 2755 casos de dengue en la ciudad durante la temporada 2019-2020, 28 fueron importados y 2727 autóctonos, de los cuales se cuenta con 2491 pares de coordenadas. Para el análisis de distribución de casos de dengue del presente capítulo, se utilizaron únicamente los casos de dengue autóctonos.

Para conocer la relación entre la distribución de casos de dengue y los diferentes grupos ambientales obtenidos en el capítulo anterior, se estimó la cantidad y porcentaje de casos por *cluster* según cada criterio de organización espacial, mediante la función de filtro de campos vectoriales del software QGIS.

5.2.3. Datos poblacionales y cálculo de incidencia

A partir de datos demográficos de Argentina del 2020 obtenidos de la base de datos *World-Pop* (261), se estimó la población de la ciudad de Córdoba por polígono en función de cada capa. Los datos demográficos están disponibles en formato Geotiff con una resolución espacial de 100 m en el sistema de coordenadas geográfico WGS84. Las unidades corresponden al número de personas por pixel con los totales de los países ajustados para que coincidan con las correspondientes estimaciones oficiales de población de las Naciones Unidas.

Para la estimación de población por polígono se utilizó el módulo *v.rast.stats* (246) de GRASS GIS. El mismo calcula estadísticas univariadas de un mapa raster y carga las estadísticas en nuevas columnas de atributos de un mapa vectorial. Para estimar los casos de dengue por polígono se utilizó el módulo *v.vect.stats* (262) del software GRASS GIS, que permite calcular estadísticas a partir de los atributos de puntos. Los datos poblacionales junto con los casos de dengue permitieron calcular la incidencia para cada criterio de organización espacial considerado. El cálculo de la misma se realizó mediante la calculadora de campos del software QGIS como: $\text{Número de casos} / \text{Población} * 10.000 \text{ habitantes}$.

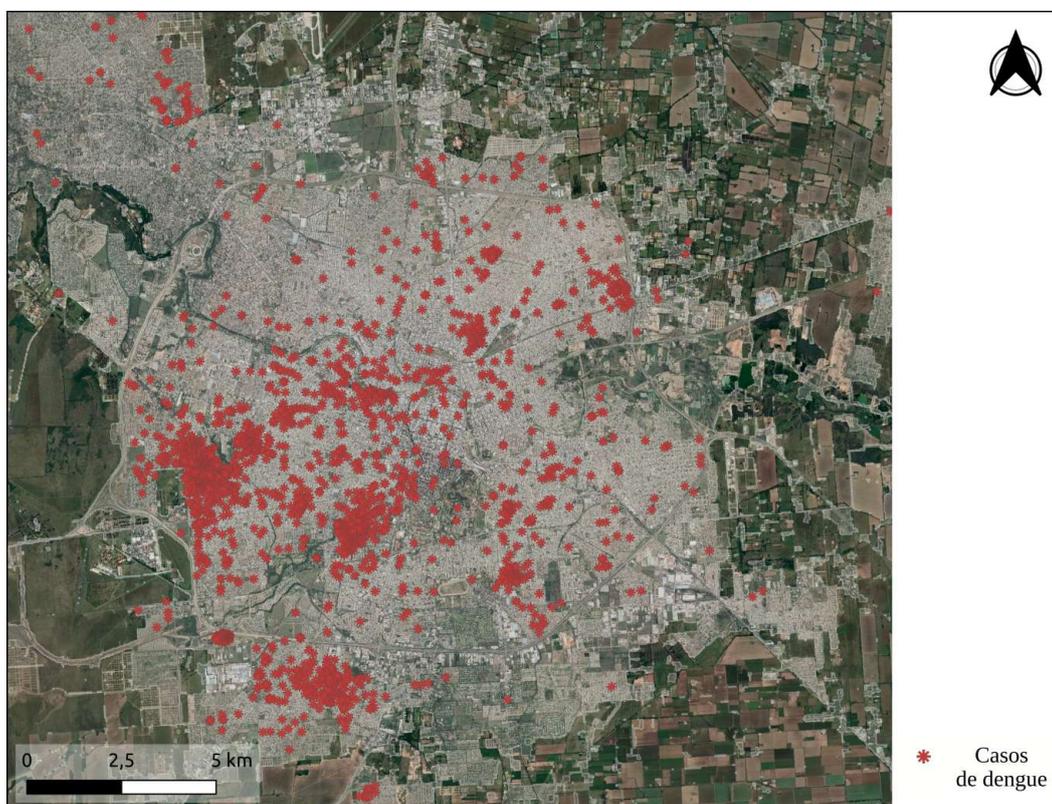


Figura 5.2: Casos autóctonos de dengue durante el 2020.
Fuente: Ministerio de Salud de la provincia de Córdoba.

5.2.4. Análisis de la distribución de ovitrampas

Además de considerar las distribuciones implementadas por el Ministerio de Salud de la provincia, se generaron nuevas distribuciones probables para un total de 150 ovitrampas. Para esto, se eligieron diferentes criterios de distribución según las diferentes técnicas de muestreo que se pueden implementar en un trabajo de campo. A continuación, se resumen algunas presentadas en Torri et al. (2017) (260):

- a. **Muestreo aleatorio simple:** Consiste en la técnica de muestreo más simple de todas (Figura 5.3a). La selección de las muestras se deja completamente al azar. Es un método por el que cada muestra tiene la misma probabilidad de ser tomada y considerada. En un área de estudio homogénea es un método satisfactorio, pero si existe una gran variabilidad o heterogeneidad ambiental es mejor usar otro método.
- b. **Muestreo aleatorio sistemático:** Este muestreo se efectúa sistemáticamente, a intervalos fijos (Fig. 5.3). Este tipo de muestreo da resultados más exactos que el muestreo al azar porque las muestras se distribuyen regularmente en toda la superficie. Sin embargo, si el área presenta una variación periódica o sistemática de una propiedad, o si el intervalo entre muestras sucesivas coincide con el ritmo de variación, se obtendrán muestras sesgadas, por lo que antes de proceder con este tipo de muestreo se recomienda hacer un estudio preliminar para conocer la naturaleza y variabilidad del área de estudio. En el muestreo sistemático, las muestras se ubican en un patrón regular en toda la zona de estudio; puede realizarse a partir de un punto determinado al azar, a partir del cual se establece cierta distancia para ubicar los demás puntos a distancias uniformes entre sí. Este tipo de muestreo puede realizarse por rejilla rectangular o polar (Fig. 5.3c). También puede seguir un diseño particular (Fig. 5.3e y 5.3g) o sobre diagonales que parten de los puntos más extremos del área (Figura 5.3f) (263).
- c. **Muestreo aleatorio estratificado:** Se emplea normalmente en áreas heterogéneas. Para ello, se divide el área en partes relativamente homogéneas, a las que se denomina “estratos” y en cada una de ellas se realiza un muestreo sistemático o al azar, tomando un número de muestras proporcional al área que representan respecto al total (Fig. 5.3b).
- d. **Muestreo en grilla:** Es una técnica de muestreo intensiva y costosa de realizar en áreas grandes (Fig. 5.3h). Las muestras son tomadas a intervalos regulares en todas las direcciones, analizándose por separado. Cada muestra provee información acerca de la variabilidad en rangos cortos dentro del área.
- e. **Muestreo por conglomerados:** Consiste en elegir de forma aleatoria ciertos barrios o conglomerados dentro de una región, ciudad, comuna, etc., para luego elegir unidades más pequeñas como cuadras, calles, etc. y finalmente otras más pequeñas, como escuelas, consultorios, hogares (una vez elegido esta unidad, se aplica el instrumento de medición a todos sus integrantes).

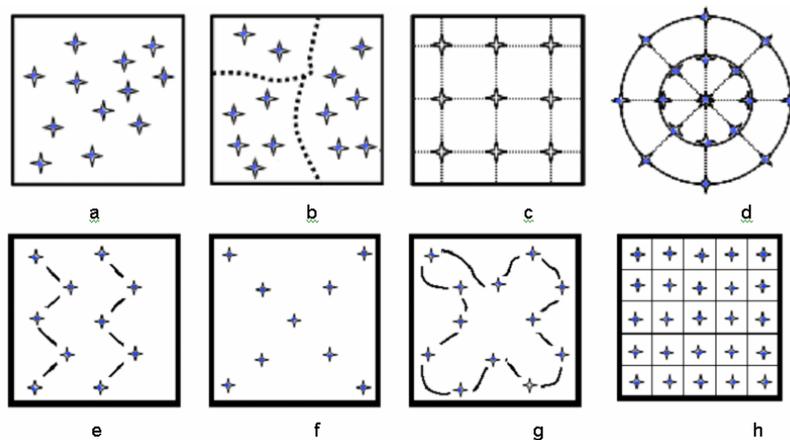


Figura 5.3: Técnicas de muestreo probabilísticas: a) Aleatorio simple; b) Aleatorio estratificado; c) Sistemático en rejilla rectangular; d) Sistemático en rejilla polar; e) zig-zag; f) Diagonal; g) Circular; h) Grilla. Fuente: Torri et al. (2017).

Teniendo en cuenta las técnicas de muestreo descritas, para esta tesis se consideraron las siguientes distribuciones:

- Distribución 2017-2019 y 2020-actual del Ministerio de Salud.
- Distribución al azar. Con una distancia mínima de 300 metros entre ovitrampas.
- Distribución sistemática. Con una distancia de 1000 metros entre ovitrampas.
- Distribución estratificada por *clusters* para cada capa. Con un número de ovitrampas proporcional a la superficie ocupada por cada *cluster*.
- Distribución al azar en polígonos con una incidencia mayor a 0.
- Distribución estratificada por *clusters* e incidencia para cada capa, considerando polígonos con una incidencia mayor a 0.

Para generar las capas vectoriales de puntos de distribución al azar y sistemática, se utilizaron las herramientas de investigación vectorial del software QGIS, mediante la función *Puntos aleatorios en polígonos* y *Puntos regulares*, definiendo la distancia mínima entre ovitrampas. Para la distribución de ovitrampas estratificada por *clusters*, se utilizó la función *strata* para generar estratos del paquete *sampling* (264) del software R. En el Anexo C.1 se presenta el código implementado en R para generar los puntos por estratos para la grilla como ejemplo. Para la distribución por incidencia, se utilizó el filtro de campos vectoriales del software QGIS para considerar polígonos que tuvieran una incidencia mayor a 0 y luego, se generaron puntos aleatorios dentro de los polígonos filtrados. Para la distribución estratificada por *clusters* e incidencia se siguieron los mismos pasos, generando los puntos en los polígonos de cada *cluster*.

Para las distribuciones estratificadas, se determinó una cantidad de ovitrampas por *cluster* proporcional al área ocupada por cada uno. Para esto, primero se estimó el área (en km²) y superficie total cubierta por cada *cluster*, mediante el módulo de reporte de estadísticas *r.report* [↗](#) (265) del software GRASS GIS. Luego, se seleccionaron aquellos *clusters* ubicados en la ciudad de Córdoba (excluyendo zonas agrícolas y periféricas) y en cada estrato (o *cluster*) se distribuyeron ovitrampas al azar.

Para analizar los distintos criterios de distribución en relación a los grupos ambientales obtenidos en el capítulo anterior, se calculó el área de cobertura de las ovitrampas por *cluster* según las cuatro capas analizadas: Radios censales, Barrios, Polígonos de salud y Grilla. Para esto, se generaron *buffers* o zonas de influencia alrededor de cada ovitrampa con un radio de 150 metros (teniendo en cuenta el rango de vuelo promedio de las hembras de *Ae. aegypti*, ver detalle en Figura 5.4), y se estimó el área cubierta por ovitrampas según cada grupo ambiental, con el mismo módulo mencionado anteriormente para la estimación del área total (*r.report*). Además, se calculó el número y porcentaje de ovitrampas total por cada *cluster* según las cuatro capas. La Figura 5.5 muestra el flujo de trabajo implementado en este capítulo.

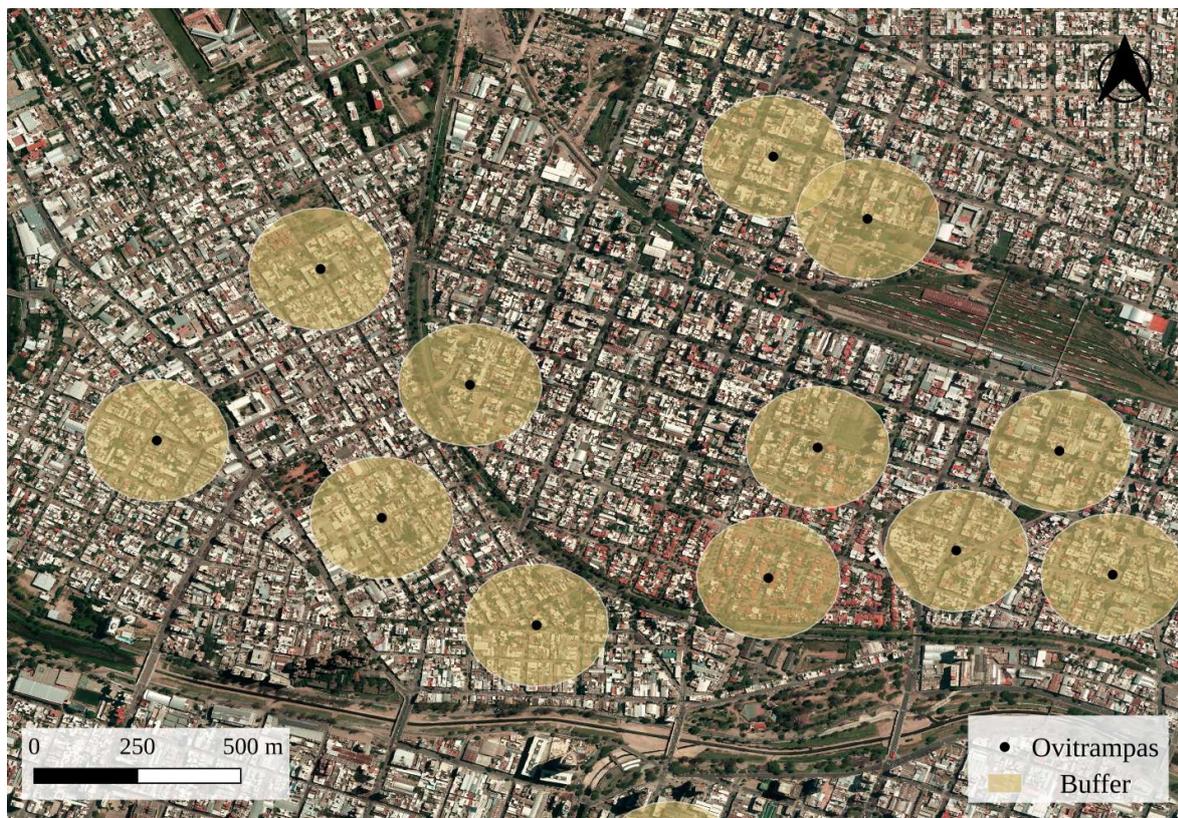


Figura 5.4: Detalle de *buffers* generados, con un radio de 150 metros, para el cálculo del área de cobertura de las ovitrampas. Imagen área de la ciudad de Córdoba, adquirida en 2016 con una resolución espacial de 20 cm. (Fuente: IGN)

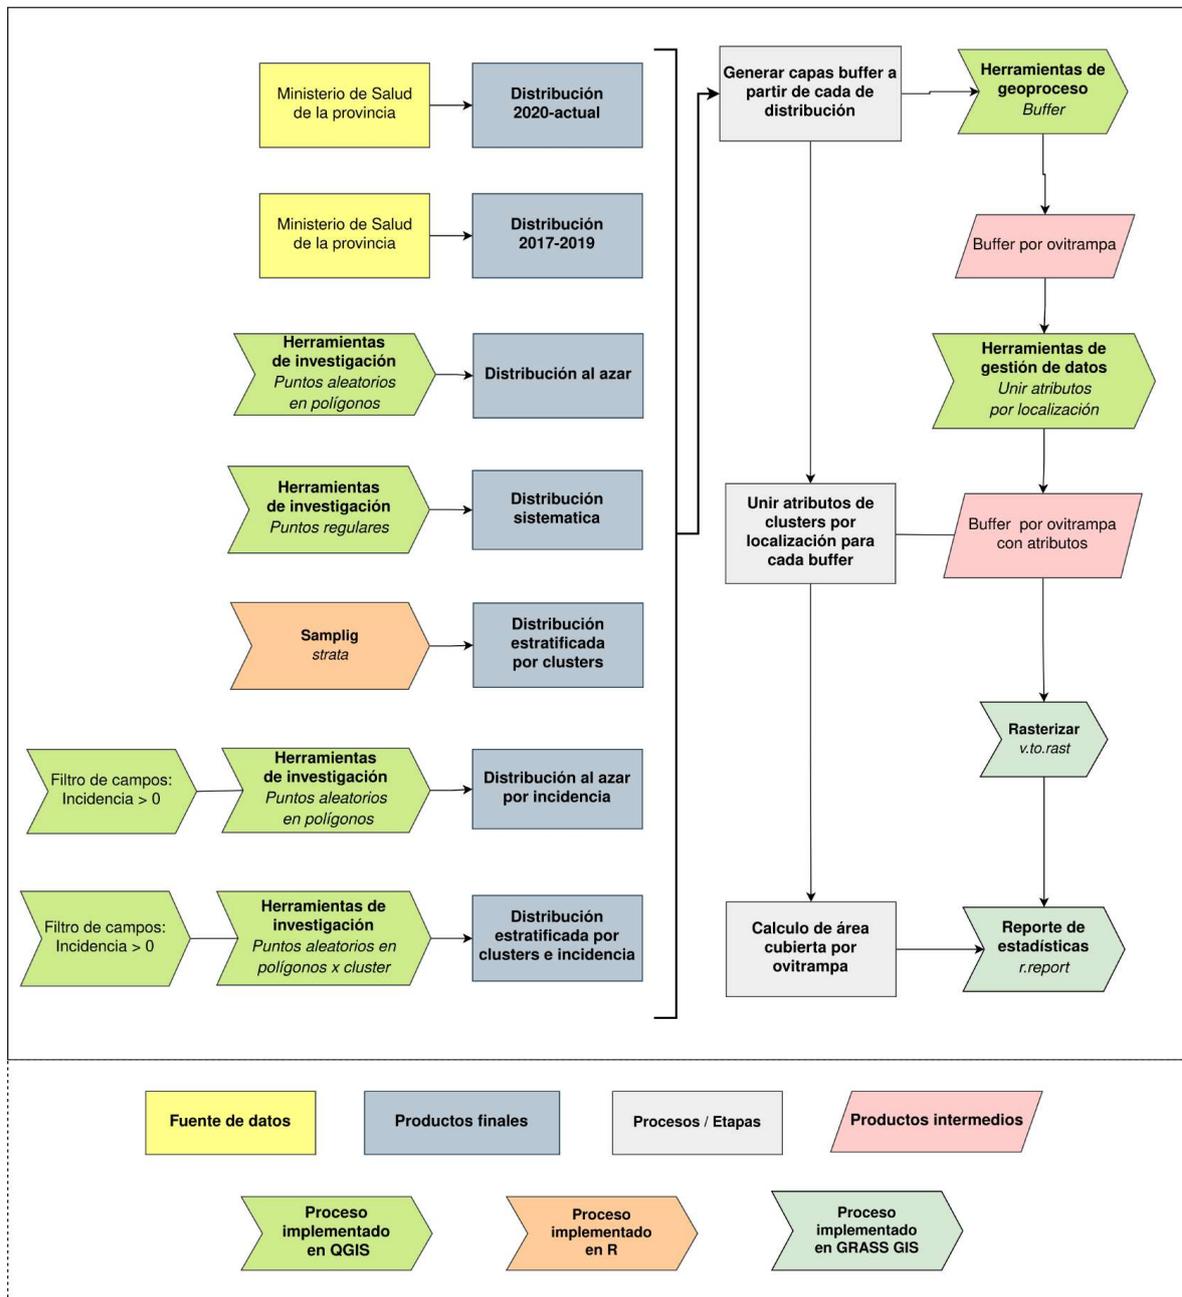


Figura 5.5: Workflow implementado para el cálculo del área cubierta por ovitrampa según cada tipo de distribución.

5.3. Resultados

5.3.1. Distribución de casos de dengue y su relación con los distintos grupos ambientales

Para analizar la relación entre la distribución de casos de dengue y los distintos grupos ambientales obtenidos en el capítulo anterior, se estimó la cantidad y porcentaje de casos de dengue por *cluster* (Tabla 5.1). Según los grupos ambientales obtenidos por radios censales de la Ciudad, el *cluster* 3 agrupó más del 50 % de los casos de dengue. Para los polígonos de salud, se observó un patrón similar para el *cluster* 4, el cual, como se analizó en el capítulo anterior, presenta similitudes ambientales con el *cluster* 3 de radios censales. Para los grupos ambientales obtenidos por barrios de la ciudad, se observó que la mayor cantidad de casos de dengue se produjo en el *cluster* 1 y para la grilla, el *cluster* 3 obtuvo la mayor cantidad de casos. Para todas las capas, se observaron pocos casos (menos del 2 %) en los *clusters* ubicados afuera del anillo de circunvalación de la ciudad.

Tabla 5.1: Cantidad y porcentaje de casos de dengue por *cluster* según cada capa.

Cluster	Cantidad de casos	Porcentaje
Radios censales		
1	213	9 %
2	10	<1 %
3	1558	63 %
4	684	28 %
Barrios		
1	1870	80 %
2	443	19 %
3	21	1 %
Polígonos de salud		
1	52	2 %
2	-	-
3	732	30 %
4	1270	52 %
5	396	16 %
Grilla		
1	-	-
2	546	22 %
3	1891	77 %
4	12	1 %

La Figura 5.6 muestra la tasa de incidencia de dengue estimada en la Ciudad de Córdoba para cada criterio de organización espacial. Para las cuatro capas, se observa el mismo patrón de incidencia, con valores bajos e intermedios en casi toda la ciudad y, valores más altos en el suroeste. Los barrios que tuvieron una mayor incidencia fueron: Residencial San Roque, Villa Martínez, Parque República y Villa Ávalos. El patrón de incidencia obtenido coincide con la distribución de casos de dengue (Figura 5.2) durante el 2020.

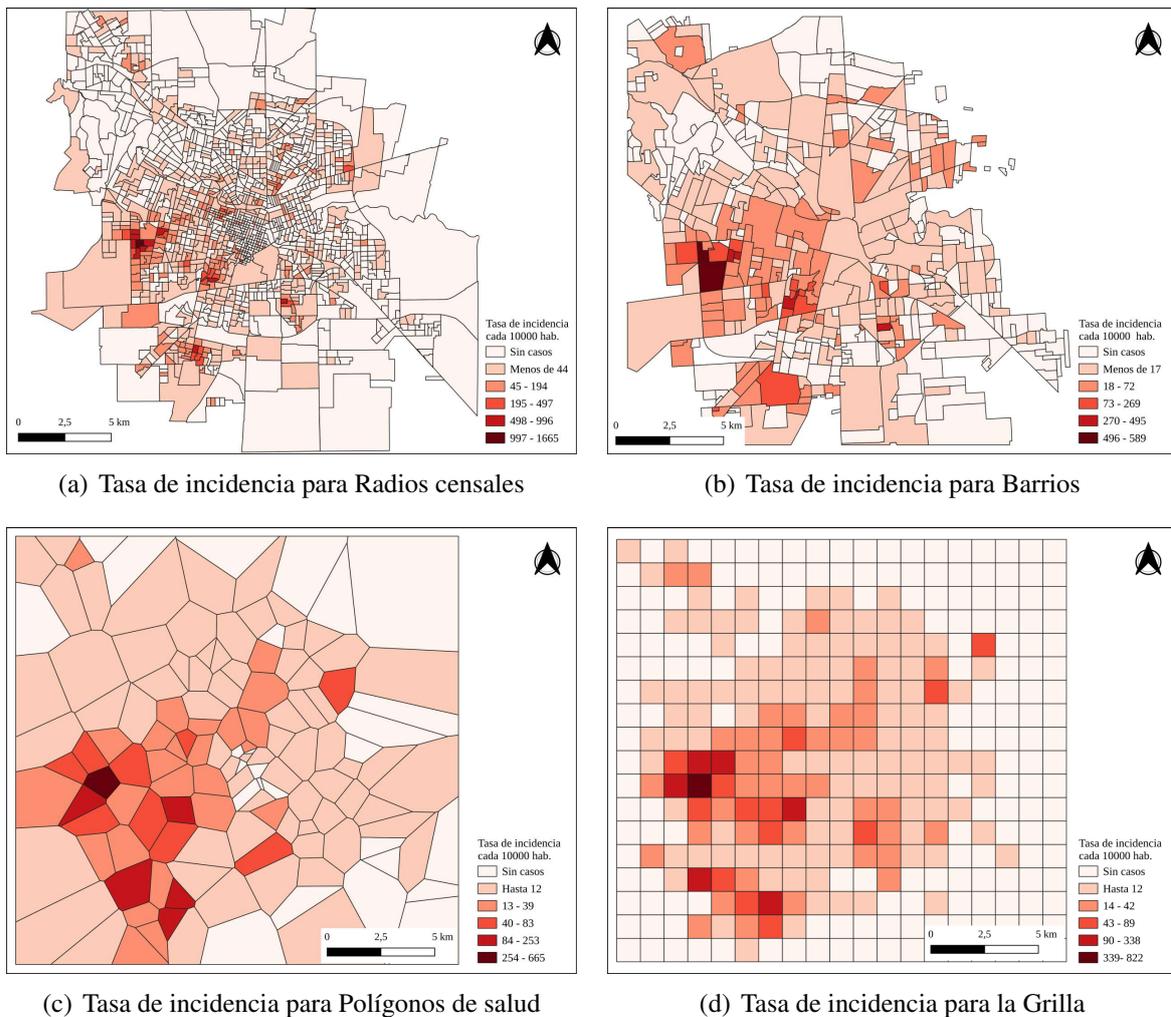


Figura 5.6: Mapas de tasas de incidencia de dengue en la Ciudad de Córdoba, a partir de datos de casos de dengue y la estimación poblacional del producto demográfico de WorldPop.

5.3.2. Análisis de distribución de ovitrampas

5.3.2.1. Estimación del número de ovitrampas por estrato

Para determinar una cantidad de ovitrampas proporcional al área ocupada por cada *cluster* para las distribuciones estratificadas, se obtuvo la Tabla 5.2. Para los radios censales, los *clusters* 2, 3 y 4 se distribuyen en proporciones similares, abarcando cada uno un 30% de la superficie total. Para esta capa, se tuvieron en cuenta los *clusters* 1, 3 y 4 para la distribución de ovitrampas, dado que el *cluster* 2 se ubica en zonas agrícolas. Para el *cluster* 1, se distribuyeron 12 ovitrampas; para el *cluster* 3 se distribuyeron 73 ovitrampas y; para el 4, 65 ovitrampas. Estos valores, se resumen en la Tabla 5.3.

Para la distribución de ovitrampas estratificada por clusters de barrios de la ciudad, según lo obtenido en la Tabla 5.2, se estimó un total de 90 ovitrampas para el *cluster* 1, 57 ovitrampas para el *cluster* 2 y, 3 ovitrampas para el *cluster* 3 (Tabla 5.3).

Para los polígonos de salud, se tuvieron en cuenta los *clusters* 3, 4 y 5 para la distribución de ovitrampas. En función del área ocupada de cada uno (Tabla 5.2), se estimó un total de 40 ovitrampas para el *cluster* 3, 50 ovitrampas para el *cluster* 4 y, 60 ovitrampas para el *cluster* 5 (Tabla 5.3).

En relación a la grilla, para la distribución de ovitrampas estratificada se tuvieron en cuenta los *clusters* 2 y 3 (Tabla 5.2). Para ambos *clusters* se estimó un total de 75 ovitrampas (Tabla 5.3)).

Tabla 5.2: Área (km²) y porcentaje de superficie total cubierto por *cluster* según cada capa. Los *clusters* resaltados en gris claro se ubican en el centro y periferia de la ciudad de Córdoba, y fueron los *clusters* seleccionados para las diferentes distribuciones de ovitrampas.

Cluster	<i>Área</i>	<i>Porcentaje</i>
Radios censales		
1	20.23	6 %
2	105.49	30 %
3	117.94	34 %
4	102.54	30 %
Barrios		
1	164.75	60 %
2	104.44	38 %
3	6.77	2 %
Polígonos de salud		
1	150.85	37 %
2	9.59	2 %
3	68.40	17 %
4	83.60	20 %
5	100.62	24 %
Grilla		
1	1.70	<1 %
2	159.50	39 %
3	129.47	32 %
4	116.72	29 %

5.3.2.2. Cantidad de ovitrampas y área de cobertura por *cluster*

La tabla 5.3 muestra la cantidad de ovitrampas por *cluster* y su área de cobertura para cada distribución. En el anexo C se presentan los porcentajes de ovitrampas para cada distribución. Las Figuras 5.7 y 5.8 muestran las diferentes distribuciones de ovitrampas analizadas.

Analizando la cantidad de ovitrampas para los *clusters* de radios censales, las distribuciones que presentan una mejor representatividad ambiental en relación al área ocupada por *cluster* son las distribuciones estratificadas por *cluster* (Figura 5.8a) y *clusters e incidencia* (Figura 5.8i), ya que por definición poseen representado cada *cluster* por una cantidad de ovitrampas proporcional a su área (Tabla 5.2). Estas distribuciones poseen el 8 % de ovitrampas en el *cluster* 1, casi el 50 % en el *cluster* 3 y, el 43 % en el *cluster* 4. El *cluster* 2 no se encuentra representado en estas distribuciones ni en las del Ministerio de salud de la provincia, ya que se ubica en zonas periféricas de la ciudad con un menor grado de urbanización. Las distribuciones sistemática y al azar poseen la menor cantidad de ovitrampas y área de cobertura en dicho *cluster*. El *cluster* 3 posee la mayor cantidad de ovitrampas en todas las distribuciones

y, a continuación el *cluster* 4, en coincidencia con su área de cobertura.

Considerando los barrios de la ciudad, el *cluster* 1 es el que posee una mayor área de cobertura de ovitrampas en todas las distribuciones, en coincidencia con el área total cubierta por dicho *cluster* (Tabla 5.2), seguido por el *cluster* 2. El *cluster* 3 se encuentra representado con una menor cantidad de ovitrampas en todas las distribuciones, a excepción de la distribución 2017-2019 del Ministerio de Salud.

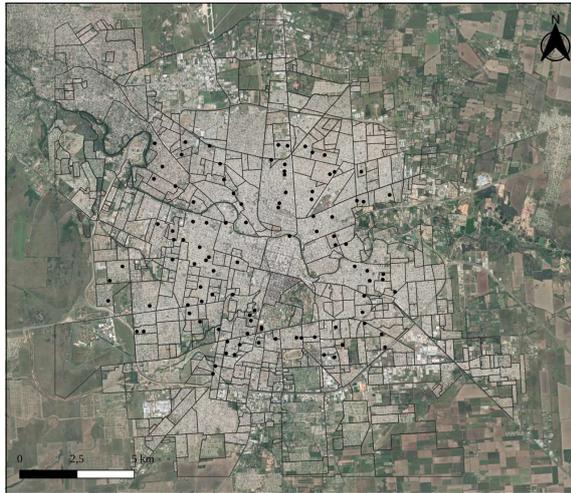
Teniendo en cuenta los polígonos de salud, la única distribución de ovitrampas que cubre todos los grupos ambientales es la sistemática (Tabla 5.3). Sin embargo, los *clusters* 1 y 2 se ubican en zonas alejadas a la ciudad con escasa urbanización. Los *clusters* 3, 4 y 5, ubicados en zonas urbanas de la ciudad, se encuentran cubiertos por ovitrampas en todas las distribuciones. Sin embargo, las distribuciones 2017-2019 y 2020-actual cubren menos del 2% del área total ocupada por el *cluster* 5. Por ejemplo, la distribución de ovitrampas actual posee solo 8 ovitrampas en dicho grupo, y para que el mismo se encuentre representado ambientalmente de forma proporcional al área que ocupa debería contar con al menos 60 ovitrampas (como en la distribución estratificada por *clusters*).

Para los grupos ambientales obtenidos para la grilla, ninguna de las distribuciones de ovitrampas cubre el *cluster* 1, y solo la distribución al azar, sistemática y estratificada por incidencia cubren el *cluster* 4. Las distribuciones 2017-219 y 2020-actual presentan la menor área de cobertura para el *cluster* 2 (menos del 2% de su área total ocupada). En cambio, el *cluster* 3, se encuentra representado con más de 70 ovitrampas para todas las distribuciones (Tabla 5.3).

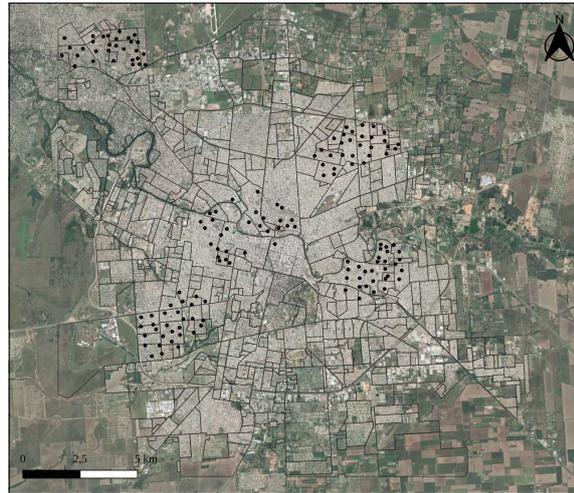
Tabla 5.3: Cantidad de ovitrampas y área de cobertura (km²) por *clusters* según cada criterio de distribución.
Dist_Ac: Distribución 2020-actual, *Dist_An:* Distribución 2017-2019, *Dist_Az:* Distribución al azar,
Dist_Sist: Distribución sistemática, *Dist_E_Cl:* Distribución estratificada por *clusters*, *Dist_E_In:*
 Distribución estratificada por incidencia, *Dist_E_Cl_In:* Distribución estratificada por *clusters* e incidencia.

Distribuciones	<i>Dist_Ac</i>	<i>Dist_An</i>	<i>Dist_Az</i>	<i>Dist_Sist</i>	<i>Dist_E_Cl</i>	<i>Dist_E_In</i>	<i>Dist_E_Cl_In</i>
Radio censales							
1	12 (0.84)	19 (1.3)	20 (1.45)	10 (0.7)	12 (0.84)	19 (1.33)	12 (0.84)
2	-	-	6 (0.42)	13 (0.91)	-	1 (0.07)	-
3	66 (4.62)	102 (7.14)	78 (5.46)	68 (4.76)	73 (5.11)	89 (6.23)	73 (5.11)
4	22 (1.54)	29 (2.03)	46 (3.22)	59 (4.13)	65 (4.55)	41 (2.87)	65 (4.55)
Barrios							
1	74 (5.18)	107 (7.49)	100 (7)	100 (7)	90 (6.3)	130 (9.1)	90 (6.3)
2	24 (1.68)	43 (3.01)	41 (2.87)	40 (2.8)	57 (3.99)	15 (1.05)	57 (3.99)
3	2 (0.14)	-	9 (0.63)	10 (0.7)	3 (0.21)	5 (0.35)	3 (0.21)
Polígonos de salud							
1	2 (0.14)	1 (0.07)	7 (0.49)	10 (0.7)	-	15 (1.05)	-
2	-	-	-	2 (0.14)	-	-	-
3	48 (3.36)	71 (4.97)	50 (3.5)	42 (2.94)	40 (2.8)	49 (3.43)	40 (2.8)
4	42 (2.94)	60 (4.2)	48 (3.36)	56 (3.92)	50 (3.5)	52 (3.64)	50 (3.5)
5	8 (0.56)	18 (1.26)	45 (3.15)	40 (2.8)	60 (4.2)	34 (2.38)	60 (4.2)
Grilla							
1	-	-	-	-	-	-	-
2	13 (0.91)	27 (1.89)	57 (3.99)	66 (4.62)	75 (5.25)	57 (3.99)	75 (5.25)
3	87 (6.09)	123 (8.61)	90 (6.3)	82 (5.74)	75 (5.25)	88 (6.16)	75 (5.25)
4	-	-	3 (0.21)	2 (0.21)	-	5 (0.35)	-

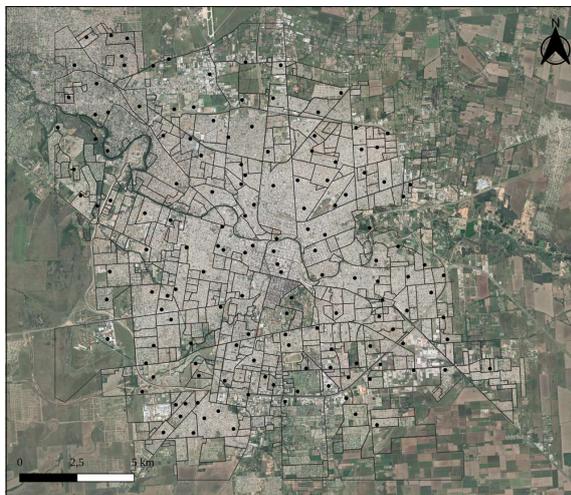
*Entre paréntesis área de cobertura de ovitrampas.



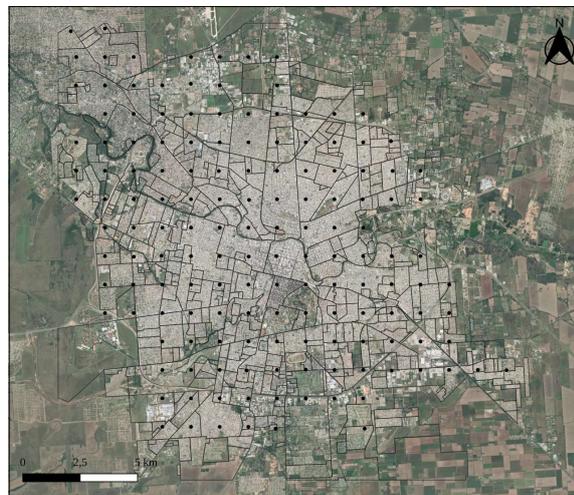
(a) Distribución 2020-actual Ministerio de Salud



(b) Distribución 2017-2019 Ministerio de Salud



(c) Distribución al azar



(d) Distribución sistemática

Figura 5.7: Distribuciones de ovitrampas en la ciudad de Córdoba.

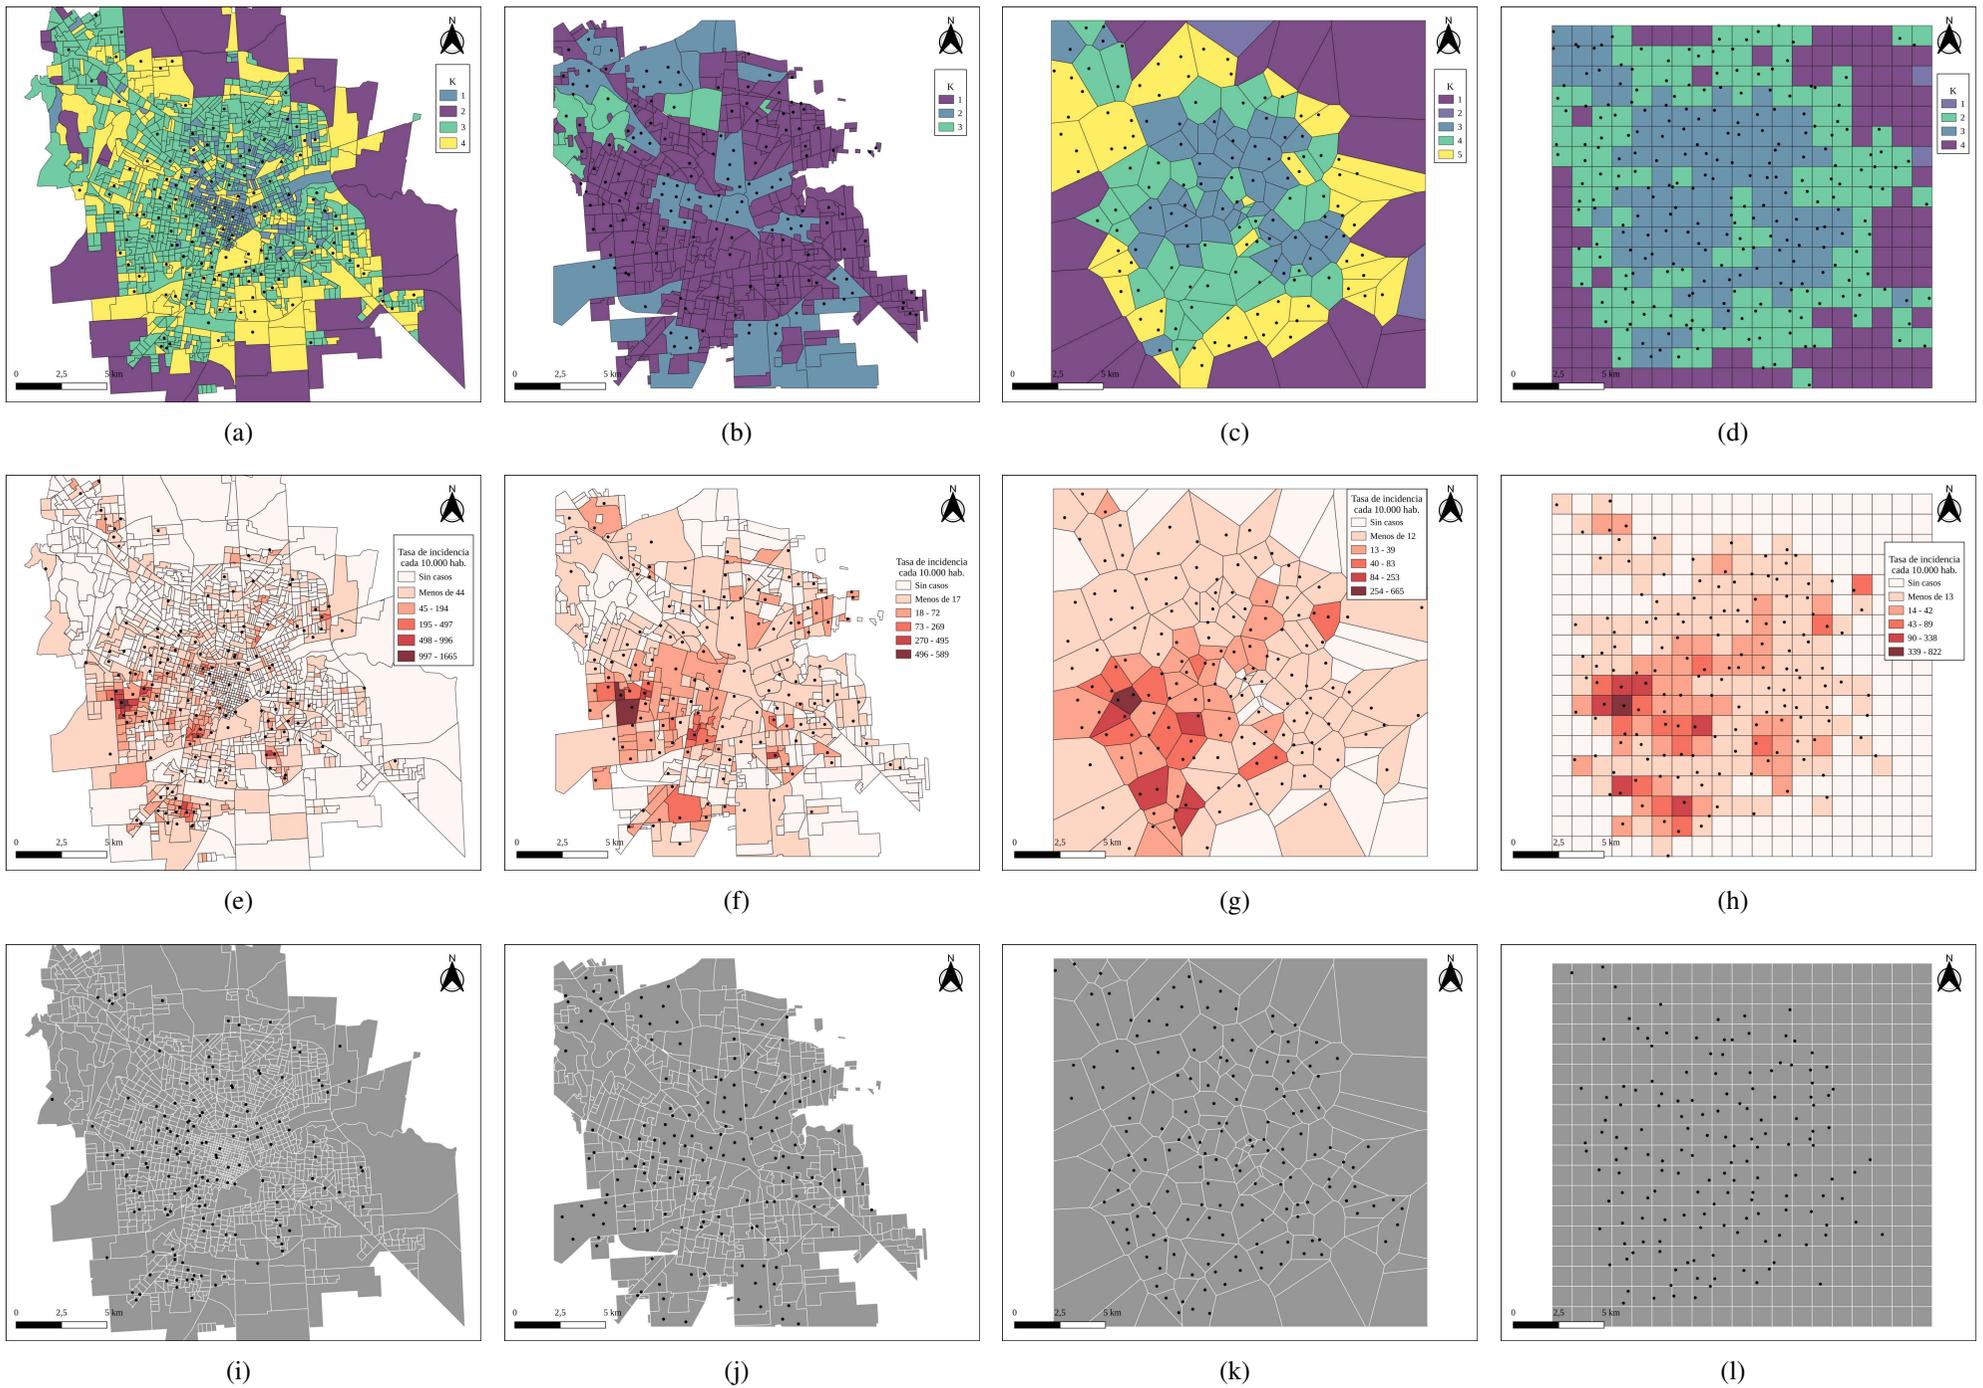


Figura 5.8: Mapas de distribución estratificada de ovitrampas según cada criterio de organización espacial de la Ciudad de Córdoba: por cluster, por incidencia y por la combinación de ambas.

5.4. Discusión

Uno de los desafíos a los que se enfrentan las autoridades sanitarias en las zonas urbanas es la vigilancia de los posibles lugares de cría de los estadios inmaduros de los mosquitos vectores (i.e., hábitats favorables para larvas y pupas). Este monitoreo y el conocimiento que se deriva del mismo son fundamentales para el diseño, la aplicación y la evaluación de medidas de prevención y control. Por lo tanto, uno de los pasos más importantes en la planificación de un sistema de vigilancia es determinar dónde colocar los sensores (en este caso las ovitrampas) o realizar muestreo larvario, con el fin de cubrir adecuadamente la variabilidad dentro del área de interés. En este contexto, como contribución al sistema de vigilancia de *Aedes aegypti* en la ciudad de Córdoba y para cubrir un vacío en estudios que relacionan la variabilidad ambiental con la distribución de ovitrampas, en este capítulo se evaluó la distribución del actual sistema de monitoreo de *Ae. aegypti* en relación a la representación a los distintos grupos ambientales obtenidos en el capítulo anterior. Además, se consideraron otras distribuciones probables y se analizó la representación ambiental de cada una. Otros estudios, como el de Albrieu-Llinás et al. 2018 (105) han mostrado la relevancia de las agrupaciones ambientales con el objetivo de caracterizar la ciudad y evaluar la dinámica espacio-temporal de los sitios de reproducción de *Ae. aegypti*.

En general, los resultados obtenidos demuestran que las distribuciones 2017-2019 y 2020-actual del Ministerio de Salud provincial poseen una baja representatividad ambiental en comparación al resto de las distribuciones analizadas. Estos sistemas poseen muchas ovitrampas en un mismo grupo ambiental y muy pocas o ninguna en otros (Tabla 5.3). Esto podría implicar que el rango o patrón de distribución del vector se determine de forma inexacta o imprecisa, o que no se detecte actividad vectorial oportunamente. Por otro lado, si bien la distribución 2020-actual cubre mejor la ciudad y no presenta ovitrampas agrupadas arbitrariamente como la distribución 2017-2019 (Figuras 5.7a y 5.7b), en la distribución actual solo se ubican ovitrampas dentro del anillo de circunvalación, lo cual deja sin cobertura muchos sectores relevantes, como la zona norte de la ciudad. En cambio, las distribuciones estratificadas por clusters son las que poseen mayor cobertura de las diferentes regiones de la ciudad y mejor maximizan la variabilidad ambiental, ya que presentan una cantidad de ovitrampas y área de cobertura proporcional al área que ocupa cada *cluster*. Considerando el análisis de los agrupamientos obtenidos en el capítulo anterior, los grupos ambientales por radios censales y polígonos de salud estarían caracterizando la ciudad de manera más precisa, por lo cual, las distribuciones de ovitrampas por estratos en dichas capas serían las de mayor relevancia y representación ambiental intra-urbana de la ciudad de Córdoba (Figuras 5.8a y 5.8c).

En la bibliografía, la mayoría de los estudios sobre la distribución y presencia de *Ae. aegypti* en ambientes urbanos determina de manera aleatoria o arbitraria los sitios de muestreo o colocación de ovitrampas. Schultes et al. (2021) (266) utilizaron datos de 1700 ovitrampas distribuidas de manera arbitraria durante el periodo 2006-2018 en la Ciudad Belo Horizonte (Brasil) para evaluar los patrones espaciales de la incidencia del dengue y el índice de positividad de las ovitrampas a lo largo del tiempo así como la relación entre ellos. En otros casos, como Norzahira et al. (2011) (267), la elección se basó en criterios como la presencia de hábitats humanos, el conocimiento previo sobre la presencia del vector, el aislamiento geográfico y la estabilidad ecológica. Otros estudios, como AK et al. (2018) (268), tuvieron en cuenta los casos de dengue reportados por las autoridades sanitarias para seleccionar dos áreas residenciales como área de estudio en Selangor (Malasia). Feria-Arroyo et al. (2020) (269) también eligieron los barrios de dos ciudades cercanas a la frontera de Texas y México, basándose en las recomendaciones de las autoridades locales, la receptividad de los residen-

tes y la seguridad personal de los técnicos de campo encargados de colocar la ovitrampas. Sin embargo, hasta el momento, ningún estudio de nuestro conocimiento ha considerado la heterogeneidad ambiental urbana para elegir la ubicación de ovitrampas de *Ae. aegypti*. Así, este trabajo constituye una novedad en la temática, dado que para la propuesta de ubicación de sitios de muestreo de oviposición se tuvo en cuenta la variabilidad ambiental del lugar a partir del procesamiento y análisis una imagen de muy alta resolución espacial y herramientas SIG.

En este capítulo, también se analizó la distribución de casos del último brote de dengue y su relación con los distintos grupos ambientales. Según los resultados obtenidos (Tabla 5.1), la mayor cantidad de casos se produjo en los *clusters* 3 de radios censales y 4 de polígonos de salud. Ambos *clusters*, coinciden en algunas métricas e índices analizadas en el capítulo anterior, con una proporción de vegetación alta y edificación intermedia. Como se resaltó en la discusión 4.4, este grupo intra-urbano constituye uno de los dos grupos de mayor preferencia por el vector, dado que posee un nivel de urbanización moderada (96; 82). En algunos estudios anteriores se ha analizado el efecto de la urbanización en los niveles de infestación del vector. Rubio et al. (2011) (270) estudiaron los niveles de infestación en neumáticos en municipios con niveles de urbanización alto, medio y bajo, y observaron una relación inversa siendo mayores los niveles de infestación en municipios con niveles de urbanización bajos. Por lo cual, los sectores de urbanización baja y media, deberían ser considerados con mayor atención a la hora de diseñar los sistemas de vigilancia, dado que presentan las mejores condiciones para que el vector se reproduzca, alimente y encuentre sitios de descanso (271).

El análisis de los distintos criterios de distribución de ovitrampas con miras a maximizar la variabilidad ambiental y considerar además la incidencia de dengue en el brote pasado, permite concluir que las distribuciones estratificadas por *clusters* e incidencia son las que mejor representan ambientalmente la ciudad y consideran la distribución de dengue. Sin embargo, teniendo en cuenta que la distribución de casos de dengue no es estática y puede variar de temporada en temporada (debido a que, en general, los brotes se inician con casos importados), la distribución de ovitrampas podría actualizarse en función de la variación de casos de dengue, o considerarse la distribución de casos en los últimos brotes conjuntamente.

En un contexto complejo, en donde se mezclan tanto las características adaptativas de un vector urbano a múltiples entornos antrópicos así como las particularidades y heterogeneidad propia de cada ciudad, se reconoce la dificultad y complejidad a la que se enfrentan tanto las autoridades regionales como los investigadores a la hora de elegir lugares de muestreo. Mas aun, considerando que se deberían seleccionar regiones que sean significativamente representativas que garanticen tanto la durabilidad del estudio/vigilancia como la eficiencia del mismo. Si bien todas las distribuciones alternativas consideradas resultaron mejores opciones en términos de representatividad ambiental frente a las establecidas por el Ministerio de Salud, se debe tener en cuenta que para implementar alguno de los criterios considerados se debe analizar cada sitio de muestreo en particular para comprobar su factibilidad y conveniencia en cuanto a la operatividad. Ninguna de las distribuciones analizadas considera los tiempos de traslado ni recorridos óptimos a la hora de distribuir y recolectar las ovitrampas. Por lo cual, como propuestas futuras, una vez definido el criterio para elegir los sitios de muestreo, podrían analizarse los tiempos de recorridos y rutas para llegar a cada sitio. Además, se podría ponderar la incidencia de casos y colocar ovitrampas a partir de cierto umbral.

CAPÍTULO 6

Discusión y conclusión final

En este trabajo se caracterizó ambientalmente la cobertura urbana de la ciudad de Córdoba con el fin de determinar una distribución óptima para la red de ovitrampas de *Aedes aegypti* que refleje la variabilidad espacial y a la vez considere el riesgo potencial de transmisión de dengue. Hasta el momento, este trabajo de tesis constituye el primer estudio en abordar esta temática vinculando la heterogeneidad ambiental presente en una ciudad con un sistema de monitoreo de un vector urbano. El uso de diferentes herramientas de libre acceso y metodologías fuertemente consolidadas y establecidas para el procesamiento de imágenes en el campo del Sensado Remoto permitió alcanzar cada uno de los objetivos propuestos y aportar tanto a la cartografía de la Ciudad como a las autoridades sanitarias locales.

En primera medida, se evaluaron dos metodologías de clasificación supervisada de imágenes satelitales a partir de una imagen de muy alta resolución espacial (0.5 m) de la Ciudad de Córdoba (Capítulo 3). Ambos enfoques permitieron obtener mapas de cobertura urbana muy precisos y aceptables, con una precisión global del 92% para el enfoque tradicional basado en píxeles y el 97% para OBIA. Estos mapas de cobertura urbana constituyen una fuente de información relevante para futuros estudios llevados a cabo en la Ciudad de Córdoba. Dado que la clasificación basada en objetos obtuvo mejores resultados en todas las métricas estimadas, tanto del mapa general como de las siete clases urbanas definidas, los análisis subsecuentes de la tesis se realizaron a partir de este mapa de cobertura.

Luego, se describieron y estimaron diferentes métricas del paisaje en función de cuatro criterios de organización espacial o capas para generar agrupamientos con el algoritmo no supervisado *k-means* y caracterizar la variabilidad ambiental urbana de la Ciudad de Córdoba (Capítulo 4). La utilización de cuatro capas (barrios, radios censales, polígonos de salud y grilla) permitió realizar una comparación entre los diferentes agrupamientos obtenidos y determinar la existencia de patrones. Si bien los *clusters* por barrios y grilla presentaron limitaciones por agrupar polígonos con características muy diferentes entre sí y no detectar correctamente la variabilidad intra-urbana de la ciudad, los agrupamientos por polígonos de salud y radios censales fueron consistentes y permitieron una mejor descripción de la ciudad, coincidiendo en un mismo patrón espacial con cuatro grupos ambientales principales. De estos grupos, tres se ubican dentro de la ciudad y son relevantes para el sistema de monitoreo del Ministerio de Salud. Las características ambientales de cada uno podría estar

determinando un patrón de distribución del vector particular (92). Según las preferencias del mosquito y los antecedentes en la bibliografía (99; 82; 98), los dos grupos ambientales de urbanización intermedia poseen particularidades que permiten un desarrollo óptimo del mismo, ofreciéndole sitios para oviponer en jardines residenciales, baldíos, desarmaderos, galpones, etc., alimentarse y suficiente vegetación para reposar y refugiarse (270).

Por último, en el Capítulo 5 se propusieron diferentes distribuciones de ovitrampas para la ciudad teniendo en cuenta distintos criterios (arbitrarios, al azar, sistemático, por incidencia de dengue) y considerando los grupos ambientales obtenidos en el capítulo anterior (estratificado por *clusters* y estratificado por *clusters* e incidencia). En términos generales, las distribuciones arbitrarias establecidas por el Ministerio de Salud provincial para la red de ovitrampas poseen la menor representación ambiental de la Ciudad. En cambio, las distribuciones estratificadas por *clusters* e incidencia de dengue cubren la variabilidad espacial existente en la ciudad y consideran el riesgo potencial de dengue, en relación al último brote ocurrido durante el 2020. Teniendo en cuenta lo analizado para el Capítulo 4, las distribuciones más recomendables serían tanto las de radios censales (Figura 5.8i) como las de polígonos de salud (Figura 5.8k). En particular, la distribución de ovitrampas estratificada por *clusters* e incidencia para polígonos de salud (Figura 6.1) posee una mayor distancia entre ovitrampas y una distribución más amplia en el espacio, que a su vez considera la ubicación de centros de salud de la ciudad.

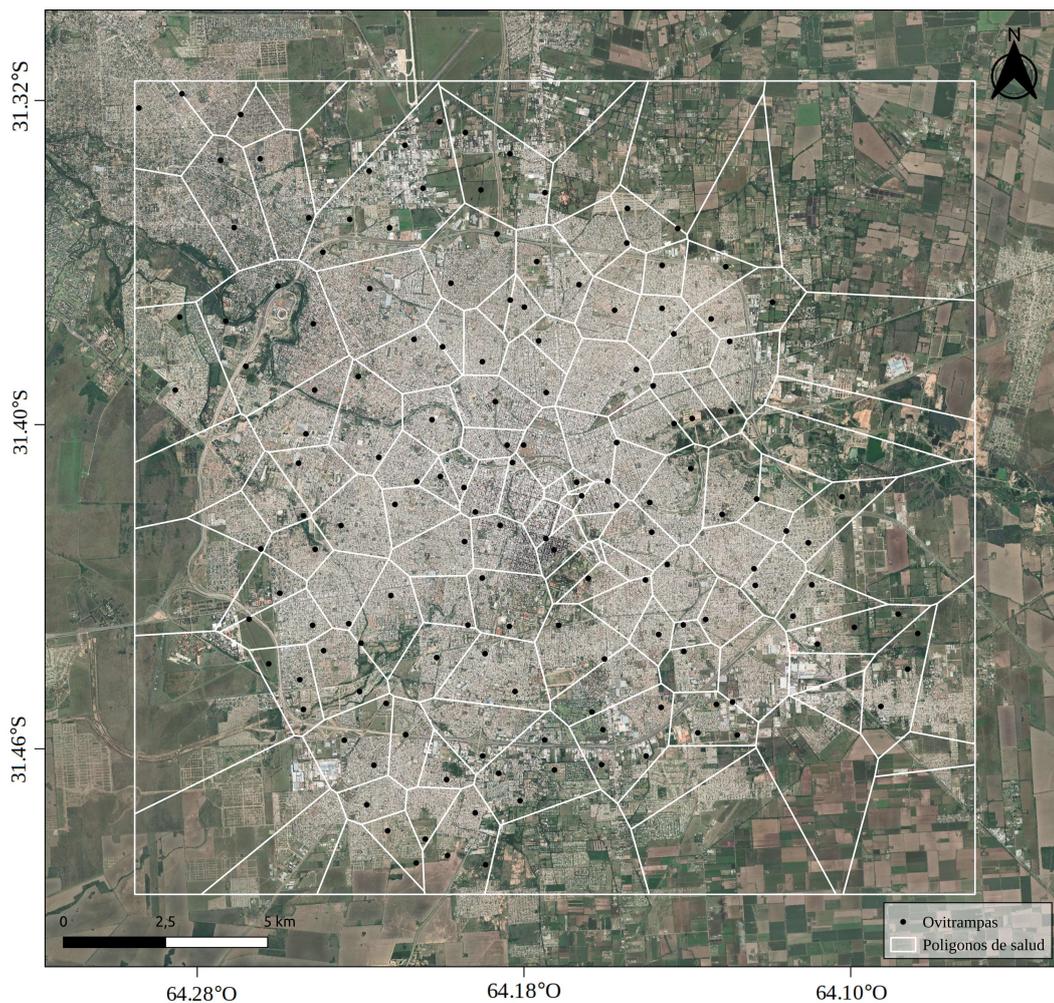


Figura 6.1: Distribución de ovitrampas para la Ciudad de Córdoba en función de *clusters* ambientales e incidencia de dengue por polígonos de salud.

Sobre los resultados y metodologías aplicadas en esta tesis, se pueden reconocer algunas limitaciones o dificultades en algunas etapas. Si bien el enfoque de clasificación supervisado basado en objetos permitió alcanzar un resultado mejor al enfoque tradicional basado en píxeles, se debe tener en cuenta la demanda computacional y el tiempo de procesamiento de cada etapa cuando se aplica la metodología de OBIA y se trabaja con imágenes de alta resolución espacial. Aún dividiendo la ciudad en *tiles* o mosaicos más chicos, la etapa de segmentación en objetos fue una de las que precisó mayor tiempo de procesamiento en esta tesis (una semana para cada prueba de segmentación y aproximadamente un mes para obtener el mapa de cobertura final, en una computadora con 16GB y un procesador Intel® Core™ i7-8565U CPU 1.80GHz×8). Esto resalta la riqueza del producto obtenido debido no solo a la calidad del mapa generado sino también al proceso realizado para obtenerlo.

Otra de las limitaciones se asocia al algoritmo de agrupamiento *k-means* utilizado, dado que se trata de una metodología no supervisada posee cierta incertidumbre en comparación a los métodos supervisados en que se conocen las clases de antemano. La etapa más crítica de esta metodología es la elección del número de *clusters*, dado que debe ser definida por el usuario previamente. Además, el algoritmo es sensible al ruido y puntos anormales, y en general, es recomendable cuando se trabaja con distribuciones esféricas (243). En este sentido, uno de los análisis que se desprende de los resultados obtenidos y que podría considerarse en trabajos futuros sería explorar otros algoritmos de agrupamiento y comparar los grupos ambientales que se generen (272; 273).

Más allá de los resultados obtenidos y de la exactitud que se podría esperar en los grupos ambientales en la Ciudad de Córdoba, la propuesta de esta tesis puede considerarse como punto de partida para incluir la variabilidad ambiental existente en un lugar a la hora de decidir en dónde se podrían colocar ovitrampas. Al tener un conocimiento ambiental más completo sobre la ciudad, se puede estimar o predecir qué zonas serán más propensas a contar con la presencia del vector. De esta forma, se pueden enfocar los esfuerzos y recursos de las autoridades sanitarias en estas regiones para tener un monitoreo del vector más efectivo.

Como líneas futuras, para hacer el sistema de monitoreo más eficiente se podrían evaluar las rutas y recorridos más convenientes en la ciudad, considerando el tráfico y los accesos particulares en cada zona, y diseñar un sistema que sea más operativo para los técnicos encargados de la distribución y revisión semanal de ovitrampas.

Referencias bibliográficas

- [1] J. S. Mackenzie, D. J. Gubler, and L. R. Petersen, “Emerging flaviviruses: the spread and resurgence of japanese encephalitis, west nile and dengue viruses,” *Nature medicine*, vol. 10, no. 12, pp. S98–S109, 2004.
- [2] S. I. Hay, E. A. Okiro, P. W. Gething, A. P. Patil, A. J. Tatem, C. A. Guerra, and R. W. Snow, “Estimating the global clinical burden of plasmodium falciparum malaria in 2007,” *PLoS Med*, vol. 7, no. 6, p. e1000290, 2010.
- [3] G. Liang, X. Gao, and E. A. Gould, “Factors responsible for the emergence of arboviruses; strategies, challenges and limitations for their control,” *Emerging microbes & infections*, vol. 4, no. 1, pp. 1–5, 2015.
- [4] WHO, “Global strategy for dengue prevention and control 2012- 2020.” Library Cataloguing-in-Publication Data. apps.who.int/iris/bitstream/handle/10665/75303/9789241504034_eng.pdf. (Acceso: agosto 2020).
- [5] OPS/OMS, “Actualización epidemiológica alerta del 9 de agosto 2019.,” 2019.
- [6] OPS/OMS, “Actualización epidemiológica: Dengue y otras arbovirosis: 10 de junio de 2020.,” 2020.
- [7] M. A. Robert, D. T. Tinunin, E. M. Benitez, F. F. Ludueña-Almeida, M. Romero, A. M. Stewart-Ibarra, and E. L. Estallo, “Arbovirus emergence in the temperate city of córdoba, argentina, 2009–2018,” *Scientific data*, vol. 6, no. 1, pp. 1–6, 2019.
- [8] C. B. Marcondes, M. Contigiani, and R. M. Gleiser, “Emergent and reemergent arboviruses in south america and the caribbean: why so many and why now?,” *Journal of medical entomology*, vol. 54, no. 3, pp. 509–532, 2017.
- [9] G. Berberian and M. T. Rosanova, “Impacto del cambio climático en las enfermedades infecciosas,” *Archivos argentinos de pediatría*, vol. 110, no. 1, pp. 39–45, 2012.
- [10] R. S. Kovats, “El niño and human health,” *Bulletin of the World Health Organization*, vol. 78, pp. 1127–1135, 2000.
- [11] P. N. Schwerdtle, K. Bowen, C. McMichael, and R. Sauerborn, “Human mobility and health in a warming world,” *Journal of travel medicine*, vol. 26, no. 1, p. tay160, 2019.

- [12] J. H. Dunk and D. S. Jones, “Sounding the alarm on climate change, 1989 and 2019,” *New England Journal of Medicine*, vol. 382, no. 3, pp. 205–207, 2020.
- [13] L. P. Lounibos, “Invasions by insect vectors of human disease,” *Annual review of entomology*, vol. 47, no. 1, pp. 233–266, 2002.
- [14] N. Becker, B. Pluskota, A. Kaiser, and F. Schaffner, “Exotic mosquitoes conquer the world,” in *Arthropods as vectors of emerging diseases*, pp. 31–60, Springer, 2012.
- [15] C. Mangudo, J. P. Aparicio, and R. M. Gleiser, “Tree holes as larval habitats for *Aedes aegypti* in urban, suburban and forest habitats in a dengue affected area,” *Bulletin of entomological research*, vol. 105, no. 6, pp. 679–684, 2015.
- [16] J. E. Brown, B. R. Evans, W. Zheng, V. Obas, L. Barrera-Martinez, A. Egizi, H. Zhao, A. Caccone, and J. R. Powell, “Human impacts have shaped historical and recent evolution in *Aedes aegypti*, the dengue and yellow fever mosquito,” *Evolution*, vol. 68, no. 2, pp. 514–525, 2014.
- [17] J. Washburn, “Regulatory factors affecting larval mosquito populations in container and pool habitat: implications for biological control,” *Journal of the American Mosquito Control Association*, vol. 11, pp. 279–283, 1995.
- [18] M. J. Nelson *et al.*, “*Aedes aegypti*: biología y ecología,” 1986.
- [19] K. P. Paaijmans and M. B. Thomas, “The influence of mosquito resting behaviour and associated microclimate for malaria risk,” *Malaria journal*, vol. 10, no. 1, pp. 1–7, 2011.
- [20] J. R. Dewald, D. O. Fuller, G. C. Müller, and J. C. Beier, “A novel method for mapping village-scale outdoor resting microhabitats of the primary african malaria vector, *Anopheles gambiae*,” *Malaria journal*, vol. 15, no. 1, pp. 1–12, 2016.
- [21] A. E. Carbajo, S. M. Gomez, S. I. Curto, and N. J. Schweigmann, “Variación espacio-temporal del riesgo de transmisión de dengue en la ciudad de buenos aires,” *Medicina (Buenos Aires)*, vol. 64, no. 3, pp. 231–234, 2004.
- [22] W. K. Reisen, “Landscape epidemiology of vector-borne diseases,” *Annual review of entomology*, vol. 55, pp. 461–483, 2010.
- [23] J. S. Wilson, M. Clay, E. Martin, D. Stuckey, and K. Vedder-Risch, “Evaluating environmental influences of zoning in urban ecosystems with remote sensing,” *Remote sensing of environment*, vol. 86, no. 3, pp. 303–321, 2003.
- [24] G. A. Llinás, “Categorización ambiental para la evaluación de la dinámica espacio-temporal de criaderos artificiales de *Aedes aegypti* en clorinda, argentina (2012-2013),” 2020.
- [25] M. Bavia, D. Carneiro, H. da Costa Gurgel, C. M. Filho, and M. R. Barbosa, “Remote sensing and geographic information systems and risk of american visceral leishmaniasis in bahia, brazil,” *Parassitologia*, vol. 47, no. 1, p. 165, 2005.
- [26] L. Zou, S. N. Miller, and E. T. Schmidtman, “Mosquito larval habitat mapping using remote sensing and gis: implications of coalbed methane development and west nile virus,” *Journal of medical entomology*, vol. 43, no. 5, pp. 1034–1041, 2006.

- [27] X. Porcasi, V. Andreo, A. Ferral, P. Guimarey, M. S. Santini, C. Spillmann, R. Hernandez, A. G. Serra, and E. Aguirre, “Regional scale environmental variables complementing a risk model of chagas disease vectorial transmission,” in *2018 IEEE Biennial Congress of Argentina (ARGENCON)*, pp. 1–5, IEEE, 2018.
- [28] D. Weinberg, X. Porcasi, S. Lanfri, M. Abril, and C. M. Scavuzzo, “Spatial analyzes of triatomine infestation indices and their association to the actions of a chagas disease program and environmental variables during a 5-year intervention period,” *Acta tropica*, vol. 188, pp. 41–49, 2018.
- [29] C. Rotela, F. Fouque, M. Lamfri, P. Sabatier, V. Introini, M. Zaidenberg, and C. Scavuzzo, “Space–time analysis of the dengue spreading dynamics in the 2004 tartagal outbreak, northern argentina,” *Acta tropica*, vol. 103, no. 1, pp. 1–13, 2007.
- [30] C. H. Rotela, L. I. Spinsanti, M. A. Lamfri, M. S. Contigiani, W. R. Almirón, and C. M. Scavuzzo, “Mapping environmental susceptibility to saint louis encephalitis virus, based on a decision tree model of remotelysensed data,” *Geospatial health*, vol. 6, no. 1, pp. 85–94, 2011.
- [31] V. Andreo, P. F. Cuervo, X. Porcasi, L. Lopez, C. Guzman, and C. M. Scavuzzo, “Towards a workflow for operational mapping of *Aedes aegypti* at urban scale based on remote sensing,” *Remote Sensing Applications: Society and Environment*, vol. 23, p. 100554, 2021.
- [32] E. Aguirre, V. Andreo, X. Porcasi, L. Lopez, C. Guzman, P. González, and C. M. Scavuzzo, “Implementation of a proactive system to monitor *Aedes aegypti* populations using open access historical and forecasted meteorological data,” *Ecological Informatics*, p. 101351, 2021.
- [33] A. Gómez-Bravo, A. German, M. Abril, M. Scavuzzo, and O. D. Salomón, “Spatial population dynamics and temporal analysis of the distribution of lutzomyia longipalpis (lutz & neiva, 1912)(diptera: Psychodidae: Phlebotominae) in the city of clorinda, formosa, argentina,” *Parasites & vectors*, vol. 10, no. 1, pp. 1–9, 2017.
- [34] V. Andreo, M. Neteler, D. Rocchini, C. Provensal, S. Levis, X. Porcasi, A. Rizzoli, M. Lanfri, M. Scavuzzo, N. Pini, *et al.*, “Estimating hantavirus risk in southern argentina: a gis-based approach combining human cases and host distribution,” *Viruses*, vol. 6, no. 1, pp. 201–222, 2014.
- [35] V. Andreo, M. Belgiu, D. B. Hoyos, F. Osei, C. Provensal, and A. Stein, “Rodents and satellites: Predicting mice abundance and distribution with sentinel-2 data,” *Ecological informatics*, vol. 51, pp. 157–167, 2019.
- [36] M. J. Moreno-Madriñán, W. L. Crosson, L. Eisen, S. M. Estes, M. G. Estes Jr, M. Hayden, S. N. Hemmings, D. E. Irwin, S. Lozano-Fuentes, A. J. Monaghan, *et al.*, “Correlating remote sensing data with the abundance of pupae of the dengue virus mosquito vector, *Aedes aegypti*, in central mexico,” *ISPRS International Journal of Geo-Information*, vol. 3, no. 2, pp. 732–749, 2014.
- [37] M. U. Kraemer, M. E. Sinka, K. A. Duda, A. Q. Mylne, F. M. Shearer, C. M. Barker, C. G. Moore, R. G. Carvalho, G. E. Coelho, W. Van Bortel, *et al.*, “The global distribution of the arbovirus vectors *Aedes aegypti* and *Aedes albopictus*,” *elife*, vol. 4, p. e08347, 2015.

- [38] M. U. Kraemer, R. C. Reiner, O. J. Brady, J. P. Messina, M. Gilbert, D. M. Pigott, D. Yi, K. Johnson, L. Earl, L. B. Marczak, *et al.*, “Past and future spread of the arbovirus vectors *Aedes aegypti* and *Aedes albopictus*,” *Nature microbiology*, vol. 4, no. 5, pp. 854–863, 2019.
- [39] J. Lubinda, M. R. Walsh, A. J. Moore, A. A. Hanafi-Bojd, S. Akgun, B. Zhao, A. S. Barro, M. M. Begum, H. Jamal, A. Angulo-Molina, *et al.*, “Environmental suitability for *Aedes aegypti* and *Aedes albopictus* and the spatial distribution of major arboviral infections in Mexico,” *Parasite epidemiology and control*, vol. 6, p. e00116, 2019.
- [40] M. Espinosa, D. Weinberg, C. H. Rotela, F. Polop, M. Abril, and C. M. Scavuzzo, “Temporal dynamics and spatial patterns of *Aedes aegypti* breeding sites, in the context of a dengue control program in Tartagal (Salta province, Argentina),” *PLoS neglected tropical diseases*, vol. 10, no. 5, p. e0004621, 2016.
- [41] C. H. Rotela, “Desarrollo de modelos e indicadores remotos de riesgo epidemiológico de dengue en Argentina,” *Tesis doctoral*, Instituto de Altos Estudios Espaciales “Mario Gulich” Comisión Nacional de Actividades Espaciales – Universidad Nacional de Córdoba. Córdoba, Argentina 2012.
- [42] E. L. Estallo, F. Sangermano, M. Grech, F. Ludueña-Almeida, M. Frías-Céspedes, M. Ainete, W. Almirón, and T. Livdahl, “Modelling the distribution of the vector *Aedes aegypti* in a central Argentine city,” *Medical and veterinary entomology*, vol. 32, no. 4, pp. 451–461, 2018.
- [43] N. Barbash, “The geographical approach to urban environment-health relationships,” *Ecology of Disease*, vol. 2, no. 2, pp. 117–123, 1983.
- [44] G. A. Shaw and H. K. Burke, “Spectral imaging for remote sensing,” *Lincoln laboratory journal*, vol. 14, no. 1, pp. 3–28, 2003.
- [45] A. C. Watts, V. G. Ambrosia, and E. A. Hinkley, “Unmanned aircraft systems in remote sensing and scientific research: Classification and considerations of use,” *Remote Sensing*, vol. 4, no. 6, pp. 1671–1692, 2012.
- [46] E. Chuvieco, “Teledetección ambiental,” *La observación de la Tierra desde el espacio*, vol. 1, 2002.
- [47] N. J. Thrower, “Annals map supplement number twelve: Land use in the southwestern United States—from Gemini and Apollo imagery,” 1970.
- [48] J.-P. Donnay, M. J. Barnsley, and P. A. Longley, *Remote sensing and urban analysis: GISDATA 9*. CRC Press, 2000.
- [49] B. Forster, “Some urban measurements from Landsat data,” *Photogrammetric Engineering and Remote Sensing*, vol. 49, pp. 1693–1707, 1983.
- [50] D. P. Roy, M. A. Wulder, T. R. Loveland, C. E. Woodcock, R. G. Allen, M. C. Anderson, D. Helder, J. R. Irons, D. M. Johnson, R. Kennedy, *et al.*, “Landsat-8: Science and product vision for terrestrial global change research,” *Remote sensing of Environment*, vol. 145, pp. 154–172, 2014.
- [51] S. Bhaskaran, S. Paramananda, and M. Ramnarayan, “Per-pixel and object-oriented classification methods for mapping urban features using Ikonos satellite data,” *Applied Geography*, vol. 30, no. 4, pp. 650–665, 2010.

- [52] J. R. Jensen and D. C. Cowen, "Remote sensing of urban/suburban infrastructure and socio-economic attributes," *Photogrammetric engineering and remote sensing*, vol. 65, pp. 611–622, 1999.
- [53] A. Schneider, M. A. Friedl, and D. Potere, "A new map of global urban extent from modis satellite data," *Environmental research letters*, vol. 4, no. 4, p. 044003, 2009.
- [54] C. D. Elvidge, K. E. Baugh, E. A. Kihn, H. W. Kroehl, and E. R. Davis, "Mapping city lights with nighttime data from the dmsp operational linescan system," *Photogrammetric Engineering and Remote Sensing*, vol. 63, no. 6, pp. 727–734, 1997.
- [55] B. Yu, H. Liu, J. Wu, Y. Hu, and L. Zhang, "Automated derivation of urban building density information using airborne lidar data and object-based method," *Landscape and Urban Planning*, vol. 98, no. 3-4, pp. 210–219, 2010.
- [56] G. Lisini, A. Salentinig, P. Du, and P. Gamba, "Sar-based urban extents extraction: from envisat to sentinel-1," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 11, no. 8, pp. 2683–2691, 2017.
- [57] Z. Zhu, C. E. Woodcock, J. Rogan, and J. Kellndorfer, "Assessment of spectral, polarimetric, temporal, and spatial dimensions for urban and peri-urban land cover classification using landsat and sar data," *Remote Sensing of Environment*, vol. 117, pp. 72–82, 2012.
- [58] Z. Zhu, Y. Zhou, K. C. Seto, E. C. Stokes, C. Deng, S. T. Pickett, and H. Taubenböck, "Understanding an urbanizing planet: Strategic directions for remote sensing," *Remote Sensing of Environment*, vol. 228, pp. 164–182, 2019.
- [59] S. T. Pickett, M. L. Cadenasso, J. M. Grove, C. H. Nilon, R. V. Pouyat, W. C. Zipperer, and R. Costanza, "Urban ecological systems: linking terrestrial ecological, physical, and socioeconomic components of metropolitan areas," *Annual review of ecology and systematics*, vol. 32, no. 1, pp. 127–157, 2001.
- [60] B. N. Haack, "An analysis of thematic mapper simulator data for urban environments," *Remote Sensing of Environment*, vol. 13, no. 3, pp. 265–275, 1983.
- [61] D. A. Quattrochi, "An initial analysis of landsat-4 thematic mapper data for the discrimination of agricultural, forested wetlands, and urban land cover," *NASA. Goddard Space Flight Center LANDSAT-4 Sci. Characterization Early Results, Vol. 4*, 1985.
- [62] F. Henderson, S. Wharton, and D. Toll, "Preliminary results of mapping urban land cover with seasat sar imagery," in *In: American Society of Photogrammetry, Annual Meeting*, 1980.
- [63] M. L. Bryan, "Interpretation of an urban scene using multi-channel radar imagery," *Remote Sensing of Environment*, vol. 4, pp. 49–66, 1975.
- [64] S. P. Kraus, L. W. Senger, and J. M. Ryerson, "Estimating population from photographically determined residential land use types," *Remote sensing of Environment*, vol. 3, no. 1, pp. 35–42, 1974.
- [65] S. Murai, "Estimation of population density in tokyo districts from erts-1 data," in *International Symposium on Remote Sensing of Environment, 9 th, Ann Arbor, Mich*, pp. 13–22, 1974.

- [66] S. Mossoux, M. Kervyn, H. Soulé, and F. Canters, “Mapping population distribution from high resolution remotely sensed imagery in a data poor setting,” *Remote Sensing*, vol. 10, no. 9, p. 1409, 2018.
- [67] T. Grippa, C. Linard, M. Lennert, S. Georganos, N. Mboga, S. Vanhuyse, A. Gadiaga, and E. Wolff, “Improving urban population distribution models with very-high resolution satellite information,” *Data*, vol. 4, no. 1, p. 13, 2019.
- [68] M. Burchfield, H. G. Overman, D. Puga, and M. A. Turner, “Causes of sprawl: A portrait from space,” *The Quarterly Journal of Economics*, vol. 121, no. 2, pp. 587–633, 2006.
- [69] K. C. Seto, B. Güneralp, and L. R. Hutyrá, “Global forecasts of urban expansion to 2030 and direct impacts on biodiversity and carbon pools,” *Proceedings of the National Academy of Sciences*, vol. 109, no. 40, pp. 16083–16088, 2012.
- [70] A. Dean and G. Smith, “An evaluation of per-parcel land cover mapping using maximum likelihood class probabilities,” *International Journal of Remote Sensing*, vol. 24, no. 14, pp. 2905–2920, 2003.
- [71] P. Casals-Carrasco, S. Kubo, and B. B. Madhavan, “Application of spectral mixture analysis for terrain evaluation studies,” *International Journal of Remote Sensing*, vol. 21, no. 16, pp. 3039–3055, 2000.
- [72] K. Wang, S. E. Franklin, X. Guo, Y. He, and G. J. McDermid, “Problems in remote sensing of landscapes and habitats,” *Progress in Physical Geography*, vol. 33, no. 6, pp. 747–768, 2009.
- [73] T. Blaschke, S. Lang, E. Lorup, J. Strobl, and P. Zeil, “Object-oriented image processing in an integrated gis/remote sensing environment and perspectives for environmental applications,” *Environmental information for planning, politics and the public*, vol. 2, pp. 555–570, 2000.
- [74] G. Hay, D. Marceau, P. Dube, and A. Bouchard, “A multiscale framework for landscape analysis: object-specific analysis and upscaling,” *Landscape Ecology*, vol. 16, no. 6, pp. 471–490, 2001.
- [75] T. Blaschke, C. Burnett, and A. Pekkarinen, “New contextual approaches using image segmentation for objectbased classification,” *Remote sensing image analysis: Including the spatial domain/Ed. De Meer, F. & de Jong, S.*, 2004.
- [76] T. Blaschke, “Object based image analysis for remote sensing,” *ISPRS journal of photogrammetry and remote sensing*, vol. 65, no. 1, pp. 2–16, 2010.
- [77] M. Baatz, C. Hoffmann, and G. Willhauck, “Progressing from object-based to object-oriented image analysis,” in *Object-Based Image Analysis*, pp. 29–42, Springer, 2008.
- [78] L. Ma, M. Li, X. Ma, L. Cheng, P. Du, and Y. Liu, “A review of supervised object-based land-cover image classification,” *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 130, pp. 277–293, 2017.
- [79] G. Castilla and G. Hay, “Image objects and geographic objects,” in *Object-based image analysis*, pp. 91–110, Springer, 2008.

- [80] F. L. Soper, "The elimination of urban yellow fever in the americas through the eradication of *Aedes aegypti*," *American Journal of Public Health and the Nations Health*, vol. 53, no. 1, pp. 7–16, 1963.
- [81] F. Rodhain, "L'écologie d'*Aedes aegypti* en afrique et en asie," *Bull Soc Pathol Exot*, vol. 89, pp. 103–6, 1996.
- [82] D. VEZZANI, H. CETRARO, and F. S. CHOPA, "Vigilancia del vector del dengue en el límite de su distribución. una experiencia colaborativa entre los ámbitos científico, municipal y ciudadano,"
- [83] A. Rubio, M. V. Cardo, D. Vezzani, and A. E. Carbajo, "*Aedes aegypti* spreading in south america: new coldest and southernmost records," *Memórias do Instituto Oswaldo Cruz*, vol. 115, 2020.
- [84] W. H. Organization, S. P. for Research, T. in Tropical Diseases, W. H. O. D. of Control of Neglected Tropical Diseases, W. H. O. Epidemic, and P. Alert, *Dengue: guidelines for diagnosis, treatment, prevention and control*. World Health Organization, 2009.
- [85] G. K. G. MG and G. Kouri, "Dengue: an update," *Lancet Infect Dis*, vol. 2, pp. 33–42, 2002.
- [86] O. Horstick, R. Boyce, and S. Runge-Ranzinger, "Dengue vector control: assessing what works?," *SOUTHEAST ASIAN JOURNAL OF TROPICAL MEDICINE AND PUBLIC HEALTH*, vol. 48, pp. 181–195, 2017.
- [87] B. Wisner, J. Adams, and J. Adams, *Environmental health in emergencies and disasters: a practical guide*. World health organization, 2002.
- [88] J. A. Bisset Lazcano, M. d. C. Marquetti Fernández, D. Montada Dorta, N. Hernández Contreras, M. Leyva Silva, O. Fuentes González, M. Castex Rodríguez, Z. Menéndez Díaz, I. García García, M. Castillo Pérez, *et al.*, "Aportes científicos del instituto de medicina tropical"pedro kouri.^a la vigilancia de *Aedes aegypti* (díptera: Culicidae) en cuba, 1982-2020," *Revista Cubana de Medicina Tropical*, vol. 73, no. 3, 2021.
- [89] R. Barrera, "Recomendaciones para la vigilancia de *Aedes aegypti*," *Biomédica*, vol. 36, no. 3, pp. 454–462, 2016.
- [90] D. A. Focks *et al.*, "A review of entomological sampling methods and indicators for dengue vectors," 2004.
- [91] M. Mogi, W. Choochote, C. Khamboonruang, and P. Suwanpanit, "Applicability of presence–absence and sequential sampling for ovitrap surveillance of *Aedes* (diptera: Culicidae) in chiang mai, northern thailand," *Journal of Medical Entomology*, vol. 27, no. 4, pp. 509–514, 1990.
- [92] C. M. Berón, R. E. Campos, L. Díaz Nieto, N. Schweigmann, O. D. Salomón, and R. M. Gleiser, "Investigaciones sobre mosquitos de argentina," 2016.
- [93] D. Vezzani, A. Rubio, S. Velazquez, N. Schweigmann, and T. Wiegand, "Detailed assessment of microhabitat suitability for *Aedes aegypti* (diptera: Culicidae) in buenos aires, argentina," *Acta Tropica*, vol. 95, no. 2, pp. 123–131, 2005.

- [94] D. Vezzani and A. Albicócco, “The effect of shade on the container index and pupal productivity of the mosquitoes *Aedes aegypti* and *Culex pipiens* breeding in artificial containers,” *Medical and veterinary entomology*, vol. 23, no. 1, pp. 78–84, 2009.
- [95] A. Rubio, M. V. Cardo, A. E. Carbajo, and D. Vezzani, “Imperviousness as a predictor for infestation levels of container-breeding mosquitoes in a focus of dengue and saint louis encephalitis in argentina,” *Acta tropica*, vol. 128, no. 3, pp. 680–685, 2013.
- [96] A. Carbajo, S. Curto, and N. Schweigmann, “Spatial distribution pattern of oviposition in the mosquito *Aedes aegypti* in relation to urbanization in buenos aires: southern fringe bionomics of an introduced vector,” *Medical and veterinary Entomology*, vol. 20, no. 2, pp. 209–218, 2006.
- [97] V. D. C. S. I. Carbajo, Aníbal. E., “Asociación entre los niveles de infestación del mosquitos *Aedes aegypti* y las categorías de edificación según el código de planeamiento urbano de buenos aires,”
- [98] M. Grech, “Bioecología de culícidos (diptera) urbanos de importancia sanitaria de la ciudad de córdoba, córdoba (argentina),” *Facultad de Ciencias Exactas Físicas y Naturales. Universidad Nacional de Córdoba, Córdoba, Argentina*, 2013.
- [99] E. L. Estallo, G. Más, C. Vergara-Cid, M. A. Lanfri, F. Luduena-Almeida, C. M. Scavuzzo, M. V. Introini, M. Zaidenberg, and W. R. Almirón, “Spatial patterns of high *Aedes aegypti* oviposition activity in northwestern argentina,” *PloS One*, vol. 8, no. 1, p. e54167, 2013.
- [100] K. J. Linthicum, C. L. Bailey, F. G. Davies, and C. J. Tucker, “Detection of rift valley fever viral activity in kenya by satellite remote sensing imagery,” *Science*, vol. 235, no. 4796, pp. 1656–1659, 1987.
- [101] K. Pope, E. Sheffner, K. Linthicum, C. Bailey, T. Logan, E. Kasischke, K. Birney, A. Njogu, and C. Roberts, “Identification of central kenyan rift valley fever virus vector habitats with landsat tm and evaluation of their flooding status with airborne imaging radar,” *Remote Sensing of Environment*, vol. 40, no. 3, pp. 185–196, 1992.
- [102] S. J. Ryan, A. McNally, L. R. Johnson, E. A. Mordecai, T. Ben-Horin, K. Paaijmans, and K. D. Lafferty, “Mapping physiological suitability limits for malaria in africa under climate change,” *Vector-Borne and Zoonotic Diseases*, vol. 15, no. 12, pp. 718–725, 2015.
- [103] M. Ferraguti, J. Martínez-de La Puente, D. Roiz, S. Ruiz, R. Soriguer, and J. Figuerola, “Effects of landscape anthropization on mosquito community composition and abundance,” *Scientific reports*, vol. 6, no. 1, pp. 1–9, 2016.
- [104] S. K. Mcfeeters, “Geographic information system to detect swimming pools for mosquito abatement: a practical approach,” 2013.
- [105] G. Albrieu-Llinás, M. O. Espinosa, A. Quaglia, M. Abril, and C. M. Scavuzzo, “Urban environmental clustering to assess the spatial dynamics of *Aedes aegypti* breeding sites,” *Geospatial health*, vol. 13, no. 1, 2018.
- [106] K. A. Hartfield, K. I. Landau, and W. J. Van Leeuwen, “Fusion of high resolution aerial multispectral and lidar data: land cover in the context of urban mosquito habitat,” *Remote Sensing*, vol. 3, no. 11, pp. 2364–2383, 2011.

- [107] X. Li, C. Wang, G. Zhang, L. Xiao, and J. Dixon, “Urbanisation and human health in china: spatial features and a systemic perspective,” *Environmental Science and Pollution Research*, vol. 19, no. 5, pp. 1375–1384, 2012.
- [108] M. C. De Castro, Y. Yamagata, D. Mtasiwa, M. Tanner, J. Utzinger, J. Keiser, and B. H. Singer, “Integrated urban malaria control: a case study in dar es salaam, tanzania,” in *The Intolerable Burden of Malaria II: What’s New, What’s Needed: Supplement to Volume 71 (2) of the American Journal of Tropical Medicine and Hygiene*, American Society of Tropical Medicine and Hygiene, 2004.
- [109] C. W. Kabaria, F. Molteni, R. Mandike, F. Chacky, A. M. Noor, R. W. Snow, and C. Linard, “Mapping intra-urban malaria risk using high resolution satellite imagery: a case study of dar es salaam,” *International journal of health geographics*, vol. 15, no. 1, pp. 1–12, 2016.
- [110] R. V. Araujo, M. R. Albertini, A. L. Costa-da Silva, L. Suesdek, N. C. S. Franceschi, N. M. Bastos, G. Katz, V. A. Cardoso, B. C. Castro, M. L. Capurro, *et al.*, “São paulo urban heat islands have a higher incidence of dengue than other urban areas,” *Brazilian Journal of Infectious Diseases*, vol. 19, pp. 146–155, 2015.
- [111] M. Kuffer, K. Pfeffer, and R. Sliuzas, “Slums from space—15 years of slum mapping using remote sensing,” *Remote Sensing*, vol. 8, no. 6, p. 455, 2016.
- [112] M. Wurm, H. Taubenböck, M. Weigand, and A. Schmitt, “Slum mapping in polarimetric sar data using spatial features,” *Remote sensing of environment*, vol. 194, pp. 190–204, 2017.
- [113] V. Machault, C. Vignolles, F. Pagès, L. Gadiaga, A. Gaye, C. Sokhna, J.-F. Trape, J.-P. Lacaux, and C. Rogier, “Spatial heterogeneity and temporal evolution of malaria transmission risk in dakar, senegal, according to remotely sensed environmental data,” *Malaria journal*, vol. 9, no. 1, pp. 1–14, 2010.
- [114] R. K. Washino and B. L. Wood, “Application of remote sensing to vector arthropod surveillance and control,” *Am J Trop Med Hyg*, vol. 50, no. 134, p. 44, 1993.
- [115] M. FORMAN, R. T. T.; GODRON, *Landscape Ecology*. Nueva York: Wiley and Sons., 1986.
- [116] P. D. Taylor, L. Fahrig, K. Henein, and G. Merriam, “Connectivity is a vital element of landscape structure,” *Oikos*, pp. 571–573, 1993.
- [117] J. A. Hilty, W. Z. Lidicker, and A. M. Merenlender, “Corridor ecology: the science and practice of linking landscapes for biodiversity conservation island press,” *Connecticut Avenue, Washington*, 2006.
- [118] J. B. Sendra and R. C. García, “El uso de los sistemas de información geografica en la planificación territorial.,” in *Anales de Geografía de la Universidad complutense*, vol. 20, p. 49, 2000.
- [119] K. McGarigal and B. J. Marks, “Spatial pattern analysis program for quantifying landscape structure,” *Gen. Tech. Rep. PNW-GTR-351. US Department of Agriculture, Forest Service, Pacific Northwest Research Station*, pp. 1–122, 1995.
- [120] E. J. Gustafson, “Quantifying landscape spatial pattern: what is the state of the art?,” *Ecosystems*, vol. 1, no. 2, pp. 143–156, 1998.

- [121] S. D. Matteucci and M. Silva, “Selección de métricas de configuración espacial para la regionalización de un territorio antropizado,” *GeoFocus. Revista Internacional de Ciencia y Tecnología de la Información Geográfica*, no. 5, pp. 180–202, 2005.
- [122] D. Cocero Matesanz, M. Azcárate Luxan, F. J. García Lázaro, C. Muguruza Cañas, and J. M. Santos Preciado, “Análisis de la evolución de la estructura espacial del uso del suelo residencial en el área metropolitana madrileña,” in *Congreso Nacional de Tecnologías de la Información Geográfica (14. 2010. Sevilla)(2010)*, p 777-787, Universidad de Sevilla, 2010.
- [123] C. Li, J. Zhao, and Y. Xu, “Examining spatiotemporally varying effects of urban expansion and the underlying driving factors,” *Sustainable cities and society*, vol. 28, pp. 307–320, 2017.
- [124] M. Herold, H. Couclelis, and K. C. Clarke, “The role of spatial metrics in the analysis and modeling of urban land use change,” *Computers, environment and urban systems*, vol. 29, no. 4, pp. 369–399, 2005.
- [125] M. Alberti, “Urban patterns and environmental performance: what do we know?,” *Journal of planning education and research*, vol. 19, no. 2, pp. 151–163, 1999.
- [126] M. Herold, N. C. Goldstein, and K. C. Clarke, “The spatiotemporal form of urban growth: measurement, analysis and modeling,” *Remote sensing of Environment*, vol. 86, no. 3, pp. 286–302, 2003.
- [127] D. Franco, A. Bombonato, I. Mannino, P. Ghetti, and G. Zanetto, “The evaluation of a planning tool through the landscape ecology concepts and methods,” *Management of Environmental Quality: An International Journal*, 2005.
- [128] S. Berling-Wolff and J. Wu, “Modeling urban landscape dynamics: a case study in phoenix, usa,” *Urban ecosystems*, vol. 7, no. 3, pp. 215–240, 2004.
- [129] C. Luca, “Generative platform for urban and regional design,” *Automation in Construction*, vol. 16, no. 1, pp. 70–77, 2007.
- [130] T. Prato, “Evaluating land use plans under uncertainty,” *Land use policy*, vol. 24, no. 1, pp. 165–174, 2007.
- [131] A. Gregrio, J. Jansen, *et al.*, “Land cover classification system (lccs); classification concepts and user manual for software version 2,” 2000.
- [132] K. C. Seto, M. Fragkias, B. Güneralp, and M. K. Reilly, “A meta-analysis of global urban land expansion,” *PloS one*, vol. 6, no. 8, p. e23777, 2011.
- [133] A. Schneider, M. A. Friedl, and D. Potere, “Mapping global urban areas using modis 500-m data: New methods and datasets based on ‘urban ecoregions’,” *Remote Sensing of Environment*, vol. 114, no. 8, pp. 1733–1746, 2010.
- [134] J. P. Kaye, P. M. Groffman, N. B. Grimm, L. A. Baker, and R. V. Pouyat, “A distinct urban biogeochemistry?,” *Trends in Ecology & Evolution*, vol. 21, no. 4, pp. 192–199, 2006.
- [135] L. L. Coulter, D. A. Stow, Y.-H. Tsai, N. Ibanez, H.-c. Shih, A. Kerr, M. Benza, J. R. Weeks, and F. Mensah, “Classification and assessment of land cover and land use change in southern ghana using dense stacks of landsat 7 etm+ imagery,” *Remote Sensing of Environment*, vol. 184, pp. 396–409, 2016.

- [136] C. Gómez and A. Michael, “Wulder., white jc optical remotely sensed time series data for land cover classification: A review. international society for photogrammetry and remote sensing,” *Journal of Photogrammetry and Remote Sensing*, vol. 116, pp. 55–72, 2016.
- [137] M. C. Pagliarella, L. Sallustio, G. Capobianco, E. Conte, P. Corona, L. Fattorini, and M. Marchetti, “From one-to two-phase sampling to reduce costs of remote sensing-based estimation of land-cover and land-use proportions and their changes,” *Remote Sensing of Environment*, vol. 184, pp. 410–417, 2016.
- [138] F. Pacifici, M. Chini, and W. J. Emery, “A neural network approach using multi-scale textural metrics from very high-resolution panchromatic imagery for urban land-use classification,” *Remote Sensing of Environment*, vol. 113, no. 6, pp. 1276–1292, 2009.
- [139] A. J. Comber, C. F. Brunson, and C. J. Farmer, “Community detection in spatial networks: Inferring land use from a planar graph of land cover objects,” *International Journal of Applied Earth Observation and Geoinformation*, vol. 18, pp. 274–282, 2012.
- [140] M. Voltersen, C. Berger, S. Hese, and C. Schmullius, “Object-based land cover mapping and comprehensive feature calculation for an automated derivation of urban structure types at block level,” *Remote Sensing of Environment*, vol. 154, pp. 192–201, 2014.
- [141] S. Myint, V. Mesev, and N. Lam, “Texture analysis and classification through a modified lacunarity analysis based on differential box counting method,” *Geographical Analysis*, vol. 38, pp. 371–390, 2006.
- [142] I. L. Castillejo-González, F. López-Granados, A. García-Ferrer, J. M. Peña-Barragán, M. Jurado-Expósito, M. S. de la Orden, and M. González-Audicana, “Object-and pixel-based analysis for mapping crops and their agro-environmental associated measures using quickbird imagery,” *Computers and Electronics in Agriculture*, vol. 68, no. 2, pp. 207–215, 2009.
- [143] G. M. Foody, “Status of land cover classification accuracy assessment,” *Remote sensing of environment*, vol. 80, no. 1, pp. 185–201, 2002.
- [144] D. Lu and Q. Weng, “Use of impervious surface in urban land-use classification,” *Remote sensing of environment*, vol. 102, no. 1-2, pp. 146–160, 2006.
- [145] P. Gong and P. J. Howarth, “The use of structural information for improving land-cover classification accuracies at the rural-urban fringe,” *Photogrammetric Engineering & Remote Sensing*, 1990.
- [146] M. Shaban and O. Dikshit, “Improvement of classification in urban areas by the use of textural features: the case study of lucknow city, uttar pradesh,” *International Journal of remote sensing*, vol. 22, no. 4, pp. 565–593, 2001.
- [147] S. W. Myint, P. Gober, A. Brazel, S. Grossman-Clarke, and Q. Weng, “Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery,” *Remote sensing of environment*, vol. 115, no. 5, pp. 1145–1161, 2011.
- [148] P. Fisher, “The pixel: a snare and a delusion,” *International Journal of Remote Sensing*, vol. 18, no. 3, pp. 679–685, 1997.

- [149] C. Burnett and T. Blaschke, “A multi-scale segmentation/object relationship modelling methodology for landscape analysis,” *Ecological modelling*, vol. 168, no. 3, pp. 233–249, 2003.
- [150] S. Lang, “Object-based image analysis for remote sensing applications: modeling reality—dealing with complexity,” in *Object-based image analysis*, pp. 3–27, Springer, 2008.
- [151] D. A. Quattrochi and R. E. Pelletier, “Remote sensing for analysis of landscapes: an introduction,” *Ecological Studies*, vol. 82, pp. 51–76, 1991.
- [152] S. Georganos, T. Grippa, M. Lennert, S. Vanhuyse, B. A. Johnson, and E. Wolff, “Scale matters: Spatially partitioned unsupervised segmentation parameter optimization for large and heterogeneous satellite images,” *Remote Sensing*, vol. 10, no. 9, p. 1440, 2018.
- [153] E. A. Willington, M. Nolasco, and M. Bocco, “Clasificación supervisada de suelos de uso agrícola en la zona central de córdoba (argentina): comparación de distintos algoritmos sobre imágenes landsat,” in *V Congreso Argentino de AgroInformática (CAI)-JAIIO 42 (2013)*, 2013.
- [154] M. V. Marinelli, “Herramientas analíticas de valoración y cuantificación de la producción hortícola basada en sensores remotos,” Master’s thesis.
- [155] O. Mudele and P. Gamba, “Mapping vegetation in urban areas using sentinel-2,” in *2019 Joint Urban Remote Sensing Event (JURSE)*, pp. 1–4, IEEE, 2019.
- [156] I. N. de Estadística y Censos., “National Population, Homes and Houses Census. [Censo Nacional de Población, Hogares y Viviendas],” 2010.
- [157] B. Jarsún, J. Gorgas, E. Zamora, E. Bosnero, E. Lovera, A. Ravelo, J. Tassile, and J. Gorjas, “Recursos naturales de la provincia de cordoba: Los suelos,” *Nivel de Reconocimiento*, vol. 1, no. 500.000, p. 541, 2003.
- [158] C. Zietsman, “GRASS Development Team Addon i.atcorr. *Geographic Resources Analysis Support System (GRASS) Software, Version 7.3*.” Open Source Geospatial Foundation: Chicago, IL, USA. Available online: <https://grass.osgeo.org/grass78/manuals/i.atcorr.html>. accessed on 20/06/2021.
- [159] M. Neteler, D. Beaudette, P. Cavallini, L. Lami, and J. Cepicky, “Grass gis,” in *Open source approaches in spatial data handling*, pp. 171–199, Springer, 2008.
- [160] Astrium GEO-Information Services, *Pléiades Imagery - User Guide*. GEO-Information Services, October 2012.
- [161] N. Alexandris, “GRASS Development Team Addon i.fusion.hpf. *Geographic Resources Analysis Support System (GRASS) Software, Version 7.3*.” Open Source Geospatial Foundation: Chicago, IL, USA. Available online: <https://grass.osgeo.org/grass78/manuals/addons/i.fusion.hpf.html>. accessed on 21/06/2021.
- [162] U. G. Gangkofner, P. S. Pradhan, and D. W. Holcomb, “Optimizing the high-pass filter addition technique for image fusion,” *Photogrammetric Engineering & Remote Sensing*, vol. 73, no. 9, pp. 1107–1118, 2007.

- [163] M. Lennert, “GRASS Development Team Addon r.texture.tiled. *Geographic Resources Analysis Support System (GRASS) Software, Version 7.3.*” Open Source Geospatial Foundation: Chicago, IL, USA. Available online: <https://grass.osgeo.org/grass78/manuals/addons/r.texture.tiled.html>. accessed on 30/08/2021.
- [164] J. R. Jensen, *Remote sensing of the environment: An earth resource perspective 2/e.* Pearson Education India, 2009.
- [165] G. Quantum, “Qgis development team–qgis geographic information system. open source geospatial foundation project,” 2015.
- [166] L. Breiman, “Random forests,” *Machine learning*, vol. 45, no. 1, pp. 5–32, 2001.
- [167] M. Belgiu and L. Drăguț, “Random forest in remote sensing: A review of applications and future directions,” *ISPRS journal of photogrammetry and remote sensing*, vol. 114, pp. 24–31, 2016.
- [168] R. R. Colditz, “An evaluation of different training sample allocation schemes for discrete and continuous land cover classification using decision tree-based algorithms,” *Remote Sensing*, vol. 7, no. 8, pp. 9655–9681, 2015.
- [169] J. Haas and Y. Ban, “Urban growth and environmental impacts in jing-jin-ji, the yangtze, river delta and the pearl river delta,” *International Journal of Applied Earth Observation and Geoinformation*, vol. 30, pp. 42–55, 2014.
- [170] N. Tsutsumida and A. J. Comber, “Measures of spatio-temporal accuracy for time series land cover data,” *International Journal of Applied Earth Observation and Geoinformation*, vol. 41, pp. 46–55, 2015.
- [171] D. R. Cutler, T. C. Edwards Jr, K. H. Beard, A. Cutler, K. T. Hess, J. Gibson, and J. J. Lawler, “Random forests for classification in ecology,” *Ecology*, vol. 88, no. 11, pp. 2783–2792, 2007.
- [172] N. Gorelick, “Google earth engine,” in *EGU General Assembly Conference Abstracts*, vol. 15, p. 11997, American Geophysical Union Vienna, Austria, 2013.
- [173] T. Blaschke, S. Lang, and G. Hay, *Object-based image analysis: spatial concepts for knowledge-driven remote sensing applications.* Springer Science & Business Media, 2008.
- [174] H.-D. Cheng, X. H. Jiang, Y. Sun, and J. Wang, “Color image segmentation: advances and prospects,” *Pattern recognition*, vol. 34, no. 12, pp. 2259–2281, 2001.
- [175] Y. J. Zhang, “Evaluation and comparison of different segmentation algorithms,” *Pattern recognition letters*, vol. 18, no. 10, pp. 963–974, 1997.
- [176] G. Mountrakis, J. Im, and C. Ogole, “Support vector machines in remote sensing: A review,” *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 66, no. 3, pp. 247–259, 2011.
- [177] T. Su and S. Zhang, “Local and global evaluation for remote sensing image segmentation,” *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 130, pp. 256–276, 2017.

- [178] T. Grippa, M. Lennert, B. Beaumont, S. Vanhuyse, N. Stephenne, and E. Wolff, “An open-source semi-automated processing chain for urban object-based classification,” *Remote Sensing*, vol. 9, no. 4, 2017.
- [179] N. R. Pal and S. K. Pal, “A review on image segmentation techniques,” *Pattern recognition*, vol. 26, no. 9, pp. 1277–1294, 1993.
- [180] H. Costa, G. M. Foody, and D. S. Boyd, “Supervised methods of image segmentation accuracy assessment in land cover mapping,” *Remote Sensing of Environment*, vol. 205, pp. 338–351, 2018.
- [181] B. W. Heumann, “An object-based classification of mangroves using a hybrid decision tree—support vector machine approach,” *Remote Sensing*, vol. 3, no. 11, pp. 2440–2460, 2011.
- [182] T. Grippa, M. Lennert, B. Beaumont, S. Vanhuyse, N. Stephenne, and E. Wolff, “An open-source semi-automated processing chain for urban object-based classification,” *Remote Sensing*, vol. 9, no. 4, p. 358, 2017.
- [183] P. Perona and J. Malik, “Scale-space and edge detection using anisotropic diffusion,” *IEEE Transactions on pattern analysis and machine intelligence*, vol. 12, no. 7, pp. 629–639, 1990.
- [184] J. R. Beveridge, J. Griffith, R. R. Kohler, A. R. Hanson, and E. M. Riseman, “Segmenting images using localized histograms and region merging,” *International Journal of Computer Vision*, vol. 2, no. 3, pp. 311–347, 1989.
- [185] K. Haris, S. N. Efstratiadis, N. Maglaveras, and A. K. Katsaggelos, “Hybrid image segmentation using watersheds and fast region merging,” *IEEE Transactions on image processing*, vol. 7, no. 12, pp. 1684–1699, 1998.
- [186] J. Canny, “A computational approach to edge detection,” *IEEE Transactions on pattern analysis and machine intelligence*, no. 6, pp. 679–698, 1986.
- [187] I. M. M. Rashad Kanavath, “GRASS Development Team Addon i.superpixels.slic..”
- [188] M. Lennert, “GRASS Development Team Addon i.cutlines. *Geographic Resources Analysis Support System (GRASS) Software.*” Open Source Geospatial Foundation: Chicago, IL, USA. Available online: <https://grass.osgeo.org/grass78/manuals/addons/i.cutlines.html>. accessed on 20/08/2021.
- [189] M. D. Hossain and D. Chen, “Segmentation for object-based image analysis (obia): A review of algorithms and challenges from remote sensing perspective,” *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 150, pp. 115–134, 2019.
- [190] E. Momsen, “Grass gsoc 2012 image segmentation. repository: Grass 7, browse at: i.segment..” https://grasswiki.osgeo.org/wiki/GRASS_GSoC_2012_Image_Segmentation#Region_Growing_Algorithm, 22 de diciembre 2015.
- [191] G. Espindola, G. Câmara, I. Reis, L. Bins, and A. Monteiro, “Parameter selection for region-growing image segmentation algorithms using spatial autocorrelation,” *International Journal of Remote Sensing*, vol. 27, no. 14, pp. 3035–3040, 2006.

- [192] M. Lennert, “GRASS Development Team Addon i.segment.uspo. *Geographic Resources Analysis Support System (GRASS) Software*.” Open Source Geospatial Foundation: Chicago, IL, USA. Available online: <https://grass.osgeo.org/grass78/manuals/addons/i.segment.uspo.html>. accessed on 10/08/2021.
- [193] M. Belgiu and L. Drăguț, “Comparing supervised and unsupervised multiresolution segmentation approaches for extracting buildings from very high resolution imagery,” *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 96, pp. 67–75, 2014.
- [194] M. Lennert, “GRASS Development Team Addon i.segment.stats. *Geographic Resources Analysis Support System (GRASS) Software, Version 7.3*.” Open Source Geospatial Foundation: Chicago, IL, USA. Available online: <https://grass.osgeo.org/grass70/manuals/addons/i.segment.stats.html>. accessed on 15/08/2021.
- [195] M. Lennert, “GRASS Development Team Addon i.segment.stats. *Geographic Resources Analysis Support System (GRASS) Software, Version 7.3*.” Open Source Geospatial Foundation: Chicago, IL, USA. Available online: <https://grass.osgeo.org/grass70/manuals/addons/v.class.mlR.html>. accessed on 25/08/2021.
- [196] M. Kuhn, “Building predictive models in r using the caret package,” *Journal of statistical software*, vol. 28, no. 1, pp. 1–26, 2008.
- [197] T. Boca and G. Rodríguez, “Métodos estadísticos de la evaluación de la exactitud de productos derivados de sensores remotos,” *Instituto de Clima y Agua, INTA Castelar*, 2012.
- [198] R. A. Monserud and R. Leemans, “Comparing global vegetation maps with the kappa statistic,” *Ecological modelling*, vol. 62, no. 4, pp. 275–293, 1992.
- [199] T. Grippa, S. Georganos, S. Zarougui, P. Bognounou, E. Diboulo, Y. Forget, M. Lennert, S. Vanhuyse, N. Mboga, and E. Wolff, “Mapping urban land use at street block level using openstreetmap, remote sensing data, and spatial metrics,” *ISPRS International Journal of Geo-Information*, vol. 7, no. 7, p. 246, 2018.
- [200] V. Arévalo, J. González, and G. Ambrosio, “Shadow detection in colour high-resolution satellite images,” *International Journal of Remote Sensing*, vol. 29, no. 7, pp. 1945–1963, 2008.
- [201] Y. Chen, D. Wen, L. Jing, and P. Shi, “Shadow information recovery in urban areas from very high resolution satellite imagery,” *International Journal of Remote Sensing*, vol. 28, no. 15, pp. 3249–3254, 2007.
- [202] K.-L. Chung, Y.-R. Lin, and Y.-H. Huang, “Efficient shadow detection of color aerial images based on successive thresholding scheme,” *IEEE Transactions on Geoscience and Remote sensing*, vol. 47, no. 2, pp. 671–682, 2008.
- [203] B.-C. Gao, “NdwI—a normalized difference water index for remote sensing of vegetation liquid water from space,” *Remote sensing of environment*, vol. 58, no. 3, pp. 257–266, 1996.
- [204] B. Leblon, L. Gallant, and H. Granberg, “Effects of shadowing types on ground-measured visible and near-infrared shadow reflectances,” *Remote Sensing of Environment*, vol. 58, no. 3, pp. 322–328, 1996.

- [205] P. M. Dare, “Shadow analysis in high-resolution satellite imagery of urban areas,” *Photogrammetric Engineering & Remote Sensing*, vol. 71, no. 2, pp. 169–177, 2005.
- [206] W. Huang and M. Bu, “Detecting shadows in high-resolution remote-sensing images of urban areas using spectral and spatial features,” *International Journal of Remote Sensing*, vol. 36, no. 24, pp. 6224–6244, 2015.
- [207] K. Yu, Y. Chen, D. Wang, Z. Chen, A. Gong, and J. Li, “Study of the seasonal effect of building shadows on urban land surface temperatures based on remote sensing data,” *remote sensing*, vol. 11, no. 5, p. 497, 2019.
- [208] J. Tang, S. Alelyani, and H. Liu, “Feature selection for classification: A review,” *Data classification: Algorithms and applications*, p. 37, 2014.
- [209] C. COMPUTACIONALES, *Selección de variables para clasificación no supervisada utilizando un enfoque híbrido Filter-Wrapper*. PhD thesis, INSTITUTO NACIONAL DE ASTROFÍSICA ÓPTICA Y ELECTRÓNICA, 2010.
- [210] M. Dash and H. Liu, “Feature selection for classification,” *Intelligent data analysis*, vol. 1, no. 1-4, pp. 131–156, 1997.
- [211] N. Brenner *et al.*, “Implosions/explosions,” *Berlin: Jovis*, 2014.
- [212] T. G. McGee, “9 the emergence of desakota regions in asia: Expanding a hypothesis,” in *Implosions/Explosions*, pp. 121–137, JOVIS Verlag GmbH, 2015.
- [213] H. Taubenböck, N. J. Kraff, and M. Wurm, “The morphology of the arrival city—a global categorization based on literature surveys and remotely sensed data,” *Applied Geography*, vol. 92, pp. 150–167, 2018.
- [214] D. R. Grafius, R. Corstanje, and J. A. Harris, “Linking ecosystem services, urban form and green space configuration using multivariate landscape metric analysis,” *Landscape ecology*, vol. 33, no. 4, pp. 557–573, 2018.
- [215] K. C. Seto, S. Dhakal, A. Bigio, H. Blanco, G. C. Delgado, D. Dewar, L. Huang, A. Inaba, A. Kansal, S. Lwasa, *et al.*, “Human settlements, infrastructure and spatial planning,” 2014.
- [216] A. Ramaswami, A. G. Russell, P. J. Culligan, K. R. Sharma, and E. Kumar, “Meta-principles for developing smart, sustainable, and healthy cities,” *Science*, vol. 352, no. 6288, pp. 940–943, 2016.
- [217] J. Southworth, H. Nagendra, and C. Tucker, “Fragmentation of a landscape: Incorporating landscape metrics into satellite analyses of land-cover change,” *Landscape Research*, vol. 27, no. 3, pp. 253–269, 2002.
- [218] E. Uuemaa, M. Antrop, J. Roosaare, R. Marja, and U. Mander, “Landscape metrics and indices: An overview of their use in landscape research. living review landscape research 3,” 2009.
- [219] C. R. Fichera, G. Modica, and M. Pollino, “Land cover classification and change-detection analysis using multi-temporal remote sensed imagery and landscape metrics,” *European journal of remote sensing*, vol. 45, no. 1, pp. 1–18, 2012.

- [220] P. Szilassi, T. Bata, S. Szabó, B. Czúcz, Z. Molnár, and G. Mezősi, “The link between landscape pattern and vegetation naturalness on a regional scale,” *Ecological Indicators*, vol. 81, pp. 252–259, 2017.
- [221] M. Kumar, D. M. Denis, S. K. Singh, S. Szabó, and S. Suryavanshi, “Landscape metrics for assessment of land cover change and fragmentation of a heterogeneous watershed,” *Remote Sensing Applications: Society and Environment*, vol. 10, pp. 224–233, 2018.
- [222] S. K. Singh, P. B. Laari, S. Mustak, P. K. Srivastava, and S. Szabó, “Modelling of land use land cover change using earth observation data-sets of tons river basin, madhya pradesh, india,” *Geocarto international*, vol. 33, no. 11, pp. 1202–1222, 2018.
- [223] S. Szabo, P. Csorba, and P. Szilassi, “Tools for landscape ecological planning—scale, and aggregation sensitivity of the contagion type landscape metric indices,” *Carpathian Journal of Earth and Environmental Sciences*, vol. 7, no. 3, pp. 127–136, 2012.
- [224] N. Csikós and P. Szilassi, “Impact of energy landscapes on the abundance of eurasian skylark (*alauda arvensis*), an example from north germany,” *Sustainability*, vol. 12, no. 2, p. 664, 2020.
- [225] L. Jiao, Y. Liu, and H. Li, “Characterizing land-use classes in remote sensing imagery by shape metrics,” *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 72, pp. 46–55, 2012.
- [226] J. A. Cardille and M. Lambois, “From the redwood forest to the gulf stream waters: human signature nearly ubiquitous in representative us landscapes,” *Frontiers in Ecology and the Environment*, vol. 8, no. 3, pp. 130–134, 2010.
- [227] K. Partington and J. A. Cardille, “Uncovering dominant land-cover patterns of quebec: Representative landscapes, spatial clusters, and fences,” *Land*, vol. 2, no. 4, pp. 756–773, 2013.
- [228] J. Niesterowicz and T. F. Stepinski, “Regionalization of multi-categorical landscapes using machine vision methods,” *Applied Geography*, vol. 45, pp. 250–258, 2013.
- [229] J. Niesterowicz and T. F. Stepinski, “On using landscape metrics for landscape similarity search,” *Ecological indicators*, vol. 64, pp. 20–30, 2016.
- [230] E. J. Gustafson, “How has the state-of-the-art for quantification of landscape pattern advanced in the twenty-first century?,” *Landscape Ecology*, vol. 34, no. 9, pp. 2065–2072, 2019.
- [231] E. Uuemaa, Ü. Mander, and R. Marja, “Trends in the use of landscape spatial metrics as landscape indicators: a review,” *Ecological Indicators*, vol. 28, pp. 100–106, 2013.
- [232] K. McGarigal, *FRAGSTATS: spatial pattern analysis program for quantifying landscape structure*, vol. 351. US Department of Agriculture, Forest Service, Pacific Northwest Research Station, 1995.
- [233] A. B. Leitão, J. Miller, J. Ahern, and K. McGarigal, *Measuring landscapes: A planner’s handbook*. Island press, 2012.

- [234] K. McGarigal, S. A. Cushman, and E. Ene, “Fragstats v4: spatial pattern analysis program for categorical and continuous maps,” *Computer software program produced by the authors at the University of Massachusetts, Amherst. Available at the following web site: <http://www.umass.edu/landeco/research/fragstats/fragstats.html>*, 2012.
- [235] J. A. Kupfer, “Landscape ecology and biogeography: rethinking landscape metrics in a post-fragstats landscape,” *Progress in physical geography*, vol. 36, no. 3, pp. 400–420, 2012.
- [236] M. Sciaini, M. Fritsch, C. Scherer, and C. E. Simpkins, “Nlmmr and landscapetools: An integrated environment for simulating and modifying neutral landscape models in r,” *Methods in ecology and evolution*, vol. 9, no. 11, pp. 2240–2248, 2018.
- [237] R. Fletcher and M. Fortin, *Spatial ecology and conservation modeling*. Springer, 2018.
- [238] S. A. Cushman, K. McGarigal, and M. C. Neel, “Parsimony in landscape metrics: strength, universality, and consistency,” *Ecological indicators*, vol. 8, no. 5, pp. 691–703, 2008.
- [239] S. Schindler, K. Poirazidis, and T. Wrbka, “Towards a core set of landscape metrics for biodiversity assessments: a case study from dadia national park, greece,” *Ecological indicators*, vol. 8, no. 5, pp. 502–514, 2008.
- [240] A. Lustig, D. B. Stouffer, M. Roigé, and S. P. Worner, “Towards more predictable and consistent landscape metrics across spatial scales,” *Ecological Indicators*, vol. 57, pp. 11–21, 2015.
- [241] J. Nowosad and T. F. Stepinski, “Information theory as a consistent framework for quantification and classification of landscape patterns,” *Landscape Ecology*, vol. 34, no. 9, pp. 2091–2101, 2019.
- [242] P. Šímová and K. Gdulová, “Landscape indices behavior: a review of scale effects,” *Applied geography*, vol. 34, pp. 385–394, 2012.
- [243] J. MacQueen *et al.*, “Some methods for classification and analysis of multivariate observations,” in *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability*, vol. 1, pp. 281–297, Oakland, CA, USA, 1967.
- [244] C. Fraley and A. E. Raftery, “How many clusters? which clustering method? answers via model-based cluster analysis,” *The computer journal*, vol. 41, no. 8, pp. 578–588, 1998.
- [245] G. James, D. Witten, T. Hastie, and R. Tibshirani, *An introduction to statistical learning*, vol. 112. Springer, 2013.
- [246] M. Lennert, “GRASS Development Team Addon v.rast.stats. *Geographic Resources Analysis Support System (GRASS) Software, Version 7.3*.” Open Source Geospatial Foundation: Chicago, IL, USA. Available online: <https://grass.osgeo.org/grass78/manuals/v.rast.stats.html>. accessed on 12/01/2022.
- [247] T. GRIPPA, “Grass development team addon r.zonal.classes. universite libre de bruxelles. anageo lab., howpublished = Open Source Geospatial Foundation: Chicago, IL, USA. Available online: <https://grass.osgeo.org/grass78/manuals/addons/r.zonal.classes.html>, year = 2020, note = accessed on 01/01/2022.”

- [248] I. Thomas, P. Frankhauser, B. Frenay, and M. Verleysen, “Clustering patterns of urban built-up areas with curves of fractal scaling behaviour,” *Environment and Planning B: Planning and Design*, vol. 37, no. 5, pp. 942–954, 2010.
- [249] R. Hamaina, T. Leduc, and G. Moreau, “Towards urban fabrics characterization based on buildings footprints,” in *Bridging the Geographic Information Sciences*, pp. 327–346, Springer, 2012.
- [250] N. Montenegro, J. P. Duarte, and J. Gil, “On the discovery of urban typologies: data mining the many dimensions of urban form,” *Urban morphology*, vol. 16, no. 1, pp. 27–40, 2012.
- [251] P. M. Schirmer and K. W. Axhausen, “A multiscale classification of urban morphology,” *Journal of Transport and Land Use*, vol. 9, no. 1, pp. 101–130, 2016.
- [252] C. Tanawatpaiboon, P. Ongkunaruk, and T. Leingpibul, “The application of two echelon distribution network zoning in an organic-chemical fertilizer distribution: The case study in northeastern thailand,” *Engineering Journal*, vol. 26, no. 2, pp. 11–22, 2022.
- [253] J. Baarsch and M. E. Celebi, “Investigation of internal validity measures for k-means clustering,” in *Proceedings of the international multiconference of engineers and computer scientists*, vol. 1, pp. 14–16, sn, 2012.
- [254] P. Netzel, J. Nowosad, J. Jasiewicz, J. Niesterowicz, and T. Stepinski, “Geopat 2: user’s manual. zenodo,” 2018.
- [255] P. Reiter and M. Colon, “Enhancement of the cdc ovitrap with hay infusions for daily monitoring of *Aedes aegypti* populations,” *J Am Mosq Control Assoc*, vol. 7, no. 1, pp. 52–55, 1991.
- [256] L. N. Regis, R. V. Acioli, J. C. Silveira Jr, M. A. V. de Melo-Santos, M. C. S. da Cunha, F. Souza, C. A. V. Batista, R. M. R. Barbosa, C. M. F. de Oliveira, C. F. J. Ayres, *et al.*, “Characterization of the spatial and temporal dynamics of the dengue vector population established in urban areas of fernando de noronha, a brazilian oceanic island,” *Acta tropica*, vol. 137, pp. 80–87, 2014.
- [257] J. E. Hernández-Ávila, M.-H. Rodríguez, R. Santos-Luna, V. Sánchez-Castañeda, S. Román-Pérez, V. H. Ríos-Salgado, and J. A. Salas-Sarmiento, “Nation-wide, web-based, geographic information system for the integrated surveillance and control of dengue fever in mexico,” *PLoS One*, vol. 8, no. 8, p. e70231, 2013.
- [258] R. Barrera, M. Amador, and A. J. MacKay, “Population dynamics of *Aedes aegypti* and dengue as influenced by weather and human behavior in san juan, puerto rico,” *PLoS neglected tropical diseases*, vol. 5, no. 12, p. e1378, 2011.
- [259] H.-H. Wu, C.-Y. Wang, H.-J. Teng, C. Lin, L.-C. Lu, S.-W. Jian, N.-T. Chang, T.-H. Wen, J.-W. Wu, D.-P. Liu, *et al.*, “A dengue vector surveillance by human population-stratified ovitrap survey for *Aedes* (diptera: Culicidae) adult and egg collections in high dengue-risk areas of taiwan,” *Journal of medical entomology*, vol. 50, no. 2, pp. 261–269, 2013.
- [260] S. I. Torri, M. J. Cabello, and R. S. Lavado, “Diagnóstico de la calidad de los suelos y su fertilidad para el cultivo de pecán,” *La Producción de Pecán en Argentina. INTA-FAUBA VI. Buenos Aires, Argentina*, pp. 1–20, 2007.

- [261] “Worldpop datasets.” <https://www.worldpop.org/>, 2013. (Accessed on 10/01/22).
- [262] M. Metz, “GRASS Development Team Addon v.vect.stats. *Geographic Resources Analysis Support System (GRASS) Software, Version 7.3*.” Open Source Geospatial Foundation: Chicago, IL, USA. Available online: <https://grass.osgeo.org/grass80/manuals/v.vect.stats.html>. accessed on 17/01/2022.
- [263] J. Arias-Gómez, M. Á. Villasís-Keever, and M. G. Miranda-Navales, “The research protocol iii. study population,” *Revista Alergia México*, vol. 63, no. 2, pp. 201–206, 2016.
- [264] A. Matei and Y. Tillé, “The r ‘sampling’ package,” in *European Conference on Quality in Survey Statistics, Cardiff*, 2006.
- [265] M. Shapiro, “U.s. army construction engineering research laboratory sort option by martin landa.” Czech Technical University in Prague. Available online: <https://grass.osgeo.org/grass80/manuals/r.report.html>, 2013. accessed on 15/01/2022.
- [266] O. L. Schultes, M. H. F. Morais, M. d. C. M. Cunha, A. Sobral, and W. T. Caiaffa, “Spatial analysis of dengue incidence and *Aedes aegypti* ovitrap surveillance in belo horizonte, brazil,” *Tropical Medicine & International Health*, vol. 26, no. 2, pp. 237–255, 2021.
- [267] R. Norzahira, O. Hidayatulfathi, H. Wong, A. Cheryl, R. Firdaus, H. Chew, K. Lim, K. Sing, M. Mahathavan, W. Nazni, *et al.*, “Ovitrap surveillance of the dengue vectors, *Aedes (Stegomyia) aegypti* (l.) and *Aedes (Stegomyia) albopictus* Skuse in selected areas in bentong, pahang, malaysia,” *Tropical biomedicine*, vol. 28, no. 1, pp. 48–54, 2011.
- [268] M. A. AK, W. Nazni, H. Lee, *et al.*, “Ovitrap surveillance of *Aedes aegypti* and *Aedes albopictus* in dengue endemic areas in keramat and shah alam, selangor in 2016,” *IJUM Medical Journal Malaysia*, vol. 17, no. 3, 2018.
- [269] T. P. Ferial-Arroyo, C. Aguilar, C. Quintero Vazquez, R. Santos-Luna, S. Roman-Perez, T. Oraby, G. Sanchez Tejeda, F. Correa Morales, V. M. Salazar Bueyes, and P. Camacho Guevara, “A tale of two cities: *Aedes* mosquito surveillance across the texas-mexico border,” *Subtropical Agriculture and Environments*, vol. 71, p. 12, 2020.
- [270] A. Rubio, M. V. Cardo, and D. Vezzani, “Tire-breeding mosquitoes of public health importance along an urbanisation gradient in buenos aires, argentina,” *Memórias do Instituto Oswaldo Cruz*, vol. 106, no. 6, pp. 678–684, 2011.
- [271] A. E. Carbajo, *Distribución espacio-temporal de Aedes aegypti (Diptera: Culicidae): su relación con el ambiente urbano y el riesgo de transmisión del virus dengue en la Ciudad de Buenos Aires*. PhD thesis, Universidad de Buenos Aires. Facultad de Ciencias Exactas y Naturales, 2003.
- [272] H. Teichgraeber and A. R. Brandt, “Clustering methods to find representative periods for the optimization of energy systems: An initial framework and comparison,” *Applied energy*, vol. 239, pp. 1283–1293, 2019.

- [273] V. Adarsh, B. Joseph, and P. P. Gopinath, “Comparison of clustering techniques used in divergence analysis,” *International Journal of Statistics and Applied Mathematics*, vol. 5, no. 4, pp. 19–21, 2020.

Anexo del capítulo 3

Listing A.1: Código en Java para la Clasificación supervisada basada pixeles.

```
1 var training_percent = 0.80;
2 var no_of_classification = 20;
3
4 // Import Pleiades image
5 var myImage = ee.Image('users/carrodriguezgonzalez/↔
    IMG_PHR1A_20170212_stack_corr') ;
6 print(myImage, 'myImage') ;
7
8 var NDWI = ee.Image('users/NDWI');
9 var NDVI = ee.Image('users/NDVI');
10 var pan_asm = ee.Image('users/pan_ASM');
11 var pan_entr = ee.Image('users/pan_Entr');
12 var pan_idm = ee.Image('users/pan_IDM');
13 var pan_Corr = ee.Image('users/pan_Corr');
14 var pan_Contr = ee.Image('users/pan_Contr');
15 var pan_DE = ee.Image('users//pan_DE');
16 var pan_DV = ee.Image('users/pan_DV');
17 var pan_moc1 = ee.Image('users/pan_MOC-1');
18 var pan_moc2 = ee.Image('users/pan_MOC-2');
19 var pan_SA = ee.Image('users/pan_SA');
20 var pan_SE = ee.Image('users/pan_SE');
21 var pan_VAR = ee.Image('users/pan_VAR');
22 var pan_SV = ee.Image('users/pan_SV');
23
24 var bands = ['b1', 'b2', 'b3', 'b4', 'b5'];
25 Map.addLayer(myImage, {
26     bands: ['b3','b2','b1']},
27     'RGB Pleiades');
28
29 // zoom
30 Map.centerObject(urban_cordoba, 11);
```

```

31
32 // Urban mask
33 //Map.addLayer(urban_cordoba.draw({color:'yellow'}), {}, '↔
    Urban_Mask_Clipped');
34 var stack = myImage.addBands (NDWI.rename ('NDWI'));
35 var stack0 = stack.addBands (NDVI.rename ('NDVI'));
36 var stack1 = stack0.addBands (pan_asm.rename ('asm'));
37 var stack2 = stack1.addBands (pan_entr.rename ('entr'));
38 var stack3 = stack2.addBands (pan_idm.rename ('idm'));
39 var stack4 = stack3.addBands (pan_Corr.rename ('Corr'));
40 var stack5 = stack4.addBands (pan_Contr.rename ('Contr'));
41 var stack6 = stack5.addBands (pan_DE.rename ('DE'));
42 var stack7 = stack6.addBands (pan_DV.rename ('DV'));
43 var stack8 = stack7.addBands (pan_moc1.rename ('MOC-1'));
44 var stack9 = stack8.addBands (pan_moc2.rename ('MOC-2'));
45 var stack10 = stack9.addBands (pan_SA.rename ('SA'));
46 var stack11 = stack10.addBands (pan_SV.rename ('SV'));
47 var stack12 = stack11.addBands (pan_SE.rename ('SE'));
48 var stack_pleiades = stack12.addBands (pan_VAR.rename ('VAR'));
49
50 print (stack_pleiades, 'stack_pleiades');
51
52 // cordoba
53 var image_cordoba = stack_pleiades
54
55 // Ground truth data
56 var points = ee.FeatureCollection (puntos);
57
58 // Visualize points
59 Map.addLayer (puntos.draw ({color: 'yellow'}), {}, 'PuntosCampo');
60 var samples = image_cordoba.sampleRegions ({
61     collection: points,
62     properties: ['Clase'],
63     scale: 0.5,
64     // tileScale: 16
65     });
66
67 // Classification with Random Forest
68 var MultipleClassification = function (seeds) {
69     var samples_points_random = samples.randomColumn ({seed: seeds});
70     var training_set = samples_points_random.filter (ee.Filter.lte ('↔
        random', training_percent));
71     var testing_set = samples_points_random.filter (ee.Filter.gt ('↔
        random', training_percent));
72     var classifier = ee.Classifier.smileRandomForest (200).train (↔
        training_set, "Clase", image_cordoba.bandNames ());
73     var oa = testing_set.classify (classifier).errorMatrix ('Clase', '↔
        classification').accuracy ();
74     var kappa = testing_set.classify (classifier).errorMatrix ('Clase↔
        ', 'classification').kappa ();
75     var prod_accuracy = testing_set.classify (classifier).errorMatrix↔
        ('Clase', 'classification').producersAccuracy ();

```

```
76 var cons_accuracy = testing_set.classify(classifier).errorMatrix(←
    ('Clase','classification').consumersAccuracy());
77 return ee.Feature(null, {oa:oa,kappa:kappa, pAccuracy: ←
    prod_accuracy, cAccuracy:cons_accuracy});
78 };
79
80 var accuracy_list = ee.List.sequence(1,no_of_classification).map(←
    MultipleClassification);
81
82 var accuracy_features = ee.FeatureCollection(accuracy_list);
83 print(accuracy_features,'accuracy features');
84
85 var samples_random = samples.randomColumn( );
86 var training_set2 = samples_random.filter(ee.Filter.lte('random', ←
    training_percent));
87 var testing_set2 = samples_random.filter(ee.Filter.gt('random', ←
    training_percent));
88 var classifier = ee.Classifier.smileRandomForest(200).train(←
    training_set2,"Clase", image_cordoba.bandNames());
89 var classified = image_cordoba.classify(classifier);
90
91 // Define a palette for the Land Use classification.
92 var palette = [
93   '008000', // Vegetacion alta (1)
94   '90EE90', // Vegetacion baja (2)
95   '1E90FF', // Agua (3)
96   'FF0000', // Edificios (4)
97   'BFBFBF', // Asfalto (5)
98   'DEB86E', // Suelo desnudo (6)
99   '000000' // Sombras (7)
100 ];
101
102 // Display the classification result and the input image.
103 Map.addLayer(classified, {min: 1, max: 7, palette: palette}, '←
    Classified RF');
104
105 //Export results
106 Export.table.toDrive({
107   collection: accuracy_features,
108   description: "Accuracy_Matrix_Test",
109   folder: "Pasantia",
110   fileNamePrefix: "clasificacion_pixeles",
111   fileFormat: "CSV"});
112
113 Export.image.toDrive({
114   image: classified,
115   description: 'clasificacion_pixeles',
116   scale: 0.5,
117   maxPixels: 10000000000000,
118   folder: "Pasantia",
119   region: urban_cordoba.geometry().bounds()
120 });
```

Listing A.2: Código en bash para la Clasificación supervisada basada en objetos.

```

1
2 # Clasificacion supervisada basada en objetos
3 # Imagen: Pleiades
4 # Region: cba_05m --> En 0.5 metros
5
6 #Preparar bandas
7 #BANDAS ORIGINALES: blue, green, red, nir, pan
8 #INDICES
9 # ndwi
10 r.mapcalc expression="ndwi=(green-nir)/(green+nir)"
11
12 # ndvi
13 r.mapcalc expression="ndvi=(nir-red)/(nir+red)"
14
15 # TEXTURA --> calculo de 13 texturas
16 METHODS=(idm entr contr corr de dv moc1 moc2 sa se sv var)
17 for METHOD in ${METHODS[@]} ; do
18     echo $SIZE $METHOD
19     r.texture.tiled input=pan \
20     output=pan_$METHOD \
21     method=$METHOD \
22     size=5 \
23     processes=7
24     done
25
26 # Crear un grupo con las bandas para la segmentacion
27 # Elegimos solo dos indices de textura porque visualmente ↔
    permiten identificar bien los contornos de la vegetacion
28 i.group group=pleiades_bands input=blue,green,red,nir,pan,ndvi,sa↔
    ,moc1
29
30 # SEGMENTACION
31 # Datos de entradas: banda pancromatica con datos crudos
32
33 PROCESSES=6
34 i.cutlines input=IMG_PHR1A_P_20170212 \
35     number_lines=25 \
36     processes=$PROCESSES \
37     output=cutlines_canny --o \
38     tile_width=3000 \
39     tile_height=3000 \
40     overlap=1 \
41     edge_detection=canny \
42     min_tile_size=70000 \
43     no_edge_friction=20 \
44     lane_border_multiplier=500 \
45     memory=8000
46
47 # Convertir el vector en raster y recategorizarlo --> 386 tiles
48 v.to.rast input=cutlines_canny \
49     output=cutlines_canny \
50     use=cat \

```

```
51         memory=8000
52 r.clump input=cutlines_canny \
53         output=cutlines_clumped --o
54
55 # Enmascarar un tiled del vector i.cutlines y buscar parametros ←
56   para optimizar la segmentacion
57 r.mask vector=cutlines_canny cats=62
58
59 # grupo de bandas
60 i.group group=bandas input=blue,green,red,nir,pan,ndvi,moc1,sa
61
62 # Sobre-segmentacion - threshold chico (0,010)
63 i.segment group=bandas output=segment_1 threshold=0.010 memory←
64   =5000
65 # Convertir a vector para visualizar
66 r.to.vect -tv input=segment_1 output=sobre_seg type=area
67
68 #Sub-segmentacion - threshold grande (0,10)
69 i.segment group=bandas output=segment_2 threshold=0.10 memory←
70   =5000
71 #Convertir a vector para visualizar
72 r.to.vect -tv input=segment_2 output=sub_seg type=area
73
74 # Generacion de semillas y segmentacion
75 # SLIC parameters
76 superpixels_step=2
77 superpixels_compacity=0.7
78 GROUP=bandas
79
80 export GRASS_OVERWRITE=1
81   for cat in `r.category cutlines_clumped_canny_int` ; do
82     r.mask raster=cutlines_clumped_canny_int maskcats=$cat
83     g.region zoom=MASK raster=ndvi save=temp_region
84     g.message message="Superpixels tile cat: $cat"
85
86 # i.superpixels slic
87 i.superpixels.slic input=$GROUP \
88     step=$superpixels_step \
89     compact=$superpixels_compacity \
90     output=slic_map_${cat} --o \
91     perturb=5 \
92     memory=8000
93
94   g.message message="USPO tile cat: $cat"
95
96 # i.segment.uspo
97 # Parametros de segmentacion
98 GROUP=bandas
99 PROCESSES=6
100 MEMORY=9000
101 start_threshold=0.010
```

```
101 stop_threshold=0.10
102 step=0.005
103 minsize=12
104 f_function_alpha=1
105
106 i.segment.uspo group=$GROUP \
107     seeds=slic_map_${cat} \
108     segment_map=segs_uspo_cat${cat} \
109     output=uspo_parameters_cat${cat}.csv --o\
110     regions=temp_region \
111     segmentation_method=region_growing \
112     tstart=$start_threshold \
113     tstop=$stop_threshold \
114     tstep=$step \
115     minsizes=$minsize \
116     optimization_function=f \
117     f_function_alpha=$f_function_alpha \
118     memory=$MEMORY \
119     processes=$PROCESSES
120
121     g.message message="Vector of the best segmentation for tile ←
122         cat: $cat"
123
124 # Convertir en vector la mejor segmentacion (rank 1) para ←
125     visualizarlo
126 r.to.vect -v input=segs_uspo_cat${cat}_temp_region_rank1 \
127     output=segs_uspo_cat${cat}_temp_region_rank1 \
128     type=area --o
129
130 # Eliminar slic_maps
131 g.remove -f type=raster name=slic_map_${cat}
132 done
133
134 # Unir cada segmento generado
135 # Remover mascara
136 r.mask -r
137
138 # Setear region original
139 g.region region=cba_OBIA
140
141 # patch tiles together and clump
142 list_tiles=`g.list type=raster pattern=segs_uspo_cat* separator←
143     =, `
144 r.patch input=$list_tiles output=patched_segmented_tiles --o
145
146 # Generar un unico raster con segmentos unificando sus valores
147 r.clump input=patched_segmented_tiles output=segments_full_region←
148     --o
149
150 # Convertir raster en vector
151 r.to.vect input=segments_full_region output=segments_full_region ←
152     type=area --o
```

```

149 # Extraer estadísticas de los segmentos por cada tile
150 # listar rasters tiles de input
151
152 g.list rast pat=segs_uspo_cat*
153
154 # listamos bandas para calcular estadísticas
155 bands=blue,green,red,nir,pan,ndvi,ndwi,asm,idm,Entr,Contr,Corr,de←
    ,dv,sa,se,var,moc1,moc2,sv
156
157 datestart=`eval date`
158 g.message message="Compute stats per segment started: $datestart"
159 # i.segment.stats
160 RASTER_STATS=(min,max,range,mean,stddev,first_quart,median,←
    third_quart,perc_90)
161 AREA_STATS=(area,perimeter,compact_circle,compact_square,fd)
162
163 for tile in `g.list rast pat=segs_uspo_cat*`; do
164     r.mask raster=$tile
165     g.region zoom=MASK raster=$tile save=temp_region --o
166     out=`echo $tile | cut -d_ -f1,2,3`
167     i.segment.stats -r \
168         map=$tile \
169         rasters=$bands \
170         raster_statistics=$RASTER_STATS \
171         area_measures=$AREA_STATS \
172         vectormap=${out}_stats \
173         processes=4 --o
174     r.mask -r
175     done
176
177 # Unir cada tile de vectores
178
179 # LABELS
180 v.import input=/home/carrodriguez/Documentos/5-IG/MAIE/TESIS/←
    Vectores/puntos/puntos_qgis.shp output=puntos_qgis
181
182 # dividimos en R desde GRASS para entrenamiento y validacion
183 # load libraries
184 library(rgrass7)
185 library(dplyr)
186
187 # load vector from GRASS
188 use_sf()
189 v <- readVECT("puntos_qgis")
190
191 # Datos para validacion -> 30% de puntos
192 test <- v %>%
193     group_by(Clase) %>%
194     sample_frac(.3)
195 table(test$Clase)
196
197 # Datos para entrenamiento -> 70% de puntos
198 train <- v[!v$cat %in% test$cat,]

```

```
199
200 # write back into GRASS
201 writeVECT(test, "test")
202 writeVECT(train, "train")
203
204 # Generamos vector de entrenamiento con labels
205 # Seleccionar segmentos que estan por debajo de los puntos
206 v.select ainput=segs_stats \
207   binput=train \
208   output=segmentos_entrenamiento \
209   operator=overlap --o
210
211 # Agregar una columna al vector con segmentos de entrenamiento
212 v.db.addcolumn segmentos_entrenamiento \
213   column="clase int"
214
215 # Asignar valores a la nueva columna a partir de la capa de ←
   puntos
216 v.distance from=segmentos_entrenamiento \
217   to=train \
218   upload=to_attr \
219   column=clase \
220   to_column=Clase
221
222 # Contar segmentos de entrenamiento por clase
223 db.select \
224   sql="SELECT clase,COUNT(cat) as count_class
225     FROM segmentos_entrenamiento
226     GROUP BY clase"
227
228 # CLASIFICACION
229 # Hacer el entrenamiento una sola vez, guardar el modelo y luego ←
   predecir con ese modelo para todos los tiles
230 v.class.mlR -t \
231   training_map=train_segments \
232   train_class_column=clase \
233   output_class_column=clase_rf \
234   output_prob_column=prob \
235   classifiers=rf \
236   max_features=70 \
237   folds=5 \
238   partitions=10 \
239   weighting_metric=accuracy \
240   variable_importance_file=/var_imp.txt \
241   accuracy_file=/accuracy.csv \
242   output_model_file=/modelo_c1 \
243   model_details=/classifier_runs.txt \
244   processes=4
245
246 # Prediccion por tile
247 for tile in `seq 1 291` ; do
248   g.message message="-TILE $tile-"
249   v.class.mlR -p \
```

```
250 segments_map=segs_uspo_cat${tile}_stats \  
251 classifiers=rf \  
252 train_class_column=clase \  
253 input_model_file=/modelo_c1 \  
254 raster_segment_map=segs_uspo_cat${tile}_temp_region_rank1 \  
255 classified_map=class1_cba_cat${tile} \  
256 classification_results=/all_results_cat${tile}.csv \  
257 processes=4 --o  
258 done  
259  
260 list_class=`g.list rast pat=class1_cba_cat* sep=,`  
261 r.patch in=$list_class out=clasificacion_rf_cba_05  
262  
263 # set color table  
264 r.colors \  
265 map=clasificacion_rf_cba_1 \  
266 rules=/urban_obia.txt  
267  
268 # Validacion  
269 # add column to test point map  
270 v.db.addcolumn map=test \  
271 column="pred_class integer"  
272  
273 # query the classified map  
274 v.what.rast map=test \  
275 column=pred_class \  
276 raster=clasificacion_rf_cba_05  
277  
278 # confusion matrix and evaluation metrics in R  
279 # read the test vector  
280 test_complete <- readVECT("test")  
281  
282 # confusion matrix and evaluation stats  
283 library(caret)  
284 rf_CM <- confusionMatrix(as.factor(test_complete$pred_class),  
285 as.factor(test_complete$Clase))  
286 print(rf_CM)
```

Anexo del capítulo 4

Listing B.1: Código en R para la estimación de algunas métricas del paisaje. Ejemplo para la grilla.

```

1 # Cargar librerías
2 library(raster)
3 library(rgrass7)
4 library(sf)
5 library(dplyr)
6 library(landscapemetrics)
7 library(rgdal)
8
9 # Importar clasificación
10 landscape <- raster("~/clasificacion_objetos_cba")
11
12 # Generar una grilla para estimar métricas
13 grilla_R_geom = st_make_grid(landscape, cellsize = 1100)
14 grilla_R = st_sf(geom = grilla_R_geom)
15
16 # Visualizar
17 plot(landscape)
18 plot(grilla_R, add = TRUE)
19
20 # calcular 10 métricas a nivel de paisaje para cada celda de la ←
    grilla:
21 metricas_grilla_p = sample_lsm(landscape, grilla_R,
22                               level = "landscape", metric = c("ent", "←
    mutinf", "tca", "ed", "pr", "shdi", "←
    ai", "division", "shape_mn", "←
    contig_mn"))
23 metricas_grilla_p
24
25 # calcular 8 métricas a nivel de clase para cada celda de la ←
    grilla:
26 metricas_grilla_c = sample_lsm(landscape, grilla_R,

```

```

27         level = "class", metric = c("ai", "pd", ←
           "area_mn", "pland", "shape_mn", "←
           contig_mn", "cpland", "tca"))
28 metricas_grilla_c
29
30 # Exportar resultados
31 write.csv(metricas_grilla_p, "grilla_metricas_paisaje")
32 write.csv(metricas_grilla_c, "grilla_metricas_clase")
33 write_sf(my_grid, "my_grid.gpkg")

```

Listing B.2: Código en R para los agrupamientos espaciales con k-means. Ejemplo para la grilla.

```

1 # Cargar librerias
2 library("cluster")
3 library("factoextra")
4 library("ggplot2")
5
6 # Importar metricas
7 Metricas_paisaje <- read.csv(file = "~/grilla_metricas_paisaje.←
  csv")
8 head(Metricas_paisaje)
9
10 Metricas <- data.frame(Metricas_paisaje)
11 str(Metricas_paisaje)
12
13 # controlar que no falten valores
14 na.fail("Metricas")
15 # datos
16 summary(Metricas)
17 # escalar datos
18 metricas_escaladas <- scale(Metricas)
19 head(metricas_escaladas)
20 #metricas_eucl = dist(x = metricas_escaladas, method = "euclidean←
  ")
21 #round(as.matrix(metricas_eucl)[1:9][1:9],1)
22
23 # Pasos para k-means
24 # 1. Definir un total de k centroides al azar.
25 # 2. Calcular las distancias de cada uno de los puntos de entrada←
  a los k centroides, y asignar cada punto al centroeide cuya ←
  distancia sea menor.
26 # 3. Actualizar la posic[i+FFFFD]de los k centroides, calculando la ←
  posic[i+FFFFD]promedio de todos los puntos que pertenecen a cada ←
  clase.
27 # 4. Repetir los pasos 2 y 3 hasta que los centroides no cambien ←
  de posic[i+FFFFD]y, por lo tanto, las asignaciones de puntos entre←
  clases no cambie.
28
29 # Determinar la cantidad de clusters (K): M[U+FFFFD] del Codo
30 set.seed(1234)
31 wcss <- vector()
32 for(i in 1:20){
33   wcss[i] <- sum(kmeans(metricas_escaladas, i)$withinss)

```

```
34 }
35
36 # Graficar los resultados
37 ggplot() + geom_point(aes(x = 1:20, y = wcss), color = 'blue') +
38   geom_line(aes(x = 1:20, y = wcss), color = 'blue') +
39   ggtitle("Metodo del Codo") +
40   xlab('Cantidad de Centroides k') +
41   ylab('WCSS')
42
43 # Otra forma de determinar la cantidad de clusters: Metodo Elbow
44 set.seed(1234)
45 fviz_nbclust(metricas_escaladas, kmeans, method = "wss")
46
47 # Otra forma de determinar la cantidad de clusters: Metodo ←
48   Silhouette
49 fviz_nbclust(metricas_escaladas, kmeans, method = "silhouette")
50
51 # Otra forma de determinar la cantidad de clusters: GAP
52 fviz_nbclust(metricas_escaladas, kmeans, method = "gap_stat", k.←
53   max = 10, nboot = 500, nstart = 50)
54
55 # Para seleccionar el valor optimo de k, se escoje el punto en ←
56   donde ya no se dejan de producir variaciones importantes del ←
57   valor de WCSS al aumentar k.
58 # Finalmente, podemos aplicar el algoritmo con la cantidad de k ←
59   seleccionada:
60 set.seed(1234)
61 k_3 <- kmeans(metricas_escaladas, 3, iter.max = 1000, nstart = ←
62   10)
63 k_4 <- kmeans(metricas_escaladas, 4, iter.max = 1000, nstart = ←
64   10)
65 k_5 <- kmeans(metricas_escaladas, 5, iter.max = 1000, nstart = ←
66   10)
67
68 fviz_cluster(k_3, data = metricas_escaladas, main = "Cluster de ←
69   datos por Grilla. Nivel = Paisaje / k = 3", geom = "point")
70 fviz_cluster(k_4, data = metricas_escaladas, main = "Cluster de ←
71   datos por Grilla. Nivel = Paisaje / k = 4", geom = "point")
72 fviz_cluster(k_5, data = metricas_escaladas, main = "Cluster de ←
73   datos por Grilla. Nivel = Paisaje / k = 5", geom = "point")
74
75 validacion <- clValid(metricas_escaladas, 2:6, clMethods = "kmeans←
76   ", validation = "internal")
77 summary(validacion)
78
79 write.csv(k_3$cluster, "~/k3_paisaje.csv")
80 write.csv(k_4$cluster, "~/k4_paisaje.csv")
81 write.csv(k_5$cluster, "~/k5_paisaje.csv")
```

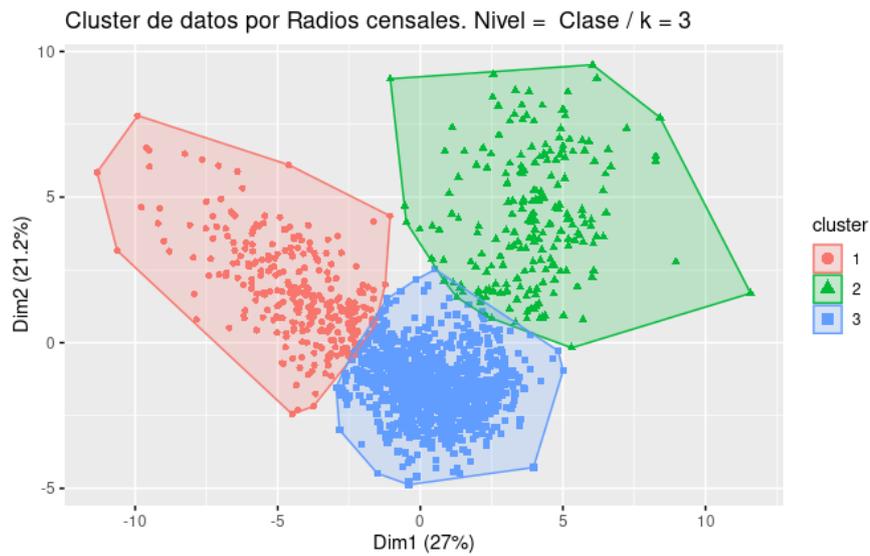


Figura B.1: Agrupamiento por *k-means* a nivel de clase para los radios censales de la Ciudad de Córdoba. El agrupamiento se realizó incluyendo las métricas mencionadas en la Tabla 4.1 a nivel de clase y el valor de *k* fue fijado en 3 en base a la observación de los gráficos de sedimentación obtenidos.

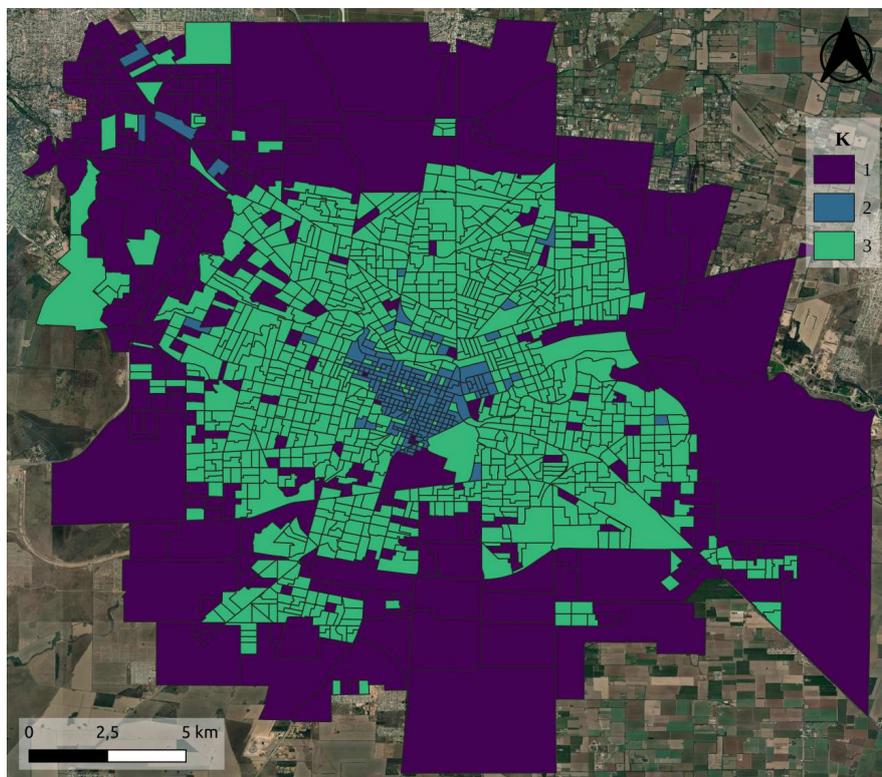


Figura B.2: Mapa obtenido a partir del análisis de agrupamiento espacial por *k-means* a nivel de clase para los radios censales de la Ciudad de Córdoba.

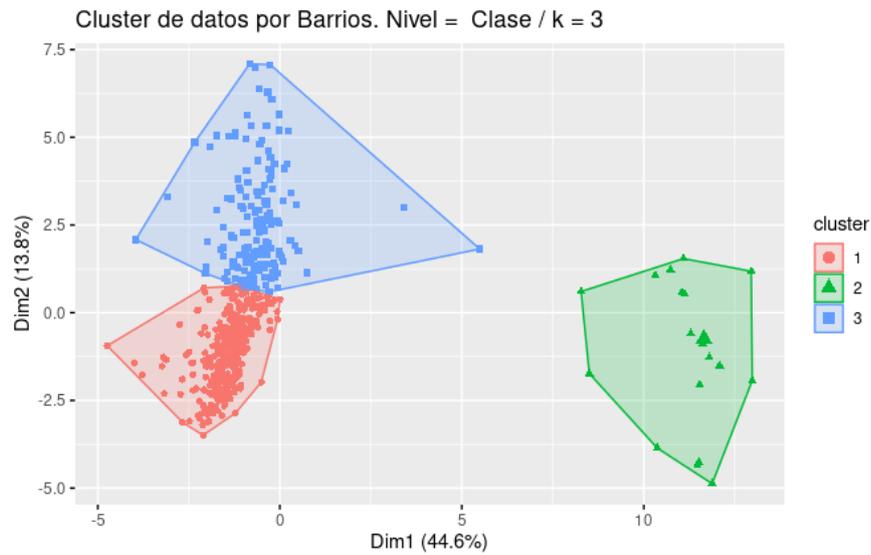


Figura B.3: Agrupamiento por *k-means* a nivel de clase para los barrios de la Ciudad de Córdoba. El agrupamiento se realizó incluyendo las métricas mencionadas en la Tabla 4.1 a nivel de clase y el valor de *k* fue fijado en 3 en base a la observación de los gráficos de sedimentación obtenidos.

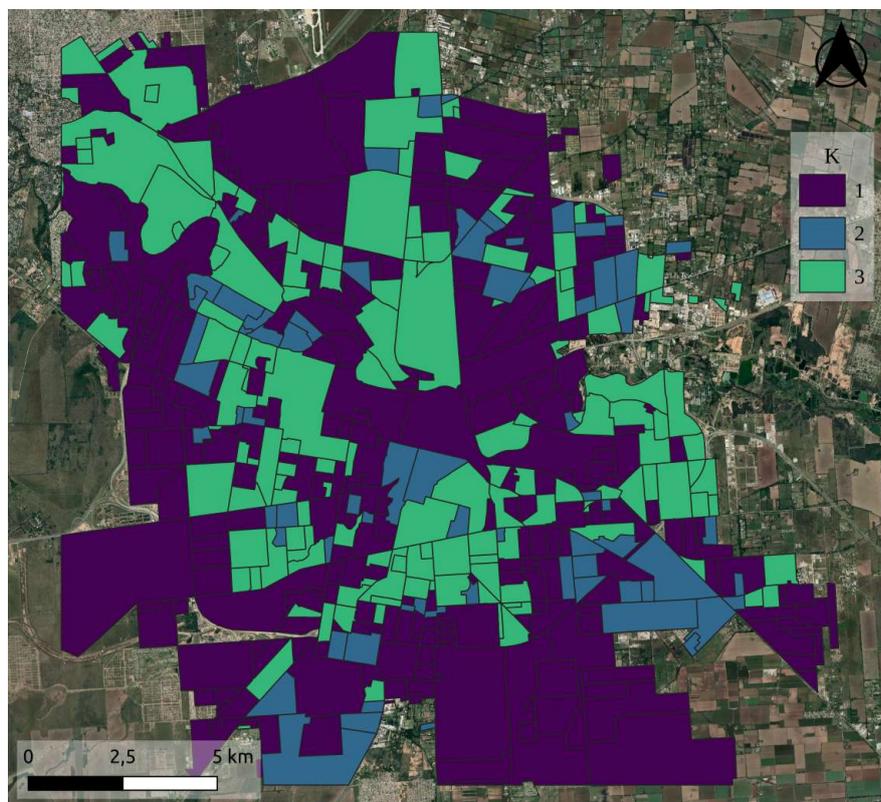


Figura B.4: Mapa obtenido a partir del análisis de agrupamiento espacial por *k-means* a nivel de clase para los barrios de la Ciudad de Córdoba.

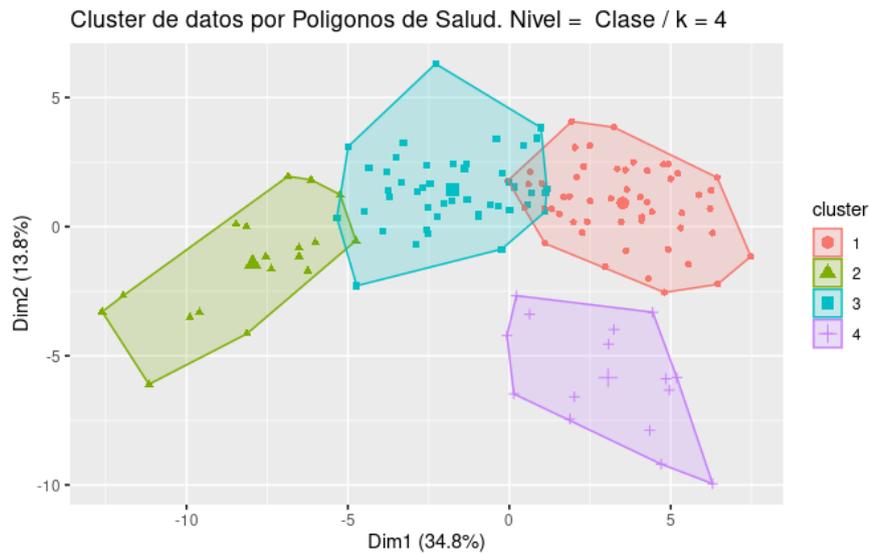


Figura B.5: Agrupamiento por *k-means* a nivel de clase para los polígonos de thiessen de la Ciudad de Córdoba. El agrupamiento se realizó incluyendo las métricas mencionadas en la Tabla 4.1 a nivel de clase y el valor de *k* fue fijado en 4 en base a la observación de los gráficos de sedimentación obtenidos.

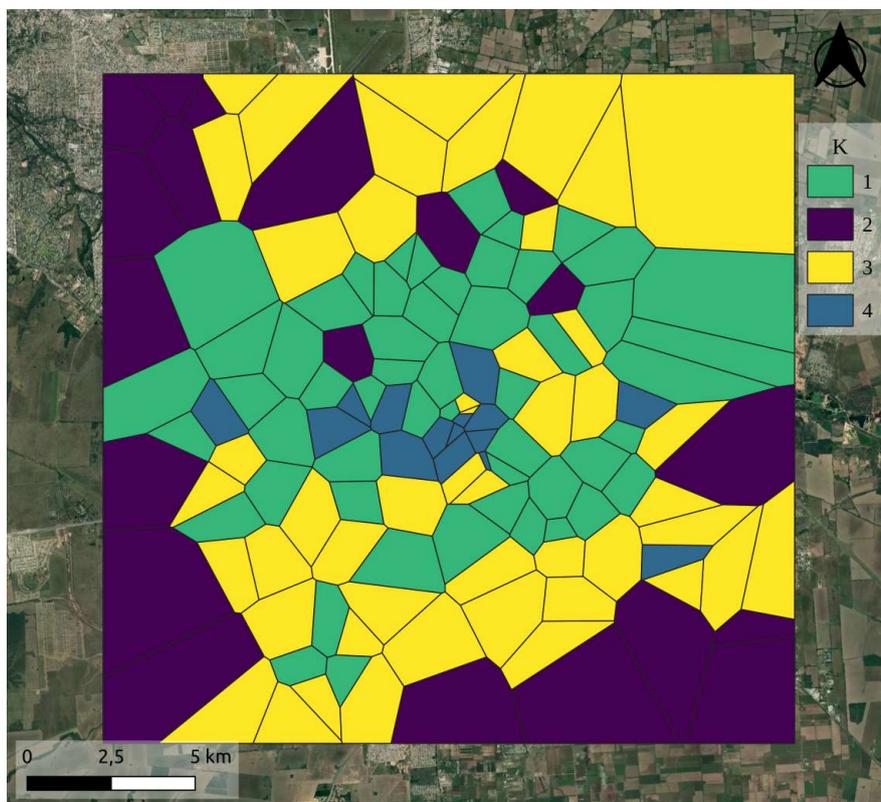


Figura B.6: Mapa obtenido a partir del análisis de agrupamiento espacial por *k-means* a nivel de clase para los polígonos de thiessen de la Ciudad de Córdoba.

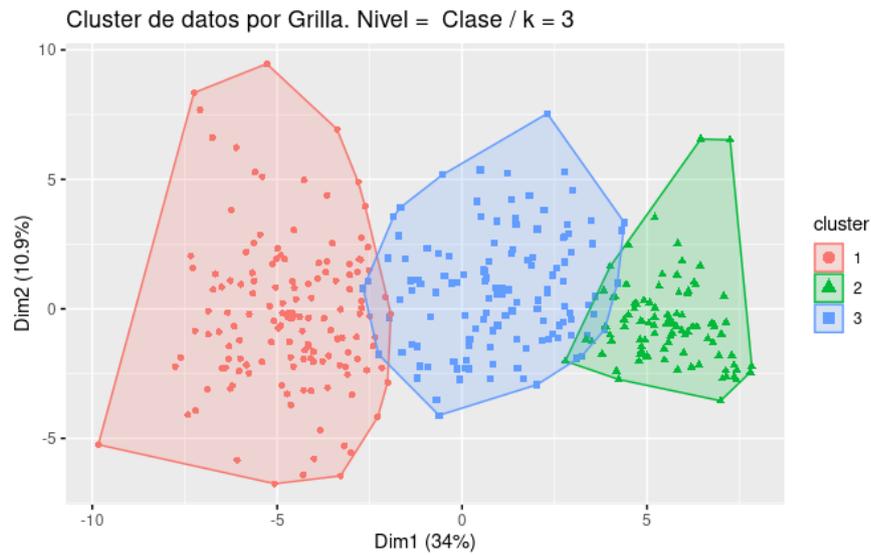


Figura B.7: Agrupamiento por *k-means* a nivel de clase para la Grilla de la Ciudad de Córdoba. El agrupamiento se realizó incluyendo las métricas mencionadas en la Tabla 4.1 a nivel de clase y el valor de *k* fue fijado en 3 en base a la observación de los gráficos de sedimentación obtenidos.

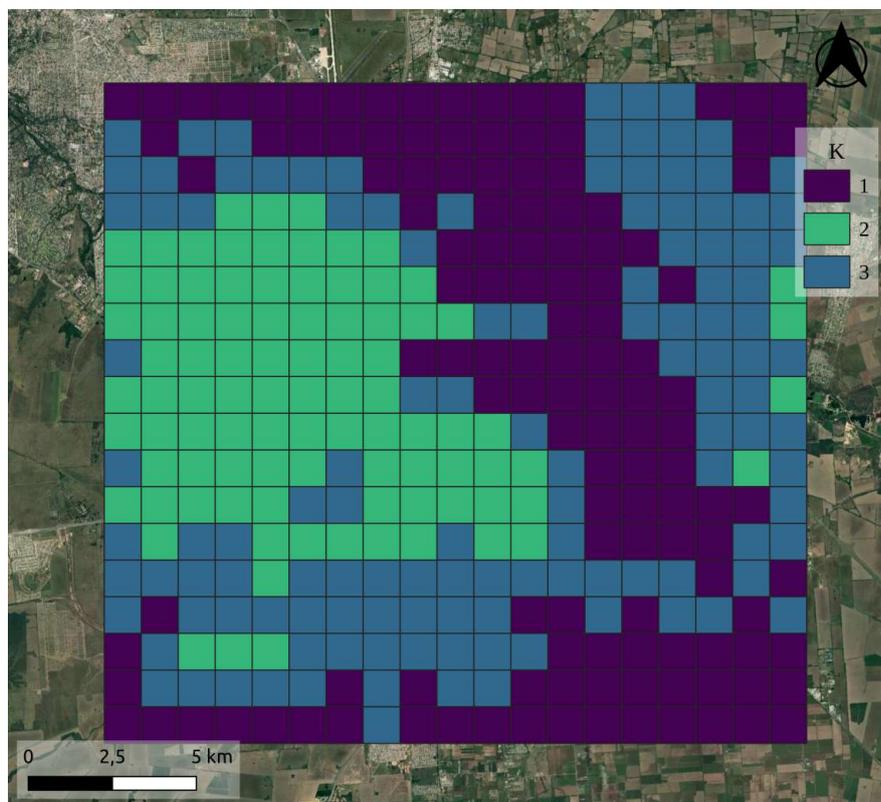


Figura B.8: Mapa obtenido a partir del análisis de agrupamiento espacial por *k-means* a nivel de clase para la Grilla de la Ciudad de Córdoba.

Anexo del capítulo 5

Listing C.1: Código en R para generar puntos en estratos. Ejemplo para la grilla.

```
1 # Cargo libreria
2 library( sampling )
3
4 # Importo cluster
5 Cluster <- read.csv(file = "~/k4_paisaje.csv")
6 head(Cluster)
7
8 # Genero puntos al azar en los dos clusters de interes para ↵
  ovitrampas
9 Estratos <- strata(Cluster, stratanames = c("k4_paisaje"), size =↵
  c(75,75), method = "srswor" )
10 cluster.muestreado <- getdata( Cluster, Estratos)
11
12 write.csv(Estratos_grilla.csv")
```

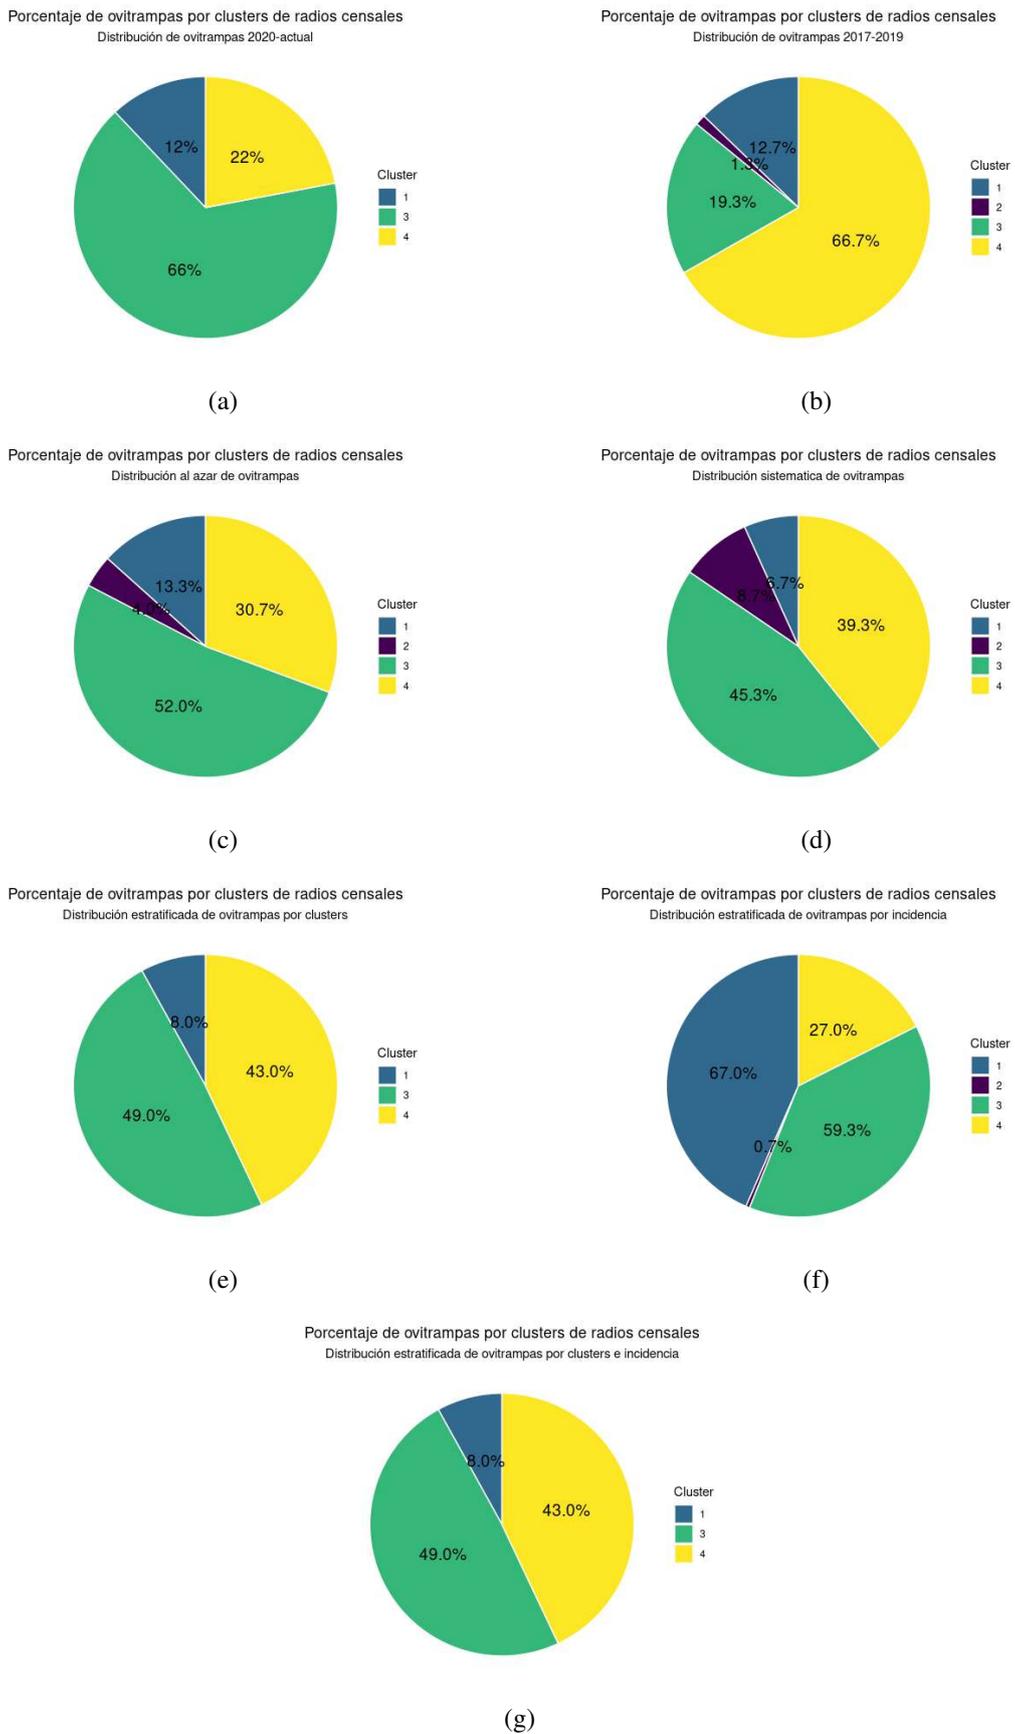


Figura C.1: Porcentaje de ovitrampas por *cluster* de Radios censales para cada tipo de distribución analizado.

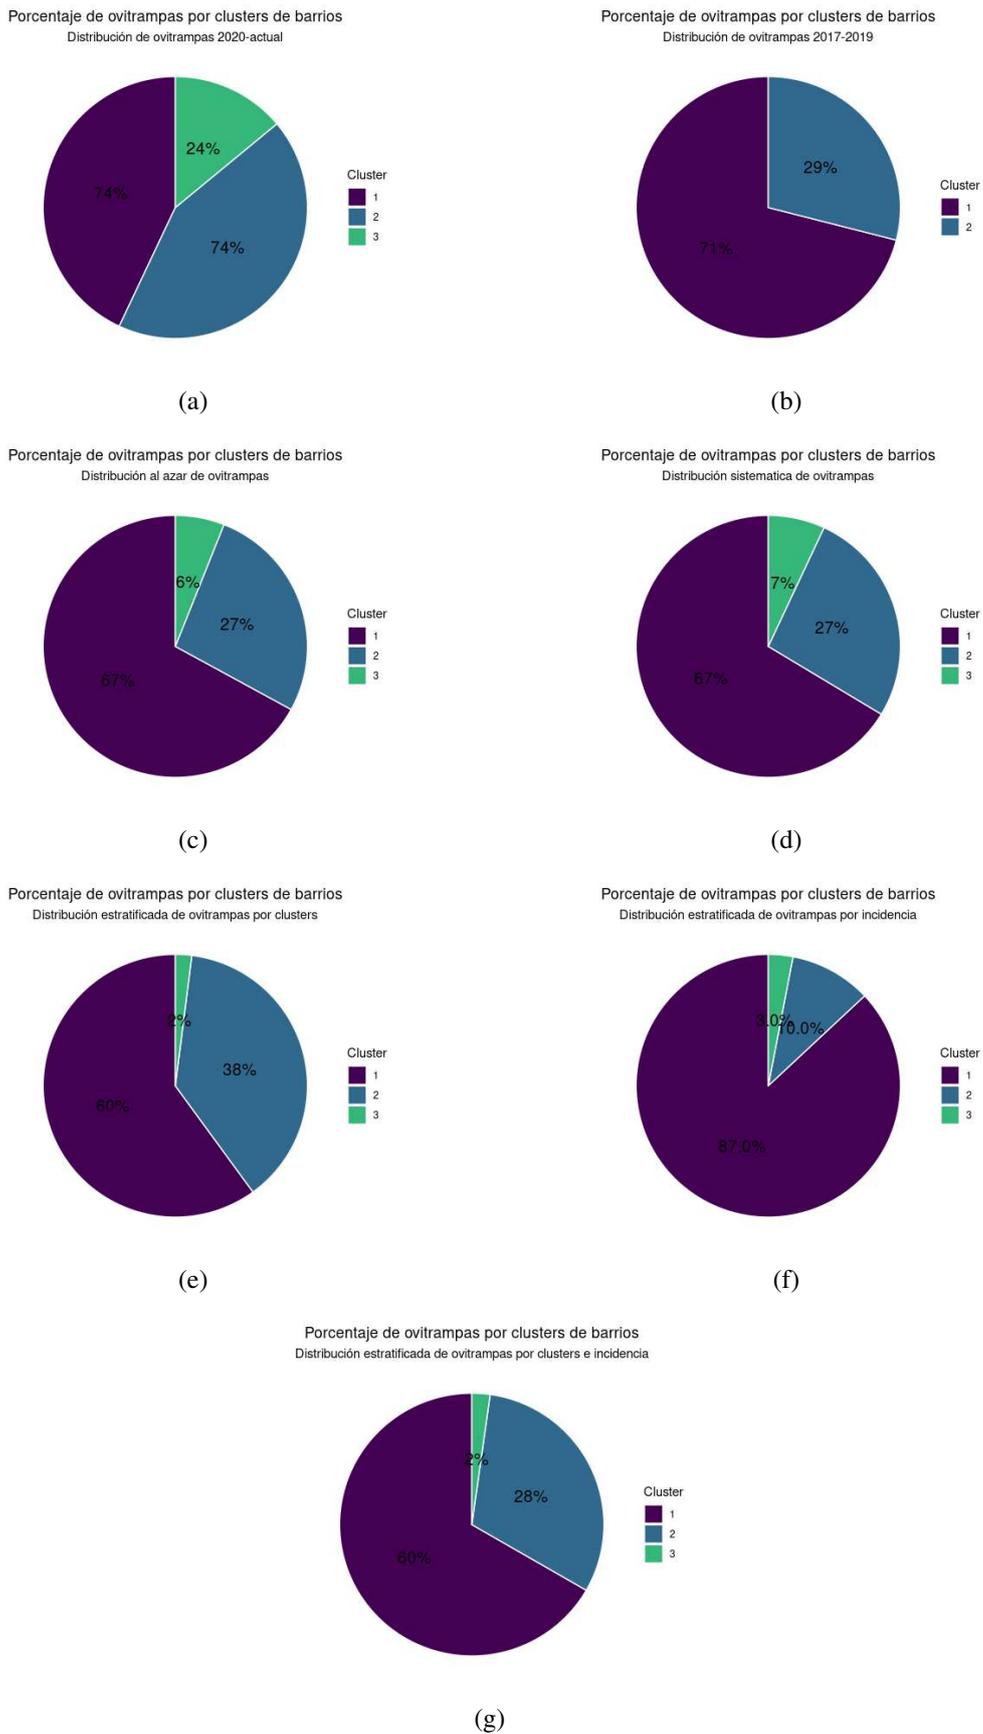


Figura C.2: Porcentaje de ovitrampas por *cluster* de Barrios para cada tipo de distribución analizado.

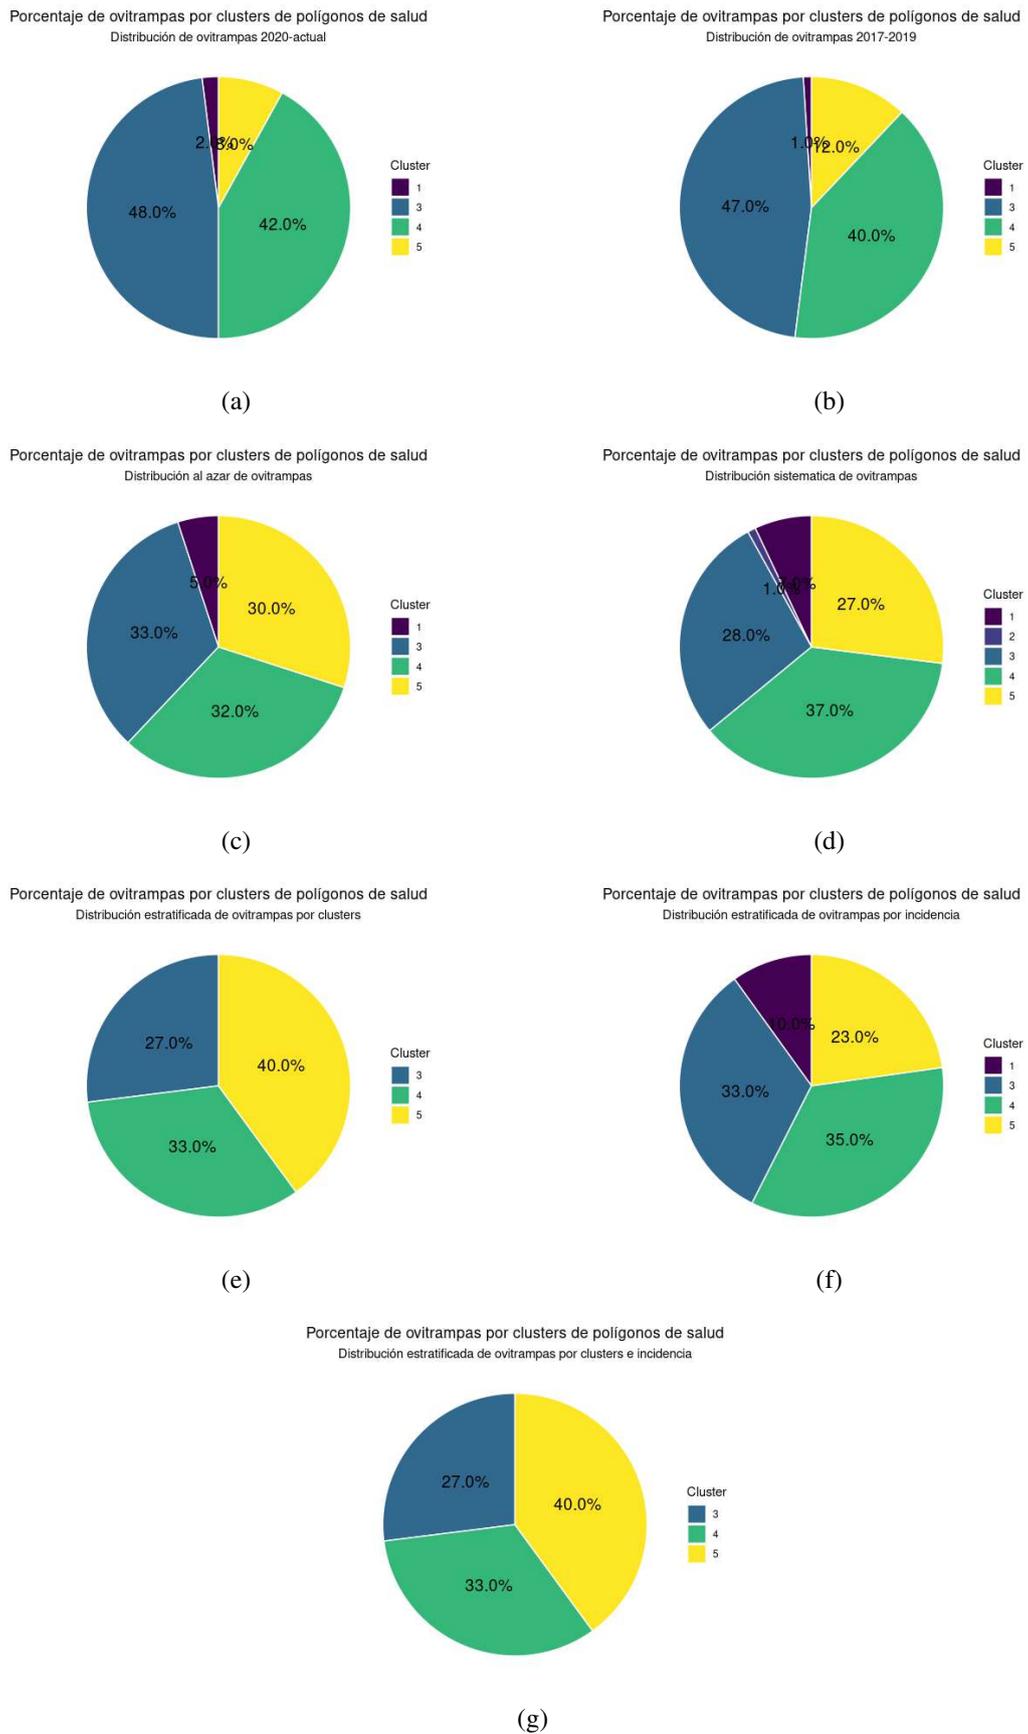
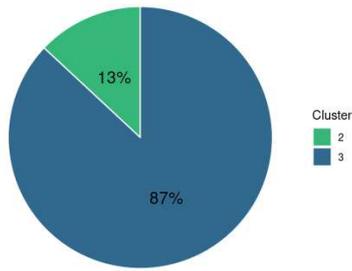


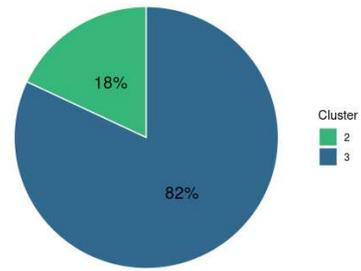
Figura C.3: Porcentaje de ovrtrampas por *cluster* de polígonos de salud para cada tipo de distribución analizado.

Porcentaje de ovitrampas por clusters de grilla
Distribución de ovitrampas 2020-actual



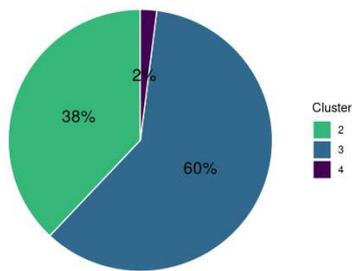
(a)

Porcentaje de ovitrampas por clusters de grilla
Distribución de ovitrampas 2017-2019



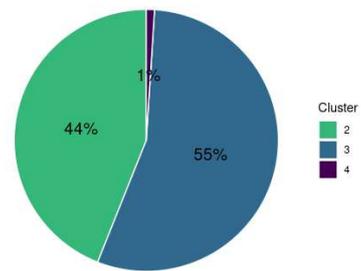
(b)

Porcentaje de ovitrampas por clusters de grilla
Distribución al azar de ovitrampas



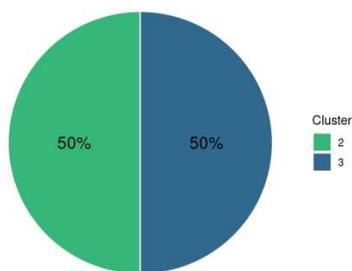
(c)

Porcentaje de ovitrampas por clusters de grilla
Distribución sistemática de ovitrampas



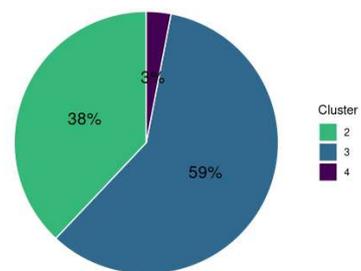
(d)

Porcentaje de ovitrampas por clusters de grilla
Distribución estratificada de ovitrampas por clusters



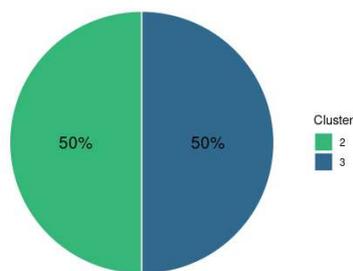
(e)

Porcentaje de ovitrampas por clusters de grilla
Distribución estratificada de ovitrampas por incidencia



(f)

Porcentaje de ovitrampas por clusters de grilla
Distribución estratificada de ovitrampas por clusters e incidencia



(g)

Figura C.4: Porcentaje de ovitrampas por *cluster* de grilla para cada tipo de distribución analizado.