


UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN

FACULTAD DE INGENIERÍA CIVIL



**INTEGRACIÓN DE REDES NEURONALES CONVOLUCIONALES Y
PERCEPCIÓN REMOTA EN LA MODELACIÓN DE LA CONECTIVIDAD Y
ACCESIBILIDAD DE ÁREAS VERDES URBANAS**

POR

ROBERTO EMMANUEL HUERTA GARCÍA

**COMO REQUISITO PARCIAL PARA OBTENER EL GRADO
DE DOCTOR EN INGENIERÍA CON ORIENTACIÓN EN
INGENIERÍA AMBIENTAL**

MAYO DE 2022



UANL

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN



FACULTAD DE INGENIERÍA CIVIL
INSTITUTO DE INGENIERÍA CIVIL

FECHA: 2022/abril/10

DR. GERARDO FAJARDO SAN MIGUEL
SUBDIRECTOR DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN
FACULTAD DE INGENIERÍA CIVIL
UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN
PRESENTE.-

Estimado Dr. Fajardo San Miguel,

Por medio de la presente, hago de su conocimiento que he finalizado la revisión del documento de **TESIS**, cuyo título es “**INTEGRACION DE REDES NEURONALES CONVOLUCIONALES Y PERCEPCIÓN REMOTA EN LA MODELACION DE LA CONECTIVIDAD Y ACCESIBILIDAD DE AREAS VERDES URBANAS**”, que presenta el **MC. ROBERTO EMMANUEL HUERTA GARCÍA**, como requisito parcial para obtener el grado de **DOCTOR EN INGENIERÍA**, del programa **DOCTORADO EN INGENIERÍA CON ORIENTACIÓN EN INGENIERÍA AMBIENTAL**.

Por lo anterior, me permito informar a Usted que el documento **CUENTA** con la calidad y nivel **CIENTÍFICO**, adecuados para su defensa, por lo que dictamino que este trabajo sea **(APROBADO)**.

Asimismo, anexo a este documento el formato de evaluación correspondiente, donde hago saber mis comentarios y observaciones al respecto.

Sin otro particular por el momento, me despido y quedo a sus órdenes para cualquier duda o aclaración que considere pertinente.

Atentamente,

DRA. FABIOLA DORACELY YÉPEZ RINCÓN

Evaluador



UANL

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN



FACULTAD DE INGENIERÍA CIVIL
INSTITUTO DE INGENIERÍA CIVIL

2022/04/25

DR. GERARDO FAJARDO SAN MIGUEL
SUBDIRECTOR DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN
FACULTAD DE INGENIERÍA CIVIL
UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN
PRESENTE. -

Estimado Dr. Fajardo San Miguel,

Por medio de la presente, hago de su conocimiento que he finalizado la revisión del documento de **TESIS**, cuyo título es "**INTEGRACION DE REDES NEURONALES CONVOLUCIONALES Y PERCEPCIÓN REMOTA EN LA MODÉLACION DE LA CONECTIVIDAD Y ACCESIBILIDAD DE AREAS VERDES URBANAS**", que presenta el **MC. ROBERTO EMMANUEL HUERTA GARCÍA**, como requisito parcial para obtener el grado de **DOCTOR EN INGENIERÍA**, del programa **DOCTORADO EN INGENIERÍA CON ORIENTACIÓN EN INGENIERÍA AMBIENTAL**. Por lo anterior, me permito informar a Usted que el documento **CUENTA** con la calidad y nivel **CIENTÍFICO**, adecuados para su defensa, por lo que dictamino que este trabajo sea **APROBADO**.

Asimismo, anexo a este documento el formato de evaluación correspondiente, donde hago saber mis comentarios y observaciones al respecto.

Sin otro particular por el momento, me despido y quedo a sus órdenes para cualquier duda o aclaración que considere pertinente.

Atentamente,

DR. ADRIAN LEONARDO FERRIÑO FIERRO

Evaluador





UANL

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN



FACULTAD DE INGENIERÍA CIVIL
INSTITUTO DE INGENIERÍA CIVIL

FECHA: 2022/03/22

DR. GERARDO FAJARDO SAN MIGUEL
SUBDIRECTOR DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN
FACULTAD DE INGENIERÍA CIVIL
UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN
PRESENTE.-

Estimado Dr. Fajardo San Miguel,

Por medio de la presente, hago de su conocimiento que he finalizado la revisión del documento de **TESIS**, cuyo título es **“INTEGRACION DE REDES NEURONALES CONVOLUCIONALES Y PERCEPCIÓN REMOTA EN LA MODELACION DE LA CONECTIVIDAD Y ACCESIBILIDAD DE AREAS VERDES URBANAS”**, que presenta el **MC. ROBERTO EMMANUEL HUERTA GARCÍA**, como requisito parcial para obtener el grado de **DOCTOR EN INGENIERÍA**, del programa **DOCTORADO EN INGENIERÍA CON ORIENTACIÓN EN INGENIERÍA AMBIENTAL**. Por lo anterior, me permito informar a Usted que el documento **CUENTA** con la calidad y nivel **CIENTÍFICO**, adecuados para su defensa, por lo que dictamino que este trabajo sea **APROBADO**. Asimismo, anexo a este documento el formato de evaluación correspondiente, donde hago saber mis comentarios y observaciones al respecto.

Sin otro particular por el momento, me despido y quedo a sus órdenes para cualquier duda o aclaración que considere pertinente.

Atentamente,


Dr. Víctor Hugo Guerra Cobián

Evaluador



Av. Universidad S/N, Cd. Universitaria, C.P. 66455
San Nicolás de los Garza, Nuevo León, México
Tels. 81 8329 4000 ext 7200 | 81 1442 4400
<http://fic.uanl.mx>

2022/MAYO/2

DR. GERARDO FAJARDO SAN MIGUEL
SUBDIRECTOR DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN
FACULTAD DE INGENIERÍA CIVIL
UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN
PRESENTE.-

Estimado Dr. Fajardo San Miguel,

Por medio de la presente, hago de su conocimiento que he finalizado la revisión del documento de **TESIS**, cuyo título es **“INTEGRACION DE REDES NEURONALES CONVOLUCIONALES Y PERCEPCIÓN REMOTA EN LA MODELACION DE LA CONECTIVIDAD Y ACCESIBILIDAD DE AREAS VERDES URBANAS”**, que presenta el **MC. ROBERTO EMMANUEL HUERTA GARCÍA**, como requisito parcial para obtener el grado de **DOCTOR EN INGENIERÍA**, del programa **DOCTORADO EN INGENIERÍA CON ORIENTACIÓN EN INGENIERÍA AMBIENTAL**. Por lo anterior, me permito informar a Usted que el documento **CUENTA** con la calidad y nivel **CIENTÍFICO**, adecuados para su defensa, por lo que dictamino que este trabajo sea **APROBADO**.

Asimismo, anexo a este documento el formato de evaluación correspondiente, donde hago saber mis comentarios y observaciones al respecto.

Sin otro particular por el momento, me despido y quedo a sus órdenes para cualquier duda o aclaración que considere pertinente.

Atentamente,



ADRIANA VARGAS-MARTINEZ

Evaluador

Monterrey, N.L. 2022/Mayo/3

DR. GERARDO FAJARDO SAN MIGUEL
SUBDIRECTOR DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN
FACULTAD DE INGENIERÍA CIVIL
UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN
PRESENTE.-

Estimado Dr. Fajardo San Miguel,

Por medio de la presente, hago de su conocimiento que he finalizado la revisión del documento de TESIS, cuyo título es **“INTEGRACION DE REDES NEURONALES CONVOLUCIONALES Y PERCEPCIÓN REMOTA EN LA MODELACION DE LA CONECTIVIDAD Y ACCESIBILIDAD DE AREAS VERDES URBANAS”**, que presenta el MC. ROBERTO EMMANUEL HUERTA GARCÍA, como requisito parcial para obtener el grado de DOCTOR EN INGENIERÍA, del programa DOCTORADO EN INGENIERÍA CON ORIENTACIÓN EN INGENIERÍA AMBIENTAL.

Por lo anterior, me permito informar a Usted que el documento CUENTA con la calidad y nivel CIENTÍFICO, adecuados para su defensa, por lo que dictamino que este trabajo sea APROBADO.

Asimismo, anexo a este documento el formato de evaluación correspondiente, donde hago saber mis comentarios y observaciones al respecto.

Sin otro particular por el momento, me despido y quedo a sus órdenes para cualquier duda o aclaración que considere pertinente.

Atentamente,



Dr. Diego Fabián Lozano García

Evaluador



UANL

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN



FACULTAD DE INGENIERÍA CIVIL
SUBDIRECCIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN

Comprobante de corrección de escritos

ESTUDIANTE PROFESOR

NOMBRE: ROBERTO EMMANUEL HUERTA GARCÍA

TIPO DE DOCUMENTO: ARTÍCULO TESIS PI OTRO

TÍTULO DEL DOCUMENTO A REVISAR:

INTEGRACIÓN DE REDES NEURONALES CONVOLUCIONALES Y PERCEPCIÓN REMOTA EN LA MODELACIÓN DE LA CONECTIVIDAD Y LA ACCESIBILIDAD DE ÁREAS VERDES URBANAS


RECOMENDACIONES ADICIONALES:

REALIZAR LAS CORRECCIONES QUE APAREZCAN EN LA TESIS IMPRESA

*Este documento certifica la corrección DEFINITIVA del trabajo arriba identificado, en los aspectos: ortográfico, metodológico y estilístico.

Nombre y firma de quien corrigió: _____

Ramón Longoria
Arq. Ramón Longoria Ramírez
Asesor Profesional de Apoyo



Gerardo Fajardo
Dr. Gerardo Fajardo San Miguel

Subdirector de Estudios de Posgrado e Investigación
Ciudad Universitaria, 15 de Marzo de 2021



Av. Universidad S/N Cd. Universitaria
San Nicolás de los Garza, Nuevo León, México, C.P.P. 66455
Tels. (81) 14424400 ext. 4448 | 83294000 ext. 7216, 7234
correo electrónico: spi.fic@uanl.mx

Integración de redes neuronales convolucionales y percepción remota en la modelación de la conectividad y accesibilidad de áreas verdes urbanas.

Aprobación de la tesis

Dra. Fabiola Doracely Yépez Rincón
Director de tesis

Dr. Víctor Hugo Guerra Cobián
Secretario

Dra. Adriana Vargas Martínez
Vocal

Dr. Adrián Leonardo Ferriño Fierro
Sinodal

Dr. Diego Fabián Lozano García
Sinodal

Dr. Gerardo Fajardo San Miguel
Subdirector de Estudios de Posgrado e Investigación

Dedicatoria

A Natalia, mi faro de esperanza a lo largo de este trayecto.

“God only knows what I'd be without you” – Wilson B. & Asher T.

Agradecimientos

Por sus enriquecedoras recomendaciones y el apoyo brindado para la producción de esta investigación, agradezco al Dr. Adrián Leonardo Ferriño Fierro, a la Dra. Adriana Vargas Martínez, al Dr. Diego Fabián Lozano García, al Dr. Héctor de León Gómez y al Dr. Víctor Hugo Guerra Cobián.

Al Consejo Nacional de Ciencia y Tecnología, por permitir que se llevara a cabo de manera satisfactoria la presente investigación gracias al apoyo económico brindado.

A mi asesora, la Dra. Fabiola D. Yépez Rincón. Agradezco sobremanera por la oportunidad de realizar este posgrado bajo tu dirección, por todo el apoyo, la confianza, y por haber creído en este proyecto pese a los contratiempos que la vida ha presentado.

Al personal del Instituto de Ingeniería Civil, en especial al Dr. Isaías Juárez Ramírez, al Dr. Daniel Sánchez Martínez, a Jessyca Saucedo Flores y al Dr. Víctor Hugo Guerra Cobián, quienes me han apoyado amablemente a resolver cualquier cuestión administrativa que se presentó a lo largo del posgrado.

Al Dr. Gustau Camps-Valls, por brindarme la oportunidad de formar parte del Laboratorio de Procesamiento de Imágenes en mi estadía en Valencia, España.

Al Dr. Valero Laparra, por ampliar mi conocimiento en redes neuronales.

A mis compañeros y amigos del Departamento de Geomática. Alejandro Barrón, Andrea Escobedo, Diana Mireles, Diego Zabala y Nelly Lucero, gracias por su amistad y buenos momentos compartidos. A Katia Figueroa, por su apoyo en la corrección de la capa de vialidades. Al Ing. Carlos Aguilar, por su colaboración en el levantamiento y procesamiento de información de campo.

Al Mtro. Daniel Mendoza, por regalarme momentos de su preciado tiempo para la resolución de dudas en temas de programación y estadística.

A Alejandro Barrón, Ángel Tamez, Arturo Garza, Daniel Caballero, Daniel Mendoza, Eleazar Lozano, Kelly Ríos, Mario Díaz, Nary, Natalia Rodríguez y Sergio Fuentes, por los gratos momentos de convivencia que me permitieron sobrellevar los tiempos de obligado encierro por pandemia que abarcaron gran parte del desarrollo de esta investigación.

A mi familia, que se mantenía atenta a cada paso recorrido por esta senda y me motivaba a seguir avanzando, gracias, Grace Huerta y familia, Cuquis Castañeda, Maricela Ibieta y familia.

Les agradezco a mis padres, Graciela García Castañeda y Roberto Jorge Huerta Vázquez, por su continuo apoyo a través de las etapas profesionales que me han permitido llegar a este punto. Gracias por continuar alentándome y celebrar cada logro obtenido a mi paso.

A Ghost, Maiki, Rictavia, Snow, Taquito, y Warry, nuestras adorables mascotas que, con sus cuyidos y ronroneos, nos han traído tanta felicidad en tiempos de pandemia, siendo una invaluable compañía para sobrellevar el encierro.

Por último, quisiera agradecer a mi amada esposa, Natalia Rodríguez Ibieta. De todo corazón, muchas gracias por todo el amor, la paciencia y apoyo brindados. Sin importar el tamaño del dragón, la inmensidad del calabozo, juntos venceremos. Ganbare!

INDICE

INTRODUCCIÓN.....	1
ANTECEDENTES Y MARCO TEÓRICO.....	2
CAPÍTULO 1. ÁREAS VERDES URBANAS.....	2
1.1 Definición.....	2
1.2 Beneficios de las AVU.....	4
1.2.1 Beneficios ambientales.....	4
1.2.2 Beneficios sociales.....	7
1.2.3 Beneficios económicos.....	9
1.3 Problemas.....	10
1.3.1 Incremento poblacional.....	10
1.3.2 Migración y transición rural-urbana.....	11
1.3.3 Cambios de uso de suelo.....	13
1.4 Gestión de AVU.....	15
1.4.1 Inventario de AVU.....	15
1.4.2 Casos de estudio.....	16
CAPÍTULO 2. PERCEPCIÓN REMOTA.....	18
2.1 Tipos de resolución.....	19
2.1.1 Resolución espacial.....	19
2.1.2 Resolución espectral.....	21
2.1.3 Resolución temporal.....	23
2.1.4 Resolución radiométrica.....	24
2.2 Índices de vegetación.....	24
2.2.1 NDVI.....	24
2.2.2 EVI.....	25
2.2.3 NDWI.....	26
CAPÍTULO 3. SEGMENTACIÓN SEMÁNTICA.....	27
3.1 Método manual.....	27
3.2 Métodos automáticos.....	28
3.2.1 Aprendizaje automático.....	28
3.2.2 Aprendizaje profundo.....	29

CAPÍTULO 4. MODELACIÓN DE AVU	36
4.1 Conectividad.....	36
4.2 Accesibilidad.....	37
CAPÍTULO 5. PROCESO. GUÍA METODOLÓGICA.....	39
5.1 JUSTIFICACIÓN DEL ESTUDIO.....	39
5.2 HIPÓTESIS.....	39
5.3 OBJETIVOS.....	39
5.3.1 OBJETIVO GENERAL.....	39
5.3.2 OBJETIVOS ESPECÍFICOS.....	39
5.4 Área de estudio.....	42
5.4.1 Usos de suelo y vegetación.....	43
5.4.2 Hidrografía.....	43
5.4.3 Clima.....	44
5.4.4 Relieve.....	45
5.4.5 Geología.....	46
CAPÍTULO 6. MÉTODO: SEGMENTACIÓN SEMÁNTICA.....	49
6.1 Insumos de entrada.....	49
6.1.1 Base de datos del INEGI.....	49
6.1.2 Base de datos de OSM.....	50
6.1.3 Base de datos de Departamento de Geomática.....	51
6.1.4 Imagen satelital de muy alta resolución.....	51
6.2 Pre-procesamiento de datos.....	54
6.2.1 Inspección de bases de datos y reclasificación tipográfica.....	54
6.2.2 Descarte de polígonos duplicados y fusión de bases de datos.....	55
6.2.3 Rasterización de etiquetas.....	55
6.2.4 Generación de composiciones.....	55
6.2.5 Fragmentación de las muestras.....	56
6.3 Implementación de modelo de RNC.....	58
6.3.1 Entorno de implementación.....	58
6.3.2 Librerías para la modelación de RNC.....	60
6.3.3 Arquitectura de red.....	60
6.3.4 Ajuste de parámetros.....	62

6.4 Evaluación de segmentación semántica de AVU	66
CAPÍTULO 7. MÉTODO: MODELACIÓN DE AVU.....	69
7.1 Evaluación de la condición de vegetación	69
7.1.1 Índices de vegetación	69
7.1.2 Comparación de condiciones entre los años 2016 y 2021.....	70
7.2 Conectividad de las AVU	70
7.3 Accesibilidad de las AVU.....	72
7.3.1 Densidad de las AVU.....	72
7.3.2 Análisis de red	72
CAPÍTULO 8. MÉTODO: VALIDACIÓN DE PRECISIÓN.....	76
8. Validación de precisión.....	76
RESULTADOS	79
CAPÍTULO 9. RESULTADOS: SEGMENTACIÓN SEMÁNTICA.....	79
9.1 Pre-procesamiento de datos.....	79
9.2 Implementación de modelo de RNC	80
CAPÍTULO 10. RESULTADOS: MODELACIÓN DE AVU.	85
10.1 Evaluación de condición de la vegetación	85
10.2 Conectividad de las AVU	99
10.3 Accesibilidad de AVU.....	101
CAPÍTULO 11. RESULTADOS: VALIDACIÓN DE PRECISIÓN.	134
DISCUSIÓN.....	143
CONCLUSIONES Y RECOMENDACIONES.....	147
CONCLUSIONES	147
RECOMENDACIONES.....	148
BIBLIOGRAFIA.....	149
ANEXOS.....	164

Lista de figuras

Figura 1. Incremento poblacional en México generado desde comienzos del siglo XX al año 2020.	11
Figura 2. Transición entre población urbana y rural de México entre los años 1950 y 2020.	12
Figura 3. Primer cuadro de la ciudad de Monterrey. Déficit de AVU (plazas) que ha generado la expansión urbana de la ciudad.	14
Figura 4. Ejemplo de ortomosaico a diversas escalas de resolución espacial..	20
Figura 5. Firmas espectrales de diversos elementos característicos presentes en la superficie terrestre.	21
Figura 6. Ejemplo de ortomosaicos de dos capas espectral diferentes sobre un AVU.	22
Figura 7. Ejemplo de ortomosaicos de la Alameda de Monterrey obtenidos para dos fechas diferentes.....	23
Figura 8. Visualización de bandas empleadas por el algoritmo NDVI.....	25
Figura 9. Visualización de bandas empleadas por el algoritmo EVI	25
Figura 10. Visualización de bandas empleadas por el algoritmo EVI2	26
Figura 11. Visualización de bandas empleadas por el algoritmo NDWI.....	26
Figura 12. Proceso de digitalización manual de polígonos para llenado de AVU de Marco Geoestadístico Nacional.	28
Figura 13. Red neuronal profunda básica con capa de entrada, capa oculta y capa de salida.....	30
Figura 14. Arquitectura típica de RNC..	31
Figura 15. Arquitectura de red completamente convolucional sin componente completamente conectado.....	33
Figura 16. Arquitectura de U-Net con configuración de codificador – decodificador.....	34
Figura 17. Bloque de construcción, componente principal de redes ResNet que integra la identidad de la salida del bloque anterior.	35
Figura 18. Proceso metodológico general seguido en la elaboración de este proyecto.	41
Figura 19. Zona Metropolitana de Monterrey.....	42
Figura 20. Tipos de uso de suelo y vegetación (Serie VI) de la ZMM	43
Figura 21. Hidrología de ZMM..	44
Figura 22. Tipos de clima presentes en la ZMM conforme a la Carta de Climas de INEGI (2010).....	45
Figura 23. Orografía de ZMM.....	46
Figura 24. Carta Geológico-Minera Monterrey G14-7 con información correspondiente a la litología de la ZMM.	47
Figura 25. Proceso metodológico seguido en la elaboración de la segmentación semántica de AVU de la ZMM a partir de redes neuronales convolucionales. .	48
Figura 26. Polígonos de AVU obtenidos a partir del MGN.....	49
Figura 27. Polígonos de AVU obtenidos a partir de OSM.....	50

Figura 28. Polígonos de AVU obtenidos a partir de base de datos de camellones generados por el Departamento de Geomática, FIC, UANL.	51
Figura 29. Ortomosaico de ZMM generado a partir de imágenes de muy alta resolución del satélite WorldView-2.	52
Figura 30. Histogramas de distribución de longitudes de onda de píxeles en las cuatro bandas del ortomosaico de la ZMM.	53
Figura 31. Fragmentación de muestras..	57
Figura 32. Arquitectura de RNC.....	61
Figura 33. Ejemplos de imágenes producidas por el aumento de datos.....	63
Figura 34. Muestras de evaluación de modelo de RNC.....	66
Figura 35. Proceso metodológico seguido en la modelación de la condición, conectividad y accesibilidad de AVU de la ZMM.....	68
Figura 36. Errores topológicos y centroides de parques y plazas.....	74
Figura 37. Errores topológicos por tipo.	74
Figura 38. Proceso metodológico seguido en la validación de la precisión de la metodología empleada.	75
Figura 39. Puntos de muestreo de AVU con equipo VANT.	76
Figura 40. Ejemplo de muestra producida en proceso de fragmentación.	80
Figura 41. Gráfica de pérdida de entrenamiento, pérdida de validación y coeficiente Dice para los codificadores ResNet34 y ResNet50	82
Figura 42. Aprendizaje en modelación de segmentación.	82
Figura 43. Modelo de evaluación.....	83
Figura 44. Condición de vegetación de AVU, de acuerdo con la media de valores del índice NDVI calculado para los municipios de la ZMM al año 2016.	877
Figura 45. Condición de vegetación de AVU, de acuerdo con la media de valores del índice EVI2 calculado para los municipios de la ZMM al año 2016.	88
Figura 46. Condición de vegetación de AVU, de acuerdo con la media de valores del índice NDWI calculado para los municipios de la ZMM al año 2016.	89
Figura 47. Condición de vegetación de AVU, de acuerdo con la media de valores del índice NDVI calculado para las manzanas de la ZMM al año 2016.	90
Figura 48. Condición de vegetación de AVU, de acuerdo con la media de valores del índice EVI2 calculado para las manzanas de la ZMM al año 2016.	91
Figura 49. Condición de vegetación de AVU, de acuerdo con la media de valores del índice NDWI calculado para las manzanas de la ZMM al año 2016.	92
Figura 50. Condición de vegetación de AVU, de acuerdo con la media de valores del índice NDVI calculado para los municipios de la ZMM al año 2021.	93
Figura 51. Condición de vegetación de AVU, de acuerdo con la media de valores del índice EVI2 calculado para los municipios de la ZMM al año 2021.	94

Figura 52. Condición de vegetación de AVU, de acuerdo con la media de valores del índice NDWI calculado para los municipios de la ZMM al año 2021.	95
Figura 53. Condición de vegetación de AVU, de acuerdo con la media de valores del índice NDVI calculado para las manzanas de la ZMM al año 2021.	96
Figura 54. Condición de vegetación de AVU, de acuerdo con la media de valores del índice EVI2 calculado para las manzanas de la ZMM al año 2021.	97
Figura 55. Condición de vegetación de AVU, de acuerdo con la media de valores del índice NDWI calculado para las manzanas de la ZMM al año 2021 .	98
Figura 56. Comparación de condición de verdor de AVU entre los años 2016 y 2021 para los municipios de la ZMM mediante el uso del índice NDVI.	99
Figura 57. Densidad de AVU presente en el municipio de Apodaca, Nuevo León.	102
Figura 58. Densidad de AVU presente en el municipio de Cadereyta, Nuevo León.	103
Figura 59. Densidad de AVU presente en el municipio de General Escobedo, Nuevo León.	104
Figura 60. Densidad de AVU presente en el municipio de García, Nuevo León.	105
Figura 61. Densidad de AVU presente en el municipio de Guadalupe, Nuevo León.	106
Figura 62. Densidad de AVU presente en el municipio de Juárez, Nuevo León (.).	107
Figura 63. Densidad de AVU presente en el municipio de Monterrey, Nuevo León.	108
Figura 64. Densidad de AVU presente en el municipio de Salinas Victoria, Nuevo León.	109
Figura 65. Densidad de AVU presente en el municipio de Santa Catarina, Nuevo León.	110
Figura 66. Densidad de AVU presente en el municipio de Santiago, Nuevo León.	111
Figura 67. Densidad de AVU presente en el municipio de San Nicolás de los Garza, Nuevo León.	112
Figura 68. Densidad de AVU presente en el municipio de San Pedro Garza García, Nuevo León.	113
Figura 69. Índice de accesibilidad a AVU para el municipio de Apodaca, Nuevo León.	115
Figura 70. Índice de accesibilidad a AVU para el municipio de Cadereyta, Nuevo León.	116
Figura 71. Índice de accesibilidad a AVU para el municipio de General Escobedo, Nuevo León.	117

Figura 72. Índice de accesibilidad a AVU para el municipio de García, Nuevo León.....	118
Figura 73. Índice de accesibilidad a AVU para el municipio de Guadalupe, Nuevo León	119
Figura 74. Índice de accesibilidad a AVU para el municipio de Juárez, Nuevo León.....	120
Figura 75. Índice de accesibilidad a AVU para el municipio de Monterrey, Nuevo León.....	121
Figura 76. Índice de accesibilidad a AVU para el municipio de Salinas Victoria, Nuevo León.....	122
Figura 77. Índice de accesibilidad a AVU para el municipio de San Nicolás de los Garza, Nuevo León.	123
Figura 78. Índice de accesibilidad a AVU para el municipio de San Pedro Garza García, Nuevo León.....	124
Figura 79. Índice de accesibilidad a AVU para el municipio de Santa Catarina, Nuevo León.....	125
Figura 80. Índice de accesibilidad a AVU para el municipio de Santiago, Nuevo León.....	126
Figura 81. Indicadores de accesibilidad a las AVU para la ZMM.	127
Figura 82. Indicadores de accesibilidad a las AVU para Apodaca, Nuevo León.	128
Figura 83. Indicadores de accesibilidad a las AVU para Cadereyta, Nuevo León.	128
Figura 84. Indicadores de accesibilidad a las AVU para General Escobedo, Nuevo León.....	129
Figura 85. Indicadores de accesibilidad a las AVU para García, Nuevo León.	129
Figura 86. Indicadores de accesibilidad a las AVU para Guadalupe, Nuevo León	130
Figura 87. Indicadores de accesibilidad a las AVU para Juárez, Nuevo León.	130
Figura 88. Indicadores de accesibilidad a las AVU para Monterrey, Nuevo León.	131
Figura 89. Indicadores de accesibilidad a AVU para Santa Catrina, Nuevo León.	131
Figura 90. Indicadores de accesibilidad a las AVU para Santiago, Nuevo León.	132
Figura 91. Indicadores de accesibilidad a las AVU para San Nicolás de los Garza, Nuevo León.....	132
Figura 92. Indicadores de accesibilidad a las AVU para San Pedro Garza García, Nuevo León.....	133
Figura 93. Índice NDVI calculado para el polígono SN1 en la imagen satelital Sentinel-2.....	135
Figura 94. Índice NDVI calculado para el polígono SN1 en el ortomosaico de fotorreconstrucción obtenida a través de VANT.....	135

Figura 95. Índice NDVI calculado para el polígono SN2 en la imagen satelital Sentinel-2.....	136
Figura 96. Índice NDVI calculado para el polígono SN2 en el ortomosaico de fotorreconstrucción obtenida a través de VANT.....	136
Figura 97. Índice NDVI calculado para el polígono SN3 en la imagen satelital Sentinel-2.....	137
Figura 98. Índice NDVI calculado para el polígono SN3 en el ortomosaico de fotorreconstrucción obtenida a través de VANT.....	137
Figura 99. Índice NDVI calculado para el polígono ESC1 en la imagen satelital Sentinel-2.....	138
Figura 100. Índice NDVI calculado para el polígono ESC1 en el ortomosaico de fotorreconstrucción obtenida a través de VANT.....	138
Figura 101. Índice NDVI calculado para el polígono ESC2 en la imagen satelital Sentinel-2.....	139
Figura 102. Índice NDVI calculado para el polígono ESC2 en el ortomosaico de fotorreconstrucción obtenida a través de VANT.....	139
Figura 103. Índice NDVI calculado para el polígono ESC3 en la imagen satelital Sentinel-2.....	140
Figura 104. Índice NDVI calculado para el polígono ESC3 en el ortomosaico de fotorreconstrucción obtenida a través de VANT.....	140
Figura 105. Índice NDVI calculado para el polígono ESC4 en la imagen satelital Sentinel-2.....	141
Figura 106. Índice NDVI calculado para el polígono ESC4 en el ortomosaico de fotorreconstrucción obtenida a través de VANT.....	141
Figura 107. Índice NDVI calculado para el polígono ESC5 en la imagen satelital Sentinel-2.....	142
Figura 108. Índice NDVI calculado para el polígono ESC5 en el ortomosaico de fotorreconstrucción obtenida a través de VANT.....	142

Lista de tablas

Tabla 1. Zonificación y clasificación de espacios abiertos y/o áreas verdes de acuerdo a LAH.	3
Tabla 2. Proporción de AVU presentes en 9 municipios de la ZMM, Nuevo León, México al año 2004.	17
Tabla 3. Ejemplos de empleos de distintas resoluciones espaciales en artículos de AVU.	20
Tabla 4. Ejemplos de productos de sensores remotos de distintas resoluciones espectrales empleados en artículos de AVU.	22
Tabla 5. Ejemplos de empleos de distintas resoluciones temporales en artículos de AVU.	23
Tabla 6. Estadísticas de los valores de longitud de onda de las cuatro bandas del ortomosaico de la ZMM.	53
Tabla 7. Reasignación de etiquetas en el proceso de reclasificación de las tres bases de datos.	54
Tabla 8. Composiciones de 3 bandas.	56
Tabla 9. Equipos empleados en preprocesamiento de datos.	58
Tabla 10. Características del equipo remoto en Google Colab.	59
Tabla 11. Versiones de software empleado para el modelo segmentación semántica de AVU de la ZMM.	62
Tabla 12. Métricas empleadas para el análisis de conectividad de AVU de la ZMM.	71
Tabla 13. Especificaciones de DJI Phantom 4 Pro.	77
Tabla 14. Especificaciones de sensores para el levantamiento de AVU de ZMM.	78
Tabla 15. Estadísticas de clases de AVU en ZMM.	79
Tabla 16. Estadísticas de clases de AVU en ZMM.	81
Tabla 17. Matriz de confusión y coeficiente Kappa.	84
Tabla 18. Variables de análisis de fragmentación de AVU de la ZMM.	100
Tabla 19. Estadísticas de la densidad de AVU por municipio.	101
Tabla 20. Estadísticas por zona de los valores de NDVI generados para las muestras obtenidas en imágenes Sentinel-2.	134
Tabla 21. Estadísticas por zona de los valores de NDVI generados para las muestras obtenidas del producto obtenido mediante fotografías de VANT y fotorreconstrucción.	134

SIGLAS Y ABREVIATURAS

AGEB	Área geoestadística básica
AGEE	Área geoestadística estatal
AGEM	Área geoestadística municipal
AVU	Área verde urbana
CDMX	Ciudad de México
CO₂	Dióxido de carbono
CONAPO	Consejo Nacional de Población
EVI	Índice de vegetación mejorado
EVI2	Índice de vegetación mejorado 2
FIC	Facultad de Ingeniería Civil
GPS	Sistema de Posicionamiento Global
GPU	Unidad de procesamiento gráfico
INEGI	Instituto Nacional de Estadística y Geografía
IRC	Infrarrojo cercano
LAH	Ley de Asentamientos Humanos, Ordenamiento Territorial y Desarrollo Urbano de Nuevo León
MGN	Marco Geoestadístico Nacional
OBIA	Análisis de imagen basado en objetos
OMS	Organización Mundial de la Salud
OSM	OpenStreetMap
PCA	Análisis de componentes principales
PR	Percepción remota
RNA	Red neuronal artificial
RNP	Red neuronal profunda
RNC	Red neuronal convolucional
RCC	Red completamente convolucional
ResNet	Red residual
SAVI	Índice de vegetación ajustado al suelo
SEDESOL	Secretaría de Desarrollo Social
SIG	Sistemas de información geográfica
SFM	Structure from motion
TPU	Unidad de procesamiento tensorial
UANL	Universidad Autónoma de Nuevo León
VANT	Vehículo aéreo no tripulado
V.F.	Verdad fundamental
ZM	Zona Metropolitana
ZMM	Zona Metropolitana de Monterrey

INTEGRACIÓN DE REDES NEURONALES CONVOLUCIONALES Y PERCEPCIÓN REMOTA EN LA MODELACIÓN DE LA CONECTIVIDAD Y ACCESIBILIDAD DE ÁREAS VERDES URBANAS

por

Roberto Emmanuel Huerta García

RESUMEN

Gracias a los servicios ambientales que brindan, las áreas verdes urbanas (AVU) representan un aspecto importante dentro los espacios públicos de las ciudades. Conforme a las políticas de manejo en que se desarrollen, los procesos de urbanización pueden influir de forma positiva o negativa en el cuidado y conservación de estos ecosistemas urbanos. El monitoreo de las AVU brinda la posibilidad de conocer su situación actual y permite evaluar las medidas de la regulación existentes, así como su adecuado cumplimiento. La conectividad, accesibilidad y condición de la vegetación son parámetros determinantes del estado en que se encuentran las AVU. A través de estos parámetros se determinan los flujos de energía, los materiales y las especies en un espacio físico. La tecnología actual de los sistemas de información geográfica (SIG), los sensores remotos y la integración del análisis autónomo, a través del aprendizaje profundo de los datos, permite generar información clave para una gestión más eficiente y económica de las AVU. En esta investigación se utiliza la sinergia de estas tres tecnologías mediante un modelo de SIG que integra imágenes de muy alta resolución, con redes neuronales convolucionales, permitiendo generar un producto que ayudará a mejorar la gestión de las AVU.

PALABRAS CLAVE

Vegetación urbana, manejo urbano, redes neuronales, segmentación semántica, aprendizaje profundo.

INTRODUCCIÓN

Fenómenos actuales como la acelerada expansión urbana ocasionada por el constante incremento poblacional, la transición de la población rural hacia áreas urbanas y los cambios de usos de suelo que genera el crecimiento urbano no planificado repercuten en las condiciones del entorno urbano, dentro del que se incluyen las AVU. Éstas representan un aspecto fundamental dentro del funcionamiento de las ciudades, debido a que ofrecen una gran variedad de servicios ecosistémicos capaces de mitigar los impactos del acelerado desarrollo urbano y ayudan a reducir los perjuicios ocasionados al ecosistema. Es por ello que su preservación, mantenimiento y consideración dentro de la planeación urbana sea de vital importancia.

Para conocer la situación actual de las AVU de manera tradicional se emplean inventarios obtenidos mediante métodos manuales. Estas herramientas requieren jornadas exhaustivas para el levantamiento de los datos, así como una importante cantidad de brigadas de personal, conforme a las proporciones del estudio. Para realizar un seguimiento de la información recolectada, los inventarios de AVU deben ser actualizados periódicamente, lo cual conlleva elevados costos económicos. En busca de la disminución de recursos para la obtención de la información, se ha demostrado que la sinergia de técnicas de la percepción remota (PR) y métodos como las redes neuronales convolucionales (RNC), desarrolladas a partir del campo del aprendizaje automático, permiten la generación de información espaciotemporal precisa y actualizada que resulta de utilidad para la toma de decisiones de manera más eficiente.

Por lo descrito anteriormente, en este trabajo se plantea integrar métodos de RNC y PR para generar datos de alta resolución que permitan la modelación de conectividad y accesibilidad de AVU de manera eficiente.

ANTECEDENTES Y MARCO TEÓRICO

CAPÍTULO 1. ÁREAS VERDES URBANAS.

1.1 Definición

Las AVU presentan diversas definiciones asociadas con las ciencias que las estudian y con las organizaciones territoriales que las administran. Como ejemplo, Haq (2011) contempla que los espacios verdes urbanos corresponden a espacios de índole pública y privada, añadiendo que se deben encontrar localizados dentro de zonas urbanas y deben presentar cubierta vegetal para el uso directo o indirecto por parte de los usuarios. Por otro lado, Benavides-Meza & Fernández-Grandizo (2012) señalan que las AVU corresponden a espacios exclusivamente públicos, con árboles, arbustos y vegetación herbácea, los cuales se encuentran bajo resguardo de gobiernos municipales y delegaciones. Uy & Nakagoshi (2008) ofrecen una definición más abstracta, al señalar que las AVU pueden ser identificadas de muy variadas formas conforme a las demandas y requerimientos de los usuarios, ajustando el concepto a distintas configuraciones referentes a la proporción entre la vegetación y la infraestructura presente.

En la república mexicana el concepto de AVU se establece dentro de distintos instrumentos legales, como la reglamentación y la legislación de competencia ambiental y los referentes al desarrollo urbano. Entre las que se encuentran, la definición brindada por la ley ambiental de protección a la tierra en el Distrito Federal, con última reforma publicada en la gaceta oficial de la Ciudad de México el 08 de septiembre de 2017, en la que en su Artículo 5° se designa bajo el nombre de área verde a toda superficie cubierta de vegetación, natural o inducida que se localice en la Ciudad de México. Otro caso es el concepto empleado en el reglamento interior de la Secretaría de Infraestructura y Servicios Públicos del honorable ayuntamiento del municipio de Puebla, en el que, en su artículo 28, hace referencia a las AVU de acuerdo con su función y localización dentro del entorno urbano. Por otro lado, en el reglamento de áreas verdes y arborización para el municipio de Tuxtla Gutiérrez, Chiapas, en el artículo 4°, se mencionan los tipos de

vegetación que presentan las AVU y los diferentes sitios en que se pueden encontrar dentro de la infraestructura de la ciudad.

En el noreste del país, el municipio de Monterrey cuenta con legislación y reglamentos que determinan la conceptualización necesaria para la gestión de AVU. En el artículo 4°, presente dentro del capítulo de las disposiciones generales del reglamento de protección ambiental e imagen urbana de Monterrey, se define en su sección I a las áreas verdes como “superficies de terreno de uso público dentro del área urbana o en su periferia, provistas de vegetación, jardines, arboledas y edificaciones menores complementarias”.

Como complemento a la definición señalada, se asigna en el artículo 138° de la ley de asentamientos humanos, ordenamiento territorial y desarrollo urbano de Nuevo León (LAH), con última reforma publicada en el periódico oficial del estado, de número 157 y fecha 20 de diciembre de 2019, que los “espacios abiertos y áreas verdes forman parte de una zonificación secundaria de suelo y edificaciones que es determinada según el destino que el gobierno les da a los suelos de espacios públicos”.

Adicionalmente, como parte de la misma ley, se contempla en el artículo 143° la clasificación del apartado a), del artículo 138°, donde se cubre la zonificación de los destinos del suelo; específicamente la de los espacios abiertos y áreas verdes mostrada en la Tabla 1.

Tabla 1. Zonificación y clasificación de espacios abiertos y/o áreas verdes de acuerdo con la LAH.

Artículo 138. Zonificación secundaria de suelo y edificaciones por destinos del suelo	Artículo 143 Clasificación de espacios abiertos y/o áreas verdes
a. Espacios abiertos y áreas verdes	I. Parques y/o espacios abiertos
b. Infraestructura y obras complementarias	II. Jardines, parques públicos y otras áreas de preservación ecológica
c. Equipamiento urbano	III. Presas, estanques, lagos y lagunas
d. Vialidad y obras complementarias	IV. Ríos, arroyos, veneros, escurrimientos
e. Mixto	

La definición y clasificación de las AVU agiliza los procesos de gestión ya que permiten distinguir y designar dichos espacios conforme a su forma, función, ubicación espacial, porcentaje de presencia de vegetación y equipamiento presente dentro de ellas. A través de su correcto empleo es posible trabajar con información consistente que permite el análisis, la evaluación y la determinación de su estado, y, de su relación con la población presente en el área de influencia (Swanwick, Dunnett, & Woolley, 2003).

1.2 Beneficios de las AVU

Las AVU, al igual que el equipamiento urbano de edificaciones e instalaciones para el transporte, la educación, la seguridad, la salud, las comunicaciones, los servicios urbanos y demás funciones públicas, conforman un aspecto fundamental dentro de la infraestructura urbana. Como aspecto fundamental dentro de la infraestructura urbana, las AVU propician un desarrollo urbano sostenible gracias a sus múltiples beneficios ambientales, sociales y económicos (Tian, Jim, & Wang, 2014). A pesar de que los servicios que ofrecen las AVU favorecen mejoras en el desarrollo de las ciudades, éstos suelen ser infravalorados por los tomadores de decisiones (Baró, 2016); por lo cual es de alta importancia que los diversos actores de la sociedad reconozcan los beneficios que se obtienen de las AVU, para que se involucren de forma activa en su conservación y cuidado, así como en la generación de nuevas AVU.

1.2.1 Beneficios ambientales

Gracias a la presencia de cobertura vegetal que proveen las AVU, existe la posibilidad de obtener servicios ambientales o ecosistémicos que ayudan a enfrentar condiciones adversas producidas dentro de las ciudades y que inciden de forma directa e indirecta en la vida de los residentes de dichos sitios (Wolch, Byrne, & Newell, 2014). De este modo, los servicios ambientales ayudan al mantenimiento de un ecosistema sano y resiliente y, a su vez, de forma paralela repercuten positivamente en la salud pública (Jennings, Larson, & Yun, 2016).

Como lo plasmaron en su trabajo, Selmi *et al* (2016), un importante aporte al ambiente por parte de las AVU es la capacidad de captar partículas contaminantes

de aire a través de la cobertura vegetal. En su trabajo lograron determinar, a través de equipo especializado, la cantidad de contaminantes que removían los árboles públicos de la ciudad francesa de Estrasburgo, demostrando la importancia de la presencia de vegetación dentro de las ciudades. Por otro lado, Oviantari, Gunamantha, Ristiati, Santiasa, & Astariani (2018), calcularon la biomasa forestal de árboles, hojarasca y hierbas pertenecientes a AVU de la ciudad de Singaraja, Indonesia, mediante ecuaciones alométricas y métodos tradicionales. Con ello determinaron que dichos sustratos, en especial los árboles, tienen muy buen potencial para realizar la captura de CO₂, de modo que participan activamente en la reducción de emisiones de gases de efecto invernadero. Al igual, Sun, Xie, & Zhao, (2019) realizaron en China una estimación de carbono capturado sobre el nivel del suelo en las AVU, con la cual demostraron su contribución en la mitigación contra el cambio climático.

A su vez, se ha reportado que la presencia de vegetación de las AVU regula el clima de la zona, generando microclimas con condiciones favorables para ecosistemas, donde además la población goza de sus beneficios, al ser proveída de áreas con condiciones agradables para el disfrute de actividades recreativas, de esparcimiento y deporte (Lafortezza, Carrus, Sanesi, & Davies, 2009). Aportando a lo previo, Klok, Rood, Kluck, & Kleerekoper (2019) realizaron una evaluación de espacios urbanos térmicamente cómodos en Ámsterdam, durante días cálidos de los años 2015 y 2016. Entre sus resultados, demostraron que las sombras producidas por árboles de AVU crean condiciones de ambiente fresco que reducen el estrés de la población ocasionado por el calor.

La inclusión de AVU dentro de la planeación de zonas urbanas ayuda a mitigar el efecto de isla de calor y para ello Huang, Cui, & He (2018) determinaron que los principales parámetros que influyen en la reducción de temperatura son el área, perímetro y forma de las AVU, siendo de especial ayuda en los meses de verano. En una evaluación del efecto de la infraestructura verde en la mitigación de islas de calor, Marando, Salvatori, Sebastiani, Fusaro, & Manes (2019) demostraron que el índice de vegetación de diferencia normalizada (NDVI) permite monitorear la

cubierta de árboles, principales elementos para la regulación climática. En su trabajo se destaca la importancia de las AVU en la adaptación climática de entornos urbanos.

Otro factor ambiental en que influyen las AVU es en la provisión de hábitats para la flora y la fauna (Threlfall et al., 2017). Estos espacios favorecen a que haya una buena biodiversidad, gracias a las variaciones genéticas que albergan, y permiten la recuperación de ecosistemas en caso de que sufran deterioros. Dicho lo anterior, es de particular interés que se mantenga el flujo genético de las especies en las ciudades a través del adecuado funcionamiento de las AVU, ya que éstas proporcionan servicios ecosistémicos vitales para la regulación del ambiente (Lepczyk et al., 2017).

Al ruido ocasionado en entornos urbanos, generalmente por la afluencia de tráfico vehicular o la industria, se le considera como un tipo de contaminación debido a que ejerce efectos negativos en la sociedad y en el ambiente. En la población, el ruido afecta en la salud, estando asociado a enfermedades cardiovasculares, respiratorias y metabólicas, debido a alteraciones fisiológicas ocasionadas por el estrés (Recio, Linares, Banegas, & Díaz, 2017). Se ha comprobado, además, que el ruido afecta a ecosistemas de aves y pequeños mamíferos que habitan en zonas urbanas, al generarles estrés (Pieniżek, Boguszewski, & Meronka, 2017) e interferir en sus procesos de comunicación, detección de peligros o actividad reproductiva (Manzanares-Mena & Macías-García, 2018). Consecuentemente, ha afectado su comportamiento, generando condiciones perjudiciales para su estado físico, supervivencia y reproducción y, a gran escala, se reflejan en una disminución de riqueza y diversidad especies que habitan los espacios urbanos (Perillo et al., 2017). A través de análisis de correlaciones, Lopez & Souza (2018) resaltaron la importancia de la presencia de AVU en las urbes, al determinar que la vegetación presente en ellas cuenta con la capacidad de atenuar el ruido urbano.

Kim, Lee, & Sung (2016) analizaron el efecto de las AVU en la probabilidad de inundación de diversas áreas en la ciudad de Seúl, Corea. Sus resultados demostraron que las AVU constituyen un elemento crucial para la provisión de un

ambiente seguro en áreas urbanas, ya que permiten la reducción de la probabilidad de inundaciones en hasta un 50 % de acuerdo con el área y su localización. Song, Tan, Edwards, & Richards (2018) hablan de los beneficios del arbolado presente en AVU, asociado con la regulación del ciclo del agua, con particular enfoque en la captación de agua de lluvia, observando que los valores anuales por árbol oscilan la absorción de entre los 0.28 m³ y 11.3 m³.

1.2.2 Beneficios sociales

Las AVU contribuyen al bienestar de la población, al proveer sitios en los cuales existe la posibilidad de realizar actividades de esparcimiento, como el desplazamiento peatonal diario de los ciudadanos a sus áreas de trabajo e instituciones educativas, así como recorridos intermedios hacia medios de transporte (Alexandre da Silva, Ribeiro da Silveira, & Leite Ribeiro, 2019); actividades de recreación, a través del uso de áreas de juego y convivio familiar (Tyrväinen, Mäkinen, & Schipperijn, 2007a); y, la práctica de diversos deportes como fútbol, básquetbol, voleibol, paseo en bicicleta, monopatín, entre otros (Wang, Dai, Wu, Wu, & Nie, 2019). Además de lo anterior, las AVU generan en los habitantes de las ciudades sentimientos positivos como el sentido de comunidad que vincula a la población con un sitio particular, la sensación de tranquilidad y conciencia por el medio ambiente (Jiménez et al, 2013). A su vez, las AVU representan en adultos un conducto de felicidad gracias a la provisión de espacios que, a través de su paisaje, les generan sentimientos de belleza, seguridad, agradabilidad y paz (Kafafy & Fathy, 2019). En acuerdo con lo antecedente, Alanis, Foroughbakhch, Alvarado, & Rocha, (2004) encontraron que las AVU mejoran la imagen urbana, al convertir a las ciudades en lugares más agradables y con mejores condiciones para vivir, y, brindar una identidad característica conforme a sus AVU.

Las AVU dotan de bienestar a la sociedad al brindarle espacios que permiten incrementar las relaciones humanas, fortaleciendo la interacción en los vínculos de comunidades (Colacios & Mendoza-Arroyo, 2017). Dadvand et al. (2019) dieron prueba de ello en individuos correspondientes a una población joven, mediante un estudio transversal en el que determinaron que el tiempo que pasan los

adolescentes en las AVU mantiene una correspondencia positiva con mejoras en su autosatisfacción y en el contacto social que mantienen. Por otra parte, Jahangir (2019) exploró los beneficios de las AVU percibidos por individuos mayores de edad y determinó que éstas forman una parte integral en sus rutinas diarias ya que a través de dichos espacios se facilita el desenvolvimiento de encuentros comunitarios y el favorecimiento de la cohesión social, en ocasiones carente por parte de la sociedad en general y de la familia hacia los adultos mayores.

Al proveer de espacios para la práctica de deportes y la realización de rutinas de ejercicio, las AVU propician mejoras en la salud de los ciudadanos, a la par que llevan a cabo procesos que ayudan a mantener en equilibrio las condiciones ambientales de las metrópolis. Akpinar (2016) encontró que individuos que residían a mayores cercanías de AVU realizaban actividades físicas con una frecuencia mayor, lo cual reflejó en menores niveles de estrés y mejoras a la salud física y mental. Más allá de la provisión de áreas para realizar actividad física e interrelación, las AVU influyen en el estado mental de la población. En un estudio realizado por Wood, Hooper, Foster, & Bull (2017) se determinó que las AVU presentes a cortas distancias de vecindarios locales mejoran la salud mental de los residentes, generando placer, felicidad, afecto positivo, relaciones interpersonales satisfactorias y funcionamiento positivo en los residentes del área bajo estudio.

De manera indirecta, la presencia de AVU en entornos urbanos ayuda a reducir los efectos nocivos a la salud causados por la misma actividad del hombre. En el trabajo de Ulmer et al. (2016) se promueve el reconocimiento del potencial que tienen las superficies arborizadas dentro de los Estados Unidos. Los resultados de dicho estudio sugieren que la cercanía a vecindarios con mayor cobertura de árboles mejora la salud pública de un sitio. Adicionalmente, en el estudio se encontró que en tales casos la gente presentó una menor tasa de obesidad, mejor cohesión social, y, en menor grado, menos cantidades de incidencia de diabetes tipo 2, presión sanguínea alta y enfermedades respiratorias.

De acuerdo con la Organización Mundial de la Salud (OMS), la calidad de vida es un indicador que señala la percepción de los individuos respecto a su realidad, su

lugar en el contexto social y su sistema de valores, sus objetivos, sus expectativas, sus normas, criterios y preocupaciones. Todo lo previo se ve influido por cuestiones como la salud física, la salud mental, el grado de independencia, las relaciones sociales y el entorno que lo rodea (Cardona-Arias & Higueta-Gutiérrez, 2014). Al tener relación con los factores anteriormente mencionados, las AVU ejercen un papel importante en la mejora de la calidad de vida de los ciudadanos, siendo el grado de sus beneficios proporcional a su calidad, cantidad y accesibilidad (Tyrväinen, Mäkinen, & Schipperijn, 2007). En una interrelación entre las variables de calidad de vida de marginación, densidad, disponibilidad de área verde por asentamiento, y, el verdor de los árboles de AVU medido por el índice NDVI, Blancarte Siqueiros (2016) encontró que la superficie vegetal de las AVU proporcionaba una mayor percepción de calidad de vida en la población.

1.2.3 Beneficios económicos

Más allá de los aportes que brindan al medio ambiente y las prestaciones que ofrecen a la sociedad, las AVU interactúan dentro del sector económico al permitir disminuir gastos en diversos sectores, como el energético y el de la salud pública. En el primer caso, la presencia de AVU genera un efecto de isla fresca o microclima fresco que ayuda en la reducción de la energía necesaria para la generación de ambientes termostáticamente agradables en las temporadas más calurosas del año. Lo anterior se cuantificó en el trabajo de Kong et al. (2016), en el que midieron los ahorros energéticos a partir una modelación que contemplaba la ausencia y presencia de AVU fragmentadas de pequeña escala. Demostraron que las AVU afectan positivamente a los microclimas y mitigan altas temperaturas del aire, mostrando un desempeño de frescura de la vegetación estimado en un ahorro equivalente a la energía que consumen 356 aires acondicionados presentes en las aulas del Campus Gulou de la Universidad de Nanjing, China, equivalente a 1.3×10^4 kW h de energía. Por otra parte, en el sector de la salud pública, los beneficios de las AVU se asocian con la captura de partículas contaminantes, donde se evalúan las reducciones monetarias analizando los costos de la mitigación de dichos contaminantes, así como la atención médica necesaria para contrarrestar sus efectos en la población (Song et al., 2018).

Las AVU también tienen influencia en la plusvalía de hogares y apartamentos cercanos a ellas. De acuerdo con el estudio hedónico realizado por Liebelt, Bartke, & Schwarz (2018), diferentes características como la proximidad, las dimensiones y la forma de las AVU cercanas a las viviendas causan un impacto en el precio de las propiedades.

Otro factor menos común pero que se contempla en el aprovechamiento de las AVU es la obtención de productos no maderables, alimenticios o de ornato, como frutos y follaje, que pueden ser usados como alimentos u ornamento (Kabisch, 2015). Como señalan Tan & Neo (2009), dichas prácticas impulsan el manejo colectivo llevado a cabo por la ciudadanía mediante la realización de actividades de jardinería.

1.3 Problemas

En la búsqueda de condiciones que permitan la prosperidad del ser humano, nuestra especie ha realizado serias modificaciones ambientales con repercusiones en una gran cantidad de ecosistemas a escala global (Western, 2001). La contaminación causada por las actividades antropogénicas ha perturbado la dinámica natural de la atmósfera, el ciclo del agua, los suelos y el ciclo biogeoquímico (Chen et al., 2013).

1.3.1 Incremento poblacional

La constante ventaja entre la tasa de natalidad sobre la tasa de mortalidad debido a los avances científicos y tecnológicos que ayudan a incrementar la esperanza de vida ha producido el incremento poblacional que se mantiene a la fecha (Lee, 2011), y, que se estima continuará hasta llegar a una cifra de 9.2 mil millones de habitantes para el año 2050 (Bongaarts, 2009), siendo la capacidad de carga del planeta la principal limitante. Importantes consecuencias de dicho crecimiento son las repercusiones que ocasionan al medio ambiente (Ehrlich & Holdren, 1971).

Como se muestra en la Figura 1, en México ha ocurrido un constante crecimiento poblacional a partir del año 1921, en el que la mayoría de los habitantes se han concentrado principalmente en ciudades, áreas que se caracterizan por contar con

un número de población mayor que los 2,500 habitantes. A su vez, las ciudades, en conjunto con municipios periféricos que mantienen estrecha relación socioeconómica, han formado Zonas Metropolitanas (ZM) que se incorporan al ver rebasados sus límites territoriales (SEDESOL, CONAPO, & INEGI, 2012). Como resultado de la búsqueda de mejores oportunidades laborales, educacionales y un incremento en la calidad de vida, la población de las áreas urbanas ha presentado un acelerado crecimiento en los últimos setenta años (Brakarz, Greene, & Rojas, 2002). Dentro de las de ZM de mayor tamaño y crecimiento poblacional se encuentra la Zona Metropolitana de Monterrey, ZMM (Aguilar-Benitez & Montforte, 2018). Los retos principales que se presentan para el adecuado desarrollo de esta zona incluyen el excesivo crecimiento poblacional que conlleva a una expansión desordenada no planificada, la desigualdad socioeconómica, problemas asociados con el transporte colectivo y privado, y, la degradación del ambiente (Consejo de Nuevo León, 2019).

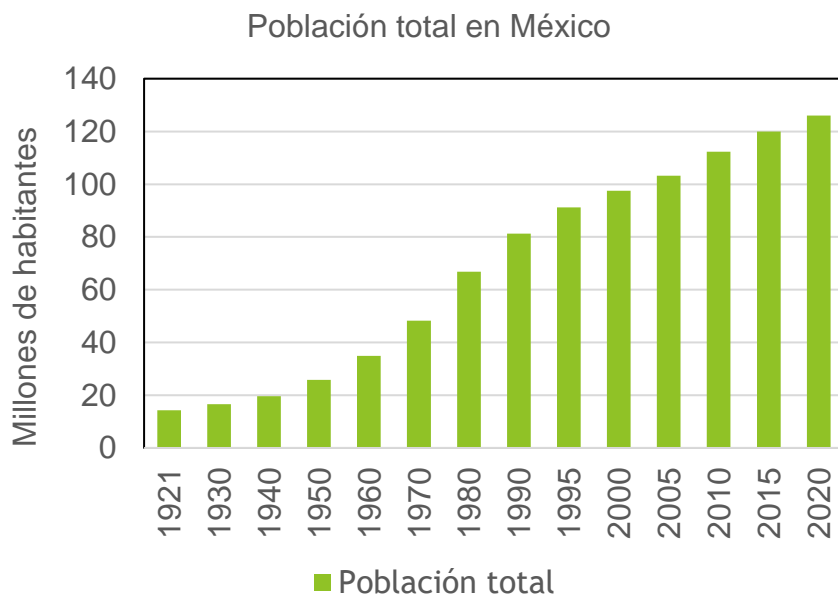


Figura 1. Incremento poblacional en México generado desde comienzos del siglo XX al año 2020 (Fuente: INEGI, 2020).

1.3.2 Migración y transición rural-urbana

En México, como en gran parte del resto del mundo, la mayoría de los habitantes reside en las ciudades, habiendo llegado en su mayoría en busca de mejores

oportunidades de desarrollo que permitieran mejorar su calidad de vida. La demanda de un mayor espacio de alojamiento para el sustento de la población en las ciudades ha ocasionado que se presente un desarrollo desordenado no planificado que ha acrecentado problemas presentes en las urbes que resultan perjudiciales para el medio ambiente y para la sociedad (Viana, Oliveira, Oliveira, & Rocha, 2019).

La población mundial que habitaba espacios urbanos sobrepasó por primera vez a la población rural en el año 2015, con un porcentaje del 51% (Zlotnik, 2017). Para México, se ha mantenido un cambio gradual entre la proporción de las poblaciones rural y urbana (Figura 2) que en suma de sus ZM, ascienden a un total de 63.8 millones de personas al año 2010 (Torres García & Ochoa Adame, 2017). Si bien no ocurre así en el nivel global o de grandes regiones. En el nivel de países, el crecimiento poblacional también se ve asociado con procesos migratorios (Bongaarts, 2009). La transición entre el entorno rural y el urbano representa un tipo de migración que en ocasiones genera pobreza e inequidad, al ofrecerles a las personas que provienen de los campos oportunidades pobres de educación y condiciones de marginación, como ocurre en ciudades de África y Asia, en las que, de acuerdo con Østby (2016) resulta en mayores cifras de los niveles de violencia urbanos.

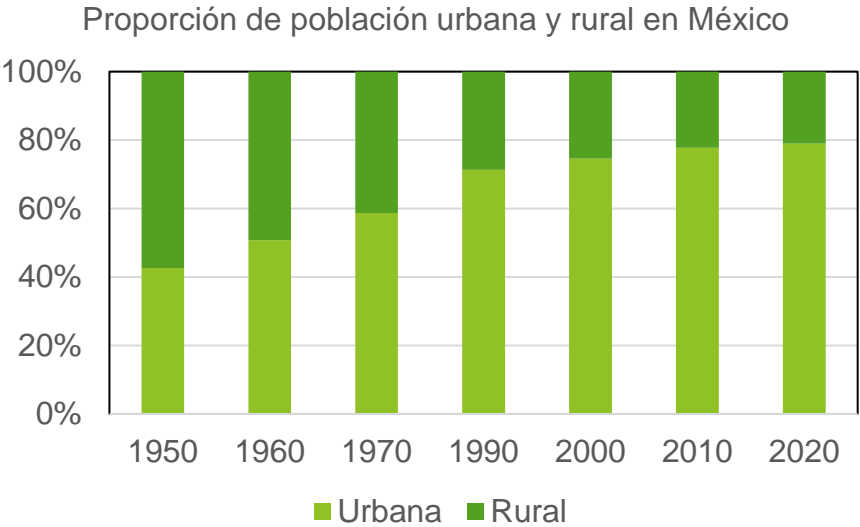


Figura 2. Transición entre población urbana y rural de México entre los años 1950 y 2020 (Fuente: INEGI, 2020).

En relación con el medio ambiente, Defries, Rudel, Uriarte, & Hansen, (2010) realizaron un estudio en el que vieron la respuesta de la pérdida de cobertura forestal con respecto al crecimiento urbano y rural. En el primer caso obtuvieron una correlación positiva entre ambas variables, mientras que para el aspecto rural no encontraron asociación alguna, demostrando que eran mayores los problemas que se generan por el desmonte realizado para la dedicación de áreas habitacionales o industriales.

Sin embargo, en un reciente estudio realizado en China para analizar los cambios en la actividad de las AVU presentes en ZU con desarrollo intensivo, D. Zhou, Zhao, Liu, & Zhang (2014) determinaron que, a través de las condiciones ambientales que propician las áreas urbanas, aunado a un buen manejo y mantenimiento de estos sitios, se pueden generar efectos positivos en las condiciones de las AVU presentes en la zona.

1.3.3 Cambios de uso de suelo

Como resultado de las necesidades de la gran cantidad de población humana se han ido vislumbrando los efectos negativos que se generan en el entorno. Entre ellos se cuentan la tala de vegetación para cobertura de necesidades habitacionales y alimenticias, como en el caso del establecimiento de campos agrícolas; y, la contaminación de agua, aire y suelo que se genera mediante la extracción de recursos naturales y producción de bienes a través de la industria (Cropper & Griffiths, 1994). De acuerdo con el tipo de cambios que ocurren, se puede ver afectado el balance de los ecosistemas, perjudicando a la biodiversidad, produciendo gases contaminantes, ocasionando desequilibrios hidrológicos, impactando a los suelos, y propiciando cambios en el clima en niveles locales, entre otros (Meyer & Turner, 1992).

Como ejemplo de pérdida de biodiversidad, McKee, Sciulli, David Foose, & Waite, (2004) modelaron la relación entre la densidad poblacional de 114 países y el número de especies de mamíferos y aves amenazadas, encontrando una relación positiva a lo largo del tiempo. Por parte de las AVU, el expansivo crecimiento de las grandes ciudades y en mayor escala de las ZM ha repercutido mediante el cambio

de uso de suelo, afectándolas a través del déficit y desigualdad en su distribución geográfica (Hegetschweiler et al., 2017). En el nivel local, Casillas, Ledezma, & Aparicio, (2018) analizaron los cambios ocurridos en las AVU y espacios abiertos de la ZMM desde el siglo XVII hasta principios del XXI; encontrando que la expansión urbana ha provocado el déficit de espacios verdes en proporción a la densidad poblacional de la región (Figura 3) y como consecuencia de ello se han perdido servicios ecosistémicos de las AVU que ayudan a aminorar la alta actividad industrial desarrollada en la zona durante el siglo XX, así como el continuo uso del automóvil como medio de transporte.

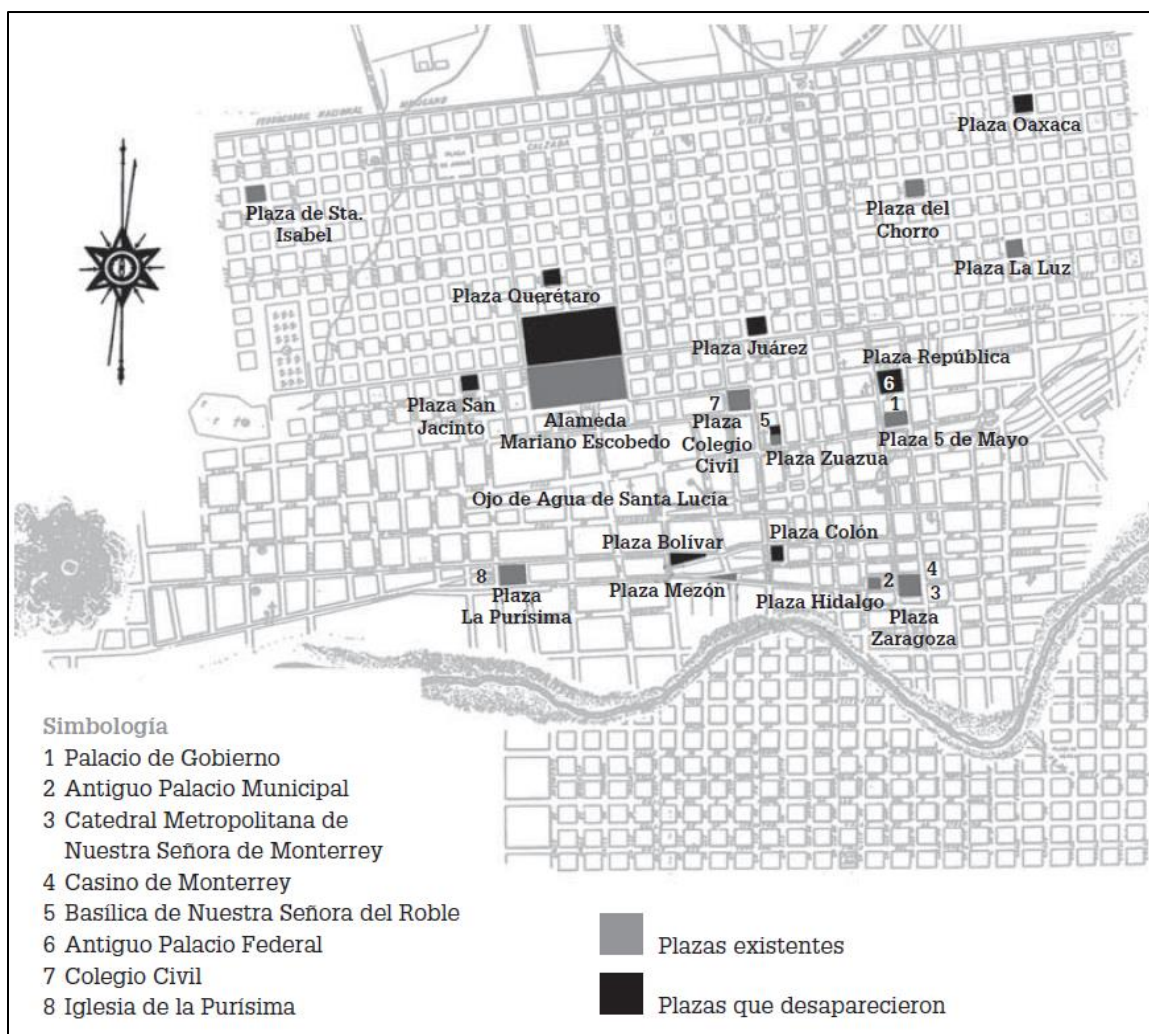


Figura 3. Primer cuadro de la ciudad de Monterrey. Se muestra el déficit de AVU (plazas) que ha generado la expansión urbana de la ciudad (Fuente: Casillas et al., 2018).

1.4 Gestión de AVU

Debido a los problemas anteriormente mencionados, las AVU corren el riesgo de verse degradadas a causa de una falta de monitoreo; por ello, es evidente la necesidad de contar con sistemas que permitan acceder a información de utilidad para la gestión de dichos espacios (Feltynowski et al., 2018). Mediante la recopilación, interpretación y el análisis de los datos de AVU por parte de expertos en el área, es posible hacerles llegar herramientas adecuadas a las autoridades involucradas en su gestión, para que cuenten con los elementos necesarios para una correcta toma de decisiones respecto a su cuidado y conservación, y, para que se logren integrar las AVU en la planeación urbana.

1.4.1 Inventario de AVU

El objetivo de los inventarios es generar información actualizada sobre su situación, sus dimensiones, y su proporción con respecto a la población y distribución espacial. Es posible estudiar el aporte de las AVU al bienestar de la población y al ambiente a través de monitoreos que permiten conocer su interacción con el entorno urbano a través del tiempo y determinar el estado del componente vegetal (Östberg, Wiström, & Randrup, 2018). Inventariar las AVU ayuda a proporcionar pautas para el desarrollo de estrategias de gestión adecuadas.

La Organización de las Naciones Unidas, a través del objetivo de desarrollo sostenible 11.7.1 presente en su agenda, reconoce la necesidad de la mejora y generación de información geoespacial que se encuentra a la disposición de los ciudadanos, con la finalidad de crear ciudades sostenibles más inclusivas, seguras y resilientes (Klopp & Petretta, 2017). De tal forma que se pueda proporcionar acceso universal a zonas verdes y espacios públicos seguros y accesibles, particularmente para mujeres, niños, adultos mayores y personas con discapacidad. La generación de inventarios de AVU, así como de otros servicios afines ayuda en el cumplimiento del objetivo que consiste en la cuantificación del porcentaje medio de espacios verdes y públicos en las ciudades.

1.4.2 Casos de estudio

En la república mexicana se han realizado estudios como el llevado a cabo en la Ciudad de México (CDMX) por Checa-Artasu, (2016), en el que analizó la influencia de las AVU a través de la medición y análisis de tres parámetros, que fueron 1) las ganancias o pérdidas de área a través del tiempo, así como 2) su relación en proporción a la cantidad de habitantes, y 3) las denuncias generadas por su destrucción. Tomando como base la información del inventario de AVU que se realizó para la CDMX, se determinó una creciente reducción de la superficie de AVU que generó una segregación entre delegaciones con mayor y menor cantidad, y, exacerbó la falta de AVU en relación con la densidad poblacional. Lo anterior, vinculado con procesos de construcción urbana. Además, se relacionaron mayores tasas de denuncia en delegaciones con mayor nivel socioeconómico, reflejando un desinterés por parte de los estratos más bajos.

Para la ZMM (Tabla 2), de acuerdo con la información reportada por Alanis et al (2004), el municipio de San Pedro Garza García presentó una alta proporción de AVU por habitante debido principalmente a las favorables condiciones climáticas y edafológicas que genera la orografía de la zona, y, a su adecuada planificación y seguimiento a partir de la segunda mitad del siglo XX. En contraste, municipios como Monterrey, Apodaca u otros, municipios que presentan una amplia expansión urbana por su actividad industrial, cuentan con una gran deficiencia de AVU. El estudio exhiben una baja proporción de AVU por habitante, la cual se encuentra por debajo del valor mínimo recomendado por la OMS para ZU, donde se recomienda contar con un intervalo de entre 9 y 15 m² por habitante (Kuchelmeister, 1998). En su investigación, Alanis et al (2004) sugieren priorizar un plan de arborización metropolitano que contemple ríos y arroyos, parques públicos, parques deportivos, parques industriales, camellones, banquetas, centros comerciales y educativos, y, que se considere su protección, regulación y sustentabilidad en innovaciones estructurales y de ordenamiento territorial. Como parte de dicha estrategia se menciona la inclusión de especies nativas, adecuados sitios de plantación y fomento de su cuidado.

Con el fin de brindar información a las administraciones de los municipios de la ZMM sobre las condiciones de sus AVU, Yépez et al., (2018, 2020) han desarrollado reportes técnicos para la actualización de las bases de datos cartográficos de AVU. A la fecha, los estudios se han llevado a cabo en Escobedo y San Nicolás de los Garza, con la meta de replicar el análisis en el resto de los municipios de la ZMM. La generación de la información geoespacial permite contar con un sustento metodológico para el cálculo de AVU por habitante en metros cuadrados (Tabla 2) y el análisis de las condiciones actuales de la vegetación e infraestructura de las AVU. Ambos parámetros, en conjunto con la base de datos, son de relevancia para las administraciones, ya que les permite contar con herramientas para la toma de decisiones sobre la conservación y el manejo de sus AVU.

Tabla 2. Proporción de AVU presentes en 9 municipios de la ZMM, Nuevo León, México al año 2004. Entre paréntesis se muestran las cifras actualizadas para los municipios de Escobedo en 2018 y San Nicolás de los Garza en 2020 (Fuente: Alanis et al., 2004; Yépez et al., 2018, 2020)

Municipio	Superficie (Ha)	AVU (Ha)	m ² AVU por habitante
García	91,380	-	5.26
Escobedo	19,100	50	2.16 (9.33)
San Nicolás de los Garza	8,680	188	3.22 (8.19)
Apodaca	22,978	47	1.67
Guadalupe	12,193	222	3.31
Santa Catarina	98,000	54	2.39
San Pedro Garza García	8,680	323	15.58
Monterrey	33,866	513	4.60
Juárez	22,780	-	1.24
ZMM		Promedio	3.91

Situaciones similares se presentan en urbes de diferentes latitudes a lo largo del continente americano, dentro de las cuales se cuenta la ciudad de Nueva York, que presenta 7.07 m² de AVU por habitante, la CDMX y Santiago de Chile con 5.3 m² y 3.2 m², respectivamente (Flores-Xolocotzi & González-Guillén, 2010).

CAPÍTULO 2. PERCEPCIÓN REMOTA

Para dar seguimiento a la información recolectada, los inventarios de AVU deben ser actualizados periódicamente, lo cual conlleva un elevado costo económico (Konijnendijk, Nilsson, Randrup, & Schipperijn, 2005). En busca de la disminución de los costos y el tiempo de obtención de la información para su utilidad en la toma de decisiones, productos de sensores remotos y su integración en SIG han sido empleados para la caracterización del suelo, dentro del cual se incluye el mapeo y la clasificación de la cobertura vegetal (Rafiee, Salman Mahiny, & Khorasani, 2009).

Mediante el proceso de la PR, se puede obtener información de objetos presentes en la superficie terrestre, a través de sensores que se encuentran a distancia, acoplados a aeronaves, vehículos aéreos no tripulados (VANT) y satélites (Horning, 2018). El uso de este tipo de tecnología, en conjunto con los SIG, permite disminuir los recursos empleados para la planificación, evaluación y actualización de inventarios de AVU (Giezen et al., 2018; Meerow & Newell, 2017). Ejemplo de ello es el trabajo de Huerta-García, Ramírez-Serrato, Yépez-Rincón, & Lozano-García, (2018), en el que, mediante sensores remotos, se redujo hasta en un 80 % el tiempo invertido en la obtención de datos de inventario forestal para un bosque urbano, con respecto al método tradicional. Además, al contemplar los diferentes niveles de resoluciones que ofrecen los sensores remotos, es posible visualizar fácilmente desequilibrios existentes en la distribución y las condiciones de las AVU (Kothencz, Kiss, & Petutschnig, 2017). La aplicación de la PR y SIG en AVU se observa en trabajos como el de Comber, Brunsdon, & Green, (2008), quienes realizaron un estudio en el que implementaron el uso de SIG basado en una red de análisis geoespacial en conjunto con análisis estadístico de datos socioeconómicos, para analizar la equidad de acceso a AVU para diferentes extractos de la sociedad, ofreciendo un método para la cuantificación de las diferencias en la provisión de bienes socioambientales a la comunidad. Por su parte, Kong & Nakagoshi, (2006) desarrollaron un método para la cuantificación y captura de cambios espaciotemporales de su cobertura. Kopecká, Szatmári, & Rosina, (2017) realizaron un levantamiento de superficie con productos de alta resolución. Ruiz-Luna, et al.

(2019) elaboraron una clasificación de AVU. Aguilera, et al. (2019) analizaron la diversidad de sus especies vegetales, mediante imágenes satelitales.

Dentro del ambiente SIG existe la posibilidad de trabajar con capas de información previamente generadas (Feltynowski et al., 2018). Sin embargo, para una gestión eficiente del AVU es crítica la necesidad de actualizar los cambios ocurridos a través del tiempo en el terreno, ya que constantemente se está llevando a cabo la expansión urbana. Lo anterior permite, además, dar seguimiento a las condiciones en que se encuentran las AVU y observar los efectos de las medidas que se hayan tomado por parte de los gestores (Keeley & Benton-Short, 2018).

2.1 Tipos de resolución

Dependiendo del tipo de información que se extrae a partir de los sensores remotos, es posible obtener diversos niveles de información o resoluciones que permiten generar análisis de los objetos bajo estudio, con mayor o menor detalle. Los niveles de resolución de la información son el espacial, el espectral, el temporal y el radiométrico.

2.1.1 Resolución espacial

Como se ejemplifica en la Figura 4, donde se muestra la misma imagen satelital a diferente escala conforme a su resolución espacial, esta resolución representa la cantidad de área que cubre cada píxel dentro de una imagen. Conforme disminuye el valor de este parámetro se cuenta con información más fina, que abarca mayor detalle de un área, permitiendo realizar análisis más precisos a diferencia del uso de información de tamaño de píxel más grueso.

Es posible observar grandes diferencias en la resolución espacial de productos procedentes de diferentes sensores. Ejemplo de lo anterior son las diferencias del tamaño de píxel de imágenes satelitales de muy alta resolución, imágenes aéreas, e imágenes con ultra-alta resolución, obtenidas a partir de VANT (Khaliq et al., 2019). En la Tabla 3 se enlistan ejemplos de trabajos de AVU donde se emplearon diversas escalas de resolución espacial.

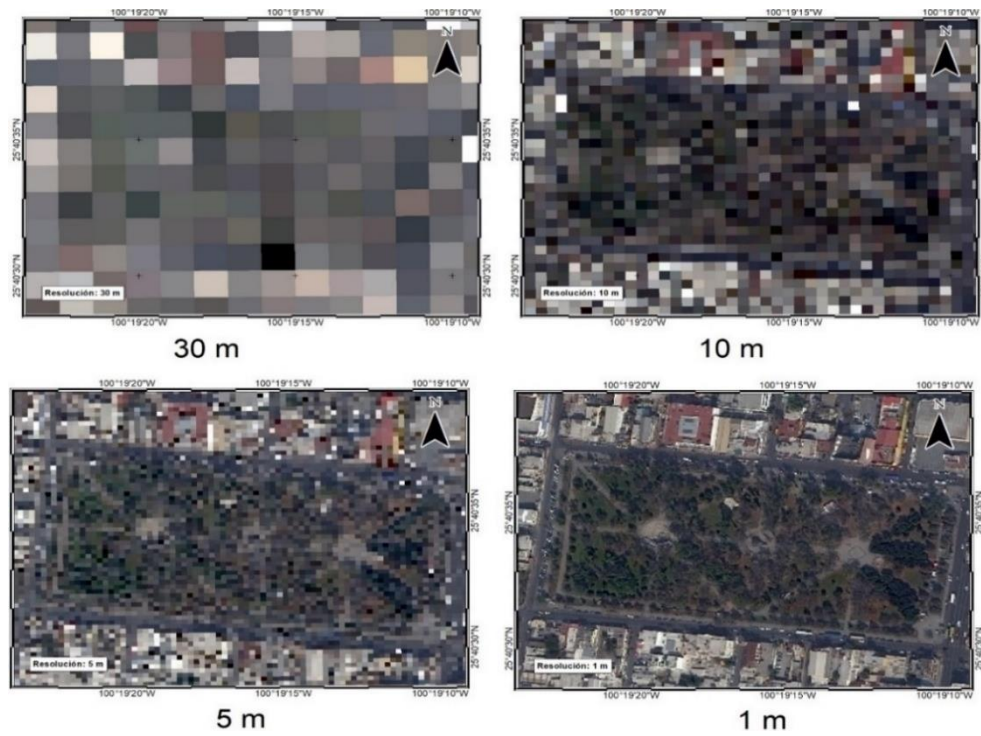


Figura 4. Ejemplo de ortomosaico a diversas escalas de resolución espacial (Elaboración propia).

Tabla 3. Ejemplos de empleos de distintas resoluciones espaciales en artículos de AVU (Elaboración propia).

Sensor	Tamaño del píxel	Escala	Tipo de datos	Trabajos en AVU a esa resolución
Landsat	30 m	1:50,000	Superficie de AVU	Alanís et al. (2004)
MODIS	250, 500 y 1000 m	1:50,000	Índice urbano	Liu et al. (2017)
Sentinel-2A	10 m	1:50,000	Superficie de AVU	Kopecká, Szatmári, & Rosina (2017)

2.1.2 Resolución espectral

Las ondas del espectro electromagnético permiten determinar el tipo de resolución espectral que se presenta en una imagen. Lo anterior es de excepcional utilidad en el campo de los sensores remotos, ya que permiten caracterizar los objetos a través de firmas obtenidas según su respuesta espectral (Figura 5). Además, la información espectral proporciona una variada gama de dimensiones o capas de información (Figura 6) que permiten la elaboración de diversos tipos de análisis. Ejemplo de ello es la generación de clasificación de imágenes para obtener la información de la vegetación mediante la banda del infrarrojo cercano (IRC). A través de las clasificaciones se identifica una determinada cantidad de elementos presentes dentro de una escena, partiendo del uso de algoritmos que determinen la separabilidad de las clases conforme a los valores de cada píxel (agregados), con el fin de generar mapas temáticos que proporcionen información puntual de alguna característica bajo estudio (Hasmadi, Pakhriazad, & Shahrin, 2009). En la Tabla 4 se enlistan ejemplos de trabajos de AVU donde se emplearon diversas escalas de resolución espectral.

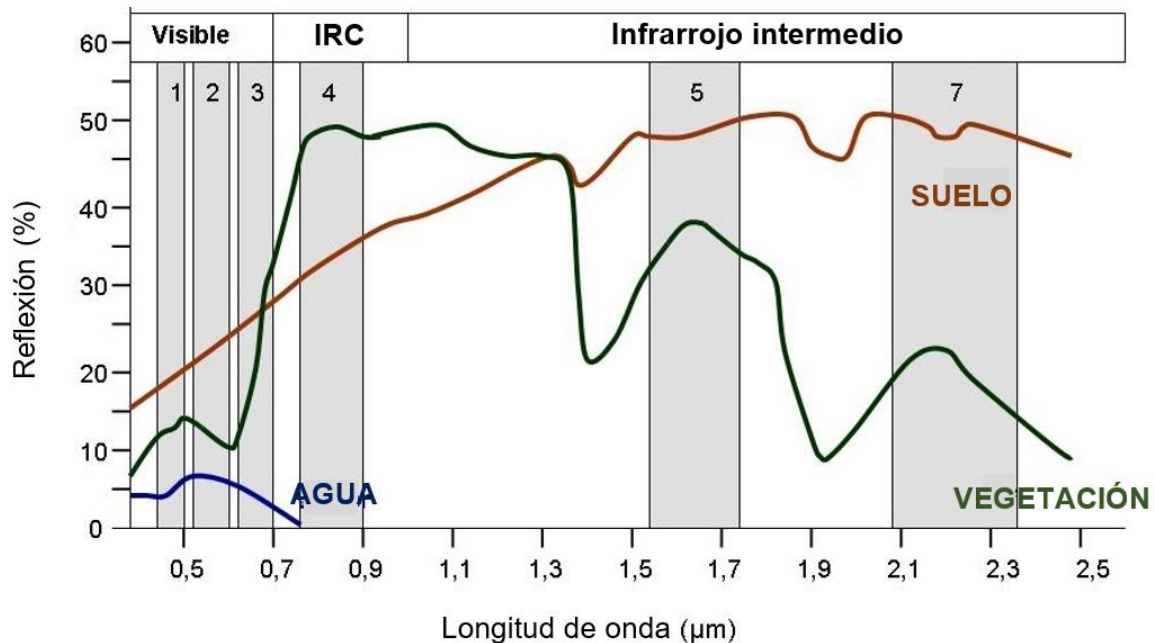


Figura 5. Firmas espectrales de diversos elementos característicos presentes en la superficie terrestre. Las franjas numeradas representan las bandas espectrales de imágenes LANDSAT 7 (Fuente: Siegmund & Menz, 2005).




Figura 6. Ejemplo de ortomosaicos de dos capas espectrales diferentes sobre un AVU. 1) Del lado izquierdo, capa de información del espectro visible (RGB), 2) del lado derecho, capa de infrarrojo cercano (Elaboración propia).

Tabla 4. Ejemplos de productos de sensores remotos de distintas resoluciones espectrales empleados en artículos de AVU (Elaboración propia).

Sensor	Bandas	Escala	Tipo de datos	Trabajos en AVU a esa resolución
SPOT	5 (pancromática, RGB, IRC)	1:50,000	Clasificación de AVU	Ruiz-Luna, et al. (2019)
Sentinel 1A Sentinel 2A	12 (azul costero, RGB, 4 rojo borde, IRC, azul vapor, 3 SWIR)	1:75,000	Mapeo de servicios ecosistémicos	Haas & Ban, (2017)
WorldView-2	8 (azul costero, RGB, amarillo, rojo borde, 2 IRC)	1:1,000	Clasificación de AVU	Santos, Tenedório, & Gonçalves, (2016)

2.1.3 Resolución temporal

La magnitud física del tiempo ayuda a determinar cambios ocurridos en una misma zona. Lo anterior proporciona información valiosa en escenarios como el medio ambiente, donde suelen ocurrir modificaciones generadas a raíz de cambios estacionales o modificaciones del entorno, como las generadas por la expansión de la mancha urbana (Figura 7). En la Tabla 5 se enlistan ejemplos de trabajos de AVU donde se emplearon diversas escalas de resolución temporal.




Figura 7. Ejemplo de ortomosaicos de la Alameda de Monterrey obtenidos para dos fechas diferentes (Elaboración propia).

Tabla 5. Ejemplos de empleos de distintas resoluciones temporales en artículos de AVU (Elaboración propia).

Sensor	Fechas	Escala	Tipo de datos	Trabajos en AVU a esa resolución
Imágenes satelitales de Google	2003 – 2008	1:50,000	Diversidad de especies en AVU	Aguilera, et al. (2019)
Landsat 5, 7 y 8	2000 – 2014	1:100,000	Tendencia de verdor de AVU	Z. Zhu et al. (2016)
Landsat	1984, 1995, 2001, 2011	1:50,000	Cambio de uso de suelo	Santos, Tenedório, & Gonçalves, (2016)

2.1.4 Resolución radiométrica

Los sensores remotos cuentan con cierta sensibilidad a la intensidad de la radiación electromagnética reflejada. Tal respuesta se cuantifica a través de la resolución radiométrica y sus unidades se presentan en la unidad llamada bit. A mayor cantidad de bits se puede obtener una mayor profundidad en la gama de intensidades de respuesta dentro de una imagen. Como ejemplo, en un producto de 8 bits cada píxel puede presentar valores que fluctúan en el intervalo de 0 a 255, mientras que un ráster de 16 bits tiene una intensidad de grises de 0 hasta 65,536.

2.2 Índices de vegetación

Gracias a la respuesta espectral de la vegetación, generada por sus características químicas y morfológicas, mediante la aplicación de algoritmos que emplean diferentes capas espectrales de productos de sensores remotos, es posible generar índices de vegetación que permiten realizar evaluaciones de diversos aspectos relacionados con la cobertura vegetal, como lo son el vigor y las dinámicas de crecimiento (Xue & Su, 2017). Algunos de los principales algoritmos para determinar el estado de la vegetación se describen a continuación.

2.2.1 NDVI

El NDVI es un algoritmo que permite la estimación del vigor o salud de la vegetación, gracias a que la clorofila absorbe la luz visible y refleja la luz infrarroja (Bannari, Morin, Bonn, & Huete, 1995; Schmid et al., 2017; Gillespie et al., 2018). A través del contraste de las bandas roja e infrarroja cercana del espectro electromagnético (Figura 8) que se calcula con la siguiente fórmula:

$$NDVI = \frac{Banda\ IRC - Banda\ roja}{Banda\ IRC + Banda\ roja} \quad (\text{Ecuación 1})$$

Este índice se emplea en el nivel global para el monitoreo de sequías, producción agrícola, predicción de incendios y el mapeo de procesos de desertificación, ya que compensa cambios de condiciones de iluminación, pendientes, aspectos y diversos factores.




Figura 8. Visualización de bandas empleadas por el algoritmo NDVI (Fuente: Elaboración propia, modificado de indexdatabase.de, 2020).

2.2.2 EVI

El índice de vegetación mejorado (enhanced vegetation index, EVI, por sus siglas en inglés) es la alternativa más común al uso del índice NDVI. A través de este algoritmo se busca atender algunos problemas del NDVI, como la sensibilidad a efectos de brillo y color del suelo, la presencia de nubes, sombras de nubes y la irremediable presencia de sombras presentes en el follaje de la vegetación (Huete, Liu, Batchily, & Van Leeuwen, 1997; Nepita-Villanueva, Berlanga-Robles, Ruiz-Luna, & Morales Barcenas, 2019). La ecuación que permite su cálculo incluye la banda roja, infrarroja cercana y azul (Figura 9), y se muestra a continuación:

$$EVI = 2.5 \frac{Banda\ IRC - Banda\ roja}{(Banda\ IRC + Banda\ roja - 7.5\ Banda\ azul) + 1} \quad (\text{Ecuación 2})$$




Figura 9. Visualización de bandas empleadas por el algoritmo EVI (Fuente: Elaboración propia, modificado de indexdatabase.de, 2020).

Para solventar la ausencia de la banda azul en diversos sensores remotos y poder generar series temporales del índice EVI a mayor largo plazo. Jiang, Huete, Didan, & Miura, (2008) desarrollaron una versión alterna del algoritmo, EVI2, que arroja la mejor similitud con el algoritmo EVI que emplea 3 bandas, particularmente cuando las imágenes presentan buena calidad y los efectos atmosféricos no son relevantes. Su uso ha demostrado buenos resultados con una variedad de superficies, entre las

que se cuenta la vegetación (Q. Zhang et al., 2020). La fórmula de dicho algoritmo emplea únicamente el canal rojo e infrarrojo cercano (Figura 10) y su ecuación es la siguiente:

$$EVI2 = 2.5 \frac{Banda\ IRC - Banda\ roja}{Banda\ IRC + 2.4\ Banda\ roja + 1} \quad (\text{Ecuación 3})$$




Figura 10. Visualización de bandas empleadas por el algoritmo EVI2 (Fuente: Elaboración propia, modificado de indexdatabase.de, 2020).

2.2.3 NDWI

El índice diferencial de agua normalizado (normalized difference water index, NDWI, por sus siglas en inglés) con el contenido de agua en la vegetación y se usa en análisis de agricultura de precisión, monitoreo de salud forestal (Piragnolo, Lusiani, & Pirotti, 2018). Para su cálculo se emplean las bandas verde e IRC, con el fin de maximizar la reflectancia de la vegetación y reducir la reflectancia de cuerpos de agua (Figura 11). Se calcula a través de la siguiente fórmula:

$$NDWI = \frac{Banda\ verde - Banda\ IRC}{Banda\ verde + Banda\ IRC} \quad (\text{Ecuación 4})$$




Figura 11. Visualización de bandas empleadas por el algoritmo NDWI (Fuente: Elaboración propia, modificado de indexdatabase.de, 2020).

CAPÍTULO 3. SEGMENTACIÓN SEMÁNTICA

En el campo de la visión computacional, la segmentación semántica es un método que asigna cada píxel de una imagen a una clase específica (Noh, Hong, & Han, 2015). Con lo anterior se genera una imagen donde se puede distinguir uno o más elementos, etiquetados de acuerdo con su clase correspondiente. La segmentación semántica es de utilidad en una amplia variedad de aplicaciones que van desde el análisis de información en tiempo real para el manejo autónomo de vehículos (Trembl et al., 2016), la contextualización ambiental en robótica (Milioto, Lottes, & Stachniss, 2018), la edición de imágenes (Arnab & Torr, 2017), hasta su empleo en medicina para el manejo asistido de instrumentos quirúrgicos en cirugías (Shvets, Rakhlin, Kalinin, & Iglovikov, 2019). En el campo de los sensores remotos, la segmentación semántica cumple la función de detectar características y etiquetar cada píxel de una imagen a una clase específica de acuerdo con la información y resolución que presentan (Marmanis et al., 2016). De este modo, sustituye la identificación a través de fotointerpretación, la cual depende en gran medida del analista.

3.1 Método manual

Técnicas como la fotointerpretación permiten realizar clasificaciones visuales a través de la identificación de objetos en las imágenes y en ocasiones mediante un limitado reconocimiento en el campo, para la delimitación de elementos de interés (Rutchev & Vilchek, 1999). Para obtener buenos resultados a través de este tipo de métodos es necesario contar con una amplia experiencia en la identificación de los elementos presentes en las imágenes a clasificar. Sin embargo, el juicio del analista generalmente puede llevar a cometer errores al momento de realizar la clasificación. A la fecha se ha desarrollado una gran cantidad de métodos que permiten la automatización de la detección de características en imágenes, y, por lo tanto, es poco común encontrar datos generados a partir del método manual. Un ejemplo del uso del método manual, a escala nacional, es la digitalización de AVU para el Marco Geoestadístico Nacional (MGN), el cual se realizó siguiendo los métodos descritos en el Manual del técnico digitalizador (INEGI, 2019). En la Figura 12 se muestra un

esquema que resume las fases que lleva a cabo el INEGI para la generación de polígonos digitales a partir de imágenes satelitales de alta resolución.

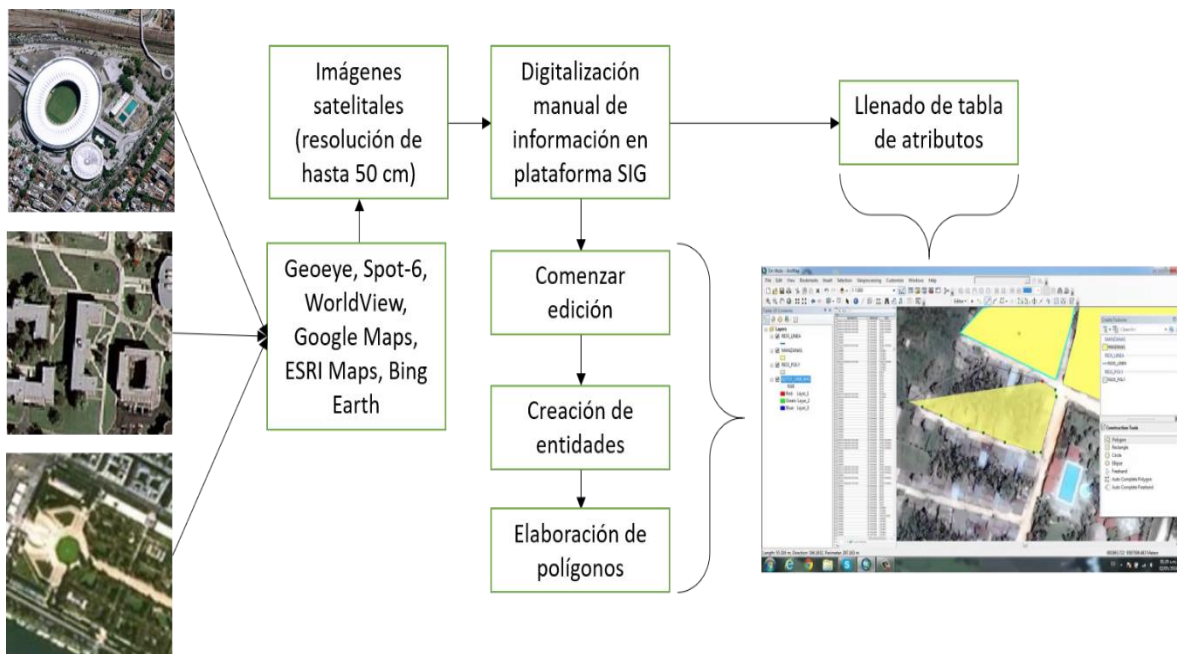


Figura 12. Proceso de digitalización manual de polígonos para llenado de AVU de Marco Geoestadístico Nacional (INEGI, 2019).

3.2 Métodos automáticos

La automatización de procesos de segmentación semántica mediante aprendizaje automático se ha desarrollado partiendo de los principios de la inteligencia artificial, a través de la percepción de patrones en imágenes mediante algoritmos para realizar la segmentación con máxima probabilidad de éxito (Amari, 2016).

El aprendizaje profundo va más allá del aprendizaje automático, puesto que éste se basa en la experiencia y la mejora de su desempeño, mediante el uso de una gran cantidad de muestras que sirven como base de entrenamiento para la detección de patrones (Bini, 2018).

3.2.1 Aprendizaje automático

Dentro de los tipos de algoritmos convencionales más utilizados para la clasificación de imágenes se encuentran los correspondientes al aprendizaje supervisado (Kotsiantis, Zaharakis, & Pintelas, 2007), no supervisado (Ghahramani, 2004), semi-

supervisado (Chapelle, Sindhwani, & Keerthi, 2008), por refuerzo (Szepesvári, 2010) y el multitarea (Y. Zhang & Yang, 2018). En cuanto a técnicas de clasificación, se enlistan entre otras las máquinas de vectores de soporte (Cortes & Vapnik, 1995), como la empleada por Zylshal, Sulma, Yulianto, Nugroho, & Sofan, (2016) para la clasificación de AVU; el algoritmo genético (Maulik & Bandyopadhyay, 2000); los árboles de decisiones (Freund, Yoav, 1999); la clasificación de k-vecinos más próximos (Malik G., Dawn M., Michael N., & Rolston St., 2013); las redes bayesianas (Friedman, Geiger, & Goldszmidt, 1997) y las redes neuronales artificiales (Nitze, Schulthess, & Asche, 2012).

Como lo señala Zylshal et al., (2016), un problema recurrente en la clasificación de imágenes mediante la mayoría de algoritmos de aprendizaje automático, es la asociación del resultado con los valores del producto del sensor remoto empleado para su obtención. Esto limita la aplicación de las clasificaciones generadas a imágenes con alta similitud espacial y temporal. Si bien los algoritmos tradicionales de aprendizaje automático funcionan de manera adecuada con datos estructurados, en el caso contrario su desempeño decrece. Además, conforme incrementa la cantidad de datos su desempeño no mejora mucho, llegando incluso a estancarse pasado cierto punto de la modelación (Jundong Li & Liu, 2017).

3.2.2 Aprendizaje profundo

Redes neuronales artificiales

Al igual que en la interacción entre un ser humano y su medio, la recolección de información en los sistemas computacionales se debe llevar a cabo a través de estímulos externos o entradas que le permitan aprender gradualmente mediante funciones de activación que conectan diversas neuronas y logran generalizar la información recibida y llegan a generar una respuesta deseada (Figura 13) (Haykin & Simon, 1999; Nguyen, Prasad, Walker, & Walker, 2010). La idea de replicar dicho comportamiento en las máquinas desencadenó el desarrollo de redes neuronales artificiales (RNA), que, a través de la entrada de grandes cantidades de información, han sido capaces de reconocer patrones y aprender de los errores que se cometen, para finalmente determinar la salida con mayor probabilidad de éxito (Schmidhuber,

2014). El nombre con el que se les acuñan se debe a la similitud de procesamiento que realizan las neuronas dentro del cerebro humano. De esta forma, las ventajas que ofrecen las RNA sobre otros métodos de detección de patrones son la no linealidad, el mapeo de entradas y salidas, la adaptabilidad, la información contextual que ofrecen, su tolerancia a fallos, la posibilidad de su implementación a gran escala, su uniformidad de análisis y diseño, y, la posibilidad de mejorar su desempeño al implementar los avances que se den en el estudio del cerebro humano, gracias al campo de las neurociencias (Haykin & Simon, 1999).




Figura 13. Red neuronal profunda básica con capa de entrada, capa oculta y capa de salida. Las flechas representan las funciones de activación (Fuente: Zhu, 2014).

Los principales componentes de una RNA son la capa de entrada o los datos que van a servir como información para el entrenamiento de la red, la cada de salida, o los datos generados a través del entrenamiento y los pesos de la red, que son parámetros que se pueden entrenar y que llevan a cabo las transformaciones realizadas en la o las capas ocultas, para ajustarse a la salida deseada.

Redes neuronales profundas

Las redes neuronales profundas (RNP) tienen un mayor número de capas ocultas, en las que se busca obtener relaciones entre los datos. De esta forma, las primeras capas de la red desempeñan funciones simples, como la detección de características de bajo nivel, por ejemplo, la detección de bordes en una imagen; y, conforme la información llegue a puntos más profundos de la red, esas funciones simples se combinarían para formar funciones más complejas o de más alto nivel, como la detección de rostros (Saavedra-Alcoba, 2015) o tipos de AVU.

La propagación hacia adelante y hacia atrás (Jing Li, Cheng, Shi, & Huang, 2012) permite la actualización y el ajuste de los valores o pesos mediante la minimización de la función de pérdida para disminuir el error de predicción, conforme se llega al valor mínimo en el descenso de gradientes (Bottou, 1991). Lo anterior determina las respuestas de las neuronas y de este modo se lleva a cabo el aprendizaje automático.

Redes neuronales convolucionales

Las convoluciones presentadas en las RNC son filtros que tienen utilidad al trabajar con imágenes, gracias a su arreglo matricial. Dichos filtros permiten compactar la información al combinar los valores de los píxeles de entrada con el fin de generar los mapas de características de bajo, medio y alto nivel (Ruiz-del-Solar, Loncomilla, & Soto, 2018). La arquitectura típica de RNC (Figura 14) presenta una capa de entrada, capas ocultas de convoluciones submuestreo y conexiones completas, y, una capa de salida con la clasificación (Fuente: LeCun, Haffner, Bottou, & Bengio, 1999). De esta forma, el poder computacional necesario para la modelación se reduce significativamente. Lo anterior permite que el número de parámetros en las RNC se reduzca y se compacte la información con cada pasada que realiza el filtro sobre la imagen. El uso de capas convolucionales y de agrupación máxima permiten llegar a un punto del modelo en que es posible vectorizar la información a través del uso de un componente completamente conectado para que pueda clasificar los datos de entrada.




Figura 14. Arquitectura típica de RNC. Los valores mostrados representan las dimensiones de alto, ancho y profundidad de las imágenes (Fuente: LeCun, Haffner, Bottou, & Bengio, 1999).

El empleo de las redes neuronales para la resolución de problemas de clasificación de imágenes recobró su auge a partir de la competición ImageNet Large-Scale Visual Recognition Challenge, en la que Krizhevsky, Sutskever, & Hinton, (2012) desarrollaron una RNC de nombre AlexNet, la cual se destacó por contar con una mayor precisión frente a diversos métodos tradicionales de aprendizaje automático para la clasificación de 1.2 millones de imágenes de alta resolución, agrupadas en 1000 clases. Las tareas más comunes realizadas mediante este tipo de redes son la detección y la caracterización de objetos en una imagen (Garza-Castañón & Garza-Elizondo, 2017), la clasificación de escenas o imágenes (Vladimír, 2017) y la segmentación semántica de objetos de interés (Kampffmeyer, Salberg, & Jenssen, 2016). En el campo de la PR y los SIG, las RNC han sido empleadas para la detección de patrones en imágenes satelitales que permiten identificar elementos de interés variados, según el campo de estudio de aplicación. Demir et al., (2018) aplicaron el uso de RNC en el campo de la ingeniería civil para segmentar de forma binaria caminos, edificaciones y coberturas terrestres; por otra parte Xu, Wu, Xie, & Chen, (2018) realizaron la extracción de edificios a partir de imágenes satelitales de muy alta resolución. A su vez, Bai, Mas, & Koshimura, (2018) las emplearon para cuantificar el daño causado por desastres naturales en edificios. Otro ejemplo de la aplicación de RNC se da en el campo de la ecología, donde se usa para la detección de poblaciones de especies animales, como el caso de tortugas marinas (Gray et al., 2019), y vegetales, como en el estudio de López-Jiménez, Vasquez-Gomez, Sanchez-Acevedo, Herrera-Lozada, & Uriarte-Arcia, (2019), donde se trabajó con cactus columnares. En el área de la gestión urbana, Albert, Kaur, & González, (2017), emplearon las RNC para identificar los patrones que caracterizan a 20 clases de ambientes urbanos, incluyendo AVU, para 300 ciudades europeas mediante su análisis y comparación- En esta misma rama, Zhou, Liu, Oliva, & Torralba, (2014) dieron uso a un conjunto de imágenes georreferenciadas en el nivel de suelo para reconocer, a través de una RNC, la identidad de los diferentes elementos que componen las ciudades de forma que la información recabada sea de utilidad para la planeación urbana.

Redes completamente convolucionales

La idea principal detrás de este tipo de redes es la remoción del componente completamente conectado, con el que finalizan las RNC. En lugar de generar este vector, se realiza un mapeo píxel por píxel que realiza predicciones en las entradas y generen una segmentación (Shelhamer, Long, & Darrell, 2017) como la que se muestra en la Figura 15. De esta forma es posible determinar no sólo la clase a la que corresponde la imagen, sino que además permite la clasificación de cada píxel de la imagen. Un problema común en las redes completamente convolucionales (RCC) es la pérdida de resolución en el resultado, el cual se busca resolver mediante el muestreo ascendente (Badrinarayanan, Kendall, & Cipolla, 2017).

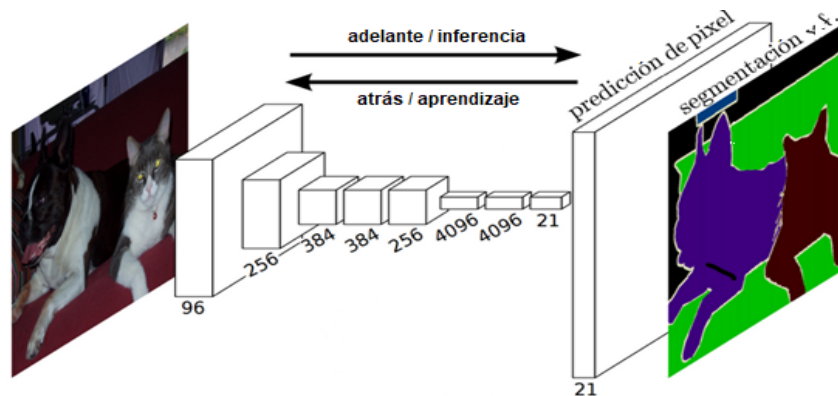


Figura 15. Arquitectura de red completamente convolucional sin componente completamente conectado. Los valores numéricos representan la cantidad de canales en cada capa (Fuente: Shelhamer et al., 2017).

U-net

El desarrollo de este tipo de redes surgió debido a la escasa cantidad de muestras de imágenes de entrenamiento que se producen en el área biomédica. Por ello Ronneberger, Fischer, & Brox, (2015) emplearon como fundamentación la arquitectura de las RCC que omiten capas completamente conectadas, con la diferencia que implementaron el aumento de datos para la generación de muestras adicionales y diseñaron la arquitectura a modo de un codificador – decodificador simétrico (Figura 16) que incluye convoluciones y operaciones que doblaban la cantidad de filtros y reducen la resolución de los mapas de activación en la sección de compresión. Aunado a lo anterior, en este modelo se incluyeron convoluciones

ascendentes que aumentan la resolución y reducen a la mitad la cantidad de filtros en la porción del descompresor. Aprovechando la simetría de la arquitectura, se transfiere información de los mapas de activación del codificador al decodificador en el proceso de la ampliación de la imagen. De este modo es posible obtener mapas de segmentación de similar tamaño que la imagen de entrada.




Figura 16. Arquitectura de U-Net con configuración de codificador – decodificador. Los valores numéricos representan el alto y ancho de cada capa, así como su número de canales (Fuente: Ronneberger et al., 2015).

Redes residuales

El aumento en el número de capas en una red neuronal lleva eventualmente a una serie de problemas como el desvanecimiento y la explosión de gradientes. Ambos efectos amplifican el error e impactan en la precisión de las predicciones del modelo debido a que los gradientes se vuelven más pequeños, afectando el desempeño de la red (Balduzzi et al., 2017). Las redes residuales o ResNets (He, Zhang, Ren, & Sun, 2016) son arquitecturas que lidian con estos problemas a través de la inclusión de pequeños bloques o conexiones residuales que contemplan saltos de conexión que añaden la salida de la capa previa (Figura 17). La adición de dichos saltos

permite el flujo de información entre las capas y evita los problemas de degradación previamente mencionados.




Figura 17. Bloque de construcción, componente principal de redes ResNet que integra la identidad de la salida del bloque anterior (Fuente: He, Zhang, Ren, & Sun, 2016).

CAPÍTULO 4. MODELACIÓN DE AVU

4.1 Conectividad

Las “redes verdes” han pasado a formar una parte fundamental del desarrollo sostenible (Mougiakou & Photis, 2014). Lo anterior debido a que estos elementos integran aspectos culturales y recreativos a la par que permiten la conservación y cuidado de la naturaleza en un entorno urbano.

Hepcan, (2013) define la conectividad de las AVU como la facilidad o dificultad con la que ocurre el flujo de energía, materiales, nutrientes y especies en el paisaje urbano, e indica que dentro de los principales factores que repercuten en la conectividad son el tamaño y la estructura de las AVU, debido a que influyen en la magnitud y dirección de los cambios que se producen en la misma.

Para la modelación de la distribución y cantidad de AVU en Kütahya, Turquía, a escala de vecindario, evaluando tasas de tamaño y AVU per cápita a través del uso de SIG, Cetin, (2015) empleó datos digitalizados del área, funciones ecológicas y buffers de determinación del dominio activo de las AVU que ayudaron para la propuesta de generación de corredores biológicos. Por otra parte, Guo, Saito, Yin, & Su, (2018), distinguieron corredores biológicos y parches vitales para el mantenimiento de la conectividad del paisaje, a través de la combinación de técnicas como el análisis de patrones espaciales morfológicos, la probabilidad de conectividad y el análisis de ruta de menor coste.

Diversos enfoques han sido empleados para el análisis de la conectividad de AVU, entre ellos destacan los trabajos de Hepcan, (2013) y Li, Chen, & He, (2015) por su uso de métricas del paisaje; Hofmann, Strobl, & Nazarkulova, (2011) y Gülçin & Akpınar, (2018), quienes emplearon métodos de análisis de imagen basado en objetos (object based image análisis, OBIA por sus siglas en inglés) y la investigación de Himan Shahabi, (2012) que empleó la combinación de las técnicas de PR de comparación de índices de vegetación, el análisis de componentes principales (principal component analysis, PCA por sus siglas en inglés) y la clasificación de imágenes satelitales.

4.2 Accesibilidad

El acceso a espacios que brinden los beneficios de la vegetación presente en las AVU, en conjunto con espacios e instalaciones para su goce y tránsito, es fundamental en las ciudades, ya que mejora las condiciones de vida de las personas. Takano, Nakamura, & Watanabe, (2002) enfatizan en la importancia de contar con AVU que sean accesibles a través de distancias caminables, lo anterior en especial para grupos poblacionales específicos como las personas mayores de edad, ya que la presencia de dichos espacios mejora la longevidad de los residentes independientemente de su estado socioeconómico.

Para la modelación de la accesibilidad a AVU, Texier, Schiel, & Caruso, (2018), utilizaron productos de sensores remotos para la obtención de parámetros que reflejaran la accesibilidad con la que cuenta la población de Bruselas, Bélgica, a las AVU de su estado. Consideraron el empleo de cuatro métricas que permitieron medir la porción de superficie dedicada a las AVU por área (índice de disponibilidad), la proporción del total del perímetro de AVU sobre su área total (índice de fragmentación), la proporción de áreas verdes privadas con respecto a las AVU (índice de privatización) y la distancia promedio, por vecindario, de cada celda al AVU más cercana a través de una red de caminos (índice de accesibilidad), y, el empleo de información perteneciente a imágenes Landsat, capas vectoriales de OSM (OpenStreetMap, por sus siglas en inglés) e información de catastro. Por su parte y haciendo uso de datos de población residente a una distancia de 400 m, Tian, Jim, & Liu, (2017) generaron un índice de accesibilidad que relacionó fuertemente los patrones espaciales de los vecindarios con las dimensiones de las AVU y expuso la falta de espacios de esta índole en Hong Kong.

De acuerdo con Coombes, Jones, & Hillsdon, (2010), para el índice de accesibilidad se recomienda el empleo de distancias de proximidad entre residencias locales y AVU correspondientes a una línea recta de 800 m, equivalentes a un promedio de 10 minutos de traslado desde el hogar de los habitantes hasta una AVU de tamaño de 2 ha o mayor. Para el estudio de zonas de mayor tamaño, correspondientes a 20, 100 y 500 ha, la distancia no debe sobrepasar los intervalos de 2, 5 y 10 km,

respectivamente. Además, se debe contemplar la presencia de un mínimo de 1 ha de reservas naturales locales estatuarias por cada mil habitantes. Entre otros indicadores empleados para la modelación de la accesibilidad de AVU se cuentan las vías de acceso, el mobiliario para estancia, las banquetas, los senderos y las vialidades (Muñoz, 2014). Estos indicadores deben ser considerados dentro de la planeación de las ciudades debido a que constituyen elementos que facilitan o dificultan el acceso, la salida o la estancia y la utilización de las AVU.

Con el desarrollo de un método que les permitió conocer la población que tenía acceso a las AVU mediante el uso de una red de análisis, Gutiérrez et al., (2021) realizaron un estudio en el nivel de manzana, para el centro urbano del Área Metropolitana de Querétaro, México. Mediante este trabajo determinaron intervalos de distancia de traslado de la población a los centroides de las AVU. La distancia máxima de proximidad empleada fue de 300 m con intervalos cada 100 m. Una vez obtenidos los valores de distancia máximos se calculó la población residente dentro del valor de distancia señalado.

CAPÍTULO 5. PROCESO. GUÍA METODOLÓGICA.

5.1 JUSTIFICACIÓN DEL ESTUDIO

Problemas como el incremento en la población urbana, su desplazamiento, y, los cambios de uso de suelo generados a partir del desarrollo urbano no planificado han causado estragos en la cantidad y la calidad de las AVU. Al tratarse de infraestructura con importantes beneficios para el ambiente, para la sociedad y para la economía, es necesario el desarrollo de herramientas que permitan realizar la gestión de las AVU de forma eficiente.

5.2 HIPÓTESIS

La integración de redes neuronales convolucionales y percepción remota producirá información geométrica de manera automática y eficaz para la modelación de la conectividad y la accesibilidad de las AVU, así como para la evaluación del indicador 11.7.1 de los Objetivos de desarrollo sostenible.

5.3 OBJETIVOS

5.3.1 OBJETIVO GENERAL

En este proyecto se pretende generar modelos de conectividad y accesibilidad de AVU que permitan la evaluación de las mismas gracias a la integración de redes neuronales convolucionales y la percepción remota.

5.3.2 OBJETIVOS ESPECÍFICOS

- Automatizar la obtención de información geoespacial de AVU, por medio de la segmentación semántica de imágenes de muy alta resolución, a través del uso de redes neuronales convolucionales.
- Evaluar la situación del arbolado urbano mediante la producción de índices de vegetación.
- Generar modelos de la conectividad de las AVU y de la accesibilidad de la población a las AVU.

- Validar la precisión de la información generada, a través de su comparación con modelos de muy alta resolución que integren el uso de tecnología VANT y fotorreconstrucción.

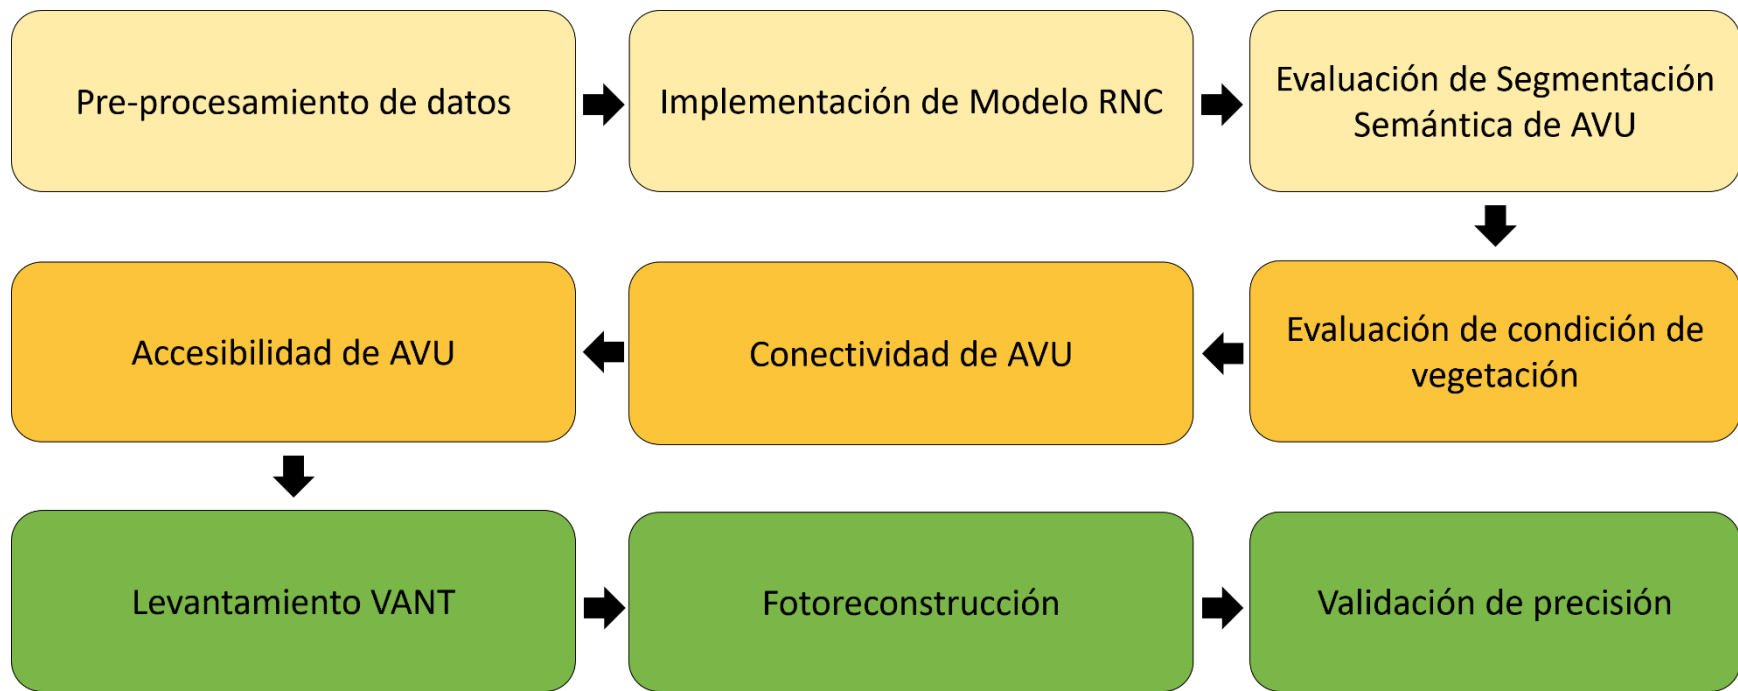


Figura 18. Proceso metodológico general seguido en la elaboración de este proyecto (Elaboración propia).

5.4 Área de estudio

El área de estudio se localiza en las coordenadas 25°40'00" N 100°18'00" O y corresponde a la ZMM, que es una zona urbana localizada al norte de México, dentro del estado de Nuevo León (Figura 19). Cuenta con una superficie de 7,657 km² y una población de 5,341,171 habitantes al año 2020 (INEGI, 2020). La configuración espacial de la ZMM se compone de la capital del estado, siendo el municipio de Monterrey, y once municipios periféricos que forman parte de su área conurbada, dentro de los que se cuenta Apodaca, Cadereyta Jiménez, García, General Escobedo, Guadalupe, Juárez, San Nicolás de los Garza, San Pedro Garza García, Santa Catarina, Santiago y Salinas Victoria. De acuerdo con datos del Censo de Población y Vivienda 2020, la ZMM cuenta con una densidad media urbana de 108.3 habitantes por hectárea.

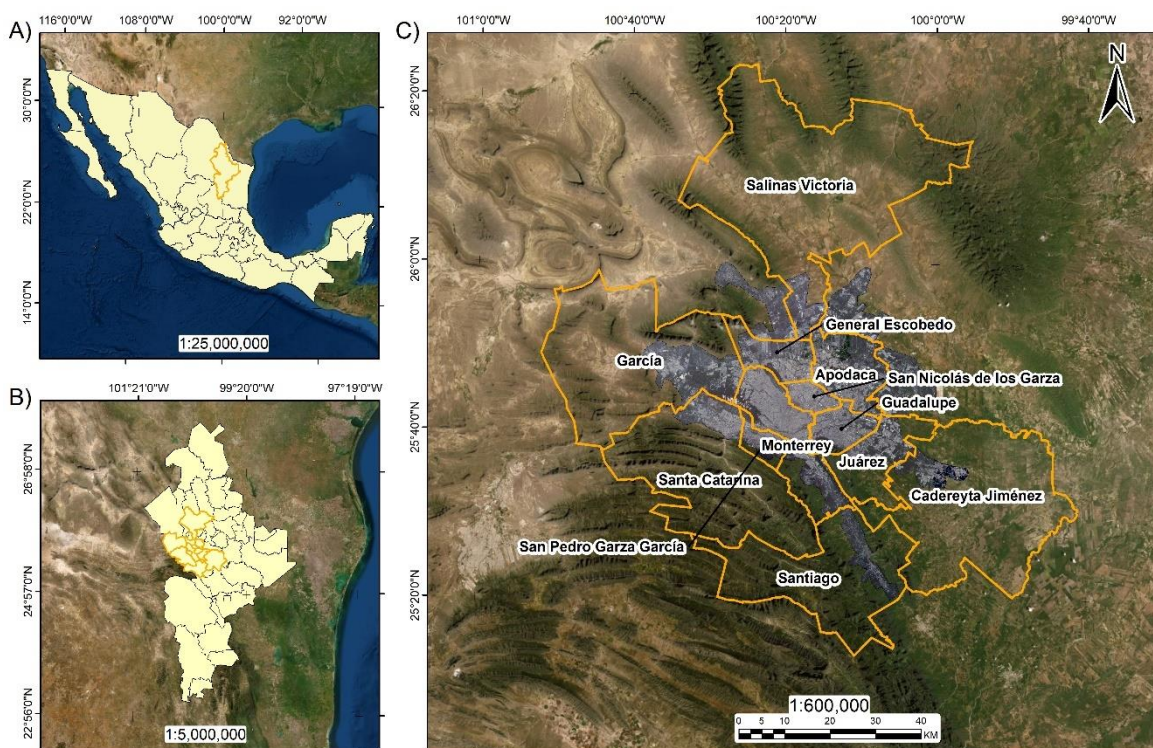


Figura 19. Zona Metropolitana de Monterrey (Elaboración propia).

5.4.1 Usos de suelo y vegetación

Conforme a datos correspondientes a la Serie VI de Uso de Suelo y Vegetación del INEGI, en escala 1:250,000, los tipos de vegetación presentes en la ZMM son la agricultura, que abarca un 11.99 % de la superficie; pastizal con 11.11 %; bosque con 14.54 %. El matorral tiene el tipo de vegetación más representativo con un 47.94 %; el chaparral con 0.002 %; mezquital con 0.005 %, mientras que un 13.39 % del área está cubierta por la zona urbana (Figura 20).

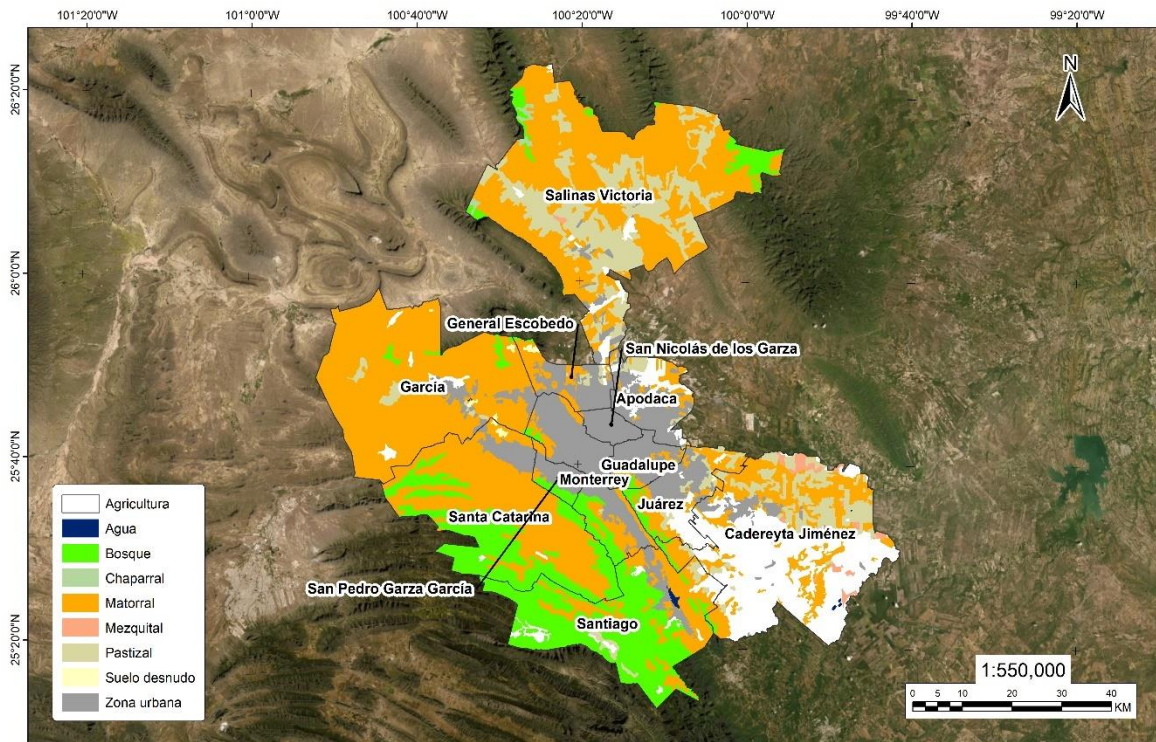


Figura 20. Tipos de uso de suelo y vegetación (Serie VI) de la ZMM (Elaboración propia).

5.4.2 Hidrografía

En la Carta Hidrológica de Aguas Superficiales de la Coordinación General de los Servicios Nacionales de Estadística, Geografía e Informática se señala que la ZMM se ubica en la región hidrológica de Bravo-Conchos, en la Cuenca Río Bravo-San Juan y alberga las subcuencas del Arroyo Huizache y los ríos Balmo, Monterrey, Pesquería, Pilón, Ramos, Salinas, San Juan, San Miguel y Sosa (Figura 21). Entre sus corrientes permanentes destacan tramos de los ríos Pesquería, Santa Catarina

y La Silla, mientras que los arroyos Topo Chico, Las Tinajas, Elizondo y El Sabinal se presentan con intermitencia (Esquivel-Puente, 2012).

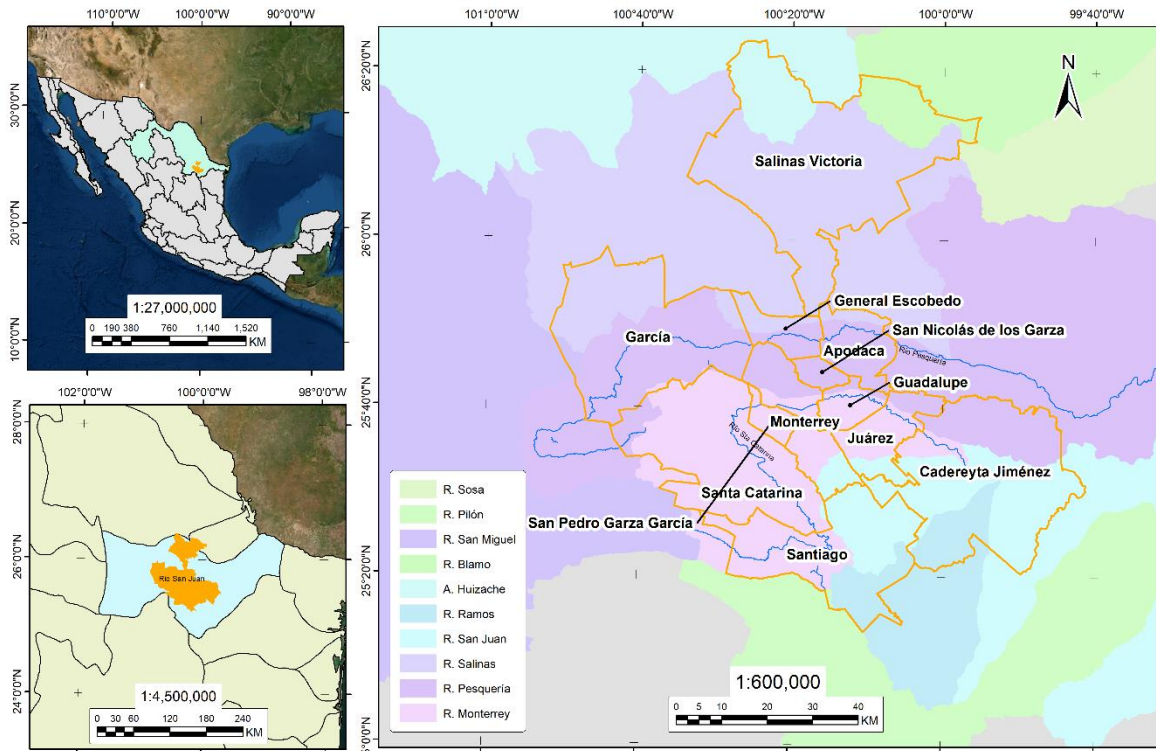


Figura 21. Hidrología de ZMM. A) Región hidrográfica de Bravo-Conchos. B) Cuenca Río Bravo-San Juan. C) Microcuencas de la ZMM (Elaboración propia).

5.4.3 Clima

Conforme a lo señalado en la Carta de Climas de INEGI (2010), escala 1:1,000,000 (Figura 22), la ZMM se caracteriza por tener condiciones climáticas en mayor proporción de tipo semiárido cálido, en una cobertura de su área de 24.13%, seguido de climas muy árido semicálido en el 17.83%, árido semicálido en el 15.51%, semicálido subhúmedo en un 13.89% y, en menor medida, climas semiárido semicálido en 10.92%, semiárido templado en 9.17%, árido cálido en el 5.24%, templado subhúmedo en un 1.87%, árido templado en un 1.26%, semifrío subhúmedo en un 0.17% y semiárido semifrío en una proporción del área de la ZMM menor que el 0.01 %.

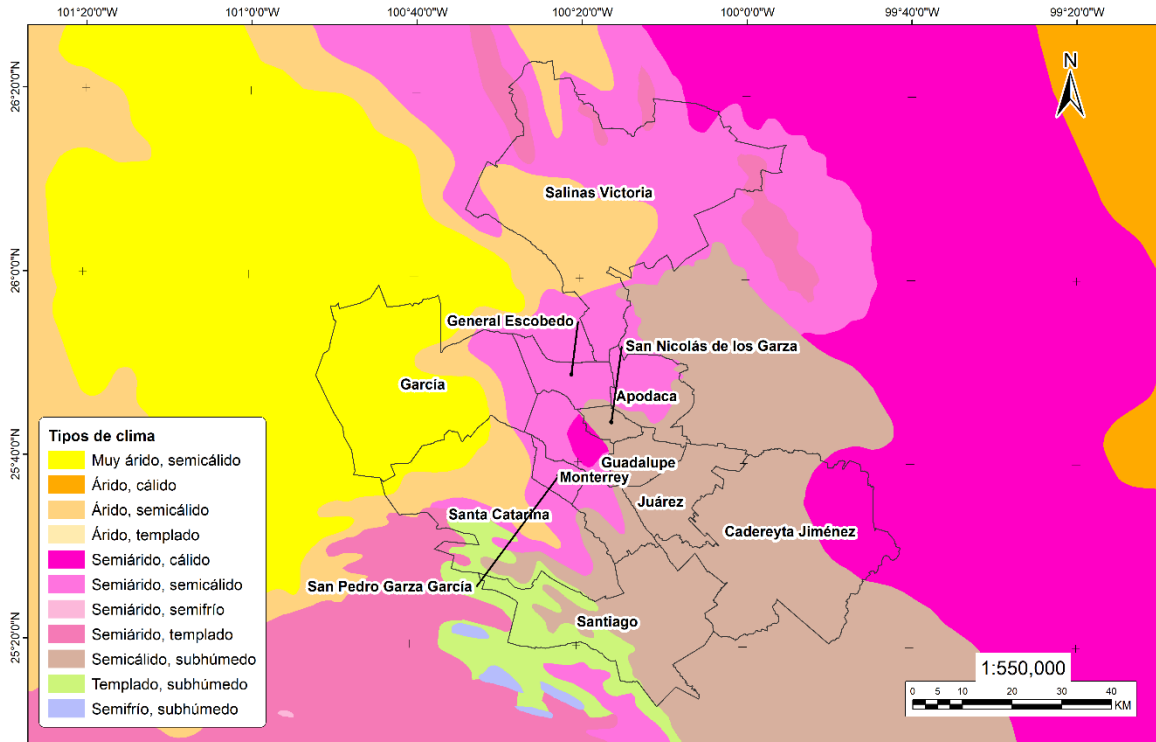


Figura 22. Tipos de clima presentes en la ZMM conforme a la Carta de Climas de INEGI (2010) (Elaboración propia).

5.4.4 Relieve

El relieve de la ZMM se ve caracterizado por diversos elementos orográficos que, de acuerdo con el Artículo 46, Fracción IX de la Ley General del Equilibrio Ecológico y la Protección al Ambiente, forman parte de Áreas Naturales Protegidas (ANP) Federales. En este grupo se encuentran la Sierra Madre Oriental, perteneciente al Parque Nacional Cubres de Monterrey, y, el Cerro de la Silla. Dentro de las ANP Estatales se cuentan las reservas de la Sierra Las Mitras, la Sierra Cerro de la Silla, el Cerro El Topo, la Sierra el Fraile y San Juan, el Cerro la Mola, la Sierra Corral de los Bandidos y la Sierra Picachos (Figura 23).

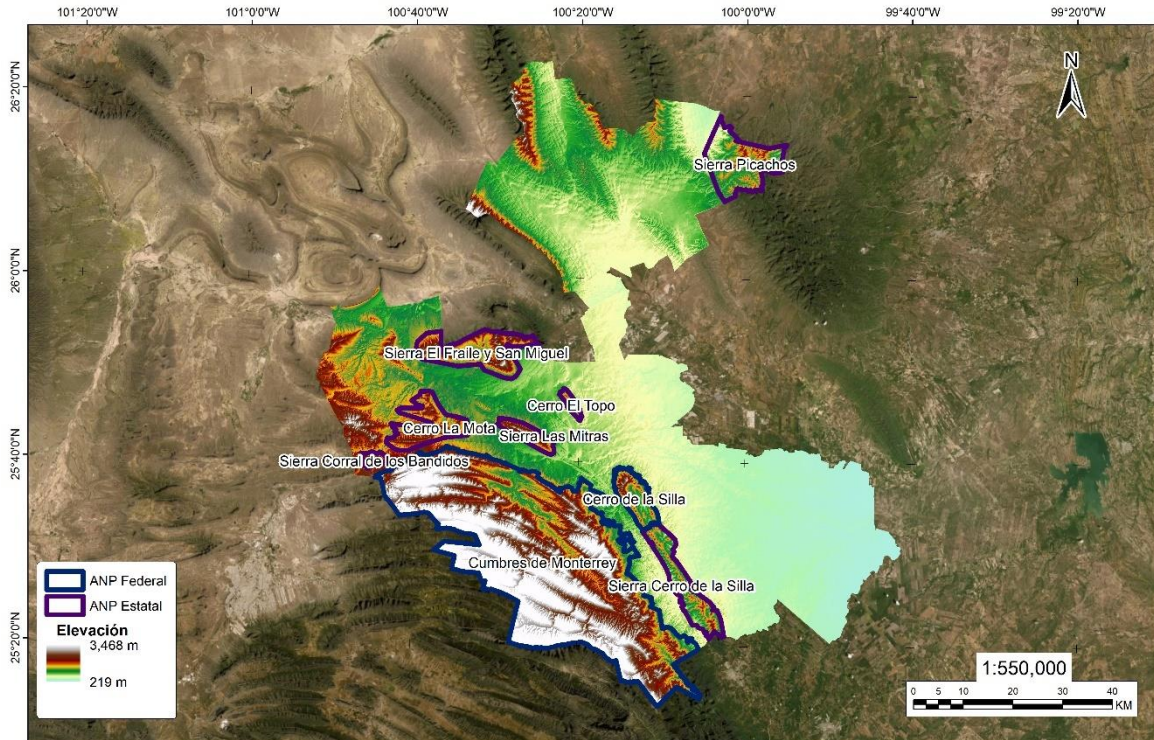


Figura 23. Orografía de ZMM. La rampa de colores muestra el continuo de elevaciones mexicano del área de estudio. Los polígonos azules y morados muestran ANP federales y estatales, respectivamente (Elaboración propia).

5.4.5 Geología

Conforme a su origen geológico, la ZMM se compone principalmente de formaciones sedimentarias de origen marino. Las formaciones geológicas que se encuentran presentes en el área de estudio son la formación Méndez, San Felipe, Agua Nueva, Cuesta del Cura, Aurora, La Peña, Cupido, Taraises, la Casita, Zuloaga y Minas Viejas. Dichas formaciones están compuestas por grupos de rocas de calizas, lutitas, así como conglomerados y areniscas (Michalzik, 1988). En la Figura 24 se muestra la Carta Geológica-Minera G14-7 producida por el Servicio Geológico Mexicano (SGM). En ella destaca la litología que compone la zona.

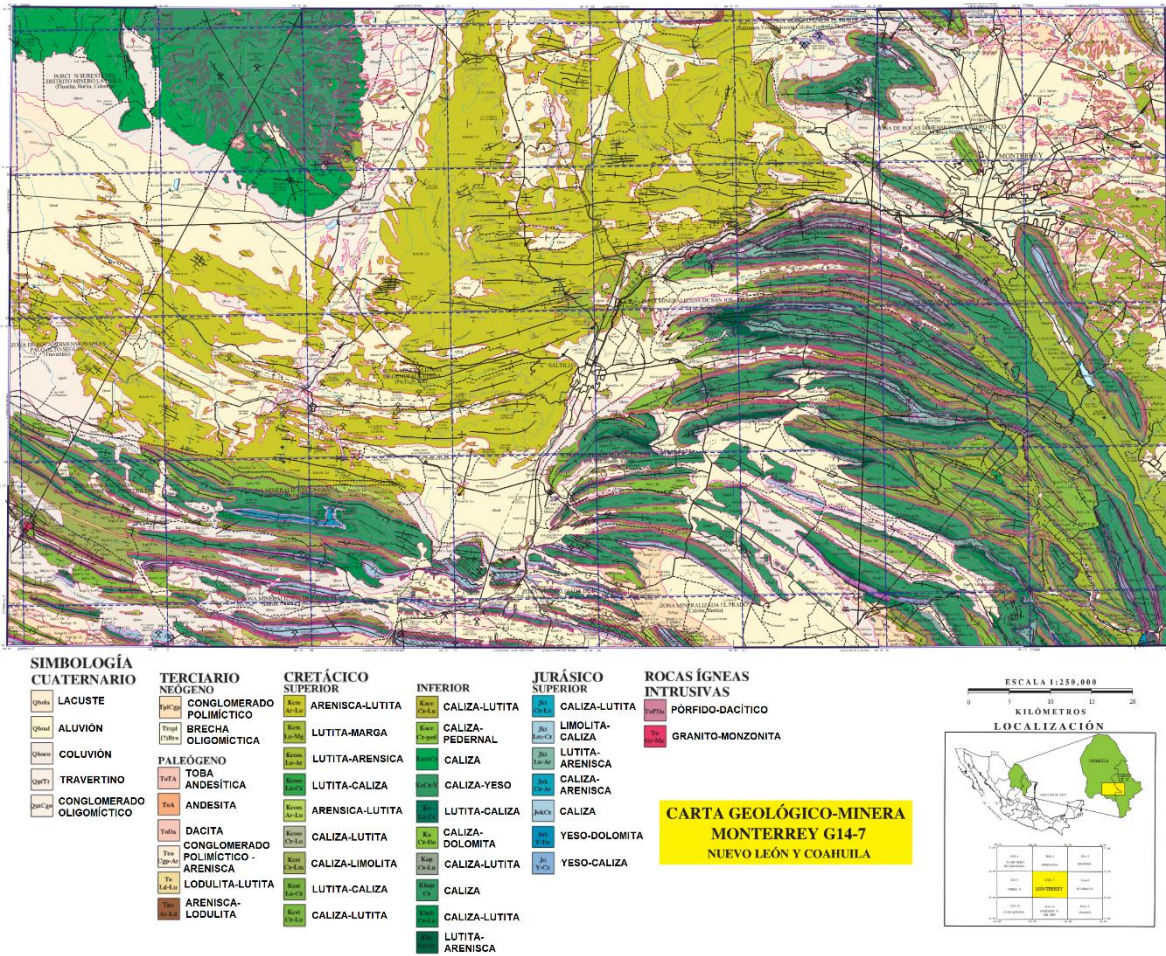


Figura 24. Carta Geológico-Minera Monterrey G14-7 con información correspondiente a la litología de la ZMM. (Fuente: SGM, 2008).

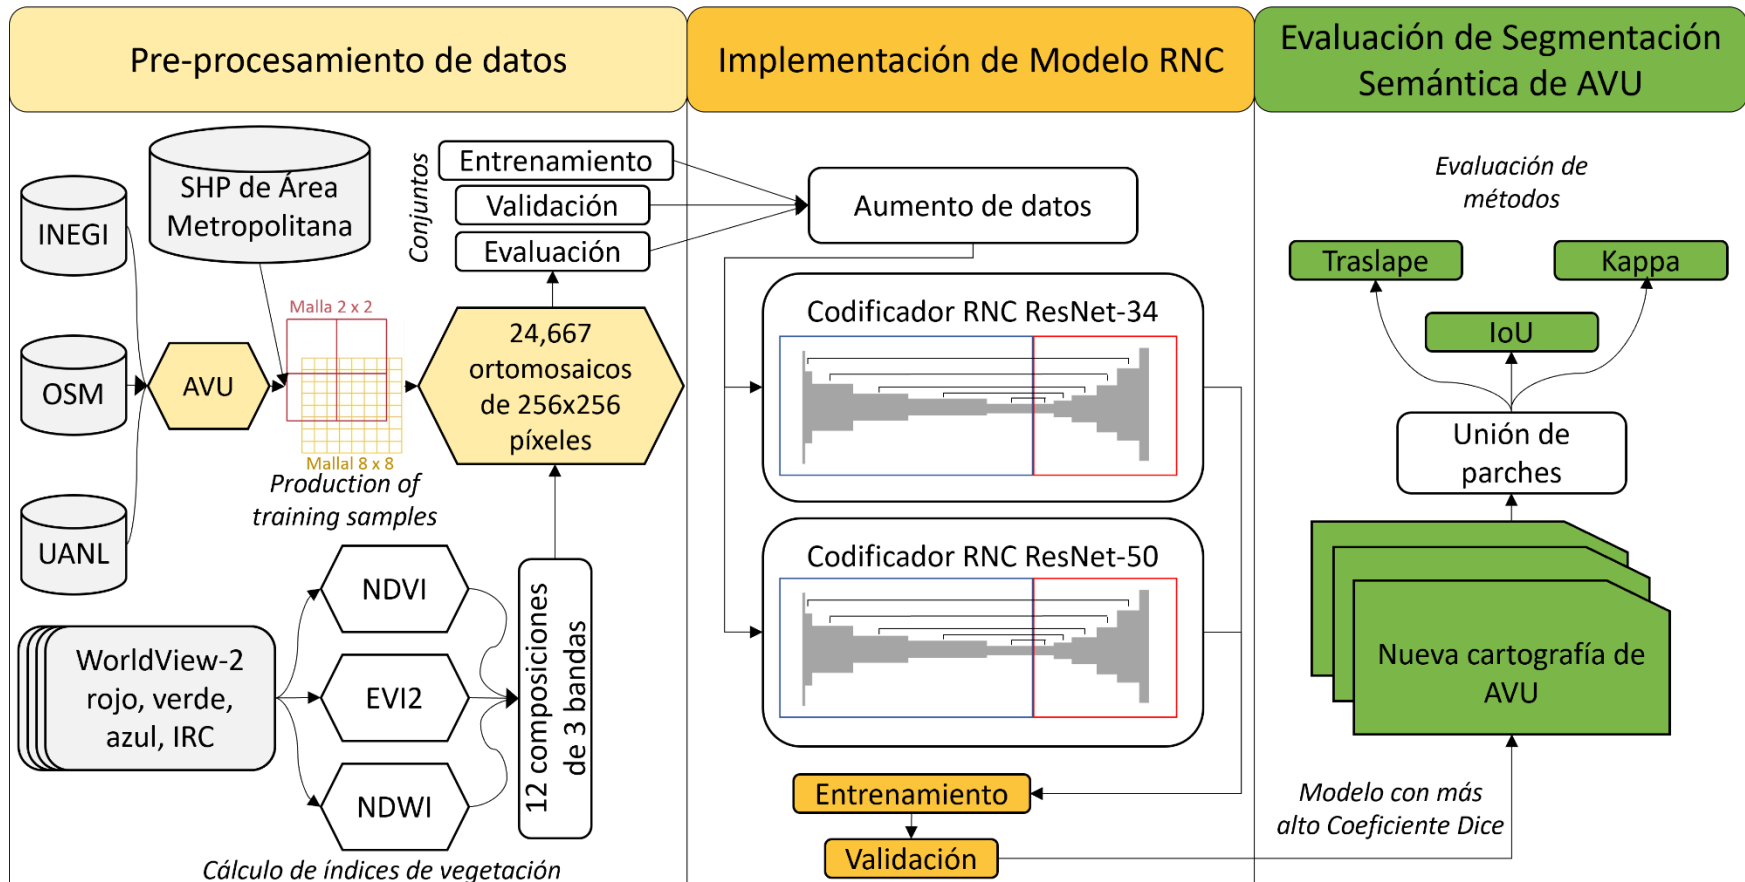


Figura 25. Proceso metodológico seguido en la elaboración de la segmentación semántica de AVU de la ZMM a partir de redes neuronales convolucionales (Fuente: Huerta et al., 2021).

CAPÍTULO 6. MÉTODO: SEGMENTACIÓN SEMÁNTICA.

6.1 Insumos de entrada

El primer paso dentro de la modelación de la segmentación semántica de AVU, a través del uso de RNC, consistió en la obtención de etiquetas de entrenamiento de las AVU de la ZMM y las imágenes a emplear como entrada. Ambos productos se describen a continuación.

6.1.1 Base de datos del INEGI

Dentro del MGN se encuentra la base de datos de polígonos de las AVU digitalizados por el INEGI (Figura 26). Esta capa cuenta con la información de claves de entidad, municipio, localidad, servicios, nombre del servicio, situación actual, nombre y clasificación del dato geográfico que se genera mediante el proceso descrito en la Figura 12.

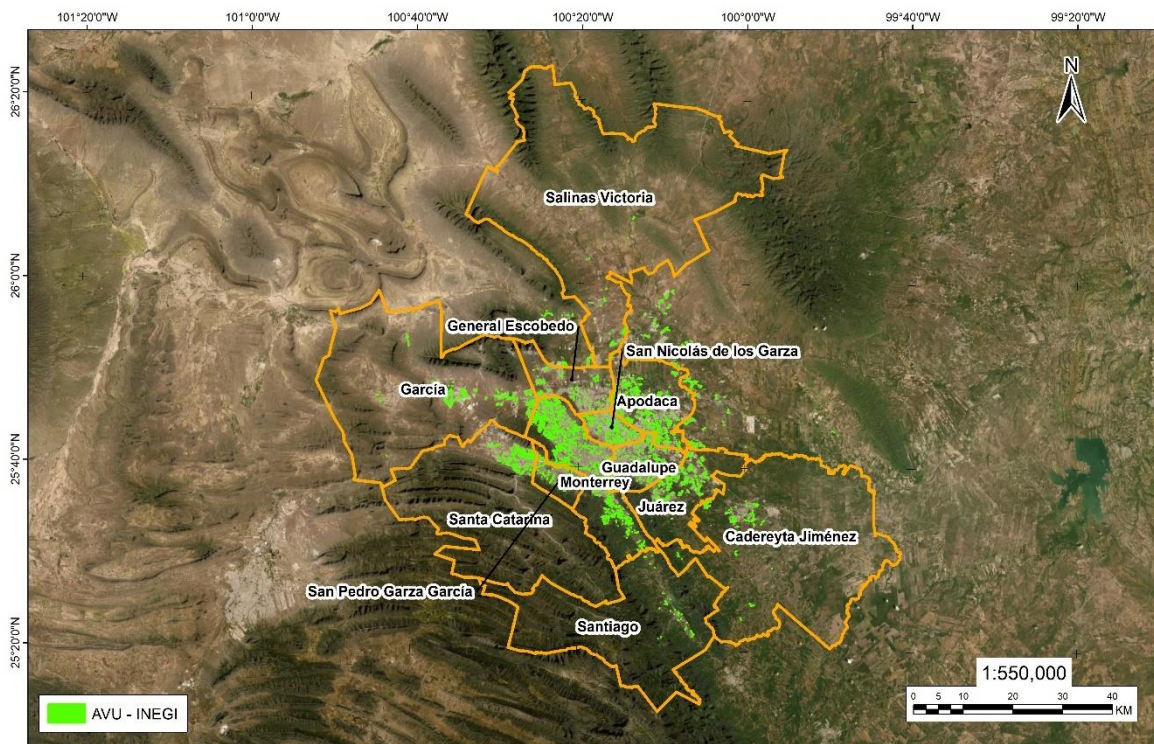


Figura 26. Polígonos de AVU obtenidos a partir del MGN (Elaboración propia).

6.1.2 Base de datos de OSM

Mediante el llenado y constante actualización de la base de datos de OSM, se ha realizado un esfuerzo colaborativo a través de la contribución de personal voluntario que ha digitalizado diversos elementos de interés presentes en la superficie terrestre como caminos, vías y servicios de todas partes del mundo. La comunidad de OSM se compone de entusiastas del mapeo, profesionales de los SIG, ingenieros que trabajan con servidores OSM y que realizan cartografía de libre acceso basada en el conocimiento local, con el apoyo de imágenes aéreas, GPS y mapas de campo (www.openstreetmap.org, 2020).

Dentro de la base de datos OSM, las AVU forman parte del esfuerzo de la comunidad por el mapeo de elementos que permiten ayudar a generar datos que sean empleados para dar solución a problemas ambientales (Figura 27). Dentro del campo leisure:common se engloban todas las áreas verdes que corresponden a espacios públicos, el campo leisure:park incluye parques y el campo leisure:playground incluye áreas verdes con equipamiento de juegos infantiles.

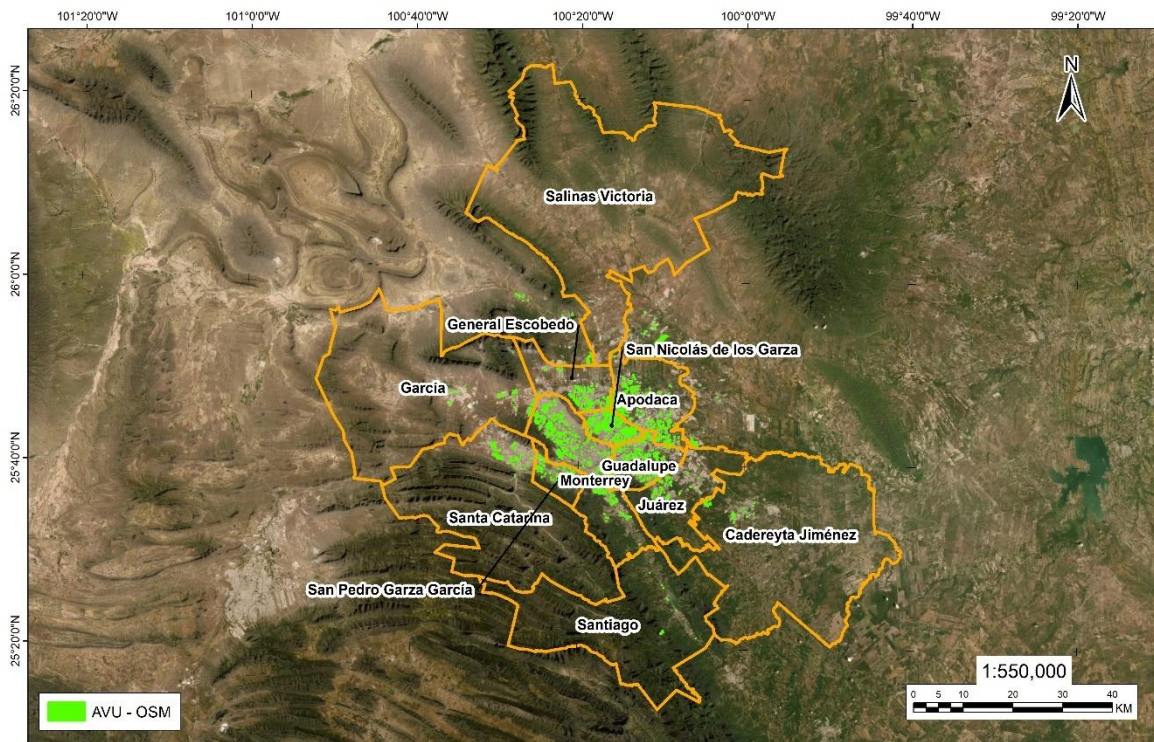


Figura 27. Polígonos de AVU obtenidos a partir de OSM (Elaboración propia).

6.1.3 Base de datos de Departamento de Geomática

Dentro de los esfuerzos realizados en el Departamento de Geomática de la Facultad de Ingeniería Civil (FIC), perteneciente a la Universidad Autónoma de Nuevo León (UANL), se generó en el año 2018 una base de datos, partiendo de una clasificación supervisada mediante el uso de una imagen WorldView-3 y la modelación de índices de vegetación que permitieran obtener de la geometría de polígonos de AVU correspondientes a la clase de camellones, como se muestra en la Figura 28 (Yépez-Rincon, Ferriño-Fierro, Guerra-Cobián, & Limón-Rodríguez, 2018).

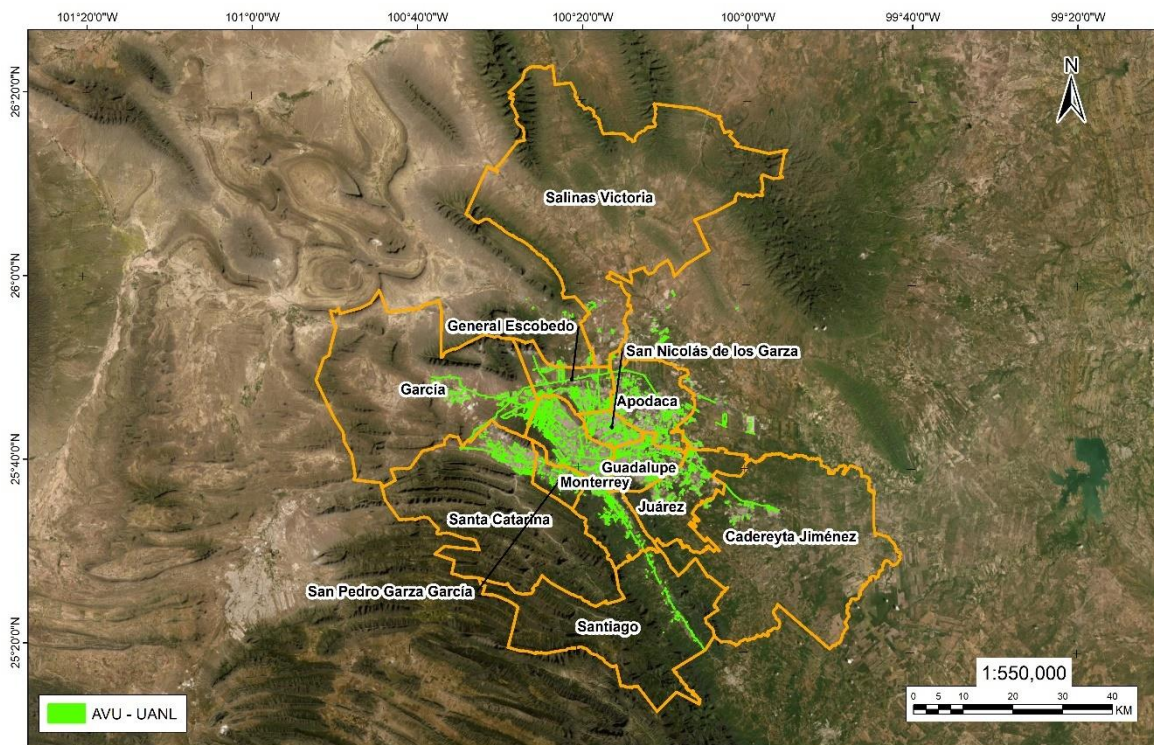


Figura 28. Polígonos de AVU obtenidos a partir de base de datos de camellones generados por el Departamento de Geomática, FIC, UANL (Elaboración propia).

6.1.4 Imagen satelital de muy alta resolución

Los sensores ópticos de muy alta resolución ofrecen la obtención de imágenes satelitales con una gran cantidad de información de las escenas capturadas. En esta investigación se empleó un ortomosaico producido a partir de nueve imágenes satelitales de muy alta resolución, correspondientes al satélite WorldView-2 (WV2) de la compañía de DigitalGlobe® (Figura 29). Las partes del preprocesamiento

correspondientes a la ortorectificación de las imágenes y balanceo radiométrico fueron llevadas a cabo previo al momento de su adquisición por la compañía distribuidora de Imágenes Geográficas®.

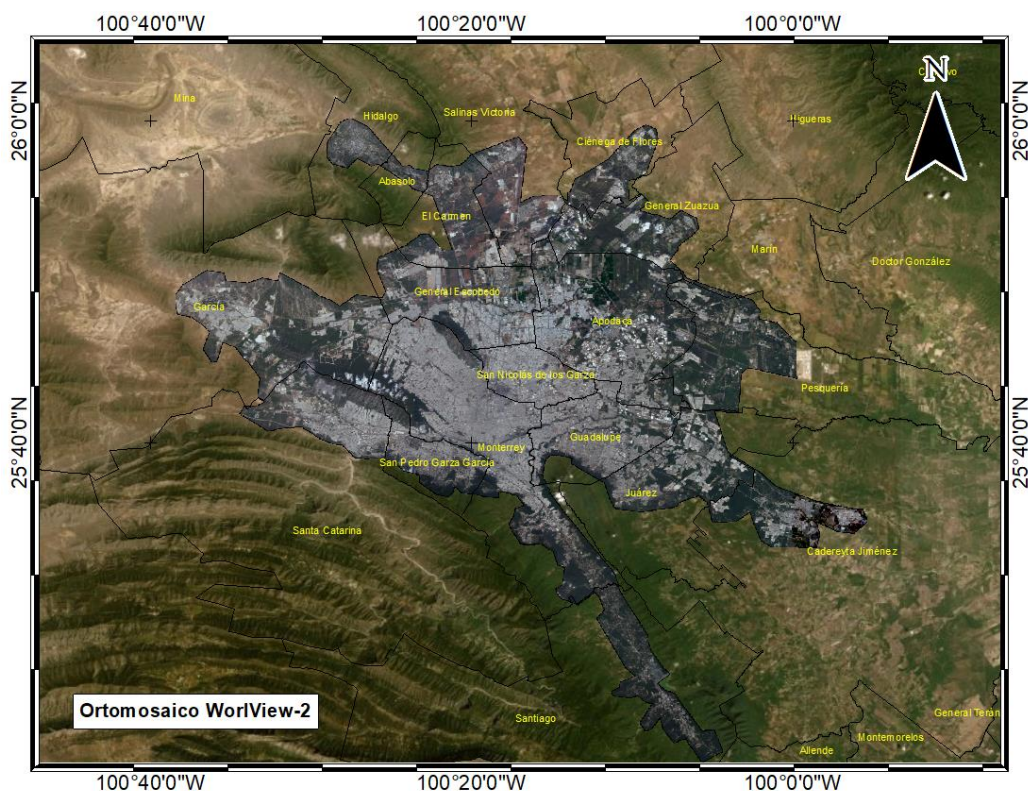


Figura 29. Ortomosaico de ZMM generado a partir de imágenes de muy alta resolución del satélite WorldView-2 (Elaboración propia).

Las fechas de la obtención de las imágenes por parte del satélite fueron en los meses de mayo, agosto y octubre del año 2017, en los días 27, 16 y 15, respectivamente. El área del ortomosaico comprendió la mancha urbana de la ZMM y su resolución espacial fue de 0.5 m. Respecto a su resolución espectral, el ortomosaico presentó información del espectro electromagnético correspondiente a la banda azul, que cubre valores de los 450 a 510 nm; verde, de los 510 a 580 nm, roja, con un intervalo de 630 a 690 nm; e infrarroja cercana, que van de los 770 a 895 nm. En la Tabla 6 se presentan las estadísticas de los valores de número digital específicos para la información que contienen los cuatro canales que componen el ortomosaico, mientras que en Figura 30 se muestran los histogramas de la distribución de sus píxeles. La resolución de la información radiométrica del satélite

WorldView-2 cuenta con un nivel dinámico de 11 bits por píxel que fue ajustada a 8 bits para trabajar con la misma resolución de las etiquetas.

Tabla 6. Estadísticas de los valores de longitud de onda de las cuatro bandas del ortomosaico de la ZMM (Elaboración propia).

Estadísticas	Bandas			
	Azul	Verde	Roja	Infrarrojo cercano
Min.	450	510	630	770
Max.	510	580	690	895
Media	471.59	522.25	646.94	790.69
Desviación estándar	7.43	10.52	9.41	8.77

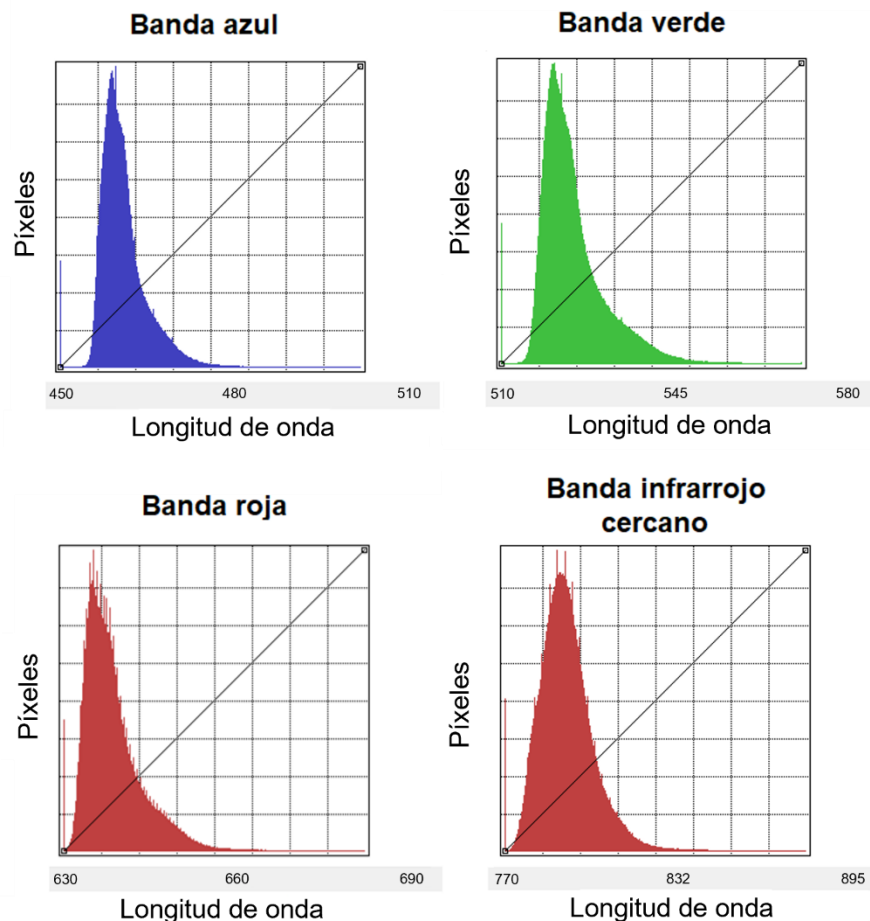


Figura 30. Histogramas de distribución de longitudes de onda de píxeles en las cuatro bandas del ortomosaico de la ZMM (Elaboración propia).

6.2 Pre-procesamiento de datos

6.2.1 Inspección de bases de datos y reclasificación tipográfica

Al pertenecer a tres diferentes fuentes de información, la base de datos de AVU presentaba variadas tipologías respecto a su clasificación de datos geográficos en la información de INEGI, así como diversas categorías para la información de OSM. Los datos generados por el Departamento de Geomática no contaban con una clasificación, al corresponder todos los polígonos a la clase de camellón. Debido a las discrepancias en la clasificación de la información fue necesario realizar una reclasificación tipográfica que tomó como precedente la estructura geométrica de las AVU de la ZMM, considerando su tamaño, su forma y su función, de modo que se pudiera producir una homogeneización de las clases de AVU (Tabla 7).

Tabla 7. Reasignación de etiquetas en el proceso de reclasificación de las tres bases de datos (Fuente: Huerta et al., 2021).

Base de Datos	Campos Originales		Campos reclasificados
Departamento de Geomática (UANL)	NA		Camellón
INEGI	Geográfico	Tipo 1	-
	Camellón	Bordo	Camellón
		Camellón	Camellón
		Glorieta	Glorieta
		Área verde	Parque
	Plaza	NA	Plaza
Instalación deportiva o recreativa	Parque	Parque	
	Jardín	Jardín residencial	
OSM	Leisure		-
	Playground		Parque
	Park		Parque
	Common		Parque

La base de datos resultante se conformó por polígonos que representaban (1) camellones a lo largo de calles y avenidas, característicos por sus formas alargadas y estrechas; (2) jardines residenciales, que cuentan con píxeles que corresponden a la vegetación administrada por el municipio; (3) glorietas, que tienen forma redondeada; (4) plazas, que son espacios mayormente utilizados para la recreación, mantienen una simetría y carecen de elementos relacionados con el deporte; (5) parques, que están integrados en áreas residenciales, utilizados para recreación y deportes, y tienden a ser asimétricos.

6.2.2 Descarte de polígonos duplicados y fusión de bases de datos

Mediante la herramienta de *Selección por ubicación* del software ArcGIS, se realizó un proceso de descarte de información duplicada para los casos de entidades que presentaban coincidencias en función de su ubicación relativa entre las distintas bases de datos. Empleando la herramienta de *Merge* se realizó el proceso de fusión de entidades de las tres capas vectoriales previamente mencionadas, para combinar los polígonos de AVU en una sola capa vectorial.

6.2.3 Rasterización de etiquetas

La información vectorial se convirtió en un formato ráster, con píxeles de 0.5 m, de tal forma que coincidiera con el formato del ortomosaico (GeoTIFF) de la ZMM. Este proceso se llevó a cabo para homogenizar las entradas de la RNC. Los valores de píxeles determinaron la presencia o ausencia de las AVU correspondientes a camellones, glorietas, parques, plazas y jardines residenciales. Se asignó una sexta clase denominada no_AVU para los píxeles de fondo que no correspondieran a ningún tipo de AVU.

6.2.4 Generación de composiciones

A través del uso de las bandas RGB e IRC del ortomosaico, se generaron los índices NDVI, EVI2 y NDWI, empleando las ecuaciones 1, 3 y 4, respectivamente. Para concentrar el poder computacional en el objeto de interés, las bandas fueron recortadas para que los cálculos se aplicaran exclusivamente al área de la capa de etiquetas de AVU. Los productos obtenidos fueron utilizados en conjunto con la información RGB e IRC del ortomosaico de la ZMM, para elaborar 12 composiciones

de 3 bandas (Tabla 8). El proceso de la generación de los índices se hizo con la herramienta *Raster calculator* de ArcGIS. Para realizar las composiciones se empleó la herramienta *Composite Bands* que permite la generación de composiciones a partir de múltiples bandas.

Tabla 8. Composiciones de 3 bandas (Elaboración propia).

Composiciones de 3 bandas			
EVI2, NDWI, IRC	NDVI, EVI2, IRC	NDVI, EVI2, NDWI	NDVI, roja, IRC
EVI2, NDWI, roja	NDVI, EVI2, roja	NDVI, NDWI, IRC	roja, verde, azul
EVI2, roja, IRC	NDVI, NDWI, roja	NDVI, roja, IRC	roja, verde, IRC

6.2.5 Fragmentación de las muestras

A mayor número de muestras de entrenamiento y validación que representen los objetos bajo estudio, mayor es la precisión que se puede alcanzar en la identificación de patrones para procesos de detección, clasificación y segmentación semántica a través de RNC (Lopes, de-Aguiar, de-Souza, & Oliveira-Santos, 2017). Por ello, después de haber realizado la rasterización de las etiquetas y la generación de las composiciones de 3 bandas, se llevó a cabo un proceso de fragmentación de las matrices de celdas de las composiciones y de sus respectivas etiquetas de AVU, para generar una cantidad considerable de muestras de entrenamiento para la RNC por cada imagen empleada. Debido a la gran cantidad de información contenida en el ráster de cada composición y en el ráster de las etiquetas de las AVU, la fragmentación se llevó a cabo por medio de un proceso de tres fases.

En la primera fase se realizó un recorte por máscara que extrajo las celdas de los ráster para corresponder al tamaño del área definido por la máscara. En este paso se realizó un mallado de 2 x 2 (Clip1) que dividió los ortomosaicos en 4 partes iguales con cobertura de 1,336.64 km². Para la segunda fase, se repitió el mismo procedimiento en los nuevos ortomosaicos, empleando en esta ocasión una malla de 8 x 8 (Clip2) que subdividió cada parte en 1 / 64 del área de la salida de la segunda fase y 1 / 256 del área total de la ZMM (Figura 31); en esta fase se descartaron los datos ráster resultantes que carecieran de información de utilidad para el entrenamiento, es decir, que únicamente presentaran datos con valores

NoData. Se obtuvieron 135 segmentos de 167.08 km², de los cuales 50 correspondieron al cuadrante del eje cardinal noreste, 43 al noroeste, 9 al sureste y 33 al suroeste. Al contar con dimensiones de ráster que exigían una menor demanda de poder computacional, en la tercera y última fase de la fragmentación, fue posible realizar un proceso automático de manejo de datos que creó una salida en mosaico directa a partir de los ráster generados en la segunda etapa. Para la totalidad del área de estudio, por cada combinación de 3 bandas se produjeron 24,667 ortomosaicos. Las características de salida fueron las siguientes: (1) Formato GeoTIFF, el cual permite conservar la información geoespacial de cada píxel; (2) Método de división, el cual consistió en definir el tamaño del mosaico otorgando los valores de 256 x 256 píxeles (128 x 128 m) en correspondencia con valores empleados en la generación de bases de datos para RNC de acuerdo con la bibliografía (Yang & Newsam, 2010), y; (3) Técnica de remuestreo del vecino más cercano, la cual es rápida y reduce los cambios en los valores de píxeles.

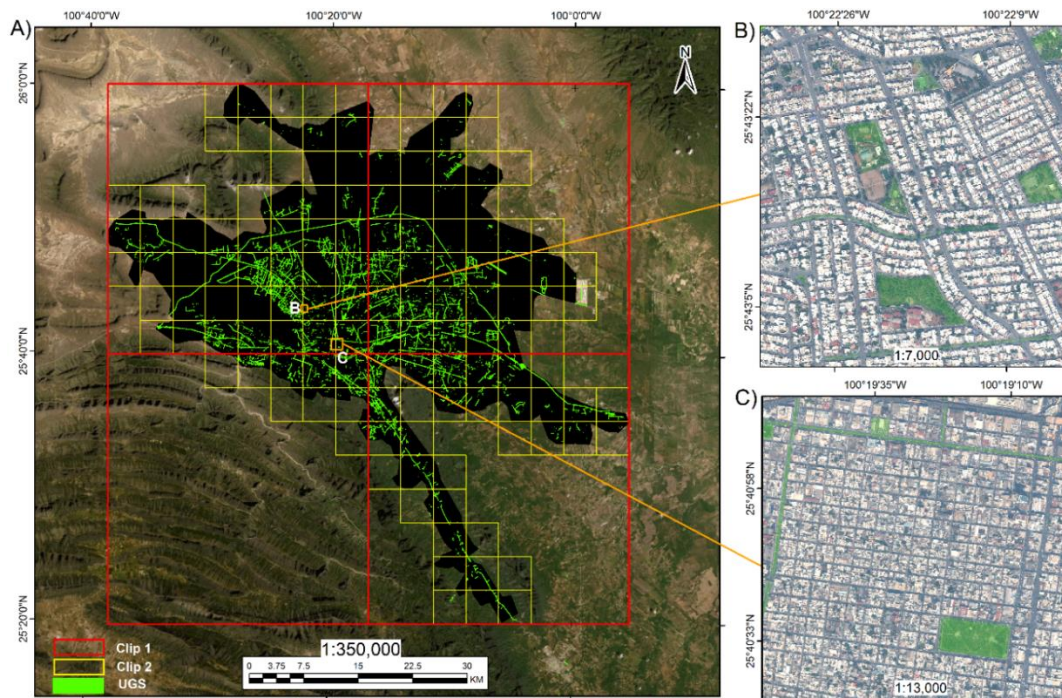


Figura 31. Fragmentación de muestras. A) Mapa con mallas de las fases 1 y 2 para subdivisión del ortomosaico y resultado de rasterización de AVU. B) y C) Ejemplos de ortomosaicos con polígonos de AVU extraídos en segunda fase de fragmentación de muestras (Fuente: Huerta et al., 2021).

Para la totalidad del preprocesamiento de datos se empleó un equipo de cómputo portátil personal marca ASUS®. Los procesos de rasterización de etiquetas y fragmentación de muestras se llevaron a cabo de forma paralela mediante el uso de la máquina anteriormente mencionada y una estación de trabajo MSi X399, perteneciente al Departamento de Geomática. Las características de hardware y software de ambos sistemas se muestran en la Tabla 9. Todos los procesos que condujeron a la generación de los insumos de entrada para la RNC se realizaron a través de herramientas del componente Esri® ArcMap™ del conjunto de programas de procesamiento geoespacial ArcGIS para escritorio, en su versión 10.8.1. Los datos fueron divididos en proporciones para su uso en las distintas fases del modelo de la RNC: un 85% fue asignado para el entrenamiento, un 14% para validación y un 1% para la evaluación (Benjelloun, El Adoui, Larhman, & Mahmoudi, 2018). La información generada se alojó en el servicio de la nube Google Drive, en formato tar.gz para su posterior uso en la plataforma de Google Colab.

Tabla 9. Equipos empleados en preprocesamiento de datos (Elaboración propia).

Características	Equipo de cómputo portátil	Estación de trabajo de Departamento de Geomática
Tarjeta de video (GPU)	NVIDIA® GEFORCE GTX™ 950M	NVIDIA® QUADRO® P4000
VRAM (GB)	4	8
Integración CUDA	Disponible	Disponible
Procesador (CPU)	Intel® Core™ i7 - 4720HQ CPU @ 2.60GHz (8 CPUs)	AMD Ryzen™ Threadripper™ 1950X 16-nucleos @ 3.4 GHz (32 CPUs)
Memoria RAM (GB)	12	64
Capacidad de almacenamiento (GB)	1024	3072
Sistema operativo	Windows 10 Home (64 bits)	Windows 10 Pro (64 bits)

6.3 Implementación de modelo de RNC

6.3.1 Entorno de implementación

Para la modelación de las RNC se empleó el entorno interactivo, de escritura y ejecución de código Python, Google Colab (<https://colab.research.google.com/>, 2020). Dentro de las principales bondades que ofrece el entorno se cuenta la

disposición de manera gratuita de GPUs y TPUs de alto rendimiento; el acceso en línea desde cualquier navegador web a la aplicación de Jupyter Notebook; una mínima configuración para desarrollo de programas debido a la presencia de librerías preinstaladas que realizan funciones para la simplificación de tareas complejas; la vinculación con otros servicios de Google; y, el acceso a las herramientas más conocidas para el desarrollo del código que permite la generación de modelos de aprendizaje profundo. Las características específicas de la capacidad computacional brindada por este servicio figuran en la Tabla 10.

Tabla 10. Características del equipo remoto en Google Colab (Elaboración propia).

Características	Google Colab
Tarjeta de video (GPU)	NVIDIA® Tesla® K80 NVIDIA® Tesla® T4S NVIDIA® Tesla P4S NVIDIA Tesla® P100-PCIE (dependiendo de disponibilidad de uso)
VRAM (GB)	NVIDIA® Tesla® K80: 24 NVIDIA® TESLA® T4S: 16 NVIDIA® Tesla P4S: 8 NVIDIA Tesla® P100-PCIE: 16 (varía según GPU disponible)
Integración CUDA	Disponible
Procesador (CPU)	Intel® Xeon® CPU @ 2.30GHz (2 CPUs)
Memoria RAM (GB)	12
Capacidad de almacenamiento	15 GB en la nube
Sistema operativo	Linux 4.14.137 (64 bits) con Ubuntu 18.04 bionic
Límite de tiempo de uso (h)	12

6.3.2 Librerías para la modelación de RNC

Para tareas de manipulación de información geoespacial como lectura o escritura dentro del cuaderno de trabajo de Jupyter Notebook, se hizo uso de la librería *GeoPandas* (<https://geopandas.org/>, 2019). La librería de *Rasterio* (<https://rasterio.readthedocs.io/>, 2018) también proporcionó un recurso valioso dentro de Google Colab pues permite la visualización de metadatos de los ortomosaicos y el manejo de archivos ráster. Otra herramienta de utilidad, que permitió graficar datos de la geometría de los elementos presentes en los ortomosaicos fue la librería *Descartes* (<https://pypi.org/project/descartes/>, 2017). En combinación con las bibliotecas anteriores, la herramienta de trazado de formas, bordes y uniones en rásters de la librería de Supermercado (<https://github.com/mapbox/supermercado/>, 2019) sirvió de apoyo para la designación aleatoria de los conjuntos de datos de entrenamiento, validación y evaluación. A continuación, con la herramienta de rio-tiller (<https://github.com/cogeotiff/rio-tiler>, 2020) se realizó la lectura de la malla de los ortomosaicos de entrenamiento y validación en formato GeoTIFF y se les hizo corresponder con sus respectivas etiquetas, empleando la librería *GeoPandas* y la herramienta de marcado de huellas, límites y áreas de contacto de la librería *Solaris* (<https://solaris.readthedocs.io/>, 2020).

6.3.3 Arquitectura de red

Para la implementación de las redes se empleó la librería de aprendizaje profundo *FastAi*, desarrollada por Howard & Gugger, (2020), ésta funciona con la biblioteca de aprendizaje profundo *Pytorch* de fondo (Paszke et al., 2019). Su integración en la aplicación Jupyter Notebook de Google Colab torna muy sencillo su uso, ya que evita conflictos de instalación y mantiene actualizadas las librerías a emplear.

Se implementaron veinticuatro modelos de segmentación semántica a través de la RNC. Por cada composición de bandas generadas se corrieron dos modelos, cada uno con un codificador diferente. Los modelos emplearon una arquitectura dinámica de U-Net (Figura 32) con los codificadores *ResNet-34* y *ResNet50* (He et al., 2016). Ambos codificadores presentan similar arquitectura, habiendo sido entrenados

previamente con el conjunto de datos ImageNet (Krizhevsky et al., 2012), siendo su principal diferencia la mayor cantidad de capas ocultas en el ResNet50.

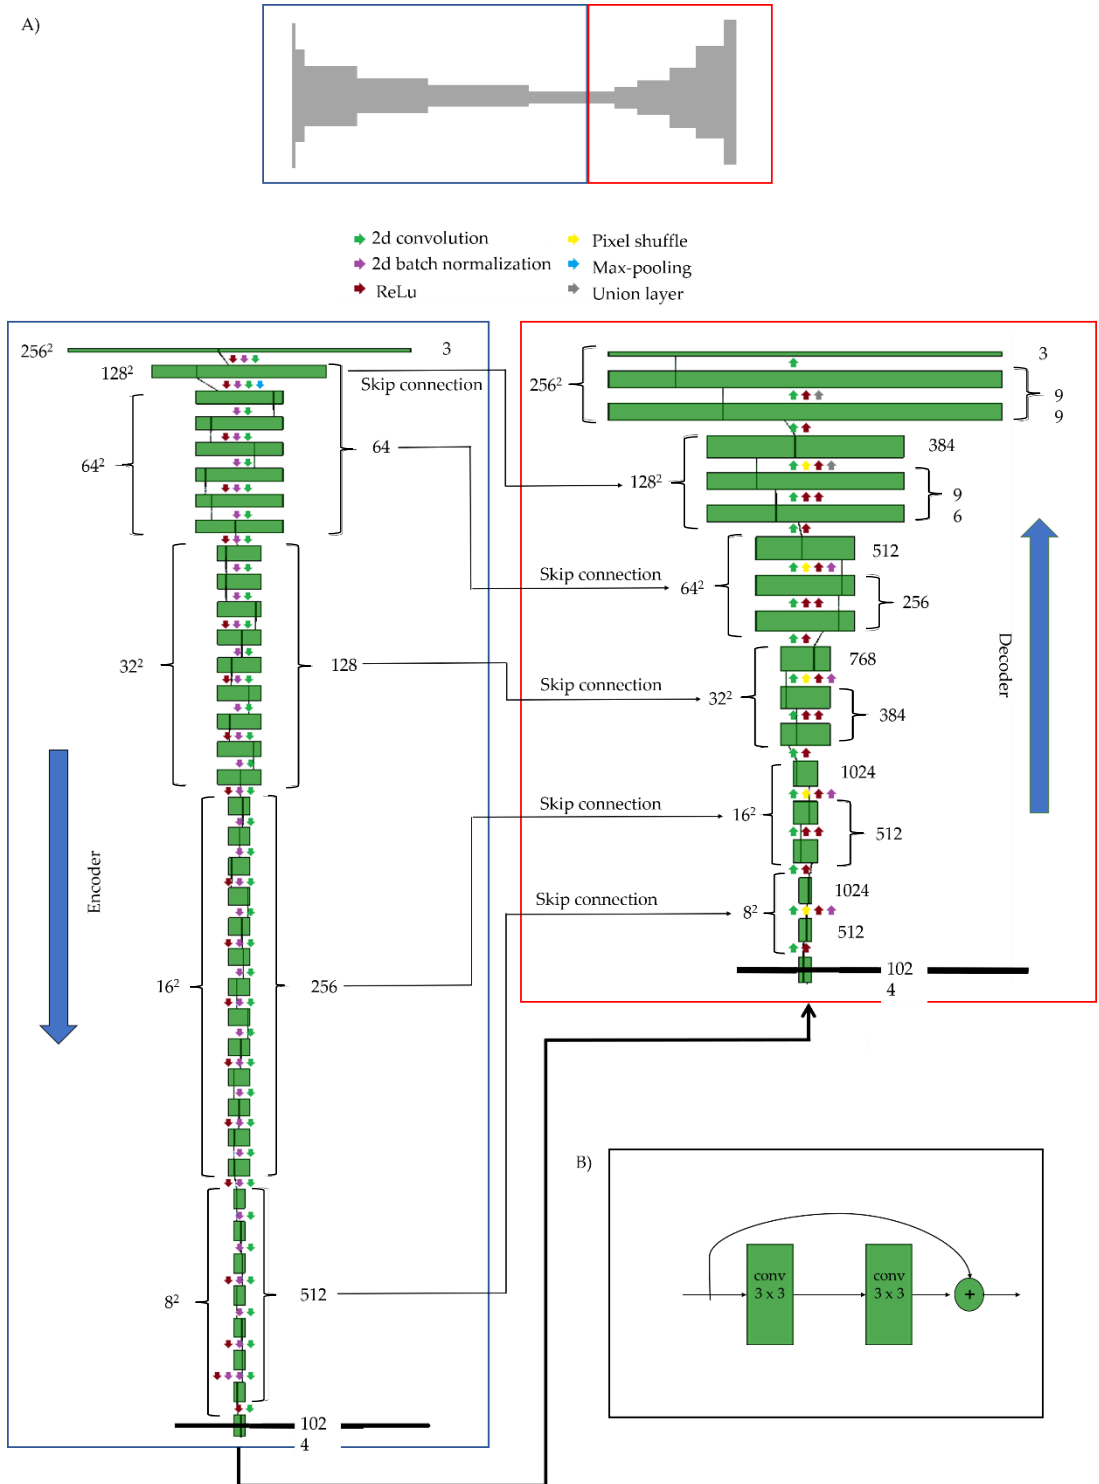


Figura 32. Arquitectura de RNC. A) Modelo de red dinámica U-net empleado para la segmentación semántica. Codificador en azul y decodificador en rojo. B) Bloques de construcción usados en la sección del codificador (Fuente: Huerta et al., 2021).

En la Tabla 11 se mencionan las versiones del software empleado para la generación de los modelos de segmentación semántica de AVU de la ZMM.

Tabla 11. Versiones de software empleado para el modelo segmentación semántica de AVU de la ZMM (Elaboración propia).

Software	Versión
Python	3.6.9
FastAi	1.0.59
Fastprogress	0.1.22
Torch	1.3.1
NVIDIA driver	418.67
Torch CUDA	10.1.243 (disponible)
Torch CUDNN	7603 (activado)

6.3.4 Ajuste de parámetros

Tamaño de lote

Un tamaño de lote elevado puede incrementar el tamaño de paso en el entrenamiento y, consecuentemente, reducir el número de parámetros a actualizar a lo largo del modelo; sin embargo, se ha observado que los incrementos en el tamaño del lote comúnmente ocasionan una reducción de la precisión de los resultados obtenidos, ya que generan la degradación del desempeño de generalización del modelo (Hoffer, Hubara, & Soudry, 2017). En acuerdo a lo anterior, y tomando en consideración las características del sistema, así como las limitantes de memoria, se asignó un número de tamaño de lote de 16 muestras analizadas por iteración.

Aumento de datos

A partir de transformaciones simples realizadas al conjunto de imágenes se logró la generación de una mayor cantidad de datos, ya que cada uno de estos cambios es registrado como una nueva imagen (Pieniążek et al., 2017). Esta información adicional ayuda a mejorar el desempeño del modelo en la generalización, ya que las modificaciones en las imágenes originales tienen importantes consecuencias en

los nuevos valores de píxel que arrojan información adicional al modelo. Por lo anterior, el aumento de datos es considerado uno de los métodos más relevantes de regularización del entrenamiento de RNC. Esta técnica es de gran utilidad cuando no existe la posibilidad de obtener un elevado número de muestras de los elementos bajo estudio (Ronneberger et al., 2015). Dentro de la librería FastAi, el aumento de datos se realizó a través de la función *get_transformations* que distingue entre las transformaciones que se llevarán a cabo al conjunto de datos de entrenamiento y al conjunto de datos de validación. En esta se realizaron (1) transformaciones con un 50 % de probabilidad de contener giros horizontales y verticales, (2) deformaciones simétricas de forma aleatoria con valores de magnitud de 0.1, (3) rotaciones al azar con ángulos de 20°, (4) cambios de hasta un 200% en el enfoque de las imágenes, y, (5) cambios en un factor de 0.3 de la luz y el contraste de los ortomosaicos. Estas técnicas generaron transformaciones en cada época dentro de los modelos y aumentaron el tamaño de las muestras de entrenamiento en 60 veces. En la Figura 33 se pueden observar ejemplos de transformaciones realizadas por el aumento de datos.

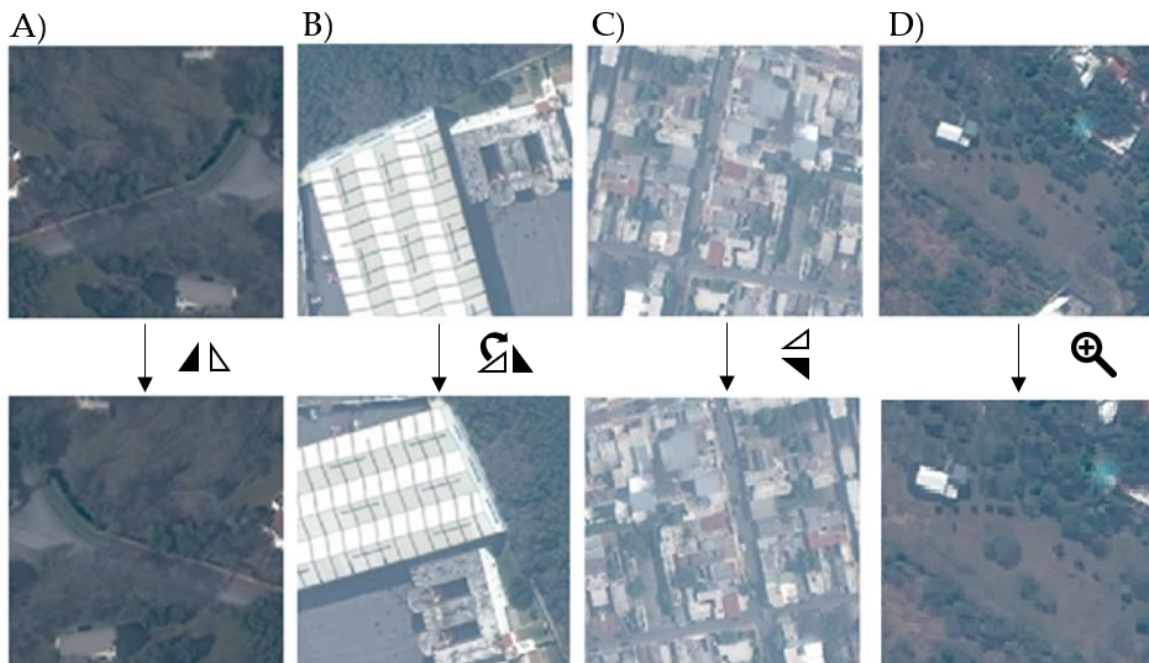


Figura 33. Ejemplos de imágenes producidas por el aumento de datos. A) giro horizontal. B) rotación aleatoria, C) giro vertical, D) cambio en enfoque (Fuente: Huerta et al., 2021).

Métricas de evaluación de entrenamiento

Para que un modelo de RNC pueda llegar a inferir características de interés a partir de nuevos datos, es necesario que previo a ello haya pasado por una fase de entrenamiento. Lo anterior implica que mediante el uso de un algoritmo de optimización, la red aprenda a ajustar los resultados que obtiene partiendo de una base de datos de entrenamiento con ejemplos que le permitan actualizar el modelo hasta lograr un adecuado mapeo de las entradas (Ian, Bengio, & Courville, 2016). De esta forma, mediante una actualización progresiva se disminuye el error en la evaluación de los resultados. En la segmentación semántica se emplea la función de pérdida para evaluar el dicho error que equivale a las diferencias entre los resultados del entrenamiento y las etiquetas de entrada. Si bien, la pérdida categórica de entropía cruzada es una de las funciones más empleadas como métrica de evaluación de los modelos de RNC, se ha demostrado que funciones de pérdida basadas en el coeficiente Sørensen – Dice o medida F1 generan mejores resultados (Q. Huang, Sun, Ding, Wang, & Wang, 2018; Lguensat et al., 2018; H. Liu, Feng, Feng, Lu, & Zhou, 2017; White, Dikow, Baugh, Jenkins, & Frandsen, 2020). Aunado a lo anterior, se ha evidenciado que la métrica Dice presenta robustez en casos donde no es posible obtener un balance de distribución entre todas las clases de entrenamiento (Fidon et al., 2018). Como se logra apreciar en la Figura 31, las AVU de la ZMM representan una pequeña porción de los píxeles del área de estudio. Lo anterior debido a que al igual que la mayoría de las ZU, la ZMM presenta mayormente una cobertura de área construida ocupada por calles, edificaciones, y otras superficies impermeables. Por esta razón, se optó por el uso del coeficiente Dice que se muestra en la Ecuación 5.

$$\text{Coeficiente Dice} = \frac{2|I_{GT} \cap O_{SEG}|}{|I_{GT}| + |O_{SEG}|} \quad (\text{Ecuación 5})$$

Donde I_{GT} son las etiquetas de entrada y O_{SEG} es la segmentación de salida.

El coeficiente Dice permite medir las similitudes entre dos muestras (Milletari, Navab, & Ahmadi, 2016). En el caso de presentarse un traslape perfecto entre I_{GT} y O_{SEG} , el coeficiente arrojaría un valor de 1, mientras que, en una situación opuesta,

el resultado sería de 0 (Guindon & Zhang, 2017). De esta forma los valores que ayudan a evaluar el modelo se encuentran entre el intervalo de 0 a 1, donde la proximidad al valor máximo reflejaría mejores resultados.

Se obtuvieron la media, la desviación estándar y los intervalos de confianza del 95% para los modelos para determinar las diferencias estadísticamente significativas entre el coeficiente de Dice calculado para cada combinación de tres bandas.

Adicionalmente, se obtuvo la puntuación de precisión (Ecuación 6) que evalúa el porcentaje de píxeles clasificados correctamente por las predicciones del modelo (Saraiva, Protas, Salgado, & Souza, 2020).

$$\text{Puntuación de precisión} = \frac{TP + TN}{TP + TN + FP + FN} \quad (\text{Ecuación 6})$$

Donde TP representa verdaderos positivos, TN son los verdaderos negativos, FP son los falsos positivos y FN son los falsos negativos.

Tasa de aprendizaje

El hiperparámetro de la tasa de aprendizaje afecta en el tiempo que le llevará al modelo para poder realizar predicciones a partir de los datos de entrenamiento. Una tasa de aprendizaje muy baja conducirá a un algoritmo de entrenamiento que converja de manera muy lenta, mientras que una tasa de aprendizaje alta hará lo contrario, generando que los resultados presenten divergencia respecto a los datos de entrenamiento (Smith, 2017). Se definió la tasa de aprendizaje óptima mediante el método de *learn.lr_find()* presente en la librería de FastAi (Howard & Gugger, 2020). A través de este método se incrementa la tasa de aprendizaje desde un valor muy bajo hasta el punto en que el gradiente de pérdida decrece y a partir de la gráfica de ese resultado es posible obtener un valor óptimo para el tipo de conjunto de datos con que se esté trabajando.

Número de épocas

Cada modelación de las composiciones de bandas con codificador ResNet34 se corrió con 100 épocas, para probar la funcionalidad de las implementaciones. Este

valor se estableció tomando como referencia los trabajos de Abraham & Khan, (2019), y X. Zhang, Xiao, Li, Fan, & Zhao, (2019). Los modelos con codificador ResNet50 se implementaron usando 10 épocas debido a las limitaciones de Google Colab respecto a la disponibilidad de GPU, RAM y tiempo de sesión.

6.4 Evaluación de segmentación semántica de AVU

El modelo con el Coeficiente Dice más alto fue evaluado haciendo uso del conjunto de evaluación que corresponde al 1% de la información original. Haciendo uso del modelo de segmentación semántica se obtuvo un ráster con la predicción de las AVU presentes en la muestra. Esta información fue convertida a vector para obtener polígonos que permitieran la evaluación de los resultados respecto a la capa de entrada de las AVU de la ZMM. El proceso de vectorización se llevó a cabo a través de la librería Solaris en Google Colab. Los polígonos resultantes fueron descargados y analizados en ArcGIS para la evaluación del modelo. Los datos de evaluación constaron de 68 muestras de mosaicos con cobertura de 32.08 ha (Figura 34).



Figura 34. Muestras de evaluación de modelo de RNC (Fuente: Huerta et al., 2021).

Se emplearon las funciones de evaluación de (1) intersección sobre unión (IoU), (2) traslape y (3) el Coeficiente Kappa.

La función de IoU calcula la cantidad de sobreposición entre los polígonos de las predicciones y las etiquetas de entrada (Stewart et al., 2019). En la Ecuación 7 se muestra el cálculo de esta función.

$$\text{Intersección sobre unión} = \frac{|I_{GT} \cap O_{SEG}|}{|I_{GT} \cup O_{SEG}|} \quad (\text{Ecuación 7})$$

Donde la variable I_{GT} corresponde a las etiquetas de entrada y O_{SEG} es la segmentación resultante.

El análisis de traslape es una métrica que calcula la proporción de datos positivos identificados correctamente (Saraiva et al., 2020) y se calcula a través de la Ecuación 8.

$$\text{Traslape} = \frac{TP}{TP + FN} \quad (\text{Ecuación 8})$$

Donde TP representa verdaderos positivos y FN son los falsos negativos.

Para calcular el Coeficiente Kappa (Ecuación 9) se obtuvieron la precisión global del usuario y la del productor. Este índice de acuerdo se obtiene a través del cálculo de una matriz de confusión con los errores de omisión y comisión entre las predicciones y las etiquetas de entrada. Cuando se obtiene un valor de 1 en este coeficiente se considera que existe un acuerdo perfecto, mientras que un valor de 0 indica que el acuerdo no es el que se esperaba (Cohen, 1960; Rwanga & Ndambuki, 2017). Para la obtención del índice es necesario establecer aleatorios de referencia. En este estudio se establecieron 2,000 puntos generados a partir de un muestro estratificado aleatorio y verificados respecto a la capa de información de AVU de referencia.

$$\text{Kappa Coefficient} = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} * x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} * x_{+i})} \quad (\text{Ecuación 9})$$

Donde r representa el número de celdas y columnas de la matriz de error, N es el número total de píxeles, x_{ij} es la observación en la celda i y columna j , x_{i+} es el total marginal de la celda i , y x_{+i} es el total marginal de la columna i .

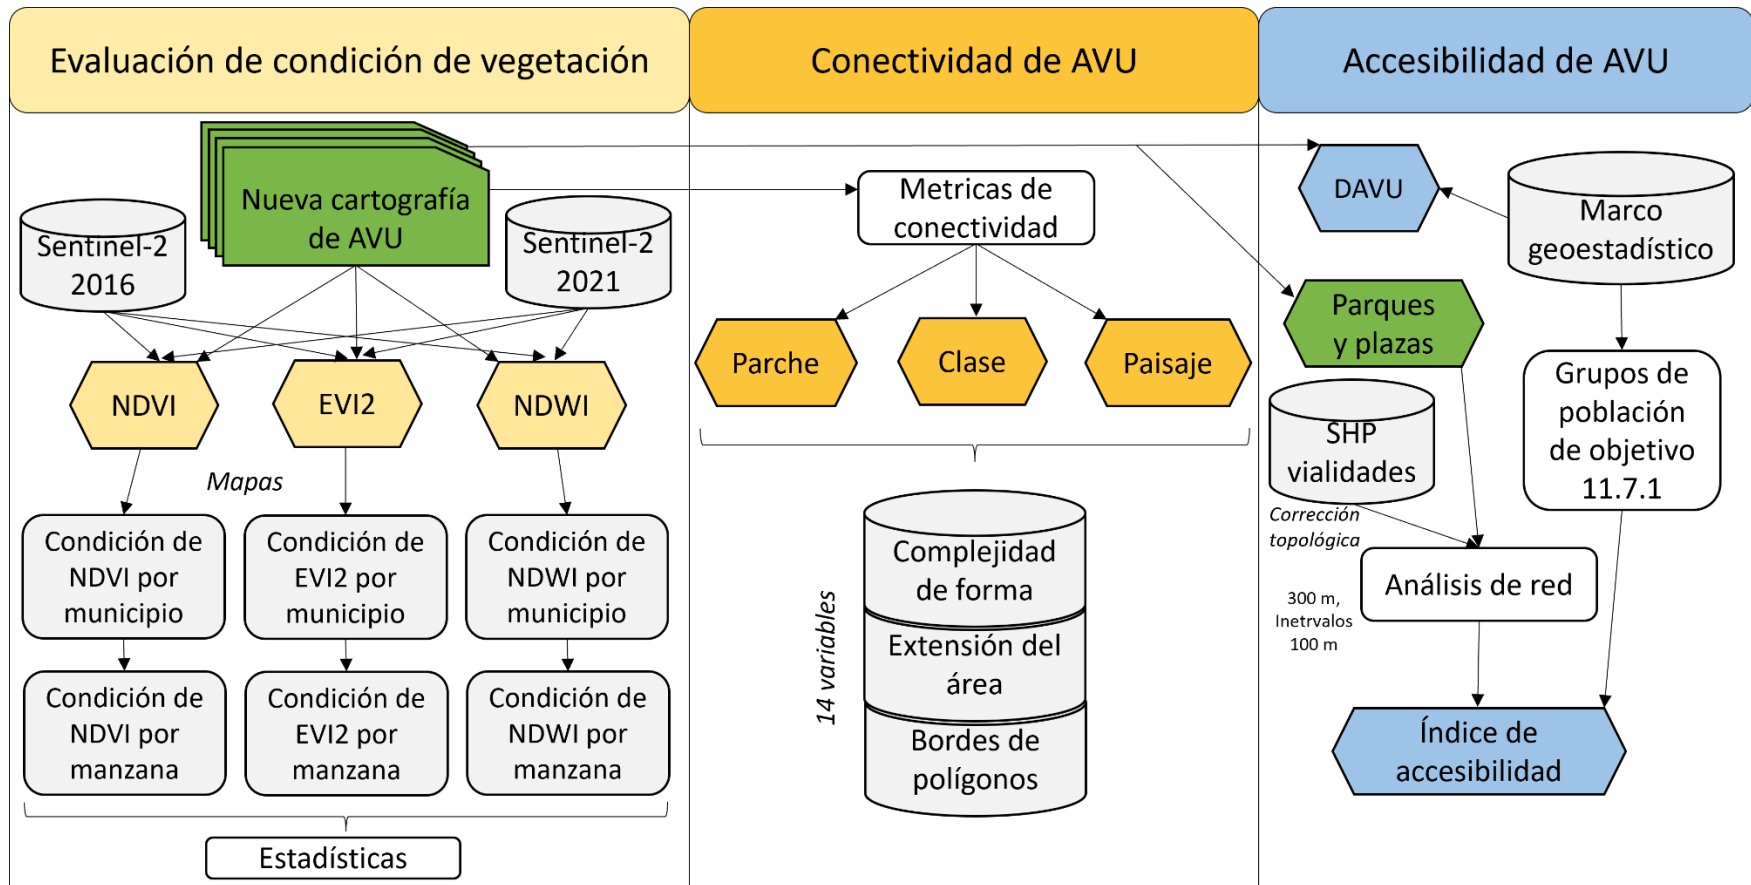


Figura 35. Proceso metodológico seguido en la modelación de la condición, conectividad y accesibilidad de AVU de la ZMM (Elaboración propia).

CAPÍTULO 7. MÉTODO: MODELACIÓN DE AVU.

7.1 Evaluación de la condición de vegetación

7.1.1 Índices de vegetación

Con los resultados obtenidos se trabajó en la elaboración de índices de vegetación para conocer las condiciones de las AVU de la ZMM. Se empleó una imagen satelital de alta resolución procedente de los satélites de la misión Sentinel-2. La imagen que se trabajó se obtuvo en el mes de julio de 2016 y contó con una resolución espacial de 10 m. Se emplearon las bandas necesarias para el cálculo de los índices NDVI, EVI2 y NDWI (Ecuaciones 1, 3 y 4). Previo al cálculo de los índices se realizaron los procesos de calibración radiométrica y corrección atmosférica, a través del entorno SNAP de la Agencia Espacial Europea (Gascon, Ramoino, & Deanos, 2017). Los índices fueron generados a través de la herramienta de calculadora de ráster del software Esri® ArcMap™, ArcGIS para escritorio, en su versión 10.8.1. En su elaboración se realizó un previo recorte a las AVU mediante la herramienta de *Clip* para evitar que píxeles vecinos repercutieran en el resultado y optimizar el procesamiento computacional. Con los índices generados se produjeron mapas de nivel municipal, así como de nivel de manzana.

Dentro de los valores del índice EVI2 se pueden presentar valores anómalos superiores a 1, por causa de superficies altamente radiantes (A. Huete et al., 2002). Sin embargo, al igual que en el NDVI y NDWI, su intervalo oscila dentro del espectro de valores de -1 a 1 (Carvacho & Sánchez Martínez, 2010; Lozoya, Eyzaguirre, Espinoza, Montes-Fonseca, & Rosas-Perez, 2019). Para los tres índices se emplearon los umbrales del método de emisividad desarrollado por Sobrino, Jiménez-Muñoz, & Paolini, (2004) y empleado por Ríos Lizcano, (2019) en su estudio de ecosistemas urbanos del municipio de Monterrey. Los valores menores que 0.2 son considerados como píxeles correspondientes a suelo desnudo lo cual refleja una condición mala, valores de píxel presentes entre 0.2 y 0.5 están compuestos por una mezcla de suelo desnudo y vegetación, presentándose una

condición moderada, y los valores mayores que 0.5 son considerados como superficies totalmente cubiertas por vegetación y por ende, en buena condición.

Finalmente, se extrajo información estadística de los productos a través de la función *isectpolyrst* del software Geoespatial Modelling Environment, en su versión 0.7.3.0. Las métricas obtenidas fueron la media, los valores mínimos, los valores máximos, la desviación estándar, la cantidad de polígonos y la suma de los valores de los píxeles de AVU.

7.1.2 Comparación de condiciones entre los años 2016 y 2021

Aprovechando la temporalidad de la misión Sentinel-2, se obtuvo una imagen satelital de la ZMM correspondiente a julio de 2021 (Figura 31), de características similares a la del análisis de índices de vegetación. Con esto se buscó hacer coincidir la estacionalidad de la imagen del 2021 con la del 2016, para contrastar los resultados y observar los cambios entre las distintas fechas. Al igual que para la imagen del 2016, se calcularon los índices de vegetación NDVI, SAVI y NDWI, y se obtuvieron estadísticas de la media, los valores mínimos, los valores máximos, la desviación estándar, la cantidad de polígonos y la suma de los valores de los píxeles de AVU. Esto permitió visualizar los cambios que han ocurrido en las AVU de la ZMM y la repercusión de las medidas y planes de manejo de AVU que se han llevado a cabo en dicho periodo.

7.2 Conectividad de las AVU

Empleando como entrada la información obtenida de las AVU de la ZMM, se elaboró un modelo de conectividad a través de SIG, que contempló diversas métricas del paisaje para el análisis de la fragmentación. Las métricas se calcularon en niveles de parche, de clase y de paisaje, con la herramienta de *análisis por parche* (Kundu, Halder, & Mandal, 2021; Rempel, Kaukinen, & Carr, 2012) desarrollada por el Centro para la Investigación de Ecosistemas Forestales del Norte para facilitar el cálculo de métricas del paisaje empleando el software de ArcGIS. El listado completo de métricas consiste en 14 variables que se describen en la Tabla 12. El conjunto de métricas se relaciona con aspectos como la complejidad de la forma, la extensión del área y los bordes de los polígonos analizados en el nivel de clase y de paisaje.

Tabla 12. Métricas empleadas para el análisis de conectividad de AVU de la ZMM (Fuente: Rempel et al., 2012).

Análisis de conectividad	
Métrica	Definición
Área de clase (CA)	Suma de áreas de todos los parches pertenecientes a una clase.
Área de paisaje (TLA)	Suma de áreas de todos los parches pertenecientes a un paisaje.
Número de parches (NumP)	Número total de parches en: (1) el paisaje, (2) para cada clase.
Media de tamaño de parche (MPS)	Promedio de tamaño de parche.
Mediana de tamaño de parche (MedPS)	Percentil 50vo del tamaño de parche.
Desviación estándar de tamaño de parche (PSSD)	Desviación estándar de áreas de parches.
Coefficiente de variación de tamaño de parche (PSCoV)	Coefficiente de variación de parches.
Borde total (TE)	Perímetro de parches
Densidad de borde (ED)	Cantidad de borde en relación con el área de paisaje
Media de borde de parche (MPE)	Cantidad promedio de borde por parche.
Mediana de forma de parche (MSI)	Complejidad de forma.
Forma media ponderada por área (AWMSI)	Cuando toma el valor de 1 la forma de los parches es circular, conforme incrementa la forma se vuelve irregular.
Dimensión media del fractal del parche (MPFD)	Complejidad de forma.
Dimensión media ponderada del área de parche fractal (AWMPFD)	Complejidad de forma ajustada para el tamaño de forma.

7.3 Accesibilidad de las AVU

7.3.1 Densidad de las AVU

Tomando como referencia el trabajo de Gutiérrez et al., (2021), previo a la modelación de la accesibilidad se realizó el cálculo de la densidad de las AVU (DAVU). Lo anterior con el fin de determinar la proporción de AVU que provee servicios a los residentes, empleando la unidad de análisis de mayor escala para estudios de población, la manzana. En la Ecuación 10 de Reyes Päcké & Figueroa Aldunce, (2010) se muestra el cálculo empleado.

$$DAVU = \frac{AAVU}{AM} \quad (\text{Ecuación 10})$$

Donde DAVU es la densidad de las AVU, AAVU es la superficie de área de las AVU por manzana y AM es el área total de la manzana correspondiente.

7.3.2 Análisis de red

La generación de datos de muy alta resolución permitió la producción de un índice de accesibilidad que tomó como base las distancias de proximidad con áreas de servicio, como lo son las AVU, permitiendo conocer las rutas que la población puede tomar para el aprovechamiento de sus servicios mediante un trayecto realizado a pie. Los datos de entrada del modelo fueron los polígonos de AVU pertenecientes a las clases de parques y plazas, las manzanas que contenían la información de población perteneciente al Censo de Población y Vivienda 2020 (INEGI, 2020) y las vialidades que conectan ambas capas de información. El análisis se llevó a cabo considerando la población total. Además se obtuvieron indicadores de accesibilidad para los grupos de población incluidos en el objetivo 11.7.1 de los Objetivos de Desarrollo Sostenible, siendo éstos la población femenina, la población masculina, la población de niños de 0 a 14 años, la población de personas de edad de 65 o más años y la población de personas con discapacidad. En este estudio se siguió el método de accesibilidad a las AVU mediante el uso de un análisis de red propuesta por Coombes et al., (2010), e igualmente empleado por Gutiérrez et al., (2021) en el Área Metropolitana de Querétaro. Con este método se hizo empleo de las distancias a través de caminos desde la locación de las manzanas hasta el

centroide del AVU más cercana. Considerando estas mediciones se generaron buffers o amortiguadores que permitieron determinar la proximidad y el acceso a los beneficios proporcionados por las AVU. Siguiendo el método que aplicó previamente Gutiérrez et al., (2021) en una ciudad mexicana, se estableció en 300 m la distancia de traslado máxima a través de las vialidades y se definieron intervalos de accesibilidad cada 100 m. Residentes que se encontraban presentes en una distancia de traslado de 100 m presentaron un alto grado de accesibilidad, seguido por un grado medio para aquellos localizados a 200 m de recorrido y finalmente, con un bajo grado de accesibilidad se consideró a la población presente a una distancia en la red de 300 m. La población no presente en los grupos anteriores correspondió a habitantes con una nula accesibilidad a las AVU, quienes carecen de la opción de trasladarse caminando a la AVU más cercana a sus hogares en un recorrido aceptable, conforme a diversas condiciones de la ciudad, como el calor. El empleo de este tipo de métodos evita realizar la sobreestimación de accesibilidad generada por el uso de mediciones euclidianas de punto a punto.

Para este análisis se empleó la extensión de *análisis de red* presente dentro del programa computacional ArcGIS. Previo al ingreso de la capa de vialidades fue necesario generar los accesos a las AVU. Para lo anterior se trabajó con técnicas de fotointerpretación para el trazado manual de rutas de acceso, en los casos que aplicara, desde los 4 puntos cardinales, así como puntos intermedios y, calles y avenidas que conectaran con los bordes de las AVU, hasta su centroide. Hecho lo anterior, fue necesario realizar la corrección de la topología de dicha información. En esta fase se encontraron 14,902 errores (Figura 36), de los cuales 11,424 correspondieron a errores que no debían tener arcos colgantes, 3,284 que no debían tener pseudonodos, 179 que no se debían intersecar, 7 que no se debían sobreponer, 3 que no se debían intersecarse a sí mismos, 3 que no se debían sobreponerse a sí mismos y 2 que debían ser partes individuales (Figura 37). El producto del análisis de red fue transferido a la capa de manzanas de la ZMM, mediante un proceso de unión espacial, en el que se asignó el grado de accesibilidad de los habitantes de cada manzana respecto al intervalo con el que tuviera mayor traslape.

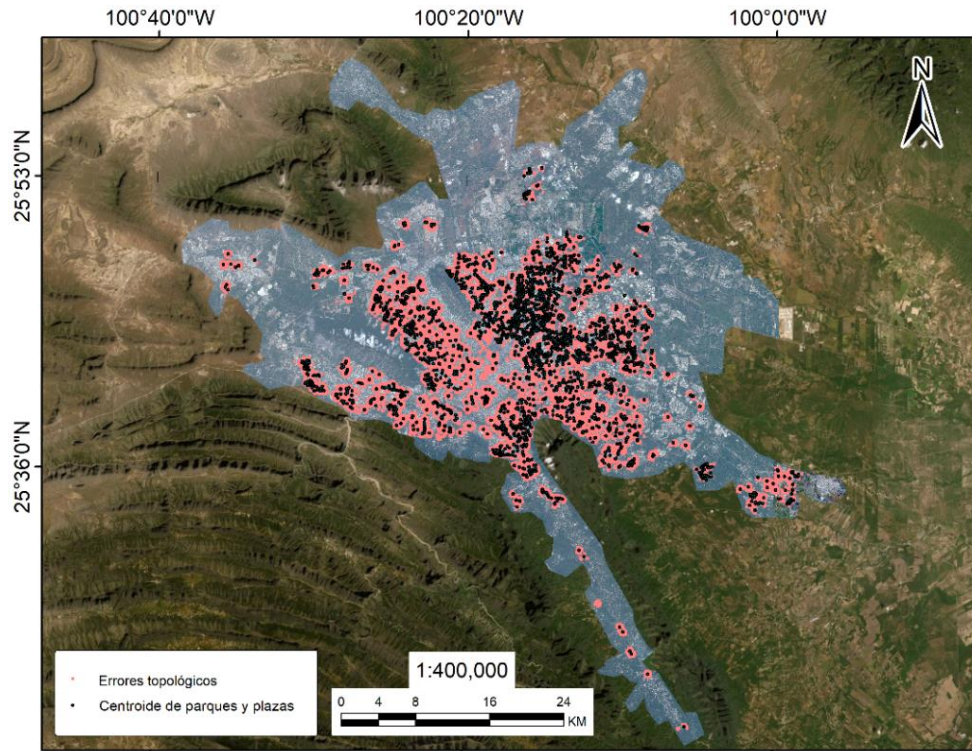


Figura 36. Errores topológicos y centroides de parques y plazas (Elaboración propia)

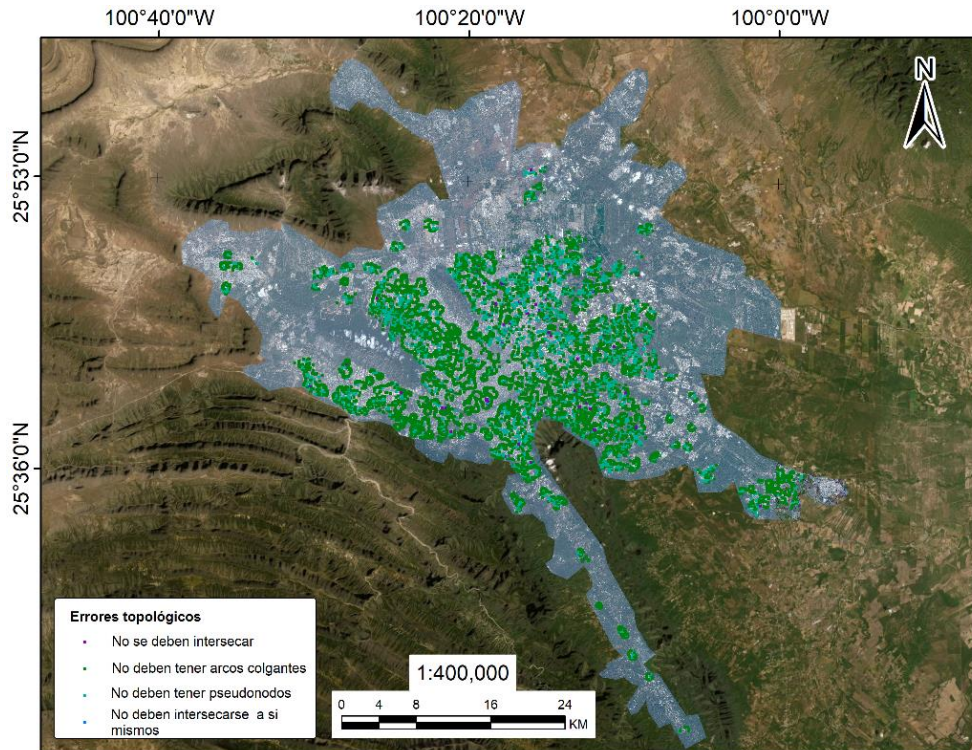


Figura 37. Errores topológicos por tipo (Elaboración propia).

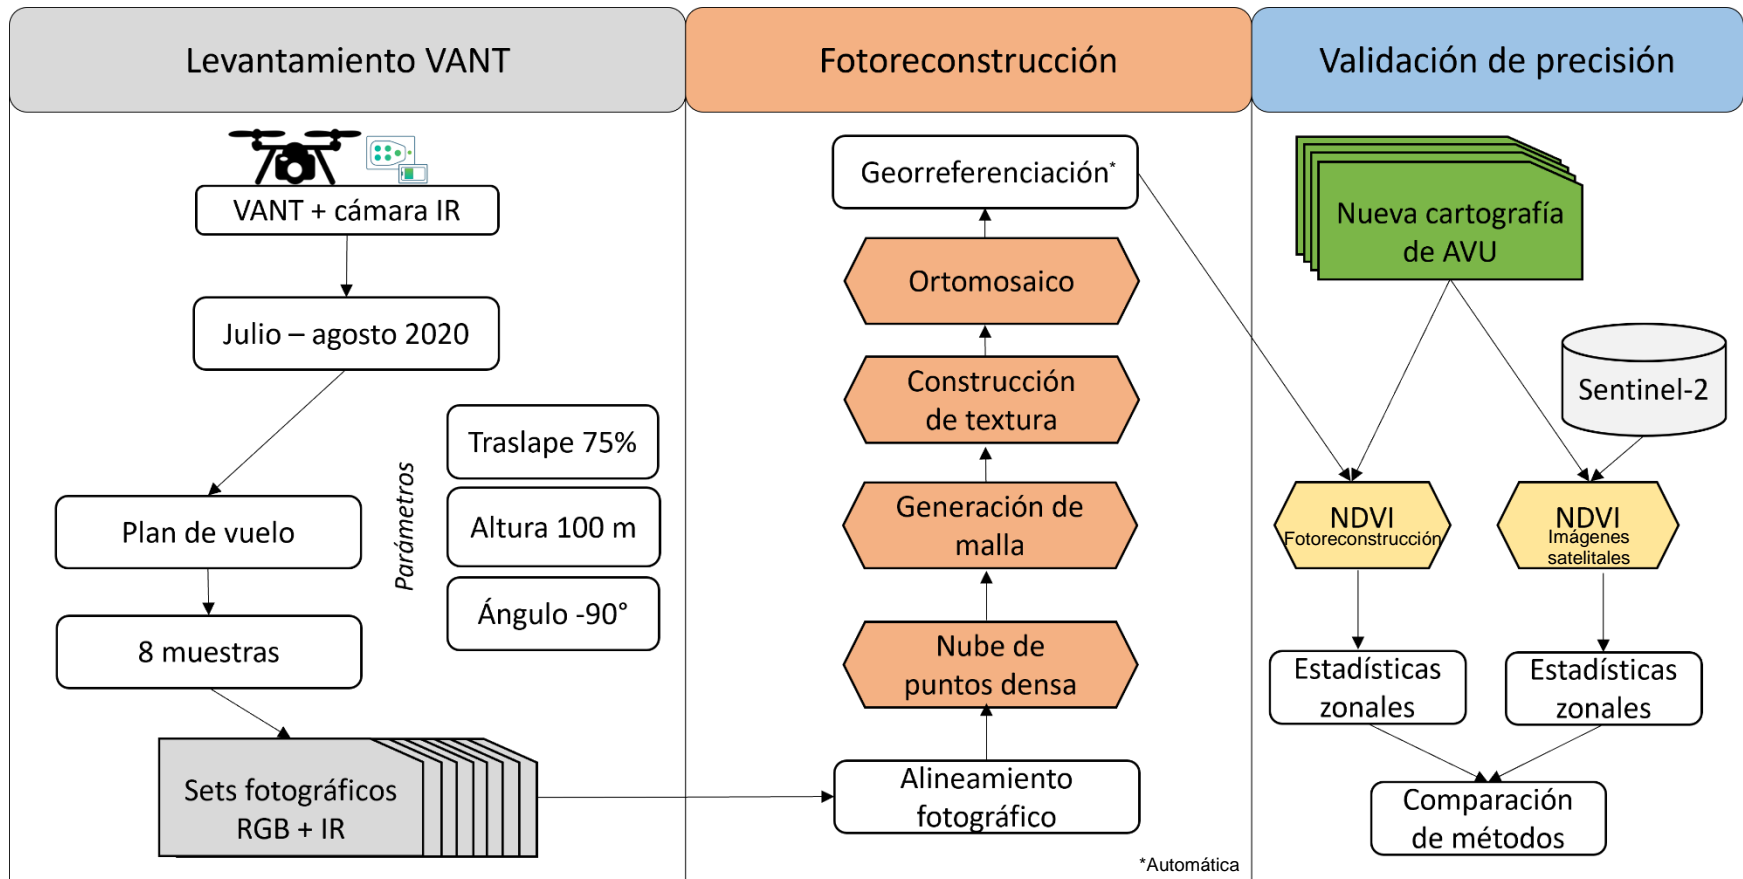


Figura 38. Proceso metodológico seguido en la validación de la precisión de la metodología empleada (Elaboración propia).

CAPÍTULO 8. MÉTODO: VALIDACIÓN DE PRECISIÓN

8. Validación de precisión

Se llevó a cabo el levantamiento de información a través del uso de VANT para la toma de fotografías aéreas, las cuales fueron procesadas a través de técnicas de structure from motion (SFM) para la reconstrucción y generación de modelos de alta resolución, como los generados en el trabajo de Huerta-García et al., (2018). Lo anterior se realizó con el fin de obtener datos de muy alta resolución que permitieran validar los resultados obtenidos mediante la segmentación semántica y la modelación de las AVU de la ZMM.

Los levantamientos se realizaron entre los meses de julio y de agosto del año 2020, coincidiendo con la temporada del año para la cual se obtuvieron las imágenes satelitales WorldView-2 empleadas para el entrenamiento de la RNC y las imágenes Sentinel-2 utilizadas para el análisis de la condición de las AVU, a través del uso de índices de vegetación. Debido a las limitaciones operacionales del equipo y de los insumos necesarios para el traslado a los sitios de muestreo, el proceso de evaluación se limitó a los municipios de San Nicolás de los Garza y de Escobedo, donde se obtuvieron 8 muestras aleatorias (Figura 39), para las cuales se realizó el levantamiento con VANT, fotoreconstrucción, y se elaboró el índice NDVI que sirvió para validar los resultados de los análisis previos mediante estadísticas zonales.

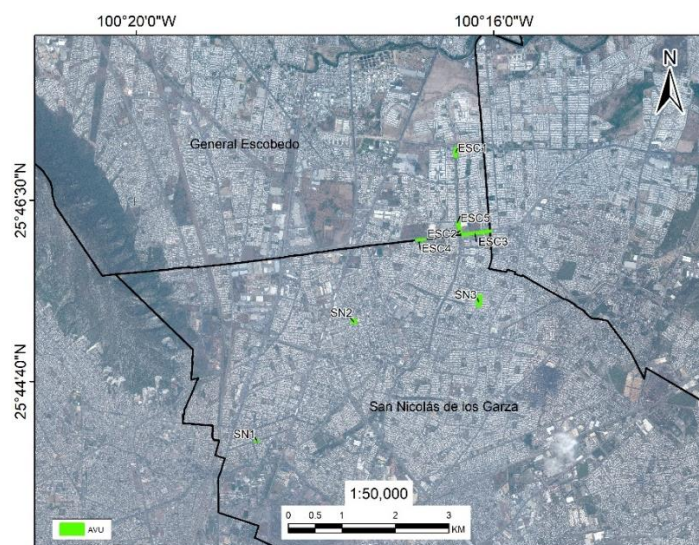


Figura 39. Puntos de muestreo de AVU con equipo VANT (Elaboración propia).

El VANT empleado para esta tarea fue un DJI Phantom 4 Pro y las características de la aeronave se detallan en la Tabla 13. Se obtuvo información espectral a partir de una cámara RGB que forma parte del VANT y mediante el montaje de una cámara multispectral Parrot Sequoia+ en el equipo, la cual permitió obtener información de las AVU correspondiente a la banda del infrarrojo cercano del espectro electromagnético. En la Tabla 14 se pueden encontrar las especificaciones sobre ambos sensores.

Tabla 13. Especificaciones de DJI Phantom 4 Pro (Elaboración propia a partir de especificaciones presentes en <https://www.dji.com/mx/phantom-4-pro/>).

Características VANT DJI Phantom 4 Pro	
Peso	1,388 g
Tamaño	350 mm
Tiempo de vuelo máximo	~ 30 min.
Rango de temperatura de funcionamiento	0 a 40 °C
Sistemas de posicionamiento satelital	GPS / GLONASS
Altura máx. sobre el nivel del mar	6,000 m

Los planes de vuelo constaron de un traslape del 75 % en los ejes XY y una altura fija a 100 m sobre el nivel del suelo. Ambos sensores se fijaron a un ángulo de -90° con el fin de que su objetivo se mantuviera en la superficie de las AVU. Se empleó el software Agisoft Photoscan Professional, en su versión de prueba, para la reconstrucción de nubes de puntos que permitieron generar los ortomosaicos de ultra alta resolución de las áreas muestreadas. Debido a que las imágenes empleadas en el proceso contaron con la información de ubicación geográfica, gracias a la unidad GPS presente en el VANT, fue posible omitir el paso correspondiente a la georreferenciación de los datos producidos.

La información generada se empleó para realizar análisis de las condiciones de vegetación de las áreas seleccionadas y validar los resultados obtenidos en fases anteriores a través de su contraste por medio de estadísticas zonales.

Tabla 14. Especificaciones de sensores para el levantamiento de AVU de ZMM (Elaboración propia a partir de especificaciones presentes en <https://www.dji.com/mx/phantom-4-pro/> y <http://www.sensefly.com/parrot-sequoia>).

Especificaciones	Sensor RGB de DJI Phantom 4 Pro	Parrot Sequoia+
Sensor	1" CMOS	Multiespectral + RGB
Multiespectral	Cámara RGB	4-bandas: Verde (550nm ± 40nm), rojo (660nm ± 40nm), rojo borde (735nm ± 10nm), infrarrojo cercano (790nm ± 40n)
Píxeles efectivos	20 M	16 M (RGB), 1.2 M (Multiespectral)
FOV	84° 8.8 mm / 24 mm	RGB HFOV: 64° VFOV: 50° DFOV: 74° Multiespectral HFOV: 62° VFOV: 49° DFOV: 74°

RESULTADOS

CAPÍTULO 9. RESULTADOS: SEGMENTACIÓN SEMÁNTICA.

9.1 Pre-procesamiento de datos

Se generó una base de datos mediante los procesos de reclasificación, descarte de polígonos duplicados y fusión de las tres bases de datos de entrada. En la Tabla 15 se muestran las estadísticas de la cantidad de polígonos, el área de cobertura y la proporción de presencia de cada clase de AVU analizada. La proporción de cobertura total que abarcaron las AVU en conjunto representó un 3.003%, siendo la clase de parques la que presentó mayor representación en el área de estudio, con una cobertura del 1.8% del territorio. La clase con menor presencia en la ZMM fue la de las glorietas, con una proporción de cobertura del 0.001%.

Tabla 15. Estadísticas de clases de AVU en ZMM (Fuente: Huerta et al., 2021).

Tipo de AVU	Polígonos	Área de AVU (m ²)	Proporción (%)
Camellón	19,869	1,141,179	0.843
Jardín residencial	1,818	463,314.5	0.342
Glorietas	61	810	0.001
Plazas	58	14,076	0.010
Parques	2,861	2,446,925	1.807
TOTAL	24,667	4,066,304.5	3.003

El ráster producido a partir de los vectores de las bases de datos se muestra en el mapa de la Figura 31. En color negro se aprecian los píxeles correspondientes a la ausencia de AVU, mientras que en color verde se destaca la presencia de AVU.

Tanto el ráster de AVU como las 13 composiciones de bandas generadas fueron fragmentados para elaborar el conjunto de datos de entrada de la RNC. En la Figura 40 se muestra un ejemplo de fragmentación de la combinación de bandas RGB y sus etiquetas correspondientes.




Figura 40. Ejemplo de muestra producida en proceso de fragmentación. Los polígonos en amarillo representan camellones y el verde un parque (Elaboración propia).

9.2 Implementación de modelo de RNC

La técnica del aumento de datos ayudó a incrementar la cantidad de información de entrada para el proceso de entrenamiento de la RNC. Mediante su empleo, el número de mosaicos aumentó de 24,667 a 1,480,020.

En la Tabla 16 se muestran los mejores resultados del coeficiente Dice y la precisión obtenidos en ambas modelaciones (ResNet34 y ResNet50) de la segmentación semántica para cada una de las 12 composiciones de 3 bandas. La composición de las bandas NDVI-roja-IRC obtuvo el mejor desempeño en la modelación con el codificador ResNet34, obteniendo valores de coeficiente Dice de 0.5748 y precisión de 0.9503. En cuanto al modelo con el codificador ResNet50, la composición roja-verde-azul logró los mejores resultados, con un coeficiente Dice de 0.4378 y una precisión de 0.9849. Para el modelo del codificador ResNet34, la media del coeficiente Dice de todas las combinaciones resultantes fue de 0.49, con una desviación estándar de 0.09 y su significancia estadística considerando intervalos de confianza de 95% se encontró en el intervalo de valores de 0.45 a 0.55. Para el modelo del codificador ResNet50, la media del coeficiente Dice fue de 0.42, con desviación estándar de 0.058 y su significancia estadística considerando intervalos de confianza de 95% se presentó en el intervalo de 0.28 a 0.36.

En la Figura 41 se muestra el comportamiento obtenido a lo largo del proceso de entrenamiento y validación de los modelos con mejor desempeño. Para el modelo

con codificador ResNet34 se corrieron 100 épocas, que presentaron fluctuaciones entre los valores de 0.45 y 0.63, observándose el valor más elevado en la época número 83, en la que se obtuvo un valor de coeficiente Dice de 0.5748. Por otro lado, el modelo con codificador ResNet50 fue corrido a través de 10 épocas, en las que se obtuvo el valor más alto de coeficiente Dice en la 4ta época, siendo de 0.4378.

Tabla 16. Estadísticas de clases de AVU en ZMM (Fuente: Huerta et al., 2021).

Composiciones de bandas	ResNet34		ResNet50	
	Coefficiente Dice	Precisión	Coefficiente Dice	Precisión
EVI2–NDWI–IRC	0.1940	0.8853	0.2231	0.9065
EVI2–NDWI–roja	0.4961	0.9337	0.2543	0.9147
EVI2–roja–IRC	0.5113	0.942	0.3199	0.9145
NDVI–EVI2–IRC	0.5307	0.9437	0.2698	0.9074
NDVI–EVI2–roja	0.5021	0.9452	0.3356	0.9227
NDVI–NDWI–roja	0.5248	0.9433	0.3187	0.9115
NDVI–EV2–NDWI	0.4617	0.9347	0.3548	0.9249
NDVI–NDWI–IRC	0.4886	0.9377	0.2763	0.9369
NDVI–roja–IRC	0.5748	0.9503	0.3149	0.9004
NDWI–roja–IRC	0.5702	0.9505	0.3610	0.9200
roja–verde–azul	0.4638	0.9792	0.4378	0.9839
verde–roja–IRC	0.5193	0.9547	0.3663	0.9322

Conforme el valor de pérdida disminuye se obtienen mejores resultados en la segmentación. Ejemplos de lo anterior se muestran en la Figura 42, en la que se observa cómo conforme disminuye la pérdida, mejora el proceso de aprendizaje en la segmentación de la composición NDVI-roja-IRC con el codificador ResNet34 (Figura 42A-D), así como en la segmentación de la composición roja-verde-azul con el codificador ResNet50 (Figura 42E-H).

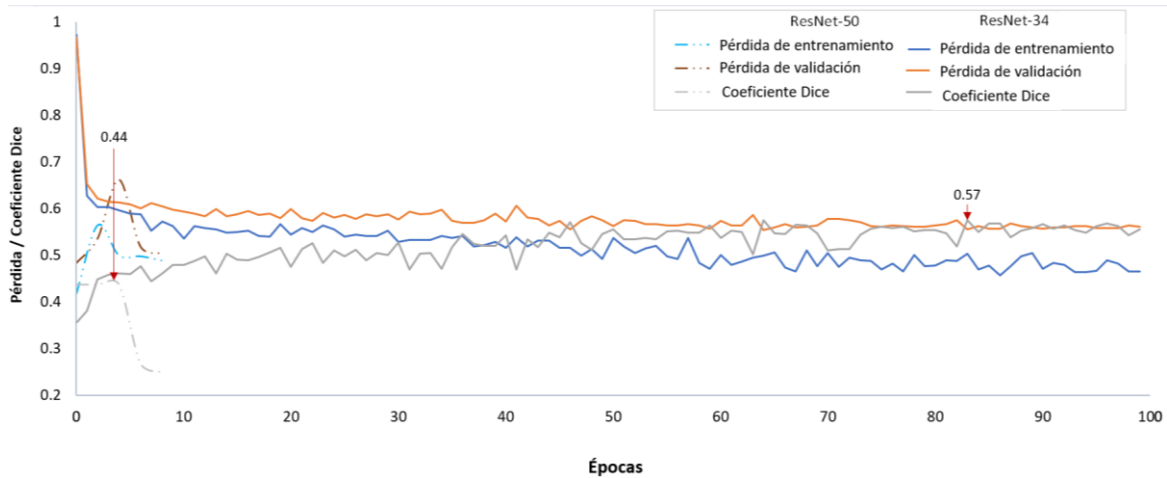


Figura 41. Gráfica de pérdida de entrenamiento, pérdida de validación y coeficiente Dice para los codificadores ResNet34 y ResNet50 (Fuente: Huerta et al., 2021).

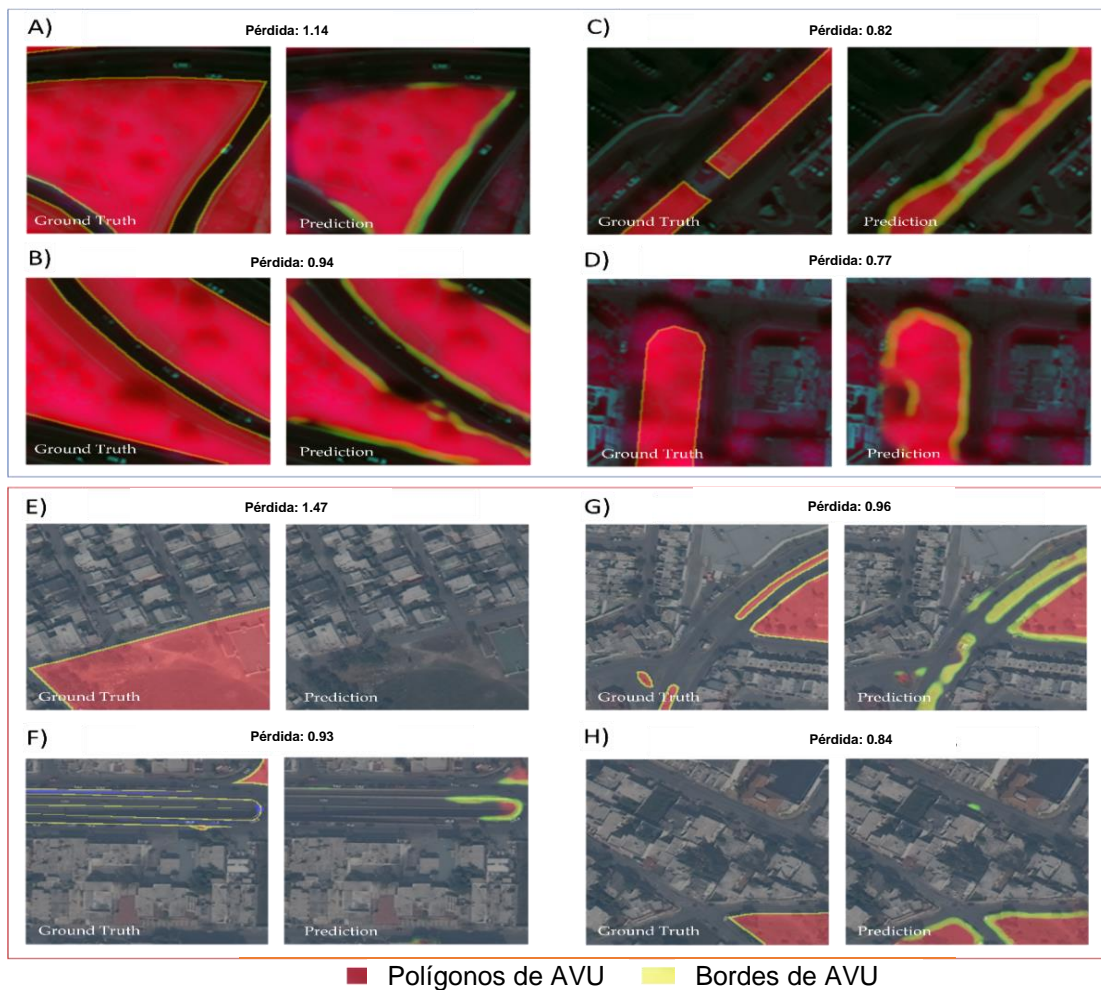


Figura 42. Aprendizaje en modelación de segmentación. (A-D) Muestras de ResNet34. (E-H) Muestras de ResNet50 (Fuente: Huerta et al., 2021).

La evaluación de la segmentación semántica de las AVU de la ZMM se realizó para la combinación de bandas con mejor desempeño, siendo la composición de NDVI-roja-IRC. Los resultados del análisis IoU arrojaron un valor de 0.75. En la Figura 43 se muestra la información empleada para su cálculo, además del análisis de traslape.

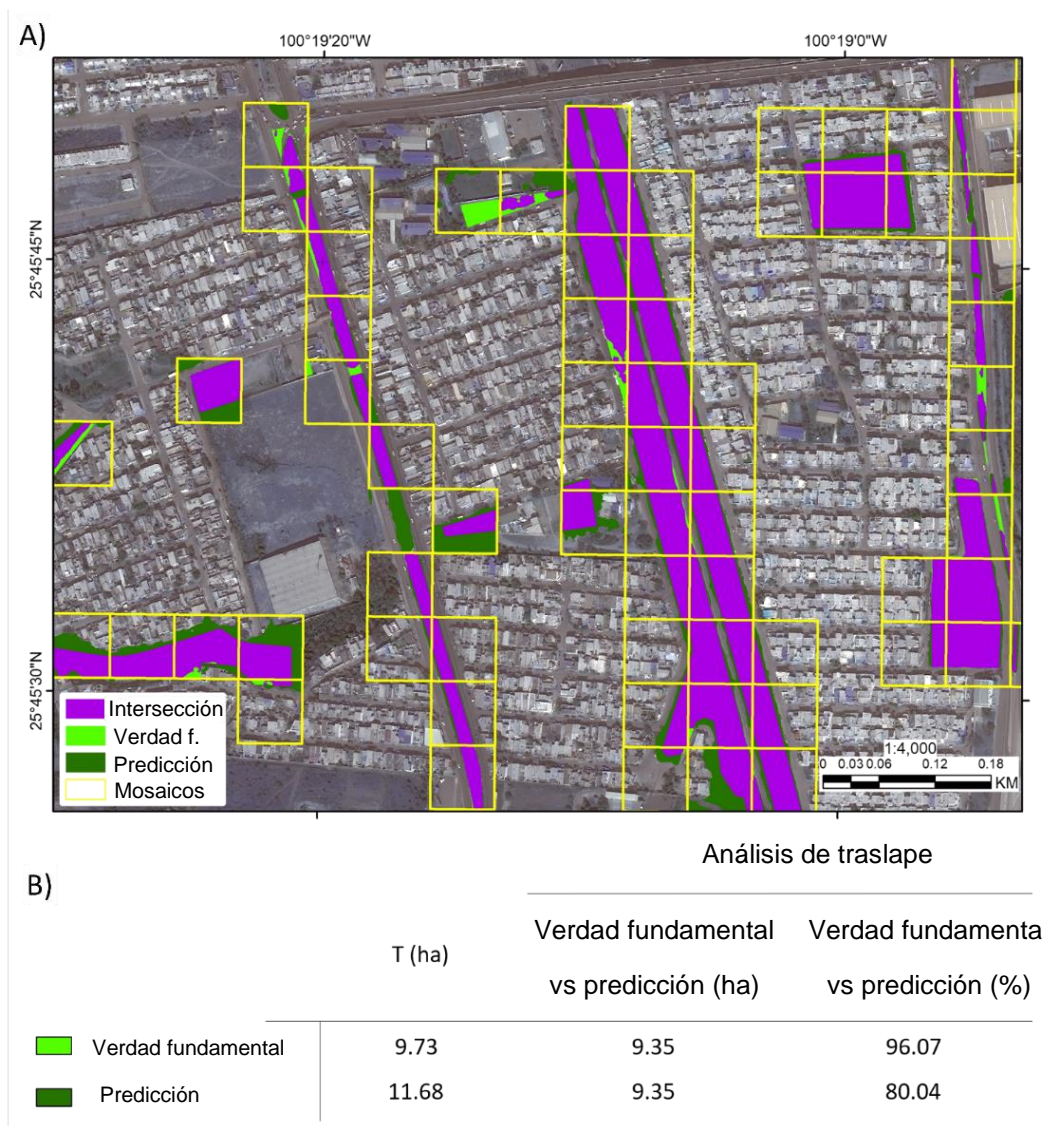


Figura 43. Modelo de evaluación. (A) Cobertura de traslape entre polígonos producidos por modelo de RNC y polígonos de las etiquetas que representan la verdad fundamental. (B) Análisis de traslape. T es la cobertura total. Las columnas de la verdad fundamental vs predicción muestran el área en hectáreas y en proporción de positivos identificados correctamente (Fuente: Huerta et al., 2021).

Los resultados de la evaluación mediante la elaboración de la matriz de confusión y el coeficiente Kappa se muestran en la Tabla 17. Tanto la capa de las predicciones como la verdad fundamental contenían polígonos correspondientes a las clases mayormente presentes en la ZMM, parques y camellones. El coeficiente Kappa resultante fue de 0.94 y la precisión general fue de 0.97. La precisión de usuario fue de 1 para los parques mientras que para los camellones resultó en 0.96. La precisión de productor fue de 0.92 en el caso de los parques y se obtuvo un valor de 1 para los camellones.

Tabla 17. Matriz de confusión y coeficiente Kappa (Fuente: Huerta et al., 2021).

	Parques	Camellones	Total	Precisión de usuario	Coeficiente Kappa
Parques	684	0	684	1	0
Camellones	58	1258	1316	0.96	0
Total	742	1258	2000	0	0
Precisión de productor	0.92	1	0	0.97	0
Coeficiente Kappa	0	0	0	0	0.94

CAPÍTULO 10. RESULTADOS: MODELACIÓN DE AVU.

10.1 Evaluación de condición de la vegetación

En las Figuras 44 – 55 se muestran los mapas de las condiciones de la vegetación de la ZMM generados tanto en el nivel municipal como en el nivel de manzana. Los mapas se elaboraron partiendo de los resultados de los índices de vegetación NDVI, EVI2 y NDWI obtenidos mediante las imágenes Sentinel-2 de julio de 2016 y junio de 2021. Las estadísticas de los índices obtenidas para cada uno de los municipios se muestran en los Anexos I y II.

De acuerdo con los resultados observados en el mapa del índice de NDVI en el nivel municipal de 2016 (Figura 44), la tendencia correspondió a una mala condición de la vegetación, con excepción de los municipios de Guadalupe, San Pedro Garza García y Santiago, que presentaron condiciones moderadas. En contraste, el índice EVI2 que se obtuvo con las imágenes Sentinel-2 de 2016 (Figura 45) mostró una constante de condiciones moderadas, exceptuando por el municipio de San Pedro Garza García, que presentó una buena condición, y, García y Salinas Victoria que poseían malas condiciones. El análisis de las condiciones hídricas de la vegetación a través del índice NDWI en las imágenes del 2016 (Figura 46) mostró malas condiciones en general para la ZMM. En cuanto a los análisis elaborados para la capa de manzanas, el índice NDVI (Figura 47) arrojó para ese año condiciones que iban de moderadas a malas. El índice EVI2 (Figura 48) presentó resultados de condiciones buenas a moderadas en la mayoría de las manzanas correspondientes a los municipios de San Pedro Garza García, San Nicolás de los Garza, Apodaca, y Guadalupe, así como en la zona sur de Monterrey. Continuando la tendencia municipal, en el nivel de manzana también se mostraron malas condiciones hídricas para toda la ZMM a través del mapa del índice NDWI (Figura 49).

En el nivel municipal, el índice de NDVI elaborado para 2021 (Figura 50) mostró mejoras en las condiciones, pasando de malas a moderadas, en los municipios de San Nicolás de los Garza, General Escobedo, Apodaca, Monterrey, Juárez y Cadereyta Jiménez. De igual forma, el índice EVI2 (Figura 51) reflejó mejoras en

las condiciones de los municipios de Apodaca, San Nicolás de los Garza, Guadalupe, Juárez, Cadereyta y Santiago, que pasaron de presentar una condición moderada a una condición buena; así como en García y Salinas Victoria que ascendieron a presentar condiciones moderadas. Respecto al índice NDWI (Figura 52), no se observó cambio, manteniendo una mala condición, a pesar del lapso de un lustro. En el análisis NDVI realizado por manzana para el año 2021 (Figura 53), con excepción del municipio de San Pedro Garza García, que destacó con buenas condiciones, se observó de manera general una condición moderada para toda la ZMM. El análisis del índice EVI2 en el nivel de manzana, en 2021 (Figura 54) mostró que los municipios de San Pedro Garza García, San Nicolás de los Garza, Apodaca, Guadalupe y la zona sur de Monterrey presentaron predominantemente buenas condiciones. El índice NDWI mantuvo condiciones malas (Figura 55).

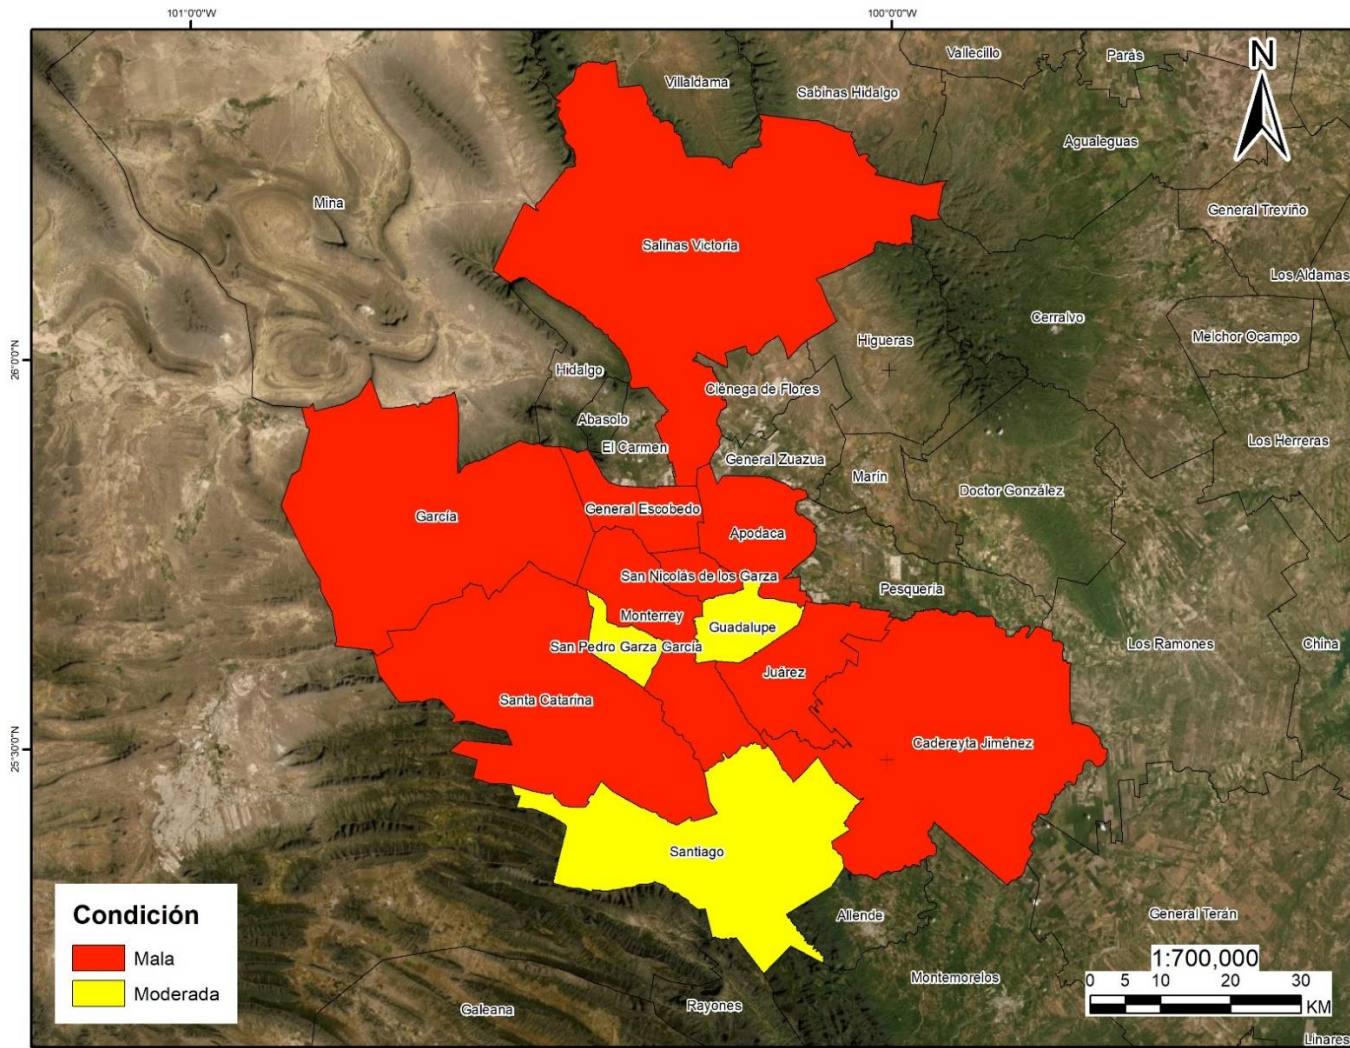


Figura 44. Condición de vegetación de AVU, de acuerdo con la media de valores del índice NDVI calculado para los municipios de la ZMM al año 2016 (Elaboración propia).

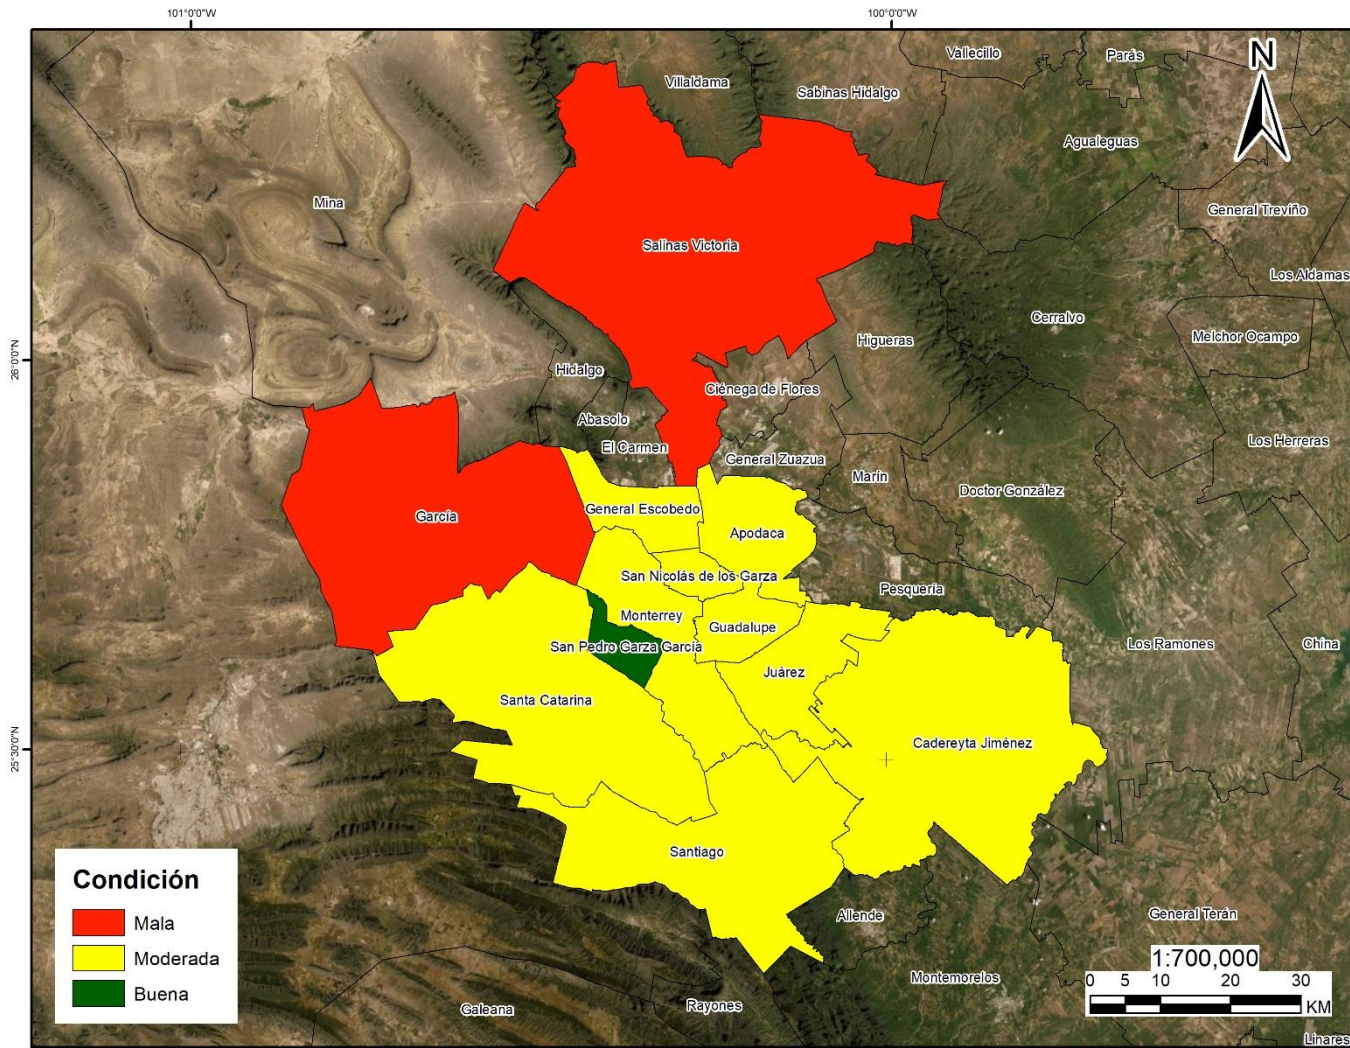


Figura 45. Condición de vegetación de AVU, de acuerdo con la media de valores del índice EVI2 calculado para los municipios de la ZMM al año 2016 (Elaboración propia).

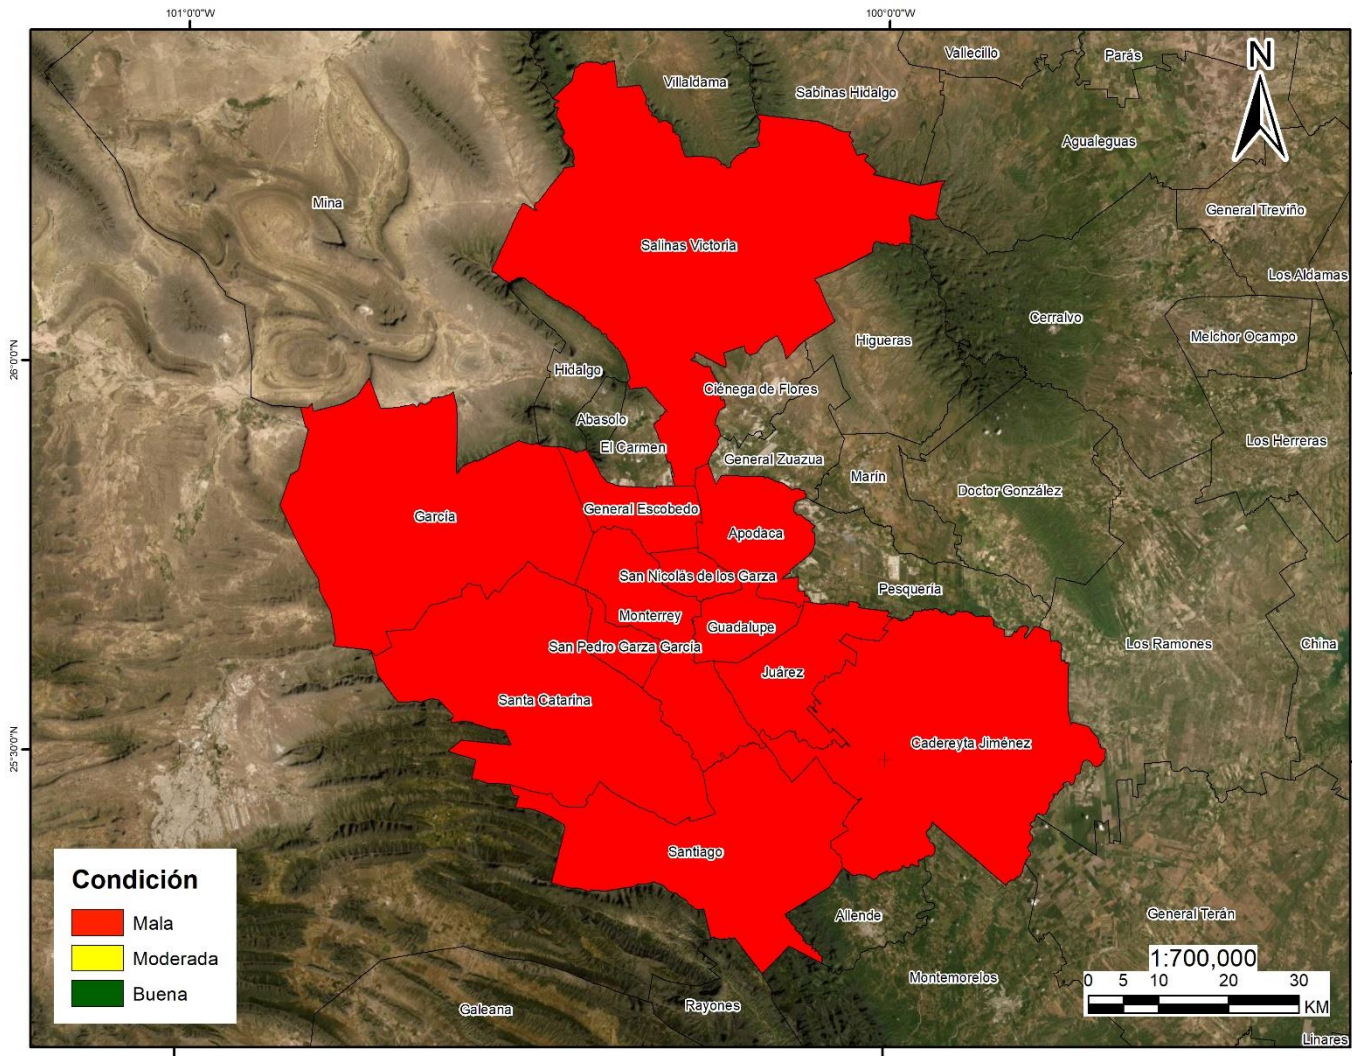


Figura 46. Condición de vegetación de AVU, de acuerdo con la media de valores del índice NDWI calculado para los municipios de la ZMM al año 2016 (Elaboración propia).

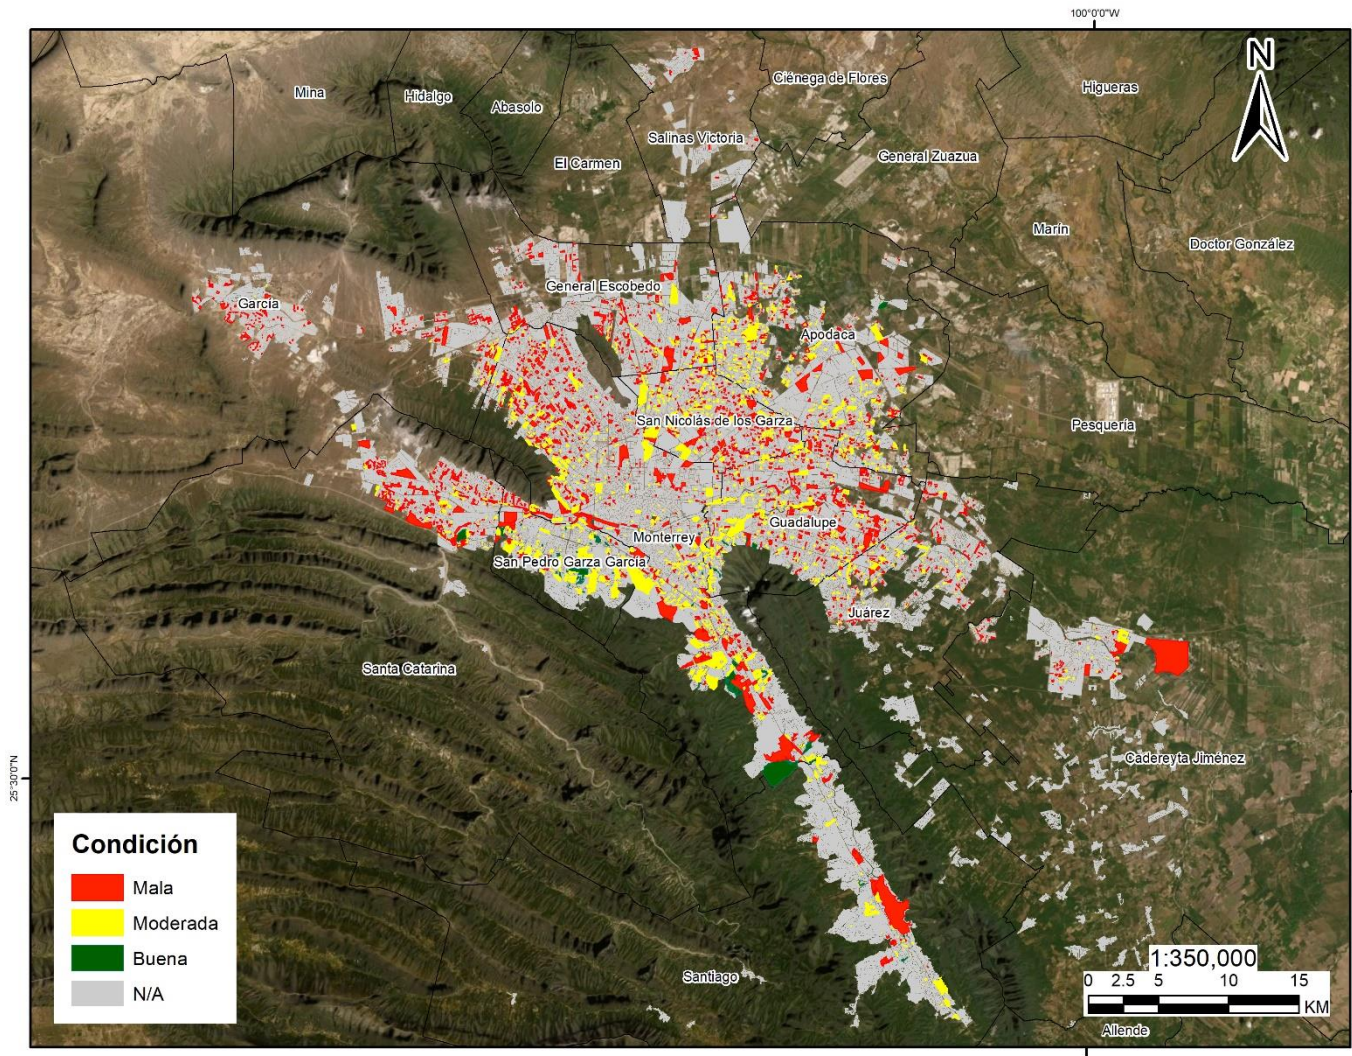


Figura 47. Condición de vegetación de AVU, de acuerdo con la media de valores del índice NDVI calculado para las manzanas de la ZMM al año 2016 (Elaboración propia).

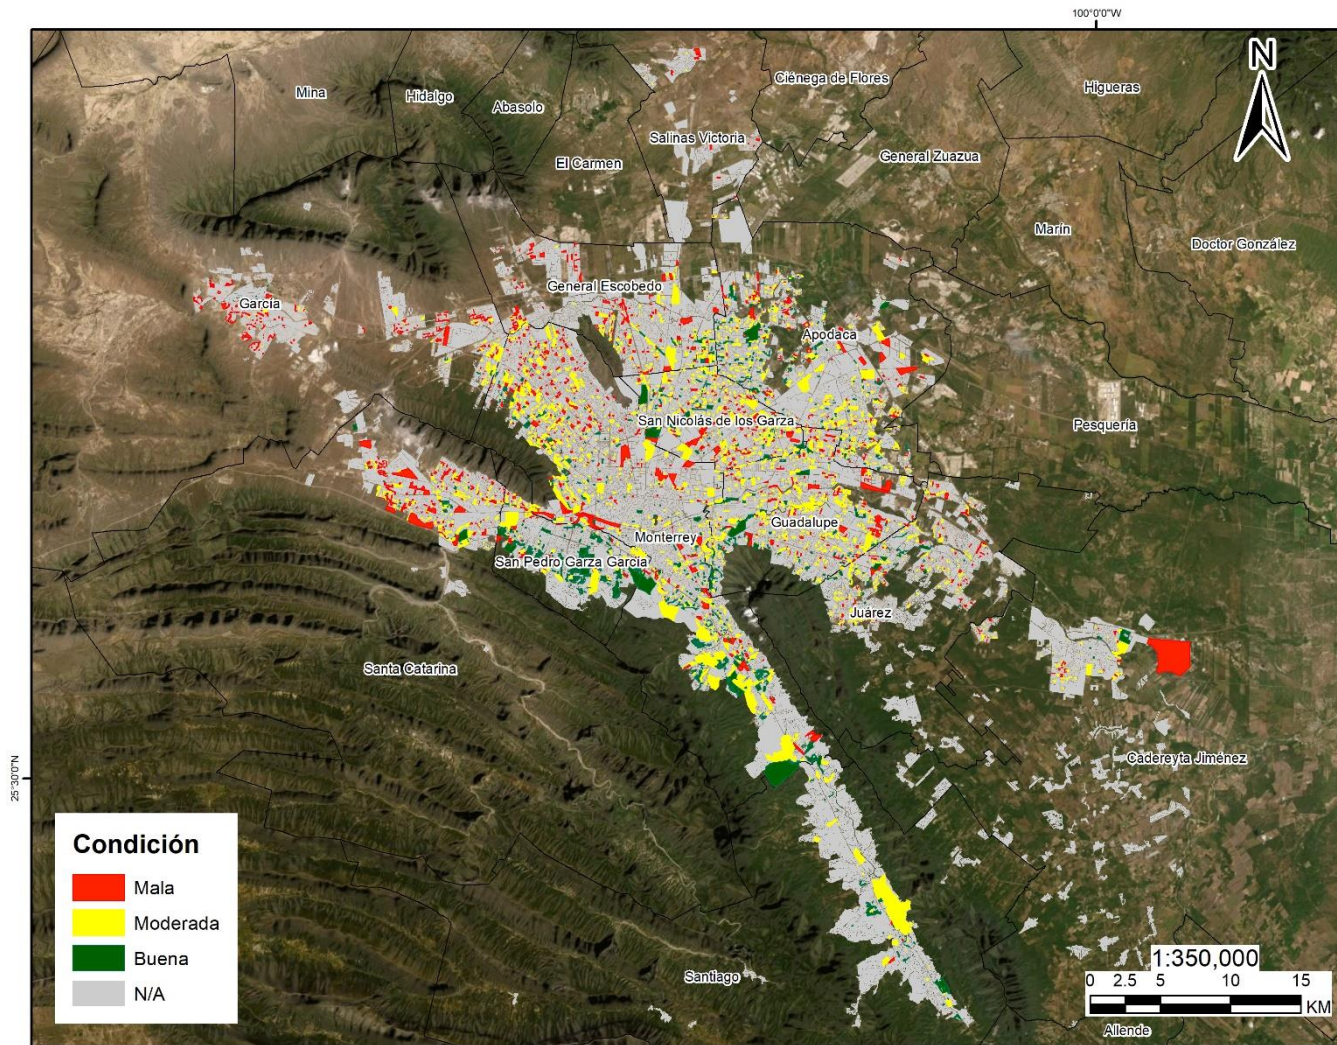


Figura 48. Condición de vegetación de AVU, de acuerdo con la media de valores del índice EVI2 calculado para las manzanas de la ZMM al año 2016 (Elaboración propia).

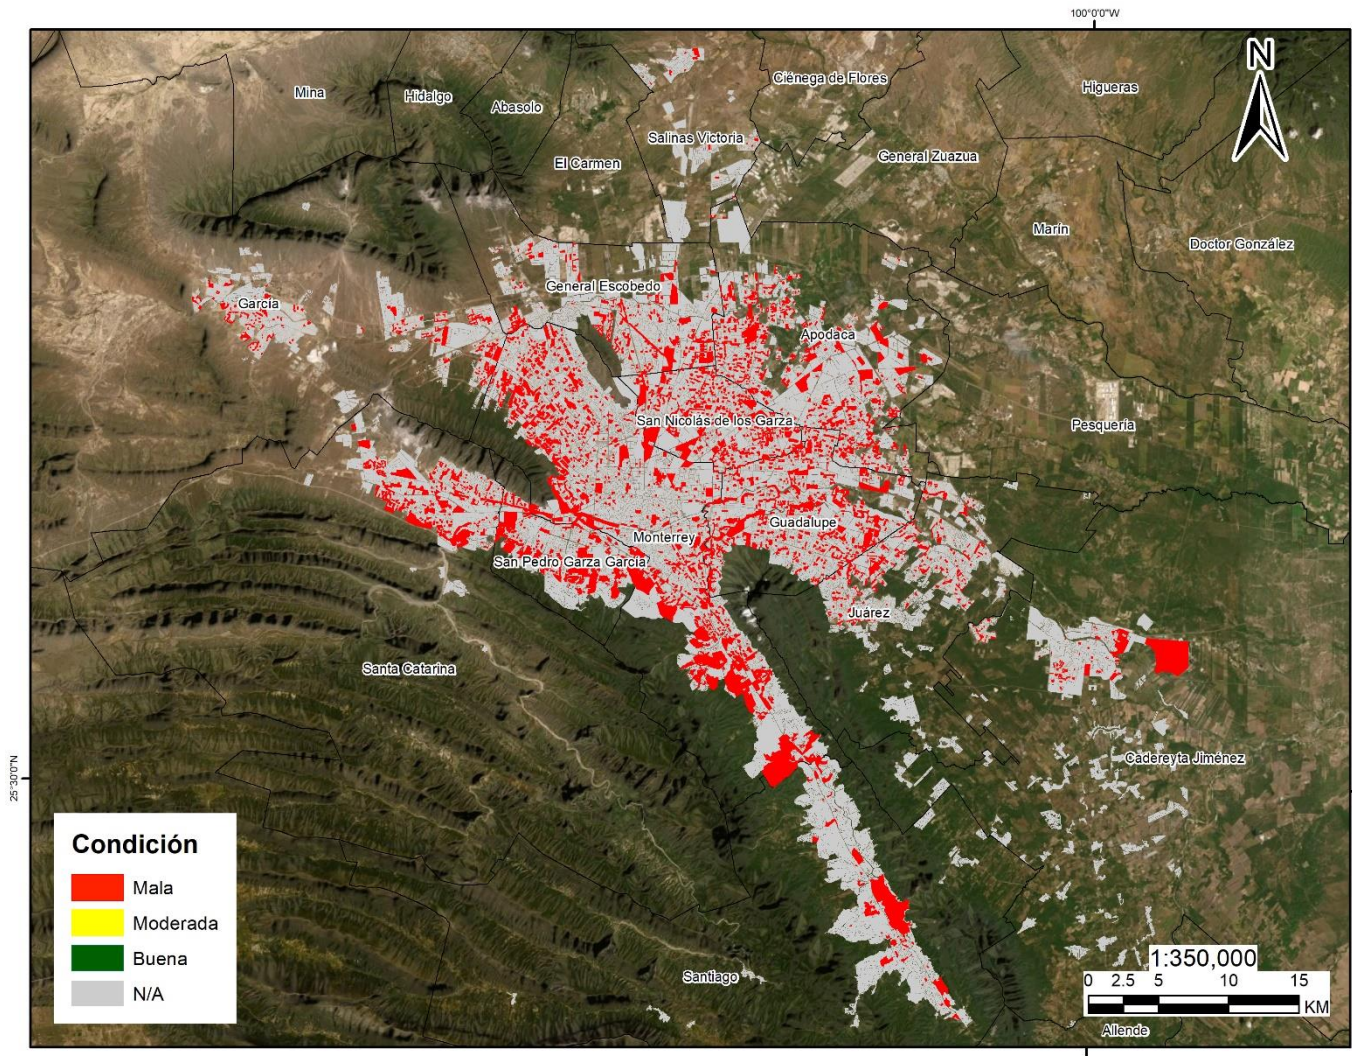


Figura 49. Condición de vegetación de AVU, de acuerdo con la media de valores del índice NDWI calculado para las manzanas de la ZMM al año 2016 (Elaboración propia).

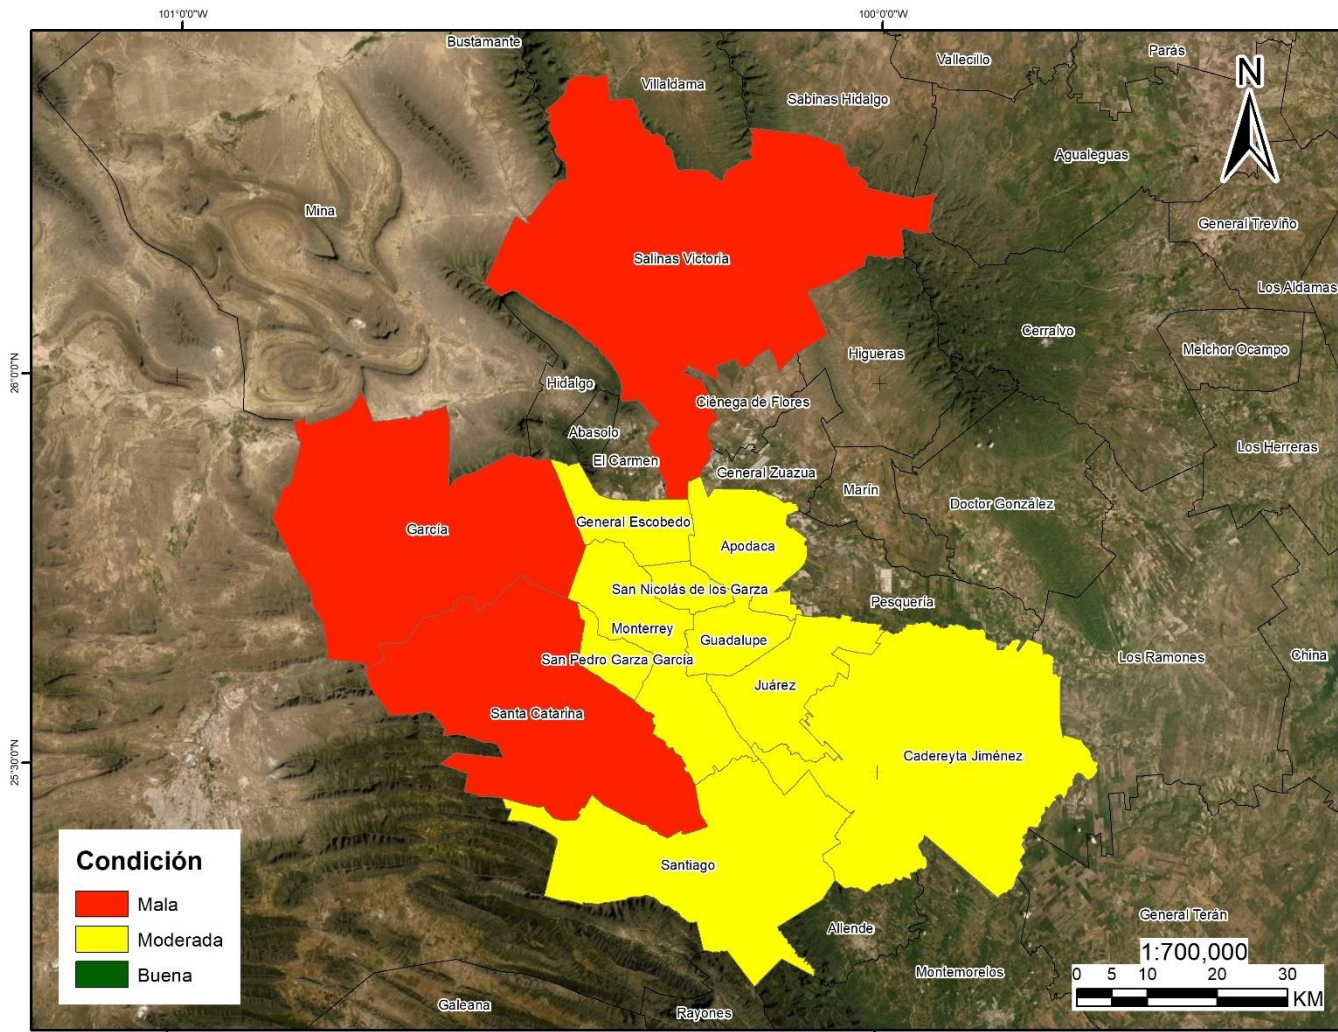


Figura 50. Condición de vegetación de AVU, de acuerdo con la media de valores del índice NDVI calculado para los municipios de la ZMM al año 2021 (Elaboración propia).

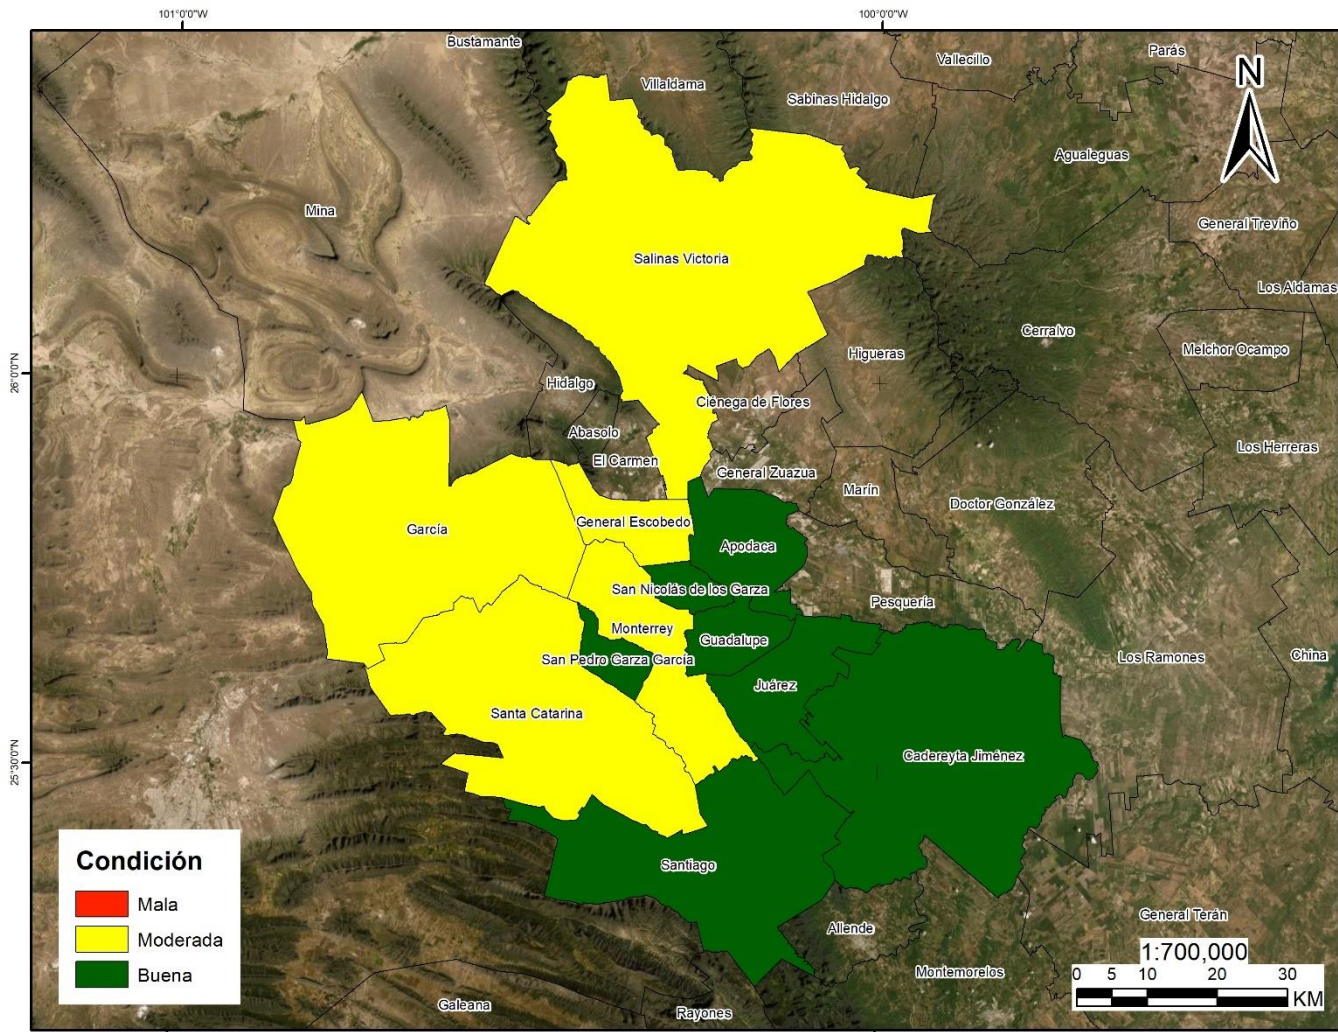


Figura 51. Condición de vegetación de AVU, de acuerdo con la media de valores del índice EVI2 calculado para los municipios de la ZMM al año 2021 (Elaboración propia).

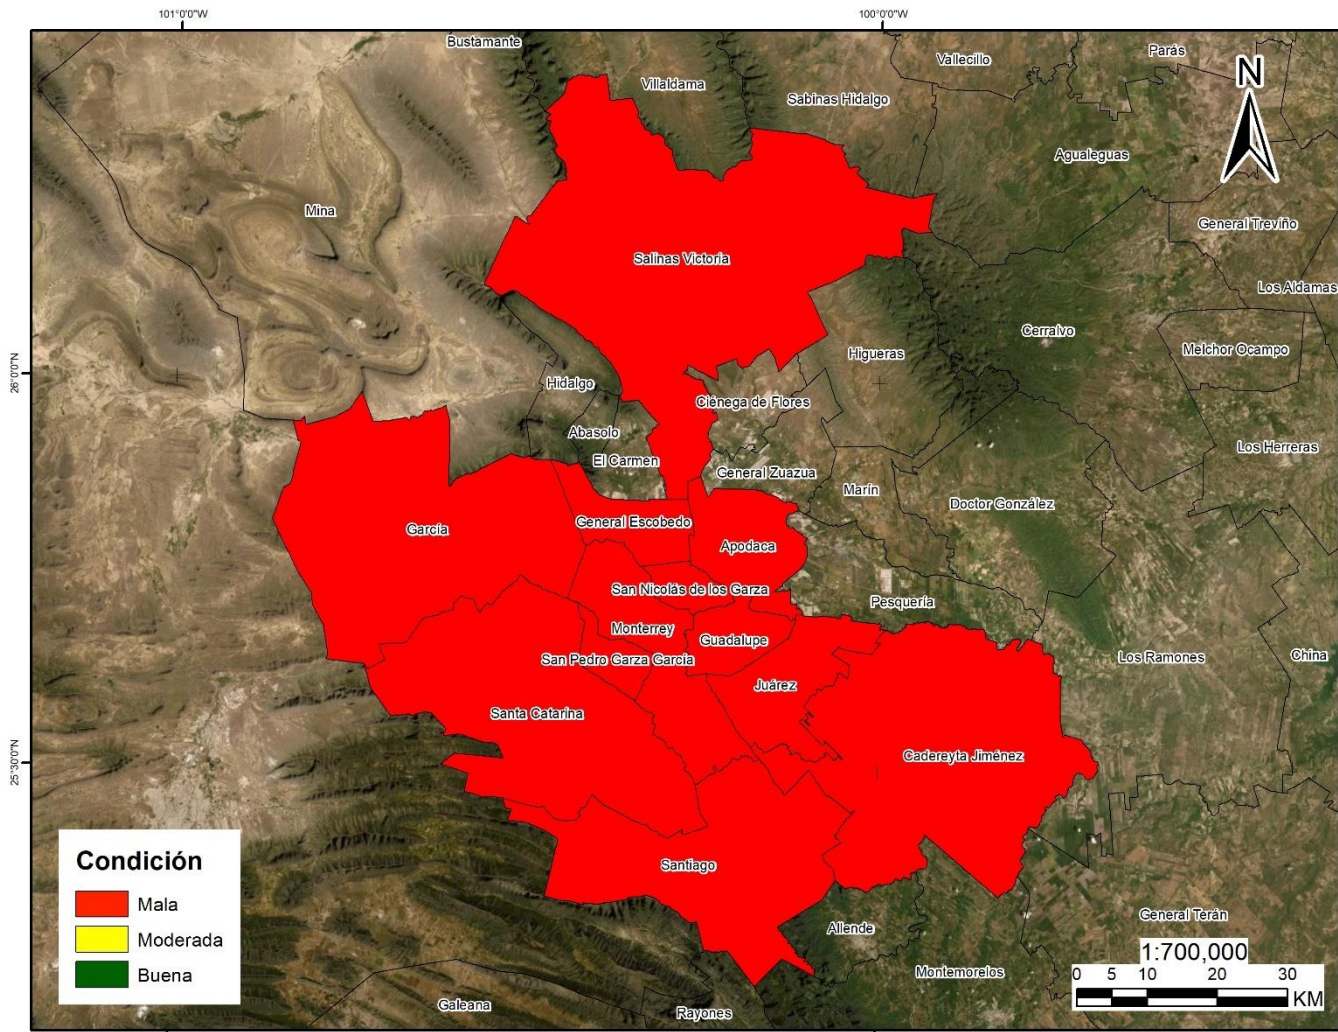


Figura 52. Condición de vegetación de AVU, de acuerdo con la media de valores del índice NDWI calculado para los municipios de la ZMM al año 2021 (Elaboración propia).

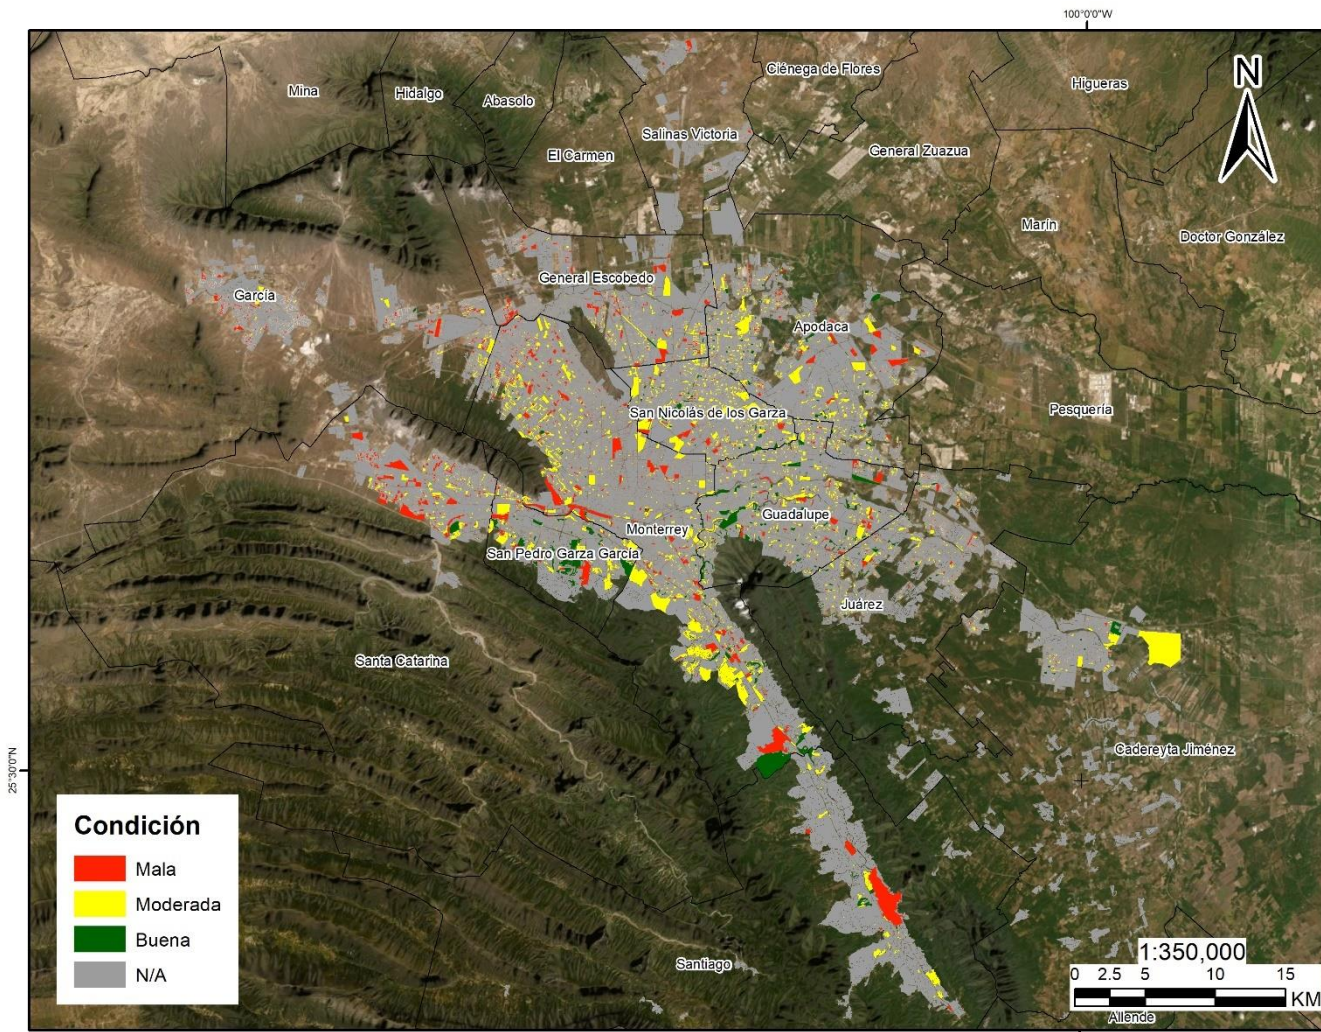


Figura 53. Condición de vegetación de AVU, de acuerdo con la media de valores del índice NDVI calculado para las manzanas de la ZMM al año 2021 (Elaboración propia).

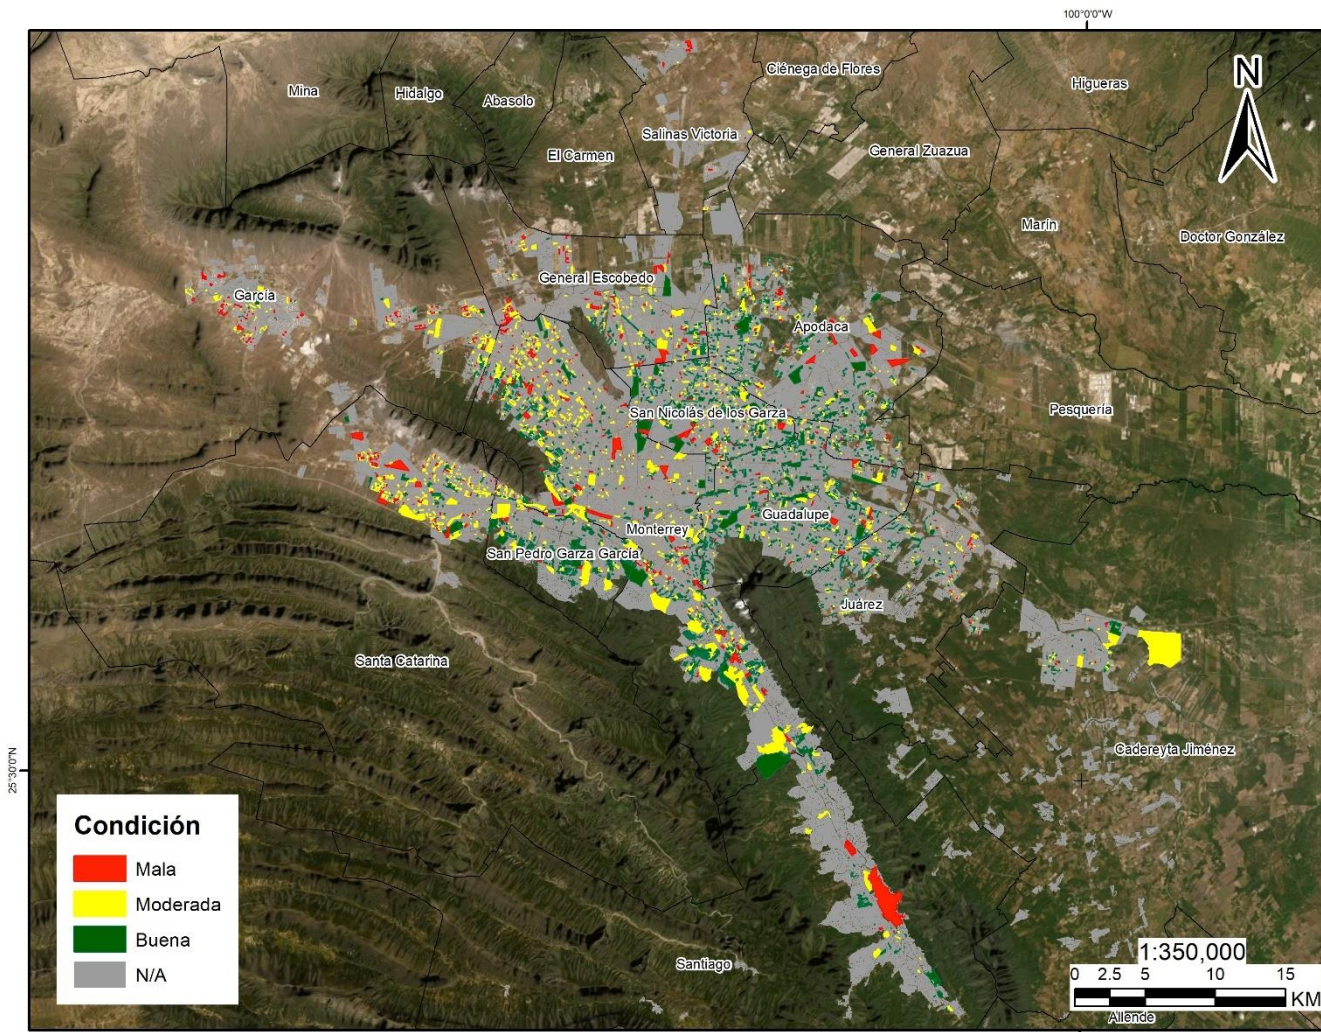


Figura 54. Condición de vegetación de AVU, de acuerdo con la media de valores del índice EVI2 calculado para las manzanas de la ZMM al año 2021 (Elaboración propia).

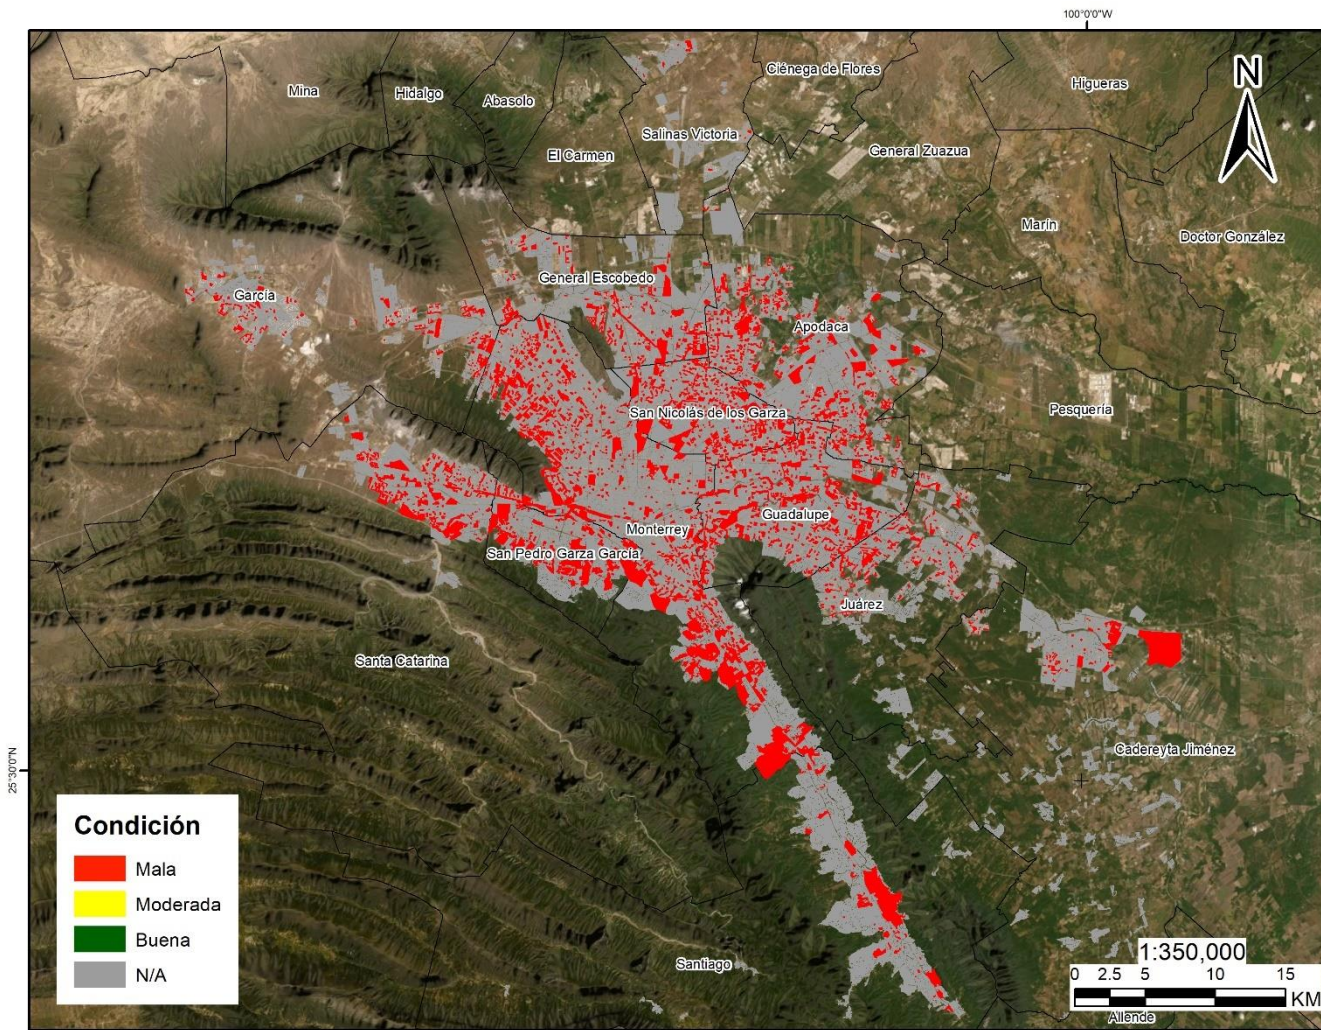


Figura 55. Condición de vegetación de AVU, de acuerdo con la media de valores del índice NDWI calculado para las manzanas de la ZMM al año 2021 (Elaboración propia).

En la Figura 56 se contrastan las medias del índice NDVI calculado para las fechas de 2016 y 2021. Se observa que para todos los municipios hubo un aumento en la calidad de sus AVU, destacando Juárez (119%), Cadereyta (98%), García (94%), Escobedo (84%) y Guadalupe (81%).




Figura 56. Comparación de condición de verdor de AVU entre los años 2016 y 2021 para los municipios de la ZMM mediante el uso del índice NDVI (Elaboración propia).

10.2 Conectividad de las AVU

En la Tabla 18 se muestran las variables calculadas en el análisis de fragmentación del paisaje considerando cada municipio como una unidad de paisaje dentro de la ZMM. En el Anexo III se muestran los resultados obtenidos tomando como unidad de medición las clases de cada municipio presente dentro de la ZMM.

Tabla 18. Variables de análisis de fragmentación de AVU de la ZMM (Elaboración propia).

	CA	TLA	NumP	MPS	MedPS	PSSD	PSCoV	TE	ED	MPE	MSI	AWMSI	MPFD	AWMPFD
Apodaca	6628708.91	45046025.03	3267.00	2028.99	599.43	5234.97	258.01	867148.71	0.02	265.43	2.24	2.23	1.63	1.45
Cadereyta	1285332.84	45046025.03	479.00	2683.37	837.64	9393.38	350.06	150012.52	0.00	313.18	2.02	3.44	1.56	1.47
García	2607419.33	45046025.03	1137.00	2293.24	709.01	6488.82	282.95	351217.92	0.01	308.90	2.15	3.06	1.60	1.49
San Pedro	2522939.11	45046025.03	1136.00	2220.90	568.79	5165.35	232.58	297382.10	0.01	261.78	2.40	1.85	1.66	1.42
Escobedo	2709835.80	45046025.03	1142.00	2372.89	688.99	7162.97	301.87	353151.60	0.01	309.24	2.18	3.16	1.61	1.47
Guadalupe	6692366.62	45046025.03	3154.00	2121.87	729.20	7660.40	361.02	1012986.86	0.02	321.18	2.53	2.45	1.64	1.47
Juárez	3336933.61	45046025.03	1459.00	2287.14	631.74	6042.57	264.20	381287.43	0.01	261.33	2.07	2.23	1.61	1.44
Monterrey	10716648.39	45046025.03	6048.00	1771.93	577.52	6267.65	353.72	1828838.99	0.04	302.39	2.57	2.53	1.66	1.47
Salinas Victoria	379985.74	45046025.03	181.00	2099.37	910.20	3237.41	154.21	44144.00	0.00	243.89	1.78	1.79	1.54	1.43
San Nicolás	4593365.38	45046025.03	1823.00	2519.67	814.27	5298.66	210.29	566075.56	0.01	310.52	2.34	2.27	1.62	1.44
Santa Catarina	3225182.08	45046025.03	1846.00	1747.12	580.99	3817.08	218.48	478625.49	0.01	259.28	2.08	2.53	1.61	1.49
Santiago	347307.22	45046025.03	263.00	1320.56	508.66	2519.52	190.79	71048.80	0.00	270.15	2.16	3.59	1.64	1.55

Los municipios con mayor cobertura de área correspondiente a AVU fueron Monterrey, Guadalupe, Apodaca, San Nicolás de los Garza y Juárez. Los municipios con mayor fragmentación de sus AVU, dada la mayor cantidad de número de parches fueron Monterrey, Apodaca, Guadalupe, Santa Catarina y San Nicolás de los Garza. Los municipios que presentaron mayor tamaño de parches promedio fueron Cadereyta, San Nicolás de los Garza, General Escobedo, García y Juárez. Los municipios con AVU con formas más elongadas fueron Monterrey, Guadalupe, Apodaca, San Nicolás de los Garza y Santa Catarina. Los municipios con polígonos con formas más complejas fueron Monterrey, Guadalupe, San Pedro Garza García, San Nicolás de los Garza y Apodaca.

10.3 Accesibilidad de AVU

Los mapas de densidad AVU que muestran la proporción de área que representa cada AVU dentro de los polígonos de las manzanas se muestran en las Figuras 57 – 68 representando cada uno de los municipios bajo análisis. La Tabla 19 muestra los valores las estadísticas que se obtuvieron para cada uno de los municipios.

Tabla 19. Estadísticas de la densidad de AVU por municipio (Elaboración propia).

Municipio	DAVU promedio	Desviación estándar
Apodaca	1.224141	5.976342
Cadereyta	0.02402	0.134082
General Escobedo	0.026918	0.141722
García	0.027886	0.151262
Guadalupe	0.047259	0.187238
Juárez	0.029683	0.15672
Monterrey	0.037347	0.167739
Salinas Victoria	0.00801	0.082669
Santa Catarina	0.052962	0.203233
Santiago	0.02097	0.129546
San Nicolás de los Garza	0.056763	0.200767
San Pedro Garza García	0.054215	0.198297

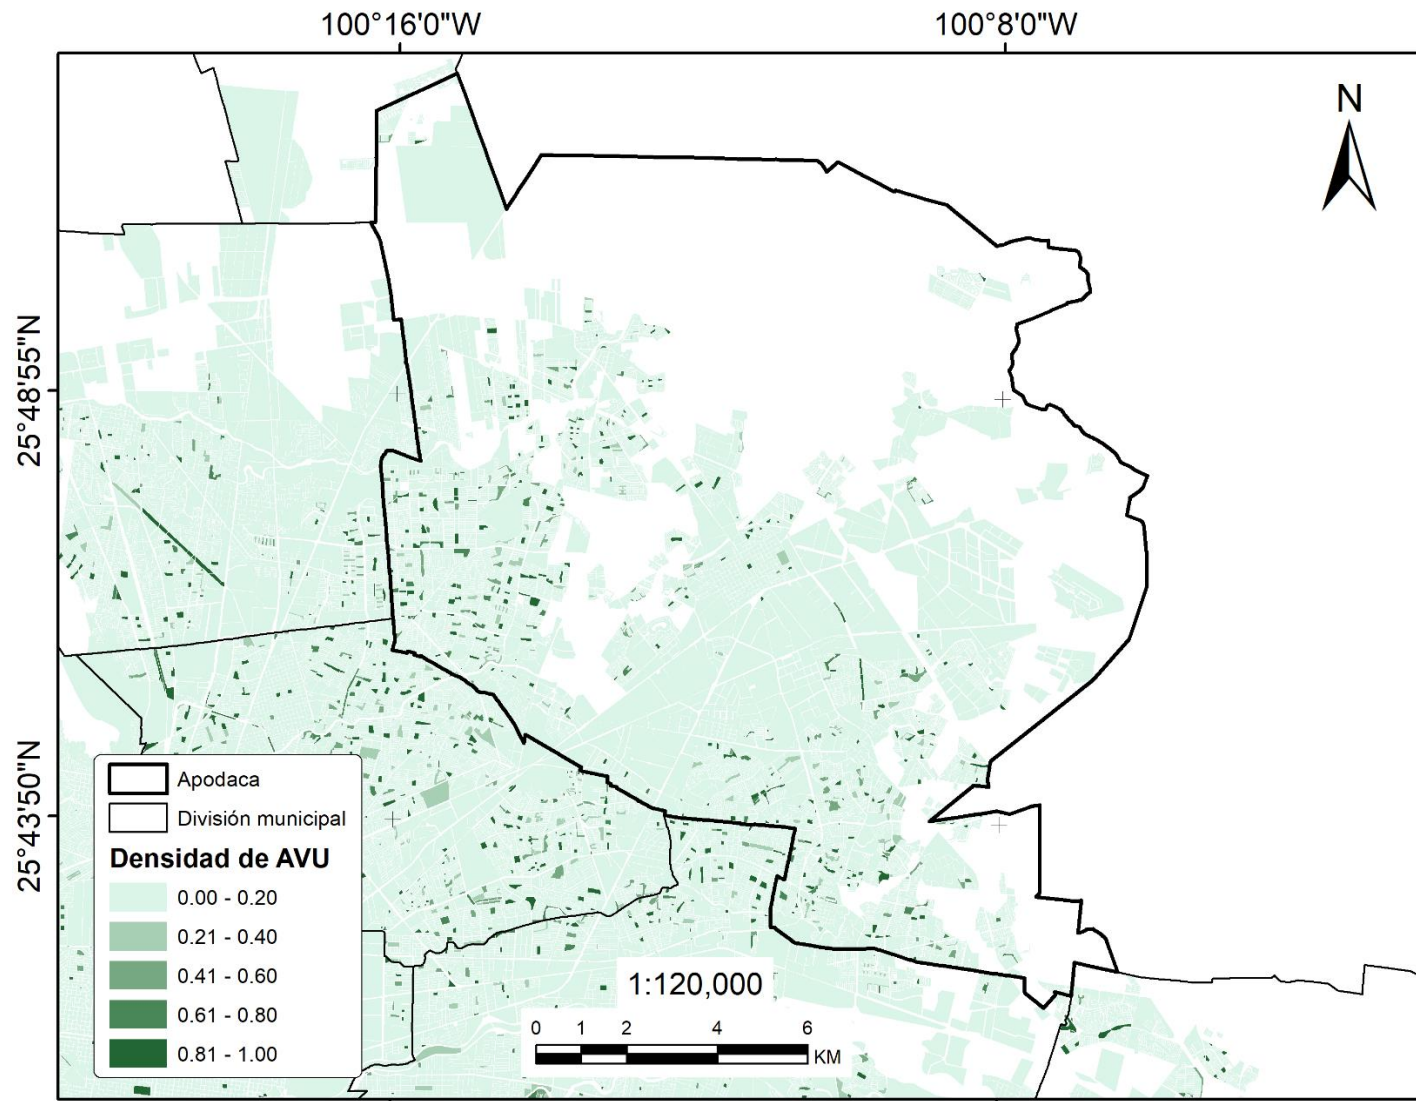


Figura 57. Densidad de las AVU presente en el municipio de Apodaca, Nuevo León (Elaboración propia).

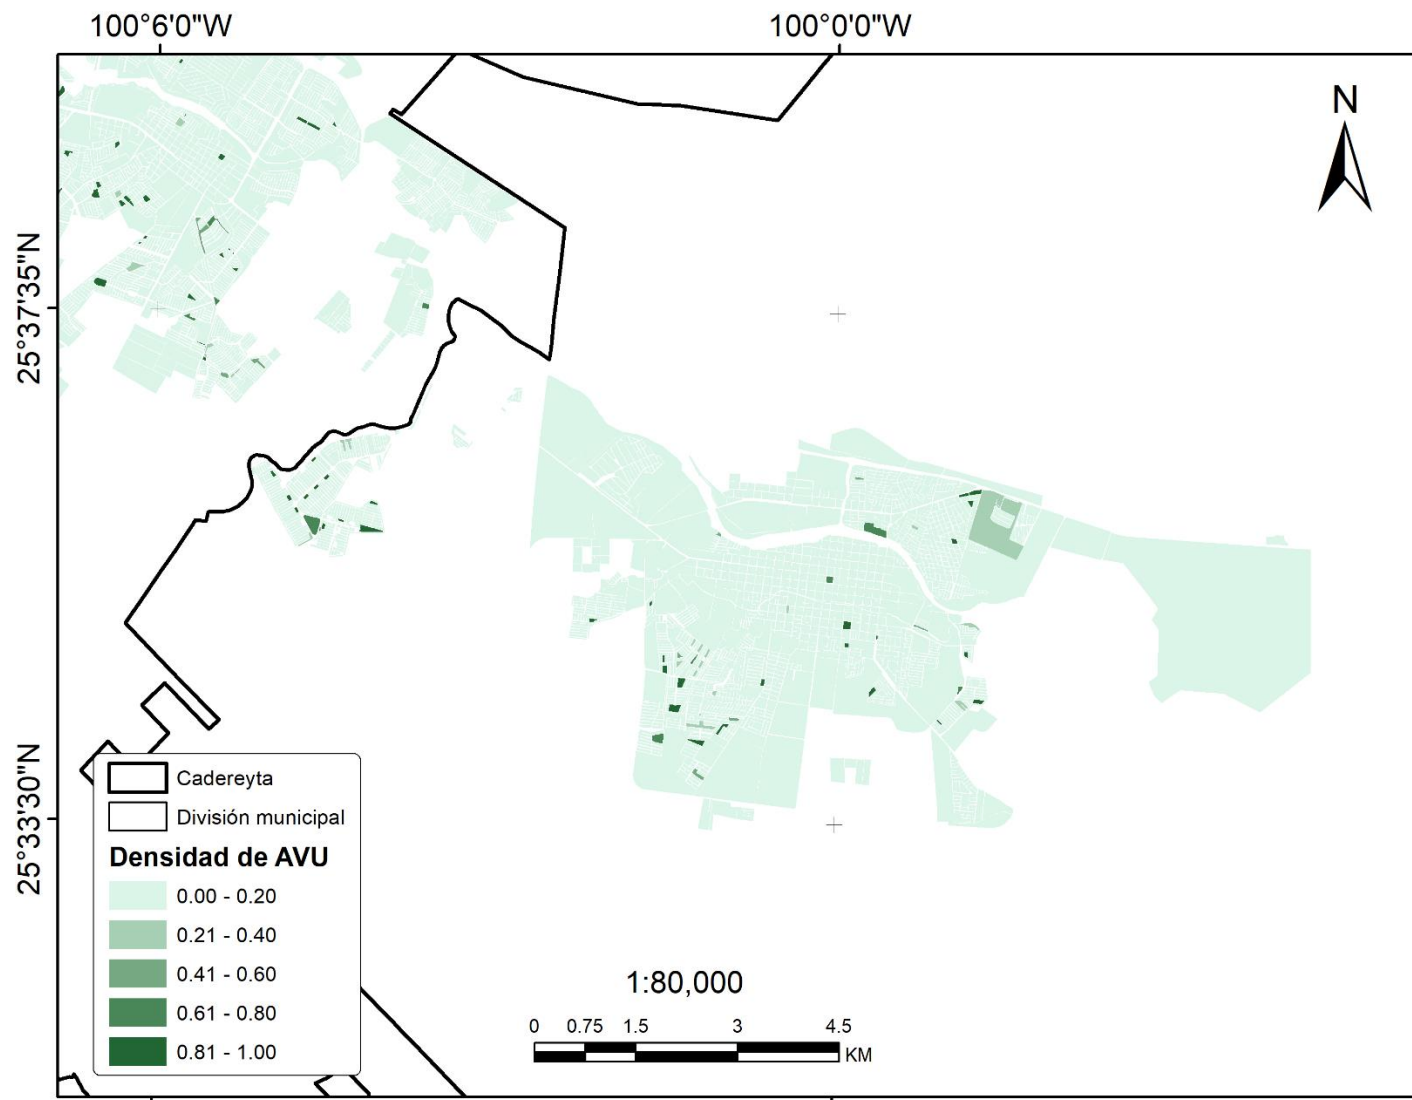


Figura 58. Densidad de las AVU presente en el municipio de Cadereyta, Nuevo León (Elaboración propia).

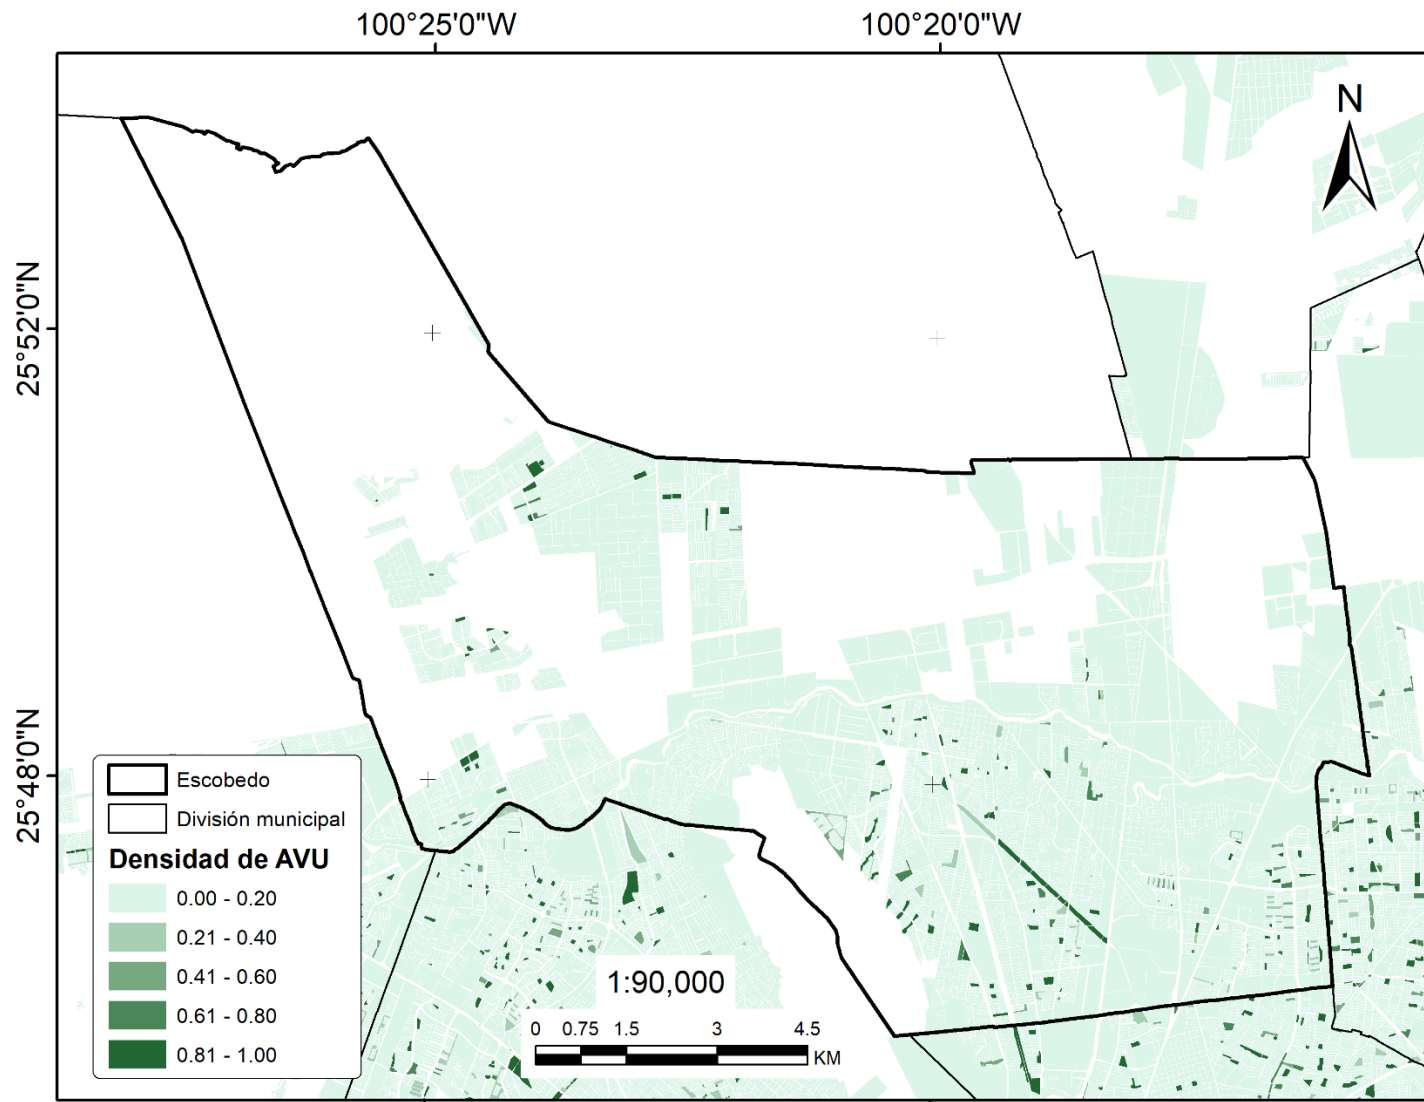


Figura 59. Densidad de las AVU presente en el municipio de General Escobedo, Nuevo León (Elaboración propia).

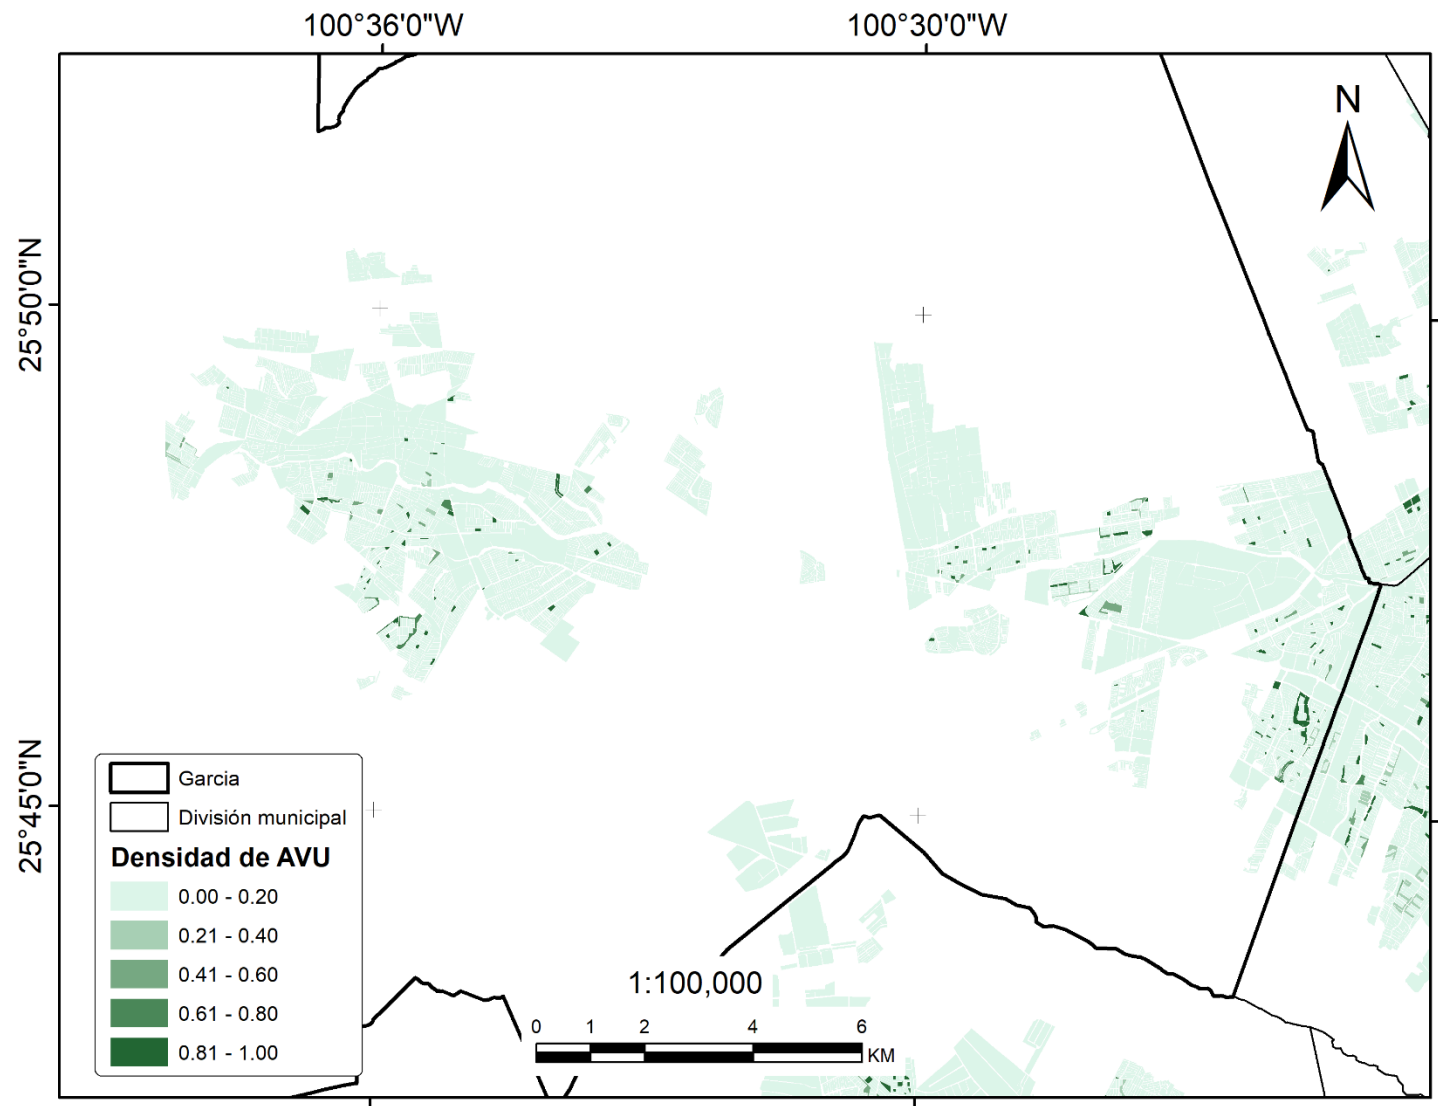


Figura 60. Densidad de las AVU presente en el municipio de García, Nuevo León (Elaboración propia).

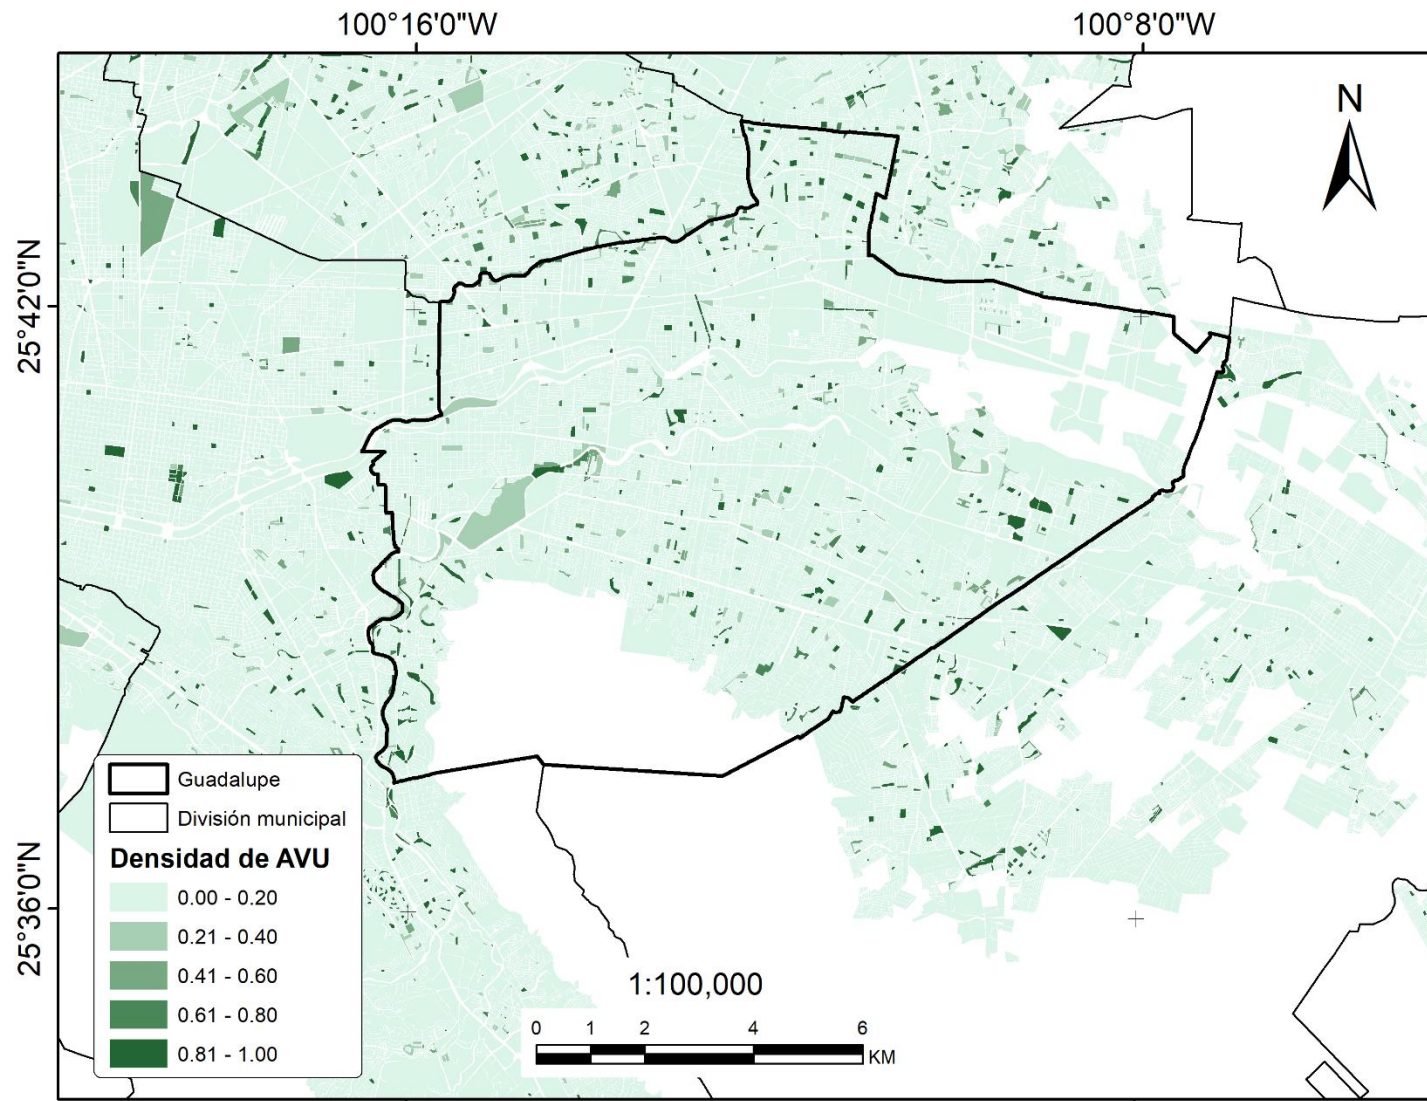


Figura 61. Densidad de las AVU presente en el municipio de Guadalupe, Nuevo León (Elaboración propia).

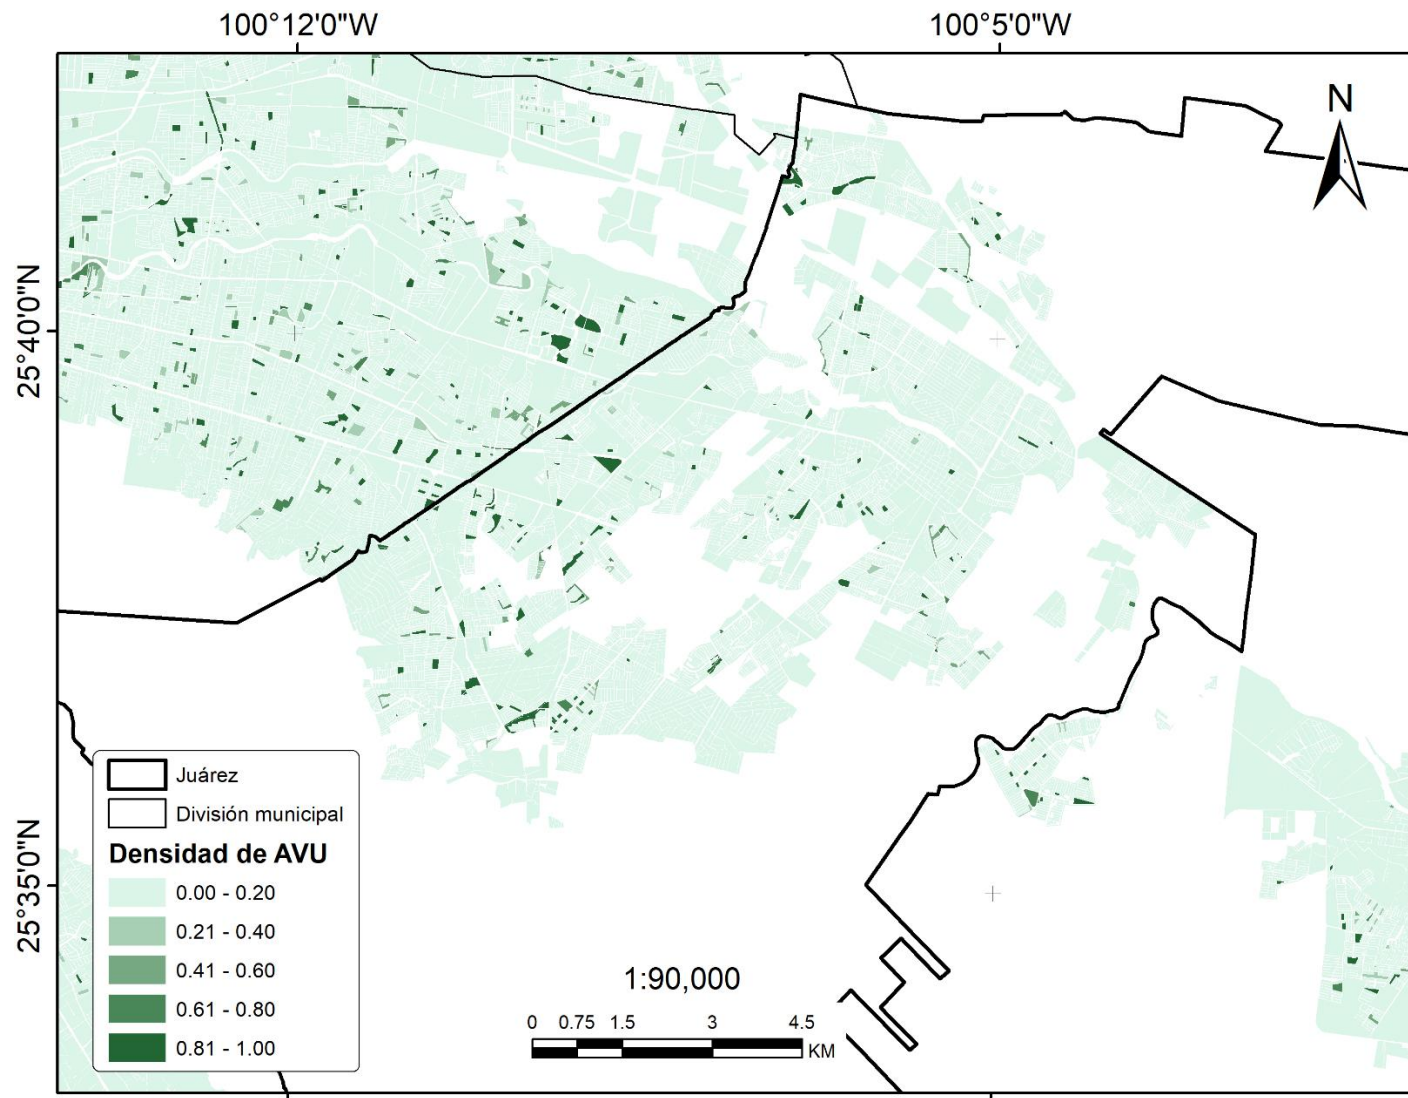


Figura 62. Densidad de las AVU presente en el municipio de Juárez, Nuevo León (Elaboración propia).

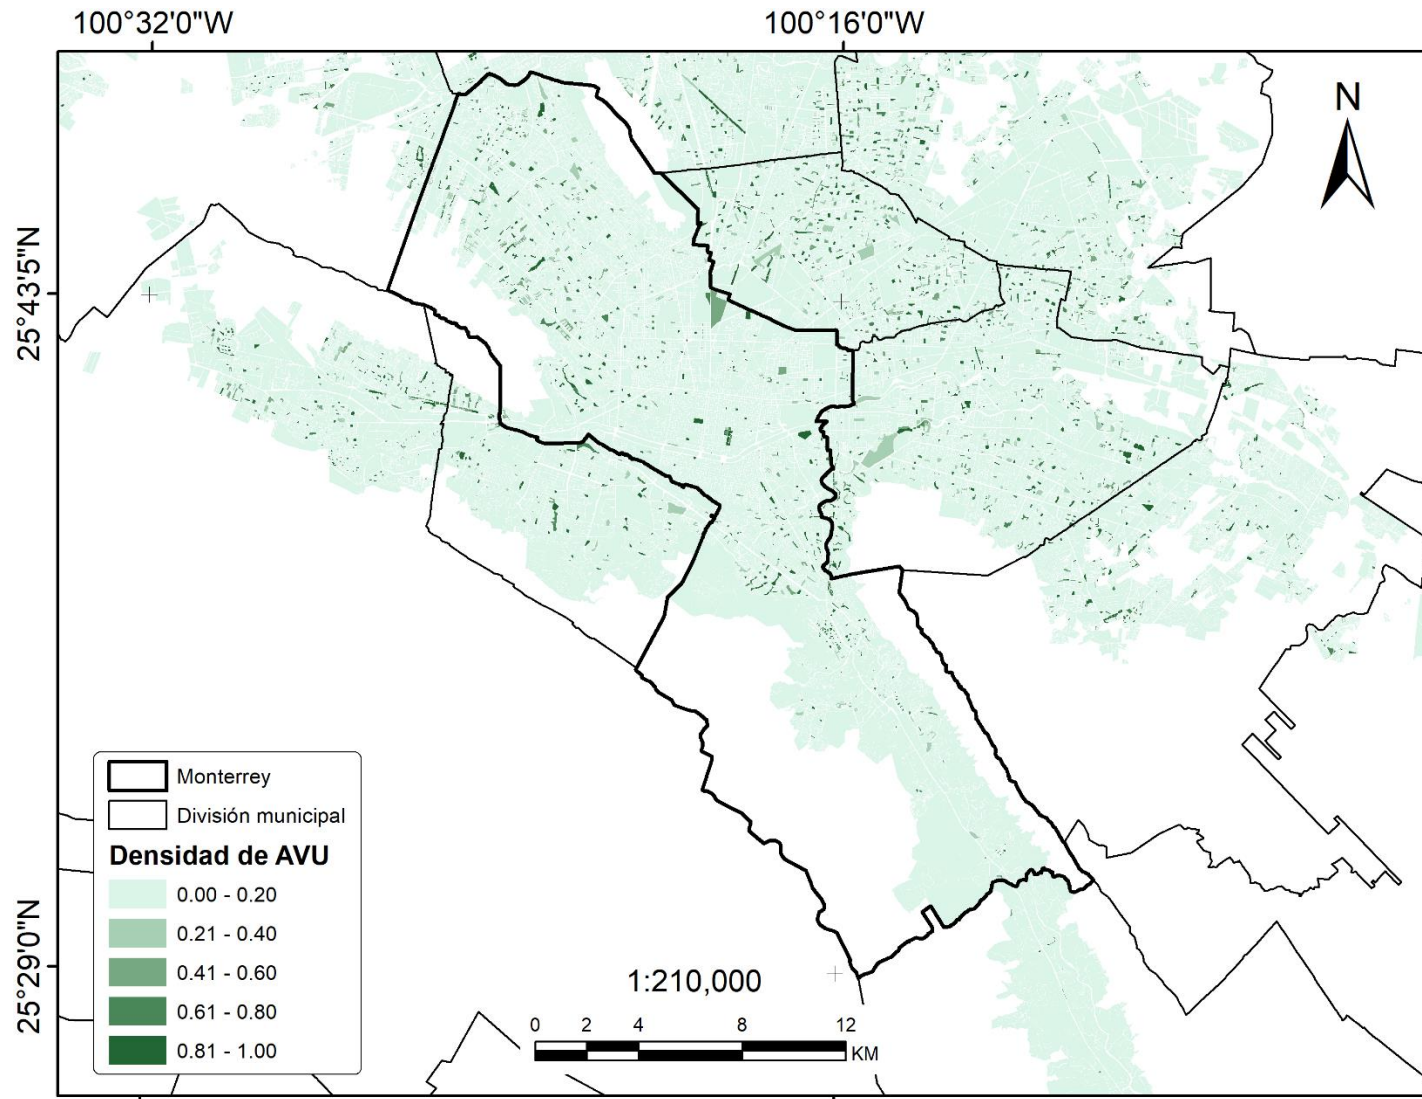


Figura 63. Densidad de las AVU presente en el municipio de Monterrey, Nuevo León (Elaboración propia).

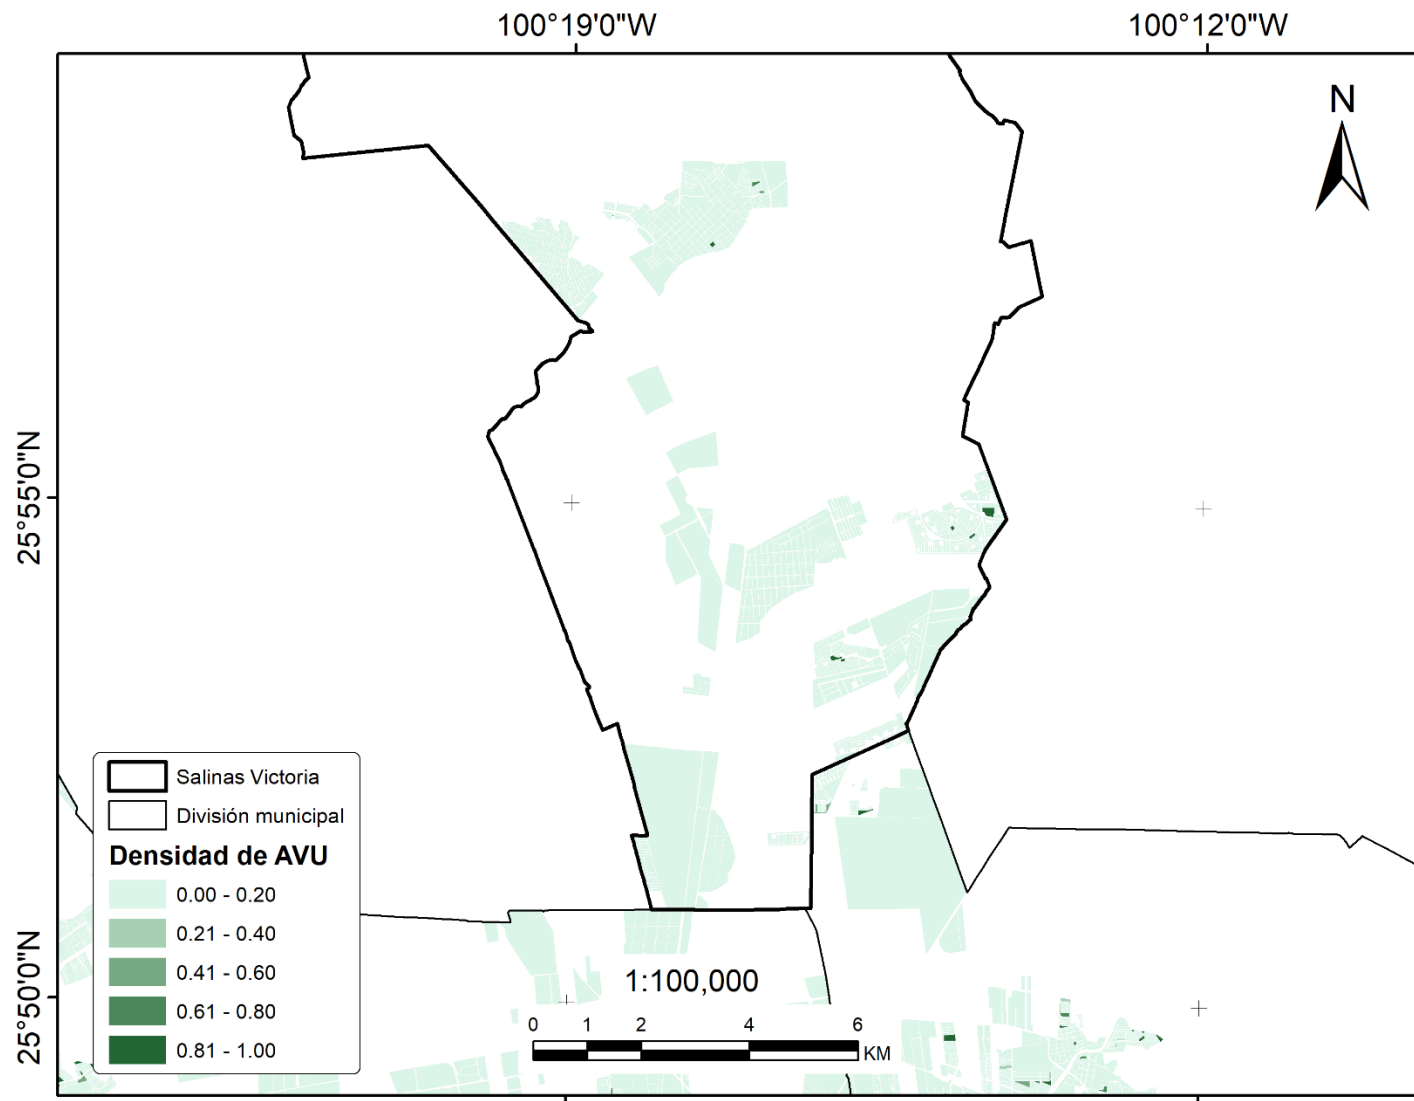


Figura 64. Densidad de las AVU presente en el municipio de Salinas Victoria, Nuevo León (Elaboración propia).

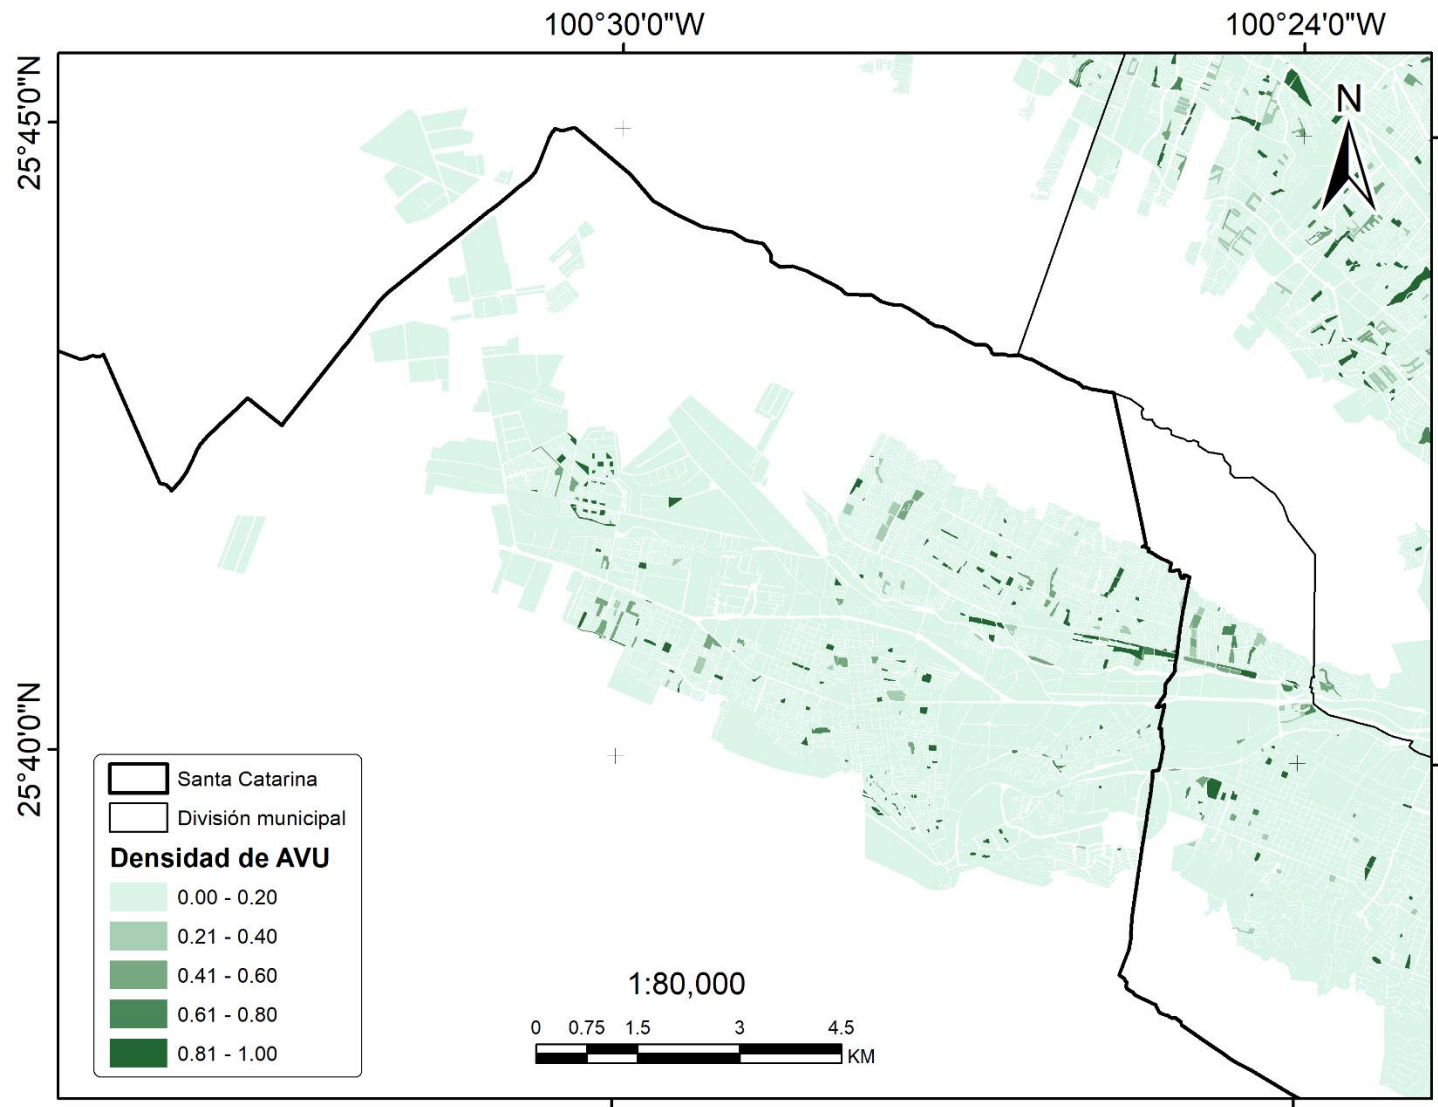


Figura 65. Densidad de las AVU presente en el municipio de Santa Catarina, Nuevo León (Elaboración propia).

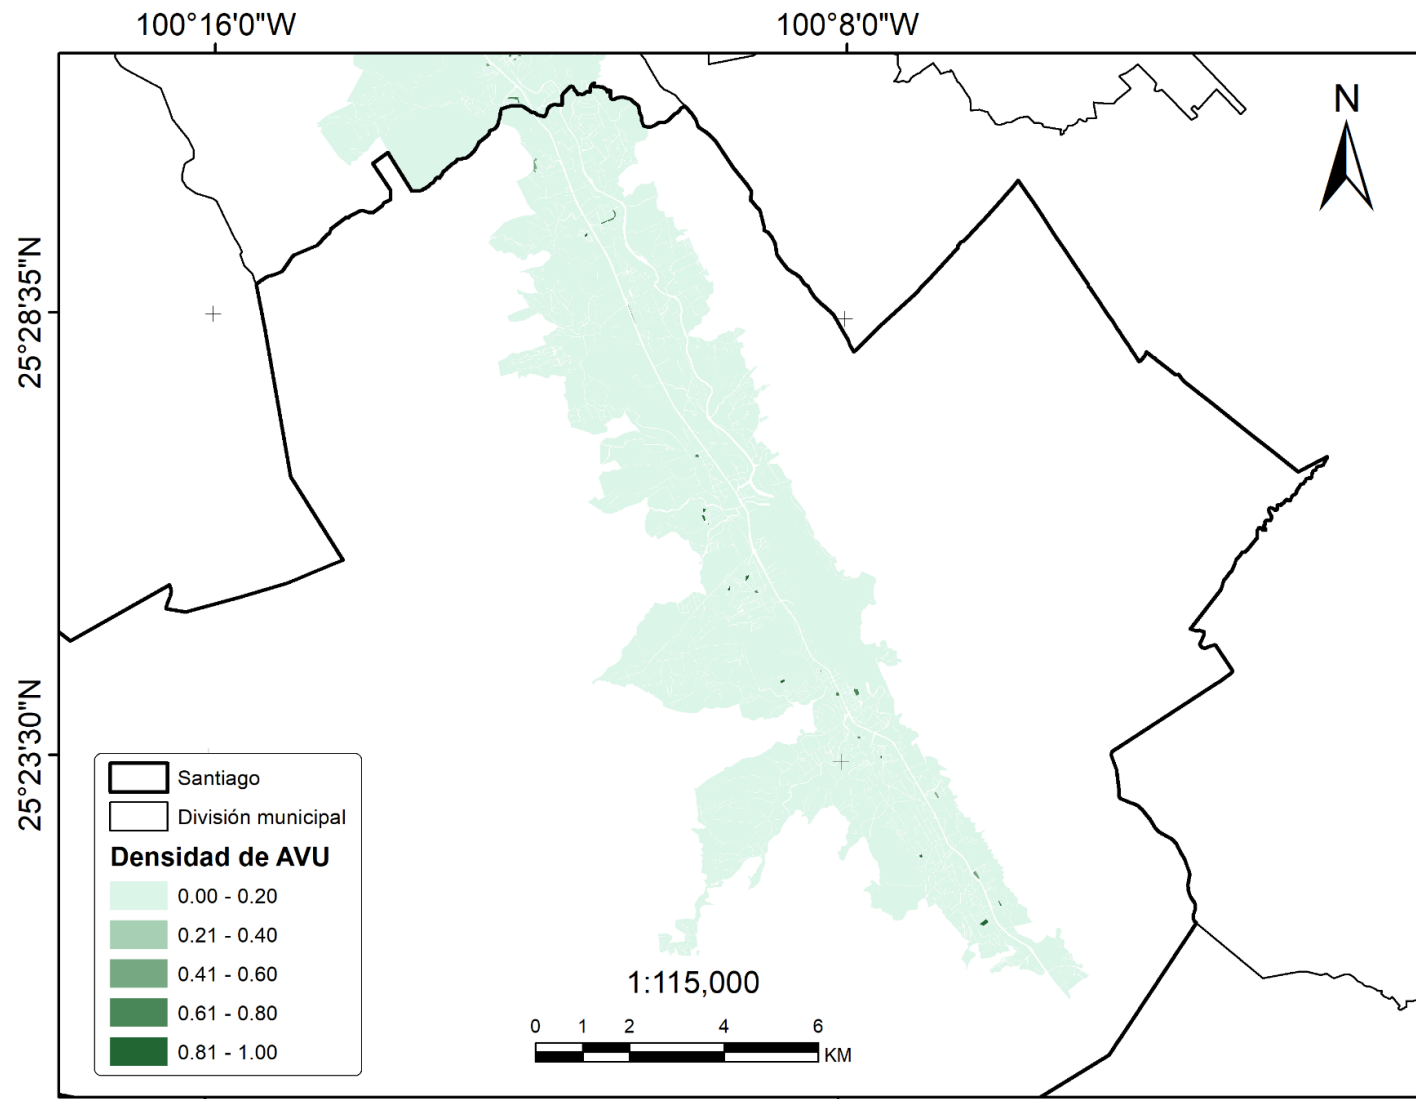


Figura 66. Densidad de las AVU presente en el municipio de Santiago, Nuevo León (Elaboración propia).

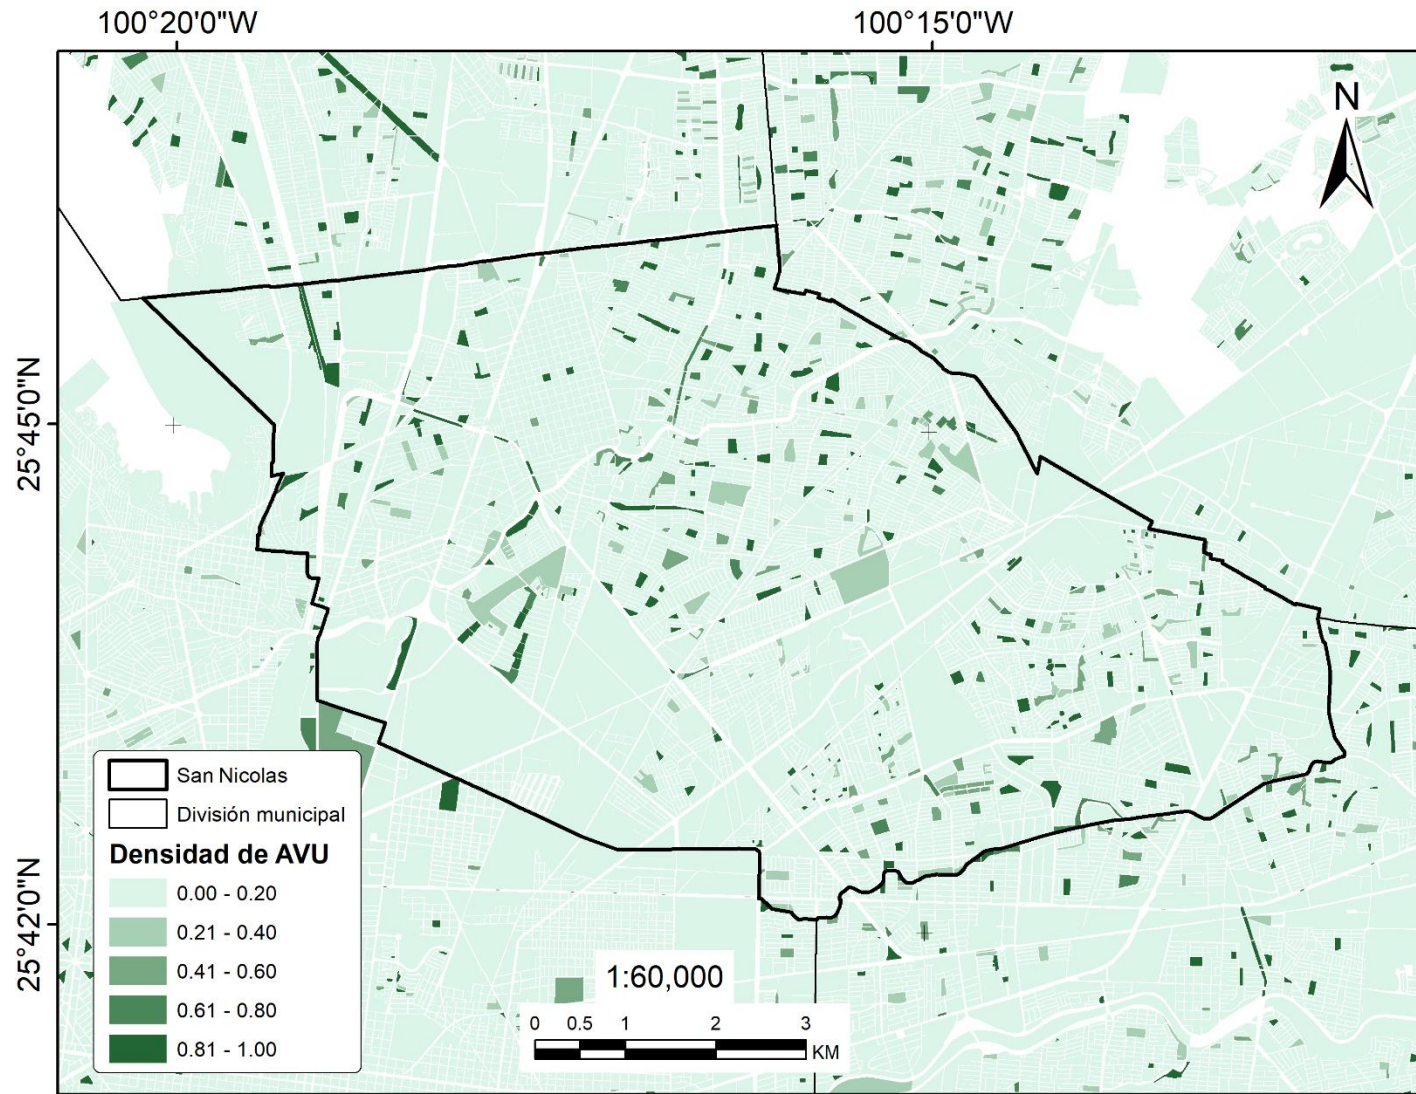


Figura 67. Densidad de las AVU presente en el municipio de San Nicolás de los Garza, Nuevo León (Elaboración propia).

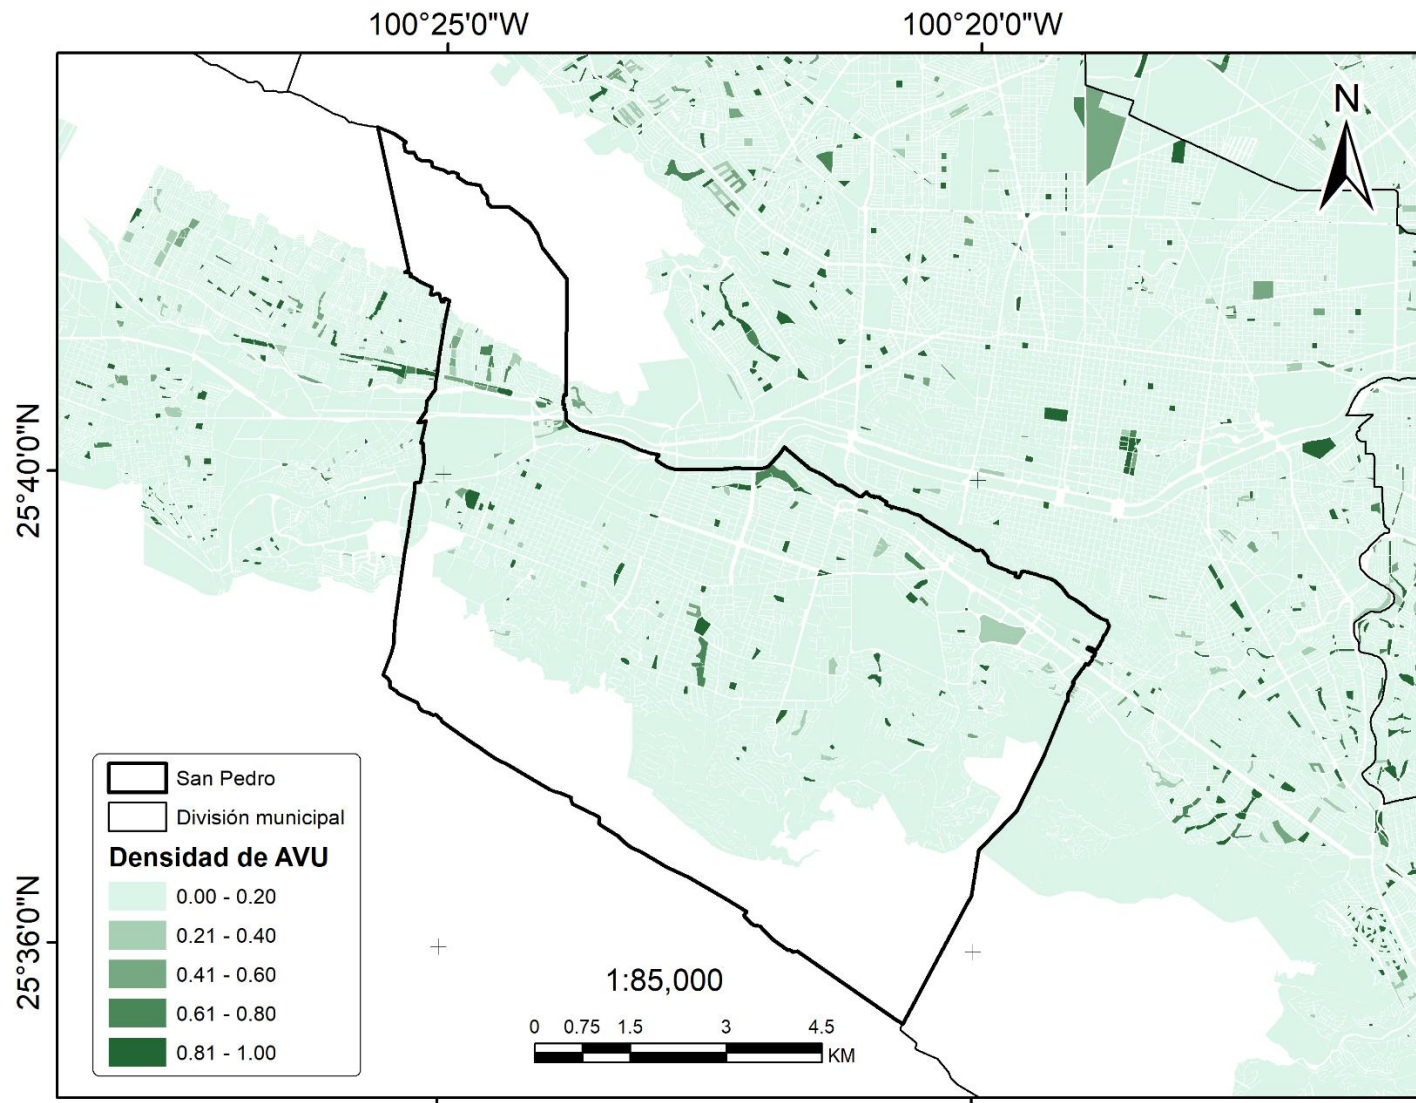


Figura 68. Densidad de las AVU presente en el municipio de San Pedro Garza García, Nuevo León (Elaboración propia).

En las Figuras 69 – 80 se muestran los mapas con los resultados del índice de accesibilidad, obtenido mediante el análisis de red para las zonas urbanas de cada uno de los municipios de la ZMM. Sus valores varían conforme a las distancias de traslado a pie a través de las vialidades, donde 100 m representan una accesibilidad alta, 200 m, media; 300 m, baja; y más de 300 m, nula. Destaca el caso del municipio de San Nicolás de los Garza, que presenta una cobertura casi total de sus zonas habitacionales. Por otro lado, los municipios de Santiago y de Salinas Victoria presentan apenas un par de áreas con acceso a AVU. Para el municipio de Monterrey se observa una amplia cobertura de AVU en sus zonas sur y poniente, mientras que las zonas norte y centro cuentan con amplios parches de zonas con nulo acceso a las AVU. En cuanto al municipio de Apodaca, presenta una alta conectividad en las zonas oriente y poniente, siendo fragmentadas principalmente debido a la presencia de la zona industrial dentro del municipio. Los municipios de Cadereyta y García presentan una amplia dispersión en la accesibilidad de sus AVU localizadas en el casco antiguo de estos municipios, no siguiendo el mismo patrón en sus nuevos desarrollos, donde se logran formar parches que forman corredores de AVU. La accesibilidad de las AVU dentro del municipio de Escobedo es alta en las cercanías a su zona central, donde incluso llega a formar un único manchón de área de acceso; no obstante, el resto del municipio necesita impulsar el desarrollo de AVU para ofrecer estos beneficios al resto de sus habitantes. El municipio de Guadalupe presenta una amplia cobertura de AVU accesible para su población, concentrándose principalmente en su zona geográfica central, así como en sus periferias colindantes con Monterrey, San Nicolás de los Garza y Apodaca. En el municipio de Juárez, la zona con mayor accesibilidad a AVU se encuentra colindante al municipio de Guadalupe, en las faldas de la Sierra Cerro de la Silla. Al ser un municipio de no muy amplias dimensiones, en San Pedro Garza García se han aprovechado los corredores que acompañan a las vialidades para mantener amplias AVU elongadas que permiten cierta conectividad a través de ellas. La zona urbana del municipio de Santa Catarina presenta zonas con amplia accesibilidad al sur mientras que al norte sus parches de AVU son dispersos, dejando amplios huecos en zonas habitacionales donde la accesibilidad a AVU es nula.

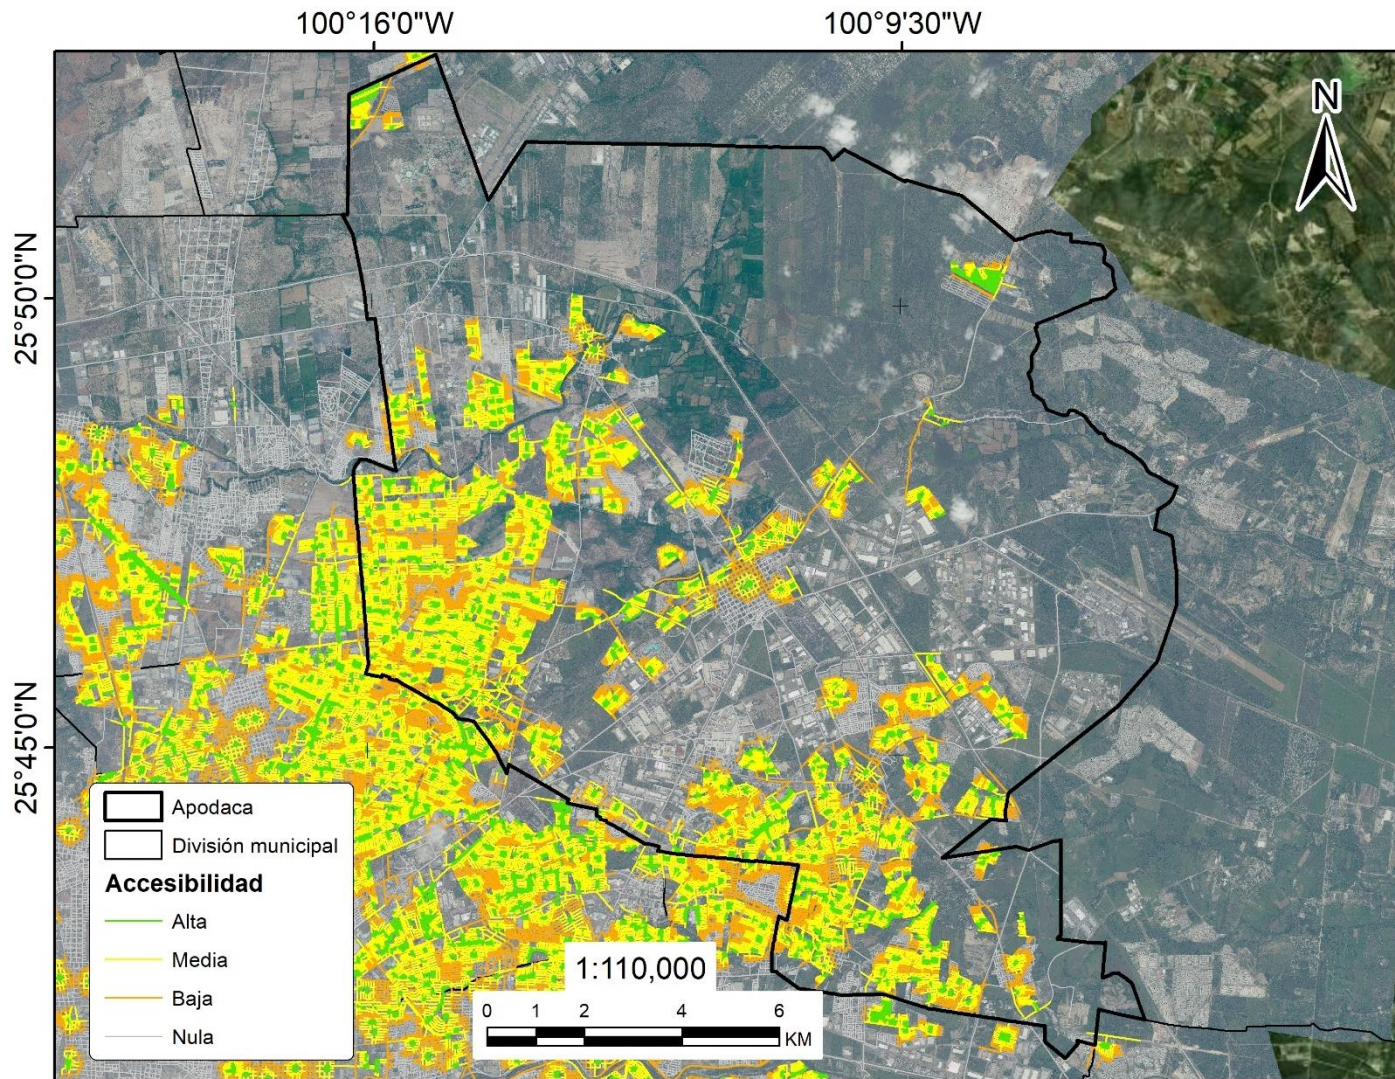


Figura 69. Índice de accesibilidad a AVU para el municipio de Apodaca, Nuevo León (Elaboración propia).

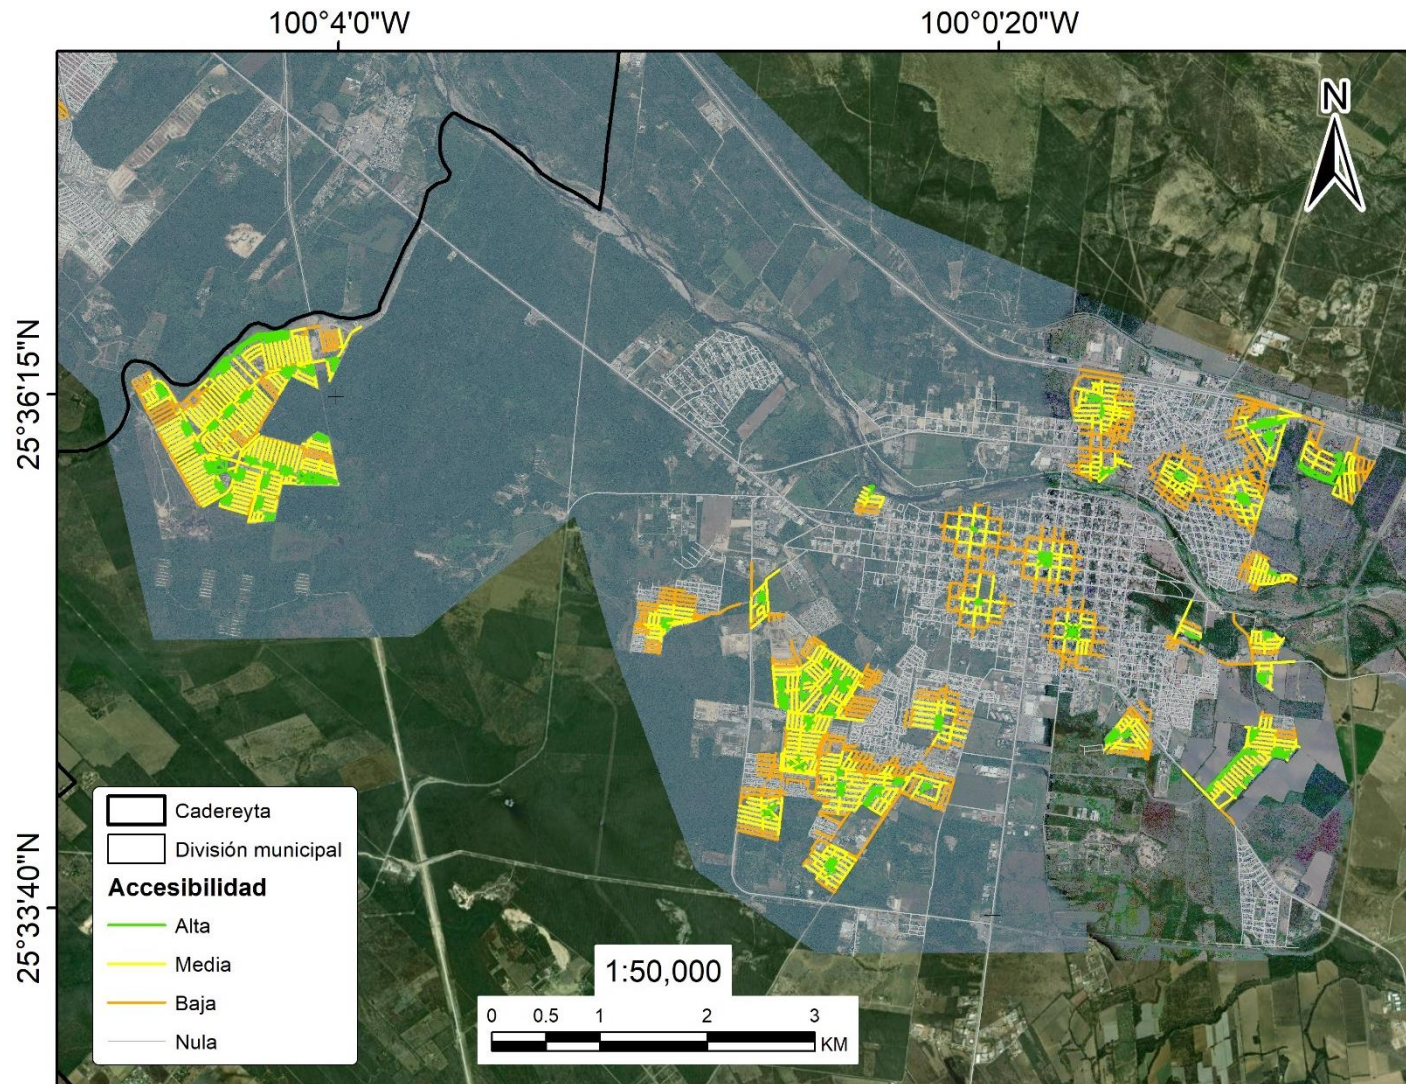


Figura 70. Índice de accesibilidad a AVU para el municipio de Cadereyta, Nuevo León (Elaboración propia).

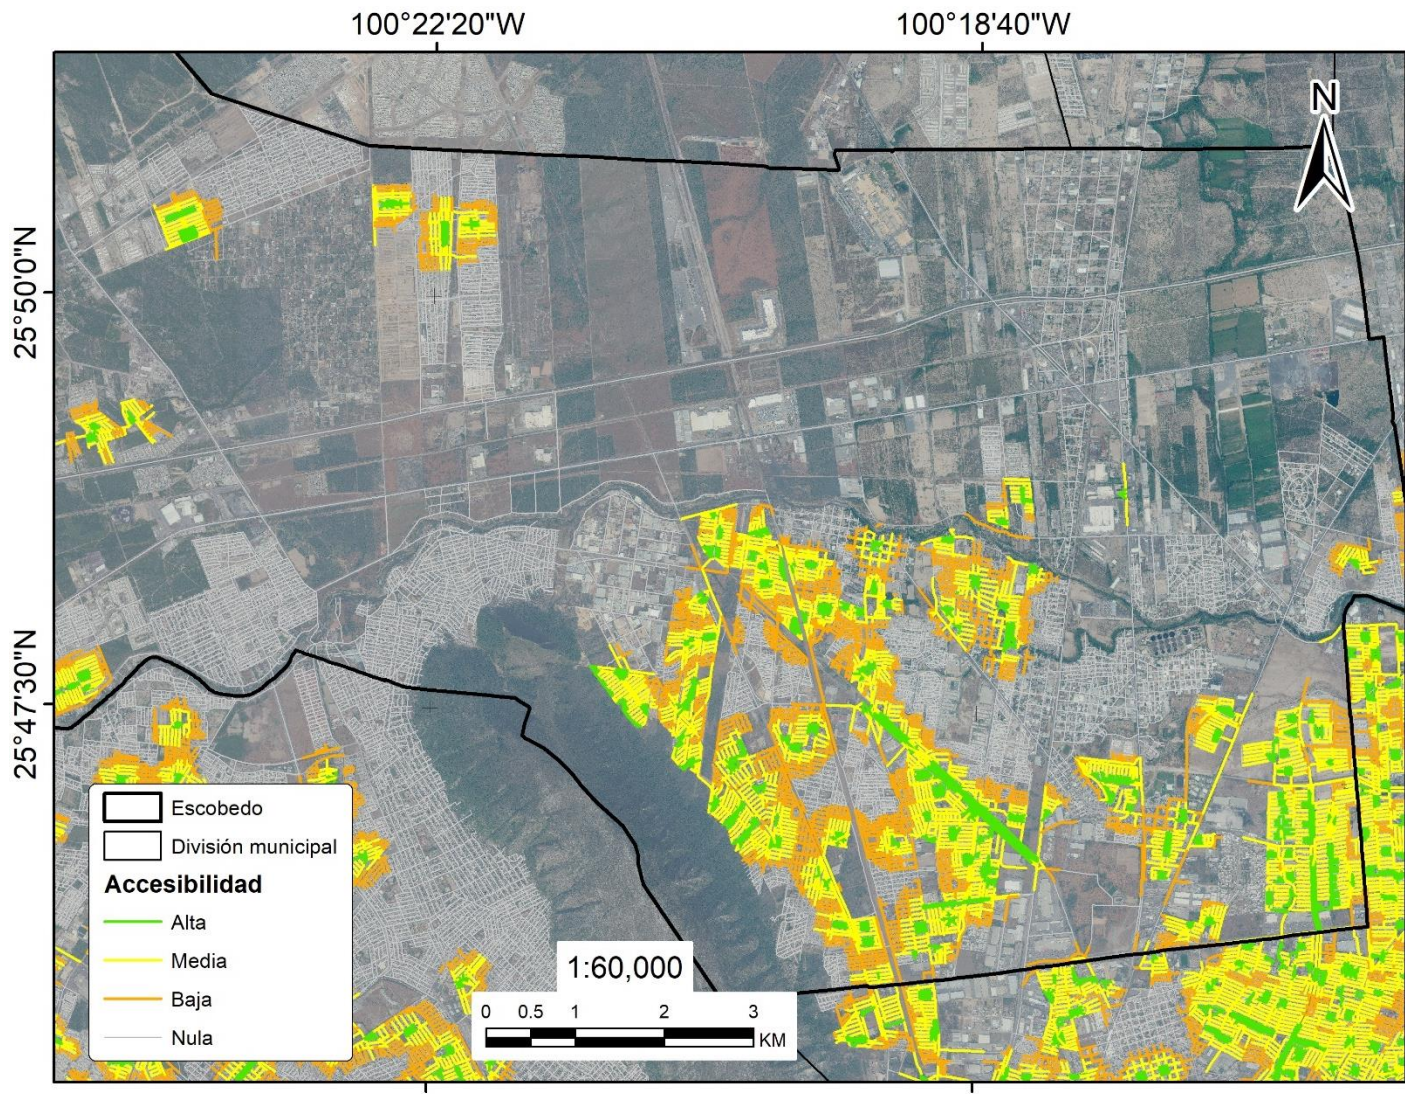


Figura 71. Índice de accesibilidad a AVU para el municipio de General Escobedo, Nuevo León (Elaboración propia).

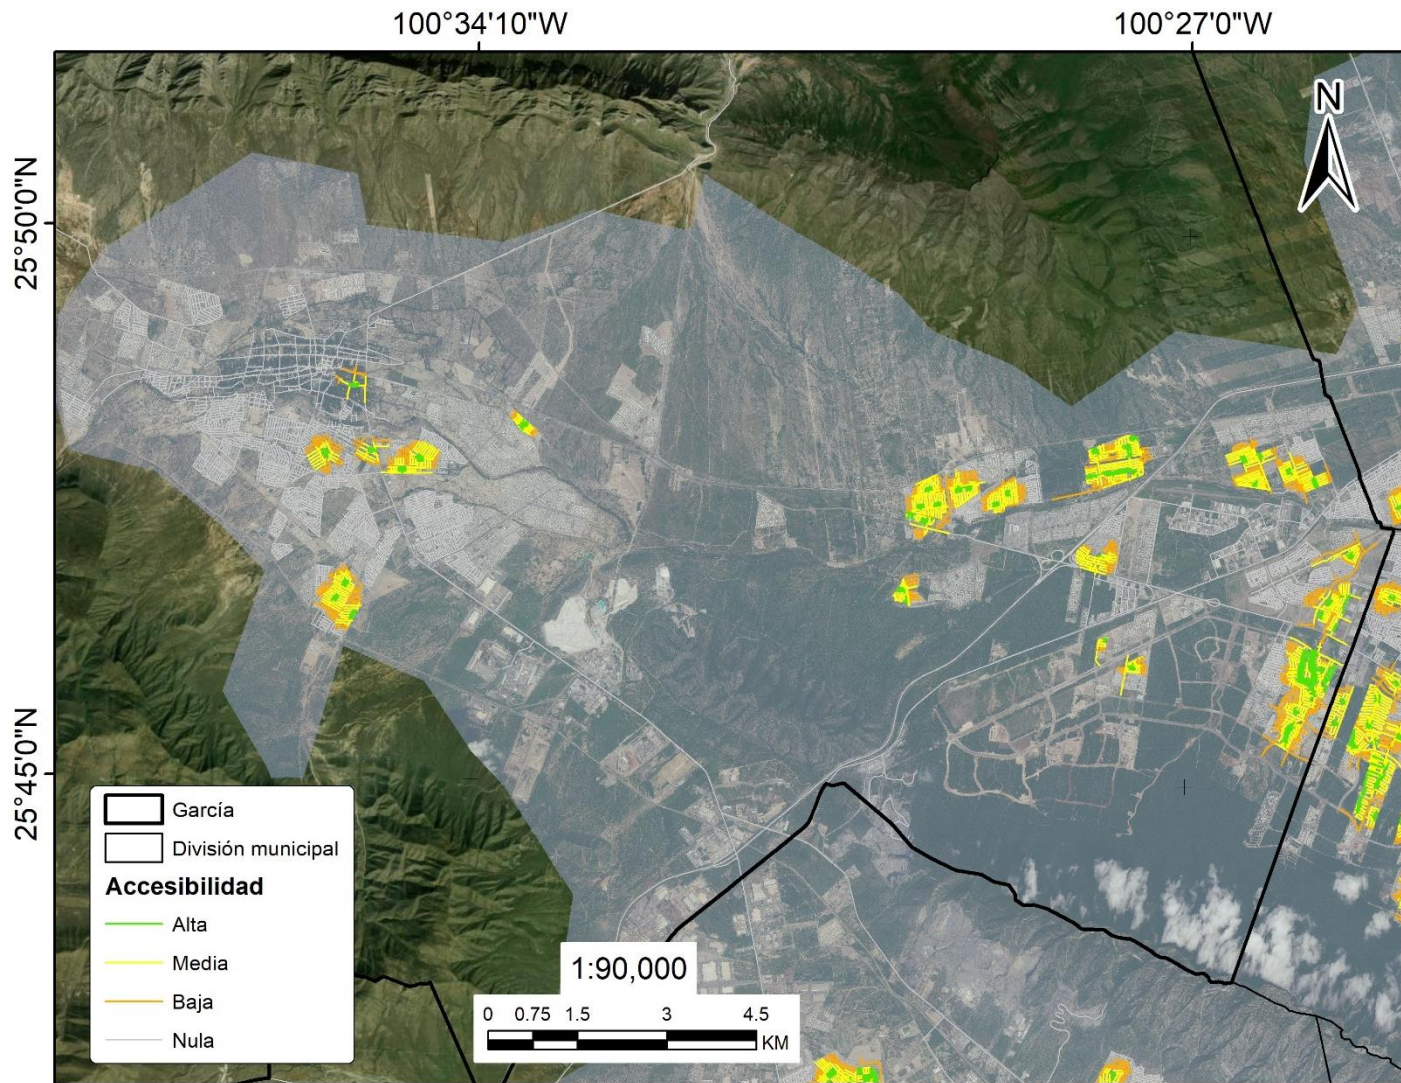


Figura 72. Índice de accesibilidad a AVU para el municipio de García, Nuevo León (Elaboración propia).

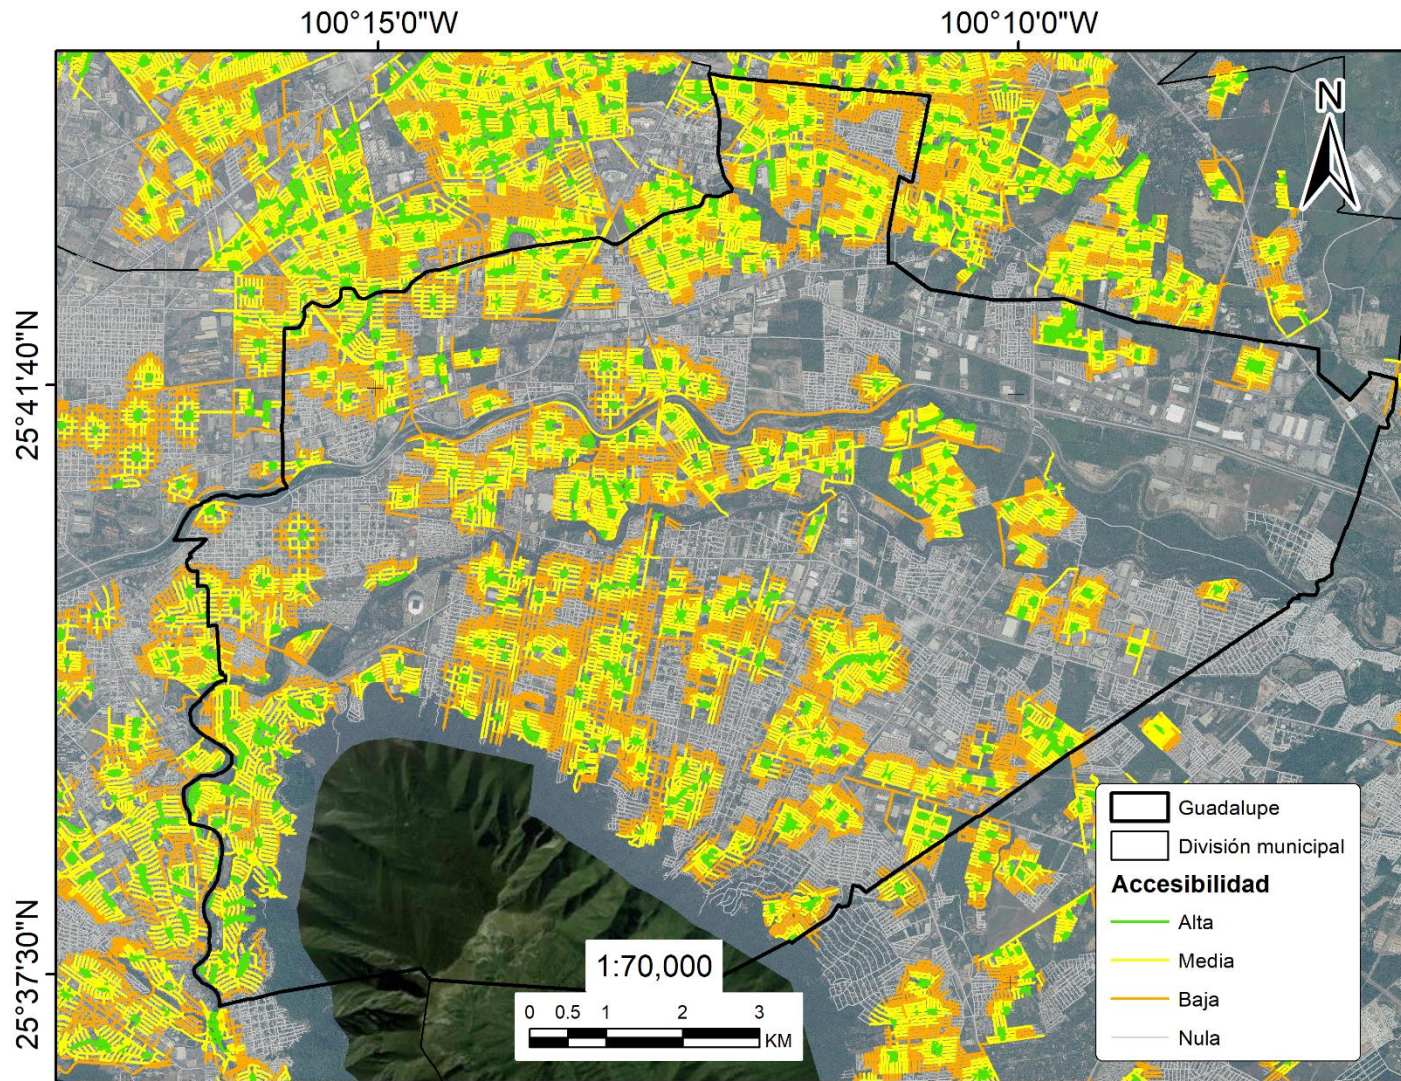


Figura 73. Índice de accesibilidad a AVU para el municipio de Guadalupe, Nuevo León (Elaboración propia).

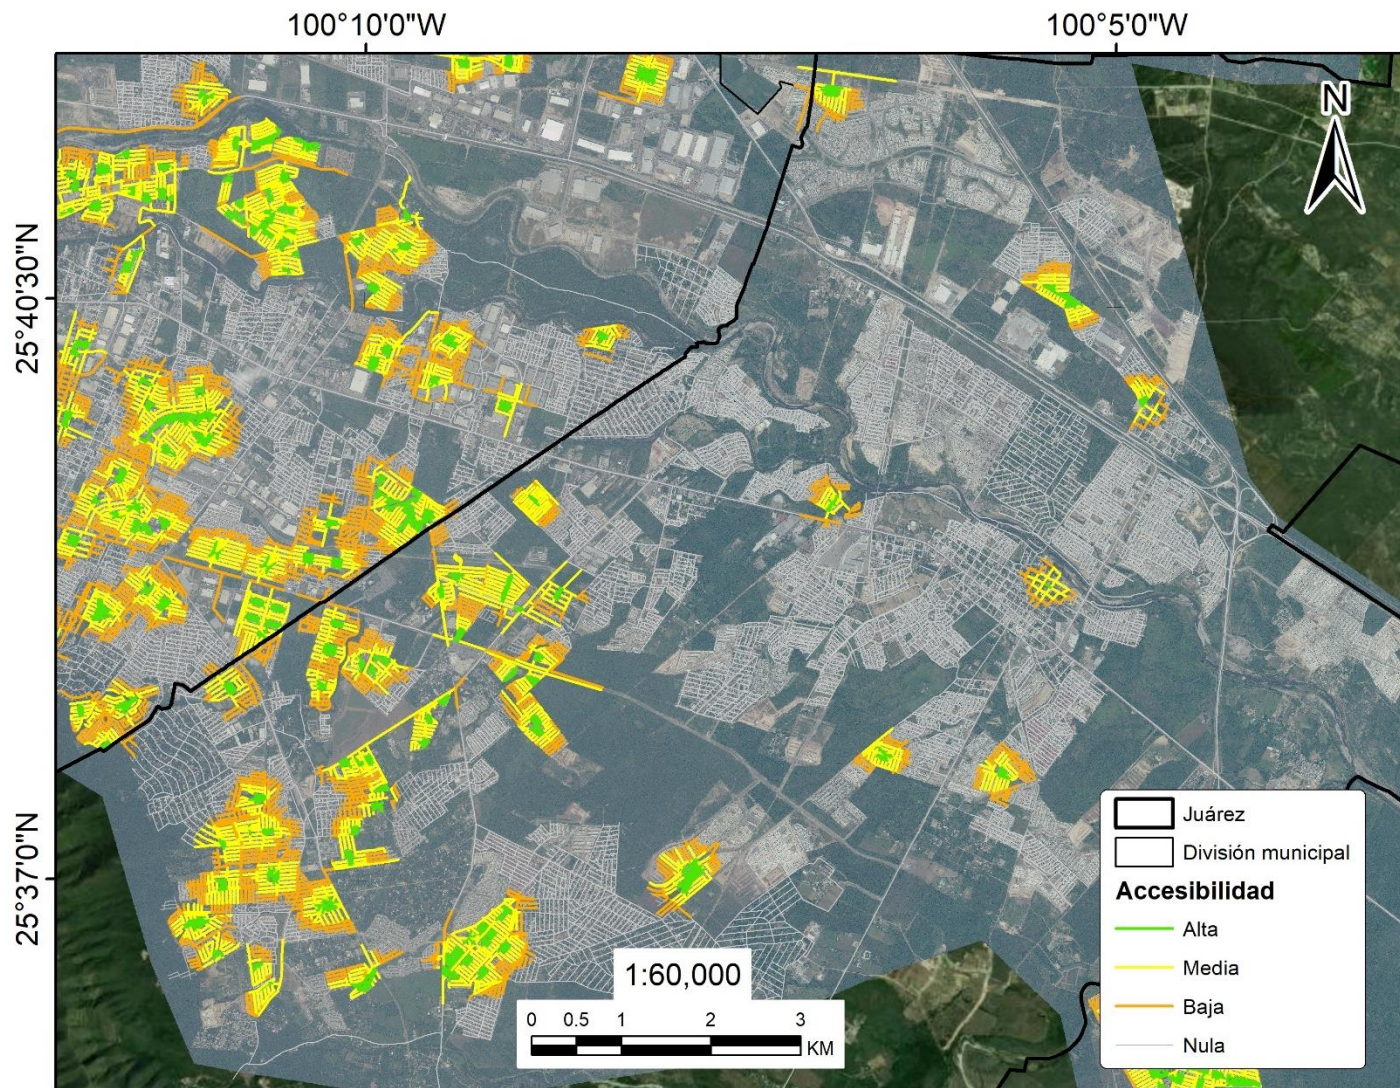


Figura 74. Índice de accesibilidad a AVU para el municipio de Juárez, Nuevo León (Elaboración propia).

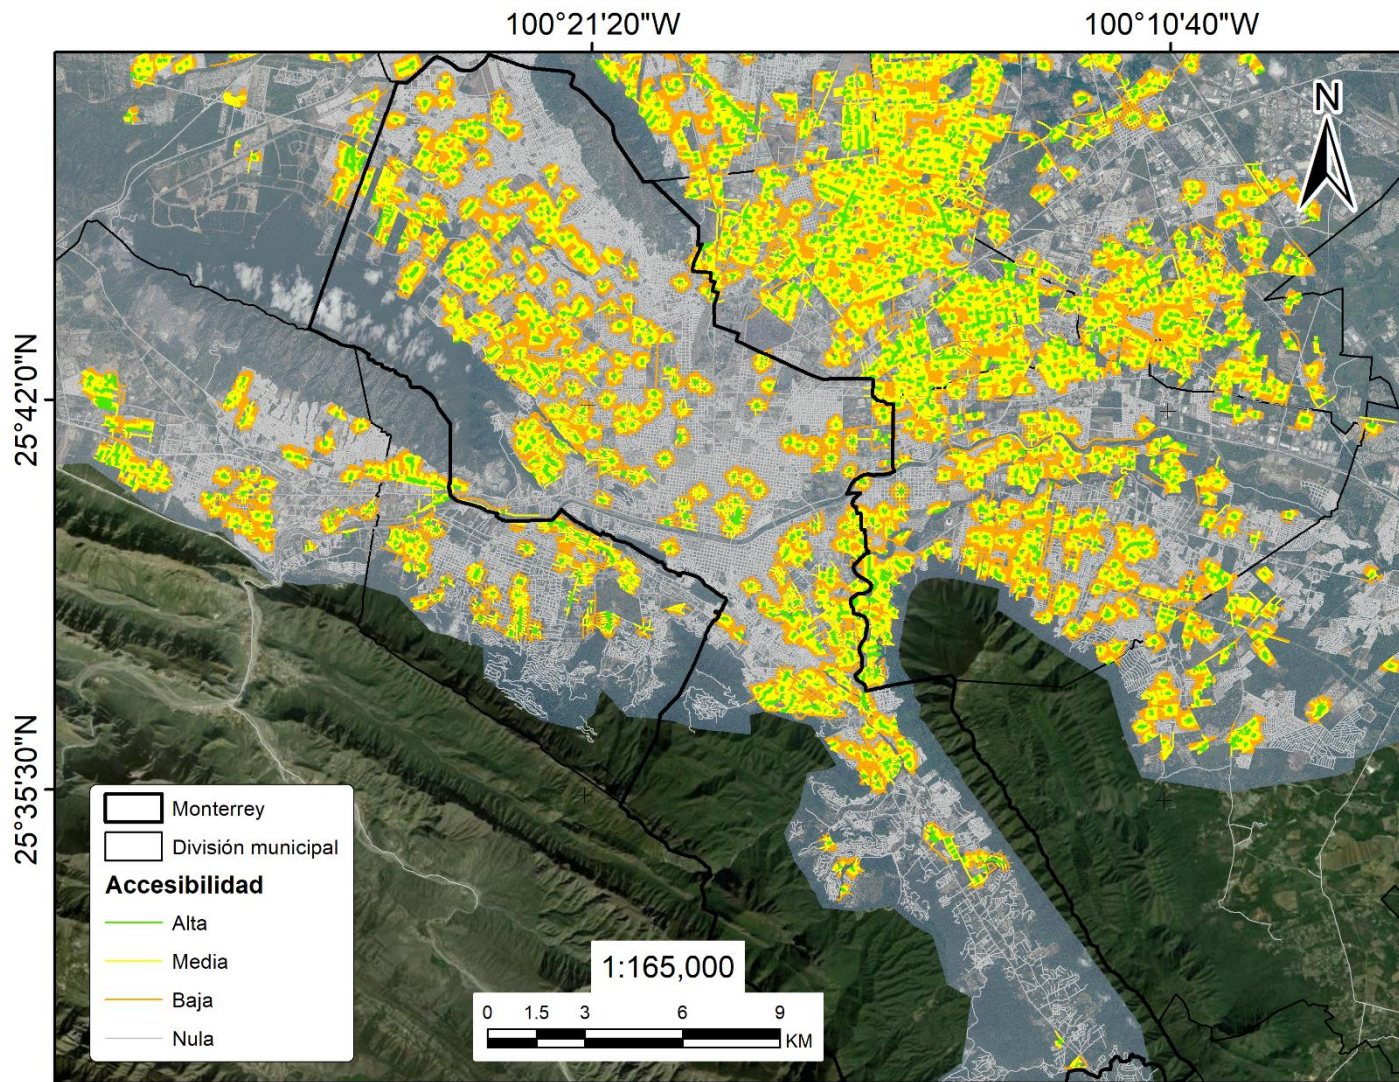


Figura 75. Índice de accesibilidad a AVU para el municipio de Monterrey, Nuevo León (Elaboración propia).

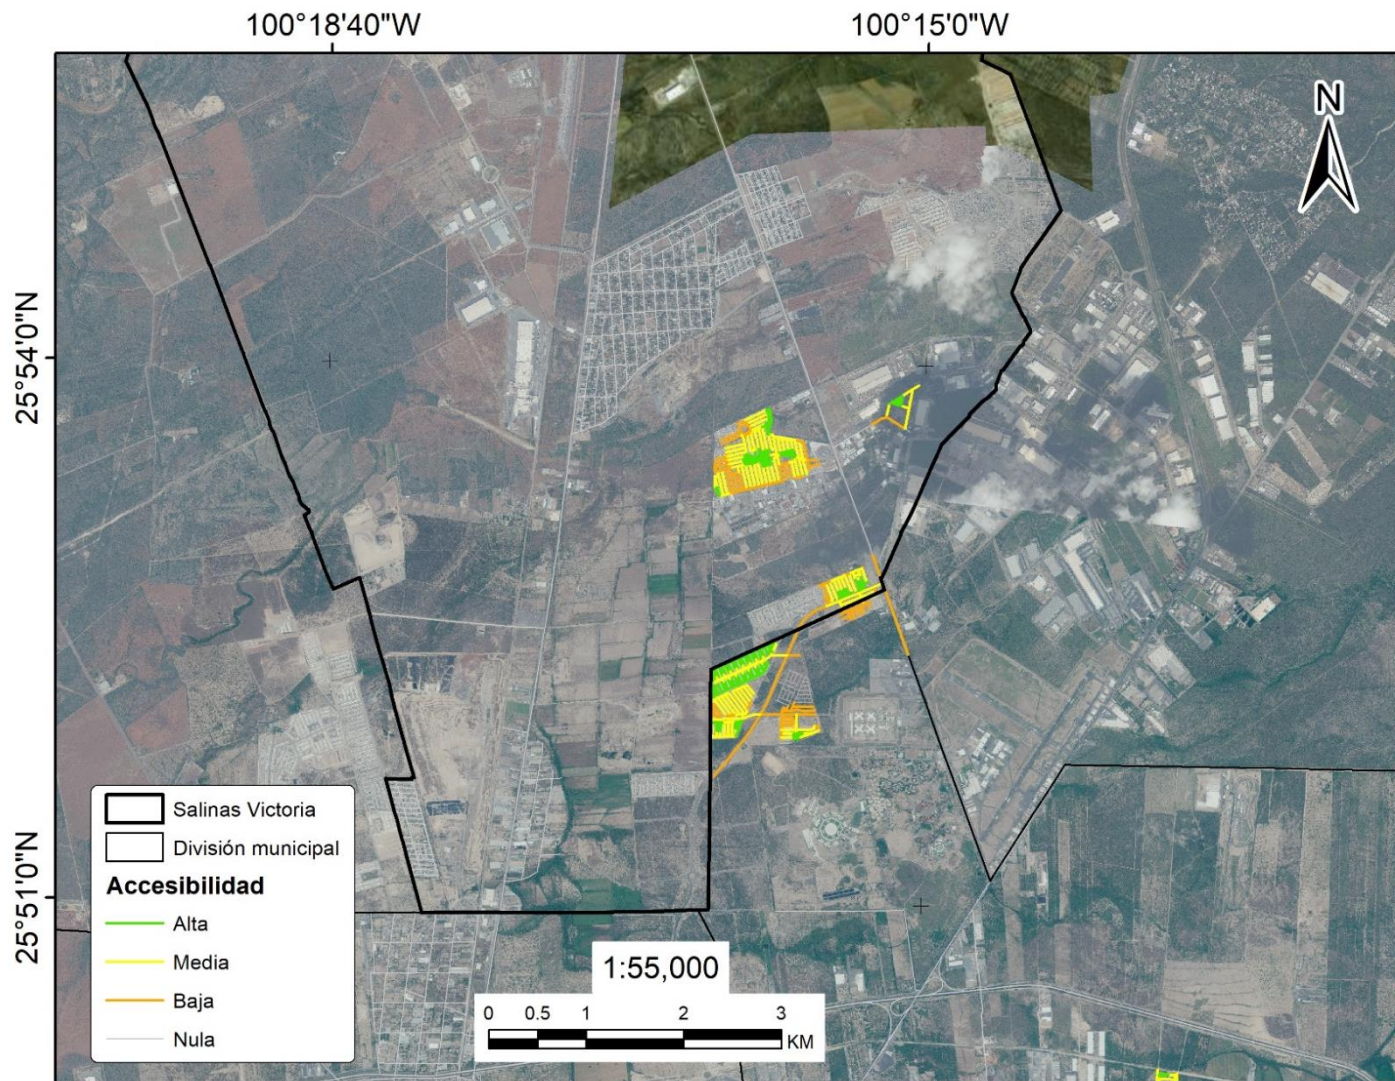


Figura 76. Índice de accesibilidad a AVU para el municipio de Salinas Victoria, Nuevo León (Elaboración propia).

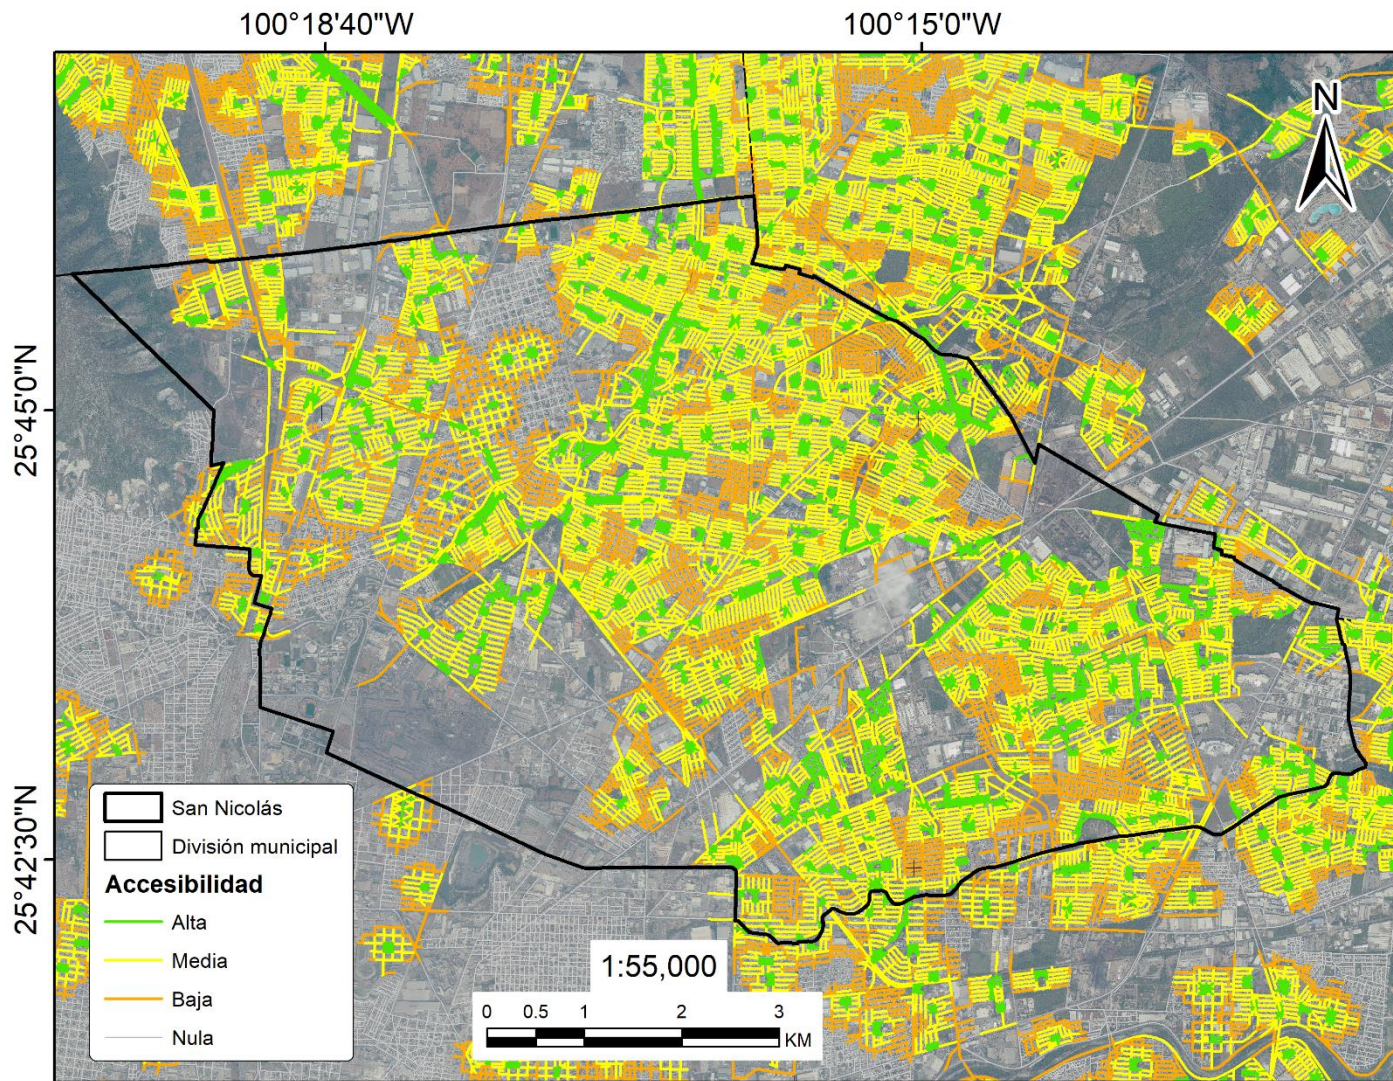


Figura 77. Índice de accesibilidad a AVU para el municipio de San Nicolás de los Garza, Nuevo León (Elaboración propia).

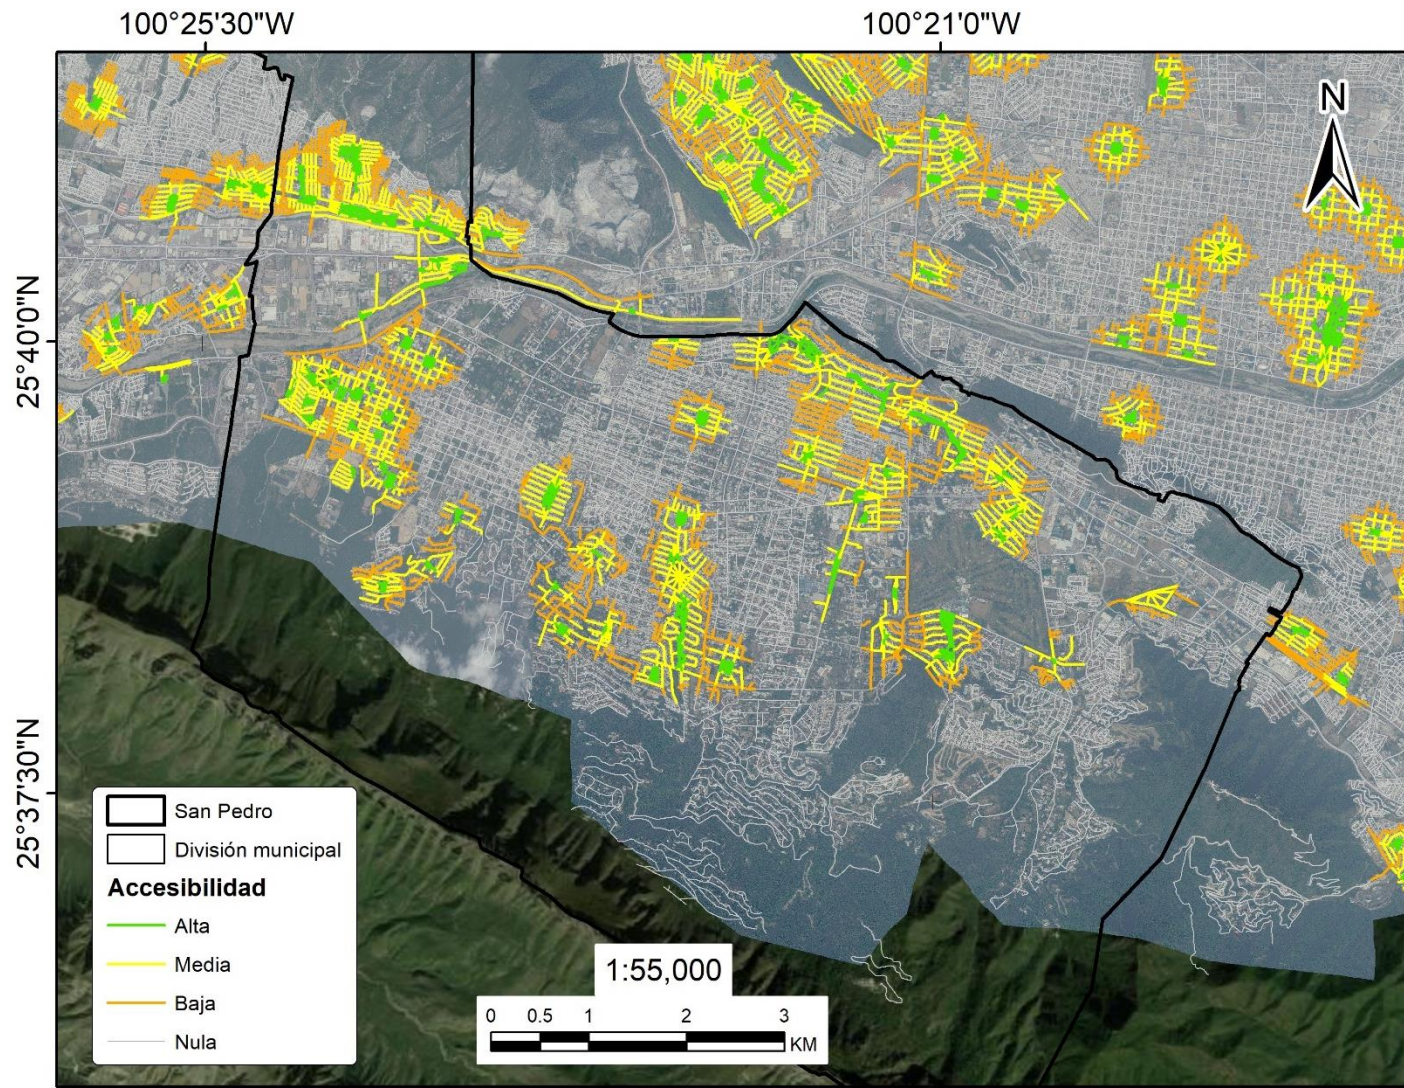


Figura 78. Índice de accesibilidad a AVU para el municipio de San Pedro Garza García, Nuevo León (Elaboración propia).

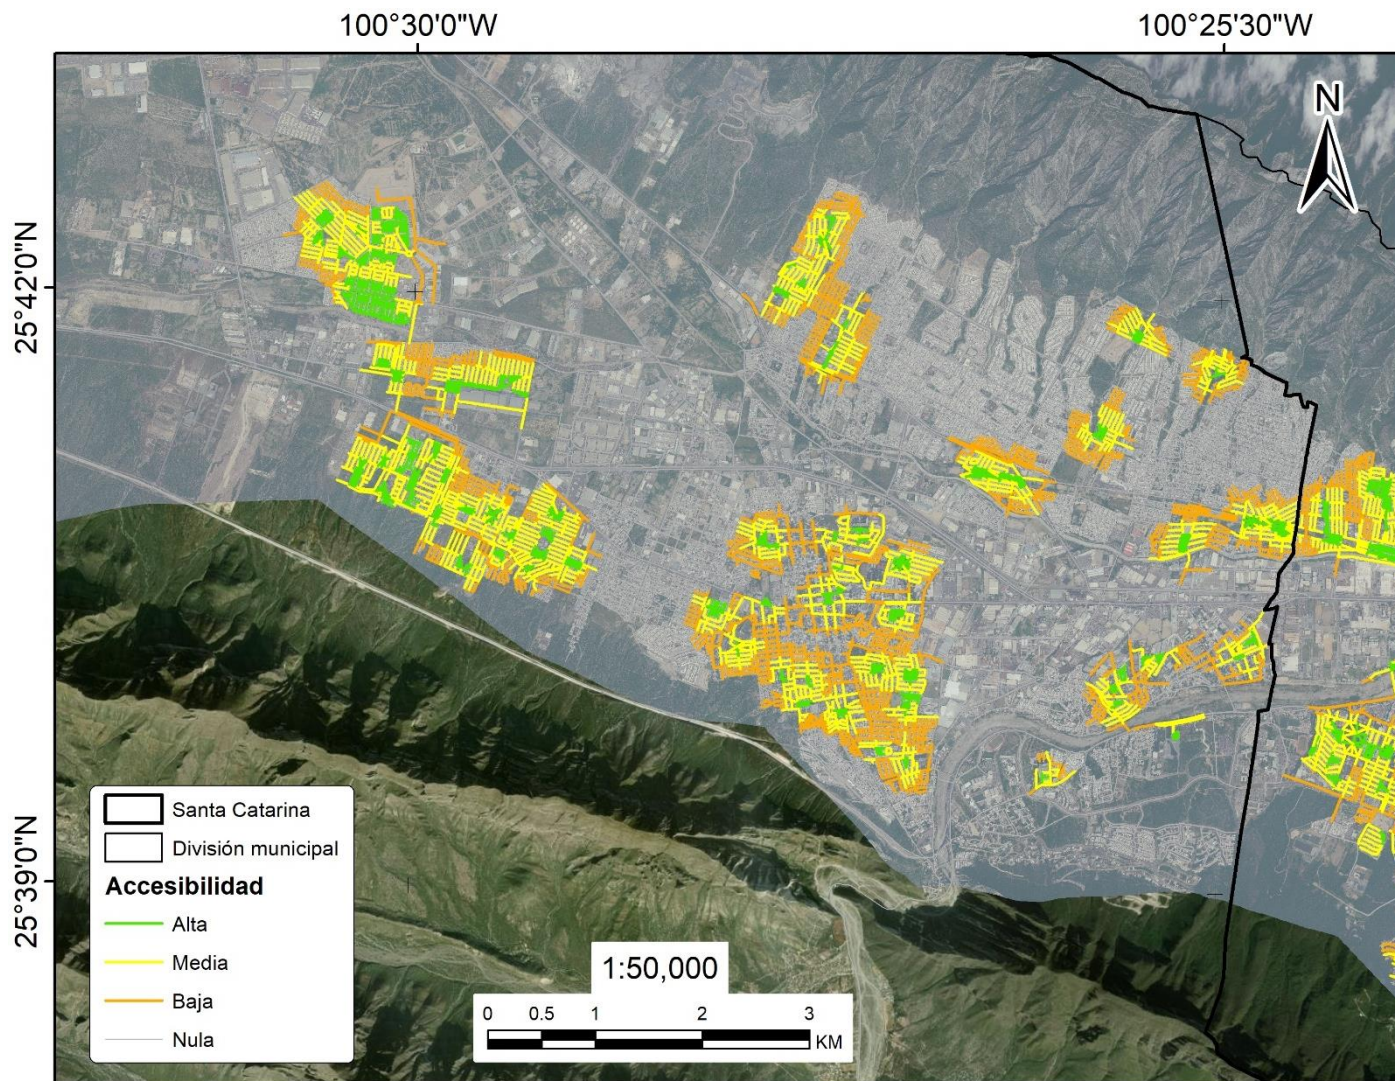


Figura 79. Índice de accesibilidad a AVU para el municipio de Santa Catarina, Nuevo León (Elaboración propia).

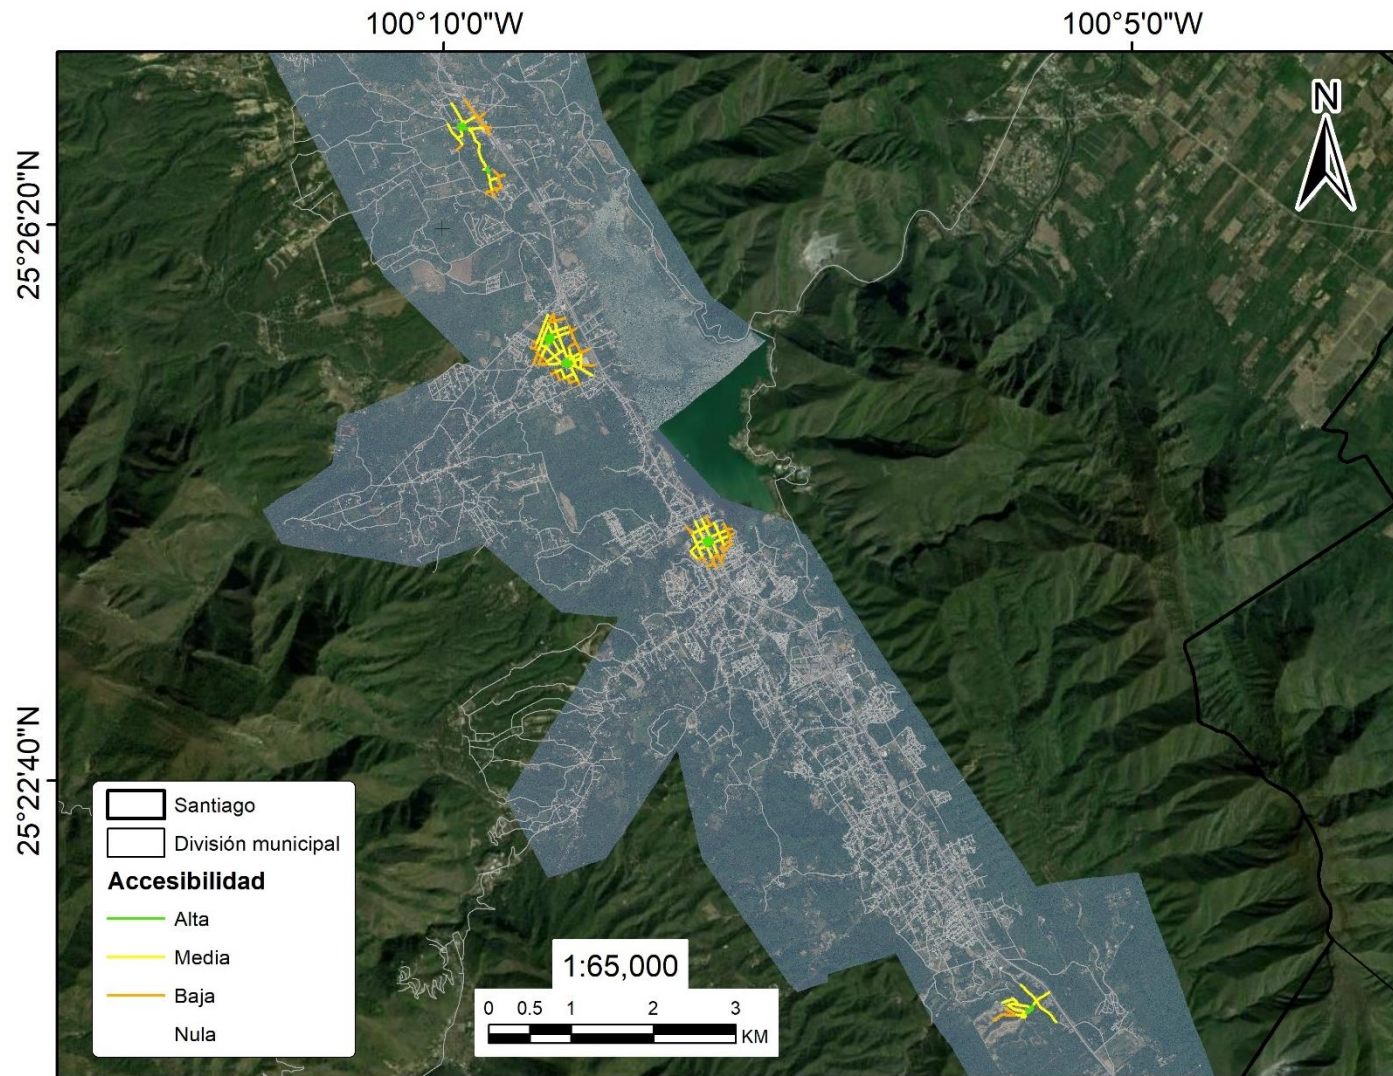


Figura 80. Índice de accesibilidad a AVU para el municipio de Santiago, Nuevo León (Elaboración propia).

Los resultados obtenidos a través del proceso de unión espacial que permitieron conocer la accesibilidad a las AVU por parte de la población de la ZMM, así como la de los otros grupos bajo análisis se muestran en la Figura 81. Para casi todos los grupos, incluyendo la población total, se observa una misma tendencia, donde predomina el nulo acceso a las AVU a través de rutas que se puedan recorrer caminando a no más de 300. La única excepción a lo anterior se observa en la población de 65 años o más, en la cual la mayoría presenta un grado de accesibilidad de bajo. Del resto de la población que tiene acceso a las AVU, la mayoría se encuentra en un intervalo de medio a bajo, es decir que, para llegar a la AVU más cercana a sus hogares deben recorrer un traslado mediante impedancia de 200 a 300 metros. De forma generalizada, todos los grupos poblacionales analizados presentaron una baja proporción de habitantes (3.97% en promedio) que cuenta con un alto grado de acceso a las AVU, siendo incluso más bajo del promedio para la población discapacitada (2.97%).




Figura 81. Indicadores de accesibilidad a las AVU para la ZMM (Elaboración propia).

En las Figuras 82 – 92 se muestran los gráficos de los indicadores de accesibilidad obtenidos en el nivel municipal y las tablas para su generación están en el Anexo.




Figura 82. Indicadores de accesibilidad a las AVU para Apodaca, Nuevo León (Elaboración propia).




Figura 83. Indicadores de accesibilidad a las AVU para Cadereyta, Nuevo León (Elaboración propia).




Figura 84. Indicadores de accesibilidad a las AVU para General Escobedo, Nuevo León (Elaboración propia).




Figura 85. Indicadores de accesibilidad a las AVU para García, Nuevo León (Elaboración propia).




Figura 86. Indicadores de accesibilidad a las AVU para Guadalupe, Nuevo León (Elaboración propia).




Figura 87. Indicadores de accesibilidad a las AVU para Juárez, Nuevo León (Elaboración propia).




Figura 88. Indicadores de accesibilidad a las AVU para Monterrey, Nuevo León (Elaboración propia).




Figura 89. Indicadores de accesibilidad a las AVU para Santa Catarina, Nuevo León (Elaboración propia).




Figura 90. Indicadores de accesibilidad a las AVU para Santiago, Nuevo León (Elaboración propia).




Figura 91. Indicadores de accesibilidad a las AVU para San Nicolás de los Garza, Nuevo León (Elaboración propia).




Figura 92. Indicadores de accesibilidad a las AVU para San Pedro Garza García, Nuevo León (Elaboración propia).

Dentro de los resultados de los indicadores de accesibilidad para cada uno de los municipios de la ZMM, destacan los valores mostrados por el municipio de San Nicolás de los Garza (Figura 91), que contó con la más alta accesibilidad de toda la ZMM, con un valor promedio, para todos los grupos analizados, del 96.78% y presentando el más elevado porcentaje de población que proporciona un alto nivel de acceso a las AVU municipales, con un 10.55%. Si bien, el municipio de Apodaca presentó una menor proporción de grupos de población con alto acceso a sus AVU, es el segundo municipio con mayor cobertura de accesibilidad, con una proporción del 92.23%. Municipios como Guadalupe, Cadereyta y San Pedro Garza García presentan valores de accesibilidad iguales o superiores al promedio calculado para la ZMM, mientras que Escobedo, Santa Catarina, Monterrey, García y Juárez se encontraron por debajo del promedio de la región. El municipio de Santiago presentó una muy baja proporción de AVU accesibles para sus habitantes (9.63%), en la que predomina un nivel de accesibilidad bajo. Para el municipio de Salinas Victoria no fue posible realizar los análisis debido a la falta de información de la población.

CAPÍTULO 11. RESULTADOS: VALIDACIÓN DE PRECISIÓN.

En las Figuras 93 – 108 se muestran los mapas del índice NDVI producido para las imágenes de Sentinel-2 como para el modelo obtenido mediante fotorreconstrucción y levantamiento de información a través de VANT. El cálculo de sus estadísticas por zona se muestra en las Tablas 20 y 21. Se observa una subestimación por parte de los valores medios obtenidos para las imágenes producidas a partir de imágenes de VANT. La comparación de las medias de ambos métodos arroja valores de 0.35 para el índice NDVI de las imágenes Sentinel-2, mientras que el método de VANT y fotorreconstrucción produjo un valor promedio de 0.29, existiendo una diferencia, entre ambos, de 0.06.

Tabla 20. Estadísticas por zona de los valores de NDVI generados para las muestras obtenidas en imágenes Sentinel-2 (Elaboración propia).

Sentinel-2						
Clave	Area	NDVI mínimo	NDVI máximo	Rango	Media	Desviación estándar
SN1	788.75	0.02	0.83	0.81	0.33	0.14
SN2	5623.25	-0.09	0.87	0.96	0.34	0.15
SN3	14058.50	0.00	0.88	0.88	0.37	0.12
ESC1	6315.00	0.04	0.99	0.95	0.50	0.11
ESC2	2254.75	-0.19	0.87	1.06	0.29	0.14
ESC3	16547.00	-0.16	0.88	1.04	0.23	0.10
ESC4	2916.25	0.08	0.97	0.89	0.36	0.11
ESC5	4726.50	-0.08	0.83	0.91	0.35	0.13

Tabla 21. Estadísticas por zona de los valores de NDVI generados para las muestras obtenidas del producto obtenido mediante fotografías de VANT y fotorreconstrucción (Elaboración propia).

VANT + Fotorreconstrucción						
Clave	Área	NDVI mínimo	NDVI máximo	Rango	Media	Desviación estándar
SN1	788.75	-0.99	0.98	1.98	0.24	0.07
SN2	5623.25	-0.99	0.91	1.91	0.29	0.06
SN3	14058.50	-0.99	0.98	1.98	0.32	0.07
ESC1	6315.00	-0.99	0.98	1.98	0.46	0.07
ESC2	2254.75	-0.99	0.98	1.98	0.24	0.07
ESC3	16547.00	-0.99	0.87	1.86	0.18	0.07
ESC4	2916.25	-0.99	0.95	1.94	0.31	0.07
ESC5	4726.50	-0.99	0.96	1.95	0.31	0.07




Figura 94. Índice NDVI calculado para el polígono SN1 (col. Anáhuac) en la imagen satelital Sentinel-2 (Elaboración propia).




Figura 93. Índice NDVI calculado para el polígono SN1 (col. Anáhuac) en el ortomosaico de fotorreconstrucción obtenida a través de VANT (Elaboración propia).




Figura 96. Índice NDVI calculado para el polígono SN2 (San Nicolás centro) en la imagen satelital Sentinel-2 (Elaboración propia).

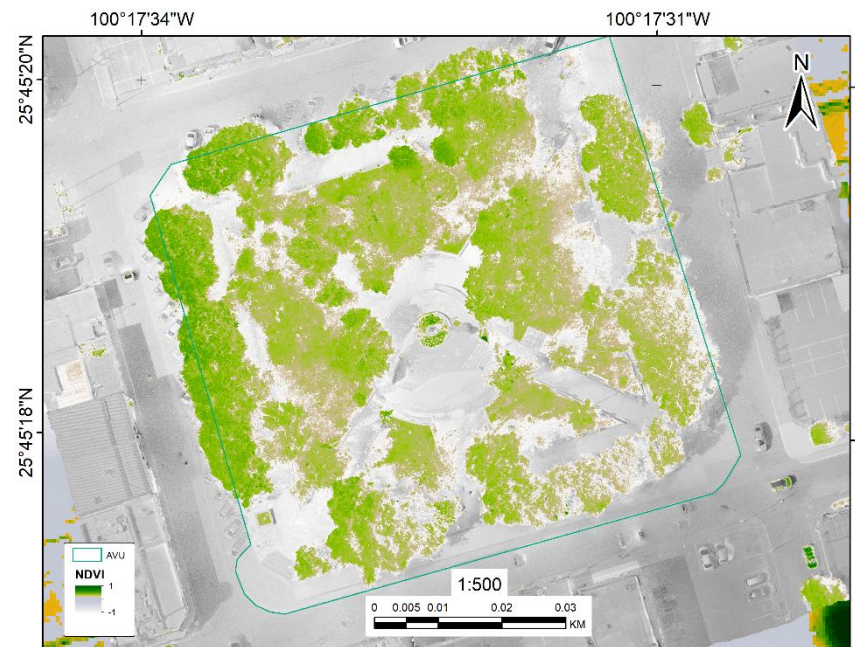


Figura 95. Índice NDVI calculado para el polígono SN2 (San Nicolás centro) en el ortomosaico de fotorreconstrucción obtenida a través de VANT (Elaboración propia).




Figura 98. Índice NDVI calculado para el polígono SN3 (Residencial San Nicolás) en la imagen satelital Sentinel-2 (Elaboración propia).

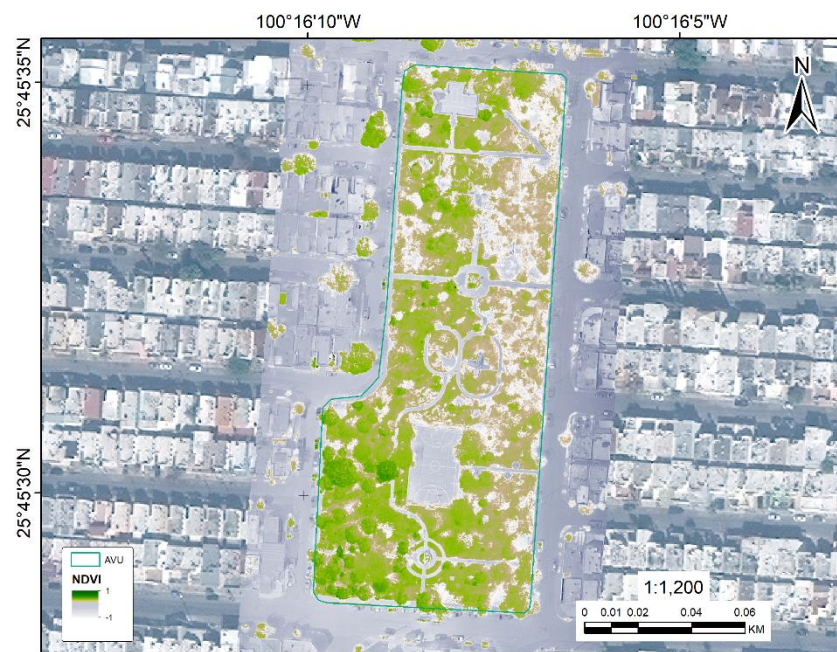


Figura 97. Índice NDVI calculado para el polígono SN3 (Residencial San Nicolás) en el ortomosaico de fotorreconstrucción obtenida a través de VANT (Elaboración propia).

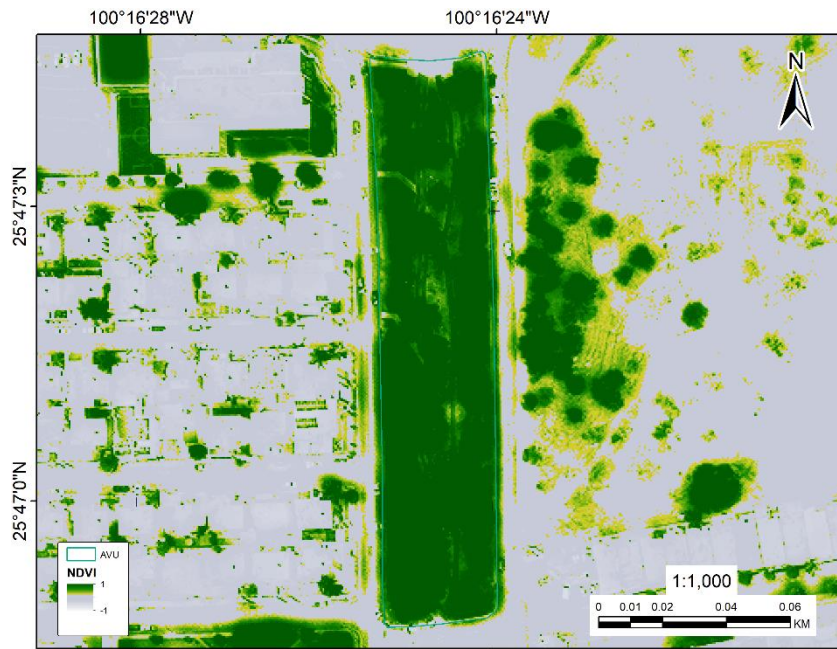


Figura 100. Índice NDVI calculado para el polígono ESC1 (av. Concordia) en la imagen satelital Sentinel-2 (Elaboración propia).

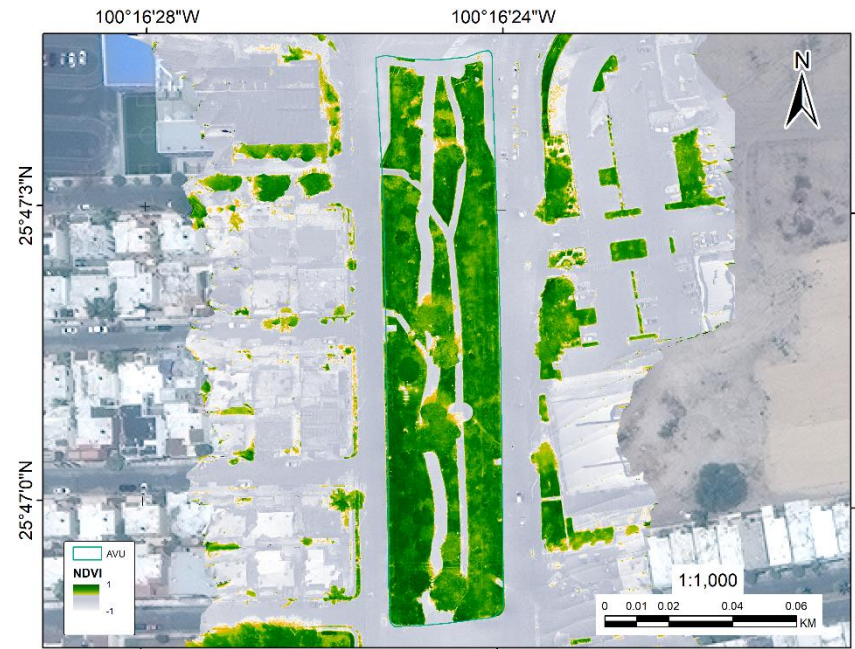


Figura 99. Índice NDVI calculado para el polígono ESC1 (av. Concordia) en el ortomosaico de fotorreconstrucción obtenida a través de VANT (Elaboración propia).




Figura 102. Índice NDVI calculado para el polígono ESC2 (calle República Mexicana) en la imagen satelital Sentinel-2 (Elaboración propia).




Figura 101. Índice NDVI calculado para el polígono ESC2 (calle República Mexicana) en el ortomosaico de fotorreconstrucción obtenida a través de VANT (Elaboración propia).

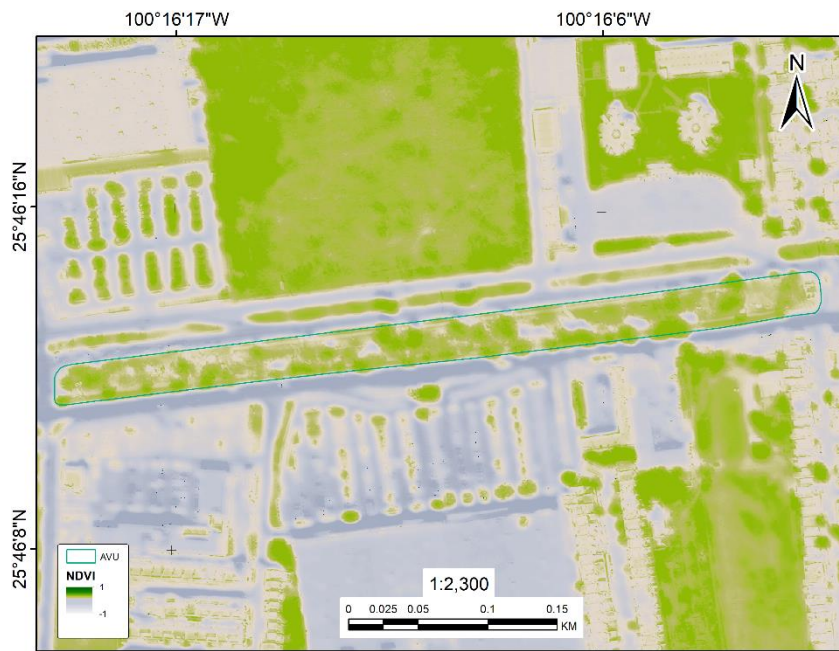


Figura 104. Índice NDVI calculado para el polígono ESC3 (av. Sendero) en la imagen satelital Sentinel-2 (Elaboración propia).



Figura 103. Índice NDVI calculado para el polígono ESC3 (av. Sendero) en el ortomosaico de fotorreconstrucción obtenida a través de VANT (Elaboración propia).




Figura 106. Índice NDVI calculado para el polígono ESC4 (av. Morenita Mía) en la imagen satelital Sentinel-2 (Elaboración propia).




Figura 105. Índice NDVI calculado para el polígono ESC4 (av. Morenita Mía) en el ortomosaico de fotorreconstrucción obtenida a través de VANT (Elaboración propia).



Figura 108. Índice NDVI calculado para el polígono ESC5 (calle Abeto) en la imagen satelital Sentinel-2 (Elaboración propia).




Figura 107. Índice NDVI calculado para el polígono ESC5 (calle Abeto) en el ortomosaico de fotorreconstrucción obtenida a través de VANT (Elaboración propia).

DISCUSIÓN

Los modelos de RNC empleados para la segmentación semántica de AVU proveen información de utilidad que puede emplearse para conocer la geometría, las condiciones, así como los atributos espaciales y la información que permita agilizar la toma de decisiones respecto a este tipo de espacios públicos. Aunado a lo anterior, la actualización de las bases de datos provee información para inventarios nacionales, permitiendo llevar un registro de la evolución de las AVU dentro del tejido urbano, lo cual es de importancia en la evaluación de su distribución y manejo.

El tipo de información producido con los métodos empleados en este proyecto permite conocer la interacción del tejido social con dichos elementos urbanos, al cruzar información demográfica con las bases de datos de AVU. De tal forma es posible evaluar la conectividad de estos entornos y la accesibilidad de la población a los servicios que estas áreas brindan. Adicionalmente, la información generada proporciona elementos que ayudan en el cumplimiento del objetivo 11.7.1 de los Objetivos de desarrollo sostenible, al permitir evaluar el acceso de las mujeres, de los niños, de las personas de edad y de personas con discapacidad a las AVU.

El aumento de los datos es un factor importante para llevar a cabo un adecuado entrenamiento de RNC. Con éste se evita la memorización de las etiquetas de entrada y, a la vez, se le provee de suficiente información a la red para detectar una gran variedad de patrones que permitan identificar los objetos de interés. En este estudio esta técnica aumentó la cantidad de ortomosaicos de entrada en aproximadamente un millón. Las variaciones presentes en esta información ayudaron a obtener un conjunto de datos de entrenamiento más completo, al cubrir variaciones presentes en las imágenes debido a la temporalidad o a las disparidades ambientales.

De acuerdo con los resultados de la validación del modelo de segmentación semántica y sus análisis estadísticos, existe diferencia significativa (0.05) entre el coeficiente Dice de las diferentes composiciones de bandas analizadas en ambos modelos. El codificador ResNet34 obtuvo los mejores resultados usando la

combinación de bandas NDVI-roja-IRC, mientras que con el codificador ResNet50 se obtuvo un mejor desempeño con la combinación de bandas roja-verde-azul.

La gran diferencia presente entre los resultados de la precisión de validación y el coeficiente Dice fue dada debido al uso de datos con desbalance de clases. Al haber una gran cantidad de píxeles correspondientes a la clase de no-AVU, la precisión de su clasificación fue alta para la totalidad del área. Por otro lado, el coeficiente Dice es más confiable en este tipo de problemas, debido a que produce una métrica exclusivamente basada en las clases segmentadas de interés.

Estudios en donde se ha aplicado la segmentación semántica para el mapeo de cobertura vegetal han demostrado que es posible obtener coeficientes Dice de hasta 0.94 (Khryashchev, Larionov, Ostrovskaya, & Semenov, 2019; Molina & Zhang, 2019; Timilsina, Aryal, & Kirkpatrick, 2020). Si bien el resultado del coeficiente Dice de este trabajo es mucho menor (0.57), se debe tener en consideración que dichos estudios están basados en áreas limitadas y en elementos de menor complejidad, como la segmentación de las copas de los árboles. En este trabajo se buscó cubrir la necesidad de generar información de las AVU, considerando toda la infraestructura con la que dichos espacios cuentan. Lo anterior se realizó de manera automatizada para toda una ZM.

Los análisis de traslape, de intersección sobre unión (IoU) y el coeficiente Kappa que se produjeron en la evaluación del modelo indican una fuerte relación entre los polígonos generados a partir de las predicciones y las etiquetas de entrada. Con resultados de análisis de traslape de 0.80, IoU de 0.75 y coeficiente Kappa de 0.94, se alcanzó una alta precisión, como la reportada en trabajos recientes relacionados con el mapeo de AVU (Lahoti, Kefi, Lahoti, & Saito, 2019; X. Sun et al., 2020). Lo anterior indica que el método empleado en este estudio es preciso para la extracción y la actualización de las bases de datos de AVU en el nivel metropolitano.

La comparación de las condiciones de vegetación mediante el uso de índices de vegetación permitió detectar diferencias entre los distintos índices, conforme a su funcionamiento. Por ejemplo, se observa que, a pesar de que se detecten mejoras en las condiciones de los índices NDVI y EVI2 en el periodo de 5 años que fue

analizado, lo mismo no se puede decir para el índice NDWI. Lo anterior puede estar relacionado con las condiciones de estrés hídrico y desabastecimiento de agua de la región. Por otra parte, en los resultados se observa la influencia de diversos elementos, como el suelo y los efectos atmosféricos que, a través de índices como el EVI2 se buscan corregir. El análisis multitemporal sugiere una mejora gradual en las condiciones de la vegetación de la ZMM, con ejemplos como los municipios de Juárez, Guadalupe, Apodaca y San Nicolás de los Garza, que pasaron de tener condiciones moderadas a buenas, conforme al índice EVI2.

El análisis de conectividad permitió determinar la cobertura de AVU, la fragmentación, el tamaño de parche promedio, la forma y la complejidad, entre otros parámetros. Lo anterior es de relevancia para adaptar medias de gestión de AVU, conforme a la información obtenida mediante este análisis. Un ejemplo es el municipio de Monterrey, que presenta la mayor cantidad de AVU con forma elongada. Lo anterior implica que los camellones predominan en su paisaje, por lo que, si se quisiera realizar alguna campaña de reforestación en la zona, sería adecuado considerar de forma prioritaria especies apropiadas para este tipo de espacios.

El análisis de densidad de las AVU permitió conocer la cantidad de AVU disponibles en las manzanas de la ZMM, lo cual se complementa con la información producida en el análisis de accesibilidad que relaciona directamente a la población con estos espacios. La elaboración del análisis de accesibilidad mediante el uso de un análisis de red proporciona recursos invaluable para la determinación de los espacios geográficos que requieren que se realicen acciones para brindar los beneficios que proporcionan las AVU.

Los resultados de la validación de la precisión arrojaron valores que subestiman el cálculo del índice NDVI. Lo anterior pudiera relacionarse con la complejidad de la forma de las copas de los árboles, que al ser fotorreconstruidos pierden información por tratarse de una superficie irregular con presencia de huecos. No obstante, la media de los resultados obtenidos partiendo de las imágenes satelitales, en contraste con los de la fotorreconstrucción a partir de imágenes adquiridas mediante

VANT presentaron una diferencia 0.06, resultando menor que la variabilidad presente mediante el uso de ambos métodos. Los resultados que se obtienen a través de imágenes provenientes de VANT presentan una muy alta resolución espacial, permitiendo la generación de productos con resoluciones de centímetros por píxel, ideales para obtener gran detalle del área de interés. Por otro lado, los productos provenientes de sensores montados en satelitales, como las imágenes satelitales correspondientes a Sentinel-2, poseen menores resoluciones, pero en cambio cuentan con una resolución temporal más amplia, permitiendo realizar la evaluación de las condiciones de AVU a través de periodos de tiempo más amplios.

CONCLUSIONES Y RECOMENDACIONES.

CONCLUSIONES

1. Los modelos de accesibilidad y conectividad producidos usando como entrada la información de AVU que se generó a partir de RNC, mediante segmentación semántica, eficientizan la gestión de las AVU, al permitir la producción de forma automatizada de datos, a nivel metropolitano. Estos modelos permiten la generación de mapas e indicadores actualizados que sirven a los tomadores de decisiones para conocer la situación actual de las AVU respecto a su ubicación geográfica, sus condiciones, su conectividad y su accesibilidad.
2. En este proyecto se evaluaron dos modelos de RNC en 12 combinaciones de bandas para la segmentación semántica de polígonos de AVU a partir de imágenes satelitales de muy alta resolución (WV2). Ambos modelos, de arquitectura dinámica U-Net con codificadores ResNet-34 y ResNet-50, permitieron automatizar la obtención de información de AVU, al conseguir detectar los patrones geométricos para la identificación automática de los diferentes tipos de polígonos de AVU presentes en la ZMM. Para corroborar la eficacia de las redes en el proceso de segmentación, se emplearon las métricas de evaluación de traslape (0.80), IoU (0.75) y el coeficiente Kappa (0.94), que en conjunto indican una buena relación geoespacial de las predicciones respecto a los polígonos empleados como verdad fundamental. La implementación de este tipo de modelos permite automatizar la actualización de la información de las AVU a nivel metropolitano para la evaluación del manejo urbano, que va de la mano con el crecimiento de las ciudades.
3. A través de técnicas de percepción remota se obtuvieron los índices de vegetación NDVI, EVI2 y NDWI, a partir de imágenes Sentinel-2 correspondientes a los años 2016 y 2021. Estos índices permitieron analizar las condiciones de la vegetación en la ZMM, a través de la generación de mapas en los niveles de municipio y de manzana, logrando con ello, identificar los cambios en condiciones en el intervalo de tiempo analizado.

4. A través del análisis de la fragmentación del paisaje, haciendo uso de los polígonos de AVU que se generaron a partir de la segmentación semántica, se obtuvieron indicadores de la conectividad de las AVU presentes en la ZMM, respecto a su tamaño, forma y complejidad. La generación de estos parámetros permitió la producción de información que ayuda a entender los patrones de la disposición de las AVU en la metrópoli. Se produjeron mapas de densidad de AVU, que permiten conocer su proporción con respecto a las manzanas de la ZMM. En el cálculo del índice de accesibilidad, obtenido a través de un análisis de red, se empleó la topología de las vialidades y los polígonos de AVU generados a través de RNC, para conocer la distancia que la población debe recorrer para acceder a las AVU más cercanas a sus hogares; lo anterior permitió la generación de mapas del índice de accesibilidad, y el cruce de ésta información, con datos demográficos, dio pie a la generación de gráficos de barras que muestran el indicador 11.7.1 de los Objetivos de desarrollo sostenible, que busca hacer accesible estos espacios a diversos grupos de la población.
5. Se realizó el levantamiento de conjuntos fotográficos aéreos de AVU, en campo, mediante el uso de VANT. Posteriormente se generó su modelo digital, a través de técnicas de fotorreconstrucción. Mediante técnicas de percepción remota, se produjo el índice NDVI para la posterior comparación de sus estadísticas zonales, con el índice NDVI resultante del análisis de imágenes satelitales Sentinel-2. La comparación de las medias de los resultados permitió validar la precisión de los datos empleados este proyecto.

RECOMENDACIONES

La calidad de los resultados de las RNC se relaciona directamente con la cantidad de muestras, es decir, de imágenes presentes en el conjunto de datos de entrenamiento. Por ello, conforme mayor cantidad de imágenes de AVU de un sitio y mayor variedad de ejemplos, mejores serán los resultados de las predicciones que se obtengan.

Si bien los indicadores de la fragmentación del paisaje permiten tener una idea de la conectividad de una ZU, se recomienda continuar la elaboración de estudios que analicen las interacciones geoespaciales que se presentan entre las AVU.

Para la continuación de este trabajo se sugiere el empleo de los datos actualizados de forma automática para el análisis de problemáticas que aquejan a las metrópolis, como: el rol de la vegetación en la fijación de contaminantes atmosféricos, la importancia de las AVU como infraestructura verde para la infiltración de aguas al subsuelo y amortiguadores de condiciones climáticas extremas como las ondas de calor presentes en la ZMM.

Esta metodología es reproducible y escalable a otras ciudades o ZM del país.

BIBLIOGRAFIA

1. Abraham, N., & Khan, N. M. (2019). A novel focal tversky loss function with improved attention u-net for lesion segmentation. En *Proceedings - International Symposium on Biomedical Imaging*. <https://doi.org/10.1109/ISBI.2019.8759329>
2. Aguilar-Benitez, I., & Montforte, G. (2018). Servicios públicos del agua, valor público y sostenibilidad. El caso del área metropolitana de Monterrey. *Gestión y Política Pública*.
3. Aguilera, G., Ekroos, J., Persson, A. S., Pettersson, L. B., & Öckinger, E. (2019). Intensive management reduces butterfly diversity over time in urban green spaces. *Urban Ecosystems*. <https://doi.org/10.1007/s11252-018-0818-y>
4. Akpinar, A. (2016). How is quality of urban green spaces associated with physical activity and health? *Urban Forestry and Urban Greening*. <https://doi.org/10.1016/j.ufug.2016.01.011>
5. Alanis, G., Foroughbakhch, R., Alvarado, M., & Rocha, A. (2004). El Arbolado Urbano en el Área Metropolitana de Monterrey (AMM), Nuevo León, México, 2.
6. Albert, A., Kaur, J., & González, M. C. (2017). Using Convolutional Networks and Satellite Imagery to Identify Patterns in Urban Environments at a Large Scale, 54-57. <https://doi.org/10.1145/nnnnnnn.nnnnnnn>
7. Alexandre da Silva, G. J., Ribeiro da Silveira, J. A., & Leite Ribeiro, E. (2019). Ciudades Compactas Y Verdes: Discusiones Sobre La Calidad De Vida Y La Sostenibilidad Urbana. *Revista M*, 14, 4-27. <https://doi.org/10.15332/rev.m.v14i0.2170>
8. Amari, S. ichi. (2016). Machine Learning. En *Applied Mathematical Sciences (Switzerland)*. https://doi.org/10.1007/978-4-431-55978-8_11
9. Arnab, A., & Torr, P. H. S. (2017). Pixelwise instance segmentation with a dynamically instantiated network. En *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*. <https://doi.org/10.1109/CVPR.2017.100>
10. Badrinarayanan, V., Kendall, A., & Cipolla, R. (2017). SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. <https://doi.org/10.1109/TPAMI.2016.2644615>

11. Bai, Y., Mas, E., & Koshimura, S. (2018). Towards operational satellite-based damage-mapping using U-net convolutional network: A case study of 2011 Tohoku Earthquake-Tsunami. *Remote Sensing*. <https://doi.org/10.3390/rs10101626>
12. Balduzzi, D., Fren, M., Leary, L., Lewis, J. P., Ma, K. W. D., & McWilliams, B. (2017). The shattered gradients problem: If resnets are the answer, then what is the question? En *34th International Conference on Machine Learning, ICML 2017*.
13. Bannari, A., Morin, D., Bonn, F., & Huete, A. R. (1995). A review of vegetation indices. *Remote Sensing Reviews*. <https://doi.org/10.1080/02757259509532298>
14. Baró, F. (2016). Urban Green Infrastructure. Modeling and mapping ecosystem services for sustainable planning and management in and around cities, 228. <https://doi.org/10.13140/RG.2.2.35758.92485/1>
15. Benavides Meza, H. M., & Young Fernández Grandizo, D. (2012). Estructura del arbolado y caracterización dasométrica de la segunda sección del Bosque de Chapultepec. *Madera Bosques*. <https://doi.org/10.21829/myb.2012.182352>
16. Benjelloun, M., El Adoui, M., Larhman, M. A., & Mahmoudi, S. A. (2018). Automated Breast Tumor Segmentation in DCE-MRI Using Deep Learning. En *2018 4th International Conference on Cloud Computing Technologies and Applications, Cloudtech 2018*. <https://doi.org/10.1109/CloudTech.2018.8713352>
17. Bini, S. A. (2018). Artificial Intelligence, Machine Learning, Deep Learning, and Cognitive Computing: What Do These Terms Mean and How Will They Impact Health Care? *Journal of Arthroplasty*. <https://doi.org/10.1016/j.arth.2018.02.067>
18. Blancarte Siqueiros, R. H. (2016). *La relación entre las áreas verdes y la calidad de vida en ambientes urbanos*. CIIDIR DGO. Recuperado de <https://www.repositoriodigital.ipn.mx/handle/123456789/23348>
19. Bongaarts, J. (2009). Human population growth and the demographic transition. *Philosophical Transactions of the Royal Society B: Biological Sciences*. <https://doi.org/10.1098/rstb.2009.0137>
20. Bottou, L. (1991). Stochastic Gradient Learning in Neural Networks. *Proceedings of Neuro-Nimes*.
21. Brakarz, J., Greene, M., & Rojas, E. (2002). *Ciudades para todos: La experiencia reciente en programas de mejoramiento de barrios*. Banco Interamericano de Desarrollo.
22. Cardona-Arias, J. A., & Higuera-Gutiérrez, L. F. (2014). Aplicaciones de un instrumento diseñado por la OMS para la evaluación de la calidad de vida. *Revista Cubana de Salud Pública*.
23. Carvacho, B. L., & Sánchez Martínez, M. (2010). Comparación De Índices De Vegetación a Partir De Imágenes Modis En La Región Del Libertador Bernardo O'Higgins, Chile, En El. *Age.leg.Csic.Es*, 728-737. Recuperado de http://age.ieg.csic.es/metodos/2010_Sevilla/ponencia3/CARVACHO.pdf
24. Casillas, A., Ledezma, M., & Aparicio, C. (2018). Conformación de áreas verdes y espacios abiertos en la transformación urbana de Monterrey del siglo XVII a inicios del siglo XXI. *Letras Históricas*. <https://doi.org/10.31836/lh.19.6728>

25. Cetin, M. (2015). Using GIS analysis to assess urban green space in terms of accessibility: Case study in Kutahya. *International Journal of Sustainable Development and World Ecology*.
<https://doi.org/10.1080/13504509.2015.1061066>
26. Chapelle, O., Sindhvani, V., & Keerthi, S. S. (2008). Optimization techniques for semi-supervised support vector machines. *Journal of Machine Learning Research*.
27. Checa-Artasu, M. M. (2016). Las áreas verdes en la Ciudad de México. *Revista bibliográfica de geografía y ciencias sociales*.
28. Chen, H., Zhu, Q., Peng, C., Wu, N., Wang, Y., Fang, X., ... Wu, J. (2013). The impacts of climate change and human activities on biogeochemical cycles on the Qinghai-Tibetan Plateau. *Global Change Biology*.
<https://doi.org/10.1111/gcb.12277>
29. Cohen, J. (1960). A Coefficient of Agreement for Nominal Scales. *Educational and Psychological Measurement*, 20(1), 37-46.
<https://doi.org/10.1177/001316446002000104>
30. Colacios, R., & Mendoza-Arroyo, C. (2017). Uso e interacción social en el espacio público: El caso del polígono de vivienda Sant Cosme, Barcelona. *Revista Urbano*. <https://doi.org/10.22320/07183607.2017.20.36.06>
31. Comber, A., Brunsdon, C., & Green, E. (2008). Using a GIS-based network analysis to determine urban greenspace accessibility for different ethnic and religious groups. *Landscape and Urban Planning*, 86(1), 103-114.
<https://doi.org/10.1016/J.LANDURBPLAN.2008.01.002>
32. Consejo de Nuevo Leon. (2019). Publicación Anual 2019, Red de Conocimiento, 2019.
33. Coombes, E., Jones, A. P., & Hillsdon, M. (2010). The relationship of physical activity and overweight to objectively measured green space accessibility and use. *Social Science & Medicine*, 70(6), 816-822.
<https://doi.org/10.1016/J.SOCSCIMED.2009.11.020>
34. Cortes, C., & Vapnik, V. (1995). Support-Vector Networks. *Machine Learning*.
<https://doi.org/10.1023/A:1022627411411>
35. Cropper, M., & Griffiths, C. (1994). The interaction of population growth and environmental quality. *American Economic Review*.
<https://doi.org/10.2307/2117838>
36. Dadvand, P., Hariri, S., Abbasi, B., Heshmat, R., Qorbani, M., Motlagh, M. E., ... Kelishadi, R. (2019). Use of green spaces, self-satisfaction and social contacts in adolescents: A population-based CASPIAN-V study. *Environmental Research*. <https://doi.org/10.1016/j.envres.2018.09.033>
37. Defries, R. S., Rudel, T., Uriarte, M., & Hansen, M. (2010). Deforestation driven by urban population growth and agricultural trade in the twenty-first century. *Nature Geoscience*. <https://doi.org/10.1038/ngeo756>
38. Demir, I., Koperski, K., Lindenbaum, D., Pang, G., Huang, J., Basu, S., ... Raskar, R. (2018). DeepGlobe 2018: A Challenge to Parse the Earth through Satellite Images. <https://doi.org/10.1109/CVPRW.2018.00031>
39. Ehrlich, P. R., & Holdren, J. P. (1971). Impact of population growth. *Science*.
<https://doi.org/10.1126/science.171.3977.1212>
40. Esquivel-Puente, S. (2012). *Impacto del escurrimiento asociado a eventos de*

- precipitación extremos en una cuenca urbana y su relación con el cambio y uso del suelo.* Universidad Autónoma de Nuevo León.
41. Feltynowski, M., Kronenberg, J., Bergier, T., Kabisch, N., Łaszkiwicz, E., & Strohbach, M. W. (2018). Challenges of urban green space management in the face of using inadequate data. *Urban Forestry and Urban Greening*.
<https://doi.org/10.1016/j.ufug.2017.12.003>
 42. Fidon, L., Li, W., Garcia-Peraza-Herrera, L. C., Ekanayake, J., Kitchen, N., Ourselin, S., & Vercauteren, T. (2018). Generalised Wasserstein dice score for imbalanced multi-class segmentation using holistic convolutional networks. En *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*.
https://doi.org/10.1007/978-3-319-75238-9_6
 43. Flores-Xolocotzi, R., & González-Guillén, M. de J. (2010). Planificación de sistemas de áreas verdes y parques públicos. *Revista Mexicana de ciencias forestales*, 1(1), 17-24. Recuperado de http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S2007-11322010000100003
 44. Freund, Yoav, and L. M. (1999). The alternating decision tree learning algorithm. *International Conference on Machine Learning*.
<https://doi.org/10.1093/jxb/ern164>
 45. Friedman, N., Geiger, D., & Goldszmidt, M. (1997). Bayesian Network Classifiers. *Machine Learning*.
<https://doi.org/10.1002/9780470400531.eorms0099>
 46. Garza-castañón, C. N. L. E., & Garza-elizondo, A. V. L. A. (2017). Shade Detection in an Industrial Photovoltaic System with Deep Neural Networks.
 47. Gascon, F., Ramoino, F., & Deanos, Y. (2017). Sentinel-2 data exploitation with ESA's Sentinel-2 Toolbox. *EGU General Assembly*, 19, 19548. Recuperado de <https://meetingorganizer.copernicus.org/EGU2017/EGU2017-19548.pdf>
 48. Ghahramani, Z. (2004). Unsupervised learning. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. <https://doi.org/10.1201/b17476-14>
 49. Giezen, M., Balikci, S., Arundel, R., Giezen, M., Balikci, S., & Arundel, R. (2018). Using Remote Sensing to Analyse Net Land-Use Change from Conflicting Sustainability Policies: The Case of Amsterdam. *ISPRS International Journal of Geo-Information*, 7(9), 381.
<https://doi.org/10.3390/ijgi7090381>
 50. Gillespie, T. W., Ostermann-Kelm, S., Dong, C., Willis, K. S., Okin, G. S., & MacDonald, G. M. (2018). Monitoring changes of NDVI in protected areas of southern California. *Ecological Indicators*.
<https://doi.org/10.1016/j.ecolind.2018.01.031>
 51. Gray, P. C., Fleishman, A. B., Klein, D. J., McKown, M. W., Bézy, V. S., Lohmann, K. J., & Johnston, D. W. (2019). A convolutional neural network for detecting sea turtles in drone imagery. *Methods in Ecology and Evolution*.
<https://doi.org/10.1111/2041-210X.13132>
 52. Guindon, B., & Zhang, Y. (2017). Application of the Dice Coefficient to Accuracy Assessment of Object-Based Image Classification. *Canadian Journal*

- of Remote Sensing. <https://doi.org/10.1080/07038992.2017.1259557>
53. Gülçin, D., & Akpınar, A. (2018). Mapping Urban Green Spaces Based on an Object-Oriented Approach. *Bilge International Journal of Science and Technology Research*, 2(January 2019), 71-81. <https://doi.org/10.30516/bilgesci.486893>
 54. Guo, S., Saito, K., Yin, W., & Su, C. (2018). Landscape connectivity as a tool in green space evaluation and optimization of the Haidan District, Beijing. *Sustainability (Switzerland)*. <https://doi.org/10.3390/su10061979>
 55. Gutiérrez, M. F., Noguez, A. B., Flamenco-Sandoval, A., Serrano, A. M., Flores-Torres, A., Ramírez, A. K. G., & Alcántara, C. (2021). Availability and accessibility of urban green spaces: the case of the urban zone of Queretaro Metropolitan Area, Mexico. <https://doi.org/10.1080/17445647.2021.1927867>, 1-5. <https://doi.org/10.1080/17445647.2021.1927867>
 56. Haas, J., & Ban, Y. (2017). Sentinel-1A SAR and sentinel-2A MSI data fusion for urban ecosystem service mapping. *Remote Sensing Applications: Society and Environment*. <https://doi.org/10.1016/j.rsase.2017.07.006>
 57. Haq, S. M. A. (2011). Urban Green Spaces and an Integrative Approach to Sustainable Environment. *Journal of Environmental Protection*, 02(05), 601-608. <https://doi.org/10.4236/jep.2011.25069>
 58. Hasmadi, M., Pakhriazad, H., & Shahrin, M. (2009). Evaluating supervised and unsupervised techniques for land cover mapping using remote sensing data. *Geografia - Malaysian Journal of Society and Space*, 5(1), 10. Recuperado de <http://ejournals.ukm.my/gmjss/article/view/17889>
 59. Haykin, S. S., & Simon. (1999). *Neural networks : a comprehensive foundation*. Prentice Hall. Recuperado de <https://dl.acm.org/citation.cfm?id=521706>
 60. He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. En *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. <https://doi.org/10.1109/CVPR.2016.90>
 61. Hegetschweiler, K. T., de Vries, S., Arnberger, A., Bell, S., Brennan, M., Siter, N., ... Hunziker, M. (2017). Linking demand and supply factors in identifying cultural ecosystem services of urban green infrastructures: A review of European studies. *Urban Forestry & Urban Greening*, 21, 48-59. <https://doi.org/10.1016/J.UFUG.2016.11.002>
 62. Hepcan, Ş. (2013). Analyzing the pattern and connectivity of urban green spaces: A case study of Izmir, Turkey. *Urban Ecosystems*, 16(2), 279-293. <https://doi.org/10.1007/s11252-012-0271-2>
 63. Himan Shahabi. (2012). Detection of urban irregular development and green space destruction using normalized difference vegetation index (NDVI), principal component analysis (PCA) and post classification methods: A case study of Saqqez city. *International Journal of the Physical Sciences*. <https://doi.org/10.5897/ijps12.009>
 64. Hoffer, E., Hubara, I., & Soudry, D. (2017). Train longer, generalize better: Closing the generalization gap in large batch training of neural networks. En *Advances in Neural Information Processing Systems* (Vol. 2017-December, pp. 1732-1742). Neural information processing systems foundation.
 65. Hofmann, P., Strobl, J., & Nazarkulova, A. (2011). Mapping green spaces in

- Bishkek-how reliable can spatial analysis be? *Remote Sensing*.
<https://doi.org/10.3390/rs3061088>
66. Horning, N. (2018). Remote sensing. En *Encyclopedia of Ecology*.
<https://doi.org/10.1016/B978-0-12-409548-9.10607-4>
 67. Howard, J., & Gugger, S. (2020). Fastai: A layered api for deep learning.
Information (Switzerland). <https://doi.org/10.3390/info11020108>
 68. Huang, M., Cui, P., & He, X. (2018). Study of the cooling effects of urban green space in Harbin in terms of reducing the heat island effect. *Sustainability (Switzerland)*, 10(4), 1-17. <https://doi.org/10.3390/su10041101>
 69. Huang, Q., Sun, J., Ding, H., Wang, X., & Wang, G. (2018). Robust liver vessel extraction using 3D U-Net with variant dice loss function. *Computers in Biology and Medicine*. <https://doi.org/10.1016/j.compbiomed.2018.08.018>
 70. Huerta-García, R. E., Ramírez-Serrat, N. L., Yépez-Rincón, F. D., & Lozano-García, D. F. (2018). Precision of remote sensors to estimate aerial biomass parameters: portable LIDAR and optical sensors. *Revista Chapingo Serie Ciencias Forestales y del Ambiente*, 24(2), 219-235.
<https://doi.org/10.5154/r.rchscfa.2017.09.059>
 71. Huerta, R. E., Yépez, F. D., Lozano-García, D. F., Guerra Cobián, V. H., Ferriño Fierro, A. L., de León Gómez, H., ... Vargas-Martínez, A. (2021). Mapping Urban Green Spaces at the Metropolitan Level Using Very High Resolution Satellite Imagery and Deep Learning Techniques for Semantic Segmentation. *Remote Sensing*, 13(11), 2031.
<https://doi.org/10.3390/rs13112031>
 72. Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X., & Ferreira, L. G. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83(1-2), 195-213.
[https://doi.org/10.1016/S0034-4257\(02\)00096-2](https://doi.org/10.1016/S0034-4257(02)00096-2)
 73. Huete, A. R., Liu, H. Q., Batchily, K., & Van Leeuwen, W. (1997). A comparison of vegetation indices over a global set of TM images for EOS-MODIS. *Remote Sensing of Environment*. [https://doi.org/10.1016/S0034-4257\(96\)00112-5](https://doi.org/10.1016/S0034-4257(96)00112-5)
 74. Ian, G., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press. MIT Press. Recuperado de <http://www.deeplearningbook.org>
 75. Jahangir, S. (2019). Perceived meaning of urban local parks and social well-being of elderly men: A qualitative study of Delhi and Kolkata. *Transactions of the Institute of Indian Geographers*.
 76. Jennings, V., Larson, L., & Yun, J. (2016). Advancing sustainability through urban green space: Cultural ecosystem services, equity, and social determinants of health. *International Journal of Environmental Research and Public Health*. <https://doi.org/10.3390/ijerph13020196>
 77. Jiang, Z., Huete, A. R., Didan, K., & Miura, T. (2008). Development of a two-band enhanced vegetation index without a blue band. *Remote Sensing of Environment*. <https://doi.org/10.1016/j.rse.2008.06.006>
 78. Kabisch, N. (2015). Ecosystem service implementation and governance challenges in urban green space planning—The case of Berlin, Germany. *Land Use Policy*, 42, 557-567. <https://doi.org/10.1016/J.LANDUSEPOL.2014.09.005>
 79. Kafafy, N., & Fathy, H. (2019). Assessing green spaces impact on people's happiness in Cairo, 8(1), 30-47.

80. Kampffmeyer, M., Salberg, A. B., & Jenssen, R. (2016). Semantic Segmentation of Small Objects and Modeling of Uncertainty in Urban Remote Sensing Images Using Deep Convolutional Neural Networks. En *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*. <https://doi.org/10.1109/CVPRW.2016.90>
81. Keeley, M., & Benton-Short, L. (2018). *Urban sustainability in the US: Cities take action. Urban Sustainability in the US: Cities Take Action*. <https://doi.org/10.1007/978-3-319-93296-5>
82. Khaliq, A., Comba, L., Biglia, A., Ricauda Aimonino, D., Chiaberge, M., & Gay, P. (2019). Comparison of satellite and UAV-based multispectral imagery for vineyard variability assessment. *Remote Sensing*, 11(4), 436. <https://doi.org/10.3390/rs11040436>
83. Khryashchev, V., Larionov, R., Ostrovskaya, A., & Semenov, A. (2019). Modification of U-Net neural network in the task of multichannel satellite images segmentation. En *2019 IEEE East-West Design and Test Symposium, EWDTs 2019*. <https://doi.org/10.1109/EWDTs.2019.8884452>
84. Kim, H., Lee, D. K., & Sung, S. (2016). Effect of urban green spaces and flooded area type on flooding probability. *Sustainability (Switzerland)*. <https://doi.org/10.3390/su8020134>
85. Klok, L., Rood, N., Kluck, J., & Kleerekoper, L. (2019). Assessment of thermally comfortable urban spaces in Amsterdam during hot summer days. *International Journal of Biometeorology*. <https://doi.org/10.1007/s00484-018-1644-x>
86. Klopp, J. M., & Petretta, D. L. (2017). The urban sustainable development goal: Indicators, complexity and the politics of measuring cities. *Cities*. <https://doi.org/10.1016/j.cities.2016.12.019>
87. Kong, F., & Nakagoshi, N. (2006). Spatial-temporal gradient analysis of urban green spaces in Jinan, China. *Landscape and Urban Planning*, 78(3), 147-164. <https://doi.org/10.1016/J.LANDURBPLAN.2005.07.006>
88. Kong, F., Sun, C., Liu, F., Yin, H., Jiang, F., Pu, Y., ... Dronova, I. (2016). Energy saving potential of fragmented green spaces due to their temperature regulating ecosystem services in the summer. *Applied Energy*. <https://doi.org/10.1016/j.apenergy.2016.09.070>
89. Konijnendijk, C. C., Nilsson, K., Randrup, T. B., & Schipperijn, J. (2005). *Urban forests and trees: A reference book. Urban Forests and Trees: A Reference Book*. <https://doi.org/10.1007/3-540-27684-X>
90. Kopecká, M., Szatmári, D., & Rosina, K. (2017). Analysis of Urban Green Spaces Based on Sentinel-2A: Case Studies from Slovakia. *Land*, 6(2), 25. <https://doi.org/10.3390/land6020025>
91. Kothencz, G., Kiss, M., & Petutschnig, A. (2017). Hot spots for improvements: Where to implement new green spaces? En *2017 IEEE SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computed, Scalable Computing & Communications, Cloud & Big Data Computing, Internet of People and Smart City Innovation (SmartWorld/SCALCOM/UIC/ATC/CBDCOM/IOP/SCI)* (pp. 1-4). IEEE. <https://doi.org/10.1109/UIC-ATC.2017.8397576>
92. Kotsiantis, S. B., Zaharakis, I., & Pintelas, P. (2007). Supervised machine

- learning: A review of classification techniques. *Emerging artificial intelligence applications in computer engineering*, 160, 3-24.
93. Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Advances In Neural Information Processing Systems*.
<https://doi.org/http://dx.doi.org/10.1016/j.protcy.2014.09.007>
 94. Kuchelmeister, G. (1998). Urban forestry in the Asia-Pacific Region: status and prospects. *Asia-Pacific Forestry Sector Outlook Study Working Paper Series (FAO)*.
 95. Kundu, K., Halder, P., & Mandal, J. K. (2021). Change Detection and Patch Analysis of Sundarban Forest During 1975–2018 Using Remote Sensing and GIS Data. *SN Computer Science 2021 2:5*, 2(5), 1-14.
<https://doi.org/10.1007/S42979-021-00749-8>
 96. Laforteza, R., Carrus, G., Sanesi, G., & Davies, C. (2009). Benefits and well-being perceived by people visiting green spaces in periods of heat stress. *Urban Forestry and Urban Greening*, 8(2), 97-108.
<https://doi.org/10.1016/j.ufug.2009.02.003>
 97. Lahoti, S., Kefi, M., Lahoti, A., & Saito, O. (2019). Mapping Methodology of Public Urban Green Spaces Using GIS: An Example of Nagpur City, India. *Sustainability*, 11(7), 2166. <https://doi.org/10.3390/su11072166>
 98. LeCun, Y., Haffner, P., Bottou, L., & Bengio, Y. (1999). Object recognition with gradient-based learning. En *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. https://doi.org/10.1007/3-540-46805-6_19
 99. Lee, R. (2011). The outlook for population growth. *Science*.
<https://doi.org/10.1126/science.1208859>
 100. Lepczyk, C. A., Aronson, M. F. J., Evans, K. L., Goddard, M. A., Lerman, S. B., & Macivor, J. S. (2017). Biodiversity in the City: Fundamental Questions for Understanding the Ecology of Urban Green Spaces for Biodiversity Conservation. *BioScience*. <https://doi.org/10.1093/biosci/bix079>
 101. Lguensat, R., Sun, M., Fablet, R., Mason, E., Tandeo, P., & Chen, G. (2018). EddyNet: A deep neural network for pixel-wise classification of oceanic eddies. En *International Geoscience and Remote Sensing Symposium (IGARSS)*. <https://doi.org/10.1109/IGARSS.2018.8518411>
 102. Li, H., Chen, W., & He, W. (2015). Planning of green space ecological network in urban areas: An example of Nanchang, China. *International Journal of Environmental Research and Public Health*.
<https://doi.org/10.3390/ijerph121012889>
 103. Li, Jing, Cheng, J. H., Shi, J. Y., & Huang, F. (2012). Brief introduction of back propagation (BP) neural network algorithm and its improvement. En *Advances in Intelligent and Soft Computing*. https://doi.org/10.1007/978-3-642-30223-7_87
 104. Li, Jundong, & Liu, H. (2017). Challenges of Feature Selection for Big Data Analytics. *IEEE Intelligent Systems*. <https://doi.org/10.1109/MIS.2017.38>
 105. Liebelt, V., Bartke, S., & Schwarz, N. (2018). Hedonic pricing analysis of the influence of urban green spaces onto residential prices: the case of Leipzig, Germany. *European Planning Studies*.

- <https://doi.org/10.1080/09654313.2017.1376314>
106. Liu, H., Feng, J., Feng, Z., Lu, J., & Zhou, J. (2017). Left atrium segmentation in CT volumes with fully convolutional networks. En *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. https://doi.org/10.1007/978-3-319-67558-9_5
 107. Liu, Y., Yang, Y., Jing, W., Yao, L., Yue, X., & Zhao, X. (2017). A new urban index for expressing inner-city patterns based on MODIS LST and EVI regulated DMSP/OLS NTL. *Remote Sensing*. <https://doi.org/10.3390/rs9080777>
 108. Lopes, A. T., de Aguiar, E., De Souza, A. F., & Oliveira-Santos, T. (2017). Facial expression recognition with Convolutional Neural Networks: Coping with few data and the training sample order. *Pattern Recognition*. <https://doi.org/10.1016/j.patcog.2016.07.026>
 109. López-Jiménez, E., Vasquez-Gomez, J. I., Sanchez-Acevedo, M. A., Herrera-Lozada, J. C., & Uriarte-Arcia, A. V. (2019). Columnar cactus recognition in aerial images using a deep learning approach. *Ecological Informatics*. <https://doi.org/10.1016/j.ecoinf.2019.05.005>
 110. Lopez, G. A. P., & Souza, L. C. L. de. (2018). Urban green spaces and the influence on vehicular traffic noise control. *Ambiente Construído*. <https://doi.org/10.1590/s1678-86212018000400299>
 111. Lozoya, C., Eyzaguirre, E., Espinoza, J., Montes-Fonseca, S. L., & Rosas-Perez, G. (2019). Spectral Vegetation Index Sensor Evaluation for Greenhouse Precision Agriculture. *Proceedings of IEEE Sensors, 2019-October*. <https://doi.org/10.1109/SENSORS43011.2019.8956911>
 112. Malik G., A.-A., Dawn M., V., Michael N., D., & Rolston St., H. (2013). *A Method to Quantitatively Classify Residential Urban Landscapes in a Desert Environment*. *HortTechnology* (Vol. 23). American Society for Horticultural Science. Recuperado de <http://horttech.ashspublications.org/content/23/4/474.full>
 113. Manzanares Mena, L., & Macías Garcia, C. (2018). Songbird community structure changes with noise in an urban reserve. *Journal of Urban Ecology*. <https://doi.org/10.1093/jue/juy022>
 114. Marando, F., Salvatori, E., Sebastiani, A., Fusaro, L., & Manes, F. (2019). Regulating Ecosystem Services and Green Infrastructure: assessment of Urban Heat Island effect mitigation in the municipality of Rome, Italy. *Ecological Modelling*. <https://doi.org/10.1016/j.ecolmodel.2018.11.011>
 115. Marmanis, D., Wegner, J. D., Galliani, S., Schindler, K., Datcu, M., & Stilla, U. (2016). Semantic Segmentation of Aerial Images With an Ensemble of Cnns. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences, III-3*, 473-480. <https://doi.org/10.5194/isprsannals-iii-3-473-2016>
 116. Maulik, U., & Bandyopadhyay, S. (2000). Genetic algorithm-based clustering technique. *Pattern Recognition*. [https://doi.org/10.1016/S0031-3203\(99\)00137-5](https://doi.org/10.1016/S0031-3203(99)00137-5)
 117. McKee, J. K., Sciulli, P. W., David Fooce, C., & Waite, T. A. (2004). Forecasting global biodiversity threats associated with human population

- growth. *Biological Conservation*. [https://doi.org/10.1016/S0006-3207\(03\)00099-5](https://doi.org/10.1016/S0006-3207(03)00099-5)
118. Meerow, S., & Newell, J. P. (2017). Spatial planning for multifunctional green infrastructure: Growing resilience in Detroit. *Landscape and Urban Planning*, 159, 62-75. <https://doi.org/10.1016/J.LANDURBPLAN.2016.10.005>
 119. Meyer, W. B., & Turner, B. L. (1992). Human population growth and global land-use/cover change. *Annual Review of Ecology and Systematics*. <https://doi.org/10.1146/annurev.es.23.110192.000351>
 120. Michalzik, D. (1988). *Trias bis tiefste Unter-Kreide der nordöstlichen Sierra Madre Oriental, Mexico*.
 121. Milioto, A., Lottes, P., & Stachniss, C. (2018). Real-Time Semantic Segmentation of Crop and Weed for Precision Agriculture Robots Leveraging Background Knowledge in CNNs. En *Proceedings - IEEE International Conference on Robotics and Automation*. <https://doi.org/10.1109/ICRA.2018.8460962>
 122. Milletari, F., Navab, N., & Ahmadi, S. A. (2016). V-Net: Fully convolutional neural networks for volumetric medical image segmentation. En *Proceedings - 2016 4th International Conference on 3D Vision, 3DV 2016*. <https://doi.org/10.1109/3DV.2016.79>
 123. Molina, E. N., & Zhang, Z. (2019). Semantic segmentation of satellite images using a U-shaped fully connected network with dense residual blocks. En *Proceedings - 2019 IEEE International Conference on Multimedia and Expo Workshops, ICMEW 2019*. <https://doi.org/10.1109/ICMEW.2019.00037>
 124. Mougiakou, E., & Photis, Y. N. (2014). Urban green space network evaluation and planning: Optimizing accessibility based on connectivity and raster gis analysis. *European Journal of Geography*, 5(4), 19-46.
 125. Muñoz, R. M. (2014). Accesibilidad a las áreas verdes urbanas como espacios públicos. El caso de Ciudad Juárez, Chihuahua ., 124.
 126. Nepita-Villanueva, M. R., Berlanga-Robles, C. A., Ruiz-Luna, A., & Morales Barcenas, J. H. (2019). Spatio-temporal mangrove canopy variation (2001–2016) assessed using the MODIS enhanced vegetation index (EVI). *Journal of Coastal Conservation*. <https://doi.org/10.1007/s11852-019-00689-9>
 127. Newell, J. P., Seymour, M., Yee, T., Renteria, J., Longcore, T., Wolch, J. R., & Shishkovsky, A. (2013). Green Alley Programs: Planning for a sustainable urban infrastructure? *Cities*. <https://doi.org/10.1016/j.cities.2012.07.004>
 128. Nguyen, H., Prasad, N., Walker, C., & Walker, E. (2010). Neural Networks for Control. En *A First Course in Fuzzy and Neural Control*. <https://doi.org/10.1201/9781420035520.ch5>
 129. Nitze, I., Schulthess, U., & Asche, H. (2012). Comparison of machine learning algorithms random forest, artificial neuronal network and support vector machine to maximum likelihood for supervised crop type classification. En *Proceedings of the 4th Conference on GEographic Object-Based Image Analysis – GEOBIA 2012*.
 130. Noh, H., Hong, S., & Han, B. (2015). Learning deconvolution network for semantic segmentation. En *Proceedings of the IEEE International Conference on Computer Vision*. <https://doi.org/10.1109/ICCV.2015.178>
 131. Östberg, J., Wiström, B., & Randrup, T. B. (2018). The state and use of

- municipal tree inventories in Swedish municipalities – results from a national survey. *Urban Ecosystems*. <https://doi.org/10.1007/s11252-018-0732-3>
132. Oviantari, M. V., Gunamantha, I. M., Ristiati, N. P., Santiasa, I. M. P. A., & Astariani, P. P. Y. (2018). Carbon sequestration by above-ground biomass in urban green spaces in Singaraja city. En *IOP Conference Series: Earth and Environmental Science*. <https://doi.org/10.1088/1755-1315/200/1/012030>
 133. Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., Chanan, G., ... Chintala, S. (2019). PyTorch: An Imperative Style, High-Performance Deep Learning Library, (NeurIPS). Recuperado de <http://arxiv.org/abs/1912.01703>
 134. Perillo, A., Mazzoni, L. G., Passos, L. F., Goulart, V. D. L. R., Duca, C., & Young, R. J. (2017). Anthropogenic noise reduces bird species richness and diversity in urban parks. *Ibis*. <https://doi.org/10.1111/ibi.12481>
 135. Pieniążek, A., Boguszewski, P. M., & Meronka, R. A. (2017). The Impact of Urban Noise on the Behavior of Two Mouse Species Belonging to the Genus <i>Apodemus</i>. *Natural Resources*. <https://doi.org/10.4236/nr.2017.82004>
 136. Piragnolo, M., Lusiani, G., & Pirotti, F. (2018). Comparison of vegetation indices from RPAS and Sentinel-2 imagery for detecting permanent pastures. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 42(3), 1381-1387. <https://doi.org/10.5194/isprs-archives-XLII-3-1381-2018>
 137. Rafiee, R., Salman Mahiny, A., & Khorasani, N. (2009). Assessment of changes in urban green spaces of Mashad city using satellite data. *International Journal of Applied Earth Observation and Geoinformation*. <https://doi.org/10.1016/j.jag.2009.08.005>
 138. Recio, A., Linares, C., Banegas, J. R., & Díaz, J. (2017). Impact of road traffic noise on cause-specific mortality in Madrid (Spain). *Science of the Total Environment*. <https://doi.org/10.1016/j.scitotenv.2017.02.193>
 139. Rempel, R. S., Kaukinen, D., & Carr, A. P. (2012). Patch Analyst and Patch Grid.
 140. Reyes Pácke, S., & Figueroa Aldunce, I. M. (2010). Distribución, superficie y accesibilidad de las áreas verdes en Santiago de Chile. *EURE (Santiago)*, 36(109), 89-110. <https://doi.org/10.4067/S0250-71612010000300004>
 141. Ríos Lizcano, A. K. (2019). *Ecosistemas urbanos: un servicio ambiental para el municipio de Monterrey*. Universidad Autónoma de Nuevo León.
 142. Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *Miccai*, 234-241. https://doi.org/10.1007/978-3-319-24574-4_28
 143. Ruiz-del-Solar, J., Loncomilla, P., & Soto, N. (2018). A Survey on Deep Learning Methods for Robot Vision. Recuperado de <http://arxiv.org/abs/1803.10862>
 144. Ruiz-Luna, A., Bautista Bautista, R., Hernández-Guzmán, R., & Camacho-Valdez, V. (2019). Uneven distribution of urban green spaces in a coastal city in northwest Mexico. *Local Environment*. <https://doi.org/10.1080/13549839.2019.1590324>
 145. Rutchey, K., & Vilchek, L. (1999). Air photointerpretation and satellite imagery analysis techniques for mapping cattail coverage in a northern

- Everglades impoundment. *Photogrammetric Engineering and Remote Sensing*.
146. Rwanga, S. S., & Ndambuki, J. M. (2017). Accuracy Assessment of Land Use/Land Cover Classification Using Remote Sensing and GIS. *International Journal of Geosciences*, 8, 611-622. <https://doi.org/10.4236/ijg.2017.84033>
 147. Saavedra-Alcoba, M. (2015). *Búsqueda De Objetos Mediante Conocimiento Semántico En Ambientes Interiores*. Universidad de Chile, Facultad de Ciencias Físicas y Matemáticas.
 148. Santos, T., Tenedório, J. A., & Gonçalves, J. A. (2016). Quantifying the city's green area potential gain using remote sensing data. *Sustainability (Switzerland)*, 8(12). <https://doi.org/10.3390/su8121247>
 149. Saraiva, M., Protas, É., Salgado, M., & Souza, C. (2020). Automatic mapping of center pivot irrigation systems from satellite images using deep learning. *Remote Sensing*. <https://doi.org/10.3390/rs12030558>
 150. Schmid, J. N., Erasmi, S., & Wyss, D. (2017). *Using Google Earth Engine for Landsat NDVI time series analysis to indicate the present status of forest stands*. *Institute of Geography*.
 151. Schmidhuber, J. (2014). Deep Learning in Neural Networks: An Overview. <https://doi.org/10.1016/j.neunet.2014.09.003>
 152. SEDESOL, CONAPO, & INEGI. (2012). *Delimitación de las zonas metropolitanas de México*.
 153. Selmi, W., Weber, C., Rivière, E., Blond, N., Mehdi, L., & Nowak, D. (2016). Air pollution removal by trees in public green spaces in Strasbourg city, France. *Urban Forestry and Urban Greening*. <https://doi.org/10.1016/j.ufug.2016.04.010>
 154. Shelhamer, E., Long, J., & Darrell, T. (2017). Fully Convolutional Networks for Semantic Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(4), 640-651. <https://doi.org/10.1109/TPAMI.2016.2572683>
 155. Shvets, A. A., Rakhlin, A., Kalinin, A. A., & Iglovikov, V. I. (2019). Automatic Instrument Segmentation in Robot-Assisted Surgery using Deep Learning. En *Proceedings - 17th IEEE International Conference on Machine Learning and Applications, ICMLA 2018*. <https://doi.org/10.1109/ICMLA.2018.00100>
 156. Siegmund, A., & Menz, G. (2005). Fernes nah gebracht - Satelliten- und Luftbildeinsatz zur Analyse von Umweltveränderungen im Geographieunterricht. *Geographie und Schule*, 27(154), 10.
 157. Smith, L. N. (2017). Cyclical learning rates for training neural networks. En *Proceedings - 2017 IEEE Winter Conference on Applications of Computer Vision, WACV 2017*. <https://doi.org/10.1109/WACV.2017.58>
 158. Sobrino, J. A., Jiménez-Muñoz, J. C., & Paolini, L. (2004). Land surface temperature retrieval from LANDSAT TM 5. *Remote Sensing of Environment*, 90(4), 434-440. <https://doi.org/10.1016/J.RSE.2004.02.003>
 159. Song, X. P., Tan, P. Y., Edwards, P., & Richards, D. (2018). The economic benefits and costs of trees in urban forest stewardship: A systematic review. *Urban Forestry & Urban Greening*, 29, 162-170. <https://doi.org/10.1016/J.UFUG.2017.11.017>
 160. Stewart, E. L., Wiesner-Hanks, T., Kaczmar, N., DeChant, C., Wu, H., Lipson, H., ... Gore, M. A. (2019). Quantitative Phenotyping of Northern Leaf

- Blight in UAV Images Using Deep Learning. *Remote Sensing*.
<https://doi.org/10.3390/rs11192209>
161. Sun, X., Tan, X., Chen, K., Song, S., Zhu, X., & Hou, D. (2020). Quantifying landscape-metrics impacts on urban green-spaces and water-bodies cooling effect: The study of Nanjing, China. *Urban Forestry and Urban Greening*, 55, 126838. <https://doi.org/10.1016/j.ufug.2020.126838>
 162. Sun, Y., Xie, S., & Zhao, S. (2019). Valuing urban green spaces in mitigating climate change: A city-wide estimate of aboveground carbon stored in urban green spaces of China's Capital. *Global Change Biology*.
<https://doi.org/10.1111/gcb.14566>
 163. Swanwick, C., Dunnett, N., & Woolley, H. (2003). Nature, role and value of green space in towns and cities: An overview. *Built Environment*.
<https://doi.org/10.2148/benv.29.2.94.54467>
 164. Szepesvári, C. (2010). Algorithms for reinforcement learning. En *Synthesis Lectures on Artificial Intelligence and Machine Learning*.
<https://doi.org/10.2200/S00268ED1V01Y201005AIM009>
 165. Takano, T., Nakamura, K., & Watanabe, M. (2002). Urban residential environments and senior citizens' longevity in megacity areas: The importance of walkable green spaces. *Journal of Epidemiology and Community Health*, 56(12), 913-918. <https://doi.org/10.1136/jech.56.12.913>
 166. Tan, L. H. H., & Neo, H. (2009). "Community in Bloom": local participation of community gardens in urban Singapore. *Local Environment*.
<https://doi.org/10.1080/13549830902904060>
 167. Texier, M. Le, Schiel, K., & Caruso, G. (2018). The provision of urban green space and its accessibility: Spatial data effects in Brussels. *PLoS ONE*.
<https://doi.org/10.1371/journal.pone.0204684>
 168. Threlfall, C. G., Mata, L., Mackie, J. A., Hahs, A. K., Stork, N. E., Williams, N. S. G., & Livesley, S. J. (2017). Increasing biodiversity in urban green spaces through simple vegetation interventions. *Journal of Applied Ecology*.
<https://doi.org/10.1111/1365-2664.12876>
 169. Tian, Y., Jim, C. Y., & Liu, Y. (2017). Using a spatial interaction model to assess the accessibility of district parks in Hong Kong. *Sustainability (Switzerland)*. <https://doi.org/10.3390/su9111924>
 170. Tian, Y., Jim, C. Y., & Wang, H. (2014). Assessing the landscape and ecological quality of urban green spaces in a compact city. *Landscape and Urban Planning*, 121, 97-108.
<https://doi.org/10.1016/j.landurbplan.2013.10.001>
 171. Timilsina, S., Aryal, J., & Kirkpatrick, J. B. (2020). Mapping urban tree cover changes using object-based convolution neural network (OB-CNN). *Remote Sensing*. <https://doi.org/10.3390/RS12183017>
 172. Torres García, A. J., & Ochoa Adame, G. L. (2017). Especialización productiva regional y crecimiento poblacional en México : un análisis para las diez zonas metropolitanas demográficamente más dinámicas , en el periodo 2000-2010. *Contraste Regional*, 4(7-8), 97-118.
 173. Trembl, M., Arjona-medina, J., Unterthiner, T., Durgesh, R., Friedmann, F., Schuberth, P., ... Hochreiter, S. (2016). Speeding up Semantic Segmentation for Autonomous Driving. *NIPS 2016 workshop MLITS*.

174. Tyrväinen, L., Mäkinen, K., & Schipperijn, J. (2007a). Tools for mapping social values of urban woodlands and other green areas. *Landscape and Urban Planning*, 79(1), 5-19. <https://doi.org/10.1016/j.landurbplan.2006.03.003>
175. Tyrväinen, L., Mäkinen, K., & Schipperijn, J. (2007b). Tools for mapping social values of urban woodlands and other green areas. *Landscape and Urban Planning*. <https://doi.org/10.1016/j.landurbplan.2006.03.003>
176. Ulmer, J. M., Wolf, K. L., Backman, D. R., Tretheway, R. L., Blain, C. J., O'Neil-Dunne, J. P., & Frank, L. D. (2016). Multiple health benefits of urban tree canopy: The mounting evidence for a green prescription. *Health and Place*, 42, 54-62. <https://doi.org/10.1016/j.healthplace.2016.08.011>
177. Uy, P. D., & Nakagoshi, N. (2008). Application of land suitability analysis and landscape ecology to urban greenspace planning in Hanoi, Vietnam. *Urban Forestry and Urban Greening*. <https://doi.org/10.1016/j.ufug.2007.09.002>
178. Viana, C. M., Oliveira, S., Oliveira, S. C., & Rocha, J. (2019). Land Use/Land Cover Change Detection and Urban Sprawl Analysis. En *Spatial Modeling in GIS and R for Earth and Environmental Sciences*. <https://doi.org/10.1016/B978-0-12-815226-3.00029-6>
179. Vladimír, K. (2017). *Deep neural network for satellite image classification using OpenStreetMap*. Czech Technical University in Prague.
180. Wang, H., Dai, X., Wu, J., Wu, X., & Nie, X. (2019). Influence of urban green open space on residents' physical activity in China. *BMC Public Health*. <https://doi.org/10.1186/s12889-019-7416-7>
181. Western, D. (2001). Human-modified ecosystems and future evolution. *Proceedings of the National Academy of Sciences of the United States of America*. <https://doi.org/10.1073/pnas.101093598>
182. White, A. E., Dikow, R. B., Baugh, M., Jenkins, A., & Frandsen, P. B. (2020). Generating segmentation masks of herbarium specimens and a data set for training segmentation models using deep learning. *Applications in Plant Sciences*. <https://doi.org/10.1002/aps3.11352>
183. Wolch, J. R., Byrne, J., & Newell, J. P. (2014). Urban green space, public health, and environmental justice: The challenge of making cities «just green enough». *Landscape and Urban Planning*, 125, 234-244. <https://doi.org/10.1016/j.landurbplan.2014.01.017>
184. Wood, L., Hooper, P., Foster, S., & Bull, F. (2017). Public green spaces and positive mental health – investigating the relationship between access, quantity and types of parks and mental wellbeing. *Health and Place*. <https://doi.org/10.1016/j.healthplace.2017.09.002>
185. Xu, Y., Wu, L., Xie, Z., & Chen, Z. (2018). Building extraction in very high resolution remote sensing imagery using deep learning and guided filters. *Remote Sensing*. <https://doi.org/10.3390/rs10010144>
186. Xue, J., & Su, B. (2017). Significant remote sensing vegetation indices: A review of developments and applications. *Journal of Sensors*. <https://doi.org/10.1155/2017/1353691>
187. Yang, Y., & Newsam, S. (2010). Bag-of-visual-words and spatial extensions for land-use classification. En *GIS: Proceedings of the ACM International Symposium on Advances in Geographic Information Systems*.

- <https://doi.org/10.1145/1869790.1869829>
188. Yepez-Rincon, F. D., Ferriño-Fierro, A. L., Guerra-Cobián, V. H., & Limón-Rodríguez, B. (2018). Uso de sensores remotos y VANTs para la gestión de áreas verdes urbanas. *Memorias de Congresso Brasileiro de Cadastro Técnico Multifinalitário e Gestão Territorial*, 11. Recuperado de <http://www.ocs.cobrac.ufsc.br/index.php/cobrac/cobrac2018/paper/viewPaper/595>
 189. Yépez, F. D., Ferriño Fierro, A. L., Escobedo Tamez, A. N., Ramírez Serrato, N. L., Aguilar Treviño, C., Huerta, R. E., & De León Gómez, H. (2018). *Creación de una base de datos cartográfica de áreas verdes urbanas de General Escobedo, Nuevo León | Request PDF*. Recuperado de https://www.researchgate.net/publication/351247789_Creacion_de_una_base_de_datos_cartografica_de_areas_verdes_urbanas_de_General_Escobedo_Nuevo_Leon
 190. Zhang, Q., Yao, T., Huemmrich, K. F., Middleton, E. M., Lyapustin, A., & Wang, Y. (2020). Evaluating impacts of snow, surface water, soil and vegetation on empirical vegetation and snow indices for the Utqiagvik tundra ecosystem in Alaska with the LVS3 model. *Remote Sensing of Environment*. <https://doi.org/10.1016/j.rse.2020.111677>
 191. Zhang, X., Xiao, Z., Li, D., Fan, M., & Zhao, L. (2019). Semantic Segmentation of Remote Sensing Images Using Multiscale Decoding Network. *IEEE Geoscience and Remote Sensing Letters*. <https://doi.org/10.1109/lgrs.2019.2901592>
 192. Zhang, Y., & Yang, Q. (2018). An overview of multi-task learning. *National Science Review*. <https://doi.org/10.1093/nsr/nwx105>
 193. Zhou, B., Liu, L., Oliva, A., & Torralba, A. (2014). Recognizing City Identity via Attribute Analysis of Geo-tagged Images (pp. 519-534). Springer, Cham. https://doi.org/10.1007/978-3-319-10578-9_34
 194. Zhou, D., Zhao, S., Liu, S., & Zhang, L. (2014). Spatiotemporal trends of terrestrial vegetation activity along the urban development intensity gradient in China's 32 major cities. *Science of the Total Environment*, 488-489(1), 136-145. <https://doi.org/10.1016/j.scitotenv.2014.04.080>
 195. Zhu, X. (2014). Computational intelligence techniques and applications. En *Computational Intelligence Techniques in Earth and Environmental Sciences*. https://doi.org/10.1007/978-94-017-8642-3_1
 196. Zhu, Z., Fu, Y., Woodcock, C. E., Olofsson, P., Vogelmann, J. E., Holden, C., ... Yu, Y. (2016). Including land cover change in analysis of greenness trends using all available Landsat 5, 7, and 8 images: A case study from Guangzhou, China (2000–2014). *Remote Sensing of Environment*, 185(November 2018), 243-257. <https://doi.org/10.1016/j.rse.2016.03.036>
 197. Zlotnik, H. (2017). World urbanization: Trends and prospects. En *New Forms of Urbanization: Beyond the Urban-Rural Dichotomy* (pp. 43-64). Taylor and Francis. <https://doi.org/10.4324/9781315248073-3>
 198. Zylshal, Sulma, S., Yulianto, F., Nugroho, J. T., & Sofan, P. (2016). A support vector machine object based image analysis approach on urban green space extraction using Pleiades-1A imagery. *Modeling Earth Systems and Environment*, 2(2), 54. <https://doi.org/10.1007/s40808-016-0108-8>

ANEXOS

Anexo I. Estadísticas de índices de vegetación. Análisis por municipios obtenidos a partir de imagen satelital Sentinel-2 de julio de 2016.

Anexo I.I. Métricas obtenidas para el índice de vegetación NDVI (julio 2016).

Índice NDVI a nivel municipal						
Municipio	Media valores	Valor mínimo	Valor máximo	Desv. est.	Cantidad píxeles	Suma valores
Apodaca	0.194	-0.227	0.703	0.133	54168.000	10511.288
Cadereyta	0.184	-0.231	0.740	0.125	10586.000	1949.031
García	0.100	-0.093	0.641	0.085	25451.000	2536.973
San Pedro	0.353	-0.069	0.744	0.198	18930.000	6688.023
Escobedo	0.134	-0.178	0.670	0.107	29956.000	4017.658
Guadalupe	0.209	-0.231	0.756	0.165	52302.000	10909.212
Juárez	0.175	-0.072	0.692	0.110	25512.000	4472.684
Monterrey	0.190	-0.356	0.829	0.158	92013.000	17484.072
Salinas Victoria	0.091	-0.034	0.560	0.067	3570.000	325.147
San Nicolás	0.200	-0.121	0.690	0.143	37920.000	7577.229
Santa Catarina	0.136	-0.163	0.673	0.110	21871.000	2983.194
Santiago	0.262	-0.002	0.733	0.140	3737.000	979.502

Anexo I.II. Métricas obtenidas para el índice de vegetación EVI2 (julio 2016).

Índice EVI2 a nivel municipal						
Municipio	Media valores	Valor mínimo	Valor máximo	Desv. est.	Cantidad píxeles	Suma valores
Apodaca	0.325	-0.305	1.456	0.245	54168	17584.912
Cadereyta	0.306	-0.311	1.565	0.241	10585	3242.144
García	0.158	-0.132	1.280	0.145	25446	4022.780
San Pedro	0.646	-0.099	1.576	0.402	18930	12229.361
Escobedo	0.218	-0.243	1.361	0.191	29956	6520.277
Guadalupe	0.359	-0.310	1.615	0.320	52302	18780.778
Juárez	0.288	-0.103	1.424	0.199	25512	7334.960
Monterrey	0.324	-0.456	1.849	0.294	92013	29790.588
Salinas Victoria	0.142	-0.050	1.071	0.113	3570	508.175
San Nicolás	0.337	-0.170	1.418	0.266	37920	12785.343
Santa Catarina	0.222	-0.224	1.368	0.197	21871	4853.599
Santiago	0.450	-0.003	1.543	0.278	3737	1681.144

Anexo I.III. Métricas obtenidas para el índice de vegetación NDWI (julio 2016).

Índice NDWI a nivel municipal						
Municipio	Media valores	Valor mínimo	Valor máximo	Desv. est.	Cantidad píxeles	Suma valores
Apodaca	-0.226	-0.597	0.521	0.114	54168	-12232.245
Cadereyta	-0.236	-0.592	0.503	0.104	10585	-2502.561
García	-0.157	-0.549	0.053	0.081	25446	-3994.876
San Pedro	-0.317	-0.623	0.189	0.146	18930	-5997.338
Escobedo	-0.180	-0.553	0.088	0.098	29956	-5402.742
Guadalupe	-0.230	-0.618	0.340	0.130	52302	-12009.465
Juárez	-0.228	-0.583	0.058	0.095	25512	-5805.586
Monterrey	-0.201	-0.641	0.527	0.132	92013	-18532.148
Salinas Victoria	-0.144	-0.497	0.006	0.066	3570	-515.847
San Nicolás	-0.220	-0.588	0.266	0.115	37920	-8357.602
Santa Catarina	-0.169	-0.563	0.165	0.095	21871	-3692.746
Santiago	-0.239	-0.582	0.089	0.110	3737	-892.042

Anexo II. Estadísticas de índices de vegetación. Análisis por municipios obtenidos a partir de imagen satelital Sentinel-2 de junio de 2021.

Anexo II.I. Métricas obtenidas para el índice de vegetación NDVI (junio 2021).

Índice NDVI a nivel municipal						
Municipio	Media valores	Valor mínimo	Valor máximo	Desv. est.	Cantidad píxeles	Suma valores
Apodaca	0.318	-0.259	0.864	0.194	54168	17242.970
Cadereyta	0.364	-0.255	0.851	0.200	10586	3854.537
García	0.194	-0.298	0.840	0.139	25451	4927.860
San Pedro	0.429	-0.056	0.884	0.229	18930	8115.146
Escobedo	0.246	-0.095	0.858	0.161	29956	7383.746
Guadalupe	0.379	-0.195	0.904	0.228	52302	19844.141
Juárez	0.383	-0.148	0.877	0.215	25512	9759.770
Monterrey	0.271	-0.394	0.999	0.190	92013	24936.354
Salinas Victoria	0.147	-0.025	0.747	0.117	3570	525.325
San Nicolás	0.340	-0.151	0.911	0.201	37920	12906.225
Santa Catarina	0.192	-0.212	0.814	0.140	21871	4197.656
Santiago	0.305	-0.023	0.882	0.172	3737	1139.603

Anexo II.II. Métricas obtenidas para el índice de vegetación EVI2 (junio 2021).

Índice EVI2 a nivel municipal						
Municipio	Media valores	Valor mínimo	Valor máximo	Desv. est.	Cantidad píxeles	Suma valores
Apodaca	0.575	-0.344	1.971	0.402	54168	31162.958
Cadereyta	0.671	-0.340	1.926	0.430	10585	7104.262
García	0.326	-0.390	1.888	0.263	25446	8288.249
San Pedro	0.823	-0.081	2.042	0.508	18930	15582.695
Escobedo	0.427	-0.134	1.950	0.318	29956	12781.690
Guadalupe	0.716	-0.265	2.117	0.499	52302	37468.629
Juárez	0.716	-0.205	2.018	0.466	25512	18276.264
Monterrey	0.482	-0.499	2.496	0.386	92013	44380.951
Salinas Victoria	0.242	-0.037	1.586	0.224	3570	863.034
San Nicolás	0.622	-0.209	2.143	0.422	37920	23596.360
Santa Catarina	0.323	-0.286	1.802	0.267	21871	7064.672
Santiago	0.542	-0.034	2.036	0.366	3737	2026.128

Anexo II.III. Métricas obtenidas para el índice de vegetación NDWI (junio 2021).

Índice NDWI a nivel municipal						
Municipio	Media valores	Valor mínimo	Valor máximo	Desv. est.	Cantidad píxeles	Suma valores
Apodaca	-0.325	-0.866	0.565	0.162	54168	- 17607.188
Cadereyta	-0.358	-0.766	0.646	0.161	10585	-3785.454
García	-0.225	-0.743	0.132	0.119	25446	-5720.850
San Pedro	-0.413	-0.791	0.031	0.187	18930	-7812.544
Escobedo	-0.267	-0.759	0.078	0.138	29956	-7984.320
Guadalupe	-0.371	-0.826	0.133	0.188	52302	- 19412.248
Juárez	-0.370	-0.777	0.373	0.172	25512	-9431.497
Monterrey	-0.289	-0.824	0.680	0.163	92013	- 26548.768
Salinas Victoria	-0.184	-0.666	0.010	0.103	3570	-658.234
San Nicolás	-0.342	-0.847	0.209	0.167	37920	- 12965.606
Santa Catarina	-0.223	-0.726	0.136	0.122	21871	-4874.205
Santiago	-0.319	-0.774	0.022	0.145	3737	-1190.709

Anexo III. Análisis de fragmentación por clase.

Anexo III.I Variables de análisis de fragmentación de AVU de clases del municipio de Apodaca.

	CA	TLA	NumP	MPS	MedPS	PSSD	PSCov	TE	ED	MPE	MSI	AMWSI	MPFD	AMMPFD
Parque	2858400.46	6628708.91	576.00	4962.50	3567.31	5472.97	110.29	180557.60	0.03	313.47	1.37	1.42	1.39	1.36
Plaza	37403.35	6628708.91	25.00	1496.13	780.13	1784.98	119.31	4859.05	0.00	194.36	1.42	1.85	1.46	1.46
Camellón	3650550.94	6628708.91	2576.00	1417.14	437.82	5062.40	357.23	671639.60	0.10	260.73	2.48	2.88	1.68	1.52
Glorieta	9308.57	6628708.91	15.00	620.57	377.06	727.47	117.23	1169.03	0.00	77.94	1.05	1.03	1.49	1.38
Jardín residencial	73045.60	6628708.91	75.00	973.94	397.41	1328.08	136.36	8923.44	0.00	118.98	1.24	1.32	1.49	1.41

Anexo III.II Variables de análisis de fragmentación de AVU de clases del municipio de Cadereyta.

	CA	TLA	NumP	MPS	MedPS	PSSD	PSCov	TE	ED	MPE	MSI	AMWSI	MPFD	AMMPFD
Parque	445137.36	1285332.84	66.00	6744.51	3122.04	12577.63	186.49	22291.19	0.02	337.75	1.30	1.54	1.37	1.35
Plaza	19335.89	1285332.84	14.00	1381.13	838.64	982.85	71.16	2046.09	0.00	146.15	1.19	1.17	1.42	1.39
Camellón	802996.20	1285332.84	393.00	2043.25	646.67	8805.41	430.95	124026.02	0.10	315.59	2.18	4.60	1.60	1.54
Glorieta	368.82	1285332.84	1.00	368.82	368.82	0.00	0.00	68.99	0.00	68.99	1.01	1.01	1.43	1.43
Jardín residencial	17494.57	1285332.84	5.00	3498.91	2110.15	3377.31	96.52	1580.23	0.00	316.05	1.76	1.59	1.46	1.40

Anexo III.III. Variables de análisis de fragmentación de AVU de clases del municipio de García.

	CA	TLA	NumP	MPS	MedPS	PSSD	PSCov	TE	ED	MPE	MSI	AWMSI	MPFD	AWMPFD
Parque	366575.92	2607419.33	71.00	5163.04	2402.34	10236.52	198.27	20386.91	0.01	287.14	1.38	1.65	1.47	1.36
Plaza	3978.12	2607419.33	1.00	3978.12	3978.12	0.00	0.00	348.38	0.00	348.38	1.56	1.56	1.41	1.41
Camellón	1813810.32	2607419.33	920.00	1971.53	596.16	6389.96	324.11	296239.38	0.11	322.00	2.33	3.70	1.64	1.54
Glorieta	977.46	2607419.33	4.00	244.37	245.42	88.28	36.13	218.96	0.00	54.74	1.01	1.00	1.47	1.46
Jardín residencial	422077.51	2607419.33	141.00	2993.46	1510.27	3858.79	128.91	34024.29	0.01	241.31	1.41	1.56	1.45	1.39

Anexo III.IV. Variables de análisis de fragmentación de AVU de clases del municipio de San Pedro.

	CA	TLA	NumP	MPS	MedPS	PSSD	PSCov	TE	ED	MPE	MSI	AWMSI	MPFD	AWMPFD
Parque	937956.12	2522939.11	121.00	7751.70	4654.48	12670.47	163.45	48153.07	0.02	397.96	1.87	1.53	1.49	1.34
Plaza	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Camellón	1142056.26	2522939.11	862.00	1324.89	355.54	2208.77	166.71	217410.92	0.09	252.22	2.68	2.31	1.72	1.50
Glorieta	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Jardín residencial	442926.74	2522939.11	153.00	2894.95	1423.65	3805.46	131.45	31818.10	0.01	207.96	1.28	1.31	1.43	1.36

Anexo III.V. Variables de análisis de fragmentación de AVU de clases del municipio de Escobedo.

	CA	TLA	NumP	MPS	MedPS	PSSD	PSCoV	TE	ED	MPE	MSI	AWMSI	MPFD	AWMPFD
Parque	1137998.60	2709835.80	184.00	6184.78	4306.76	6513.49	105.31	65677.66	0.02	356.94	1.37	1.48	1.38	1.36
Plaza	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Camellón	1366629.47	2709835.80	913.00	1496.86	449.83	6990.27	467.00	277252.60	0.10	303.67	2.39	4.86	1.66	1.59
Glorieta	1437.08	2709835.80	5.00	287.42	169.65	226.18	78.69	313.87	0.00	62.77	1.11	1.10	1.51	1.46
Jardín residencial	203770.64	2709835.80	40.00	5094.27	1331.88	7877.82	154.64	9907.46	0.00	247.69	1.23	1.23	1.40	1.32

Anexo III.VI. Variables de análisis de fragmentación de AVU de clases del municipio de Guadalupe.

	CA	TLA	NumP	MPS	MedPS	PSSD	PSCoV	TE	ED	MPE	MSI	AWMSI	MPFD	AWMPFD
Parque	2749991.33	6692366.62	365.00	7534.22	4089.88	20262.44	268.94	129754.83	0.02	355.49	1.35	1.53	1.38	1.34
Plaza	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Camellón	2966369.09	6692366.62	2512.00	1180.88	558.79	1886.38	159.74	820189.70	0.12	326.51	2.83	3.68	1.70	1.62
Glorieta	3095.87	6692366.62	2.00	1547.93	1547.93	691.45	44.67	271.81	0.00	135.91	1.00	1.00	1.35	1.34
Jardín residencial	972910.34	6692366.62	275.00	3537.86	1674.96	6827.02	192.97	62770.52	0.01	228.26	1.32	1.31	1.43	1.35

Anexo III.VII. Variables de análisis de fragmentación de AVU de clases del municipio de Juárez.

	CA	TLA	NumP	MPS	MedPS	PSSD	PSCoV	TE	ED	MPE	MSI	AWMSI	MPFD	AWMPFD
Parque	403465.75	3336933.61	81.00	4981.06	2817.61	5546.25	111.35	25296.53	0.01	312.30	1.40	1.42	1.40	1.36
Plaza	5222.83	3336933.61	1.00	5222.83	5222.83	0.00	0.00	360.63	0.00	360.63	1.41	1.41	1.38	1.38
Camellón	2266208.24	3336933.61	1190.00	1904.38	493.99	6208.35	326.00	306307.36	0.09	257.40	2.22	2.58	1.65	1.47
Glorieta	562.08	3336933.61	3.00	187.36	199.43	47.88	25.55	144.73	0.00	48.24	1.00	1.00	1.49	1.48
Jardín residencial	661474.71	3336933.61	184.00	3594.97	2260.74	4553.26	126.66	49178.18	0.01	267.27	1.39	1.55	1.43	1.38

Anexo III.VIII Variables de análisis de fragmentación de AVU de clases del municipio de Monterrey.

	CA	TLA	NumP	MPS	MedPS	PSSD	PSCoV	TE	ED	MPE	MSI	AWMSI	MPFD	AWMPFD
Parque	3927393.31	10716648.39	489.00	8031.48	4365.03	19103.88	237.86	179458.39	0.02	366.99	1.36	1.41	1.38	1.33
Plaza	35101.01	10716648.39	7.00	5014.43	4983.60	2752.18	54.89	1917.64	0.00	273.95	1.18	1.14	1.35	1.32
Camellón	5020503.18	10716648.39	4939.00	1016.50	438.31	1817.55	178.80	1518599.49	0.14	307.47	2.85	3.81	1.71	1.62
Glorieta	1411.60	10716648.39	11.00	128.33	91.45	94.27	73.46	482.55	0.00	43.87	1.16	1.19	1.64	1.57
Jardín residencial	1732239.29	10716648.39	602.00	2877.47	1210.36	5754.49	199.98	128380.93	0.01	213.26	1.35	1.40	1.44	1.37

Anexo III.IX. Variables de análisis de fragmentación de AVU de clases del municipio de Salinas Victoria.

	CA	TLA	NumP	MPS	MedPMS	PSSD	PSCoV	TE	ED	MPE	MSI	AWMSI	MPFD	AWMPFD
Parque	48601.17	379985.74	9.00	5400.13	3478.14	3337.69	61.81	3355.90	0.01	372.88	1.43	1.56	1.38	1.38
Plaza	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Camellón	223600.49	379985.74	147.00	1521.09	726.19	2198.59	144.54	34543.17	0.09	234.99	1.90	2.12	1.57	1.49
Glorieta	3028.35	379985.74	4.00	757.09	753.04	218.57	28.87	391.48	0.00	97.87	1.01	1.01	1.39	1.38
Jardín residencial	104755.73	379985.74	21.00	4988.37	3544.67	6001.26	120.30	5853.45	0.02	278.74	1.23	1.22	1.36	1.33

Anexo III.X. Variables de análisis de fragmentación de AVU de clases del municipio de San Nicolás.

	CA	TLA	NumP	MPS	MedPMS	PSSD	PSCoV	TE	ED	MPE	MSI	AWMSI	MPFD	AWMPFD
Parque	2835778.31	4593365.38	550.00	5155.96	2834.01	7725.75	149.84	172360.94	0.04	313.38	1.41	1.54	1.41	1.36
Plaza	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Camellón	1756946.38	4593365.38	1271.00	1382.33	522.78	3183.08	230.27	393585.47	0.09	309.67	2.74	3.45	1.71	1.58
Glorieta	640.69	4593365.38	2.00	320.34	320.34	109.85	34.29	129.15	0.00	64.58	1.04	1.03	1.46	1.45
Jardín residencial	-	-	-	-	-	-	-	-	-	-	-	-	-	-

Anexo III.XI. Variables de análisis de fragmentación de AVU de clases del municipio de Santa Catarina.

	CA	TLA	NumP	MPS	MedPS	PSSD	PSCov	TE	ED	MPE	MSI	AWMSI	MPFD	AWMPFD
Parque	631387.41	3225182.08	113.00	5587.50	3289.04	5906.56	105.71	37469.00	0.01	331.58	1.38	1.45	1.40	1.36
Plaza	1679.34	3225182.08	3.00	559.78	458.83	257.41	45.98	345.21	0.00	115.07	1.36	1.46	1.50	1.51
Camellón	2001559.70	3225182.08	1484.00	1348.76	505.88	3442.60	255.24	391427.54	0.12	263.77	2.25	3.20	1.65	1.56
Glorieta	349.99	3225182.08	2.00	174.99	174.99	29.01	16.58	95.01	0.00	47.50	1.02	1.02	1.50	1.50
Jardín residencial	590205.64	3225182.08	244.00	2418.88	1342.53	3702.54	153.07	49288.73	0.02	202.00	1.35	1.43	1.46	1.38

Anexo III.XII. Variables de análisis de fragmentación de AVU de clases del municipio de Santiago.

	CA	TLA	NumP	MPS	MedPS	PSSD	PSCov	TE	ED	MPE	MSI	AWMSI	MPFD	AWMPFD
Parque	17714.67	347307.22	7.00	2530.67	2483.59	1269.75	50.17	1366.76	0.00	195.25	1.18	1.18	1.43	1.36
Plaza	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Camellón	244081.71	347307.22	227.00	1075.25	407.25	2440.97	227.01	63080.88	0.18	277.89	2.30	4.57	1.67	1.63
Glorieta	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Jardín residencial	85510.84	347307.22	29.00	2948.65	2396.07	2658.11	90.15	6601.16	0.02	227.63	1.30	1.29	1.40	1.36

Anexo IV.I. Tabla de indicadores de accesibilidad para la ZMM.

ZMM												
Accesibilidad	Población total	Población total (%)	Población femenina	Población femenina (%)	Población masculina	Población masculina (%)	Población de 0 a 14 años	Población de 0 a 14 años (%)	Población de 65 o más años	Población de 65 o más años (%)	Población discapacitada	Población discapacitada (%)
ALTA	198528	4.26	99670	4.27	98505	4.25	45956	4.36	13012	3.69	4575	2.97
MEDIA	934729	20.0	471769	20.2	462434	19.97	196731	18.7	74662	21.15	28232	18.34
BAJA	1607165	34.5	808618	34.6	796154	34.38	333368	31.59	144801	41.0	56522	36.71
NULA	1920095	41.2	954149	40.9	958534	41.39	479080	45.4	120513	34.1	64637	41.98
TOTAL	4660517		2334206		2315627		1055135		352988		153966	

Anexo IV.II. Tabla de indicadores de accesibilidad para Apodaca, Nuevo León.

Apodaca												
Accesibilidad	Población total	Población total (%)	Población femenina	Población femenina (%)	Población masculina	Población masculina (%)	Población de 0 a 14 años	Población de 0 a 14 años (%)	Población de 65 o más años	Población de 65 o más años (%)	Población discapacitada	Población discapacitada (%)
ALTA	49017	7.82	24408	7.87	24570	7.81	13528	8.64	1024	5.09	779	5.10
MEDIA	237658	37.92	118713	38.30	118837	37.75	59655	38.10	7184	35.69	5583	36.54
BAJA	289400	46.17	142763	46.05	146333	46.49	70626	45.11	10308	51.20	7903	51.72
NULA	50741	8.10	24111	7.78	25044	7.96	12751	8.14	1615	8.02	1015	6.64
TOTAL	626816		309995		314784		156560		20131		15280	

Anexo IV.III. Tabla de indicadores de accesibilidad para Cadereyta, Nuevo León.

Cadereyta												
Accesibilidad	Población total	Población total (%)	Población femenina	Población femenina (%)	Población masculina	Población masculina (%)	Población de 0 a 14 años	Población de 0 a 14 años (%)	Población de 65 o más años	Población de 65 o más años (%)	Población discapacitada	Población discapacitada (%)
ALTA	4386	5.79	2220	5.86	2163	5.76	1173	6.60	136	2.69	43	2.74
MEDIA	14268	18.84	7155	18.90	7098	18.91	3585	20.16	726	14.35	277	17.64
BAJA	28026	37.02	14016	37.02	13961	37.19	6734	37.86	1862	36.81	615	39.17
NULA	29034	38.35	14471	38.22	14313	38.13	6293	35.38	2334	46.14	635	40.45
TOTAL	75714		37862		37535		17785		5058		1570	

Anexo IV.IV. Tabla de indicadores de accesibilidad para General Escobedo, Nuevo León.

General Escobedo												
Accesibilidad	Población total	Población total (%)	Población femenina	Población femenina (%)	Población masculina	Población masculina (%)	Población de 0 a 14 años	Población de 0 a 14 años (%)	Población de 65 o más años	Población de 65 o más años (%)	Población discapacitada	Población discapacitada (%)
ALTA	17952	3.96	8926	3.97	8974	3.94	4519	3.86	341	2.09	262	1.82
MEDIA	71983	15.87	36009	16.01	35921	15.78	17923	15.29	2217	13.60	1891	13.12
BAJA	152100	33.54	76021	33.79	76005	33.39	36664	31.29	6777	41.57	4930	34.21
NULA	211504	46.63	104000	46.23	106726	46.89	58084	49.56	6967	42.74	7326	50.84
TOTAL	453539		224956		227626		117190		16302		14409	

Anexo IV.V. Tabla de indicadores de accesibilidad para García, Nuevo León.

García												
Accesibilidad	Población total	Población total (%)	Población femenina	Población femenina (%)	Población masculina	Población masculina (%)	Población de 0 a 14 años	Población de 0 a 14 años (%)	Población de 65 o más años	Población de 65 o más años (%)	Población discapacitada	Población discapacitada (%)
ALTA	5567	1.52	2794	1.54	2773	1.50	1653	1.44	94	2.04	94	1.02
MEDIA	30751	8.38	15417	8.49	15319	8.27	9384	8.16	457	9.92	803	8.72
BAJA	54165	14.76	26950	14.85	27194	14.69	16745	14.56	883	19.17	1489	16.16
NULA	276595	75.35	136379	75.12	139890	75.54	87238	75.85	3171	68.86	6827	74.10
TOTAL	367078		181540		185176		115020		4605		9213	

Anexo IV.VI. Tabla de indicadores de accesibilidad para Guadalupe, Nuevo León.

Guadalupe												
Accesibilidad	Población total	Población total (%)	Población femenina	Población femenina (%)	Población masculina	Población masculina (%)	Población de 0 a 14 años	Población de 0 a 14 años (%)	Población de 65 o más años	Población de 65 o más años (%)	Población discapacitada	Población discapacitada (%)
ALTA	25373	3.98	12760	3.97	12760	4.04	5652	4.50	1796	2.68	524	1.96
MEDIA	146843	23.03	74226	23.11	72543	22.96	28184	22.42	14819	22.08	4987	18.62
BAJA	295889	46.41	149352	46.51	146252	46.29	56456	44.92	33544	49.99	13122	49.01
NULA	169439	26.58	84784	26.40	84418	26.72	35399	28.16	16948	25.26	8143	30.41
TOTAL	637544		321122		315973		125691		67107		26776	

Anexo IV.VII. Tabla de indicadores de accesibilidad para Juárez, Nuevo León.

Juárez												
Accesibilidad	Población total	Población total (%)	Población femenina	Población femenina (%)	Población masculina	Población masculina (%)	Población de 0 a 14 años	Población de 0 a 14 años (%)	Población de 65 o más años	Población de 65 o más años (%)	Población discapacitada	Población discapacitada (%)
ALTA	8701	1.95	4284	1.94	4411	1.97	2596	1.98	115	1.47	176	1.71
MEDIA	33212	7.46	16669	7.56	16537	7.38	9580	7.32	553	7.05	707	6.86
BAJA	76054	17.08	37892	17.19	38093	17.00	21669	16.56	1525	19.45	1821	17.67
NULA	327439	73.51	161629	73.31	165013	73.65	96977	74.13	5647	72.03	7601	73.76
TOTAL	445406		220474		224054		130822		7840		10305	

Anexo IV.VIII. Tabla de indicadores de accesibilidad para Monterrey, Nuevo León.

Monterrey												
Accesibilidad	Población total	Población total (%)	Población femenina	Población femenina (%)	Población masculina	Población masculina (%)	Población de 0 a 14 años	Población de 0 a 14 años (%)	Población de 65 o más años	Población de 65 o más años (%)	Población discapacitada	Población discapacitada (%)
ALTA	28445	2.51	14513	2.54	13835	2.48	5096	2.34	3209	2.39	684	1.52
MEDIA	156549	13.80	80169	14.01	76230	13.64	26014	11.94	21425	15.96	5077	11.31
BAJA	375801	33.12	190933	33.36	183597	32.85	65020	29.83	49720	37.05	14266	31.78
NULA	573946	50.58	286708	50.10	285246	51.04	121807	55.89	59854	44.60	24861	55.38
TOTAL	1134741		572323		558908		217937		134208		44888	

Anexo IV.IX. Tabla de indicadores de accesibilidad para Santa Catarina, Nuevo León.

Santa Catarina												
Accesibilidad	Población total	Población total (%)	Población femenina	Población femenina (%)	Población masculina	Población masculina (%)	Población de 0 a 14 años	Población de 0 a 14 años (%)	Población de 65 o más años	Población de 65 o más años (%)	Población discapacitada	Población discapacitada (%)
ALTA	12156	4.02	6062	3.99	6074	4.04	3452	4.95	365	1.84	228	2.26
MEDIA	48486	16.02	24149	15.91	24312	16.15	11042	15.84	2497	12.56	1433	14.19
BAJA	97060	32.07	48709	32.10	48253	32.06	21347	30.63	6983	35.13	3427	33.93
NULA	144904	47.89	72842	48.00	71861	47.75	33854	48.57	10033	50.47	5013	49.63
TOTAL	302606		151762		150500		69695		19878		10101	

Anexo IV.X. Tabla de indicadores de accesibilidad para Santiago, Nuevo León.

Santiago												
Accesibilidad	Población total	Población total (%)	Población femenina	Población femenina (%)	Población masculina	Población masculina (%)	Población de 0 a 14 años	Población de 0 a 14 años (%)	Población de 65 o más años	Población de 65 o más años (%)	Población discapacitada	Población discapacitada (%)
ALTA	8	0.02	*	*	*	*	*	*	*	*	*	*
MEDIA	432	1.01	215	1.02	207	0.98	82	0.94	73	1.59	6	0.50
BAJA	3253	7.60	1598	7.58	1627	7.73	571	6.55	531	11.56	129	10.72
NULA	39106	91.37	19260	91.40	19215	91.29	8065	92.51	3990	86.85	1068	88.78
TOTAL	42799		21073		21049		8718		4594		1203	

*Información no disponible.

Anexo IV.XI. Tabla de indicadores de accesibilidad para San Nicolás de los Garza, Nuevo León.

San Nicolás de los Garza												
Accesibilidad	Población total	Población total (%)	Población femenina	Población femenina (%)	Población masculina	Población masculina (%)	Población de 0 a 14 años	Población de 0 a 14 años (%)	Población de 65 o más años	Población de 65 o más años (%)	Población discapacitada	Población discapacitada (%)
ALTA	43269	10.50	21844	10.45	21346	10.53	7630	11.45	5490	10.12	1644	10.24
MEDIA	173511	42.11	88169	42.18	85282	42.07	27887	41.84	21860	40.30	6671	41.56
BAJA	182096	44.19	92420	44.21	89561	44.18	29016	43.53	24849	45.81	7283	45.37
NULA	13160	3.19	6594	3.15	6515	3.21	2121	3.18	2040	3.76	454	2.83
TOTAL	412036		209027		202704		66654		54239		16052	

Anexo IV.XII. Tabla de indicadores de accesibilidad para San Pedro Garza García, Nuevo León.

San Pedro Garza García												
Accesibilidad	Población total	Población total (%)	Población femenina	Población femenina (%)	Población masculina	Población masculina (%)	Población de 0 a 14 años	Población de 0 a 14 años (%)	Población de 65 o más años	Población de 65 o más años (%)	Población discapacitada	Población discapacitada (%)
ALTA	3654	2.77	1859	2.68	1776	2.85	657	3.11	442	2.51	141	4.21
MEDIA	21036	15.92	10878	15.69	10148	16.27	3395	16.07	2851	16.20	797	23.80
BAJA	53321	40.36	27964	40.33	25278	40.54	8520	40.33	7819	44.43	1537	45.89
NULA	54115	40.96	28631	41.30	25156	40.34	8552	40.48	6488	36.86	874	26.10
TOTAL	132126		69332		62358		21124		17600		3349	