

UNIVERSIDAD DE CANTABRIA



ESCUELA DE DOCTORADO DE LA UNIVERSIDAD DE CANTABRIA
DOCTORADO EN INGENIERÍA CIVIL

TESIS DOCTORAL

DESARROLLO DE HERRAMIENTAS DE MODELIZACIÓN ESPACIAL DE RIESGOS AMBIENTALES URBANOS PARA FACILITAR SU MITIGACIÓN MEDIANTE SOLUCIONES BASADAS EN LA NATURALEZA

PhD THESIS

DEVELOPING TOOLS FOR SPATIAL MODELLING OF URBAN ENVIRONMENTAL RISKS TO FACILITATE THEIR MITIGATION THROUGH NATURE-BASED SOLUTIONS

Presentada por:

ALEJANDRO ROLDÁN VALCARCE

Dirigida por:

Prof./Dra. CRISTINA MANCHADO DEL VAL

Prof./Dr. DANIEL JATO ESPINO

Santander, 2023

Agradecimientos

Deseo expresar mi más profundo agradecimiento a todas las personas e instituciones que hicieron posible la culminación de mi tesis doctoral:

En primer lugar, agradezco al Ministerio de Ciencia e Innovación del Gobierno de España por su generosa financiación a través de las Ayudas para Contratos Predoctorales (FPI) con referencia PRE2019-089450, vinculada al proyecto "Caracterización mecánica de secciones filtrantes y estrategias de localización inteligente para un drenaje urbano sostenible a escala ciudad" con referencia RTI2018-094217-B-C32. Esta financiación fue fundamental para llevar a cabo mi investigación.

Quiero expresar mi más sincero agradecimiento a mis directores de tesis, Cristina Manchado del Val y Daniel Jato Espino, por su orientación experta, paciencia, templanza y apoyo constante a lo largo de esta investigación. También a mi tutor, Jorge Rodríguez Hernández, quien me inspiró en esta aventura y gracias al cual consideré emprender esta travesía. Ha sido un viaje desafiante, y ellos tres nunca dejaron de creer en alcanzar el objetivo. Vuestra profesionalidad y humanidad son dignas de inspiración y admiración.

Gracias al Instituto Suizo de Ciencia y Tecnología de Agua (EAWAG) por permitirme realizar mi estancia predoctoral en sus instalaciones de Dübendorf. Agradezco a Peter Bach su supervisión y cálida acogida durante mi estancia en Zürich. También a todas las personas que hicieron de la estancia una experiencia inolvidable.

Gracias a mis compañeros de investigación en GITECO, Anik y Carlos los cuales fueron imprescindibles en mis primeros pasos. También dar las gracias a mi segunda oleada de compañeros en GITECO en especial a Christopher, Dario, Adrian e Itzayana por todo el apoyo y ayuda desinteresada. Nuestra convivencia cercana dio lugar a lazos no solo profesionales, sino también personales, y eso es lo que le da valor a seguir caminando en la cotidianidad.

Gracias a todos mis amigos y otras personas que se han cruzado por mi camino estos años que han gastado tiempo de sus vidas para hacer la mía más interesante, agradable y enriquecedora. En especial me gustaría agradecer a Maria su estoico, inquebrantable y perseverante apoyo durante todos los días desde que supimos de nuestra existencia, no habría Alejandro sin ella.

Y por supuesto agradecer sin reservas a mis padres, Esther y Javier, grandes fuentes de inspiración de constancia, perseverancia. Gracias a mi hermana, por recordarme mantenerme regio y a mis abuelos por enseñarme a amar la vida.

Finalmente, a todas las personas que de una u otra forma contribuyeron en este proyecto.

Gracias a todos.

Tabla de contenido

1	INTRODUCCIÓN	1
1.1	CAMBIO CLIMÁTICO	3
1.2	EXPANSIÓN URBANA	5
1.3	PROBLEMAS AMBIENTALES URBANOS	6
1.3.1	<i>Inundaciones</i>	6
1.3.2	<i>Efecto isla de calor urbano</i>	7
1.3.3	<i>Vulnerabilidad urbana</i>	8
1.4	ADAPTACIÓN URBANA	10
1.4.1	<i>Soluciones basadas en la naturaleza (NBS)</i>	10
1.4.2	<i>Importancia de la toma de decisiones</i>	13
1.5	ESTRUCTURA DEL DOCUMENTO	14
1.6	MARCO DE LA TESIS	15
1.7	OBJETIVOS E HIPÓTESIS	16
2	ESTADO DEL ARTE	19
2.1	MODELOS DE INUNDACIÓN PLUVIAL URBANOS	21
2.2	PREDICCIÓN DEL EFECTO ISLA DE CALOR URBANO	25
2.3	MÉTODOS DE ÍNDICES DE VULNERABILIDAD URBANAS	29
2.4	RECURSOS INFORMÁTICOS EN EL ÁMBITO DE LOS RIESGOS URBANOS	31
2.5	COROLARIO	33
3	METODOLOGÍA	35
3.1	CASOS DE ESTUDIO	37
3.1.1	<i>Santander</i>	37
3.1.2	<i>Madrid</i>	37
3.2	MODELO HIDROLÓGICO URBANO	39
3.2.1	<i>Datos de entrada en fase inicial</i>	40
3.2.2	<i>Delineación y jerarquización de las subcuencas</i>	44
3.2.3	<i>Integración de los datos</i>	46
3.2.4	<i>Cálculo del caudal máximo de escorrentía</i>	47
3.3	MODELO DE PREDICCIÓN DEL EFECTO ISLA DE CALOR URBANO	51
3.3.1	<i>Procesamiento de datos</i>	52
3.3.2	<i>Machine learning</i>	55
3.3.3	<i>Preparación de datos y poder predictivo</i>	58
3.4	ÍNDICE DE VULNERABILIDAD URBANA	60
3.4.1	<i>Recopilación de datos de entrada</i>	61
3.4.2	<i>Clasificación, selección y correlación</i>	61
3.4.3	<i>Cálculo de la vulnerabilidad espacial</i>	64
3.4.4	<i>Suma ponderada y mapeo de subíndices</i>	65
3.4.5	<i>Test de sensibilidad</i>	65
4	RESULTADOS Y DISCUSIÓN	67
4.1	MODELO HIDROLÓGICO URBANO	69
4.1.1	<i>Tratamiento de datos de entrada</i>	69
4.1.2	<i>Cálculo de escorrentía acumulada</i>	71
4.1.3	<i>Simulación de escenarios de mitigación</i>	74

4.2	MODELO DE PREDICCIÓN DEL EFECTO ISLA DE CALOR URBANO.....	78
4.2.1	<i>Tratamiento de datos</i>	80
4.2.2	<i>Machine learning</i>	82
4.2.3	<i>Discusión</i>	85
4.3	ÍNDICE DE VULNERABILIDAD URBANA.....	89
4.3.1	<i>Clasificación, selección y correlación</i>	89
4.3.2	<i>Suma ponderada y mapeo de subíndices</i>	90
4.3.3	<i>Cálculo de la vulnerabilidad espacial</i>	93
4.3.4	<i>Test de sensibilidad</i>	95
4.3.5	<i>Mapa de riesgo</i>	95
4.3.6	<i>Discusión</i>	96
5	CONCLUSIONES	99
5.1	CONCLUSIONES GENERALES.....	101
5.2	CONCLUSIONES ESPECIFICAS.....	102
5.2.1	<i>Modelo hidrológico urbano</i>	102
5.2.2	<i>Modelado de predicción del efecto isla de calor urbano</i>	103
5.2.3	<i>Índice de vulnerabilidad urbana</i>	103
5.3	FUTURAS LÍNEAS DE INVESTIGACIÓN.....	105
5.3.1	<i>Modelo hidrológico urbano</i>	105
5.3.2	<i>Modelo de predicción del efecto isla de calor urbano</i>	105
5.3.3	<i>Índice de vulnerabilidad urbana</i>	105
5.3.4	<i>Unificación, aplicación y sinergia</i>	106
6	REFERENCIAS	107
7	ANEXOS	139
7.1	ANEXO 1.....	141
7.2	ANEXO 2.....	149
7.3	ANEXO 3.....	152

Lista de Figuras

FIGURA 1. ESQUEMA DE CLASIFICACIÓN DE METODOLOGÍAS DE MODELIZACIÓN DE INUNDACIONES. _____	22
FIGURA 2. ESQUEMA DE LAS DIFERENTES APROXIMACIONES DE PREDICCIÓN Y ANÁLISIS DEL EFECTO UHI _____	25
FIGURA 3. ESQUEMA DE LAS DIVISIONES PRINCIPALES DE LA ATMÓSFERA URBANA (FABRIZI ET AL., 2010) _____	27
FIGURA 4. RESUMEN DE LAS MÉTODOS Y RECURSOS UTILIZADOS EN LA TESIS Y SU IMPLICACIÓN EN LA IMPLEMENTACIÓN ARGUMENTADA DE SOLUCIONES BASADAS EN LA NATURALEZA (NBS). _____	33
FIGURA 5. LOCALIZACIÓN DE LOS CASOS DE ESTUDIO. A) SANTANDER Y B) MADRID. _____	38
FIGURA 6. ESQUEMA DEL PROCESO DE TRABAJO EN MODELADO HIDROLÓGICO. _____	39
FIGURA 7. GRUPOS HIDROLÓGICOS SEGÚN COMPOSICIÓN DEL SUELO EXTRAÍDA DE LA NORMA 5.2-IC DE LA INSTRUCCIÓN DE CARRETERAS DE DRENAJE SUPERFICIAL. _____	43
FIGURA 8. CODIFICACIÓN DE LA HERRAMIENTA DE FLOW DIRECCIÓN PARA LA DETERMINACIÓN DE LA DIRECCIÓN DE LA ESCORRENTÍA. MODIFICADO DE ARCGIS® (HTTPS://PRO.ARCGIS.COM/EN/PRO-APP/LATEST/TOOL-REFERENCE/SPATIAL-ANALYST/FLOW-DIRECTION.HTM). _____	45
FIGURA 9. PROCESO DEL ALGORITMO DE JERARQUIZACIÓN DE SUBCUENCAS. _____	46
FIGURA 10. ESQUEMA CONCEPTUAL DEL FLUJO DE TRABAJO PARA LA PREDICCIÓN DEL EFECTO SUHI. _____	51
FIGURA 11. DIAGRAMA DE FLUJO DE LA METODOLOGÍA APLICADA PARA ESTIMAR UN ÍNDICE DE VULNERABILIDAD. _____	60
FIGURA 12. RESUMEN DE LAS PRINCIPALES FASES DEL ADD-IN ARCDRAIN. _____	69
FIGURA 13. LOCALIZACIÓN DEL CASO DE ESTUDIO DE LA CIUDAD DE SANTANDER Y DATOS DE ENTRADA DE ARCDRAIN, (A) MAPA DE SITUACIÓN DE LA CIUDAD DE SANTANDER, (B) MODELO DIGITAL DE ELEVACIÓN (MDE), (C) GRUPO HIDROLÓGICO DEL SUELO (HSG), (D) MAPA DE COBERTURA DEL SUELO DEL ATLAS URBANO, Y (E) PRECIPITACIÓN MÁXIMA DIARIA PARA UN PERIODO DE RETORNO DE 10 AÑOS. _____	70
FIGURA 14. DESGLOSE DE LOS PROCESOS DEL ADD-IN ARCDRAIN Y SU CORRESPONDENCIA CON LA ESTRUCTURA DEL APARTADO 3.2. _____	71
FIGURA 15. PRODUCTOS DERIVADOS DEL MDE, (A) PENDIENTE, (B) ACUMULACIÓN DE FLUJO, (C) ORDEN DE ARROYOS, Y (D) LONGITUD DE CAUCE MÁS LARGO PARA CADA SUBCUENCA. _____	72
FIGURA 16. VALORES DE (A) CAUDAL MÁXIMO INDIVIDUAL (m^3/s) Y (B) CAUDAL MÁXIMO ACUMULADO (m^3/s) GENERADO EN LAS SUBCUENCAS. _____	73
FIGURA 17. SOLAPAMIENTO ENTRE LAS SUBCUENCAS DELIMITADAS MEDIANTE ARCDRAIN Y LAS ZONAS INUNDABLES SEÑALADAS POR EL AYUNTAMIENTO DE SANTANDER. _____	73
FIGURA 18. GRÁFICO DE VIOLÍN DE LOS VALORES DEL CAUDAL MÁXIMO ACUMULADO EN LAS SUBCUENCAS INUNDABLES “FLOOD RELATED” Y NO INUNDABLES “FLOOD-NONRELATED”. _____	74
FIGURA 19. SUBCUENCAS SELECCIONADAS PARA SIMULAR DIFERENTES MODIFICACIONES DE LA CUBIERTA TERRESTRE (NARANJA). _____	75
FIGURA 20. GRÁFICOS DE VIOLÍN DE LOS VALORES DE CAUDAL MÁXIMO ACUMULADO COMPARANDO SUBCUENCAS INUNDABLES “FLOOD RELATED” Y NO INUNDABLES “FLOOD-NONRELATED” AL SUSTITUIR LA SUPERFICIE DEL SUELO URBANA POR PAVIMENTOS PERMEABLES E INFRAESTRUCTURAS VERDES: (A) 10% DEL ÁREA SUSTITUIDA, (B) 25% DEL ÁREA SUSTITUIDA, (C) 50% DEL ÁREA SUSTITUIDA Y (D) 100% DEL ÁREA SUSTITUIDA. _____	76
FIGURA 21. INTERFAZ DEL ADD-IN ARCUHI QUE INCLUYE SUS BOTONES PRINCIPALES Y VENTANAS EMERGENTES. _____	78

FIGURA 22. MAPA DE SITUACIÓN QUE INDICA LA UBICACIÓN DE LA ZONA DE ESTUDIO (A) Y SUS CORRESPONDIENTES MAPAS DE OCUPACIÓN DEL SUELO EN 2006 (B), 2012 (C) Y 2018 (D) SEGÚN LA CODIFICACIÓN DEL URBAN ATLAS.	79
FIGURA 23. DISTRIBUCIÓN ESPACIAL DE LAS VARIABLES QUE INTERVIENEN EN LA MODELIZACIÓN DEL EFECTO ISLA DE CALOR URBANO (UHI) EN TODA LA ZONA DE ESTUDIO, EXPRESADA EN VALORES MEDIOS O PORCENTAJES DEL ÁREA OCUPADA POR PÍXEL. (2018)	81
FIGURA 24. GRÁFICO DE CORRELACIÓN ENTRE LAS VARIABLES QUE INTERVIENEN EN LA MODELIZACIÓN DEL EFECTO ISLA DE CALOR URBANO (UHI).	82
FIGURA 25. PREDICCIONES Y ERRORES ABSOLUTOS DERIVADOS DE LA MODELIZACIÓN DE LOS VALORES OBSERVADOS DE AMPLITUD TÉRMICA (ΔT) EN LA ZONA DE ESTUDIO MEDIANTE RANDOM FOREST REGRESSION (RFR).	84
FIGURA 26. SENSIBILIDAD DE LAS VARIABLES EXPLICATIVAS PROCEDENTES DE DIFERENTES FUENTES DE DATOS (A) MAPAS DE ALBEDO A LO LARGO DEL PERIODO DE ESTUDIO (B) ERRORES ABSOLUTOS PRODUCIDOS POR DIFERENTES MODELOS DIGITALES DEL TERRENO (MDT)	85
FIGURA 27. IMPORTANCIA DE LAS VARIABLES SEGÚN EL AUMENTO DEL ERROR CUADRÁTICO MEDIO (%INC MSE) OBTENIDO PARA LAS PREDICCIONES DEL MODELO RANDOM FOREST REGRESSION (RFR).	86
FIGURA 28 .ANÁLISIS DE SENSIBILIDAD DEL EFECTO DE LAS VARIABLES EXPLICATIVAS SOBRE LA AMPLITUD TÉRMICA (ΔT)	87
FIGURA 29. CORRELACIÓN ENTRE VARIABLES DE LAS TRES CLASES DE VULNERABILIDAD. LA DIAGONAL CON VALOR 1, CARACTERÍSTICA DE ESTE TIPO DE GRÁFICOS, SE HA OMITIDO PARA UNA MEJOR VISUALIZACIÓN DE LOS DATOS. A) VARIABLES DEMOGRÁFICAS. B) VARIABLES SOCIOECONÓMICAS. C) VARIABLES DE INFRAESTRUCTURA.	90
FIGURA 30. PORCENTAJE DE VARIANZA EXPLICADO POR CADA DIMENSIÓN DE LOS COMPONENTES PRINCIPALES (FILA SUPERIOR) Y CONTRIBUCIONES DE CADA VARIABLE EN LAS DIMENSIONES 1 Y 2 (SEGUNDA Y TERCERA FILA). LA LÍNEA DE PUNTOS REPRESENTA EL UMBRAL QUE DEFINE LA IMPORTANCIA DE ESA CONTRIBUCIÓN. LAS BARRAS MARCADAS EN ROJO CORRESPONDEN A LAS VARIABLES DESCARTADAS DURANTE EL ANÁLISIS DE COMPONENTES PRINCIPALES (PCA) POR NO CONTRIBUIR A NINGUNA DE LAS DOS DIMENSIONES MÁS PREPONDERANTES EN LA EXPLICACIÓN DE LA VARIANZA ESPACIAL POR ENCIMA DEL UMBRAL. A) DEMOGRAFÍA B) SOCIOECONOMÍA C) INFRAESTRUCTURAS.	92
FIGURA 31. MAPAS DE SUBÍNDICE DE VULNERABILIDAD POR CLASE. A) DEMOGRÁFICA. B) SOCIOECONÓMICA. C) INFRAESTRUCTURAS.	93
FIGURA 32. BIPLLOT DE LAS 2 DIMENSIONES MÁS PREPONDERANTES QUE MUESTRAN LAS VARIANZAS DE LAS DIMENSIONES PRINCIPALES A PARTIR DEL ANÁLISIS DE COMPONENTES PRINCIPALES (PCA). A) VARIABLES DEMOGRÁFICAS. B) VARIABLES SOCIOECONÓMICAS. C) VARIABLES DE INFRAESTRUCTURA.	94
FIGURA 33. MAPAS DE SENSIBILIDAD A LA PONDERACIÓN DE LAS CLASES. A) PONDERACIÓN EQUITATIVA, B) 2/3 DEMOGRAFÍA C) 2/3 SOCIOECONOMÍA D) 2/3 INFRAESTRUCTURAS.	95
FIGURA 34. MAPA DE RIESGO DE INUNDACIÓN DE SANTANDER, CREADO COMBINANDO EL MAPA DE VULNERABILIDAD Y EL MAPA DE PELIGROSIDAD (CAUDAL MÁXIMO ACUMULADA) DE LA FIGURA 16B.	96
FIGURA 35. REGIONES CONSIDERADAS PARA LA CARACTERIZACIÓN DEL COEFICIENTE CORRECTOR. EXTRACCIÓN DE LA NORMA 5.21C (ORDEN, 2016).	149
FIGURA 36. DISTRIBUCIÓN ESPACIAL DE LAS VARIABLES QUE INTERVIENEN EN LA MODELIZACIÓN DEL EFECTO ISLA DE CALOR URBANO (UHI) EN TODA LA ZONA DE ESTUDIO, EXPRESADA EN VALORES MEDIOS O PORCENTAJES DEL ÁREA OCUPADA POR PÍXEL. (2006)	152
FIGURA 37. DISTRIBUCIÓN ESPACIAL DE LAS VARIABLES QUE INTERVIENEN EN LA MODELIZACIÓN DEL EFECTO ISLA DE CALOR URBANO (UHI) EN TODA LA ZONA DE ESTUDIO, EXPRESADA EN VALORES MEDIOS O PORCENTAJES DEL ÁREA OCUPADA POR PÍXEL. (2012)	153

Lista de tablas

TABLA 1. CATEGORIZACIÓN DE NBS PROPUESTA POR EL PROYECTO URBAN GREENUP (URBAN GREENUP, 2018)	12
TABLA 2. FUENTES DE BASES DE DATOS APLICABLES AL MODELO Y DISPONIBLES DE FORMA LIBRE.	41
TABLA 3. CONJUNTOS DE DATOS ESPACIALES QUE SE NECESITAN PARA EJECUTAR EL ADD-IN ARCUHI.	53
TABLA 4. FUENTES DE DATOS UTILIZADAS EN PARA EL DESARROLLO DEL ÍNDICE DE VULNERABILIDAD.	61
TABLA 5. VARIABLES INICIALES SELECCIONADAS QUE AFECTAN A LA VULNERABILIDAD FRENTE A LAS INUNDACIONES URBANAS CRUZADO CON OTROS AUTORES Y ORGANIZADAS EN TRES CLASES. EL CÓDIGO ES UTILIZADO EN FIGURAS POSTERIORES.	62
TABLA 6. ESCENARIOS PROPUESTOS PARA LAS PRUEBAS DE SENSIBILIDAD EN LA COMBINACIÓN DE LAS DIFERENTES CLASES DE VULNERABILIDAD.	66
TABLA 7. MEDIDAS DE LA CALIDAD DE AJUSTE OBTENIDAS PARA LOS TRES ALGORITMOS APLICADOS PARA MODELIZAR EL EFECTO ISLA DE CALOR URBANO SUPERFICIAL (SUHI).	83
TABLA 8. RESUMEN DEL NÚMERO DE VARIABLES RESTANTES DESPUÉS DE CADA PASO DE SELECCIÓN.	91
TABLA 9. PONDERACIONES OBTENIDAS MEDIANTE LA SUMA ORTOGONAL DE LA CONTRIBUCIÓN DE LAS VARIABLES FINALES SELECCIONADAS EN CADA CLASE. LAS VARIABLES ANALIZADAS QUE NO ALCANZARON EL NIVEL MÍNIMO DE CONTRIBUCIÓN EN LOS DOS COMPONENTES PRINCIPALES COMO "-" Y SU VALOR ES 0.	91
TABLA 10. VALOR INICIAL DEL UMBRAL DE ESCORRENTÍA (MM)	141
TABLA 11. COEFICIENTE CORRECTOR DEL UMBRAL DE ESCORRENTÍA.	150

Índice de acrónimos

ANN: Artificial Neural Network / Red neuronal artificial.

BGI: Blue Green Infrastructure / Infraestructuras azules y verdes

BMP: Best Management Practices / Mejores prácticas de gestión

CFD: Computational Fluid Dynamics / Dinámica de fluidos computacional

CN: Curve Number / Número de curva

ESA: European Space Agency / Agencia espacial europea

FIV: Factor de Inflación de la Varianza

GI: Green Infrastructures / Infraestructuras verdes

IGME: Instituto Geológico y Minero de España

IGN: Instituto Geográfico Nacional

IPCC: Intergovernmental Panel on Climate Change / Grupo intergubernamental sobre el cambio climático

LID: Low Impact Development / Desarrollos de bajo impacto

LST: Land Surface Temperature / Temperatura de la superficie terrestre

MCD: Multiple-Criteria Decision Analysis / Análisis de decisiones multicriterio

MDE: Modelo Digital de Elevación

MDS: Modelo Digital de Superficie

MDT: Modelo Digital de Terreno

MLR: Multiple Linear Regression / Regresión lineal múltiple

NBS: Nature-Based Solutions / Soluciones basadas en la naturaleza

NOx: Óxidos de Nitrógeno

ODS: Objetivos de Desarrollo Sostenible

ORNL DAAC: The Oak Ridge National Laboratory Distributed Active Archive Center

PCA: Principal Components Analysis / Análisis de componentes principales

RFR: Random Forest Regression / Regresión de bosque aleatorio

RMSE: Root Mean Square Deviation / Raíz del error cuadrático medio

SIG: Sistemas de Información Geográfica

SIOSE: Sistema de Información de Ocupación del Suelo en España

SUDS: Sistemas Urbanos de Drenaje Sostenible

SUHI: Surface Urban Heat Island / Isla de calor urbano superficial

SVF: Sky View Factor / Factor de cielo visible

SVR: Support Vector Regression / Regresión de vectores de soporte

TEB: Town Energy Balance / Balance energético urbano

TEDUS: Técnicas de Drenaje Urbano Sostenible

UBL: Urban Boundary Layer / Capa límite urbana.

UCL: Urban Canopy Layer / Capa de cobertura urbana

UHI: Urban Heat Island / Isla de calor urbano

WSUD: Water Sensitive Urban Desing / Diseño urbano sensible al agua

WRF: Weather Research and Forecasting / Investigación y predicción meteorológica

1 Introducción

Desde que la humanidad comenzó la era industrial en 1820 hasta el día de hoy en 2023, se han realizado innumerables avances tecnológicos, sociales y económicos que han permitido a los seres humanos mejorar su calidad de vida. No obstante, este periodo de prosperidad ha creado dinámicas como el aumento exponencial de la población mundial y el cambio de su distribución espacial en la tierra, que generan nuevos retos y problemáticas. Además, el gasto de recursos naturales para este desarrollo no es sostenible en el tiempo con la tecnología disponible actualmente, lo que ha derivado en desequilibrios medioambientales a nivel global, amenazando nuestro el modo de vida.

1.1 Cambio climático

En la actualidad, estamos experimentando un cambio de las variables del clima sin precedentes. Durante los últimos 50 años (1970-2020), la temperatura de la superficie terrestre ha aumentado a un ritmo más acelerado que en cualquier otro período similar estudiado en los últimos 2000 años. Esto es debido al aumento de las concentraciones de gases de efecto invernadero en la atmósfera, llegando a niveles de CO₂ en 2019 de 410 partes por millón (ppm) no encontradas al menos en los últimos dos millones de años, o las concentraciones de 1866 partes por billón (ppb) de metano o 332 ppb de óxidos de nitrógeno (NO_x), que también son los registros más altos en los últimos 800000 años (IPCC, 2023). El aumento de estos compuestos en la atmósfera es el causante del cambio de forzamiento radiativo que ejerce el efecto invernadero en la atmósfera, aumentando la capacidad del sistema para retener la energía y, por extensión, la temperatura superficial en todo el planeta (IPCC, 2023).

En términos globales, este desequilibrio ha supuesto un incremento de 1,09°C en la última década (2011-2020) con respecto a la temperatura media de la era preindustrial (1850-1900). Este cambio brusco de la temperatura media superficial, en comparación con los tiempos que suelen conllevar los cambios de temperatura del planeta observados en eras geológicas anteriores (Burke et al., 2018), provoca cambios en comportamientos de sistemas como la atmósfera, hidrosfera, criosfera o biosfera. Entre estos cambios se pueden destacar el aumento del nivel del mar o el aumento de la frecuencia, intensidad y/o duración de eventos naturales extremos como olas de calor, precipitaciones torrenciales, sequías y ciclones tropicales (Hansen et al., 2016; IPCC, 2021).

Los expertos del grupo intergubernamental sobre el cambio climático (IPCC) encargados de descubrir las causas de estos cambios han concluido en su informe que este aumento de gases de efecto invernadero en la atmósfera es causado casi en su totalidad por actividades humanas tales como el uso de energías no renovables, los cambios de los usos del suelo o los actuales modelos económicos de producción y consumo. Estos comportamientos desencadenan efectos drásticos y extremos que afectan tanto a la naturaleza como a los seres humanos, causando pérdidas humanas y en los ecosistemas (IPCC, 2022b).

Por ello, es necesario un plan de acción para adaptarse al proceso climático ya iniciado y sus cambios inevitables, así como reducir el incremento de la concentración de gases de efecto invernadero para que esas alteraciones sean lo menos drásticas posibles. La mejora de los cultivos, la mejora de la gestión y almacenamiento del agua, enfoques de gestión sostenible de la tierra o el uso de principios y prácticas agroecológicos son algunos ejemplos de las acciones necesarias para mitigar los efectos del cambio climático en los ecosistemas naturales (IPCC, 2022b). Otras medidas como las soluciones basadas en la naturaleza (NBS), el reverdecimiento urbano o la restauración de humedales ya han sido eficaces para reducir el riesgo de inundaciones y el efecto isla de calor urbano (UHI) (Bayulken et al., 2021; Hobbie & Grimm, 2020; Jessup et al., 2021).

Las políticas y leyes adoptadas que abordan la mitigación del aumento de la temperatura superficial terrestre a día de hoy estiman que el aumento de temperatura superará antes de 2100 los 1,5°C respecto a la media entre 1850 y 1900 (era preindustrial) con una probabilidad de más del 50 % en los escenarios más conservadores, dificultando el objetivo de mantenerlo por debajo de los 2°C debido a la inercia de acumulada en el sistema (IPCC, 2018). Problemas ambientales por causas

relacionadas con las olas de calor, el incremento de la frecuencia y la intensidad de fuertes precipitaciones (traduciéndose en más inundaciones locales) derivarán en el aumento de enfermedades transmitidas por alimentos, agua u otros vectores y la pérdida de biodiversidad se convertirá en un decrecimiento de la producción de alimentos (IPCC, 2023). Esta escasez de recursos básicos como el agua puede, además, generar fricción entre diferentes comunidades como ya está ocurriendo en los países de África (Lawson, 2017), Oriente próximo (Gleick, 2014) o, a una escala menor pero más cercana, los trasvases de agua en las cuencas hidrográficas dentro de España (Farinós & Eds, 2022).

1.2 Expansión urbana

Además del cambio climático, existen otros eventos antropogénicos que son incompatibles con un equilibrio del sistema y con un uso sostenible de los recursos naturales. Uno de los más notables es el crecimiento de la población mundial y su distribución geográfica. En 2020, la tasa de crecimiento de la población global cayó por debajo del 1% anual por primera vez desde 1950. No obstante, según las proyecciones de las Naciones Unidas (UN-DESA, 2022), se espera que la población mundial alcance los 8,5 mil millones en 2030 (superando India a China como el país más poblado del mundo en 2023) y los 9,7 mil millones en 2050. Además, se prevé que alcance un máximo de alrededor de 10,4 mil millones durante la década de 2080 y que posteriormente se mantenga en ese nivel hasta 2100.

En cuanto a su distribución, actualmente se está experimentando un récord histórico en el crecimiento urbano. Más de la mitad de la población mundial vive en áreas urbanas, cifra que ha aumentado desde el 30% en 1950 y se espera alcanzar el 68% según las proyecciones de las Naciones Unidas para 2050 (UN-DESA, 2018b). Se estima que la población urbana mundial aumentará en 2.500 millones de personas más entre 2018 y 2050, todo ello ocupando no más del 3% de la superficie del planeta no sumergida (Z. Liu et al., 2014). Este fenómeno es una de las principales tendencias demográficas junto con el crecimiento de la población global anteriormente descrito, el envejecimiento demográfico y la migración internacional (Guna, 2018; IPCC, 2022a; UN-DESA, 2022).

Este crecimiento urbano está estrechamente vinculado con las dimensiones económica, social y ambiental (UN-DESA, 2022). Las áreas urbanas son puntos clave para el desarrollo, ya que la proximidad entre el comercio, el gobierno y el transporte facilita el intercambio de conocimientos e información. Una gestión sostenible de la expansión urbana, basada en una comprensión de las tendencias demográficas a largo plazo y su influencia en el ecosistema, puede maximizar los beneficios de la concentración urbana al mismo tiempo que mantiene sus funciones ecosistémicas, especialmente en países de ingresos bajos y medianos-bajos donde se experimentará una rápida urbanización en las próximas décadas (UN-HABITAT, 2009). Los habitantes de las urbes suelen ser más jóvenes, más alfabetizados y con mayor nivel educativo, lo que les brinda mejores oportunidades de empleo, vivienda adecuada, servicios sociales, participación cultural y política, así como equidad de género. Sin embargo, una expansión urbana no planificada o mal gestionada, combinada con patrones insostenibles de producción y consumo, así como una falta de capacidad de las instituciones públicas para gestionar la urbanización, puede afectar al crecimiento desordenado de las ciudades, la contaminación atmosférica y acuática, la degradación ambiental, pérdida de biodiversidad, la impermeabilización de grandes superficies o la amplificación de la inercia térmica de las zonas debido a los materiales de construcción (UN-DESA, 2018a).

1.3 Problemas ambientales urbanos

La urbanización ha tenido un impacto positivo en términos de crecimiento económico, reducción de la pobreza y desarrollo de la globalización. Las ciudades ofrecen un entorno propicio para el emprendimiento y la innovación tecnológica debido a la presencia de una fuerza laboral diversa y con un nivel alto de educación, así como una concentración de empresas que mejora la eficiencia logística (UN-DESA, 2018a). No obstante, globalmente la urbanización está teniendo probablemente la mayor influencia directa e indirecta en el cambio global (Shaker et al., 2019).

El crecimiento de las ciudades y concentración de la población hacen que las primeras sean objetivos más grandes para inundaciones, terremotos y otros eventos naturales extremos, aumentando la población e infraestructuras afectadas. También de manera local, la concentración de la población afecta a la capacidad del medio para absorber su impacto. La alta demanda de desplazamientos provoca la aglomeración de vehículos y crea congestión del tráfico, aumentando la contaminación atmosférica y acústica (J. Khan et al., 2018). Los materiales artificiales con los que se cubre la superficie natural tienen propiedades físicas que almacenan calor procedente de la radiación solar y crean problemas como el efecto isla de calor urbano (Verbeke & Audenaert, 2018). Las construcciones verticales, puntos de luz nocturna y señales luminosas crean contaminación visual y contaminación lumínica nocturna (Pothukuchi, 2021). La demanda hídrica, así como la acumulación de residuos exige de un dimensionamiento de su infraestructura acorde al tamaño de la población para su gestión y así evitar contaminación en aguas y suelos (Otterpohl et al., 1997). Además, los cambios socioeconómicos actuales aumentan las desigualdades (Alvaredo et al., 2018) y es crucial su identificación dentro de la ciudad para poder realizar una efectiva y equitativa actuación para minimizar los efectos de estos problemas ambientales.

1.3.1 Inundaciones

Las inundaciones son ocupaciones de la superficie por masas de agua que se concentran en la parte baja de las cuencas debido a la imposibilidad de su infiltración en el suelo. Las inundaciones se pueden clasificar según la fuente de la que proviene la masa de agua o el tiempo de formación. En cuanto a sus fuentes, suelen ser hidro-meteorológicas como lluvias, crecidas de ríos, deshielos o aumentos del nivel del mar por mareas vivas o tsunamis; la rotura de presas o diques también puede ser la causante de una inundación. Según su periodo temporal pueden, ser de formación lenta, que tardan días en ocurrir, o repentinas que se formen en horas o minutos.

La transformación producida en la urbanización de las superficies naturales permeables en zonas impermeables disminuye la capacidad de filtración y aumenta la acumulación de agua por escorrentía durante episodios de lluvia en las zonas más bajas de las diferentes subcuencas que componen la ciudad (Hobbie & Grimm, 2020; Jacobson, 2011; Scalenghe & Ajmone-Marsan, 2009). Además, el aumento de la cubierta impermeable canaliza hacia los arroyos los contaminantes acumulados en los edificios, calles y aparcamientos (Grimm et al., 2008). Por lo tanto, el desarrollo de herramientas y métodos para apoyar la identificación, antes de que se produzca el evento, de áreas propensas a inundaciones se está volviendo cada vez más crucial para la planificación urbana de las sociedades futuras. Disminuir esa impermeabilidad de la cobertura del suelo urbano también disminuirá la escorrentía superficial y así evitará que las zonas bajas sufran estas inundaciones.

Las pérdidas económicas y humanas causadas por las inundaciones han sido especialmente graves durante los últimos años. Siguiendo las tendencias observadas durante las últimas dos décadas, los eventos de inundaciones en 2022 fueron un 4% más recurrentes, un 34% más mortales (7954 personas) y causaron un 8% más de pérdidas económicas que alcanzaron el valor de \$4490 millones en todo el mundo que la media entre 2002 y 2021 (CRED, 2023). Ejemplo de lo descrito anteriormente lo encontramos en Lagos (Nigeria), donde las inundaciones urbanas de julio de 2011 afectaron a más de 5000 personas con cerca de 25 muertos y pérdidas económicas que alcanzaron los 320 millones de dólares (Chimnonyerem et al., 2016). Otro ejemplo reciente es la destrucción de humedales en la periferia de Delhi (India), debido a la expansión urbana descontrolada que ha creado también un escenario ideal para que se produzcan inundaciones urbanas con las crecidas del río Yamuna debidas a las lluvias monzónicas en la región (India Today News, 2023). Como consecuencia, en julio de 2023 se registró la mayor crecida del río hasta la fecha. Esta inundación obligó a evacuar a 25400 personas y costó la vida de 3 niños. Además, tres de las plantas de tratamiento de aguas se vieron obligadas a cerrar, poniendo en peligro el suministro del agua potable durante días en la capital (HindustanTimes, 2023; Times of India, 2023).

Otro caso se ha vivido en España el 6 de julio de 2023 en la ciudad de Zaragoza, donde se ha producido una fuerte precipitación de 54,2 litros por metro cuadrado en menos de una hora y con picos de 10 minutos equivalentes a 166 litros por metro cuadrado a la hora (Sorribes, 2023). Este evento ha colapsado las vías de comunicación, producido cortes de electricidad y obligado a los servicios de emergencias a hacer varios rescates en los que no se han tenido que lamentar pérdidas humanas. La solución para este tipo de inundaciones urbanas pasa por una mejor planificación urbanística, protegiendo las áreas de inundación naturales y mejorando las infraestructuras de la ciudad para que permitan la infiltración del agua o su almacenamiento. Así, se evita urbanizar zonas con peligro de inundación, se aumenta el tiempo de retención del agua en origen y existe más tiempo para su gestión aguas abajo.

1.3.2 Efecto isla de calor urbano

El efecto UHI es un problema que afecta tanto desde el punto de vista medioambiental como de salud para los habitantes de las ciudades. Existe un consenso claro en la definición del efecto UHI, entendiendo este efecto como el desarrollo de temperaturas más altas en el interior de las ciudades en comparación con el área que las rodea (Mohajerani et al., 2017; Nakayama & Fujita, 2010; M. Santamouris, 2013). Existen estudios con evidencias de este efecto desde hace más de 180 años (Yang & Chen, 2016), pero fue Oke en 1982 el que inició el estudio del efecto UHI de una manera más profunda (Oke, 1982).

El calor procedente de la radiación solar y el calor antropogénico liberado por vehículos, centrales eléctricas, aparatos de aire acondicionado y otras fuentes de calor es almacenado por los materiales artificiales usados masivamente en las infraestructuras urbanas. Combinado con la falta de refrigeración debido a la rugosidad morfológica de la ciudad y la falta de vegetación que realice una liberación del calor a través de la evapotranspiración, produce que las temperaturas en la ciudad sean más altas que en las zonas periféricas formando una isla de temperaturas más altas de día, y sobre todo de noche (Kunapo et al., 2018; Oke, 1982; Rizwan et al., 2008). Los estudios iniciales sobre el efecto UHI indicaban que se incrementaba entre 2 y 8°C la temperatura del aire en las

ciudades, pero nuevos estudios corrigen al alza este mínimo y máximo hasta 5 y 15°C, respectivamente (Mattheos Santamouris & Kolokotsa, 2013).

Como ya se ha mencionado, el efecto UHI es provocado por la transformación del entorno natural, reduciendo el área cubierta por ecosistema natural, aumentando la cobertura con superficies con baja capacidad de reflectancia solar y alta inercia térmica e incrementando la producción de calor antropogénico (Matsler et al., 2021). Este efecto puede variar de forma temporal en una misma zona según la estacionalidad, las condiciones climáticas, e incluso de forma diaria. Por la noche, la cobertura terrestre influye significativamente en la temperatura del aire (Mattheos Santamouris & Kolokotsa, 2013). También puede variar espacialmente debido a la diferente topografía y orientación del área urbana, importante en la formación y amplificación de este efecto (Debbage & Shepherd, 2015).

Las consecuencias de este problema ambiental son menos perceptibles para el público general por no poder ilustrarse con imágenes tan impactantes como una inundación. No obstante, se ha observado que la mortalidad puede aumentar hasta un 52% debido al efecto UHI durante un episodio de ola de calor (Heaviside et al., 2016). Por otro lado, también puede causar problemas de salud no mortales como deshidratación intravascular o hipertermia que pueden derivar en hipoglucemias, insuficiencias renales, disfunciones neurológicas y cognitivas, etc. (Singh et al., 2020). Un estudio reciente ha estimado unas 61000 muertes relacionadas con el calor en el verano de 2022, el segundo más caluroso registrado en Europa (Ballester et al., 2023). Además de este perjuicio para la salud humana, se encuentran otros problemas ambientales asociados al efecto UHI. El aumento de las temperaturas aumenta el uso de energía para aclimatar espacios interiores, de tal manera que un aumento de 1°C incrementa la demanda de electricidad entre un 2 y un 4% (Akbari et al., 2001). También la degradación de la calidad del aire se ve afectada por este incremento de temperatura, como, por ejemplo, con producción de ozono troposférico (Cardelino & Chameides, 1990; Grimmond, 2007). Un estudio reciente apunta a que Madrid es la ciudad que más diferencia de temperatura tiene respecto a sus alrededores, por encima de urbes más grandes desde el punto de vista poblacional y espacial como pueden ser Bombay, Nueva York o Los Angeles (Arup, 2023).

1.3.3 Vulnerabilidad urbana

Para una comprensión completa del riesgo, es necesario considerar tanto la peligrosidad como la vulnerabilidad como componentes interrelacionados (Wisner et al., 2004). El estudio de la peligrosidad se enfoca en evaluar los peligros ambientales como las inundaciones y el efecto UHI, que pueden afectar a las áreas urbanas. Por otro lado, el análisis de la vulnerabilidad se centra en comprender cómo los elementos de una ciudad pueden influir en su capacidad para resistir, adaptarse y recuperarse de estos peligros (Adger, 2006). La vulnerabilidad urbana ante los peligros ambientales es un tema de suma importancia en el contexto de la planificación y gestión de las ciudades, ya que revela las condiciones y los factores que hacen que un grupo de población sea más propenso a sufrir daños o experimentar impactos significativos debido a un evento. Al combinar la peligrosidad y la vulnerabilidad, se facilita la identificación de las áreas de riesgo, lo cual es fundamental para la toma de decisiones y el establecimiento de medidas que aborden los problemas ambientales y promuevan la resiliencia urbana.

Existen diferentes aspectos de esta vulnerabilidad a tener en cuenta dependiendo de cual sea el objetivo del estudio (Karmakar et al., 2022). La distribución espacial de las personas en la ciudad y sus características demográficas (densidad, edad, idioma, tamaño del núcleo familiar...) o socioeconómicas (educación, ingresos, estado civil, acceso a la vivienda...), así como las infraestructuras de servicios básicos (salud, educación, administración pública...) pueden amplificar la vulnerabilidad de las personas y de las zonas de una ciudad ante un peligro (Blaikie et al., 2014). Por ello es necesario el estudio de la heterogeneidad espacial de diferentes factores para establecer relaciones entre ellos y localizar las zonas críticas de la ciudad susceptibles de ser más afectadas y con menor capacidad de recuperación por un peligro ambiental. Esta vulnerabilidad, combinada junto con el peligro en cuestión, facilita la localización de las zonas en riesgo y ayuda a la toma de decisión a la hora de establecer medidas de adaptación que promuevan la resiliencia urbana.

1.4 Adaptación urbana

La creciente urgencia sobre la necesidad de mitigar las consecuencias del cambio climático y de proteger y preservar los ecosistemas naturales ha llevado a reconocer la importancia de implementar soluciones en el entorno urbano. La adaptación urbana implica la adopción de medidas y estrategias que permitan a las ciudades enfrentar y superar los desafíos ambientales, al mismo tiempo que promueven la sostenibilidad (IPCC, 2022a).

1.4.1 Soluciones basadas en la naturaleza (NBS)

La presión que ejercen la urbanización, el cambio climático y el crecimiento de la población han obligado a desarrollar soluciones técnicas como las NBS. Las NBS se basan en trabajar en sinergia con los procesos naturales e integrar elementos de la naturaleza como parte de la infraestructura urbana. Gracias a ello, pueden contribuir significativamente a la adaptación de núcleos urbanos a los cambios ambientales derivados del cambio climático y solventar los problemas asociados a la transformación antropogénica de la superficie terrestre. El desarrollo de estas infraestructuras multifuncionales surge de una aproximación interdisciplinar a los problemas mencionados, en la que colaboran ingenieros, científicos, economistas, políticos y más agentes que puedan aportar valor, buscando transformar las ciudades y que aumente su resiliencia frente a los cambios ambientales. Estas infraestructuras combinan elementos naturales como masas de agua o vegetación con elementos artificiales para crear una red estratégicamente planificada de áreas naturales y seminaturales.

La aparición de estas técnicas paralelamente en diferentes partes del mundo ha creado una atomización en la terminología a su alrededor. Así, surgieron diferentes nomenclaturas que engloban estas corrientes de utilización de la naturaleza. Términos como desarrollos de bajo impacto (LID) (Z. Zhu et al., 2019), mejores prácticas de gestión (BMP) (Urban Water Infrastructure Management Committee, 2001), infraestructuras verdes (GI) (Fletcher et al., 2015), infraestructuras azules y verdes (BGI) (Brears, 2018), diseño urbano sensible al agua (WSUD) (Kuller et al., 2017), ciudades esponja (Li et al., 2017), sistemas urbanos de drenaje sostenible (SUDS) (Ballard et al., 2015) o técnicas de drenaje urbano sostenible (TEDUS) (Castro-Fresno et al., 2013), entre otros, han sido utilizados en diferentes zonas geográficas y han evolucionado paralelamente a lo largo de los años. Actualmente, el término más utilizado entre la comunidad científica en Asia y Europa es NBS (Eggermont et al., 2015) y se muestra una tendencia hacia la convergencia en torno a esta denominación en todo el mundo (Matsler et al., 2021).

No obstante, existen ciertas fricciones entre algunos de los términos debido a algún matiz discrepante en su visión o filosofía, lo que dificulta su confluencia bajo el mismo paraguas terminológico (Rodríguez-Rojas & Grindlay Moreno, 2022). Las BMP, por su parte, reducen los contaminantes para proteger la calidad del agua y promover la conservación del suelo en entornos urbanos y periurbanos. Las GI y las NBS son denominaciones más generales que se refieren a la incorporación de espacios verdes en entornos urbanos para mejorar la calidad ambiental. WSUD, por el contrario, es un término que se refiere a la integración del ciclo urbano del agua en la planificación de la ciudad con el fin de reducir el impacto hidrológico del desarrollo urbano y aumentar la resiliencia al cambio climático.

En la década de 1960 este tipo de soluciones eran exclusivamente utilizadas para la mitigación de inundaciones, pero, con el paso del tiempo, se han ido añadiendo nuevas funciones (Fletcher et al., 2015) como el control de la contaminación difusa del agua en los 90 (Arnold Jr & Gibbons, 1996). Actualmente, estas funciones complementarias se denominan servicios ecosistémicos y se definen como la capacidad de los procesos y componentes naturales para proporcionar bienes y servicios que satisfagan las necesidades humanas directa o indirectamente (de Groot et al., 2002). Estos servicios ecosistémicos pueden ser de aprovisionamiento de los recursos necesarios para los procesos ecológicos, de regulación para asegurar la habitabilidad del entorno ante la variabilidad de los ciclos naturales, de conservación de la diversidad genética proveyendo de hábitat de refugio y reproducción para seres vivos, y culturales como la función de mantenimiento de la salud humana, dando oportunidad al desarrollo cognitivo, el ocio y la estética (Reid et al., 2005). Estas funciones mencionadas varían según la categorización usada, pero en esencia engloban las necesidades para el desarrollo sostenible y saludable de los seres humanos y favorecen el desempeño normal del ecosistema anteriormente asentado en la zona.

Existe una gran variedad de guías o catálogos que detallan las NBS en diferentes partes del mundo como Reino Unido (Ballard et al., 2015), Australia (Victoria State Government, 2017), Singapur (Singapore. Public Utilities Board, 2014) o Estados Unidos (Mean & Efficiencies, 2006). En estas guías se puede obtener información sobre categorías de las NBS, aspectos técnicos de la instalación de las soluciones, así como los servicios ecosistémicos que puedan aportar. Por ejemplo, unas de las categorizaciones de NBS más actuales son las propuestas por los catálogos de los proyectos *Urban Nature Labs* (UNaLab) (Eisenberg & Polcher, 2020), o *URBAN GreenUP* (Urban GreenUP, 2018). Este último proyecto propone una clasificación de 45 NBS diferentes en 14 grupos. En la tabla 1 se exponen las diferentes categorías y una breve descripción de las mismas.

Cada una de las infraestructuras de estos grupos tienen consideraciones de diseño que las hace tener sinergias con diferentes superficies de uso de suelo e incluso se pueden realizar combinaciones de varias de las infraestructuras para realizar diferentes funcionalidades en la misma área. Esta complejidad de funciones, sinergias y consideraciones técnicas hace que se necesite manejar una gran cantidad de información para optimizar su implementación. Por ejemplo, la localización de los riesgos a mitigar, los espacios disponibles, las características técnicas de cada tipo de NBS y el diseño de la combinación estratégica.

Tabla 1. Categorización de NBS propuesta por el proyecto URBAN GreenUP (Urban GreenUP, 2018)

<i>AGRUPACIÓN DE NBS</i>	<i>DESCRIPCIÓN</i>
<i>Green Route (Ruta Verde)</i>	Se refiere a NBS que se utilizan para crear corredores verdes en áreas urbanas, como pasarelas, senderos o vías con vegetación.
<i>Intervenciones Arbóreas</i>	Son NBS que implican la plantación y mantenimiento de árboles en entornos urbanos para proporcionar sombra, mejorar la calidad del aire y propósitos estéticos.
<i>Captura de Carbono</i>	Esta categoría de NBS se enfoca en la captura y almacenamiento de carbono a través de la vegetación urbana, como árboles y arbustos.
<i>Sistemas Urbanos de Drenaje Sostenible (SUDS)</i>	Son sistemas diseñados para gestionar eficazmente el agua de lluvia en áreas urbanas, previniendo inundaciones y mejorando la calidad del agua. Pueden incluir características como techos verdes y áreas permeables.
<i>Acciones contra Inundaciones</i>	Se refiere a las estrategias y medidas para prevenir o mitigar inundaciones en entornos urbanos, que pueden incluir diques, canales y áreas de almacenamiento temporal de agua.
<i>Tratamiento de Agua</i>	Estas NBS se utilizan para purificar y tratar el agua en áreas urbanas, a menudo mediante la restauración de humedales o la creación de zonas de tratamiento natural.
<i>Pavimentos Verdes</i>	Implican el uso de pavimentos permeables o pavimentos con vegetación para reducir la escorrentía de agua y mejorar la calidad del agua.
<i>Suelos Inteligentes</i>	Son técnicas que mejoran la calidad del suelo urbano para promover la infiltración del agua y el crecimiento de la vegetación.
<i>Polinizadores</i>	Estas NBS se centran en la creación de hábitats para polinizadores, como abejas y mariposas, para promover la biodiversidad y la polinización de plantas.
<i>Infraestructura Verde Vertical</i>	Incluye soluciones que incorporan vegetación en estructuras verticales, como paredes verdes o jardines verticales.
<i>Infraestructura Verde Horizontal</i>	Se refiere a soluciones que utilizan áreas verdes en superficies horizontales, como parques y espacios públicos.
<i>Filtración de Contaminantes</i>	Estas NBS se diseñan para eliminar contaminantes del agua o el aire en áreas urbanas, a menudo utilizando vegetación específica.
<i>Áreas de Descanso</i>	Son espacios públicos diseñados para el descanso y la relajación de los residentes urbanos, que a menudo incorporan vegetación y áreas sombreadas.
<i>Agricultura Urbana</i>	Incluye prácticas agrícolas en entornos urbanos, como huertos comunitarios y cultivos en azoteas.

1.4.2 Importancia de la toma de decisiones

La toma de decisiones desempeña un papel fundamental en la implementación de NBS para mitigar los riesgos ambientales urbanos. La efectividad de estas soluciones en términos de resiliencia y sostenibilidad depende en gran medida de las decisiones estratégicas y políticas que se tomen en el proceso de planificación y gestión urbana. Estas decisiones han de ser informadas y basadas en evidencia científica para identificar los riesgos ambientales específicos que enfrenta una ciudad y determinar qué NBS son más adecuadas para abordarlos con los recursos disponibles. Esto implica la evaluación de datos sobre el estado de los ecosistemas locales, la recopilación y análisis de los peligros ambientales, la vulnerabilidad de los elementos de la ciudad y la comprensión de cómo las NBS pueden interactuar con otros aspectos urbanos como topografía, usos del suelo, nivel freático o área disponible.

Las condiciones ambientales y las necesidades de las ciudades pueden cambiar con el tiempo, por lo que es importante tomar decisiones que sean flexibles y permitan la adaptación a nuevos desafíos y circunstancias. Esto implica la integración de la gestión del riesgo y la planificación urbana en un marco a largo plazo, considerando escenarios futuros del cambio climático y promoviendo la innovación en la implementación de NBS. También, la participación y colaboración de todos los actores es esencial para garantizar que las NBS sean socialmente justas y culturalmente apropiadas. Los conocimientos científicos, la comunidad local, organizaciones no gubernamentales y administración pública deben implicarse en el proceso de toma de decisiones, permitiendo tener en cuenta diferentes perspectivas, conocimientos locales y necesidades específicas. Esto no solo aumenta la aceptación y el apoyo de las soluciones, sino que también contribuye a la equidad de las medidas de mitigación de riesgos.

1.5 Estructura del documento

Este primer capítulo introductorio contextualiza la tesis doctoral dentro de la problemática del cambio climático y el crecimiento de población urbana (apartados 1.1 y 1.2 respectivamente). Seguidamente se proporciona una visión general y se exploran las materias clave relacionadas con los problemas ambientales urbanos como son los peligros ambientales y la vulnerabilidad urbana (apartado 1.3). A modo de hilo conductor de esta tesis, se han abordado los aspectos fundamentales de la adaptación urbana mediante soluciones basadas en la naturaleza (apartado 1.4.1) y la toma de decisiones informadas (apartado 1.4.2) en el contexto de los riesgos urbanos. En los siguientes apartados del presente capítulo se describe asimismo el contexto de investigación en el que se ha desarrollado este trabajo, así como los objetivos que se pretenden alcanzar y las hipótesis de partida.

Cada capítulo siguiente se adentrará en estos temas de manera más detallada y se presentarán los resultados de la investigación con una estructura de 3 bloques. En el capítulo 2, se examinará el estado del arte en relación con los modelos de inundación pluvial urbana (bloque 1) (apartado 2.1), la predicción del efecto isla de calor urbano (bloque 2) (apartado 2.2) y los métodos de índices de vulnerabilidad urbana (bloque 3) (apartado 2.3). Se incluye además un cuarto bloque adicional en este capítulo en donde se describen los diferentes recursos informáticos de los que se dispone dentro de este ámbito de investigación (apartado 2.4). A través de estas investigaciones, en el capítulo 3 se busca contribuir al conocimiento en estas áreas en dos casos de estudio (apartado 3.1). Para ello, el documento continúa con la metodología diseñada para localizar estos dos problemas ambientales (apartados 3.2 y 3.3) además de un método para evaluar la vulnerabilidad de las diferentes zonas de la ciudad (apartado 3.4).

La presentación de resultados, producto de la aplicación de los métodos descritos, y su discusión, se encuentran en el cuerpo del capítulo 4. Así, en la estructura de cada apartado de este capítulo podemos encontrar primero, los resultados y, seguidamente, la discusión de estos. Cerrando esta tesis se encuentra el capítulo 5 que versa sobre las conclusiones, tanto generales como específicas (apartados 5.1 y 5.2 respectivamente) de cada uno de los 3 bloques definidos y unas recomendaciones para futuras investigaciones (apartado 5.3).

1.6 Marco de la tesis

La presente tesis doctoral se supedita al Grupo de Investigación de Tecnología de la Construcción (GITECO) y a su línea de investigación creada en 2003 “Construcción de Sistemas Urbanos de Drenaje Sostenible”. Durante estos 20 años, esta línea de investigación ha estado operativa ininterrumpidamente gracias a 8 proyectos de investigación de ámbito nacional e internacional. De entre ellos, el proyecto “Rehabilitación Hidrológica de Infraestructuras Viales Urbanas (RHIVU)”, con referencia BIA2012-32463, fue el punto de partida en la línea de investigación de la materia de localización de zonas susceptibles y selección de soluciones en el ámbito de la gestión ambiental urbana. A fecha de escritura de esta tesis, siguen 2 proyectos en activo:

- D4RUNOFF: Data driven implementation of hybrid nature-based solutions for preventing and managing diffuse pollution from urban water runoff (ref: HORIZON-CL6-2021-ZEROPOLLUTION-01).
- SUDSlong: Mejora de superficies permeables y juegos serios para la toma de decisión sobre drenaje urbano. (ref: PID2021-122946OB-C33)

Al amparo de esta línea de investigación, se han publicado más de 30 artículos indexados en el *Journal Citations Report* (JCR) y se han realizado más de 40 ponencias en congresos a lo largo del mundo. También se han defendido 9 tesis doctorales, destacando las más recientes:

- “Modelado hidrológico de cuencas urbanas bajo cambio climático para diseñar un sistema espacial de apoyo a la decisión que mitigue inundaciones mediante pavimentos permeables cumpliendo los principios de sostenibilidad”. Dr. Daniel Jato Espino (2016).
- “Investigación y desarrollo de firmes permeables y sistemas lineales de drenaje orientados a la mejora de la gestión de la escorrentía superficial urbana”. Dr. Valerio Carlos Alessio Andrés Valeri (2017).
- “Estudio de superficies urbanas multifuncionales de hormigón poroso”. Dr. Eduardo Javier Elizondo Martínez (2020).
- “Estudio para la mejora de mezclas asfálticas porosas con una selección multicriterio de aditivos y un nuevo betún modificado con polímeros”. Dra. Anik Gupta (2022).

Como continuación a todo este trabajo, se presenta esta tesis enmarcada en el subproyecto “Caracterización mecánica de secciones filtrantes y estrategias de localización inteligente para un drenaje urbano sostenible a escala ciudad (MELODRAIN)”, con referencia “RTI2018-094217-B-C32”, parte del proyecto “Caracterización holística de secciones filtrantes para una gestión inteligente y sostenible de sistemas urbanos de drenaje a escala ciudad (HOFIDRAIN)”. Este proyecto, sexto del Plan Nacional asignado a la línea de investigación, adicionalmente está asociado a la concesión de una ayuda para la formación de personal investigador (FPI) del Ministerio Español de Ciencia e Innovación con referencia “PRE2019-089450”, conseguida mediante concurso público por el autor de esta tesis. Gracias a esta ayuda, se han podido financiar los estudios de doctorado del autor, la asistencia a 2 congresos internacionales y la realización de una estancia de investigación de 4 meses de duración en el *Abteilung Siedlungswasserwirtschaft* (Departamento de Gestión del Agua Urbana) del *Eawag: Wasserforschungsinstitut* (Instituto de investigación sobre los recursos hídricos) de Suiza bajo la supervisión del Dr. Peter Bach.

1.7 Objetivos e hipótesis

El auge de la conciencia social hacia la necesidad de abordar problemas ambientales manteniendo un sistema sostenible e igualitario ha evolucionado en el desarrollo de una hoja de ruta para adaptarse y mitigar los riesgos derivados del cambio global. En 2015, este movimiento se materializó en la aprobación de la Agenda 2030 por parte de las Naciones Unidas, en la que se encuentran 17 Objetivos de Desarrollo Sostenible (ODS) (UN-DESA, 2020). Como contribución al propósito de la Agenda 2030, esta tesis está orientada principalmente a dar soporte a la adaptación de los entornos urbanos mediante la instalación de NBS para conseguir estos ODS. La integración de NBS en la planificación y gestión urbana puede ofrecer múltiples beneficios, como la reducción del riesgo de inundaciones, la mejora de la calidad del aire, la mitigación del efecto UHI y el fomento de la biodiversidad en entornos urbanizados sin comprometer la sostenibilidad del medio. Así, las NBS repercuten en la consecución del ODS número 11 (Ciudades y comunidades sostenibles) (UN-DESA, 2020). No obstante, las propuestas de mitigación de estos problemas ambientales urbanos con NBS también ayudan a la consecución de otros ODS (números 3, 6, 7, 8, 9, 10, 13, 14, 15) relacionados con la salud humana, la calidad del agua, la vida subacuática, la captura de carbono y la renaturalización de los ecosistemas terrestres.

Por lo tanto, el objetivo principal de esta tesis doctoral es ayudar a planificadores urbanos y autoridades locales a abordar los desafíos ambientales urbanos de manera eficiente promoviendo, paralelamente, la mejora de la sostenibilidad y la resiliencia de las áreas urbanas, cumpliendo así los compromisos alcanzados para abordar esta demanda social. Este objetivo se lleva a cabo mediante la propuesta de metodologías y herramientas que asistan en la detección, análisis y evaluación de problemas ambientales urbanos, con especial énfasis en la localización de zonas susceptibles de sufrir inundaciones, el estudio del efecto UHI y el análisis de la vulnerabilidad urbana frente a los peligros derivados de estos problemas ambientales. Los objetivos específicos que se derivan de este propósito general se detallan a continuación:

- Facilitar la localización de zonas urbanas bajo peligro de inundación mediante la automatización del cálculo de escorrentía superficial en un entorno de Sistemas de Información Geográfica (SIG).
- Cuantificar la mejora en la resiliencia al peligro ante inundaciones urbanas para diferentes escenarios que integran NBS.
- Establecer un método que permita el modelado del efecto UHI utilizando algoritmos de aprendizaje automático a partir de un conjunto de variables espaciales urbanas.
- Detectar las principales características morfológicas de la ciudad que contribuyen a la formación del efecto UHI.
- Identificar y clasificar los factores demográficos, socioeconómicos y de infraestructuras que influyen en la vulnerabilidad urbana ante peligros medioambientales.
- Localizar desequilibrios espaciales significativos de las variables que influyen en la vulnerabilidad urbana.

Para respaldar los objetivos específicos mencionados anteriormente, esta investigación doctoral se basa en una serie de hipótesis que se centran en la interacción entre los problemas ambientales urbanos, la vulnerabilidad y la planificación de medidas de mitigación. Las hipótesis que proporcionan un marco para orientar la investigación son las siguientes:

- El método de cálculo racional de la escorrentía, válido para pequeñas cuencas de drenaje, es adecuado para identificar las zonas de riesgo de inundación en el medio urbano.
- Es factible crear escenarios virtuales de implementación de NBS en entornos SIG para cuantificar su efecto positivo en la mitigación de inundaciones urbanas.
- Es posible generar un modelo de predicción del efecto UHI a partir de un conjunto de variables que definen las características morfológicas urbanas.
- Los algoritmos de aprendizaje pueden identificar las características morfológicas principales de la ciudad que afectan a la formación del efecto UHI.
- La vulnerabilidad urbana ante peligros ambientales se puede calcular mediante la consideración de factores demográficos, socioeconómicos y de infraestructura.
- El análisis de componentes principales (PCA) es un enfoque eficaz para identificar las variables que presentan un mayor desequilibrio espacial y que influyen en la vulnerabilidad.

Estas hipótesis proporcionan una estructura para la investigación, que se centrará en la recopilación de datos, el análisis estadístico y la modelización numérica y espacial para plantear y cuestionar estas hipótesis, generando conclusiones que puedan guiar la toma de decisiones y las políticas urbanas orientadas a la sostenibilidad y la mitigación de riesgos ambientales en entornos urbanos.

2 Estado del Arte

En este capítulo se exponen los recursos informáticos aplicados que facilitan el estudio de los peligros y vulnerabilidades urbanas citadas en el capítulo 1. Además, se profundiza en los avances y tendencias de las metodologías y técnicas de modelado más comunes en cada materia, así como en una discusión de su estado actual en un corolario.

2.1 Modelos de inundación pluvial urbanos

Los modelos de inundaciones están típicamente involucrados en los análisis cuantitativos del riesgo de inundaciones urbanas y han sido ampliamente estudiados en las últimas décadas (Cea & Costabile, 2022). El estudio, análisis, observación y la consiguiente investigación de inundaciones puede hacerse más eficaz mediante el empleo de modelos de inundaciones urbanas. Estos modelos son útiles a la hora de analizar, simular y gestionar aportaciones de agua por lluvias, de manera que la urbanización se pueda diseñar con una perspectiva dirigida hacia el desarrollo sostenible y resiliente frente a las inundaciones. La accesibilidad de diferentes grupos de población a los resultados de estos modelos puede utilizarse para la planificación, educación y la concienciación, y así fomentar el uso de técnicas de mitigación de inundaciones como las soluciones basadas en la naturaleza (NBS) (Bodoque et al., 2016; Botzen et al., 2009). El mayor problema que presenta su uso es conseguir transformar los procesos de escorrentía en modelos informáticos que permitan evaluar su comportamiento asemejándose lo más posible a la realidad con la menor cantidad de recursos necesarios para su desempeño. Por ello, existen diferentes aproximaciones a la hora de elaborar un modelo de inundación (Elliott & Trowsdale, 2007).

Los modelos numéricos de inundación urbana se centran en aspectos como el cálculo de la producción, dirección y acumulación de escorrentía en diferentes superficies urbanas, y la interacción hidrodinámica del agua con la superficie, el subsuelo y la red de saneamiento (P. Luo et al., 2022). Cuantos más aspectos sean considerados, más datos son requeridos como entrada para determinar las condiciones de contorno, mayor es la complejidad del algoritmo de cálculo y más potencia o tiempo de cómputo será necesario (Qi et al., 2021). Los diferentes modelos de inundaciones creados por la comunidad científica han sido recopilados y analizados en diferentes revisiones bibliográficas (Azizi et al., 2022; Bulti & Abebe, 2020; K. Guo et al., 2021; P. Luo et al., 2022; Nkwunonwo et al., 2020; Qi et al., 2021; Salvadore et al., 2015; Teng et al., 2017). K. Guo et al. (2021) realiza una clasificación en 4 grupos: modelos de red de drenaje, modelos de aguas poco profundas, aproximación hidrogeomorfológica y otros métodos relacionados con inteligencia artificial. Qi et al. (2021), en su revisión de los modelos de inundaciones urbanas, utiliza una clasificación totalmente diferente dentro de tres grandes grupos: modelos simplificados, modelos hidrológicos y modelos hidrodinámicos. Gayathri (2015) propuso una clasificación para los modelos hidrológicos de tres grupos: empíricos, conceptuales y basados en física. Además, identifica otras características dicotómicas que diferencian a los modelos de manera general, como el tipo de parametrización utilizada (agrupadas o distribuidas), la dimensión temporal (estáticos o dinámicos) y tipo de modelo matemático (estocástico o determinístico). Bulti y Abebe (Bulti & Abebe, 2020) proponen una clasificación para los modelos hidrodinámicos en relación a la dimensionalidad de los modelos. En esta clasificación se puede destacar el grupo de método de propagación rápida de inundaciones, similares a los modelos de red de drenaje que a su vez estarían próximos conceptualmente a los modelos hidrológicos empíricos y conceptuales. La figura 1 esquematiza y agrupa las diferentes clasificaciones propuestas por estos autores en función de las características comunes de los modelos.

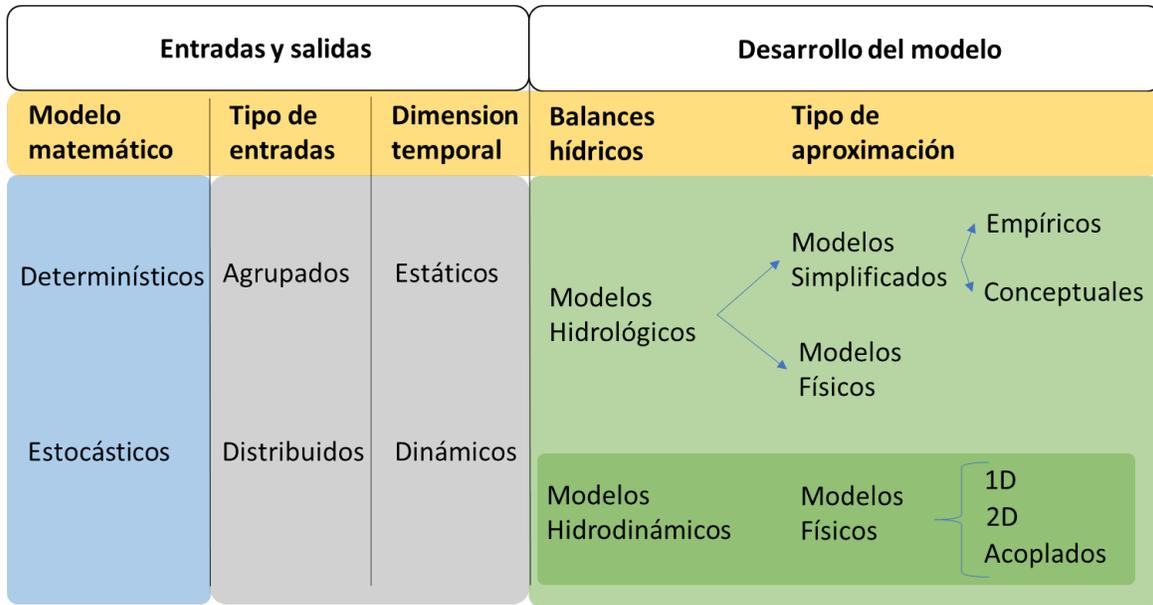


Figura 1. Esquema de clasificación de metodologías de modelización de inundaciones.

Desde el punto de vista del desarrollo del modelo matemático utilizado existen los denominados modelos determinísticos, con solo una solución para unos mismos datos de entrada, o estocásticos o basados en criterios probabilísticos, dando como resultado varias soluciones para unos mismos datos de entrada. En los modelos agrupados se considera toda la cuenca como una sola unidad en la que se ignora la variabilidad espacial. En este enfoque, se intenta relacionar los datos de entrada, principalmente las precipitaciones, con las salidas del sistema (caudal), sin tener en cuenta los procesos espaciales, patrones y organización de las características que rigen esos procesos dentro de la cuenca (Smith et al., 2004). Por otro lado, un modelo distribuido es aquel que tiene en cuenta estas variaciones espaciales de los parámetros, lo que implica una caracterización explícita de las propiedades dentro de la cuenca (Moradkhani & Sorooshian, 2008). También dependiendo del tipo de salida pueden clasificarse como estáticos, donde solo se produce una única salida para un tiempo determinado (máximo de escorrentía o resultado final de la zona inundada), o dinámicos, los cuales dan una salida continua en el tiempo (Qi et al., 2021).

Los denominados modelos simplificados o cero dimensiones (0D) aplican métodos no basados en física que necesitan principalmente datos obtenidos por mediciones topográficas. A su vez se pueden subdividir en empíricos y conceptuales, diferenciando los modelos simplificados que necesitan datos medidos en campo y datos calibrados con un ajuste de curvas o ecuaciones semiempíricas, respectivamente (Gayathri et al., 2015). Los más avanzados como el *Stanford Watershed Model* (SWM) pueden usar ecuaciones con más de 20 parámetros considerando procesos hidrológicos como la infiltración (Donigian & Imhoff, 2006). Estos modelos realizan una estimación de la profundidad de las inundaciones sin tener en cuenta la hidrodinámica, formas complejas de la topografía como edificios u otros procesos como la posible retención o infiltración de la escorrentía (Teng et al., 2015). El método de propagación rápida de inundaciones (RFSM) divide la llanura aluvial en áreas elementales denominadas zonas de impacto, que representan depresiones topográficas, e implementa un proceso de llenado y vertido para determinar qué píxeles se considerarían inundados (Lhomme et al., 2008). Otro de los más utilizados es el método

de superficie planar, en el que una superficie plana se superpone al modelo digital de elevación y donde todas las áreas bajo esta superficie se consideran inundadas (Teng et al., 2017). Este método puede ser mejorado con algoritmos de jerarquía u orden de flujo o de filtrado de sumideros como se realiza en el modelo HAND (Nobre et al., 2016). Estos métodos han demostrado ser adecuados cuando se requieren múltiples escenarios de inundaciones, debido a su tiempo de cálculo muy corto y a su aplicabilidad a grandes escalas geográficas (McGrath et al., 2018).

Los modelos hidrológicos están basados en métodos para simular los aspectos del ciclo hidrológico en relación a la producción de escorrentía y dirección de flujo (Teng et al., 2015). Tienen la capacidad de calcular el flujo de agua que entra en el sistema, con el propósito de ofrecer soluciones para la mayoría de las necesidades prácticas en cuanto a diseño e implementación. Se centran principalmente en deducir las pérdidas de la entrada de agua pluvial precipitada en la retención de agua por parte de las plantas, cuerpos de agua, infraestructuras de captación (reservorios de agua o alcantarillado) y, principalmente, la infiltración para formar un balance neto calculando la escorrentía generada (P. Luo et al., 2022). Uno de los modelos hidrológicos más utilizado es el método del número de curva (CN) (Boughton, 1989), usado originalmente en cuencas rurales por el departamento del servicio de conservación del suelo agrícola de Estados Unidos (USDA SCS). Este modelo relaciona empíricamente la cantidad de lluvia con la cantidad de escorrentía obtenida en función de un factor en el que se tienen en cuenta propiedades y usos del suelo. Este método se extendió posteriormente al resto del mundo y está siendo utilizado también en ambientes urbanos (Eli & Lamont, 2010; He et al., 2020; X Meng et al., 2019; Tanaka et al., 2020). Otro modelo hidrológico ampliamente utilizado es el método racional (Eli & Lamont, 2010; He et al., 2020; X Meng et al., 2019; Tanaka et al., 2020), el cual está incluido en la Norma 5.2-IC de la Instrucción de carreteras, donde se recomienda su uso para cuencas de menos de 50 km² (BOE, 2016). Este método empírico se crea a partir de las observaciones de generación de escorrentía en diferentes superficies y consiste en la deducción del caudal máximo de la escorrentía de una cuenca para una precipitación de intensidad y duración determinadas (J. C. Y. Guo, 2001; Kabir et al., 2011; S. Wang & Wang, 2018). La ventaja de estos modelos hidrológicos radica en la accesibilidad de los datos de entrada necesarios y su rápido cálculo (Bulti & Abebe, 2020).

No obstante, los modelos hidrológicos ofrecen un resultado estático (escorrentía máxima o estado final de la inundación), y no pueden simular completamente todo el ciclo hidrológico, por lo que resulta inviable que proporcionen una descripción minuciosa de las grandes cuencas urbanas e, hidrodinámicamente, tampoco pueden realizar un seguimiento temporal de la escorrentía superficial en un punto determinado. Esto se debe a que las cuencas urbanas están alteradas con infraestructuras antropogénicas no contempladas en el modelo que modifican las propiedades hidrológicas del suelo. También, finalmente, son más limitados por no considerar el movimiento del agua de forma dinámica, sino únicamente mediante un balance de volumen (Qi et al., 2021).

Los modelos hidrodinámicos, además de los balances de materia de los modelos hidrológicos, incluyen otros aspectos dinámicos calculando el comportamiento del agua a través del área de estudio. Existen diferentes opciones para definir esta característica dinámica: la ecuación de Saint-Venant (Cunge et al., 1980), ecuación de Richards para la dinámica de infiltración (Richards, 1931), o el esquema de volumen finito tipo Godunov (Liang & Smith, 2015). Su dimensionalidad abarca modelos lineales de una dimensión (1D) del flujo superficial o del sistema de alcantarillado, donde se simplifica el sistema con una serie de nodos interconectados. Su complejidad se ve aumentada

con los modelos de dos dimensiones (2D), donde el esquema pasa a ser una malla ortogonal o triangular que representa una superficie donde la cantidad de precipitación y las características del suelo se suponen homogéneas en cada nodo. La combinación de modelos 2D de superficie con el modelo 1D de alcantarillado, donde la salida de un sistema es la entrada del otro (Bulti & Abebe, 2020), es una aproximación de modelado que representa con mayor profundidad el comportamiento del agua en las ciudades. A pesar de ello, presenta problemas de coste desde el punto de vista informático en términos de tiempo de ejecución y requisitos de datos de entrada.

2.2 Predicción del efecto isla de calor urbano

Como ya se ha comentado en el apartado 1.3.2, el efecto isla de calor urbano (UHI) es un problema con efectos de gran alcance tanto en la salud humana como en los ecosistemas. Para combatir sus efectos sobre los residentes urbanos y el medio ambiente, es crucial desarrollar medidas de mitigación eficaces. Para lograrlo, es necesario disponer de métodos precisos de estimación del efecto UHI. Estos diferentes métodos pueden estar basados en conceptos físicos o aproximaciones estadísticas (figura 2).

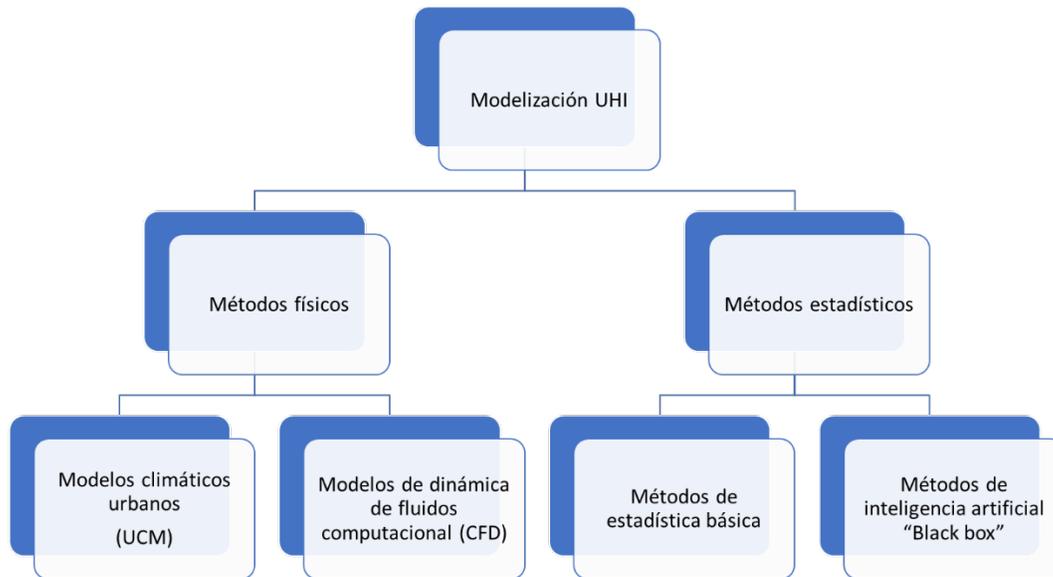


Figura 2. Esquema de las diferentes aproximaciones de predicción y análisis del efecto UHI

Algunos de estos modelos se rigen por conceptos termodinámicos como la ley de conservación de la energía y utilizan el balance de la energía entre la superficie y la atmósfera que se ve influido por flujos de calor (Baklanov et al., 2009). Estos modelos son conocidos como modelos climáticos urbanos (UCM), los cuales se aplican mediante una matriz o red de puntos espaciales que calculan temperatura y humedad. Además, pueden ser de una única capa, donde toda la topografía es considerada como una única superficie dentro del cañón urbano (entendiendo como cañón urbano el arquetipo espacial formado por el espacio entre edificios adyacentes (Oke, 2002), o de capas múltiples que son apiladas de manera vertical e interactúan unas con otras (Ryu et al., 2011). Estos modelos omiten la dinámica de los sistemas meteorológicos, como la circulación del aire, las corrientes oceánicas y los vientos. Uno de los más utilizados es el *Town Energy Balance* (TEB) (Masson, 2000), que utiliza una sola capa considerando en ella la geometría de la ciudad, la conducción térmica de carreteras, tejados y paredes y la evaporación o retención de agua. Similar al TEB es uno de los módulos utilizados en el modelo climático *Weather Research and Forecasting* (WRF) (Hiroyuki Kusaka et al., 2001), que combina una parametrización de los edificios multicapa (Lauzet et al., 2019). Por ejemplo, WRF fue utilizado para uno de los estudios que se han llevado a cabo en la ciudad de Roma para estudiar la mitigación del efecto UHI aumentando el albedo de las superficies (Morini et al., 2018).

Un avance en estos modelos basados en la física son los modelos incluyen la conservación de masa, temperatura y momento mediante modelos de dinámica de fluidos computacional (CFD). Estos modelos dan una mejor precisión de la distribución espacial del efecto UHI dentro de la ciudad, aunque con un costo computacional alto. Una de las herramientas más utilizadas para el análisis del efecto UHI basadas en CFD es ENVI-met (D. Liu et al., 2020), en la que se simulan interacciones de construcciones y vegetación con la atmósfera (Tsoka et al., 2018). Un ejemplo de utilización de esta herramienta es el estudio realizado para medir la disminución del efecto UHI con diferentes tipos de vegetación en el Cairo (Aboelata, 2020).

Todos estos modelos basados en física requieren de información detallada sobre materiales, geometrías y condiciones climáticas de contorno, por lo que es necesario una gran especialización para abarcar estos conocimientos, así como una gran potencia de cómputo (Pena Acosta et al., 2023). Esto crea una brecha en la falta de herramientas útiles para la toma de decisiones urbanas teniendo en cuenta el efecto UHI y dirigido a usuarios sin ese nivel de especialización. Por ello, se ha extendido el uso de métodos estadísticos convencionales que relacionan el efecto UHI con factores meteorológicos, ambientales y la morfología de la ciudad. Por ejemplo, la regresión lineal múltiple es uno de los métodos estadísticos más usados para cuantificar el impacto de diferentes alturas de edificios en la intensidad del efecto UHI (Equere et al., 2020) o la relación del efecto UHI con la contaminación en la ciudad de Bangalore (Menon et al., 2017). Otros métodos estadísticos usados son la regresión lineal bivariada, regresión de mínimos cuadrados ordinarios (OLS), correlación de Pearson, o el análisis de mezclas espectrales entre otros (S. W. Kim & Brown, 2021).

Estos métodos estadísticos tienen una precisión menor que los basados en física y necesitan de una variable dependiente con la que poder relacionar estos factores. El principal dato necesario para poder estudiar el comportamiento del efecto UHI desde la observación es la medición de la variación espacial de la temperatura dentro de la ciudad. Para poder discutir cómo obtener estas mediciones se ha de tener en cuenta el tipo de efecto UHI a analizar según la escala. Los estudios del análisis del efecto UHI se pueden agrupar en dos amplias categorías: el efecto UHI atmosférico y el efecto UHI superficial (SUHI) (Zhou et al., 2019). El atmosférico tiene dos niveles o capas, la *urban canopy layer* (UCL) y la *urban boundary layer* (UBL) (figura 3). La UCL comprende la altura hasta la superficie a los tejados de los edificios, mientras que la UBL se define como la capa de la atmósfera donde la orografía tiene efecto sobre sus características, pudiendo comprender entre los 200 metros y 2 kilómetros de altura. La estimación de la distribución espacial del efecto UHI en la atmósfera se realiza mediante estaciones meteorológicas (fijas o móviles) y sondas en altura. Cada medición está muy limitada debido a la pequeña superficie cubierta por la zona de influencia de la estación o sonda (Bahi et al., 2020). Este tipo de medición se utiliza para comparar la temperatura entre la zona periurbana y ciudad (mesoescala), pero no es asumible operacional y económicamente cuando se intenta relacionar las diferentes características dentro de la ciudad (microescala), ya que sería necesario instalar y mantener una red de estaciones meteorológicas en cada ciudad.

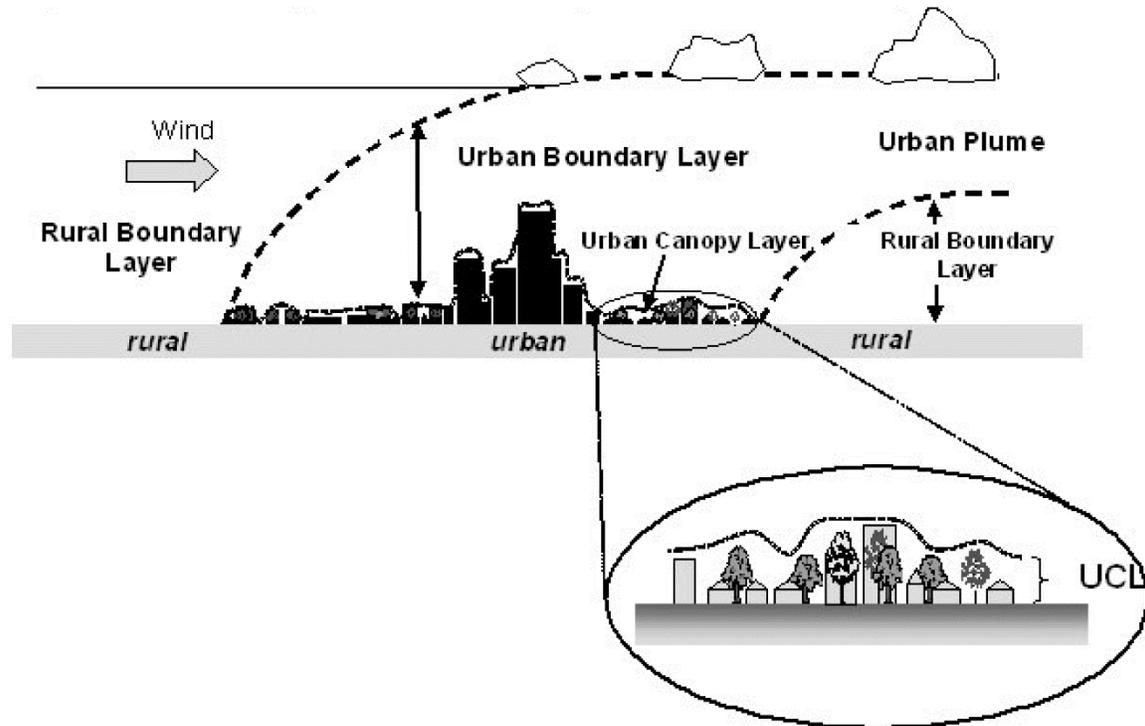


Figura 3. Esquema de las divisiones principales de la atmósfera urbana (Fabrzi et al., 2010)

Para poder analizar las variaciones a microescala, la observación térmica remota del efecto SUHI hizo posible al medir la temperatura superficial terrestre (LST) gracias al avance de la tecnología de los sensores satelitales (El Kenawy et al., 2020). La temperatura superficial contiene los efectos de las propiedades radiativas como la humedad superficial, la emisividad superficial y el albedo (Mirzaei & Haghighat, 2010). La LST influye en la capa inferior de la temperatura del aire de la atmósfera urbana y desempeña un papel fundamental en el control de la radiación superficial y el intercambio de energía, el clima interior de los edificios y el confort humano general dentro de las ciudades (Voogt & Oke, 1998). Esta temperatura superficial observada puede ser significativamente diferente de la temperatura del aire ambiente; no obstante, esta diferencia puede reducirse mediante el desarrollo de modelos de predicción que filtran las anomalías y discordancias entre temperatura superficial y temperatura ambiente en el aire (Nemunaitis-Berry et al., 2017). Por lo tanto, aunque el efecto SUHI proporciona una estimación indirecta de la temperatura del aire (Tepanosyan et al., 2021), está estrechamente relacionado con la expansión urbana y el efecto UHI (Zhou et al., 2019).

A raíz de estos métodos estadísticos, en los últimos años se ha evolucionado a métodos que utilizan la inteligencia artificial (Adilkhanova et al., 2022). Aunque hay algunas excepciones (Straub et al., 2019), muchos de ellos demuestran que los algoritmos de aprendizaje automático están superando a los enfoques convencionales basados en análisis de regresión múltiple debido a su capacidad mejorada de automatización (Oh et al., 2020). Por ejemplo, Rui Wang et al. (2020) documentaron un mayor poder predictivo de la *Random Forest Regression* (RFR) en comparación con la *Multiple Linear Regression* (MLR) al tener en cuenta el efecto SUHI en Hangzhou, China. A diferencia de este estudio, Yoo (2018) combinó variables físicas con una serie de indicadores socioeconómicos. Se encontró que la RFR era un enfoque efectivo para modelar el efecto UHI en el condado de Marion,

Indiana. En una línea similar, Gardes et al. (2020) utilizaron la RFR con la MLR como base para modelar el efecto UHI nocturno en varias aglomeraciones urbanas francesas a partir de un conjunto de predictores morfológicos y geográficos. Esta investigación reafirmó la utilidad de la RFR para predecir el efecto UHI, a pesar de su peor ajuste en áreas altamente pobladas como París.

La predicción del efecto UHI también se ha abordado mediante enfoques híbridos que involucran RFR u otros algoritmos. Este es el caso de Zhang et al. (2021), quienes combinaron RFR con un algoritmo de Monte Carlo para evaluar el efecto SUHI en el noreste de China a partir de datos de cobertura del suelo entre 2010 y 2017. En comparación con MLR y RFR no combinadas, los autores argumentaron que su enfoque era más efectivo para manejar valores atípicos. El estudio realizado por Equere et al. (2021) desarrolló una *Artificial Neural Network* (ANN) para integrar variables topográficas y morfológicas en la predicción del efecto UHI basada en LST. En cambio, Mathew et al. (2019) encontraron que la *Support Vector Regression* (SVR) superó a ANN para predecir el efecto SUHI utilizando el índice de vegetación mejorado, la densidad de carreteras y la elevación como parámetros de entrada. Otros enfoques han recurrido a la combinación de modelos de regresión y modelos autómatas de Markov-Cellular (Xiangjin Meng et al., 2021) o a la regresión geográficamente ponderada basada en el espacio climático para predecir el efecto SUHI (G. Guo et al., 2021).

2.3 Métodos de índices de vulnerabilidad urbanas

La vulnerabilidad puede definirse como el estado de fragilidad de las personas y del sistema en el que viven cuando es afectado por un peligro en función de sus aspectos físicos, sociales, culturales, económicos, tecnológicos y políticos, lo que merma todas sus capacidades (Monte et al., 2021). Existen diferentes métodos para evaluar la vulnerabilidad como el método de curva, en el que se crean curvas de daño y se promedian para cuantificar los daños en función de la magnitud de una determinada amenaza (G. Guo et al., 2021). Para ello se utilizan modelos de simulación complejos, como la programación estocástica difusa o las redes neuronales, permitiendo determinar la vulnerabilidad basándose en grandes bases de datos recopiladas durante un largo período de tiempo (K. A. Nguyen & Liou, 2019; Pham et al., 2022).

El análisis de la vulnerabilidad mediante índices es uno de los enfoques más extendidos en áreas como la ecología, la salud y la tecnología (Gupta et al., 2018; H. Kim et al., 2015; Tiwari et al., 2021). Para seleccionar las variables que conforman estos índices, Bucherie et al. (2022) explican que se requiere información subjetiva basada en el juicio de expertos. Esta selección depende del contexto del desastre natural a evaluar, el área que se va a analizar y el enfoque de los expertos. Una vez seleccionadas las variables, se pueden utilizar diferentes enfoques para cuantificar el impacto relativo de las variables en la vulnerabilidad, como el análisis de decisiones multicriterio (MCDA) o métodos estadísticos como el análisis de componentes principales (PCA) (Andersson-Sköld et al., 2015; Y. Chen et al., 2022; Cho & Chang, 2017; Sarmah et al., 2020; Sauti et al., 2020). Generalmente, existen 3 grupos de aproximaciones para calcular los índices de vulnerabilidad en función de cómo se seleccionan los factores que influyen en el índice y sus ponderaciones o pesos: deductivos, jerárquicos e inductivos (Xie & Meng, 2023).

1. Los deductivos, también conocidos como enfoques basados en teorías, generalmente solo consideran un pequeño número de factores sociales para un área de estudio y los agregan para calcular el índice de vulnerabilidad social utilizando la suma general (Collins et al., 2009; Sehili et al., 2022).
2. Los jerárquicos dividen los factores sociales en varios grupos o temas. Un ejemplo de este grupo es el método del índice de vulnerabilidad social (SVI) del centro de control y prevención de enfermedades de Estados Unidos (CDC), que está compuesto por cuatro temas que incluyen aspectos como el estatus socioeconómico, la composición de los hogares y la discapacidad, el estatus de minoría y el idioma, y el tipo de vivienda y el transporte. Primero realiza un análisis de subíndices para calcular las puntuaciones de vulnerabilidad social para cada tema individual mediante la agregación de todos sus factores sociales, y posteriormente calcula el índice general mediante la agregación de las puntuaciones de todos los temas (Flanagan et al., 2011).
3. Los inductivos, también conocidos como enfoques basados en datos, pueden considerar una gran cantidad de factores sociales y realizar un análisis de factores, como el PCA o el método de entropía. El índice de vulnerabilidad social (SoVI) de Cutter et al. (2006) es uno de los enfoques más comunes y utiliza el análisis factorial para seleccionar los componentes relevantes y el análisis de correlación para seleccionar los factores determinantes de cada componente. Las puntuaciones finales de los factores se normalizan mediante el método de z-score.

Los estudios que presentan índices de vulnerabilidad difieren metodológicamente también en cuanto al tamaño del área de estudio (Dottori et al., 2018) o al tipo de vulnerabilidad evaluada por el índice (Parsons et al., 2016). Los más frecuentes son los que se centran en datos demográficos para construir algoritmos que describan el efecto de los factores sociales, económicos, políticos e institucionales o una combinación de ellos (Balica et al., 2009; Chan et al., 2022). No obstante, los índices de vulnerabilidad relacionados con peligros ambientales tienden a centrarse en la vulnerabilidad socioeconómica o demográfica (Cutter, 2003). Es decir, los índices de vulnerabilidad para desastres naturales generalmente tienden a evaluar la susceptibilidad humana frente a los peligros ambientales.

No obstante, la vulnerabilidad a los peligros ambientales no sólo se debe a los aspectos sociales y demográficos de las comunidades, sino también a la interacción con los sistemas del entorno físico y construido, es decir, las infraestructuras. Así como los aspectos que describen características de las personas que son comunes para todos los peligros ambientales, las diferentes infraestructuras podrán tener diferentes grados de afectación según el peligro al que sean expuestas (Julià & Ferreira, 2021).

A pesar de su amplio uso, existe un problema a la hora de validar los índices, ya que los investigadores se han visto obstaculizados en gran medida porque la vulnerabilidad social no es un fenómeno directamente observable, por lo que no existe ningún dispositivo con el que medirla. En consecuencia, la validación de los índices requiere el uso de indicadores indirectos (Schneiderbauer et al., 2006). La validación de los índices de vulnerabilidad social se ha intentado con datos indirectos independientes, como la mortalidad (Gall, 2007), los daños en el entorno construido (Burton, 2010), las pérdidas económicas (Schmidtlein et al., 2011), la migración humana (Myers et al., 2008), la entrega de correo residencial (Finch et al., 2010; Flanagan et al., 2011) y la encuesta de hogares (Fekete, 2009). En conjunto, estos esfuerzos han tenido resultados desiguales. Un enfoque alternativo relativamente inexplorado es la validación interna de los índices de vulnerabilidad social (Damm, 2010) a través de un examen de cómo los cambios en la construcción del índice afectan a los resultados modelados (Tate, 2012).

2.4 Recursos informáticos en el ámbito de los riesgos urbanos.

Las funcionalidades y aplicaciones de la informática en diferentes ámbitos de la vida han revolucionado la sociedad actual y agilizado tareas hasta entonces muy costosas en tiempo y recursos. En el campo específico de la ciencia y la investigación ha supuesto un gran salto en tareas relacionadas con la computación y manejo de grandes bases de datos.

Así, los Sistemas de Información Geográfica (SIG) permiten el manejo de una gran variedad de datos espaciales, cuyo geoprocesamiento es esencial para jerarquizar zonas de estudio de acuerdo al riesgo, o sus componentes de peligro y vulnerabilidad para elementos de la ciudad como la población, la infraestructura urbana o el ecosistema urbano (Ahiablame & Shakya, 2016; Hong et al., 2018; Skilodimou et al., 2019). Una gran mayoría de los estudios de análisis de riesgos naturales emplean SIG como herramienta principal en su enfoque (Coppock, 1995; Hakim & Lee, 2020; Manfré et al., 2012). En este sentido, una amplia variedad de investigaciones se enfoca en la superposición y relación de capas temáticas para producir mapas de riesgo, peligrosidad y vulnerabilidad (Bandi et al., 2019; J. Chen et al., 2009; W. Chen et al., 2019; Feloni et al., 2019; Hammami et al., 2019; Jato-Espino et al., 2016; Mukherjee & Singh, 2020; Mutani et al., 2019; Souissi et al., 2020; Vyas et al., 2014).

A colación de esta tesis doctoral, tanto la implementación espacial de modelos de inundaciones, la predicción del efecto UHI o el cálculo de la vulnerabilidad se pueden apoyar en los SIG para gestionar datos y representar resultados. Por ejemplo, existen investigaciones que recurren y combinan SIG con diferentes modelos informáticos de aguas pluviales, como *Storm Water Management Model* (SWMM) (Allende-Prieto et al., 2018), *Hydrologic Modeling System* (HEC-HMS) (Niyazi et al., 2020), *Soil and Water Assessment Tool* (SWAT) (Kalogeropoulos et al., 2020) o MIKE FLOOD (Yin et al., 2020). En general, estos modelos utilizan SIG para producir y gestionar una gran variedad de tipos de información espacial que posteriormente funcionan como entradas y condiciones de contorno en los modelos de aguas pluviales, que, a su vez, se utilizan para simular la escorrentía y devolver soluciones aplicables a su vez en SIG. Por ejemplo, los datos de entrada de los modelos digitales de elevación (MDE) son tratados en herramientas SIG para calcular la dirección del flujo en función de la diferencia de altura.

Igualmente, para la detección o análisis de los factores que afectan a la aparición del efecto UHI es necesario primero una gestión de los datos espaciales para su posterior cálculo y representación; por ejemplo, el cálculo de las densidades de ciertos elementos dentro del área de influencia del punto de medición de la temperatura como la densidad de edificios, carreteras o zonas vegetadas, entre otros. Otra aplicación usualmente utilizada debido a su correlación con la variación espacial de la temperatura es el factor de cielo visible (*Sky View Factor*) (Rongtao Wang et al., 2023), definido como el porcentaje del área de cielo visible desde un punto teniendo en cuenta su topografía circundante. Esta topografía suele estar representada por un producto que tiene en cuenta el MDE y la altura de los edificios (este producto también es obtenido utilizando herramientas SIG) (Kastendeuch, 2013). Muchos de los modelos físicos como WRF o ENVI-met están integrados también con herramientas SIG. La herramienta THIS (*Tool for Heat Island Simulation*) se crea como una extensión del software propietario ArcGIS que permite identificar zonas de efecto UHI en función de la geometría urbana (relación entre altura y anchura) (Nakata-Osaki et al., 2018). En Egipto se utilizaron los SIG para gestionar mediciones de temperatura y detectar varianzas del

campo térmico urbano de mediciones remotas satelitales para posteriormente hacer un estudio de estas temperaturas en diferentes usos de suelo (Ahmed, 2018).

Los SIG también son protagonistas en el análisis espacial de la vulnerabilidad para gestionar la información (Nasiri et al., 2016). A menudo se recurre a ellos para realizar MCDA, especialmente en forma de técnicas de suma ponderada (Shen et al., 2021), proceso analítico jerárquico (AHP) (Lyu et al., 2018; Souissi et al., 2020; Stefanidis & Stathis, 2013) u orden de preferencia por similitud a la solución ideal (TOPSIS) (Ha et al., 2023; Rezaei et al., 2020; Zope et al., 2016) para agregar una serie de factores para su análisis de contribución al peligro, vulnerabilidad o riesgo. No solo para decisiones multicriterio se utilizan SIG, sino también para realizar análisis estadísticos de la vulnerabilidad como PCA (Ajtai et al., 2023) o validaciones de índices de vulnerabilidad mediante regresiones geográficamente ponderadas (GWR) (Sung & Liaw, 2020).

Los lenguajes de programación también son un avance para la realización de tareas que conectan modelos con SIG o crear nuevas funcionalidades dentro de los propios SIG. Así, WetSpa-Urban (Rezazadeh Helmi et al., 2019) se diseñó como un modelo de lluvia y escorrentía basado en eventos que vincula SIG y SWMM a través de Python. En un sentido similar, DrainGIS (Barreto et al., 2020) surgió como un complemento construido usando Python para incorporar los métodos de infiltración y enrutamiento disponibles en SWMM en QGIS. Estas herramientas son variantes del software propietario PCSWMM (Akhter & Hewa, 2016).

Los cálculos estadísticos como medias, medianas, desviaciones típicas e incluso relaciones de regresiones lineales pueden realizarse con herramientas que los software SIG disponen. Cuando esto no es posible, o cuando usar esa herramienta no resulta intuitiva, existen otras opciones que ayudan a la gestión de esos datos. Existe software estadístico simple como SPSS o Minitab que proporcionan un entorno amigable para el usuario para realizar cálculos estadísticos. Su desventaja es la nula comunicación con cualquier SIG, por lo que son útiles para un uso puntual, pero no están preparados para la automatización de procesos iterativos. Para ello, los lenguajes de programación como Python o R son la solución a este problema, ya que hacen de puente de comunicación entre SIG y paquetes de funcionalidades para el cálculo y representación de datos estadísticos.

2.5 Corolario

Esta tesis se orienta hacia el desarrollo de metodologías con un compromiso entre las debilidades y fortalezas observadas en métodos anteriores. Con esta condición, se intenta proporcionar una solución equilibrada: lo suficientemente precisa, sin un requerimiento excesivo de cálculo computacional y útil para el usuario responsable de la toma de decisiones. Para ello, se utilizan los recursos informáticos expuestos en el apartado 2.4 que proporcionan la base para el desarrollo de estas metodologías y herramientas (figura 4).



Figura 4. Resumen de los métodos y recursos utilizados en la tesis y su implicación en la implementación argumentada de soluciones basadas en la naturaleza (NBS).

Actualmente existe una división de las opciones de software SIG entre los de código abierto y los cerrados o propietarios. Entre los de código abierto, actualmente QGIS (QGIS Development Team, 2023) es el más comúnmente utilizado. QGIS tiene una infraestructura de complemento donde el usuario puede desarrollar nuevas funciones. Estos complementos pueden ser escritos en lenguajes de programación como C++ o Python. En cuanto a los que trabajan bajo licencia comercial, existe un aparente monopolio por la empresa ESRI con su ecosistema ArcGIS (*Software de Cartografía SIG Web | ArcGIS Online*, 2023). Este es, probablemente, el SIG más completo y con las funcionalidades más potentes y versátiles al disponer de desarrolladores especializados. En este caso, el usuario o desarrollador también puede generar complementos nuevos que podrán ser utilizados por otros usuarios de este software. El uso del código nativo de la máquina objetivo para la creación de nuevas funcionalidades en los SIG da como resultado un rendimiento más rápido y eficiente, lo que

contrasta con la acción ampliamente adoptada en la literatura, donde se prefiere Python, un lenguaje interpretable no optimizado para las bases de datos geoespaciales.

La tendencia observada en los modelos de inundación como WetSpa-Urban, DrainGIS o SWMM resulta en complejos y diferentes módulos necesarios para tener en cuenta los procesos hidrológicos e hidrodinámicos involucrados en la escorrentía. Eso dificulta su accesibilidad debido a sus necesidades de datos de entrada y difiere de la simplicidad necesaria para el usuario no especializado. Por ello se propone utilizar el método racional, que se distingue por su accesibilidad y simplicidad donde únicamente se utiliza el balance de volumen para calcular la escorrentía a partir de datos de lluvia y características básicas de la superficie de la cuenca. La dependencia directa del método racional en la configuración de la cobertura del suelo para el cálculo de la escorrentía hace de esta metodología la idónea. Sin embargo, la precisión del cálculo de la escorrentía en esta metodología se ve limitada por la falta de mecanismos para calcular el enrutamiento del flujo. Por ello, en esta investigación se propone actualizarla añadiendo esta característica. Además, se automatiza el proceso de aplicación de la metodología programando la gestión de los datos de entrada, el cálculo de la metodología y la producción de una salida interpretable en SIG, creando un complemento o *add-in* amigable con el usuario.

En cuanto a la predicción y modelado del efecto UHI, independientemente de los modelos utilizados, la literatura reciente se ve limitada en las técnicas convencionales. Primero por la complejidad de los métodos basados en procesos matemáticos y conceptos físicos. Y segundo, por la no replicabilidad de los modelos creados mediante regresiones lineales en diferentes lugares. La disrupción de los métodos dirigidos por datos o de aprendizaje computacional abre un nuevo y amplio enfoque que simplifica el proceso de la relación causa efecto y, al mismo tiempo, mantiene o aumenta su precisión. Bajo esta premisa, se desarrolla una metodología que permita determinar una relación estadística de la LST con bases de datos accesibles que definan las causas del efecto UHI. En ella se utilizan de manera paralela métodos estadísticos básicos y de aprendizaje computacional para posteriormente comparar su rendimiento.

Al evaluar y analizar la vulnerabilidad existen aspectos ambientales, físicos, sociales y económicos que deben tenerse en cuenta. Sin embargo, la amplia mayoría de estudios anteriores se han centrado en la vulnerabilidad social, económica y demográfica. Así, se identificó una falta de estudios que compilen estos criterios en un único índice y proporcionen una perspectiva holística del problema. Además de centrarse en evaluar aspectos de la vulnerabilidad que afectan directamente a los habitantes urbanos basados en la demografía o sus limitaciones sociales y económicas, este estudio propone también ampliar el foco a las infraestructuras que brindan refugio y servicios a los ciudadanos, ya que su vulnerabilidad puede afectar directa o indirectamente al funcionamiento normal de la ciudad. Así, se propone un enfoque híbrido basado en metodologías existentes que combina aproximaciones de tipo jerárquico e inductivo; concretamente, en los análisis numéricos utilizando análisis de correlación y PCA.

Con el fin de proporcionar una aproximación abarcando una visión integral del riesgo, los resultados de vulnerabilidad se integran con los resultados obtenidos en el apartado correspondiente a la localización del peligro de inundaciones sobre el mismo caso de estudio. El análisis del riesgo de inundaciones sirve como ejemplo de la sinergia entre las diferentes metodologías propuestas en esta tesis, sus posibilidades y posteriores posibles mejoras en investigaciones futuras.

3 Metodología

En este capítulo se aborda la metodología empleada en esta tesis doctoral para llevar a cabo el estudio de los peligros asociados a las inundaciones y el efecto isla de calor urbano, así como analizar la vulnerabilidad del entorno urbano. Para ello, se describen los procedimientos y herramientas utilizados en cada fase de la investigación. Las metodologías aquí presentadas están diseñadas para contribuir a un enfoque integral en la evaluación de los riesgos urbanos presentándose cada una de ellas en detalle junto a los casos de estudio específicos utilizados para su desarrollo. Además, a través de este capítulo, se busca enfatizar la importancia de las soluciones basadas en la naturaleza (NBS) en la toma de decisiones para mitigar estos riesgos.

3.1 Casos de estudio

3.1.1 Santander

La ciudad de Santander ha sido seleccionada para realizar un modelado hidrológico urbano y, posteriormente, un estudio de vulnerabilidad con el propósito de combinar ambos trabajos y completar así el análisis de riesgo de inundaciones en esta localidad (figura 5a). Santander se ubica en el norte de España, en la Comunidad Autónoma de Cantabria, y su clima, según la clasificación Köppen-Geiger, se cataloga como oceánico (*Cfb*). Este tipo de clima se caracteriza por una humedad constante y un rango estrecho de temperaturas a lo largo del año, incluyendo inviernos frescos y veranos templados. Estas condiciones resultan en una precipitación media anual elevada, de 1200 mm, lo que justifica el interés en el estudio del riesgo ante inundaciones en esta ciudad. La topografía de Santander presenta áreas de elevación variable y zonas bajas, lo que hace a estas últimas más propensas a inundaciones.

Las inundaciones han sido uno de los problemas más importantes de la ciudad en los últimos 10 años, con varios episodios registrados (Álvarez et al., 2021; Ayuntamiento de Santander, 2023; El Diario Montañés, 2023; Mena, 2023; Pesquera et al., 2020). Un ejemplo claro y reciente ocurrió el 10 de septiembre de 2023, cuando una precipitación de 49,4 mm/m² provocó inundaciones en las zonas más bajas de la ciudad (Mena, 2023). Consciente de esta situación, el Ayuntamiento de Santander ha publicado un Plan Municipal de Emergencia para abordar los riesgos naturales (Ayuntamiento de Santander, 2016), antropogénicos y tecnológicos, entre los cuales las inundaciones representan una de las principales amenazas identificadas debido a la presencia de varias zonas en la ciudad especialmente susceptibles a la acumulación de escorrentía.

3.1.2 Madrid

La zona metropolitana de Madrid (España) se encuentra a cierta distancia de la influencia del mar, lo que puede acentuar el efecto isla de calor urbano (UHI) (figura 5b). Con altitudes que oscilan entre 580 y 750 metros sobre el nivel del mar, la región experimenta temperaturas extremas tanto en verano como en invierno. Desde el punto de vista de la clasificación climática de Köppen-Geiger, esta región se cataloga como un clima en transición entre el semiárido continental (*Bsk*) y el mediterráneo frío (*Csa*), con una temperatura media anual de 14,5 °C y una precipitación anual de 415 mm/m² (H. E. Beck et al., 2018). Según un informe de la Dirección General de Salud Pública de Madrid, se prevé que el escenario más desfavorable para el año 2100 conllevará un aumento significativo en los días con temperaturas máximas superiores a 36,5 °C, llegando al 40% de los días y con olas de calor que podrían extenderse en el tiempo alrededor de 20 días (Consejería de Sanidad de la Comunidad de Madrid, 2021).

El efecto UHI en la ciudad de Madrid se ha constatado como especialmente común y acentuado durante las noches en temporadas de temperaturas cálidas (Sánchez-Guevara Sánchez et al., 2017). La relevancia de este fenómeno en la región ha impulsado su análisis durante las últimas tres décadas, desde que se documentó por primera vez en investigaciones científicas (Yagüe et al., 1991), hasta su inclusión en planes urbanos que hacen hincapié en su marcado impacto sobre la población (Ayuntamiento de Madrid, 2022).

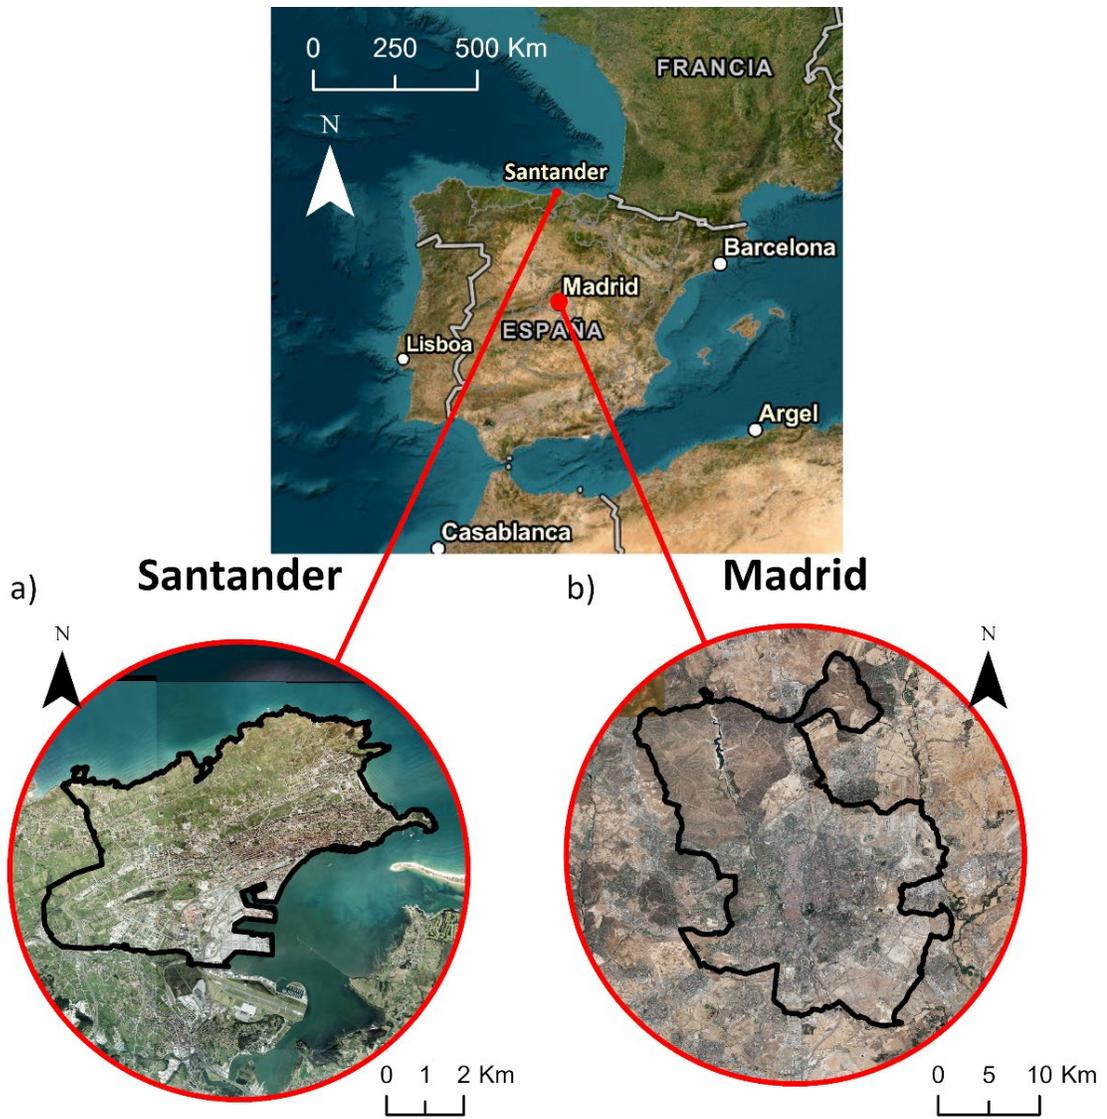


Figura 5. Localización de los casos de estudio. a) Santander y b) Madrid.

3.2 Modelo hidrológico urbano

El modelado hidrológico tiene como uno de sus objetivos entender y predecir cómo reaccionan las cuencas hidrográficas frente a eventos de lluvia intensa. El método racional en el que se basa este enfoque implica una ecuación de balance hídrico. Esta ecuación evalúa la cantidad de agua que entra en una cuenca en forma de lluvia y cómo se gestiona, ya sea infiltrada en el suelo o convirtiéndose en escorrentía superficial. Para aplicar este método, se requiere cierta información sobre la cuenca, como su área, topografía, tipo de suelo y tipo de cobertura del suelo. También es fundamental contar con datos que describan los patrones de precipitación en la zona para poder conocer la cantidad de agua a gestionar.

Cuando el enfoque se centra en áreas urbanizadas, la topografía se ve influenciada por diversas estructuras construidas por el ser humano, como edificios, que alteran la gestión del agua en la cuenca hidrográfica. Por lo tanto, es necesario tener en cuenta estos elementos. Una ventaja del método racional es su dependencia directa de la configuración de la cobertura del suelo en las áreas de captación, ya que permite evaluar cómo la impermeabilidad influye en la formación de escorrentía y cómo la incorporación de superficies permeables puede contribuir a reducir este fenómeno.

Para llevar a cabo este proceso, se utilizó el software ArcGIS Pro (*Software de Cartografía SIG Web / ArcGIS Online*, 2023) como plataforma de análisis espacial, en la cual se desarrolló un complemento o *add-in* que fue denominado ArcDrain. Este *add-in* consta de cuatro fases en las que se calcula e identifican los flujos de escorrentía dentro de la ciudad, incluyendo la introducción de datos y parámetros requeridos, un algoritmo lógico que conecta las diversas subcuencas que conforman la ciudad, el tratamiento de los datos de entrada y el cálculo de escorrentía utilizando el método racional (figura 6). Estas fases se ejecutan de manera secuencial y automatizada, de modo que la salida de una fase se convierte en la entrada de la siguiente.

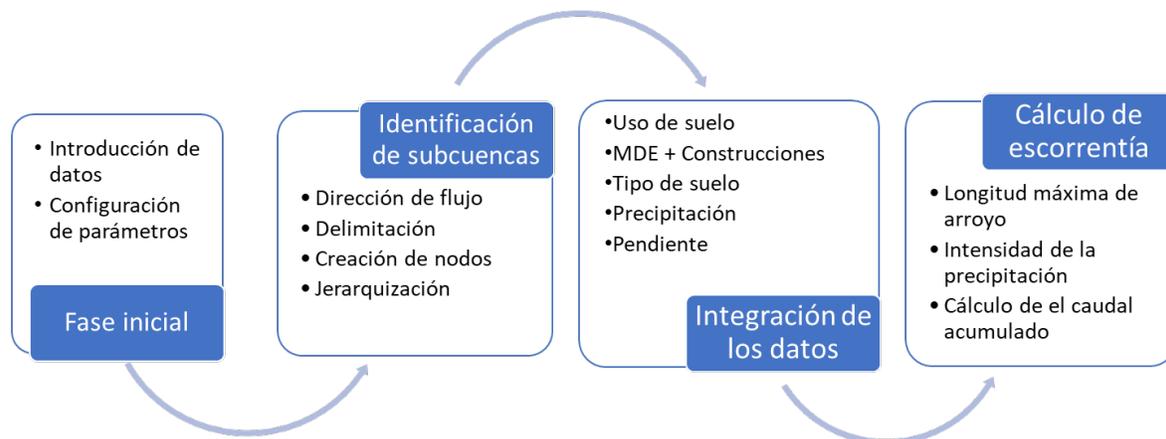


Figura 6. Esquema del proceso de trabajo en modelado hidrológico.

En la fase inicial se incorporan las bases de datos que se utilizarán posteriormente y se configuran los parámetros necesarios en el método racional, los cuales dependen de las características de las precipitaciones en la zona geográfica donde se aplique la metodología. La segunda fase se compone de dos procesos que delimitan y jerarquizan las subcuencas del área de estudio, lo que permite rastrear el flujo de escorrentía a lo largo de las subcuencas aguas abajo mediante la implementación de un método de seguimiento del flujo de escorrentía. En la tercera fase realiza un tratamiento de los datos iniciales para obtener todos los valores necesarios para aplicar el método racional. En la última fase se aplica la fórmula de balance hídrico del método racional, la cual calcula el caudal máximo de escorrentía en cada una de las subcuencas y la acumulación de esta escorrentía en las subcuencas aguas abajo gracias a la jerarquización previamente definida.

3.2.1 Datos de entrada en fase inicial

El *add-in* requiere principalmente de 4 fuentes de datos que posteriormente se proceden a almacenar y procesar en esta fase inicial. Estos datos contienen información sobre la topografía, las características de las infraestructuras creadas por el hombre sobre el suelo natural, las características hidrológicas de la superficie de la zona y el tipo de precipitaciones que se producen.

Estos datos son básicos para poder estimar la escorrentía en una cuenca mediante el método racional. Las fuentes de datos propuestas como entrada en esta metodología (tabla 2) son de libre acceso en la amplia mayoría de países del mundo, incluso existen entidades que proporcionan dicha información para un extenso número de países como es el caso de los pertenecientes a la Unión Europea.

El primer paso en la obtención de datos de entrada consiste en precisar el Modelo Digital de Elevaciones (MDE) a utilizar. Estos modelos digitales se generan a partir de mediciones obtenidas mediante técnicas como la fotogrametría estereoscópica o el LIDAR, que recopilan una gran cantidad de puntos de medición en la superficie del terreno, formando así una nube de puntos. Los MDE que se emplean para el estudio de la topografía de una región y su hidrología pueden ser Modelos Digitales del Terreno (MDT) o incluso pueden derivar de Modelos Digitales de Superficie (MDS) a los que se le aplica cierto procesamiento; por ejemplo, suavizar las diferencias de altura dentro de las masas de agua. Existe cierta controversia en la definición de estos diferentes tipos de modelos digitales, ya que en algunos países se utilizan estos términos como sinónimos o se agrupan y subordinan unos dentro de otros en una clasificación. Sin embargo, el propósito de esta tesis no es debatir sobre dicha ontología. A continuación, se presentarán las bases de datos y las definiciones utilizadas en este estudio para cada uno de estos términos.

Tabla 2. Fuentes de bases de datos aplicables al modelo y disponibles de forma libre.

<i>TIPO</i>	<i>FUENTE</i>	<i>TIPO DE DATO</i>	<i>DOMINIO</i>	<i>REFERENCIA</i>	<i>FUENTES APLICADAS</i>
<i>Modelos Digitales de Elevación (MDE)</i>	ESA-Copernicus	Ráster, resolución 10-30m	Global	(ESA, 2023)	
<i>Modelos digitales de terreno (MDT)</i>	Instituto geográfico nacional (IGN)	Ráster 2m	España	(CNIG, 2023)	✓
<i>Modelos digitales de superficie (MDS)</i>	Continental Europe Digital Terrain Model	Raster 30m	Europa	(Hengl et al., 2021)	
	Instituto geográfico nacional (IGN)	Ráster 2m	España	(CNIG, 2023)	
<i>Edificios</i>	Catastro	Vectorial	España	(Ministerio de Hacienda y Función Pública, 2023)	✓
	OpenStreetMap	Vectorial	Global	(OpenStreetMap contributors, 2017)	
<i>Cobertura del suelo</i>	ESA-Copernicus Corine Land Cover	Vectorial/Ráster 100m	Europa	(Copernicus, 2023a, 2023b)	
	ESA-Copernicus Urban Atlas	Vectorial	Europa	(Copernicus, 2023c)	✓
	Sistema de Información de Ocupación del Suelo en España (SIOSE)	Vectorial	España	(CNIG, 2023)	
<i>Geología</i>	The Oak Ridge National Laboratory Distributed Active Archive Center (ORNL DAAC)	Ráster 250m	Global	(Ross et al., 2018)	
	Federal Institute for Geosciences and Natural Resources	Vectorial	Europa	(Duscher et al., 2015)	
	Instituto Geológico y Minero de España (IGME)	Vectorial	España	(IGME, 2023) (del Pozo Gómez, 2009)	✓
<i>Precipitación</i>	WorldClim	Ráster, resolución 1km	Global	(Fick & Hijmans, 2017)	

A nivel europeo existe el Servicio de Vigilancia Terrestre (COPERNICUS) de la Agencia Espacial Europea (ESA), desde el que se puede acceder a sus MDE con una resolución de 10 metros para Europa y de 30 metros para el resto del mundo. Este producto de la ESA define su MDE como un MDS que representa la superficie de la Tierra, incluidos vegetación, edificios e infraestructuras, así como suavización de las masas de agua, corrección del curso de los ríos para asegurar su continuidad y alguna infraestructura como aeropuertos (AIRBUS Defence and Space, 2021). Al tener incluidos estos elementos no sería un MDE aplicable directamente en esta metodología pero podría llegar a ser un punto de partida como en el caso del *Continental Europe Digital Terrain Model* en el que se obtuvo un MDT a través de un MDS precursor al que se le ha realizado un tratamiento mediante inteligencia artificial para predecir la elevación del terreno con una resolución de 30m (Hengl et al., 2021). En este estudio se utilizó el MDT proporcionado por el Instituto geográfico nacional (IGN), ya que cuenta con una resolución de 2 metros (CNIG, 2023). El IGN define su MDT como la representación interpolada de la variable elevación del terreno a partir de la nube de puntos LIDAR donde las masas de agua son editadas para asignar una cota constante.

Para mejorar la precisión de la simulación de la escorrentía en entornos urbanos, es recomendable incorporar al MDT ciertas infraestructuras que pueden alterar la dirección del flujo de escorrentía. Entre estas infraestructuras, las edificaciones desempeñan un papel fundamental, ya que actúan como obstáculos físicos presentes en prácticamente todo el tejido urbano. Para integrar estas edificaciones en la simulación, se dispone de datos que las representan (OpenStreetMap contributors, 2017). En el caso concreto de España, esta información puede obtenerse a través de la sede electrónica del Catastro del Ministerio de Hacienda y Función Pública (Ministerio de Hacienda y Función Pública, 2023).

Se pueden obtener datos sobre la cobertura y usos del terreno en las diferentes ciudades de los países europeos en el Urban Atlas o en el Corine Land Cover (Copernicus, 2023a, 2023b, 2023c). Estas dos fuentes de datos clasifican las diferentes coberturas del suelo con una codificación de 5 dígitos donde en ocasiones solo son representados los 3 dígitos de los niveles de clasificación más importantes. A pesar de seguir la misma codificación, ambas presentan diferencias significativas. El Urban Atlas, destinado exclusivamente a ciudades, ofrece una mayor resolución y cobertura detallada con 17 categorías en comparación con las 11 del Corine Land Cover.

Los datos geológicos o edáficos para determinar el tipo de suelo sobre el que se asientan las coberturas de suelo son necesarios para determinar la capacidad de retención del agua de escorrentía tras rebasar esa primera capa de la superficie terrestre. Se pueden encontrar datos en formato shapefile (.shp) elaborados por el *Federal Institute for Geosciences and Natural Resources* de Hannover y también se dispone de información geológica más detallada a nivel nacional a través del Mapa geológico digital a escala 1:50000 que ofrece el Instituto Geológico y Minero de España (IGME) (IGME, 2023). Las características hidrogeológicas de los suelos suelen ser definidas en función de sus grupos hidrológicos. Estos grupos hidrológicos se codifican en 4 clases en función a su potencial de infiltración, desde alto (A) a bajo (D) (Patra, 2001). Esta clasificación hidrológica del suelo está relacionada con su composición, donde los diferentes porcentajes de arenas, limos y arcillas definen la capacidad de infiltración (figura 7). Existen mapas hidrogeológicos de esta clasificación con una resolución de 250 metros a nivel mundial, ofrecidos por *The Oak Ridge National Laboratory Distributed Active Archive Center* (ORNL DAAC) (Ross et al., 2018).

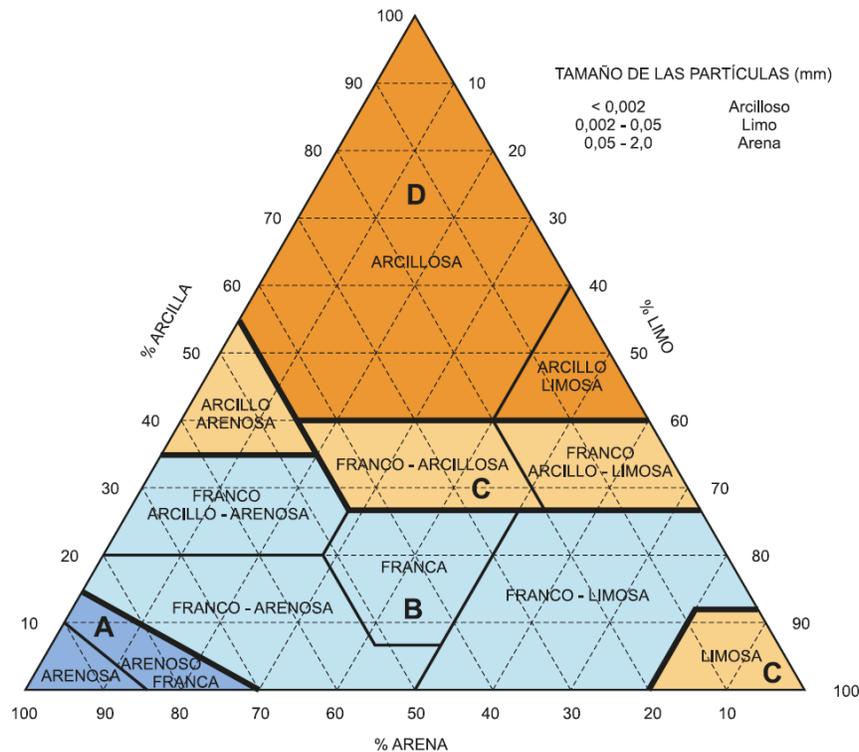


Figura 7. Grupos hidrológicos según composición del suelo extraída de la Norma 5.2-IC de la instrucción de carreteras de drenaje superficial.

Las mediciones de precipitaciones del planeta se basan en series de registros puntuales de estaciones meteorológicas. Este dato puntual puede interpolarse entre estaciones si se dispone de varios puntos de medición. No obstante, existe un problema en su conversión a dato espacial, ya que no en todos los casos es recomendable realizar una interpolación. Esto es debido a su pérdida de fiabilidad por la no linealidad de la precipitación entre estaciones meteorológicas en base a diferentes factores como la orografía (Briggs & Cogley, 1996) o efectos de la física atmosférica (Karger et al., 2017). Para solventar esto, existen alternativas como WorldClim que ofrece mapas continuos en formato ráster con una resolución de 1 kilómetro para diferentes periodos de tiempo. También se pueden utilizar proyecciones de diferentes modelos climáticos globales para el final de este siglo sugeridos por el Grupo Intergubernamental sobre el Cambio Climático (IPCC) para una evaluación de hipotéticos escenarios de emisiones futuras. No obstante, en este caso se obtuvo un mapa interpolado de precipitaciones considerando que el área de estudio es lo suficientemente pequeño (35km²) como para no existir variaciones espaciales significativas de la precipitación. Esta interpolación se obtuvo de valores de precipitación máxima anual con un periodo de retorno de 10 años en las estaciones meteorológicas cercanas a la ciudad (Jato-Espino & Pathak, 2021).

El procesamiento de todos estos datos es recomendable comenzar incluso con anterioridad a su inclusión en el *add-in*. El MDT debe ser revisado para realizar un recorte del área de estudio y la unión de las diferentes hojas cartográficas necesarias para cubrir la totalidad del terreno de la ciudad, además de la inclusión de los edificios como parte de la topografía de la ciudad que interfiere en la dirección del flujo acumulado de la escorrentía. El Urban Atlas debe incluir la codificación necesaria de 5 dígitos que definen las diferentes clases de cobertura del suelo existentes para que

sea compatible con la tabla de equivalencias de la norma 5.2 - IC drenaje superficial de la Instrucción de Carreteras (apartado 3.2.4.2, que relaciona el umbral de generación de escorrentía con cada tipo de cobertura) (Dirección General de Carreteras, 2016).

La obtención de datos sobre las características de precipitación en la zona es un proceso que requiere una preparación minuciosa debido a los requisitos y a la dificultad de obtener datos con una resolución espacial adecuada para el nivel de la ciudad, así como una resolución temporal diaria. Además, es necesario realizar el procesamiento de interpolación de los datos en caso de que solo estén disponibles en puntos específicos en las diferentes estaciones meteorológicas. Esto implica llevar a cabo una interpolación entre estas estaciones para asegurar la disponibilidad de datos en toda el área de estudio de la ciudad. Como se mencionó anteriormente, el *add-in* ha utilizado datos de precipitación con un periodo de retorno de 10 años de acuerdo con la Orden FOM/298/2016, de 15 de febrero, en la que se aprueba la norma 5.2 - IC drenaje superficial de la Instrucción de Carreteras (Dirección General de Carreteras, 2016).

Se planteó la posibilidad de incorporar la red de saneamiento en esta primera versión del *add-in*. Sin embargo, los datos existentes presentaban varios errores, como desconexiones en la red y campos de atributos vacíos necesarios para su análisis. Otra complicación al llevar a cabo este tipo de análisis teniendo en cuenta la red de saneamiento es la disponibilidad pública de este tipo de datos debido a cuestiones de seguridad (Policía Nacional Española, 2023). Estas infraestructuras, al carecer de medidas de seguridad adecuadas, presentan numerosas oportunidades para llevar a cabo actividades delictivas. Esta preocupación lleva a que diferentes países no divulguen información sobre sus sistemas de saneamiento e incluso cuenten con unidades especializadas de los cuerpos de seguridad del estado para proteger estas infraestructuras. Además, se debe destacar que la inaccesibilidad a estos datos se debe a la custodia por parte del gestor del agua urbana de la ciudad. Por lo general, este gestor es una entidad privada a la que se le han otorgado temporalmente las competencias de la gestión del agua, lo que puede generar conflictos de intereses, contractuales o legales a la hora de compartir esa información. Por lo tanto, se optó por descartar su utilización.

Estos desafíos llevaron a descartar este dato en favor de la disponibilidad de los datos necesarios para el análisis de inundaciones, lo cual se considera una de las ventajas de este *add-in*. No obstante, es importante destacar que, al no considerar la influencia de la red de saneamiento y su capacidad de drenaje, la severidad de las inundaciones podría variar. No obstante, se espera que la jerarquía de prioridad en las subcuencas sea similar (Sañudo et al., 2020). En consecuencia, el *add-in* sigue siendo útil para realizar comparaciones entre cada una de las subcuencas en función de la máxima escorrentía acumulada para su posterior gestión.

3.2.2 Delineación y jerarquización de las subcuencas

En esta fase, se definió las subcuencas en la zona de estudio utilizando Sistemas de Información Geográfica (SIG). Se han automatizado una serie de procesos para preparar el MDE y permitir que los usuarios utilicen el modelo sin requerir habilidades avanzadas en geoprocésamiento de este tipo de datos. El primer proceso implica revisar los datos del MDE utilizando la herramienta *Fill* de manera iterativa, necesaria para eliminar posibles errores interpretados de manera incorrecta como sumideros, lo que afectaría el cálculo del flujo. Después de esta revisión, se procedió a realizar un

análisis con la herramienta *Flow direction*, la cual relaciona la altitud de la celda con los valores de altitud de las 8 celdas adyacentes para determinar la dirección del flujo de una hipotética escorrentía que se mueve gravitacionalmente (figura 8).

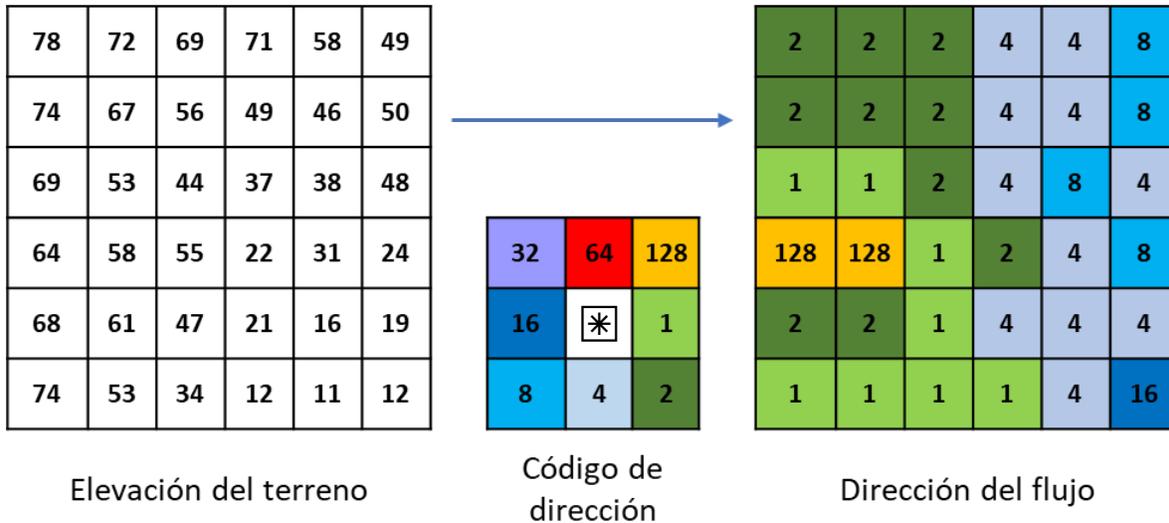


Figura 8. Codificación de la herramienta de Flow dirección para la determinación de la dirección de la escorrentía. Modificado de ArcGIS® (<https://pro.arcgis.com/en/pro-app/latest/tool-reference/spatial-analyst/flow-direction.htm>).

A continuación, es necesario calcular la acumulación de flujo a lo largo del área de estudio. De este modo, se conoce el flujo acumulado en cada píxel, a partir de todas las celdas en pendiente descendente. Gracias a esta información, se delinea la red principal de arroyos y ordenarlos mediante la herramienta *Stream Order*, que asigna un nivel jerárquico a cada uno de los arroyos en base a dos posibles organizaciones: por nivel (método de Strahler) o por número de arroyos que llegan a cada nodo (método de Shreve). En este caso se optó por la primera opción, más comúnmente usada. Una vez se dispone de la jerarquía de arroyos, se utilizó la herramienta *Stream Link* para obtener cada arroyo de forma independiente.

A partir de la información anterior, que se generó en todo momento trabajando en formato ráster, es el momento de estudiar las conexiones entre los diferentes arroyos. Para ello, se vectorizaron con la herramienta *Stream to feature* que suministra, para cada arroyo vectorizado, sus nodos de entrada y salida de acuerdo a la dirección de flujo descendente previamente calculada. Remarcar que el nodo de salida de un arroyo se identifica como el punto de descarga de cada subcuenca (*pour point*).

Con ello, es posible delinear las cuencas de drenaje en las áreas donde la configuración de la pendiente genera una acumulación de flujo hacia un punto determinado. Una vez se dispone del conjunto de subcuencas, éste se combina con la información asociada a la red de arroyos, lo que permite identificar la jerarquía de cuencas existente y crear una clasificación de las mismas. Para obtener dicha clasificación se diseñó un algoritmo de búsqueda capaz de identificar las subcuencas de cabecera (aquellas que no reciben flujo de corriente de ninguna otra) y aquellas finales (las que no drenan hacia ninguna otra). Posteriormente, se estudia la transmisión de flujo entre ellas, siendo capaz de obtener entre qué cuencas circulan las diferentes escorrentías que se generan (figura 9).

Ello permitirá, posteriormente, obtener el flujo que se va acumulando a medida que la escorrentía avanza aguas abajo.

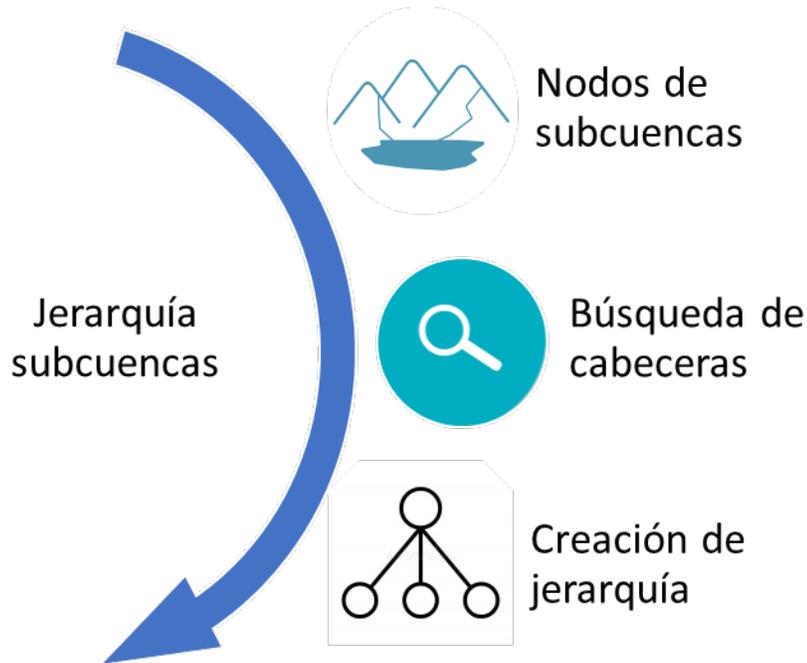


Figura 9. Proceso del algoritmo de jerarquización de subcuencas.

El tamaño de estas subcuencas viene determinado por el filtrado realizado en la red de arroyos. En este estudio, se estableció un umbral del 1% para este parámetro, ya que valores inferiores definían subcuencas demasiado pequeñas para poder analizarlas con la resolución disponible. Posteriormente se comprobó que este umbral del 1% estaba alineado con los límites de delimitación de subcuencas y con los cálculos de escorrentía máxima recomendados por la literatura (Azizian & Shokoohi, 2014). Es importante destacar que este porcentaje es modificable dentro de la herramienta, lo que permite ajustar el tamaño de la subcuenca en la que se desea trabajar.

Toda la información sobre la red de arroyos y las subcuencas de drenaje que de ellos se derivan es almacenada para su uso posterior, asociando a cada subcuenca sus nodos de entrada y salida, así como las cuencas conectadas a ella (de vertido y de salida) como atributos. De esta forma, se genera una estructura jerárquica de árbol en la que se conoce el flujo de la corriente de agua a través de las distintas subcuencas. Una vez se dispone de esta estructura jerárquica, se procede al cálculo de la escorrentía acumulada mediante el método racional, utilizando los datos obtenidos en la combinación de los datos después de ser integrados para un manejo más fácil.

3.2.3 Integración de los datos

Esta fase incluye una serie de tareas de preprocesamiento para tratar algunas de las variables que intervienen en la determinación del caudal máximo de escorrentía por unidad de subcuenca. Por un lado, datos discretos como la cubierta terrestre y los tipos de suelo se combinaron con la capa de subcuencas para obtener una tabla de atributos que contenga las relaciones entre esas variables. Por otro lado, se creó una capa ráster multibanda combinando datos continuos como la

precipitación, la pendiente y la red de arroyos con las subcuencas. Este procedimiento permitió preparar todos los datos necesarios para aplicar el método racional. La realización de dos combinaciones diferentes fue debido a que computacionalmente es más eficiente trabajar con una sola banda de datos que contenga una tabla de atributos asociada. Sin embargo, ello no es posible cuando se utilizan datos ráster continuos (como es el caso de la precipitación o la pendiente, en donde cada píxel tiene un valor generalmente distinto a sus adyacentes). En este caso se optó por la solución del ráster multibanda.

Además, se ejecutó un conjunto de tareas adicionales para preparar algunos datos que se utilizarían en la última fase de ArcDrain. Así, la precipitación media en toda la cuenca se determinó promediando los valores de la precipitación diaria máxima anual en cada subcuenca. Del mismo modo, se utilizaron los resultados de la herramienta *Flow Length* para calcular la longitud del arroyo más largo de cada subcuenca. Por último, se utilizó la herramienta de geoprosesamiento *Slope* para calcular la pendiente en cada píxel del MDE, lo que permite calcular posteriormente la pendiente media de cada subcuenca.

3.2.4 Cálculo del caudal máximo de escorrentía

Una vez se ha establecido esta estructura jerárquica, se procede al cálculo de la escorrentía acumulada utilizando el método racional con los datos obtenidos anteriormente. La escorrentía en la zona de estudio se determinó siguiendo las pautas establecidas en la norma 5.2-IC Drenaje Superficial, establecida por el Ministerio de Transportes, Movilidad y Agenda Urbana de España (Dirección General de Carreteras, 2016). Esta norma recomienda el uso del método racional para calcular el caudal máximo de escorrentía en cuencas con una superficie inferior a 50 km². La fórmula general de este método es la siguiente:

$$Q_T(m^3/s) = \frac{I(T, t_c) \cdot C \cdot A \cdot K_t}{3,6} \quad \text{Ecuación 1}$$

Donde Q_T (m³/s) es el caudal máximo de escorrentía correspondiente a un período de retorno T en el punto de descarga de la cuenca; I (mm/h) es la intensidad de la precipitación asociada a un período de retorno T y una duración de la lluvia igual al tiempo de concentración t_c de la cuenca; C (adimensional) es el coeficiente medio de escorrentía en la cuenca; A es la superficie de la cuenca expresada en km²; y K_t (adimensional) es el coeficiente de uniformidad en la distribución temporal de la precipitación.

Este método es idóneo en cuanto a su equilibrio entre complejidad y disponibilidad de datos (Grimaldi & Petroselli, 2015), haciendo sinergia con la filosofía de ArcDrain de simplicidad y datos abiertos. Para el modelado se calculó cada uno de los términos de la fórmula general de caudal máximo de escorrentía para cada una de las subcuencas mediante las consideraciones de la norma. A excepción del área de cada subcuenca, que se determinó a partir del cálculo del número de píxeles y la resolución de la capa ráster en la zona, en los siguientes subapartados se realiza una descripción pormenorizada del resto de los términos de la ecuación 1.

3.2.4.1 Intensidad de la precipitación

La intensidad de precipitación (I) es un término que se utiliza en hidrología para describir la cantidad de lluvia que cae en un área determinada durante un período específico de tiempo (Ghebreyesus &

Sharif, 2021). En el método racional de cálculo de escorrentía, la intensidad de precipitación se define como la cantidad de agua de lluvia caída en un tiempo determinado para el periodo de retorno establecido. Este valor se puede obtener de curvas de intensidad-duración-frecuencia (IDF). Si no se dispone de ese dato, se puede determinar mediante el producto de la intensidad diaria (I_d) corregida y el factor de intensidad (F_{int}) (ecuación 2).

$$I(T, t) = I_d \cdot F_{int} \quad \text{Ecuación 2}$$

Para el cálculo de la intensidad diaria (I_d) se utiliza la precipitación máxima diaria (24h) en un año (P_d) para un período de retorno de 10 años. Después, esta es corregida por un factor de reducción en función del área a determinar (K_A) (ecuación 3).

$$I_d = \frac{P_d \cdot K_A}{24} \quad \text{Ecuación 3}$$

En el caso del estudio de ciudades divididas en subcuencas, este factor K_A toma el valor de 1 siempre que las subcuencas estudiadas no tengan un área superior a 1km². Si existiera una cuenca con una dimensión mayor se corregiría esa precipitación con el factor resultante de la ecuación 4, dependiente del área de la subcuenca (A).

$$K_A = 1 - \frac{\log_{10} A}{15} \quad \text{Ecuación 4}$$

El término del factor de intensidad (F_{int}) es dependiente de la distribución de la precipitación a lo largo del día, donde se divide la intensidad máxima horaria anual (I_1) entre la intensidad máxima horaria anual (I_d) (ecuación 5). Este factor de intensidad (I_1/I_d) varía en el territorio español entre 8 y 12.

$$F_{int} = \left(\frac{I_1}{I_d} \right)^{3,5287 - 2,5287 \cdot t_c^{0,1}} \quad \text{Ecuación 5}$$

El término t_c se refiere al tiempo necesario para que la escorrentía del punto de la subcuenca hidráulicamente más alejado afecte al punto más bajo de la subcuenca, es decir, al punto de salida (ecuación 6). Este tiempo se obtiene calculando el trayecto más largo de un arroyo virtual (L_s) en la cuenca multiplicado por la pendiente media de ese arroyo (J_s).

$$t_c = 0,3 \cdot L_s^{0,76} \cdot J_s^{-0,19} \quad \text{Ecuación 6}$$

Estas fórmulas se obtuvieron gracias a datos recogidos de series cronológicas en diferentes cuencas naturales. Por ello es necesario la incorporación del coeficiente de escorrentía para poder tener en cuenta las diferentes superficies urbanas. Un análisis reciente de las fórmulas de tiempo de concentración más utilizadas en la literatura refuerza que la escogida en la norma se encuentra entre las que menos incertidumbre aporta (Azizian, 2018).

3.2.4.2 Coeficiente de escorrentía

El coeficiente de escorrentía (C) define la cantidad de escorrentía en función de la cantidad de precipitación que se produce en la subcuenca. Esta C está definida por la cobertura superficial del terreno, la permeabilidad del suelo subyacente y la pendiente media de la subcuenca. Con ello se asume que toda la precipitación se produce paralelamente en todo el territorio de la subcuenca,

por lo que se estaría despreciando K_A (ecuación 4). Una caracterización más realista de C , teniendo en cuenta este parámetro se determinó mediante la ecuación 7.

$$C = \frac{\left(\frac{P_d \cdot K_A}{P_0} - 1\right) \cdot \left(\frac{P_d \cdot K_A}{P_0} + 23\right)}{\left(\frac{P_d \cdot K_A}{P_0} + 11\right)^2}, \quad \text{if } P_d \cdot K_A > P_0 \quad \text{Ecuación 7}$$

$$C = 0, \quad \text{if } P_d \cdot K_A \leq P_0$$

Así, el umbral de escorrentía (P_0) es la cantidad mínima de precipitación necesaria para la generación de escorrentía en esa subcuenca. Este umbral de escorrentía depende de un valor inicial de escorrentía (P_0^i) que se puede ajustar si fuera necesario, debido a las diferencias climatológicas de la región respecto al recogido como estándar en la norma. La corrección se lleva a cabo mediante el coeficiente corrector del umbral de escorrentía (β) a través de la ecuación 8.

$$P_0 = P_0^i \cdot \beta \quad \text{Ecuación 8}$$

De esta manera, el valor de la P_0^i viene determinado por una tabla de valores ofrecidos por la Dirección General de Carreteras que esta implementada en el add-in (anexo 1), mientras que β ha de ser calculado a través de datos de precipitación reales de la propia cuenca para diferentes periodos de retorno en comparación con los resultados del método racional. Si no se dispone de esa información, existe la opción, dentro del territorio español, de aplicar dos fórmulas diferentes según la metodología de la norma 5.2IC para la obtención de β . β^{PM} se utiliza para determinar el umbral de escorrentía en la infraestructura auxiliar de las carreteras, mientras que β^{DT} , que es más restrictiva porque minimiza P_0 es utilizada para la propia superficie de la carretera. Puesto que este trabajo tuvo por objetivo simular el peor escenario posible para determinar la peligrosidad potencial de las inundaciones, se aplicó esta segunda opción (ecuación 9).

$$\beta^{DT} = (\beta_m - \Delta_{50}) \cdot F_T \quad \text{Ecuación 9}$$

Los valores de β_m , Δ_{50} y F_T vienen determinados en la tabla 11 del anexo 2 para el período de retorno al que se esté calculando la precipitación y la región en la que se encuentre (anexo 2). Si la cuenca está fuera del territorio peninsular español, se puede determinar estos valores con diferentes aproximaciones. La primera opción y menos recomendada es usar esta metodología sin el factor corrector del umbral de escorrentía. Dada la multitud de diferentes tipos de clima que ofrece la península ibérica, otra alternativa sería utilizar la región española más similar a la climatología de la zona de estudio. Si estas alternativas no son satisfactorias, se deberá optar por una calibración manual de datos y definir nuevos β_m , Δ_{50} y F_T para el caso de estudio concreto o determinar una nueva tabla de P_0^i .

3.2.4.3 Coeficiente de distribución temporal de las precipitaciones

Atendiendo a la forma básica del método racional, este coeficiente de distribución es omitido. No obstante, para una mayor profundización en el uso del método se ha desestimado la hipótesis de tener una distribución temporal de las precipitaciones uniforme. La ecuación 10 muestra cómo se ha calculado, basándose en el tiempo de concentración de la escorrentía (t_c) en la subcuenca:

$$K_t = 1 + \frac{t_c^{1,25}}{t_c^{1,25} + 14}$$

Ecuación 10

Este factor de distribución temporal de las precipitaciones es el último parámetro necesario para calcular la esorrentía mediante el método racional.

3.3 Modelo de predicción del efecto isla de calor urbano

Esta parte de la tesis tiene como objetivo desarrollar un *add-in* llamado ArcUHI para comprender y predecir cómo se manifiesta el efecto isla de calor urbano superficial (SUHI). Para abordar esta tarea, se empleó un enfoque que integra diferentes variables dependientes de la morfología urbana y su relación con un indicador del efecto SUHI como es la diferencia de temperatura superficial (LST por su denominación en inglés: *Land Surface Temperature*). Este trabajo se basa en la recopilación y análisis de datos geoespaciales, el procesamiento de información y el uso de algoritmos de regresión para lograr una comprensión profunda de cómo el efecto SUHI se manifiesta. El método aplicado consta de dos pasos principales: procesamiento de datos y aprendizaje automático (*machine learning*). El primer paso se refiere a la preparación de un conjunto de variables utilizadas para modelar el efecto SUHI, mientras que el segundo se ocupa de su estimación a través de algoritmos de aprendizaje automático. Para el desarrollo del *add-in* ArcUHI, estos pasos requirieron establecer un nexo de comunicación entre ArcGIS y R (R Core Team, 2022) a través del paquete *arcgisbinding* (Esri, 2019), que permite leer y escribir datos geoespaciales de ArcGIS en R y viceversa. La figura 10 muestra una síntesis gráfica de la metodología para construir el *add-in* ArcUHI.

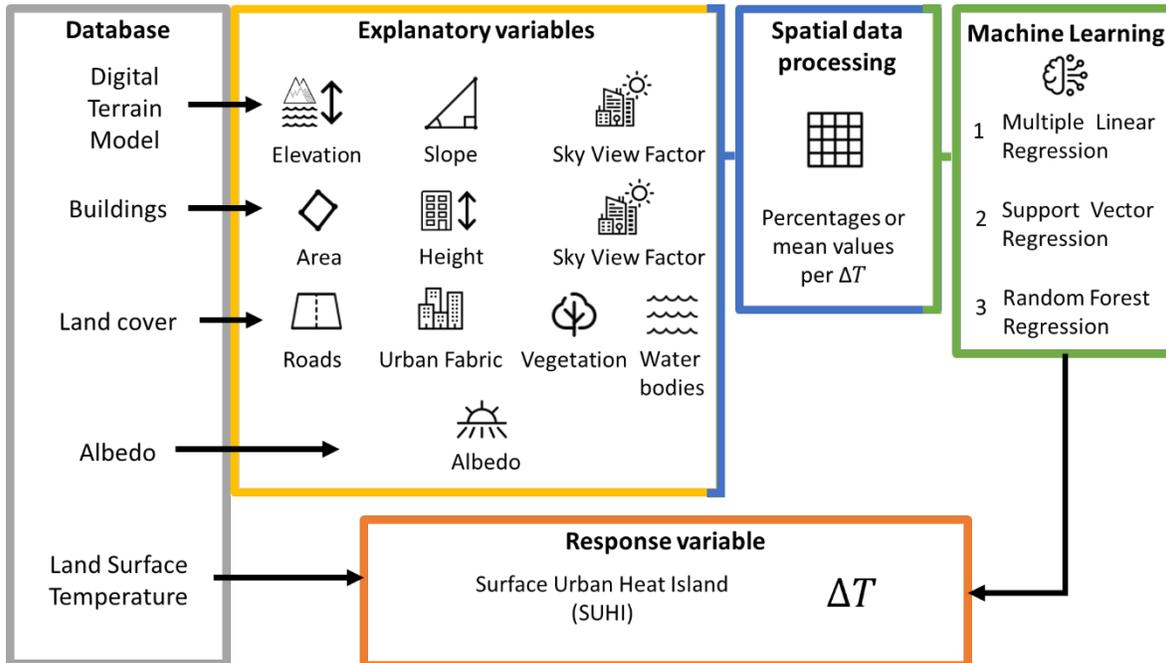


Figura 10. Esquema conceptual del flujo de trabajo para la predicción del efecto SUHI.

Se utilizó la amplitud térmica (ΔT) como indicador del efecto SUHI en toda el área de estudio (Jato-Espino, 2019), definiéndola como la diferencia entre la temperatura media máxima y mínima diaria de la superficie terrestre (LST) (ecuación 11), lo que representa la capacidad para disipar el calor acumulado en las horas de sol (LST_{max}) durante la noche (LST_{min}).

$$\Delta T = LST_{max} - LST_{min} \quad \text{Ecuación 11}$$

A menor valor de ΔT se deduce, por el principio de conservación de la energía, una menor disipación de calor y, por lo tanto, una mayor intensidad del efecto SUHI. Finalmente, el producto de la

modelización de ΔT a partir de una serie de predictores fue un mapa ráster cuyos valores más bajos indican las áreas donde el efecto UHI es más acentuado. A continuación, se proporciona una descripción detallada de cada una de las tareas incluidas en la metodología propuesta.

Para tener en cuenta las diferencias de áreas muy densamente urbanizadas, como la ciudad de Madrid y sus alrededores, se amplió la extensión del caso de estudio. Estas fronteras corresponden aproximadamente a las del área metropolitana de Madrid, que está encerrada dentro de la Comunidad de Madrid, en el centro de la Península Ibérica (figura 5). Esta región incluye 27 municipios con una superficie combinada de casi 2000 km², siendo el hogar de más de 5 millones de personas (INE, 2018)

3.3.1 Procesamiento de datos

El principal impulsor del aumento de la temperatura del aire urbano se debe a los cambios en la superficie terrestre (Rhee et al., 2014; Xiao et al., 2018), mediante los cuales las superficies naturales y seminaturales son reemplazadas por materiales artificiales como carreteras y edificios, cuya presencia aumenta el efecto SUHI a través de alteraciones en los flujos radiativos (Alexander, 2020; Rui Wang et al., 2020). Bajo esta premisa, se seleccionó el conjunto de variables espaciales enumeradas en la tabla 3 para predecir el efecto SUHI. Estos datos también se seleccionaron debido a su replicabilidad, ya que se pueden obtener fácilmente en repositorios de acceso abierto a nivel local, regional o continental. De acuerdo con la frecuencia con la que se crean los mapas de cobertura terrestre, todas estas variables se caracterizaron para tres años diferentes: 2006, 2012 y 2018. Esto permitió determinar no solo los patrones espaciales del efecto SUHI, sino también su evolución con el tiempo.

Tabla 3. Conjuntos de datos espaciales que se necesitan para ejecutar el add-in ArcUHI.

<i>DATO</i>	<i>RESOLUCIÓN / ESCALA</i>	<i>TIPO DE ARCHIVO</i>	<i>VARIABLE</i>
<i>Temperatura superficial terrestre (LST)</i>	500 m	.nc	Gradiente térmico (ΔT)
<i>Modelo Digital de terreno (MDT)</i>	2m/5m	.asc	Elevación del terreno media por pixel de ΔT
			Pendiente media por pixel de ΔT
			Porcentaje medio de Sky View Factor por pixel ΔT *
<i>Construcciones</i>	1:1000	.shp	Altura media de edificios por pixel de ΔT
			Porcentaje de edificios por pixel de ΔT
			Porcentaje medio de Sky View Factor por pixel ΔT *
<i>Albedo</i>	1km	.nc	Albedo medio por pixel ΔT
<i>Mapa Urban Atlas</i>	1:10000	.shp	Porcentaje de carreteras por pixel ΔT
			Porcentaje de tejido urbano por pixel ΔT
			Porcentaje de vegetación por pixel ΔT
			Porcentaje de agua por pixel ΔT
*Calculado a partir de la combinación de MDT y edificios para determinar el sky view factor (SVF)			

El efecto SUHI se determinó a partir de la LST como se formula en la ecuación 11. Los datos de LST se obtuvieron con una resolución de 500 metros por el sensor espectroradiométrico de resolución moderada (MODIS) a bordo de los satélites Terra y Aqua de la NASA (DAAC, 2018). Los valores de la temperatura máxima y mínima diaria promedio durante los meses de verano correspondientes a los tres años considerados se extrajeron utilizando operadores de álgebra de mapas y luego se combinaron en una sola capa de ráster multibanda. Dado que esta era la variable de respuesta, su resolución espacial se tomó como referencia, de modo que las variables explicativas se expresaron por píxel de ΔT (tabla 3). Esta decisión se tomó en concordancia con las conclusiones de Buttstädt y Schneider (Buttstädt & Schneider, 2014), quienes argumentaron que expresar los predictores espaciales como porcentajes era adecuado en áreas de estudio grandes.

La primera variable explicativa considerada fue la elevación del terreno, disponible en el centro de datos del IGN (CNIG, 2023), que la produce mediante interpolación de vuelos LiDAR del Plan Nacional de Ortofotografía Aérea (PNOA). El procesamiento espacial de esta variable implicó el cálculo de la elevación media por píxel de ΔT utilizando herramientas de estadísticas zonales, así como su pendiente media y su orientación correspondiente. Este fue el único dato no disponible para los tres años considerados para el análisis. En su lugar, se tenían dos MDT correspondientes a 2010 (resolución de 5 metros) y 2017 (resolución de 2 metros), que podrían asimilarse a la situación en 2012 y 2018. En cualquier caso, dado que los MDT representan la elevación de la superficie del suelo y omiten áreas urbanizadas como los edificios, no se espera que evolucionen sustancialmente

con el tiempo. No obstante, se analizó la sensibilidad de este dato en sus diferentes resoluciones para descartar que este fuera un factor influyente en la modelización del efecto SUHI.

La Sede Electrónica del Catastro Español (Ministerio de Hacienda y Función Pública, 2023) proporcionó una capa vectorial con la información necesaria para representar los edificios en la zona de estudio y, por lo tanto, tener en cuenta los cambios morfológicos inducidos por la actividad humana. Además de la huella de los edificios, la tabla de atributos de esta capa vectorial incluía campos que indicaban su altura y año de construcción. Después de rasterizar esta información, se calculó la altura media y el área (expresada en porcentaje) de los edificios por píxel de ΔT a través de la herramienta de estadísticas zonales.

Los edificios se rasterizaron con resoluciones de 2 y 5 metros para que coincidieran con el tamaño de celda de los MDT, lo que permitió combinarlos mediante operadores de álgebra de mapas para producir un Modelo Digital de Superficie (MDS). Esto es un requisito previo para calcular el factor de vista del cielo (comúnmente nombrado en la bibliografía como *Sky View Factor* y su acrónimo SVF), que representa la proporción de cielo visible desde un punto de observación. El SVF se calculó utilizando el paquete *horizon* de R (Van Doninck, 2018), que implementa los algoritmos de SVF de Dozier & Frew (1990) para un MDE a partir de una distancia máxima de búsqueda y un número discreto de ángulos de azimut. Estos dos parámetros se configuraron en 100 metros y 16 ángulos, respectivamente, ya que valores más altos no resultan en mejoras significativas en los resultados (Dirksen et al., 2019) y supondrían un aumento sustancial en el coste computacional.

Los datos sobre la proporción de radiación solar reflejada desde las superficies en el área de estudio se incorporaron al modelo a través del albedo. El programa Copernicus proporciona los casos extremos de albedo de cielo negro (ausencia de radiación difusa) y albedo de cielo blanco (ausencia de radiación directa), producidos a partir de datos recopilados a través de los sensores PROVA-V (1998-2014) y SPOT (2014-2020) (European Union & Copernicus Land Monitoring Service, 2020). Ambos tipos de albedo han demostrado producir resultados similares debido a su correlación lineal (Dewan et al., 2021; Peng et al., 2012), lo cual, sumado a que la finalidad del estudio era analizar las diferencias proporcionales del efecto SUHI en el área, llevó a utilizar solo el albedo de cielo negro. Se utilizaron los datos correspondientes a los meses de verano de 2006, 2012 y 2018, promediados mediante álgebra de mapas para obtener un mapa de albedo por año. Luego, los mapas resultantes se volvieron a muestrear mediante interpolación bilineal para ajustarse a la resolución de 500 metros de la variable de respuesta ΔT .

El último dato necesario para modelar el efecto SUHI fue un mapa con la configuración de la cobertura del suelo del área de estudio. Como se mencionó en la

tabla 2, esto se adquirió a través a través del Urban Atlas (European Union & Copernicus Land Monitoring Service, 2023). Entre la clasificación ofrecida por el Urban Atlas, se consideraron las siguientes clases debido a su relevancia en términos de efecto SUHI (Žuvela-Aloise et al., 2016) : tejido urbano (1.1), carreteras (1.2.2), vegetación (1.4, 2 y 3) y agua (4 y 5). Las áreas cubiertas por estas categorías se recortaron utilizando herramientas de extracción, dando lugar a capas separadas que luego se rasterizaron con una resolución de 5 metros. Finalmente, se determinó el porcentaje de celdas cubiertas por tejido urbano, carreteras, vegetación o agua por píxel de ΔT utilizando estadísticas zonales. Una vez que se prepararon todas las variables involucradas en la caracterización del efecto SUHI, el siguiente paso fue utilizarlas para construir modelos para su estimación.

Como análisis exploratorio previo a la modelización predictiva a través del aprendizaje automático, se calculó una matriz de correlación para mostrar la asociación entre las variables enumeradas en la tabla 3 utilizando el coeficiente de correlación de Pearson (Kirch, 2008). La presencia de relaciones estadísticamente significativas se determinó comparando el valor p del coeficiente de correlación con un nivel de significancia (α) de 0,05 (R. A. Fisher, 1992). Los valores de rho (ρ) de Pearson se calcularon y representaron en R con el apoyo de las funciones *cor* y *ggcorrplot* (Kassambara, 2019), respectivamente.

3.3.2 Machine learning

El objetivo en este paso fue determinar los valores de ΔT derivados de las mediciones satelitales de LST a partir de la combinación de las variables explicativas en la tabla 1. Estudios previos han destacado la naturaleza compleja de las relaciones entre la forma urbana y las variaciones de LST, recomendando el uso de métodos no lineales para su modelización (K. Liu et al., 2019; Shatnawi & Abu Qdais, 2019; Sun et al., 2019).

Por esta razón, este paso se abordó con el apoyo de algoritmos de aprendizaje automático no lineales como la Regresión de Vectores de Soporte o *Support Vector Regression* (SVR) y la Regresión de Bosques Aleatorios o *Random Forest Regression* (RFR). Sin embargo, también se utilizó la Regresión Lineal Múltiple o *Multiple Linear Regression* (MLR) como referencia para facilitar la comprensión de las relaciones entre ΔT y las variables de cobertura del suelo y elevación. Los algoritmos de aprendizaje profundo basados en redes neuronales no se consideraron debido a su menor idoneidad para este conjunto de datos, ya que su uso se recomienda para problemas complejos que involucran reconocimiento de voz, procesamiento de lenguaje natural o clasificación de imágenes (Alshemali & Kalita, 2020; Montavon et al., 2018). Además, las redes neuronales a menudo se denominan "cajas negras" debido a las dificultades para su interpretación comprensible desde el punto de vista de la lógica humana (Sheu, 2020).

3.3.2.1 Multiple Linear Regression

La *Multiple Linear Regression* (MLR) se utiliza para ajustar las relaciones entre una serie de variables explicativas o predictores y una variable de respuesta utilizando una ecuación lineal (Bottyán & Unger, 2003; Sussman et al., 2021). En este caso, la respuesta fue la amplitud térmica ΔT , como se define en la ecuación 11, mientras que los predictores fueron los factores que representaban la topografía, características de las construcciones antropogénicas, la reflectancia y la cobertura del terreno (tabla 3). En términos matemáticos, los modelos generados por la MLR se formulan como

se expresa en la ecuación 12, donde y es la variable respuesta, x_i son las variables explicativas, b_i son los coeficientes de regresión asociados con las variables explicativas, N es el número de observaciones en el conjunto de datos y e son los residuos del modelo. Estos últimos representan la distancia entre la línea de regresión y los valores observados, de modo que la MLR busca minimizar la suma cuadrática residual mediante el cálculo de los coeficientes de regresión.

$$y = b_0 + b_1 \cdot x_1 + b_2 \cdot x_2 + \dots + b_N \cdot x_N + e \quad \text{Ecuación 12}$$

El interés en utilizar MLR como modelo básico o inicial radica en su alta interpretabilidad y baja exigencia computacional en comparación con otros métodos (H. D. Nguyen et al., 2021). Sin embargo, su capacidad predictiva puede ser insuficiente para tener en cuenta la naturaleza de las relaciones entre ΔT y los predictores propuestos, que pueden ser no lineales. Este hecho también puede conducir a transgredir algunas de las suposiciones de la MLR (Osborne & Waters, 2019), invalidando así el uso del modelo construido mediante este método.

El cálculo de la MLR en R se realizó utilizando el paquete *e1071* (Meyer et al., 2022) a través de la función *lm*. Además, se utilizó la función *vif* del paquete *car* (Fox & Weisberg, 2011) para cuantificar la intensidad de la multicolinealidad entre las variables explicativas a través del Factor de Inflación de la Varianza (FIV) (Salmeron et al., 2018). Los valores alcanzados por los predictores con respecto a este parámetro ayudaron a determinar cuáles de ellos contribuyeron más a explicar la varianza en la variable respuesta.

3.3.2.2 Support Vector Regression (SVR)

En previsión de que el poder predictivo de la MLR pudiera ser insuficiente para ajustar la ΔT a partir de los predictores propuestos, se utilizó la *Support Vector Regression (SVR)* para tener en cuenta las relaciones no lineales entre estas variables. Para ello, la línea recta requerida en la MLR para ajustar los datos se convierte en un hiperplano. En el caso de la SVR, el objetivo es encontrar el hiperplano que maximice un margen de tolerancia ε , de manera que se minimice el error entre los valores medidos y los predichos (El Kenawy et al., 2020). Esto se puede formular como se muestra en la ecuación 13.

$$\min \frac{1}{2} \|w\|^2 + C \sum_1^N (\xi_i^+ + \xi_i^-)$$

$$\text{En función de: } y_i + wx_i - b \leq \varepsilon + \xi_i^+ \quad \text{Ecuación 13}$$

$$wx_i + b - y_i \leq \varepsilon + \xi_i^-$$

$$\xi_i^+, \xi_i^- \geq 0$$

En este *contexto*, w es el vector de coeficientes normales al hiperplano de regresión, b es la intercepción, y_i y x_i representan las variables de respuesta y explicativas, respectivamente, ξ_i^+ y ξ_i^- son los errores o desviaciones desde el margen de tolerancia ε , N es el número de observaciones en el conjunto de entrenamiento y C se refiere a un parámetro de regularización que representa el equilibrio entre alcanzar un bajo error en los datos de entrenamiento y minimizar $\|w\|$ la SVR utiliza funciones de *kernel* para construir el modelo de predicción. Esto incluye funciones lineales, polinómicas, sigmoides y radiales. El tipo de función de *kernel* a utilizar, así como los *valores de coste, gamma, grado y epsilon*, son los parámetros que se pueden ajustar en la SVR. La función

tune en el paquete R *e1071* (Meyer et al., 2022) permite determinar estos valores, así como construir el modelo de SVR a través de la función *svm*.

En relación con la MLR, la principal ventaja de la SVR es su capacidad para modelar relaciones complejas y no lineales entre las variables mediante la transformación del espacio original con dimensiones $N * M$ en un nuevo espacio con dimensiones $N * N$, donde M es el número de variables (De Gregorio et al., 2018). La SVR también proporciona una alta capacidad de generalización (Behzad et al., 2009). Sin embargo, la transformación de *kernel* diluye la información contenida en los datos originales y dificulta la interpretación de los resultados (Üstün et al., 2007). Además, la SVR no se recomienda para conjuntos de datos grandes, ya que el almacenamiento de la matriz de *kernel* requiere mucha memoria si el número de observaciones es alto (Rahimi & Recht, 2007).

3.3.2.3 Random Forest Regression (RFR)

Como alternativa a la SVR, se utilizó otro algoritmo de aprendizaje supervisado llamado *Random Forest Regression* (RFR) para modelar el efecto SUHI. La RFR construye modelos de regresión en forma ramificada y jerárquica (forma de árbol), donde el conjunto de datos se divide en subconjuntos cada vez más pequeños para predecir una variable de respuesta mediante el aprendizaje de reglas de decisión (Breiman et al., 1984). Estos árboles se combinan mediante agregación de *bootstrap* o *bagging*, de modo que cada modelo se ejecuta de forma independiente y las salidas correspondientes se fusionan para lograr predicciones más precisas (Breiman, 1996).

El proceso comienza seleccionando n muestras de k observaciones aleatorias de un conjunto de datos de entrenamiento. Luego, se construyen árboles de decisión individuales para cada muestra. Estos n árboles se ejecutan en paralelo para generar resultados separados, cuyo promedio produce la predicción final buscada. El valor predicho y_i proporcionado por el árbol i en la observación j se puede denotar como una función de (j, x_i, k) , donde x_i son los predictores seleccionados aleatoriamente de la muestra de k observaciones. Por lo tanto, la predicción promedio $y_{n,j}$ derivada de la agregación de los árboles se puede expresar mediante la ecuación 14.

$$y_n(j, x_i, k) = \frac{1}{n} \sum_{i=1}^n y_i(j, x_i, k) \quad \text{Ecuación 14}$$

El algoritmo de selección aleatoria en la RFR evita que los árboles de decisión hagan un sobreajuste, ya que no manejan todo el conjunto de datos (Huynh-Thu & Geurts, 2019). Además, el algoritmo aleatorio, ramificado y jerárquico selecciona un subconjunto de variables que pueden actuar como predictores en cada árbol, resolviendo así problemas de correlación al asegurarse de que no todos los árboles recurran a las mismas variables (Au, 2018). Solventado este problema de desviación por el muestreo, el único inconveniente de RFR radica en sus altas demandas computacionales (Cichosz & Pawełczak, 2014).

La RFR se implementó en R a través del paquete *randomForest* (Liaw & Wiener, 2002), que implementa el algoritmo desarrollado originalmente por Breiman, 2001 en código Fortran, incluyendo varios parámetros que se pueden ajustar para un mejor rendimiento. Este estudio se

centró en la sintonización de dos parámetros: el número de árboles (*ntree*) y el número de variables muestreadas al azar en cada división (*mtry*). Estos parámetros se determinaron con el apoyo de la función *tuneRF*, que busca el valor de *mtry* que minimiza la estimación del error *Out-Of-Bag* (OOB). Esto, a su vez, se calcula utilizando predicciones de los árboles sobre muestras que no se encuentran en sus respectivas selecciones.

3.3.3 Preparación de datos y poder predictivo

Las variables presentes en la tabla 3 fueron estandarizadas antes de construir las MLR y SVR descritas anteriormente. La estandarización se llevó a cabo restando la media y dividiendo por la desviación estándar de los valores de cada variable (Meyer et al., 2022). Este paso fue particularmente necesario en el caso de la SVR, ya que es un algoritmo basado en la distancia que es más sensible a las diferencias en las escalas de las métricas (Graf et al., 2003). En cambio, la RFR se basa en algoritmos de particionamiento que no se ven afectados por problemas de escala (Menze et al., 2009).

Una vez preprocesado, el conjunto de datos se dividió en conjuntos de entrenamiento y testeo en una proporción de 70:30, una relación que se ha utilizado previamente para modelar el efecto UHI (Hidayat & Soekirno, 2021; Khalil et al., 2021; A. Khan et al., 2020). Luego, cada subconjunto se muestreó en función de un proceso de validación cruzada *k-fold*, que consiste en dividir las observaciones en *k* grupos para estimar el rendimiento de los modelos al realizar predicciones sobre datos que no se utilizaron para el entrenamiento (James et al., 2013). Esto se llevó a cabo utilizando la función *trainControl* de R (Kuhn, 2015), que permite tomar cada grupo como un subconjunto de test y los restantes como el subconjunto de entrenamiento sistemáticamente, de manera que el modelo se ajuste con estos últimos y se evalúe en el primero. Basándose en las recomendaciones encontradas en la literatura y en consideraciones computacionales, se estableció un valor de *k* igual a 5 (Marcot & Hanea, 2021).

La influencia de las variables en los modelos se evaluó de manera diferente en cada caso. En lo que respecta al algoritmo base (MLR), las variables explicativas se seleccionaron paso a paso según sus *p*-valores. Además, se determinó el Factor de Inflación de la Varianza (VIF) para tener en cuenta la multicolinealidad. Por lo tanto, aquellas variables que demostraron carecer de significancia estadística y/o tener valores de VIF superiores a 5 (J. H. Kim, 2019) se excluyeron de todos los modelos debido a sus interrelaciones con otras variables explicativas.

En cuanto a los otros dos modelos, se seleccionaron variables según su importancia. Los efectos de las variables explicativas en la SVR se evaluaron a través de la función *Importance* en el paquete *rminer* de R (Cortez, 2016), que se basa en un análisis de sensibilidad (Cortez & Embrechts, 2013). En cambio, este aspecto se evaluó en la RFR utilizando el método de importancia de características de permutación. Consiste en calcular la disminución en la precisión del modelo cuando se modifican aleatoriamente los valores de una sola característica (Breiman, 2001). Cuanto mayor sea el aumento en la raíz del error cuadrático medio (RMSE), más depende el modelo de una variable (A. Fisher et al., 2019).

Siguiendo las recomendaciones de Chicco et al., 2021, quienes destacaron las limitaciones de usar una sola medida de ajuste, la precisión de las predicciones devueltas por los modelos se midió a

través de dos métricas: el coeficiente de determinación (R^2) y RMSE. R^2 indica la proporción de la varianza en la variable de respuesta (en este caso, ΔT) que se explica por las otras variables, mientras que RMSE tiene en cuenta el error de predicción entre los valores observados y estimados. Siguiendo los enfoques utilizados para determinar la importancia de las características de la SVR y la RFR, se realizó un análisis de sensibilidad de las variables relevantes incluidas en el modelo que proporcionó los mejores valores de R^2 y RMSE. En particular, se utilizó el método del perfil de Lek (Gevrey et al., 2003; Lek et al., 1996) para este propósito. Este método busca obtener predicciones de la variable de respuesta en el rango de valores de cada variable explicativa, mientras se mantienen constantes las otras. Esto se implementó en R a través de la función *lekprofile* en el paquete *NeuralNetTools* (M. W. Beck, 2018).

3.4 Índice de vulnerabilidad urbana

Para poder estimar un índice de vulnerabilidad que manifieste las áreas con mayores desigualdades en la ciudad se utilizaron datos desagregados de las 146 secciones censales que conforman la ciudad de Santander. Estos datos fueron adquiridos del Instituto Nacional de Estadística (INE) de España y del gobierno de la Comunidad Autónoma de Cantabria (Gobierno de Cantabria, 2021; INE, 2011b, 2015). En total, se recopilaron y organizaron 159 variables siguiendo clasificaciones de estudios previos que fueron seleccionadas en función del número de citas y fecha de publicación. Posteriormente, se utilizó un Análisis de Componentes Principales (PCA) para analizar y reducir el número de variables, seleccionando aquellas con mayor variabilidad espacial. A continuación, se utilizó una suma ponderada para mapear la vulnerabilidad basada en estas variables de forma conjunta y se finalizó combinando este conjunto con un mapa de peligrosidad de inundaciones de la misma zona de estudio. La figura 11 muestra el flujo de trabajo.



Figura 11. Diagrama de flujo de la metodología aplicada para estimar un índice de vulnerabilidad.

3.4.1 Recopilación de datos de entrada

Se utilizaron dos bases de datos para crear clasificaciones demográficas y socioeconómicas, seleccionando los datos en función de su disponibilidad en el momento del estudio. Aproximadamente cada 10 años, el INE publica datos sobre la condición demográfica, cultural, económica y social de los habitantes de España (INE, 2011a, 2011b). Este estudio se basa en la versión de 2011 de estos datos, que desagrega la población por sexo, edad, educación, características familiares, etc. Además, se utilizaron datos sobre la distribución de ingresos para los años 2015 y 2016 con la misma resolución espacial, también obtenidos del INE, que contienen información económica de los ciudadanos (INE, 2011a, 2015). Surgieron dos incongruencias en la distribución de dos secciones censales debido a una división de una sección censal del 2011 en la fuente de datos del 2018 que se resolvieron fusionando las respectivas secciones censales posteriores. No fue necesario ningún tratamiento debido a que, aunque se observaron pequeñas variaciones en los valores de ciertas variables a lo largo del tiempo, se esperaba que la proporción de valores en las secciones censales fuera estable.

Además, se utilizaron datos georreferenciados de acceso abierto de las infraestructuras críticas de la ciudad relacionadas con la salud, educación, cultura y la gobernabilidad de la región de Cantabria (Gobierno de Cantabria, 2021). Se verificó la ausencia de tramos temporales vacíos de los datos. Estas fuentes de datos (tabla 4) se utilizaron para la selección inicial de variables para determinar la vulnerabilidad a inundaciones de las secciones censales.

Tabla 4. Fuentes de datos utilizadas en para el desarrollo del índice de vulnerabilidad.

<i>DATOS</i>	<i>TIPO DE ARCHIVO</i>	<i>REFERENCIA</i>
<i>Demográficos y socioeconómicos</i>	.shp	(INE, 2011b, 2016)
<i>Económicos</i>	.shp	(INE, 2011a, 2015)
<i>Infraestructuras</i>	.shp	(Gobierno de Cantabria, 2021)

Se seleccionaron variables para calcular la vulnerabilidad utilizando literatura clave sobre índices demográficos y socioeconómicos, como por ejemplo el trabajo de Cutter et al. (2006). El cual, posteriormente fue adaptado a otros países y entornos socioeconómicos (Guillard-Gonçalves et al., 2015). De forma paralela, se agregaron una serie de variables relacionadas con infraestructuras críticas que son necesarias para el funcionamiento normal de la ciudad y algunas otras que son susceptibles a inundaciones, como las instalaciones subterráneas de estacionamiento de vehículos.

3.4.2 Clasificación, selección y correlación

Las variables seleccionadas se dividieron en tres clases, que posteriormente se cotejaron con las variables utilizadas por otros autores para las clases demográficas y socioeconómicas (tabla 5). En el caso de la clase de infraestructuras, no se encontraron índices de vulnerabilidad a inundaciones que utilizaran estas variables. Sin embargo, las infraestructuras que son susceptibles a inundaciones y pueden dificultar el funcionamiento normal de la ciudad (Golz et al., 2016; Ruiz & Rajib, 2022) se incluyeron como la tercera clase del estudio de vulnerabilidad.

Tabla 5. Variables iniciales seleccionadas que afectan a la vulnerabilidad frente a las inundaciones urbanas cruzado con otros autores y organizadas en tres clases. El código es utilizado en figuras posteriores.

CLASE	CÓDIGO	DESCRIPCIÓN	BIBLIOGRAFÍA RELACIONADA
Demográfica	Tot_Pop	Población Total	(Guillard-Gonçalves & Zêzere, 2018; Méndez-Lázaro et al., 2018; Tate, 2012)
	Density_Pop	Densidad de población	(Frigerio & De Amicis, 2016; Méndez-Lázaro et al., 2018; Török, 2018)
	<16	Nº de personas menores de 16 años	(Cutter et al., 2000; Frigerio & De Amicis, 2016; Guillard-Gonçalves & Zêzere, 2018; X. T. Luo et al., 2021)
	>64	Nº de personas mayores de 64 años	(Cutter et al., 2000; Frigerio & De Amicis, 2016; Guillard-Gonçalves et al., 2015; Karunarathne & Lee, 2020; X. T. Luo et al., 2021; Tate, 2012; Török, 2018)
	<16 >64	Nº de personas menores de 16 años y personas mayores de 64 años	(Cutter, et al., 2000; Guillard-Gonçalves et al., 2015)
	Non_Spa	Nº de extranjeros	(Frigerio & De Amicis, 2016; Guillard-Gonçalves et al., 2015)
	Home=1	Nº de familias unifamiliares	(Frigerio & De Amicis, 2016; Wisner et al., 2004)
	Home>5	Nº de familias con más de 5 miembros	(Frigerio & De Amicis, 2016; Wisner et al., 2004)
	Prsn_Home	Media de personas por familia	(Guillard-Gonçalves et al., 2015; Török, 2018)
	Mean_age	Edad media	(Guillard-Gonçalves et al., 2015; Tate, 2012)
Socioeconómica	Studies_no	Nº de analfabetos o sin graduado escolar	(Guillard-Gonçalves et al., 2015; Méndez-Lázaro et al., 2018; Tate, 2012; Török, 2018)
	Inc_mean_pers	Renta media por persona	(Cutter, et al., 2000; Tate, 2012; Török, 2018; Wood et al., 2021)
	Inc_mean_hgr	Renta media por familia	(Cutter et al., 2000; Karunarathne & Lee, 2020; Méndez-Lázaro et al., 2018)
	Inc_mean_udc	Renta media por unidad de consumo	(Cutter et al., 2000)
	Inc_median_udc	Renta Mediana por unidad de consumo	(Cutter et al., 2000)
	Poverty_threshold	% de población con una renta inferior al 60% de la mediana	(Cutter et al., 2000; Tate, 2012)
	Non_married	Nº de solteros	(Dalu & Shackleton, 2018)
	Rent&Mortgage	Nº de viviendas en renta o con hipoteca	(Mudasser et al., 2020; Tate, 2012)
	< 90sqm	Nº de familias en viviendas de menos de 90m ²	(Bigi et al., 2021; Chakraborty et al., 2020)

Tabla 5. (Continúa)

CLASE	CÓDIGO	DESCRIPCIÓN	BIBLIOGRAFÍA RELACIONADA
Infraestructuras	Residential	Nº de hogares	(Mudasser et al., 2020; Tate, 2012; Wood et al., 2021)
	House_1st	Nº de hogares principales	-
	House_2nd	Nº de hogares secundarios	-
	House_Emp	Nº de viviendas vacías	-
	Room<3	Nº de viviendas con menos de 3 habitaciones	-
	Room>3	Nº de viviendas con más de 3 habitaciones	-
	Health	Nº de hospitales y centro de salud	(Guillard-Gonçalves et al., 2015; Méndez-Lázaro et al., 2018)
	Parking	Nº de aparcamientos subterráneos	-
	Cult	Nº de museos monumentos y edificios de interés cultural	-
	Educ	Instalaciones y centros de Educación	(Eini et al., 2020)
	Gov	Instalaciones y centros de la administración pública	-

Después, se aplicó un análisis de correlación y el PCA para reducir el número inicial de variables a las más impactantes y relevantes. Se utilizó un coeficiente de correlación de 0,75 como umbral mínimo para indicar una relación fuerte o muy fuerte entre variables (Akoglu, 2018). Para aquellas variables que alcanzan el umbral, se estudió la relación lógica entre ellas. En el caso de que dos variables describieran el mismo aspecto o grupo de habitantes, se descartaron para evitar una duplicidad y posterior sobreponderación de la vulnerabilidad de ese grupo.

3.4.2.1 Clasificación demográfica

Las características demográficas son determinantes en la vulnerabilidad a las inundaciones (Donner & Rodríguez, 2008). Esta clase representa características que explican la estructura de las comunidades que viven en un lugar y tiempo determinados. La estructura se entiende como las características de la población, incluyendo la cantidad, la edad y otras. El censo realizado por el INE define y delimita las variables demográficas, asegurando su claridad y permitiendo un razonamiento posterior. Por ejemplo, familia se define como un grupo de personas que conviven en una vivienda y están unidas por lazos de sangre o acuerdos de pareja, y conforman un hogar único. Un hogar se define como un grupo de personas que residen en una sola vivienda, sin necesidad de parentesco. Un término propenso a causar confusión es el grupo denominado extranjeros, que se refiere a personas que no tienen la nacionalidad española. Por lo tanto, es posible que una persona obtenga la nacionalidad española y, por lo tanto, deje de pertenecer al grupo de personas extranjeras.

3.4.2.2 Clasificación socioeconómica

Esta clase se definió como las condiciones de los habitantes relacionados con los recursos que tienen disponibles para hacer frente a un peligro y reducir su impacto. Se evalúan recursos sociales como la educación o las relaciones interpersonales, y recursos económicos como los ingresos o la propiedad de vivienda. La educación y los recursos económicos son variables clave que son importantes antes, durante y después de un peligro. “Antes” tiene que ver con la optimización de la protección material y personal a través de interacciones sociales que contribuyen a una mejor organización de la población, o una mejor interpretación de la información de seguridad provista por las autoridades competentes. “Durante” se refiere a la gestión eficiente de los recursos disponibles para afrontar el peligro. “Después” se trata de volver a la normalidad en el menor periodo de tiempo posible.

Por lo tanto, existen variables como el grupo de personas que no saben leer ni escribir o que no han completado la educación primaria que se fusionaron en una sola variable para poder comparar con estudios anteriores. Se tomó la misma prescripción para agrupar todas las viviendas de menos de noventa metros cuadrados en una sola variable. Otra variable en esta clase con una terminología específica es la unidad de consumo, un término que se utiliza para hacer una mejor comparación de la economía de un hogar. El número de unidades de consumo se calcula utilizando una escala modificada de la Organización para la Cooperación y el Desarrollo Económicos (OCDE), que otorga un peso de 1 al primer adulto, un peso de 0,5 a los demás adultos y un peso de 0,3 a los niños menores de 14 años. Una vez calculado el ingreso por unidad de consumo del hogar, se asigna por igual a cada miembro del hogar.

3.4.2.3 Clasificación de infraestructuras

Esta clase fue creada para tener en cuenta edificios o instalaciones donde se realizan servicios básicos dentro de una ciudad. Estos incluyen edificios residenciales donde viven los habitantes, que sirven como refugios en caso de inundaciones, y otros que son necesarios para el funcionamiento normal de la ciudad, como centros de salud, educación o gobierno municipal. Además, se agregó a esta categoría las infraestructuras adicionales que pudieran resultar seriamente dañadas por las inundaciones, como estacionamientos subterráneos, debido también al potencial valor de los vehículos que podrían estar en estas instalaciones.

3.4.3 Cálculo de la vulnerabilidad espacial

Este cálculo de la vulnerabilidad se realizó mediante un PCA, que es un procedimiento estadístico para reducir la dimensionalidad de los datos a un conjunto de variables sintéticas no correlacionadas llamado "componentes principales" que explican la mayor parte de la variabilidad encontrada en los datos originales (Abdi & Williams, 2010; Hotelling, 1933). Cada componente principal está compuesto por las sumas de coeficientes de las variables originales, que las transforman en variables que explican un porcentaje particular de la variabilidad total (Jolliffe & Cadima, 2016). Estos componentes principales se ordenan de mayor a menor importancia para la explicación de la variabilidad.

El PCA ayuda a identificar las variables que causan variabilidad en los componentes principales más importantes. Por lo tanto, puede reducir la dimensionalidad con una pérdida mínima de información (Abson et al., 2012). Además, esta información se puede utilizar para definir el peso de cada variable

con el fin de agregarlas en un índice. Para este estudio, se utilizó la suma de los componentes principales mínimos necesarios para explicar al menos el 50% de la variabilidad acumulada como criterio de selección.

Después de identificar las variables que contribuyen más a los componentes principales, se realizó un razonamiento crítico basado en las 2 dimensiones principales del PCA. El propósito de este análisis es agrupar variables que pueden tener alguna relación en su variabilidad y sugerir las razones que pueden explicar este patrón.

3.4.4 Suma ponderada y mapeo de subíndices

Los pesos para las variables seleccionadas en cada clase se calcularon mediante la suma ortogonal de las cargas absolutas de cada una de las variables en cada componente principal en su forma normalizada (Lebart et al., 1995; Yue & Tomoyasu, 2004). La suma ortogonal se realiza siguiendo la definición de los componentes principales del PCA, asumiendo que las contribuciones de cada componente principal no están correlacionadas. La ecuación 15 es una expresión modificada de la correlación entre un componente y una variable a través del concepto de peso o ponderación (Abdi & Williams, 2010). El coeficiente de varianza de los componentes principales se utilizó para dar más importancia a las variables que tenían una mayor variabilidad espacial entre las secciones censales. Además, como condición, solo se incluyeron variables dentro de cada componente principal que estuvieran por encima de la contribución esperada de la importancia homogénea de las variables. Los pesos de las variables se normalizaron para cada clase. Estos pesos se multiplicaron por los valores normalizados de las secciones censales para obtener el mapa del subíndice de cada clase.

$$\text{Importancia de la variable} = \sqrt{\sum_{i=1}^n (|x_i| \cdot w_i)^2}, \text{ where } \sum w_i = 1$$

i: Dimensión de la componente principal

Ecuación 15

n: N° de dimensiones de componente principal

x: Contribución de la variable en la componente principal

w: Principal component explained variance

3.4.5 Test de sensibilidad

Se utilizaron cuatro escenarios de ponderación de los mapas de los subíndices para testear la sensibilidad de los pesos de las clases al combinarse, donde se representan pesos iguales (W1) y tres combinaciones de pesos (W2, W3, W4) en las que una clase recibe pesos más altos que las otras dos (tabla 6). Después de verificar la consistencia de los resultados obtenidos en la prueba de sensibilidad, se combinó el mapa de vulnerabilidad con el índice de peligrosidad de inundación obtenido para la misma ciudad con la metodología del apartado 3.2. La multiplicación de los índices de ambos estudios produjo un índice de riesgo de inundación para la ciudad (Kumpulainen, 2006; UNISDR, 2009). Debido a que el mapa de vulnerabilidad y el mapa de peligro no coinciden

completamente en su extensión, el mapa de riesgo resultante cubrió solo las áreas donde ambos coincidieron espacialmente, que es ligeramente diferente al área del mapa de vulnerabilidad de este estudio.

Tabla 6. Escenarios propuestos para las pruebas de sensibilidad en la combinación de las diferentes clases de vulnerabilidad.

<i>ESCENARIO/CLASE</i>	<i>PONDERACIÓN</i>		
	<i>Demográfica</i>	<i>Socioeconómica</i>	<i>Infraestructuras</i>
W1	1/3	1/3	1/3
W2	2/3	1/6	1/6
W3	1/6	2/3	1/6
W4	1/6	1/6	2/3

4 Resultados y discusión

Este capítulo explora los resultados obtenidos y culmina con una discusión sobre sus implicaciones. La interacción entre el análisis detallado y la visión global se hace patente, revelando cómo las herramientas de modelización espacial pueden ser aplicadas eficazmente en entornos urbanos. Además, enfatiza el impacto práctico de esta tesis en el campo de la sostenibilidad urbana, reflejando el potencial transformador de las soluciones basadas en la naturaleza y mostrando su impacto en la mitigación de los riesgos ambientales.

4.1 Modelo hidrológico urbano

Este apartado presenta los resultados del modelado hidrológico aplicado al caso de estudio en Santander, obteniendo finalmente un mapa de escorrentía máxima acumulada. Para ello se diseñó un complemento o *add-in* que facilita su aplicación siguiendo las directrices explicadas en el apartado 3.2 y que se ilustra en la figura 12. Posteriormente se propuso una simulación de escenarios de mitigación, destacando la sustitución estratégica de superficies construidas para reducir la escorrentía.

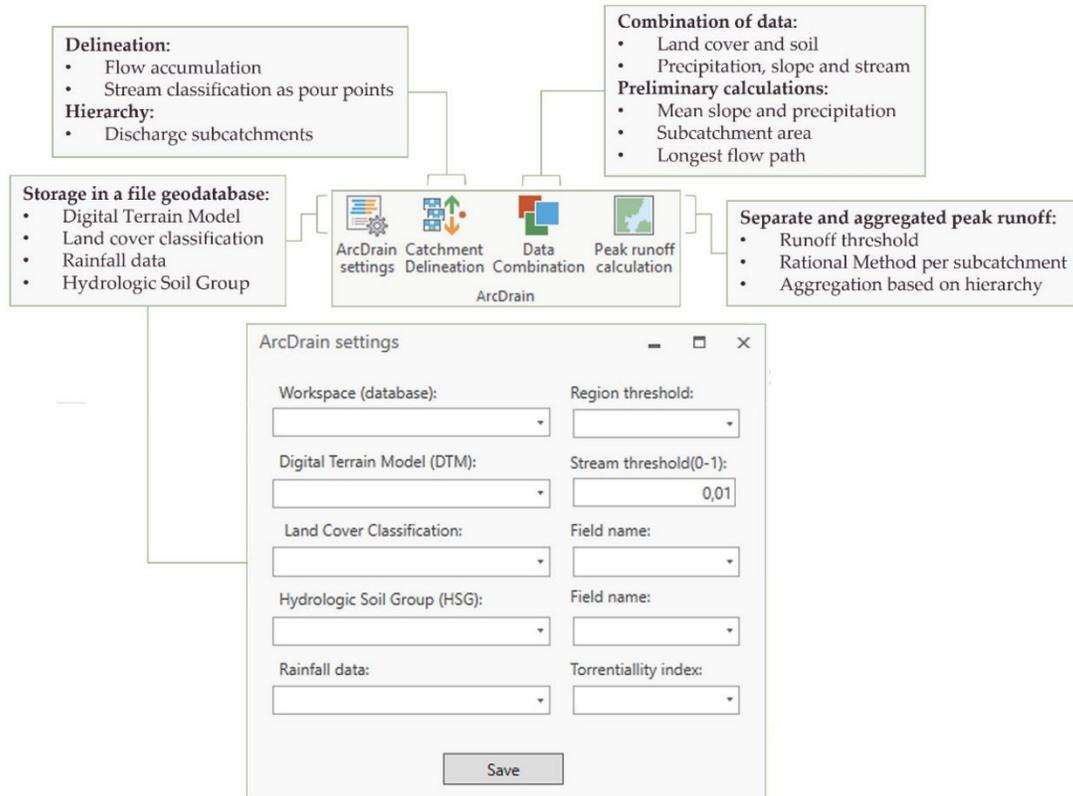


Figura 12. Resumen de las principales fases del add-in ArcDrain.

4.1.1 Tratamiento de datos de entrada

El caso de estudio y sus fuentes de datos principales pretratadas para la fase inicial del modelado expuesto en el apartado 3.2.1 e ilustrado en la figura 13. El Modelo Digital de Terreno (MDT) se obtuvo del Instituto Geográfico Español (IGN), con una resolución de 5 metros, a través de la interpolación de datos de vuelos LiDAR del Plan Nacional de Ortofotografía Aérea CNIG, (2023). Este MDT utiliza el sistema de referencia ETRS89 y se proyecta en la zona UTM 30N, con altitudes ortométricas. En cuanto a la tipología del suelo, se buscó mejorar su nivel de información mediante la evaluación del mapa litoestratigráfico creado por el Instituto Geológico y Minero de España (IGME) (del Pozo Gómez, 2009) y disponible a través del portal de información georreferenciada del Gobierno de Cantabria (Gobierno de Cantabria, 2021), relacionando sus características de composición de suelo con su grupo hidrológico. La cobertura de suelo fue

proporcionada por el Urban Atlas a escala 1:10.000 (European Union & Copernicus Land Monitoring Service, 2023).

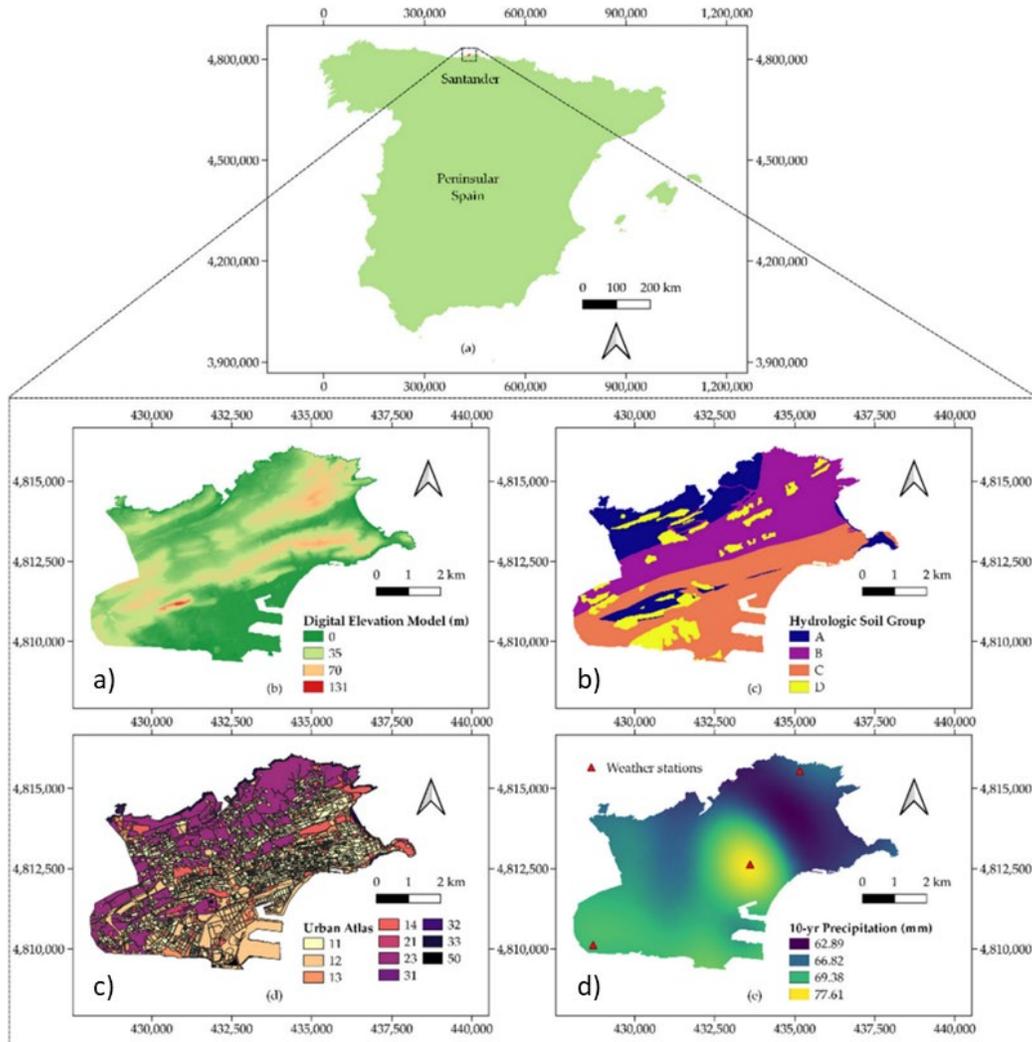


Figura 13. Localización del caso de estudio de la ciudad de Santander y datos de entrada de ArcDrain, (a) mapa de situación de la ciudad de Santander, (b) modelo digital de elevación (MDE), (c) grupo hidrológico del suelo (HSG), (d) mapa de cobertura del suelo del atlas urbano, y (e) precipitación máxima diaria para un periodo de retorno de 10 años.

Por último, el dato de precipitación fue la entrada que requirió más trabajo de preprocesamiento, ya que se generó a partir de una cuadrícula de 1 km² con valores de precipitación diaria en toda Cantabria (Gutiérrez Llorente et al., 2010), la región de la cual Santander es la capital. Esta cuadrícula se obtuvo a partir de 148 estaciones meteorológicas distribuidas por toda la zona, con registros entre 1950 y 2003. Los datos resultantes se ajustaron según una lista de funciones de probabilidad para obtener valores de precipitación máxima anual, que luego se interpolaron espacialmente mediante *kriging* simple para producir el mapa representado en la figura 13e (Jato-Espino & Pathak, 2021). La distribución no uniforme y limitada de las estaciones en Santander explica la forma del mapa de precipitación. Además, el máximo encontrado en el centro de la ciudad coincide con los

hallazgos de Baik et al. (2001) y J.-Y. Han et al. (2014), quienes argumentaron que las zonas urbanizadas pueden aumentar la precipitación a través de un incremento de la convección.

4.1.2 Cálculo de escorrentía acumulada

El MDE fue la capa base empleada para generar una variedad de salidas intermedias previas al cálculo del área de captación utilizando el botón *Catchment delineation* (figura 14), que ejecuta el procedimiento de delineación y jerarquización de las subcuencas del apartado 3.2.2. El proceso de rellenar las depresiones en el MDE con la herramienta *Fill* reveló la influencia de algunos cuerpos de agua, como el lago artificial del parque Las Llamas, cuya presencia derivó en algunas inconsistencias en términos de dirección de flujo. Como tal, la capa original del MDE fue delimitada dejando fuera la ubicación de estos cuerpos de agua para evitar estos errores. La omisión de las masas de agua en relación a la figura 13b se puede observar en algunas regiones del sur y centro-este en el mapa de pendiente representado en la figura 15a. El aspecto del mapa de acumulación de flujo indicó la sensibilidad de la zona ampliada en la figura 15b, que era especialmente susceptible a recibir grandes volúmenes de escorrentía debido a la topografía de la vertiente aguas arriba.

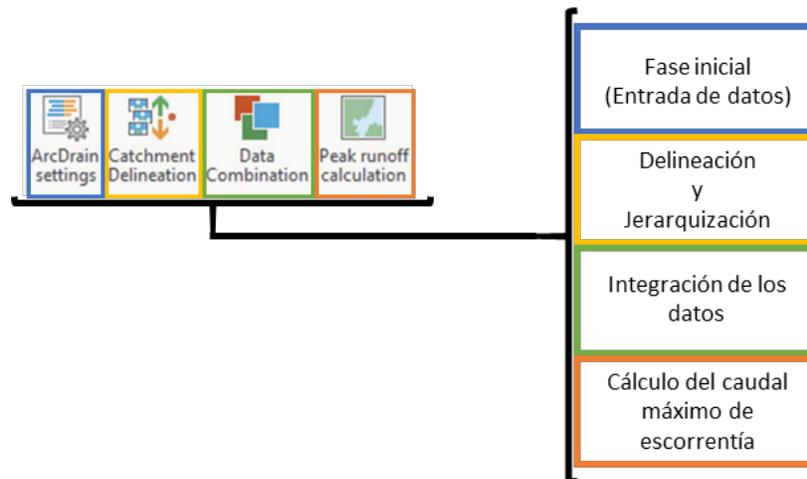


Figura 14. Desglose de los procesos del add-in ArcDrain y su correspondencia con la estructura del apartado 3.2.

La definición de la red de arroyos asociada con el mapa de acumulación de flujo y su posterior ordenamiento produjo la capa mostrada en la figura 15c. Este mapa proporcionó información sobre la jerarquía de las rutas de circulación del flujo en toda la zona de estudio. Dependiendo de su pendiente y condición de cobertura del suelo, las áreas de alto orden pueden convertirse en zonas propensas a inundaciones. El orden de los arroyos también se relacionó con la salida en la figura 15d, que se refiere a la longitud de flujo en cada celda en toda la ciudad. De acuerdo con el MDE y el mapa de acumulación de flujo, aquellas zonas que dieron lugar a largos caminos de flujo aguas abajo se asociaban con altos valores de elevación (figura 13b).

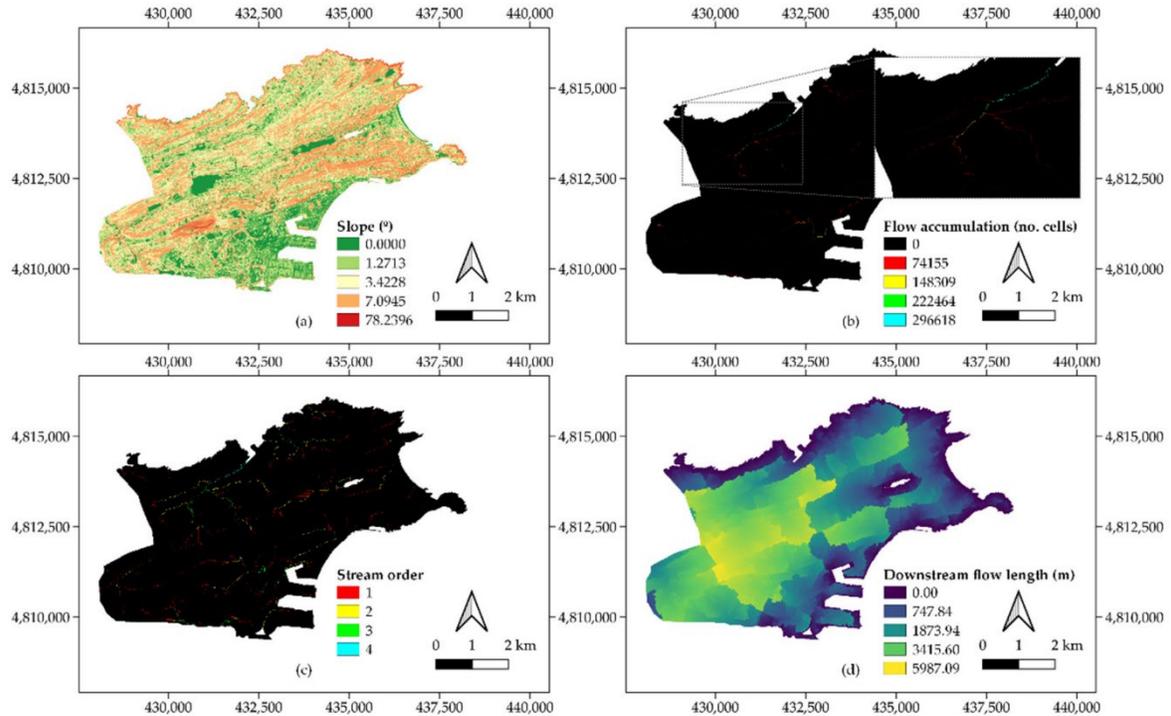


Figura 15. Productos derivados del MDE, (a) pendiente, (b) acumulación de flujo, (c) orden de arroyos, y (d) longitud de cauce más largo para cada subcuenca.

La ordenación de los arroyos como puntos de vertido, representada en la figura 15c, permitió tanto la delimitación de Santander en 247 subcuencas como la determinación de su jerarquía según relaciones de precedencia gracias al algoritmo desarrollado. Una vez realizados todos los cálculos relacionados con las subcuencas, se ejecutó la tarea *Data Combination* (figura 14) como siguiente paso en la aplicación de ArcDrain según lo descrito en el apartado 3.2.3. Esto incluyó el cálculo de valores medios de pendiente y precipitación por subcuenca, cuya superficie media ascendió a 0,137 km². Además, se calculó la longitud del flujo más largo en cada subcuenca a partir de los valores de longitud de flujo en la figura 15d. Luego se ejecutó el módulo *Peak runoff calculation* (figura 14) para aplicar el método racional en las subcuencas, tal y como se formula en la ecuación principal del método racional (ecuación 1), y se derivaron las ecuaciones restantes del apartado 3.2.4 a partir de ella. Esto resultó en el mapa representado en la figura 16a, que sugiere una concentración de subcuencas con valores altos de caudal máximo en el centro de la ciudad. Estas subcuencas están asociadas con la mayor presencia de superficies construidas en la ciudad (figura 13d), cuya impermeabilidad podría favorecer altas tasas de escorrentía.

La consideración de las relaciones entre las subcuencas dio como resultado los valores de caudal máximo acumulado mostrados en la figura 16b. Aunque el centro de la ciudad y sus alrededores siguen siendo una de las zonas más críticas, este mapa destaca el impacto de la acumulación del flujo de escorrentía gracias a la jerarquización de arroyos, donde las zonas más propensas a inundaciones se encuentran en el noroeste de la ciudad debido a la incorporación de los procesos de seguimiento de flujo entre subcuencas.

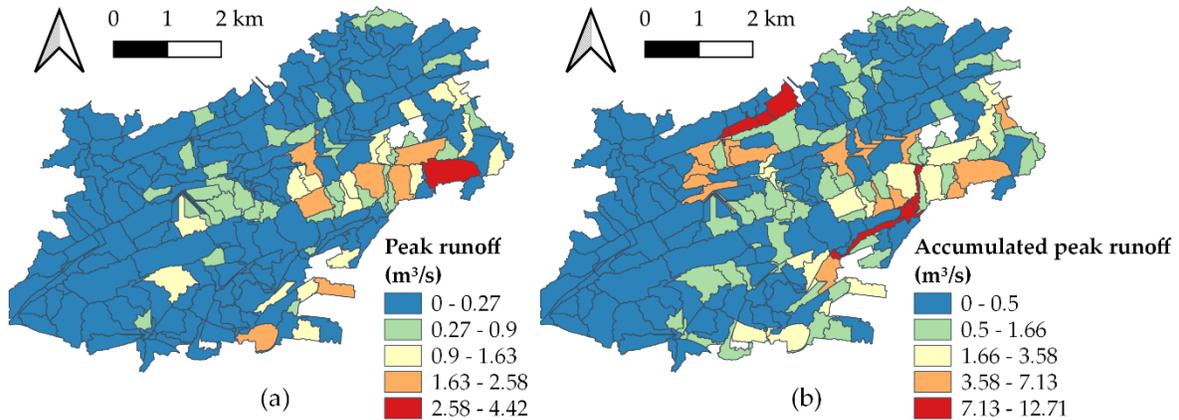


Figura 16. Valores de (a) caudal máximo individual (m^3/s) y (b) caudal máximo acumulado (m^3/s) generado en las subcuencas.

Para la validación de los resultados obtenidos en la figura 16 se superpusieron las áreas de riesgo de inundación identificadas por el ayuntamiento en su Plan de Emergencia Municipal con la capa que contiene la disposición geométrica de las subcuencas. Luego, ambos datos de entrada fueron cruzados para identificar qué subcuencas eran coincidentes espacialmente con estas áreas. Por lo tanto, se separaron aquellas subcuencas que coincidían espacialmente con cualquier área propensa a inundaciones, como se ilustra en la figura 17. Una inspección visual de las figura 16b y figura 17 revela una falta de acuerdo con respecto al grupo de subcuencas ubicado en el norte de la ciudad. Este último alcanzó altas tasas de acumulación de escorrentía según ArcDrain; sin embargo, esta área no fue considerada una prioridad por el ayuntamiento en términos de riesgo de inundación. Esto se debe a sus características demográficas, que incluyen una baja densidad de población, así como la existencia limitada de servicios e instalaciones que se verían afectados por las inundaciones. Esta circunstancia muestra el valor de la necesidad de modelar los peligros teniendo en cuenta también la vulnerabilidad de la zona. Por lo tanto, el interés en mitigar estos eventos en dicha área se reduce en comparación con zonas más vulnerables como posteriormente se aborda en el apartado 4.3 con la aplicación de la metodología del apartado 3.4.

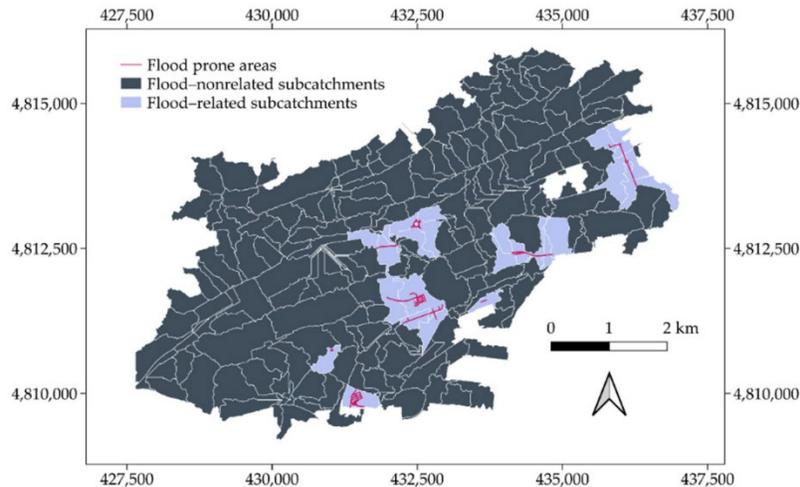


Figura 17. Solapamiento entre las subcuencas delimitadas mediante ArcDrain y las zonas inundables señaladas por el Ayuntamiento de Santander.

Sin embargo, a pesar de que algunas de las subcuencas no atravesasen áreas propensas a inundaciones, se observaron en ellas tasas significativamente altas de caudal máximo acumulado, como se ilustra en la figura 18. Los valores promedio y los cuantiles de las subcuencas relacionadas con inundaciones resultaron ser más elevados. Para determinar si existían diferencias significativas en los valores de flujo de caudal máximo acumulado entre ambos tipos de subcuencas, se llevaron a cabo pruebas estadísticas. Las pruebas se basaron en la distribución de los conjuntos de datos asociados con ambos grupos de subcuencas. Los resultados del test de Shapiro-Wilk revelaron que los p-valores eran prácticamente 0 en ambos casos, indicando que ninguno de los grupos seguía una distribución normal

Por lo tanto, se aplicó el test de Mann-Whitney-Wilcoxon para comparar ambas agrupaciones de subcuencas. El p-valor obtenido por la prueba fue de 0,096, lo que demuestra la existencia de diferencias significativas en el caudal máximo acumulado en ambos grupos para un nivel de significancia del 0,100. Este resultado proporcionó la evidencia estadística de la mayor susceptibilidad a inundaciones de las subcuencas que son comunes espacialmente a las áreas identificadas por el Ayuntamiento de Santander, lo que permitió verificar la fiabilidad de ArcDrain. El enfoque de validación está en línea con la filosofía del *add-in*, ya que una de sus principales premisas es ser poco exigente en términos de requisitos de entrada, en contraste con las mediciones de campo, cuya disponibilidad puede ser bastante limitada y costosas en recursos económicos y en tiempo. No obstante, los datos categóricos o binarios sobre la existencia de inundaciones se pueden adquirir con más facilidad o incluso producir mediante la realización de entrevistas para obtener información sobre las tendencias de eventos pasados en el área de estudio (Paixão et al., 2021).

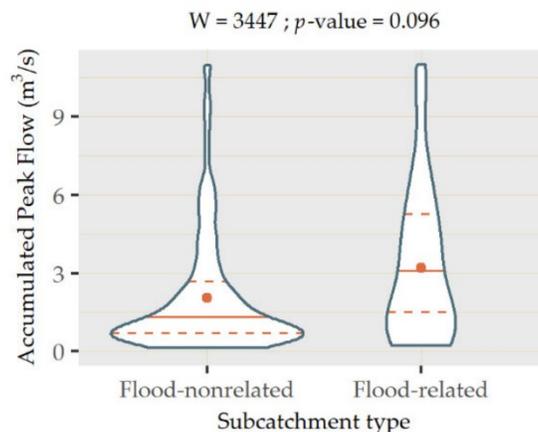


Figura 18. Gráfico de violín de los valores del caudal máximo acumulado en las subcuencas inundables “Flood related” y no inundables “Flood-nonrelated”.

4.1.3 Simulación de escenarios de mitigación

Una vez validado en condiciones de referencia, se exploró la utilidad de ArcDrain más en profundidad mediante el diseño de una serie de escenarios destinados a reducir la acumulación de escorrentía. Esto se logró sustituyendo las siguientes clases de cobertura de suelo construido con superficies permeables: tejido urbano discontinuo (código 112) por infraestructura verde (GI) (código 141); tanto el tejido urbano continuo (código 111) como las unidades industriales, comerciales, públicas, militares y privadas (código 121) por tejido urbano discontinuo de muy baja

densidad (código 112); y carreteras (código 122) por pavimentos permeables. Según estudios previos (Marchioni & Becciu, 2015; H. Zhu et al., 2019), se asumió que estos últimos tenían un umbral de escorrentía equivalente al del tejido urbano discontinuo de muy baja densidad. Estas sustituciones se aplicaron a aquellas subcuencas que tenían valores especialmente altos de caudal máximo individual y que estaban conectados a las áreas propensas a inundaciones representadas en la figura 17. Así, se diseñaron cuatro escenarios en los que se reemplazó el 10%, 25%, 50% y 100% de las superficies asociadas con las coberturas de suelo mencionadas anteriormente en las subcuencas resaltadas en la figura 19.

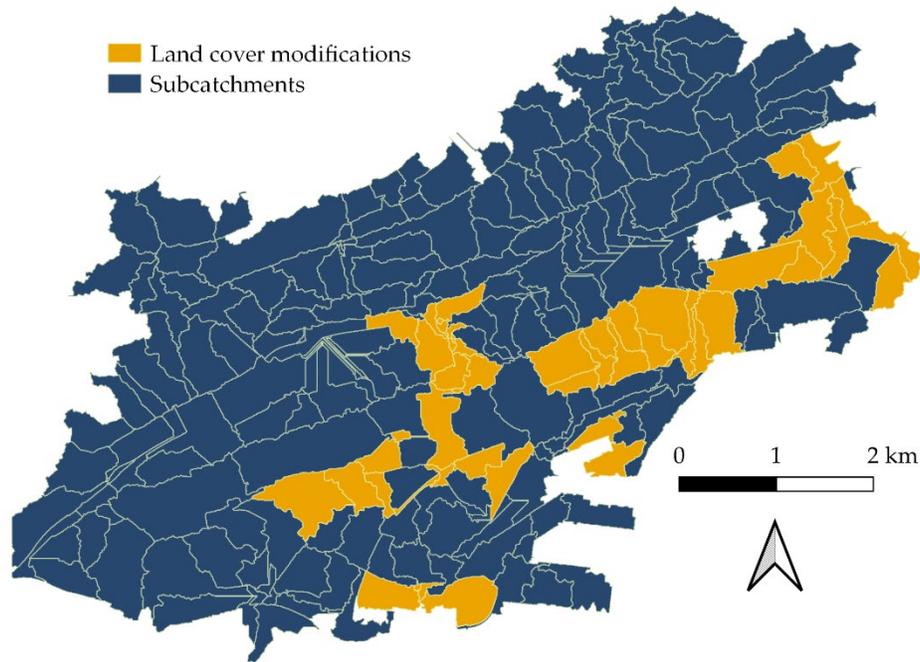


Figura 19. Subcuencas seleccionadas para simular diferentes modificaciones de la cubierta terrestre (Naranja).

Como prueba de la precisión de este proceso de selección, una comparación entre la figura 16a y la figura 19 revela una fuerte concordancia entre las subcuencas que alcanzan altas tasas de escorrentía máxima y aquellas seleccionadas para reemplazo. ArcDrain se volvió a ejecutar para calcular los nuevos valores de escorrentía acumulada con los cambios incluidos en los nuevos escenarios. Los p-valores derivados de la aplicación de la prueba de Mann-Whitney-Wilcoxon para comparar la distribución de ambos grupos en los escenarios fueron 0,163, 0,271, 0,522 y 0,872 para los cambios del 10%, 25%, 50% y 100%, respectivamente, como se muestra en la figura 20. Todos estos valores estuvieron por encima de cualquier nivel de significancia estadística comúnmente utilizado en la literatura (0,100), lo que demostró que no existían diferencias significativas entre los dos grupos de subcuencas. Dicho de otra forma, las medidas propuestas permitieron reducir la escorrentía de las subcuencas relacionadas con las zonas inundables, hasta el punto de no existir diferencias estadísticamente significativas desde un punto de vista hidrológico al otro grupo de subcuencas no relacionadas con las inundaciones. De acuerdo con estos resultados, los gráficos de violín producidos para estos nuevos escenarios (figura 20) reflejan una mayor concentración de

valores en su parte inferior, a medida que el porcentaje de superficies construidas reemplazadas fue mayor.

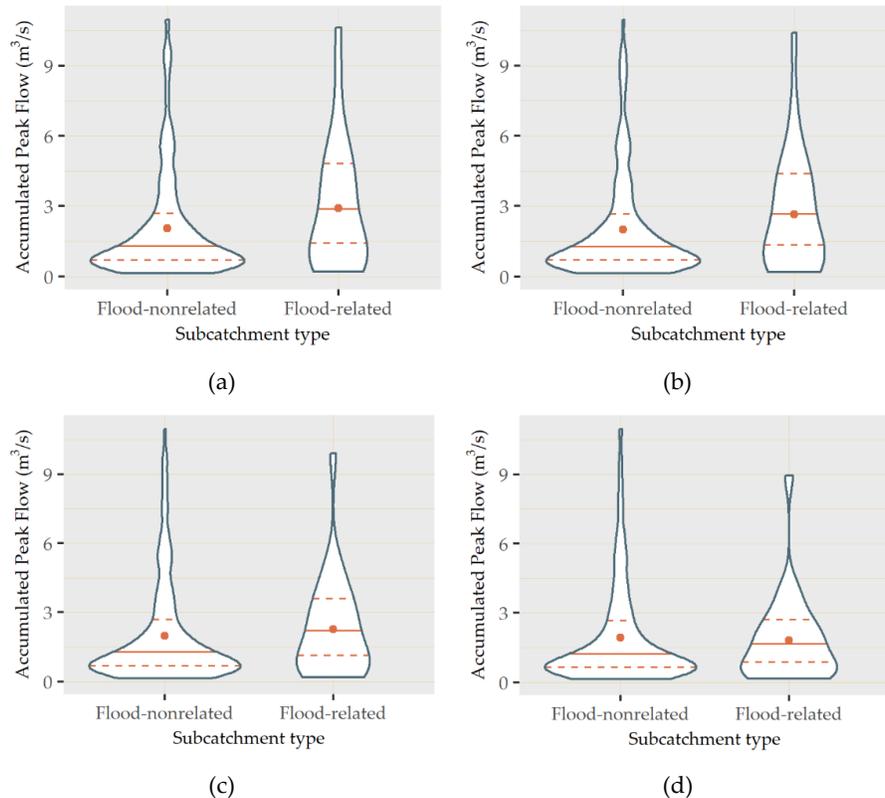


Figura 20. Gráficos de violín de los valores de caudal máximo acumulado comparando subcuencas inundables “Flood related” y no inundables “Flood-nonrelated” al sustituir la superficie del suelo urbana por pavimentos permeables e infraestructuras verdes: (a) 10% del área sustituida, (b) 25% del área sustituida, (c) 50% del área sustituida y (d) 100% del área sustituida.

Esta tendencia fue respaldada por la mediana alcanzada por los nuevos escenarios, que se redujo progresivamente de 2,447 a 2,296, 2,180, 2,038 y 1,663 m³/s en las subcuencas relacionadas con inundaciones. En cambio, la mediana de las otras subcuencas permaneció generalmente sin cambios, hasta el punto de que fue constante (1,254) para los escenarios iniciales del 10% y 25%, y solo varió cuando se reemplazó el 50% (1,185) y el 100% (1,025) de las clases construidas. Este hecho demostró cuán precisa fue la selección estratégica de las subcuencas para el reemplazo (figura 19), ya que sus efectos se limitaron casi exclusivamente a las áreas propensas a inundaciones específicas.

Para demostrar aún más los beneficios de aumentar la permeabilidad para la reducción de la escorrentía, se realizó un análisis de valores atípicos de los valores de acumulación de la escorrentía máxima en el grupo de subcuencas propensas a inundaciones para todos los escenarios considerados. En particular, se eligió el test de Dixon debido a su utilidad para muestras pequeñas (Efstathiou, 2006). Los p-valores devueltos por el test fueron 0,351 y 0,152 para los escenarios inicial y de reemplazo del 10%, lo que sugiere una reducción suave de los altos valores de escorrentía máxima acumulada que no dio lugar a ningún valor atípico. En cambio, los p-valores para los escenarios restantes fueron 0,036 (25%) y 0,000 (50% y 100%), lo que indica la presencia de un valor atípico en cada caso en comparación con los demás valores de su mismo grupo. Esto significa que

la mayoría de las subcuencas identificadas como áreas propensas a inundaciones por el Ayuntamiento de Santander tendrían valores reducidos de flujo máximo acumulado en comparación con estos valores inusuales detectados por el test de Dixon.

En vista de todos los resultados, una estrategia para mejorar la resiliencia a inundaciones en Santander podría consistir en reemplazar el 25% de las carreteras y áreas urbanizadas densamente de las subcuencas destacadas en la figura 19 por NBS. Estas acciones contribuirían a mitigar el caudal de escorrentía máxima generada al mejorar la capacidad de infiltración de las superficies. Además, las medidas propuestas proporcionarían otros beneficios adicionales gracias a sus servicios ecosistémicos, destinados a la regeneración urbana, la regulación térmica, la mejora estética, el control de la contaminación del aire o la mejora de la preservación de la biodiversidad. Por lo tanto, su adopción podría liderar futuros planes urbanos que busquen garantizar la sostenibilidad y resiliencia de las ciudades en el contexto de los cambios climáticos y de cobertura del suelo.

4.2 Modelo de predicción del efecto isla de calor urbano

En esta sección se presentan y discuten los resultados de aplicar las tareas de geoprocésamiento y los algoritmos de aprendizaje automático descritos en la metodología para modelar el efecto isla de calor urbano superficial (SUHI) en el área metropolitana de Madrid. Para ello, se utilizó el *add-in* ArcUHI, que se desarrolló en base a cuatro pasos, como se muestra en la figura 21: (1) Sky View Factor (SVF), (2) Cálculo del porcentajes, (3) Altura promedio de los edificios y (4) Mapa de temperatura. Cada herramienta conduce a una serie de ventanas emergentes donde los usuarios deben ingresar los datos requeridos para producir las variables involucradas en el efecto SUHI y modelarlo a través de algoritmos de aprendizaje automático.

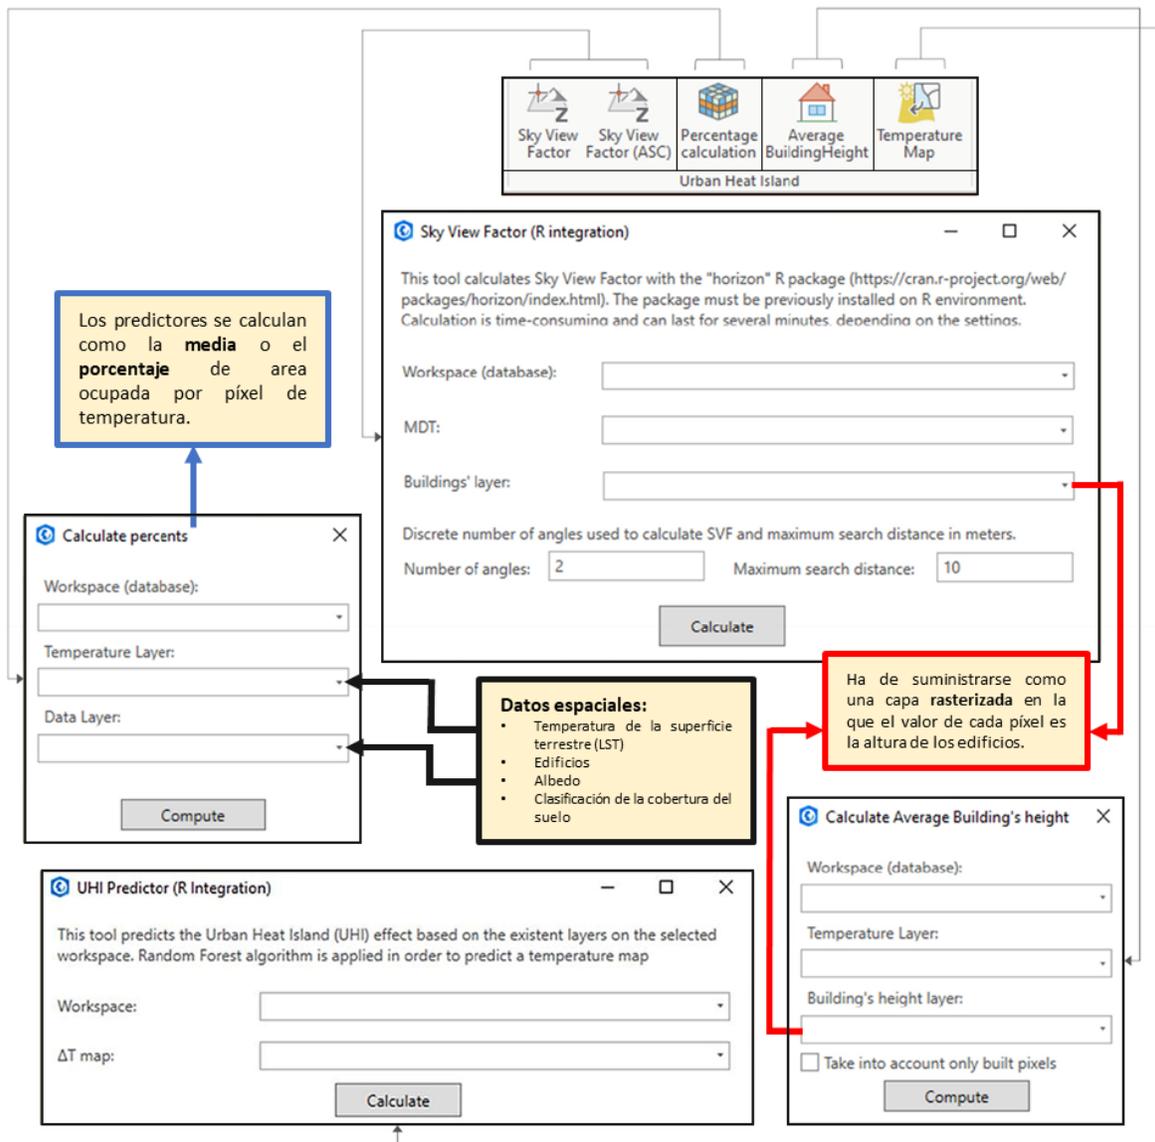


Figura 21. Interfaz del add-in ArcUHI que incluye sus botones principales y ventanas emergentes.

Además del patrón espacial del efecto SUHI en el área metropolitana de Madrid, se analizó su evolución temporal en tres períodos: 2006, 2012 y 2018. Estos años fueron seleccionados en

consonancia con la frecuencia con la que se publican los mapas de cobertura terrestre en Europa. Como representación de los cambios a lo largo de los años, la figura 22 muestra los mapas de cobertura terrestre para 2006, 2012 y 2018 según la codificación del Urban Atlas del programa Copernicus de la Unión Europea (Copernicus, 2023c).

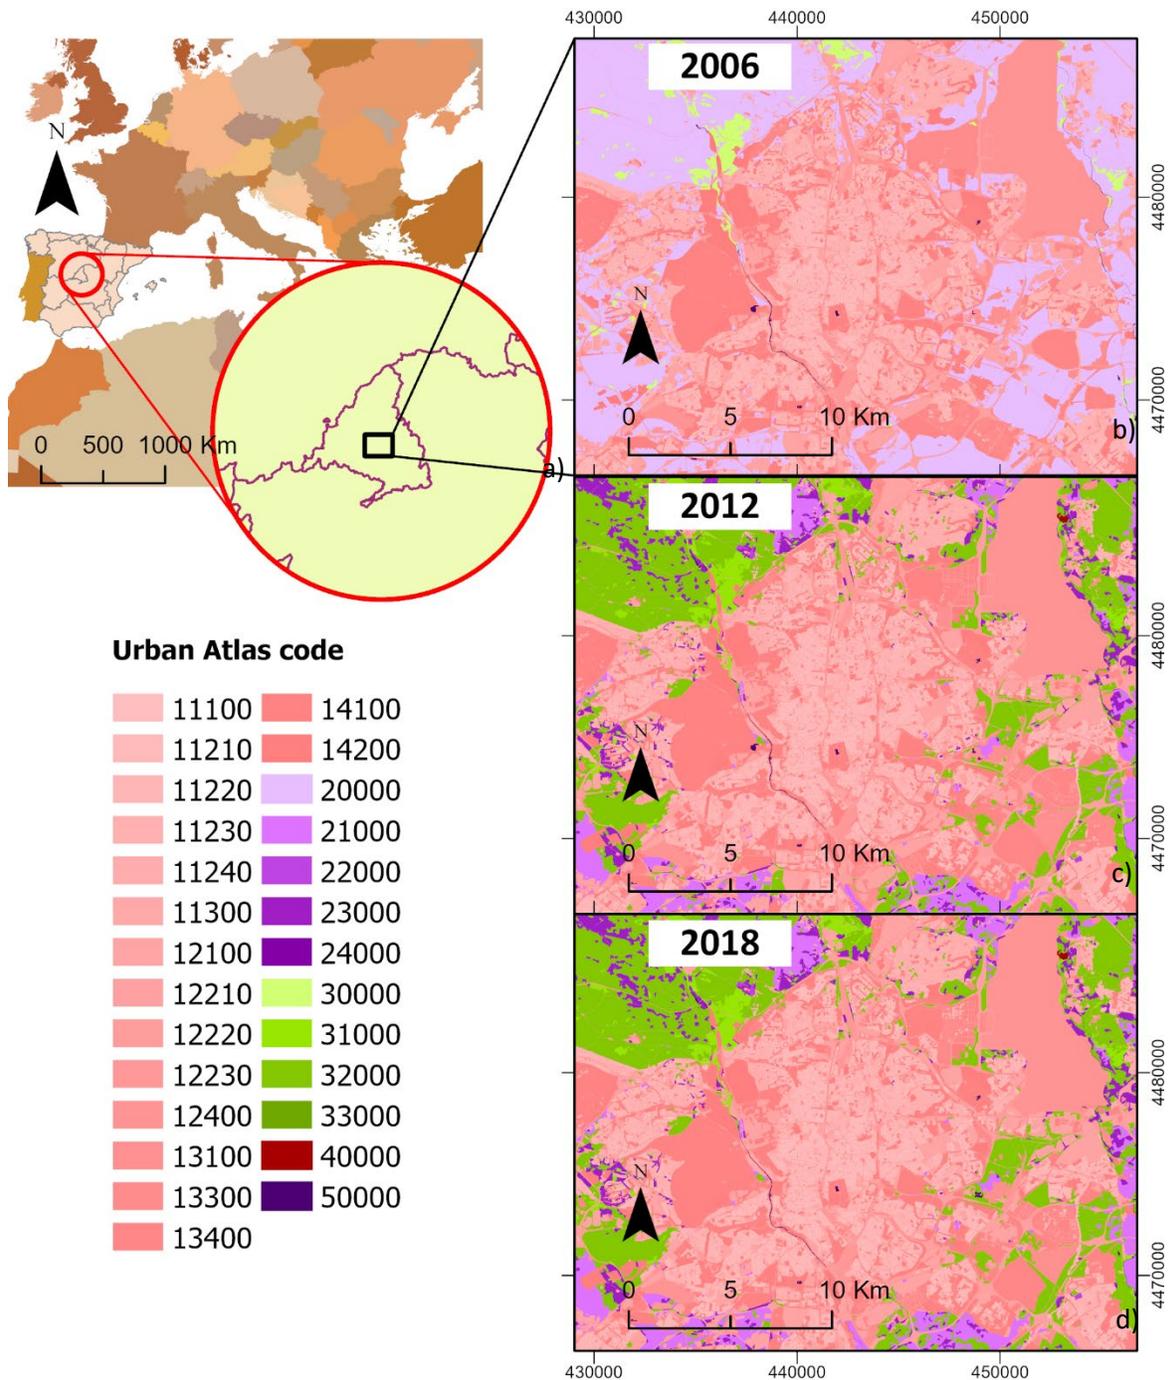


Figura 22. Mapa de situación que indica la ubicación de la zona de estudio (a) y sus correspondientes mapas de ocupación del suelo en 2006 (b), 2012 (c) y 2018 (d) según la codificación del Urban Atlas.

Estos mapas revelan un ligero pero constante aumento en las áreas cubiertas por tejido urbano a lo largo de los años, lo que destaca el interés en modelar el efecto SUHI en el área de estudio a lo largo del tiempo. El nivel de desagregación utilizado para delimitar las clases dentro de la codificación 2X000 y 3X000 en el mapa de cobertura terrestre de 2006 fue diferente que en 2012 y 2018. Sin embargo, esta diferencia no fue relevante para este estudio, ya que ambas clases y todas sus codificaciones se procesaron conjuntamente como vegetación en los pasos siguientes. Hay algunas subcategorías dentro de estas clases que no se pueden considerar vegetación (por ejemplo, las playas), pero su presencia en el área de estudio es extremadamente marginal o nula.

4.2.1 Tratamiento de datos

Los conjuntos de datos espaciales utilizados para modelar el efecto SUHI fueron procesados a través de las primeras tres herramientas de ArcUHI (figura 21), con las que se ejecutaron las tareas esquematizadas en la tabla 3 para los tres años analizados: 2006, 2012 y 2018. Como muestra de los patrones espaciales de las variables derivadas de estos conjuntos de datos, la figura 23 muestra los mapas correspondientes a 2018. Los patrones resultantes para los años 2006 y 2012 se proporcionan como material suplementario en el anexo 3. La distribución del mapa de amplitud térmica (ΔT), que osciló entre 10 y 24 °C, estaba en línea con el mapa de cobertura de suelo representado en la figura 22d. A menor ΔT , mayor presencia de áreas densamente urbanizadas, y viceversa para las zonas menos desarrolladas. La concordancia entre ambos tipos de mapas da muestra de la idoneidad de usar ΔT como indicador del efecto SUHI.

Debido a la independencia de los desarrollos urbanos, las variables derivadas del MDT son los únicos mapas no relacionados con la configuración de la cobertura del suelo en el área de estudio en 2012. Los valores más altos de elevación coincidieron con el barrio del Pardo en la parte noroeste del área de estudio. En cambio, los valores más bajos con respecto a esta variable se encontraron en la parte sureste del mapa, coincidiendo con las Lagunas de Porcal y los mayores cambios de pendiente, que por lo demás eran bastante suaves en toda el área de estudio. El mapa de orientación de laderas sugiere que las direcciones predominantes de estas pendientes estaban entre el sur y el este, con algunas áreas orientadas hacia el oeste.

El siguiente mapa contabilizó la altura media de los edificios en cada píxel de ΔT . Los valores más altos correspondieron a los barrios de La Paz y Costillares, ambos situados en el norte de la ciudad de Madrid (figura 23). Esto diverge de la tendencia observada para la superficie de los edificios, cuyo mapa indicó que el área más sensible en este aspecto era el centro de la ciudad. El patrón en el mapa de SVF es similar a este último, pero haciéndose más presente en aquellas zonas donde la visibilidad del cielo estaba particularmente obstaculizada por una gran aglomeración de edificios altos.

El mapa de albedo representa la capacidad de absorción de calor dependiendo del tipo de superficie. La mayor presencia de tejido urbano en el centro de la ciudad explica los valores más bajos de albedo encontrados en el mapa. La consideración conjunta de la capa con la distribución de carreteras con aquellas que registran los edificios proporcionó una desagregación de la relación entre la altura de los edificios y el ancho de la calle, ampliamente utilizada en la literatura (Pigliautile et al., 2020; Yuan et al., 2020). Finalmente, los mapas de vegetación y agua fueron consistentes con los mapas

topográficos, ya que alcanzaron sus valores extremos en la montaña y en el embalse de Pardo y las Lagunas de Porcal.

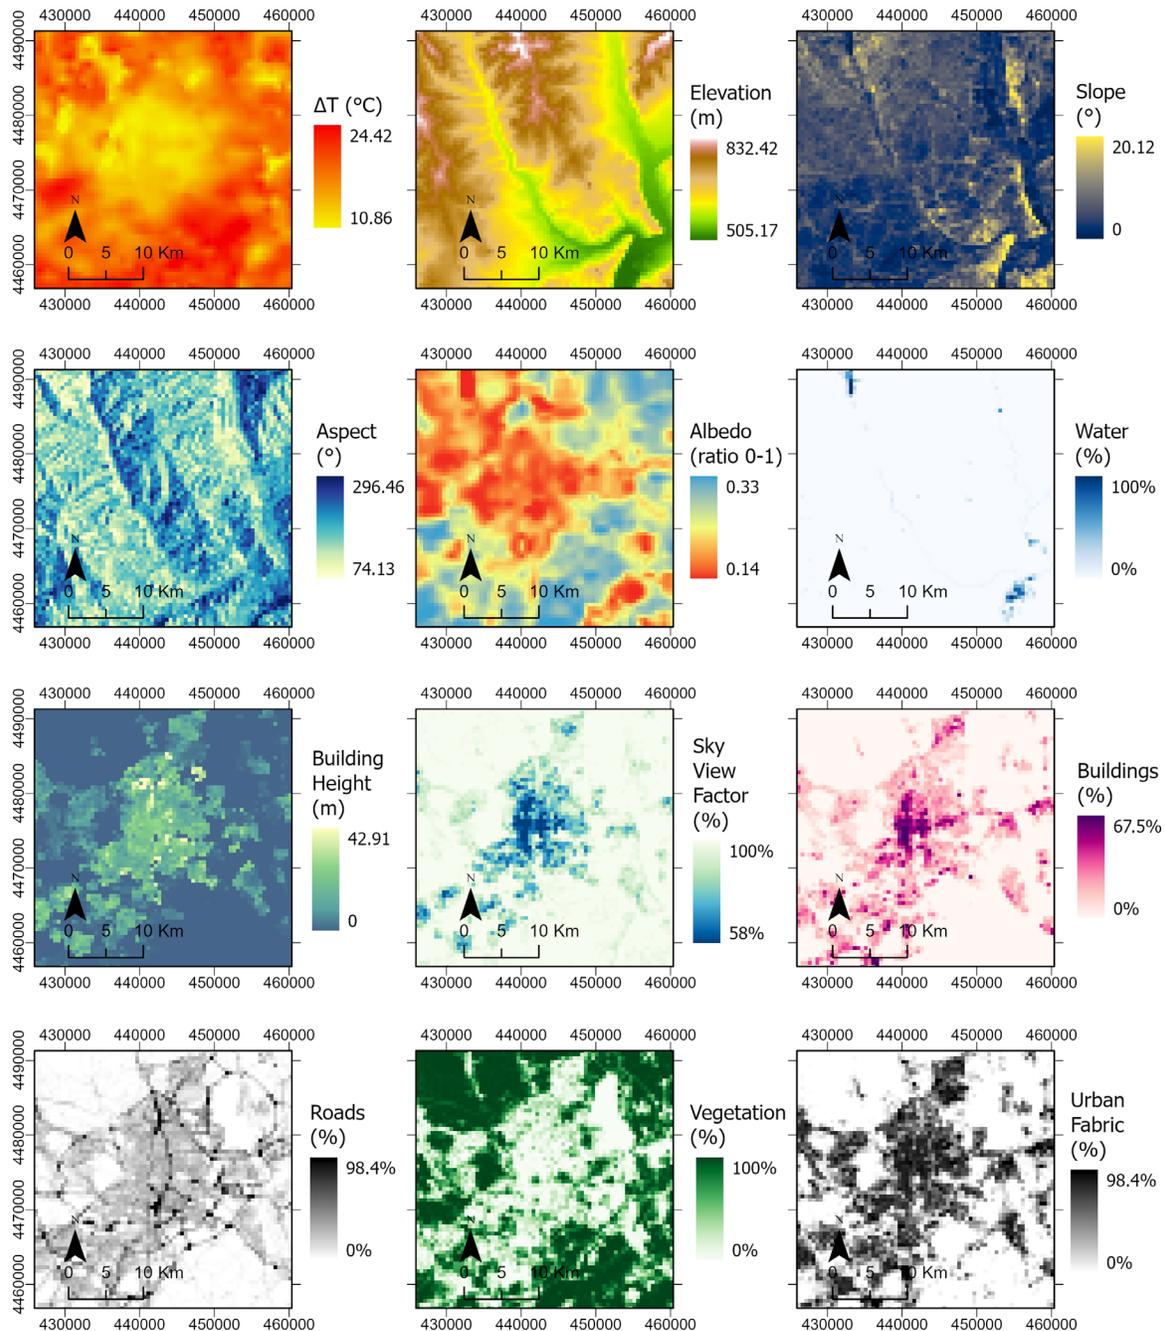


Figura 23. Distribución espacial de las variables que intervienen en la modelización del efecto isla de calor urbano (UHI) en toda la zona de estudio, expresada en valores medios o porcentajes del área ocupada por píxel. (2018)

Para explorar las relaciones entre las variables mapeadas en la figura 23, se preparó un análisis de correlación como se muestra en la figura 24. Las variables que involucran construcciones estaban correlacionadas negativamente con ΔT , lo que sugiere una menor disipación del calor en esas áreas cubiertas por tejido urbano en forma de carreteras y edificios con gran cantidad de material para almacenar calor. Estos últimos son consistentes con el impacto positivo de valores altos de SVF en

ΔT , ya que mayores proporciones de cielo visible implican menor presencia de edificios. La existencia de áreas vegetadas y superficies con alto albedo también se relacionó con una menor retención de calor, favoreciendo así valores más altos de ΔT . Los valores del coeficiente de correlación de Pearson entre la pendiente, el agua y la orientación de las laderas con ΔT fueron débiles. Los dos primeros están implícitos en la variable de elevación, ya que son derivados de la altitud y depresiones del terreno. Finalmente, la orientación de laderas es un parámetro direccional cuya asociación numérica con una variable continua como ΔT es difícil de interpretar.

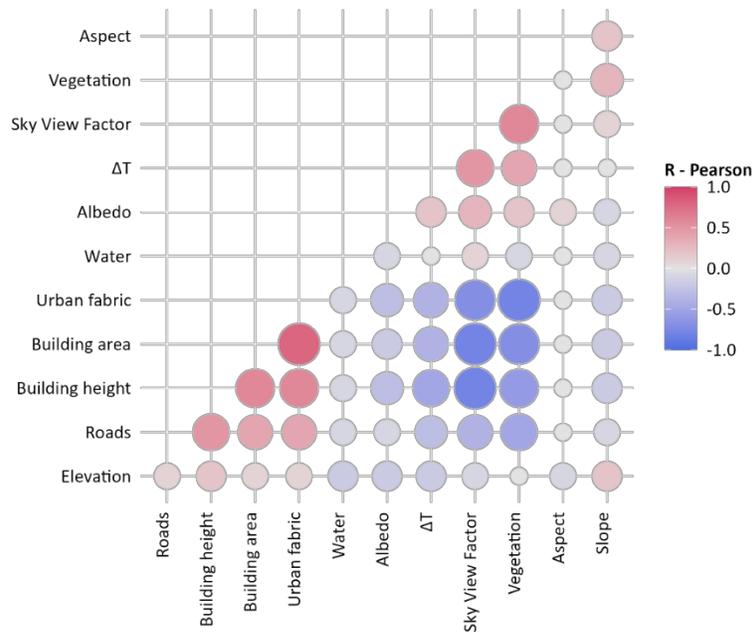


Figura 24. Gráfico de correlación entre las variables que intervienen en la modelización del efecto isla de calor urbano (UHI).

Este análisis previo permitió entender las relaciones entre las variables explicativas y la variable de respuesta. Todos los valores de rho de Pearson mostrados en la figura 24 fueron estadísticamente significativos para un nivel de significancia (α) de 0,05. Esta significancia generalizada se vio favorecida por el gran tamaño del conjunto de datos, ya que el área de estudio cubría 6142 píxeles, que sumaron 18426 al considerar los tres años bajo análisis. La totalidad de estos píxeles ejercieron como observaciones para las regresiones en los pasos posteriores.

4.2.2 Machine learning

El último botón del *add-in* ArcUHI (figura 21) permitió producir un mapa de ΔT que se ajusta a los valores observados de amplitud térmica en el área de estudio durante los años 2006, 2012 y 2018. El conjunto de datos completo formado por estos años se dividió en subconjuntos de entrenamiento y testeo utilizando una proporción de 70:30. Posteriormente, el subconjunto de entrenamiento fue evaluado a través de la validación cruzada *k-fold*. La primera regresión que se construyó fue el modelo de *Multiple Linear Regression* (MLR) como línea de base para determinar si la combinación de las relaciones lineales representadas en la figura 24 era suficiente para modelar el efecto SUHI con precisión.

Los resultados del procedimiento paso a paso y el Factor de Inflación de la Varianza (FIV) apoyaron las deducciones extraídas del análisis de correlación (figura 24), ya que el agua y la orientación fueron las únicas variables estadísticamente no significativas con valores de FIV superiores a 5 (J. H. Kim, 2019). Por lo tanto, debido a su superposición con otras variables, su uso como variables explicativas fue descartado en todos los modelos. Los valores de R^2 para MLR estuvieron por debajo de 0,6 para los subconjuntos de entrenamiento y testeo, mientras que la raíz del error cuadrático medio (RMSE) estuvo por encima de 2 °C, lo que supone >10% de variación en respecto a los valores de ΔT observados en del área de estudio (figura 23).

La capacidad predictiva de la MLR confirmó que se requerían algoritmos no lineales y más complejos para capturar las relaciones entre las variables consideradas. Como tal, la siguiente aproximación se llevó a cabo utilizando la *Support Vector Regression* (SVR). El ajuste óptimo proporcionado por este algoritmo correspondió a una función del kernel radial con los siguientes parámetros: $cost = 32$, $gamma = 0,143$, $degree = 3$ y $\epsilonpsilon = 0,1$. Aunque el R^2 aumentó a $> 0,7$, los valores de RMSE seguían siendo demasiado altos, especialmente para el subconjunto de entrenamiento.

En última instancia, se utilizó la *Random Forest Regression* (RFR) para intentar aumentar la precisión del modelo. Como se muestra en la tabla 7, que proporciona una comparación de los tres algoritmos de aprendizaje automático probados, las medidas de calidad de ajuste mejoraron sustancialmente al usar RFR. El número óptimo de árboles (n_{tree}) y predictores muestreados aleatoriamente en cada división (m_{try}) fueron 495 y 4, respectivamente. El entrenamiento del modelo con estos parámetros produjo un valor de RMSE de 1,14 °C, una cifra que aumentó a 1,22 °C para el subconjunto de testeo.

Tabla 7. Medidas de la calidad de ajuste obtenidas para los tres algoritmos aplicados para modelizar el efecto isla de calor urbano superficial (SUHI).

ALGORITMO	ENTRENAMIENTO		TESTEO	
	R^2	RMSE(°C)	R^2	RMSE(°C)
Multiple Linear Regression	0,58	2,14	0,56	2,30
Support Vector Regression	0,76	1,79	0,73	1,90
Random Forest Regression	0,92	1,14	0,90	1,22

En general, los mapas predichos proporcionaron un ajuste que puede considerarse excelente respecto al ΔT observado, con una distribución homogénea de errores en toda el área de estudio. Los mayores errores correspondieron a 2018, como se ilustra en la figura 25. En comparación con los mapas de 2006 y 2012, que eran muy similares entre sí, las áreas donde ΔT fue inferior a 15 °C aumentaron notablemente en 2018. Esto podría estar relacionado con un aumento de las actividades humanas en distritos periféricos como Fuencarral-El Pardo ($x = 434.082$; $y = 4.489.800$), Hortaleza ($x = 445413$; $y = 4481325$), Villa de Vallecas ($x = 447694$; $y = 4466929$) o Barajas ($x = 451352$; $y = 4482840$). La población en estos distritos aumentó en un rango del 5 al 13% entre 2012 y 2018 (Ayuntamiento de Madrid, 2023), lo que podría haber llevado a un aumento del punto caliente principal de ΔT en el centro de la ciudad a otras partes del área metropolitana de Madrid. A su vez, esta expansión podría haber limitado el efecto refrigerante del Parque Forestal Adolfo

Suárez ($x = 434654$; $y = 4476783$), que actuó como una isla térmica en 2006 y 2012 y fue el principal causante de los errores asociados con el mapa de 2018.

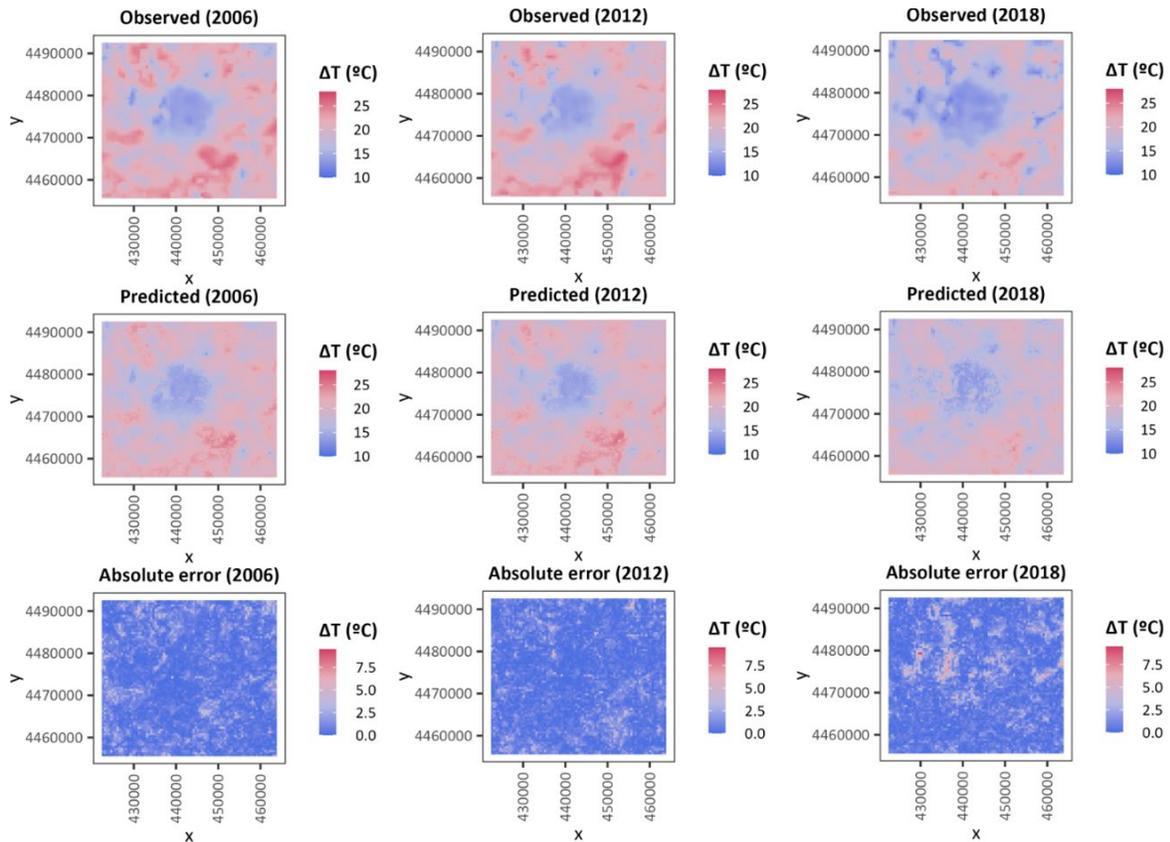


Figura 25. Predicciones y errores absolutos derivados de la modelización de los valores observados de amplitud térmica (ΔT) en la zona de estudio mediante Random Forest Regression (RFR).

Otra posible explicación para la divergencia entre las observaciones y las predicciones en 2018 puede estar en los datos de albedo para ese año, que provienen de un satélite diferente con respecto a 2006 y 2012. Como resultado, el mapa de 2018 contenía valores más altos de albedo en general (figura 26a), lo cual es inconsistente con la evolución de la cobertura terrestre en la figura 22. Aunque el patrón espacial de esta variable es comparativamente similar para los tres años, especialmente para valores extremos, esta diferencia en términos de recopilación de datos podría explicar la reducida suavidad del mapa de ΔT predicho para 2018.

La influencia de los datos de albedo contrasta con la estabilidad de los MDT utilizados. Como se indica en la tabla 3, las variables relacionadas con la elevación se procesaron utilizando MDT de 5 y 2 metros, que se asociaron con 2012 y 2018, respectivamente. La figura 26b muestra una distribución casi igual de *outliers* para todos los años, independientemente de la resolución del MDT, lo que sugiere que el efecto de esta variable en las predicciones no fue significativo.

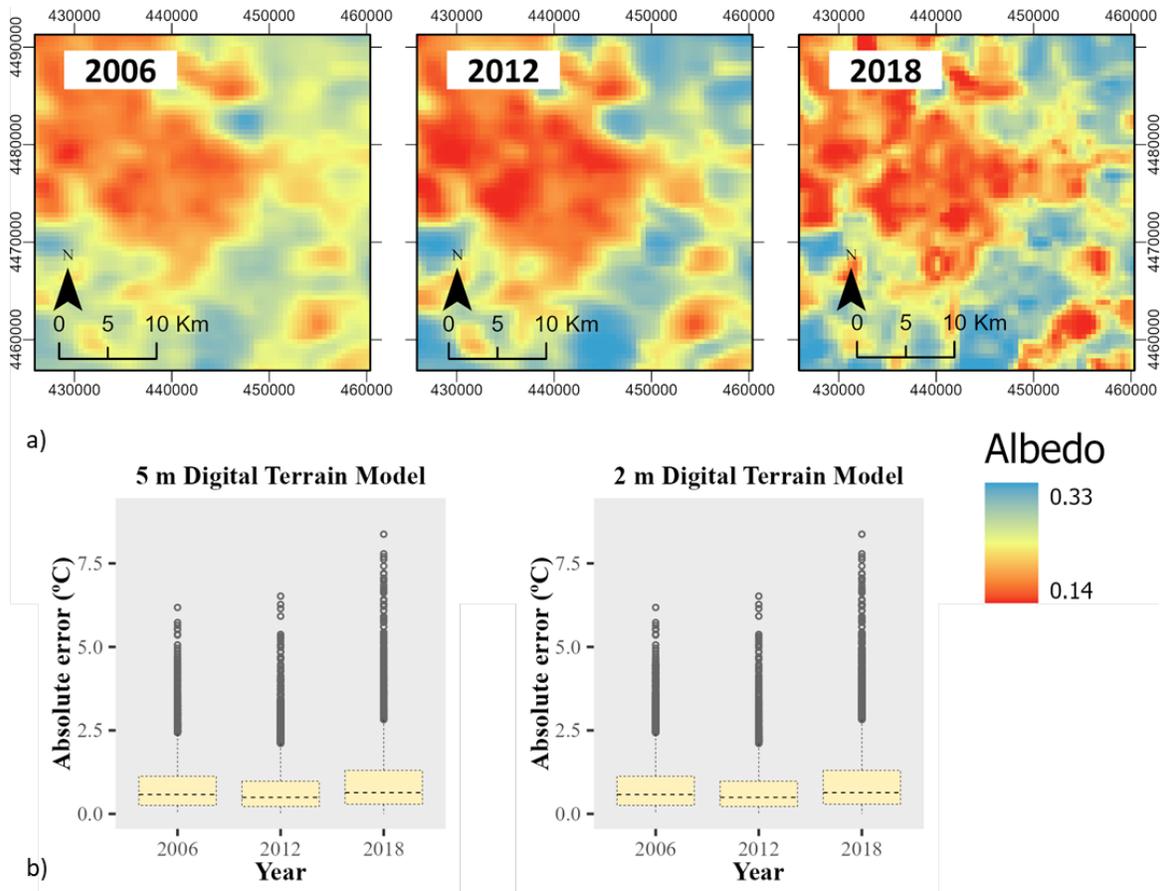


Figura 26. Sensibilidad de las variables explicativas procedentes de diferentes fuentes de datos (a) Mapas de albedo a lo largo del periodo de estudio (b) Errores absolutos producidos por diferentes Modelos Digitales del Terreno (MDT)

4.2.3 Discusión

Según la correlación del agua y la orientación con ΔT (figura 24) y los resultados del modelo MLR, el papel de estas variables en la predicción del efecto SUHI para el área de estudio fue muy limitado. Como se ha comprobado en investigaciones anteriores, el agua puede ser un predictor importante de la temperatura en ciudades costeras (Hart & Sailor, 2009) o áreas que contengan o estén cerca de grandes masas de agua (Hjort et al., 2011), lo que no es el caso del área metropolitana de Madrid.

La orientación del terreno puede ser relevante para ΔT debido a la relación de las pendientes orientadas hacia el ecuador o los polos con la radiación solar (Chuanyan et al., 2005). Este efecto se ha argumentado que es influyente en ciudades montañosas, aunque puede ser eclipsado por factores antropogénicos en áreas densamente construidas (G. F. Han et al., 2014). Esta circunstancia justificaría la falta de importancia de esta variable en este caso de estudio.

La relevancia de las variables explicativas restantes en el modelo RFR se determinó utilizando el método de función de permutación, cuyos resultados concordaron con las tendencias mostradas en estudios anteriores (figura 27). La importancia de los edificios altos radica en los cañones urbanos que implican dicha altura, lo que desencadena la conversión de las superficies vecinas en masas térmicas que no permiten la liberación del calor acumulado durante el día (Gaffin et al., 2008; Unger,

2004). Este efecto se potencia cuando se considera junto con el SVF (Bottján & Unger, 2003). De hecho, aumentar el SVF se ha propuesto como una medida para la mitigación del efecto UHI mediante el equilibrio entre la altura de los edificios y el porcentaje área edificada (Yuan & Chen, 2011).

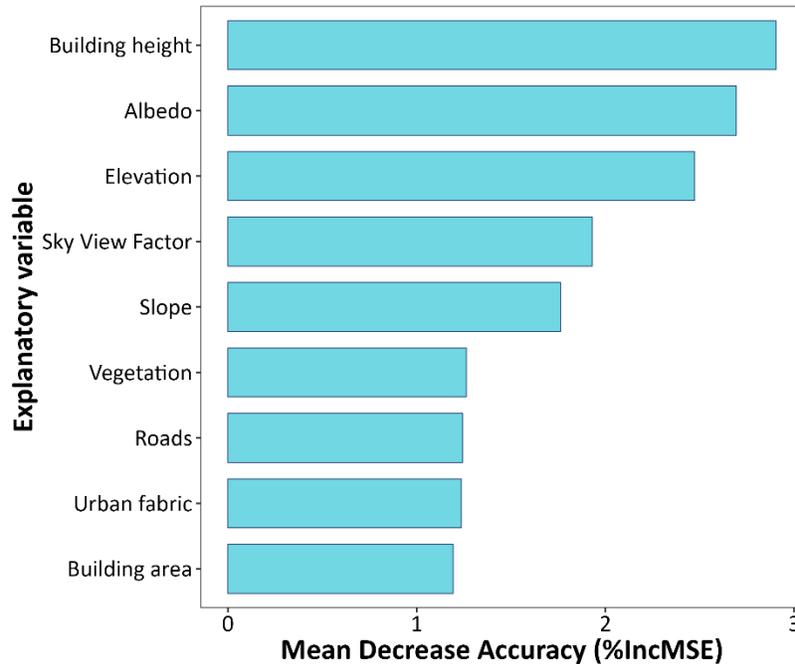


Figura 27. Importancia de las variables según el aumento del Error Cuadrático Medio (%IncMSE) obtenido para las predicciones del modelo Random Forest Regression (RFR).

Las alteraciones en la superficie terrestre por elementos urbanos han sido identificadas por muchos autores como uno de los principales impulsores del efecto UHI. Por ejemplo, Yoo (2018) y Szymanowski & Kryza (2012) señalaron el porcentaje de impermeabilización y el Índice de Vegetación Normalizado (NDVI) como las variables más influyentes en la LST. Otros autores, como Zhang et al. (Zhang et al., 2021), destacaron la importancia de equilibrar la concentración de vegetación y áreas construidas para reducir el efecto UHI, mientras que Tan et al. (2021) y Makido et al. (2016) enfatizaron el papel de los materiales de alto albedo y las plantas para contrarrestar la retención de calor y enfriar sus alrededores. Estos hallazgos concuerdan con los resultados obtenidos en este estudio, donde el albedo fue la segunda variable más importante en el modelo RFR construido. Además, la relevancia de los cambios en la cobertura del suelo también fue coherente con el efecto combinado de las cuatro variables menos importantes según la figura 27: vegetación, carreteras, tejido urbano y área edificada.

La alta influencia de las variables derivadas de los MDT también fue coherente con las conclusiones obtenidas de investigaciones previas (Bindajam et al., 2020), donde se encontró que la elevación desempeña un papel clave en la modelización del efecto UHI. En la misma línea, algunos autores argumentaron que las variaciones en la elevación de 285 metros dentro del área de estudio pueden causar un importante impacto topográfico en la temperatura del aire (Buttstädt & Schneider, 2014), que está fuertemente relacionado con el efecto UHI (Mutiibwa et al., 2015). El rango de elevación

en el área de estudio ascendió a >300 metros (figura 23), lo que justifica la capacidad predictiva de las variables de elevación y pendiente.

Para corroborar los resultados ilustrados en la figura 27, se realizó un análisis de sensibilidad como se muestra en la figura 28 para determinar cómo la variable de respuesta (ΔT) se ve afectada por cambios en las variables explicativas. Las diferentes líneas incluidas en los gráficos representan los cambios en la relación entre cada variable explicativa y la respuesta cuando las otras variables explicativas se mantienen constantes en diferentes cuantiles: mínimo, 20, 40, 60, 80 y máximo. Aunque todas las variables incluidas en el modelo RFR contribuyeron a explicar las variaciones en ΔT , esto fue especialmente notable en el caso de albedo, altura de los edificios, elevación y SVF, lo que es consistente con la figura 27.

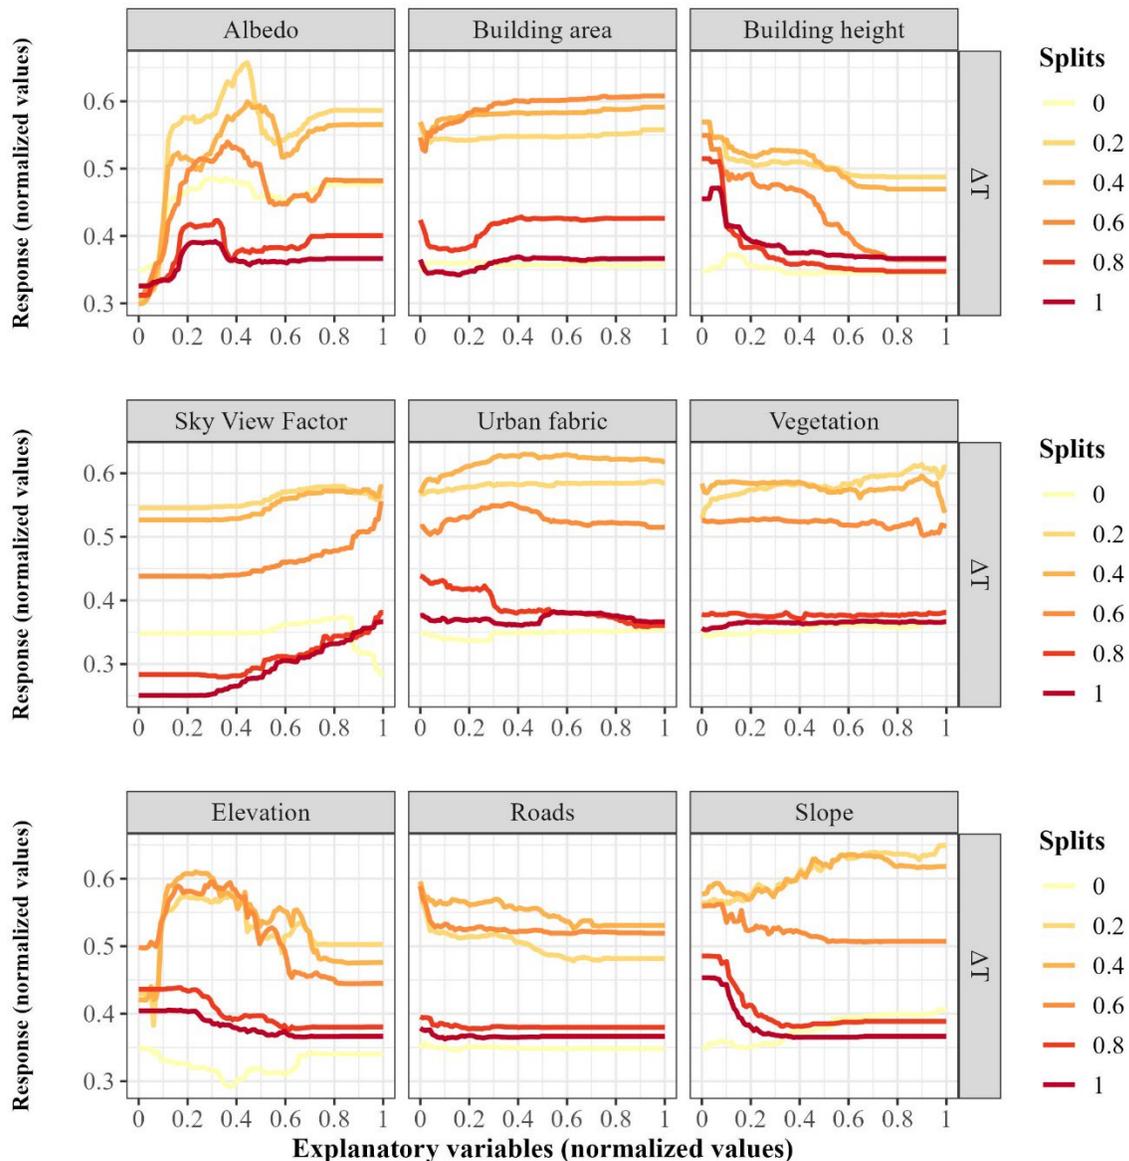


Figura 28. Análisis de sensibilidad del efecto de las variables explicativas sobre la amplitud térmica (ΔT)

A la luz de estos resultados, el *add-in* ArcUHI se puede utilizar como punto de partida para proponer medidas de renovación en la ciudad para la mitigación del efecto SUHI, ya que permite tanto la detección automatizada de áreas importantes en términos de ΔT como la clasificación de las variables involucradas según su importancia (figura 27). Debido al espacio horizontal limitado disponible en las ciudades, la vegetación en tejados y fachadas (Herath et al., 2018) ofrece una solución para compensar parcialmente el efecto cañón urbano causado por edificios altos, al tiempo que se aumenta la vegetación y el albedo y se reduce el área cubierta por edificios y tejidos urbanos. La plantación de árboles también tendría impactos positivos en algunas de las variables mencionadas anteriormente y, por lo tanto, en la mitigación de la temperatura superficial (Schwaab et al., 2021); sin embargo, su inclusión debería ser diseñada cuidadosamente para minimizar la reducción del SVF (Noro & Lazzarin, 2015), lo que va en contra de la atenuación del efecto SUHI.

Otra línea de acción podría consistir en reemplazar las carreteras de asfalto oscuro por pavimentos con alta reflectancia solar (C. Wang et al., 2021), aumentando así el albedo en esas áreas de 0,1 a entre 0,2 a 0,5. Dada la relevancia de esta variable (figura 27), esta estrategia podría ser muy efectiva para reducir el efecto SUHI. Sin embargo, estos materiales pueden causar deslumbramiento por reflexión (Kotthaus & Grimmond, 2014), en especial cuando están instalados recientemente. Por lo tanto, la capacidad de reflexión de este tipo de pavimentos debería equilibrarse garantizando una seguridad en la conducción (Kyriakodis & Santamouris, 2018).

En el caso de áreas urbanas planificadas, pero no desarrolladas, las medidas preventivas para evitar el efecto UHI en el futuro deben centrarse en promover la presencia de NBS (Marando et al., 2022). Su ubicación debería realizarse estratégicamente para maximizar su potencial para atenuar el efecto cúpula causado por edificios altos y contrarrestar la capacidad de retener calor de las superficies construidas. Además, aspectos como la perspectiva espacial, la conectividad y la accesibilidad también deben considerarse para garantizar los beneficios a gran escala de las NBS (J. Liu et al., 2021).

4.3 Índice de vulnerabilidad urbana

En esta sección se detalla y analiza el índice de vulnerabilidad urbana, el cual se ha generado mediante la implementación de la metodología propuesta en el apartado 3.4. Cada uno de los pasos que componen este procedimiento se presenta detalladamente, y se proporcionan explicaciones y justificaciones de las razones que respaldan la elección de las variables más representativas. De esta manera, se ofrece una visión completa de cómo se ha desarrollado y fundamentado este índice de vulnerabilidad urbana.

4.3.1 Clasificación, selección y correlación.

De las 159 variables disponibles por distrito censal, se clasificaron 57 como variables demográficas, 84 como variables socioeconómicas y 18 como variables de infraestructura. Posteriormente se procedió a la selección de aquellas variables más relevantes dentro de cada una de las clases propuestas, secundada por bibliografía previa y datos de correlación entre variables, con los siguientes resultados: la clase demográfica se redujo de 57 a 10 variables, combinándose algunas de ellas durante la selección cualitativa. Se observaron correlaciones significativas entre algunas variables (por ejemplo, población total con el número de personas menores de 16 años y población total con el factor de la suma de personas menores de 16 años y mayores de 64 años). Dado que el factor de personas mayores de 64 años no se correlacionó con ninguna otra variable de edad, se seleccionaron este factor y el factor de personas menores de 16 años, mientras que las otras dos variables se descartaron asumiendo que los grupos vulnerables por edades quedan representados por los anteriores.

En la clase socioeconómica, se seleccionaron 9 de las 84 variables iniciales. Las variables relacionadas con los ingresos se correlacionaron altamente entre sí, excepto el porcentaje de población por debajo del umbral de pobreza (ingreso familiar por debajo del 60% de la mediana de ingresos). Se seleccionaron las variables con la correlación acumulativa más alta entre las otras variables de ingresos. Además, se descartaron las variables relativas al número de viviendas por debajo de 90 m² y al estado civil de solteros. Esta decisión se basó en la ausencia de correlación entre el estado económico de pobreza con vivir en una casa más pequeña y la alta correlación entre el número de personas con hipoteca o alquiler, respectivamente. Para todas las variables, excepto el umbral de pobreza, se observó una correlación negativa con valores muy cercanos al umbral entre el estado civil (no casado) y los ingresos. Se observó un valor de correlación más bajo, aunque positivo, entre un tamaño de vivienda de menos de 90 m² y las personas que viven por debajo del umbral de pobreza.

En la clase de infraestructura, se seleccionaron 11 de las 18 variables disponibles. Sin embargo, se descartaron los usos desglosados de los edificios residenciales y las diferencias en el número de habitaciones. Esto se debió a que el objetivo principal es proteger las residencias principales, y estas estaban correlacionadas con los datos agregados de todos los edificios residenciales.

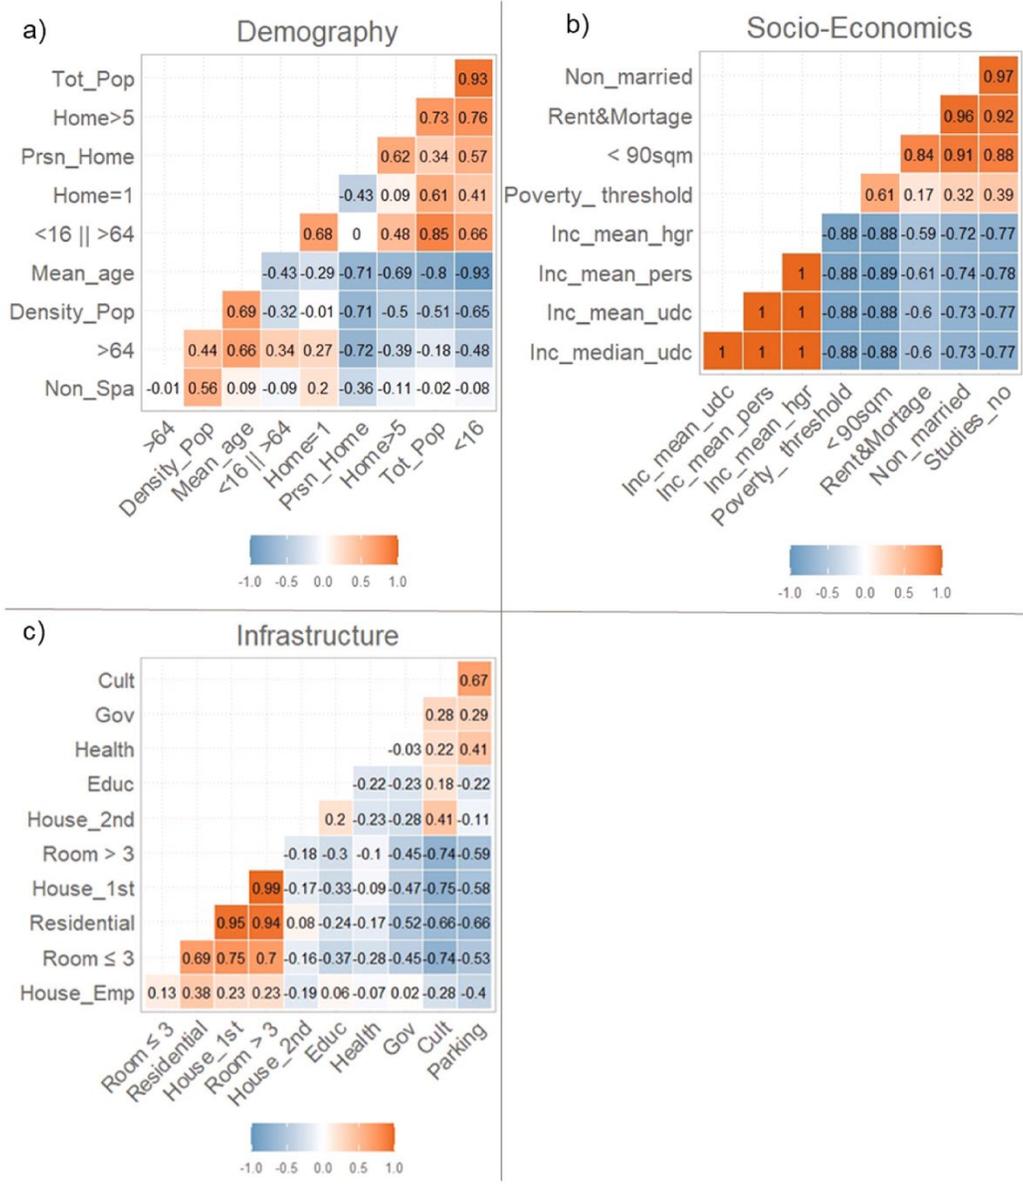


Figura 29. Correlación entre variables de las tres clases de vulnerabilidad. La diagonal con valor 1, característica de este tipo de gráficos, se ha omitido para una mejor visualización de los datos. a) Variables demográficas. b) Variables socioeconómicas. c) Variables de infraestructura.

4.3.2 Suma ponderada y mapeo de subíndices

El screening, el análisis de correlación y el análisis de componentes principales (PCA) redujeron progresivamente el número de variables que quedaron en la selección (tabla 8) después de cada paso. Por ejemplo, en la categoría demográfica, el proceso fue el siguiente: de las 57 variables originalmente disponibles, se seleccionaron 10 a través del proceso de selección. De estas, 2 se descartaron durante el análisis de correlación, dejando 8 variables. Posteriormente, una variable se eliminó durante el PCA porque no cumplía con el umbral requerido de porcentaje explicativo espacial.

Tabla 8. Resumen del número de variables restantes después de cada paso de selección.

	<i>DEMOGRÁFICA</i>	<i>SOCIECONÓMICA</i>	<i>INFRAESTRUCTURAS</i>	<i>TOTAL</i>
<i>INICIAL</i>	57	84	18	159
<i>SCREENING</i>	10	9	11	30
<i>CORRELACIÓN</i>	8	4	6	18
<i>PCA</i>	7	4	5	16

Los pesos de las variables que permanecieron después del proceso de selección se determinaron utilizando la ecuación 15 (tabla 9). Cuanto mayor fue el valor del peso, mayor fue la variabilidad en los datos. Las variables que no tenían peso asignado (*Density_Pop* y *Gov*) se descartaron durante el análisis del PCA debido a su reducido aporte a cualquiera de los dos componentes principales (figura 30).

Tabla 9. Ponderaciones obtenidas mediante la suma ortogonal de la contribución de las variables finales seleccionadas en cada clase. Las variables analizadas que no alcanzaron el nivel mínimo de contribución en los dos componentes principales como "-" y su valor es 0.

<i>CLASE</i>	<i>CÓDIGO</i>	<i>PONDERACIÓN DE LA SUMA ORTOGONAL NORMALIZADA</i>
<i>DEMOGRÁFICA</i>	<16	0,17
	>64	0,10
	Non_Spa	0,12
	Prsn_Home	0,16
	Home=1	0,14
	Home>5	0,10
	Density_Pop	-
	Mean_Age	0,21
<i>SOCIECONÓMICA</i>	Poverty_threshold	0,21
	Studies_No	0,29
	Inc_mean_udc	0,23
	Rent&Mortgage	0,27
<i>INFRAESTRUCTURAS</i>	Residential	0,19
	Cult	0,26
	Health	0,16
	Gov	-
	Educ	0,16
	Parking	0,23

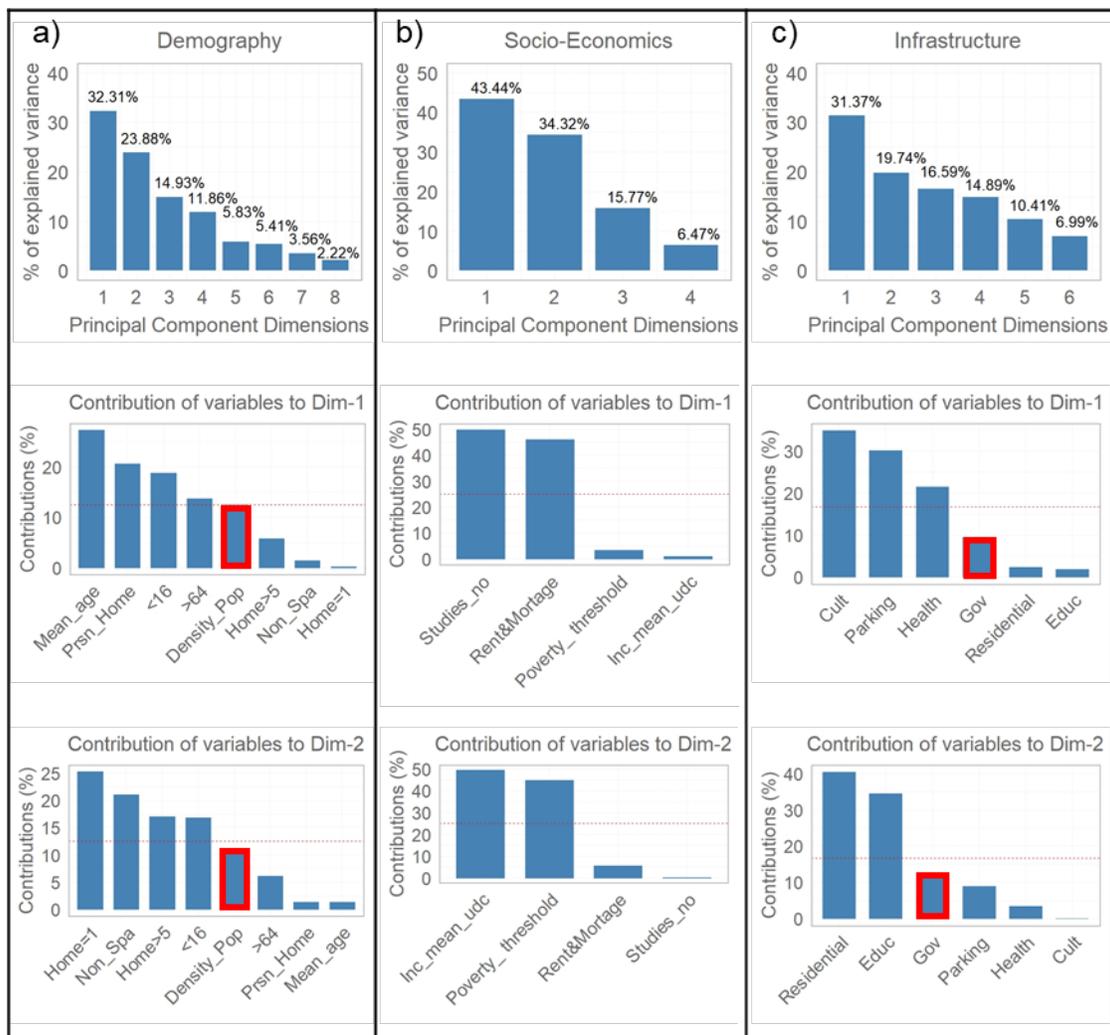


Figura 30. Porcentaje de varianza explicado por cada dimensión de los componentes principales (fila superior) y contribuciones de cada variable en las dimensiones 1 y 2 (segunda y tercera fila). La línea de puntos representa el umbral que define la importancia de esa contribución. Las barras marcadas en rojo corresponden a las variables descartadas durante el análisis de componentes principales (PCA) por no contribuir a ninguna de las dos dimensiones más preponderantes en la explicación de la varianza espacial por encima del umbral. a) Demografía b) Socioeconomía c) Infraestructuras.

En el mapa de la clase socioeconómica, las 2 secciones con valores altos coincidieron con las secciones 1ª y 3ª más vulnerables de la clase demográfica. En este caso, este alto valor se debió a la presencia de personas sin educación (o que aún no han obtenido el graduado escolar), donde en su totalidad son niños menores de 16 años, y a un número de hogares que actualmente están pagando alquiler o una hipoteca. Esto indica, en contraste con el centro de la ciudad, que estas personas acaban de instalarse en esta área y son más vulnerables financieramente que aquellas de áreas donde la vivienda no representa actualmente un esfuerzo financiero.

En cuanto a la clase de infraestructura, el subíndice estuvo fuertemente dominado por el gran número de edificios universitarios en una de las áreas censales. Las siguientes 4 áreas censales con el valor de vulnerabilidad de infraestructura más alto también se caracterizaron por un gran número de centros educativos. Esto resaltó la gran variabilidad espacial de los centros educativos entre las

diferentes áreas censales de la ciudad. Esta variable tiene implicaciones de vulnerabilidad directa para los trabajadores y estudiantes, pero también para los familiares responsables de estos estudiantes, que podrían verse indirectamente afectados si estas infraestructuras se ven afectadas por inundaciones.

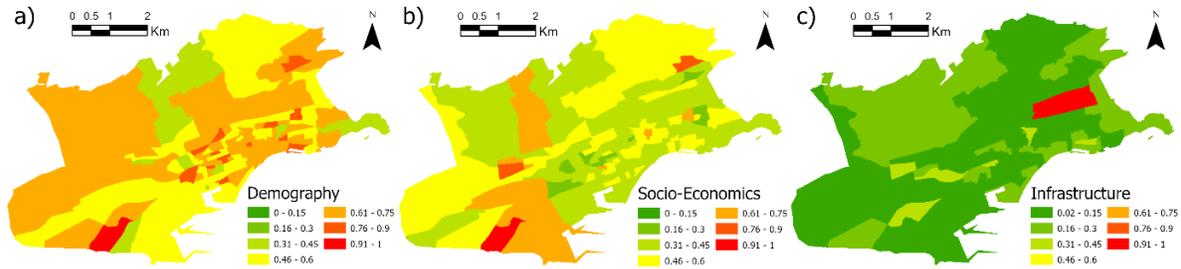


Figura 31. Mapas de subíndice de vulnerabilidad por clase. a) Demográfica. b) Socioeconómica. c) Infraestructuras.

4.3.3 Cálculo de la vulnerabilidad espacial

Las diferencias en los valores de cada sección censal se examinaron mediante el análisis de componentes principales en los valores de las variables (figura 32). En la clase demográfica, los dos primeros componentes principales explicaron el 56,2% de la variabilidad espacial. Se pudo apreciar en las variables cierto patrón de distribución por pares cuando se proyectan en el plano bidimensional utilizando los 2 primeros componentes principales. Los resultados indicaron relaciones espaciales positivas entre las siguientes parejas de variables: personas mayores de 64 años y densidad de población; personas extranjeras y familias unipersonales; familias con más de 5 miembros y personas menores de 16 años. También se encontró una relación negativa entre la edad media y el tamaño medio de la vivienda.

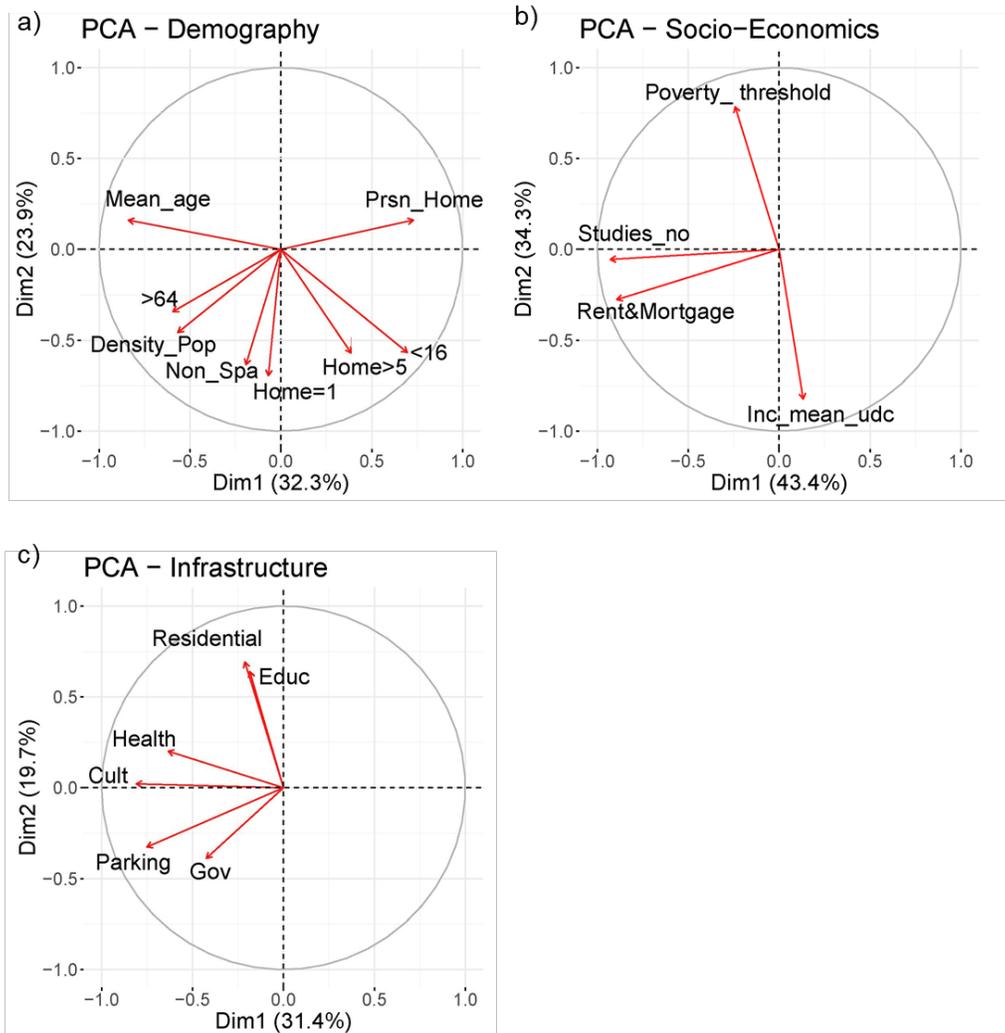


Figura 32. Biplot de las 2 dimensiones más preponderantes que muestran las varianzas de las dimensiones principales a partir del análisis de componentes principales (PCA). a) Variables demográficas. b) Variables socioeconómicas. c) Variables de infraestructura.

Como posibles razones detrás de estas relaciones en la clase demográfica se puede apuntar a que las personas mayores viven en las áreas más céntricas y densamente pobladas de la ciudad (García Ballesteros & Jiménez Blasco, 2016). Además, como muestra la figura 32, la relación entre los extranjeros y las familias unipersonales puede ser un comportamiento relacionado con la inmigración, pero también una forma de comportamiento de los nativos que no abandonan su unidad familiar de forma individual (Requena y Díez de Revenga, 2002). Sin embargo, en el análisis de correlación anterior, este comportamiento no fue evidente. Esta discrepancia puede deberse al hecho de que los componentes principales explicaron el 50% de la distribución espacial. Las otras dos relaciones que se encontraron en esta clase indicaron que cuanto mayor es el número de personas menores de 16 años, mayor es el número de familias numerosas (más de 5 miembros). Esto está relacionado con el hecho de que, a menor edad media en el distrito censal, mayor es el tamaño medio de la vivienda. Una posible explicación es que las familias numerosas están compuestas por un mayor número de niños y las secciones censales donde este tipo de familia es prevalente tienden a tener una edad media más baja.

En la clase socioeconómica, los dos primeros componentes principales explicaron el 77,7% de la variabilidad. Se observaron relaciones entre personas sin educación y aquellas que tienen una hipoteca o un contrato de alquiler de vivienda, y entre el ingreso promedio del hogar y el umbral de pobreza. En esta clase, las relaciones más claras se encontraron en el ámbito económico, donde a mayor variable de ingresos, menor es el valor de umbral de pobreza. En cuanto a la clase de infraestructura, solo se encontró una relación espacial entre el número de edificios residenciales y la infraestructura destinada para la educación.

4.3.4 Test de sensibilidad

Los resultados del test de sensibilidad muestran que hay un área en la periferia sur donde se observó una alta vulnerabilidad en todos los escenarios, aunque este efecto es menos pronunciado con pesos más altos para la clase de infraestructura (figura 33). En el escenario de pesos equitativos, se encontraron áreas vulnerables en el centro de la ciudad que limitan con el área de la bahía (al sur del centro). En general, no se encontraron anomalías en las sumas ponderadas y los valores no fueron sensibles a las variaciones de peso. Por lo tanto, en la siguiente sección se consideró el uso del escenario de pesos equitativos para el estudio adicional.

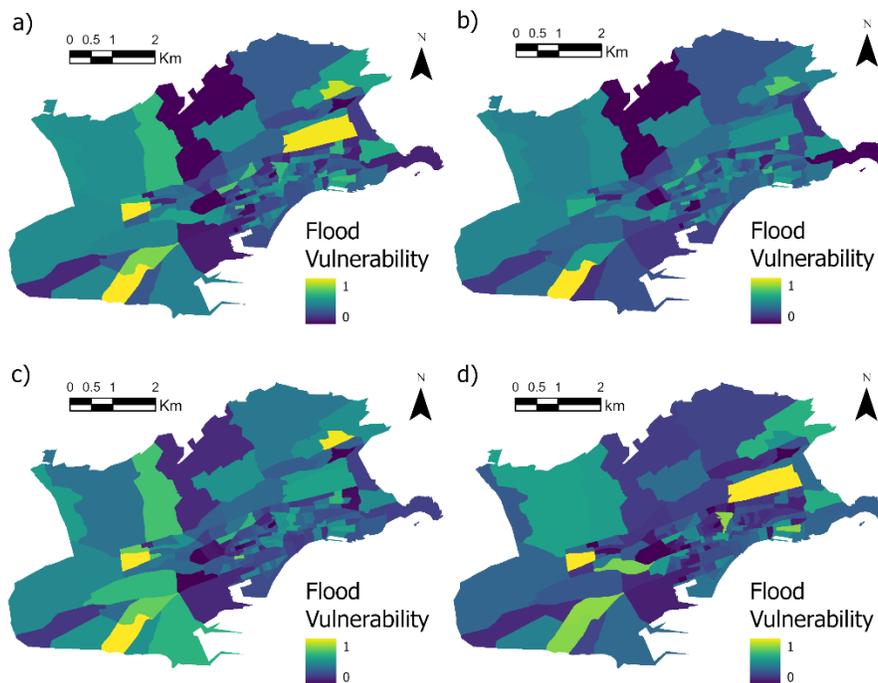


Figura 33. Mapas de sensibilidad a la ponderación de las clases. a) Ponderación equitativa, b) 2/3 demografía c) 2/3 socioeconomía d) 2/3 infraestructuras.

4.3.5 Mapa de riesgo

Los mapas de vulnerabilidad y peligro a menudo no producen las mismas zonas críticas. Esto se debe al hecho de que el peligro suele estar a lo largo de los ríos coincidiendo con sus zonas inundables, áreas de acumulación de flujo o cerca de la costa, mientras que la distribución de la vulnerabilidad está determinada por variables como las sugeridas en la tabla 5. El mapa de vulnerabilidad calculado

con el escenario equitativo mostró cuatro zonas con puntuaciones elevadas. Estas zonas no siguieron un patrón particular en cuanto a la topografía de la ciudad. Se caracterizaron por un gran número de niños menores de 16 años, un mayor número de personas que pagan alquiler o hipoteca y una concentración de instalaciones educativas. Además, en este caso de estudio, el mapa de peligro abarcó una zona ligeramente más pequeña que el mapa de vulnerabilidad. Esto se debió a limitaciones en la resolución espacial en el cálculo de las áreas de captación en las zonas costeras durante el análisis de la escorrentía acumulada. Sin embargo, todos los distritos censales estuvieron representados en la figura 34.

El mapa de riesgo resultante mostró 3 áreas de alto riesgo, una en cada una de las principales cuencas de la ciudad. El área del noroeste está compuesta por viviendas unifamiliares con muy poco desarrollo urbano. La sección censal correspondiente es un territorio amplio con la mayoría de la población residiendo en la parte sur, fuera de peligro y evitando el riesgo. Otra circunscripción de alto riesgo se encontró cerca del humedal situado al oeste, donde se ubica alguna de las principales carreteras de la ciudad. Finalmente, la zona cerca del centro de la ciudad se caracterizó por una urbanización densa, canalizando la escorrentía de las áreas altas e impermeables aguas abajo.

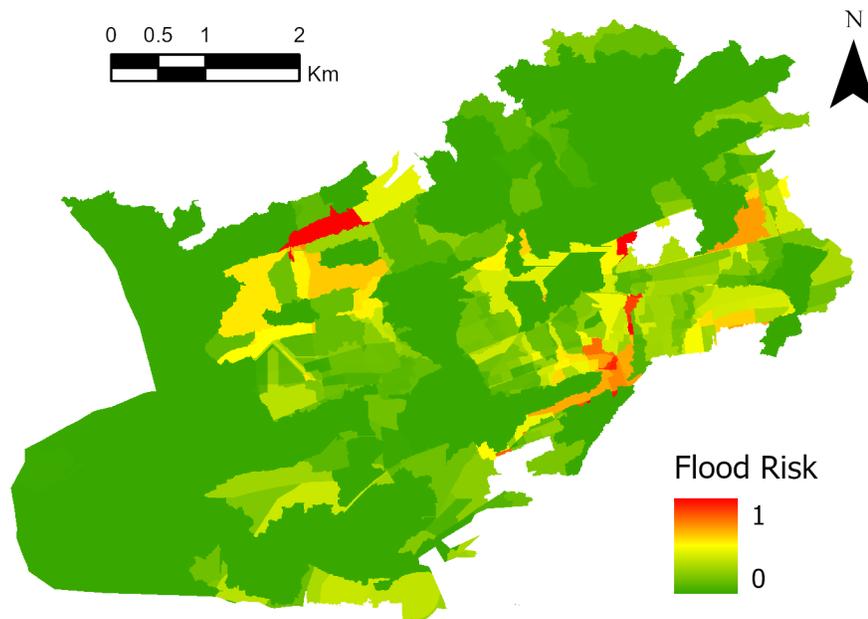


Figura 34. Mapa de riesgo de inundación de Santander, creado combinando el mapa de vulnerabilidad y el mapa de peligrosidad (caudal máximo acumulada) de la figura 16b.

4.3.6 Discusión

Este estudio propuso una solución para la reducción de variables. En estudios previos, la selección de variables se realizaba exclusivamente en función de la disponibilidad de datos, criterios subjetivos (Guillard-Gonçalves et al., 2015) o análisis de correlación (Peduzzi et al., 2009). Por ello, en este estudio se utilizó un procedimiento híbrido utilizando técnicas estadísticas para seleccionar

los conjuntos de datos disponibles que explican la mayor parte de la vulnerabilidad. En cuanto a la cobertura de la mayoría de los elementos vulnerables dentro de la ciudad, este trabajo mejora estudios previos en los que solo se evaluaba el alcance social, como el Índice de Vulnerabilidad Social (SoVI) (Cutter et al., 2006) que se utiliza actualmente en todo el mundo (Bouaakkaz et al., 2022; Guillard-Gonçalves et al., 2015).

Los fallos estructurales son una de las principales causas de daños extensos por inundaciones, lo que destaca su importancia en la evaluación del riesgo (Deshmukh et al., 2011). Se incluyó la vulnerabilidad de las infraestructuras críticas, una categoría que no se considera en la mayoría de la literatura sobre índices de vulnerabilidad a inundaciones urbanas recientes. Esto proporcionó una visión holística de la vulnerabilidad a las inundaciones.

Enfocarse en las poblaciones vulnerables en la ciudad mejora la preparación y los esfuerzos de socorro (Y. Chen et al., 2022; Maantay & Maroko, 2009). La metodología seguida permitió seleccionar las variables más relevantes e identificar las áreas con mayor vulnerabilidad. Este trabajo obtuvo resultados que concuerdan con estudios previos, especialmente para el centro de la ciudad de Santander (Jato-Espino et al., 2019), y son similares al Plan de Emergencia Municipal que el Ayuntamiento de Santander publicó en 2016 para identificar puntos críticos de riesgo de inundación (Ayuntamiento de Santander, 2016).

Este análisis demuestra que las áreas más vulnerables de Santander se determinaron por variables como la presencia de niños menores de 16 años, el mayor número de personas que pagan alquiler o hipoteca y la mayor concentración de instalaciones educativas. Estos resultados son consistentes con estudios previos sobre vulnerabilidad en otras partes del mundo, donde se ha demostrado que estas variables también son significativas. Los niños son un grupo con capacidad limitada para lidiar con inundaciones, y su dependencia para sobrevivir durante las inundaciones se ha observado en Greater Manchester (Reino Unido), Aotearoa (Nueva Zelanda) o Estados Unidos (Ashley & Ashley, 2008; Kaźmierczak & Cavan, 2011; Mason et al., 2021). Del mismo modo, las personas con deudas hipotecarias son la principal causa de vulnerabilidad a las inundaciones en comunidades de bajos ingresos en el estado de Luisiana (EE. UU.) (Deria et al., 2020). Además, las personas con bajo nivel de educación se correlacionaron con áreas de riesgo de inundación en Virginia (Eghdami et al., 2023). Se ha reconocido que la infraestructura crítica más afectada por las inundaciones a menudo está relacionada con las instalaciones educativas (Hemmati et al., 2021; UNISDR, 2007). Estas variables podrían incluso tener un efecto más pronunciado en áreas de economías emergentes con más dificultades para apoyar a estos grupos de población (Mucherera & Mavhura, 2020; Pandey et al., 2010; Qasim et al., 2015, 2016).

No se produjo una contribución significativa a la variabilidad por densidad de población (clase demográfica) y edificios gubernamentales (clase de infraestructura) (figura 30). Esto no implica que estas variables no sean relevantes para la vulnerabilidad, pero fueron homogéneas en todos los distritos censales para este caso de estudio. Incluso las variables descartadas en el análisis de correlación pueden ser relevantes en otras ubicaciones.

Es aconsejable, por lo tanto, aplicar la metodología completa al analizar otros casos de estudio para encontrar las variables relevantes. No obstante, existen ciertos problemas en áreas poco pobladas donde estas secciones censales son demasiado grandes para una evaluación precisa de la

vulnerabilidad. Por lo tanto, es necesario prestar especial atención a esas áreas en la periferia de la ciudad, donde la densidad de población es menor al combinar los datos de vulnerabilidad y peligro.

5 Conclusiones

La sección de conclusiones de esta tesis doctoral ofrece una síntesis integral de los hallazgos y contribuciones significativas en el ámbito de la planificación urbana sostenible. Al centrarse en la gestión de inundaciones, el efecto isla de calor urbano (UHI) y la vulnerabilidad urbana, la investigación adopta un enfoque interdisciplinario que pone en valor el uso de los sistemas de información geográfica (SIG) y el análisis estadístico. Estos descubrimientos no solo contribuyen al conocimiento existente sobre la interacción entre morfología urbana, desafíos ambientales y vulnerabilidad, sino que también tienen implicaciones prácticas para la planificación urbana y la formulación de políticas. La sección concluye con propuestas para futuras líneas de investigación, destacando la mejora de las metodologías existentes y la unificación de herramientas para abordar de manera integral los problemas ambientales urbanos.

5.1 Conclusiones generales

Los hallazgos de esta tesis doctoral apoyan la toma de decisiones para una planificación urbana sostenible. Sus contribuciones originales a su campo de investigación han proporcionado herramientas y enfoques novedosos para abordar los problemas ambientales urbanos. En este ámbito, el objetivo principal era proporcionar herramientas efectivas para abordar los desafíos ambientales urbanos, centrándose en la gestión de inundaciones, el efecto UHI y la vulnerabilidad urbana. Para lograr este objetivo, se implementó una metodología de investigación que involucró sistemas de información geográfica (SIG) y análisis estadístico a través de un enfoque interdisciplinario. Los resultados de esta tesis se relacionan con investigaciones previas y teorías existentes que tienen relevancia y aportan conocimiento nuevo sobre la interacción entre la morfología urbana, los desafíos ambientales y la vulnerabilidad urbana.

En cuanto a las hipótesis propuestas, se puede concluir que:

- El método racional de cálculo de escorrentía es adecuado para identificar zonas de peligro de inundación en entornos urbanos. Las zonas detectadas con la metodología propuesta coinciden con las señaladas por estudios previos publicados por la administración del área de estudio.
- Es posible crear escenarios en entorno SIG que simulen las características de las NBS y cuantificar su efecto positivo en la mitigación de inundaciones. El modelo creado es capaz de simular la capacidad de retención de escorrentía de estas infraestructuras mejorando los resultados significativamente.
- La modelización del efecto UHI es posible a partir de un conjunto de variables que definen las características morfológicas urbanas mediante algoritmos de aprendizaje entrenados con datos de mediciones satelitales de temperatura superficial.
- Los algoritmos de aprendizaje automático pueden identificar las principales características morfológicas de la ciudad que afectan a la formación del efecto UHI, entre las que destacaron la altura de los edificios y el albedo.
- El método propuesto identificó, clasificó y seleccionó diferentes variables demográficas, socioeconómicas e infraestructurales influyentes en la vulnerabilidad urbana ante peligros de inundaciones.
- El análisis de componentes principales (PCA) es una metodología eficaz para identificar el desequilibrio espacial de las variables que influyen en la vulnerabilidad.

Los hallazgos de esta tesis tienen el potencial de impactar en las prácticas de planificación urbana, la formulación de políticas y la sociedad en general. Pueden mejorar la capacidad de las ciudades para abordar los problemas ambientales y aumentar su resiliencia ante los desastres. Sin embargo, es importante reconocer que esta investigación tiene limitaciones, como restricciones de disponibilidad de datos o simplificaciones en los modelos utilizados. Estas limitaciones pueden haber influido en los resultados y deben considerarse en futuras investigaciones.

5.2 Conclusiones específicas

5.2.1 Modelo hidrológico urbano

En este apartado de la tesis doctoral se diseñó, testeó y validó un complemento o *add-in* SIG llamado ArcDrain, que tiene como objetivo facilitar el cálculo del caudal máximo en cuencas urbanas. ArcDrain se basa en el método racional, cuya simplicidad y facilidad de aplicación están alineadas con la idea de crear una herramienta que permita la evaluación rápida de la escorrentía superficial. Los datos necesarios para ejecutarlo incluyen un modelo digital de elevación (MDE), un mapa geológico o litoestratigráfico, un mapa de cobertura terrestre y una capa con los valores de precipitación en el área de estudio. Estos datos se pueden obtener de repositorios de acceso abierto continentales o globales, lo que garantiza la aplicabilidad de ArcDrain a escala mundial.

Los resultados logrados utilizando la ciudad de Santander (norte de España) como caso de estudio resaltaron la precisión del *add-in*, ajustándose a las áreas propensas a inundaciones identificadas por su ayuntamiento en su plan de emergencia municipal para inundaciones (Ayuntamiento de Santander, 2016). Un análisis estadístico reveló que existían diferencias significativas entre los valores de acumulación de caudal máximo en las subcuencas dentro de las áreas identificadas como críticas y el resto. A diferencia de los modelos continuos basados en SIG para la predicción de inundaciones, el enfoque propuesto estableció relaciones entre las subcuencas que forman el área de estudio, lo que es muy útil para identificar aquellas ubicaciones de origen de la escorrentía acumulada. A su vez, esto ayuda a la localización de lugares estratégicos donde implementar las medidas de mitigación.

Para ejemplificar esta implantación, se modificaron parte de las superficies con un valor alto de escorrentía de las subcuencas que contribuían a las mayores acumulaciones de escorrentía. Estas modificaciones ayudaron a reducir el coeficiente de escorrentía de esas subcuencas, contribuyendo así a atenuar su acumulación aguas abajo. Las pruebas de varios escenarios de reemplazo revelaron que el 25% de la superficie reemplazada era el umbral a partir del cual las diferencias entre las subcuencas relacionadas con las inundaciones y las no relacionadas dejaron de ser estadísticamente significativas.

Este hecho subraya la eficacia de la actuación con técnicas como las NBS para atenuar la impermeabilidad de las superficies urbanas, lo que proporciona una solución para hacer frente a las amenazas cada vez mayores que plantea la urbanización y el cambio climático. Por ello, la planificación urbana debe orientarse hacia el fomento de la implementación de este tipo de prácticas, dando importancia a su conectividad con las infraestructuras ya instaladas para aprovechar al máximo sus beneficios e intentando replicar el ciclo hidrológico natural tanto como sea posible. Así, ArcDrain surge como una herramienta para impulsar este enfoque mediante la simplificación de la gestión del agua urbana a través de la identificación de ubicaciones estratégicas para implementar las medidas de mitigación de inundaciones. Hemos de advertir también las principales limitaciones de esta aproximación al modelado hidrológico, relacionadas con su extensión geográfica limitada, la falta de mediciones de flujo de agua para fines de calibración y la reducida capacidad de personalización del *add-in* en cuanto a la entrada de datos.

5.2.2 Modelado de predicción del efecto isla de calor urbano

Similar al anterior, este apartado se ha centrado en el desarrollo de ArcUHI, un *add-in* que combina algoritmos de aprendizaje automático y SIG para proporcionar una herramienta independiente de modelización del efecto UHI. ArcUHI combina álgebra de mapas y otras funciones de estadísticas zonales disponibles en ArcGIS con una serie de algoritmos de regresión ejecutados en R para predecir el efecto isla de calor urbano superficial (SUHI), que se representa mediante la amplitud térmica diaria en la temperatura de las diferentes superficies urbanas. Los datos necesarios para alimentar este *add-in* son ampliamente accesibles a través de repositorios de datos en abierto, lo que también garantiza su utilidad para diferentes localizaciones.

La validez de ArcUHI se puso a prueba mediante un caso de estudio en el área metropolitana de Madrid (España), que es muy sensible al efecto SUHI. Los resultados indicaron que eran necesarios algoritmos de aprendizaje automático no lineales para obtener predicciones de alta precisión, debido a las complejas relaciones entre las variables involucradas. En este sentido, el ajuste proporcionado por la Random Forest Regression (RFR) fue especialmente notable, incluso al considerar tres años diferentes (2006, 2012 y 2018). El coeficiente de determinación (R^2) obtenido para los conjuntos de datos de entrenamiento y testeo (divididos en una proporción de 70:30) fue de 0,96 y 0,80, respectivamente, mientras que la raíz del error cuadrático medio (RMSE) fue de 0,83 y 1,65 °C, respectivamente.

Estos resultados no solo sirvieron para localizar puntos con mayor efecto SUHI, sino también para identificar cuáles eran las causas tras ellos. En este sentido, se encontró que la altura de los edificios y el albedo eran los factores más determinantes para impulsar el efecto SUHI, señalando así a las superficies construidas como los principales contribuyentes de la retención de calor en el área de estudio. Posibles medidas para mitigar el efecto de ambas variables podrían consistir en la renovación de áreas urbanas con NBS tanto vertical como horizontal. También, La ubicación estratégica de NBS podría generar un efecto de enfriamiento a través de la ventilación y sombreado.

La integración automatizada de algoritmos de aprendizaje automático en un entorno SIG puede facilitar la implementación efectiva de tales medidas en el futuro, ya que los organismos de administración pública están acostumbrados a trabajar con SIG para manejar datos espaciales. Por lo tanto, ArcUHI proporciona una herramienta fácil de usar y poco exigente en cuanto a los requisitos de datos para predecir el efecto SUHI con precisión, sirviendo como base para prevenir este fenómeno a través de estrategias de localización destinadas a maximizar los beneficios de regulación térmica ofrecida por las NBS. No obstante, la precisión de ArcUHI deberá ser estudiada en otras regiones con características climáticas diferentes y también aplicada a otros periodos estacionales (por ejemplo, efecto UHI en épocas invernales) para corroborar su utilidad.

5.2.3 Índice de vulnerabilidad urbana

Para esta evaluación, se seleccionaron y clasificaron variables relacionadas con la vulnerabilidad ante inundaciones para estudiar su distribución espacial dentro de las secciones censales de la ciudad de Santander. Esto se realizó mediante una metodología basada en la selección de variables relevantes y su posterior análisis estadístico. Las variables seleccionadas fueron ponderadas para producir un índice de vulnerabilidad basado en tres clases diferentes de vulnerabilidad:

demográfica, socioeconómica y de infraestructura. Finalmente, se obtuvo un mapa de riesgo al combinar los resultados de la vulnerabilidad con los de la peligrosidad derivados del primer apartado de esta misma tesis doctoral con la que comparte caso de estudio.

Este método fue satisfactorio para determinar las variables y áreas (secciones censales) más significativas dentro de una ciudad. Este estudio ha identificado dos áreas en la ciudad de Santander con una alta vulnerabilidad demográfica y socioeconómica, y un área con una alta vulnerabilidad debido a las infraestructuras que contiene. También se encontraron tres áreas críticas en términos de riesgo de inundación, una por cada una de las principales subcuencas de la ciudad.

La segregación de los datos en las diferentes secciones censales utilizadas para obtener el índice de vulnerabilidad puede ser utilizada para cualquier ciudad en España. Estos datos y sus correspondientes actualizaciones temporales también permiten observar la evolución de una misma ciudad a lo largo del tiempo. Sin embargo, existen ciertos problemas en áreas escasamente pobladas donde estas secciones censales son demasiado grandes para una evaluación precisa de la vulnerabilidad. Por ello, se debe prestar especial atención al combinar vulnerabilidad y peligrosidad en áreas en la periferia de la ciudad, donde la densidad de población es menor.

Gracias a este estudio de las áreas más vulnerables, se pueden tomar futuras medidas de mitigación para reducir la vulnerabilidad ante inundaciones. Para ello, los urbanistas pueden hacer uso de aplicaciones SIG y establecer nuevos escenarios que reduzcan el impacto social de estos eventos naturales de la manera más eficiente posible, ayudando a las administraciones a utilizar de manera óptima sus recursos contra el cambio climático y sus posibles efectos adversos.

5.3 Futuras líneas de investigación

La presente tesis ha arrojado luz sobre diversos aspectos cruciales relacionados con la planificación urbana sostenible y la gestión de problemas ambientales en entornos urbanos. Como en cualquier campo científico en constante evolución, los hallazgos y resultados de este estudio abren la puerta a posibles líneas de investigación futuras. Por ello, en esta sección se plantean propuestas a partir de los resultados obtenidos en esta tesis doctoral que abordan tanto la mejora de las metodologías y herramientas desarrolladas como la expansión hacia nuevas tecnologías y funcionalidades. Las futuras líneas sugeridas se presentan de acuerdo a los tres bloques en que se estructura la tesis doctoral.

5.3.1 Modelo hidrológico urbano

- Aplicación del modelado propuesto a otras regiones con características climáticas diferentes para validar su precisión.
- Inclusión de la red de alcantarillado con el objetivo de estudiar su influencia en la capacidad de mitigación de la escorrentía superficial.
- Flexibilización y adaptación de la metodología a las especificidades de otros casos de estudio en términos de disponibilidad de datos.
- Desarrollo de un módulo de creación de diferentes escenarios incluyendo NBS de forma iterativa que permita calcular sus posiciones óptimas y clasificarlas por su rendimiento/coste.
- Gamificación de los resultados para la difusión y asimilación de los beneficios de las NBS hacia el público general.

5.3.2 Modelo de predicción del efecto isla de calor urbano

- Aplicación de esta metodología en otras localizaciones y análisis de las similitudes o diferencias de los factores principales generadores de efecto UHI respecto a los obtenidos en esta tesis.
- Integración del componente SIG del módulo y obtención de los datos satelitales de medición de temperatura superficial en software R.
- Uso de otras variables dependientes derivadas de la temperatura para modelizar el efecto UHI.
- Exploración de las posibilidades de utilizar esta metodología de predicción del efecto SUHI para las otras tipologías del efecto UHI.
- Creación de un sistema de entrada de datos en tiempo real para la alerta temprana a la población.

5.3.3 Índice de vulnerabilidad urbana

- Análisis y comparación a lo largo del tiempo de las desigualdades de una misma ciudad o de diferentes ciudades en el mismo momento temporal.

- Extensión del uso de esta metodología para estudiar la vulnerabilidad en las ciudades frente a otros problemas ambientales.
- Creación de módulo para la elaboración automática de informes de las zonas más vulnerables y de sus causas principales para tomadores de decisiones.
- Participación ciudadana para cotejar la ubicación de las zonas en riesgo.
- Consulta a expertos para la determinación de los factores más importantes en la vulnerabilidad.

5.3.4 Unificación, aplicación y sinergia

Aunque se ha realizado una integración de dos de las tres partes de la tesis, adentrándose en la combinación del peligro de inundación y su vulnerabilidad, cabría destacar que una notable mejora y futura línea de investigación podría surgir de la unión de estas herramientas bajo el mismo software e interfaz para su fácil uso por los técnicos o tomadores de decisiones. También en esa hipotética interfaz podrían añadirse módulos que localicen y cuantifiquen otros problemas ambientales urbanos como la contaminación atmosférica, acústica, lumínica o la pérdida de biodiversidad, desarrollando una aplicación o sistema de detección de problemas urbanos derivados de la planificación urbanística futura o presente.

Otra aplicación futura es la creación de propuestas y escenarios (manuales o automatizados) en los que la implementación de las NBS no fuera solo asociada a una medida de mitigación contra un problema ambiental determinado, sino poder crear sinergias entre diferentes NBS que mitiguen diferentes problemas ambientales, abordando de manera holística las casuísticas de cada ciudad.

6 Referencias

- Abdi, H., & Williams, L. J. (2010). Principal component analysis. *Wiley Interdisciplinary Reviews: Computational Statistics*, 2(4), 433–459. <https://doi.org/10.1002/wics.101>
- Aboelata, A. (2020). Vegetation in different street orientations of aspect ratio (H/W 1:1) to mitigate UHI and reduce buildings' energy in arid climate. *Building and Environment*, 172, 106712. <https://doi.org/10.1016/j.buildenv.2020.106712>
- Abson, D. J., Dougill, A. J., & Stringer, L. C. (2012). Using Principal Component Analysis for information-rich socio-ecological vulnerability mapping in Southern Africa. *Applied Geography*, 35(1–2), 515–524. <https://doi.org/10.1016/j.apgeog.2012.08.004>
- Adger, W. N. (2006). Vulnerability. *Global Environmental Change*, 16(3), 268–281. <https://doi.org/10.1016/j.gloenvcha.2006.02.006>
- Adilkhanova, I., Ngarambe, J., & Yun, G. Y. (2022). Recent advances in black box and white-box models for urban heat island prediction: Implications of fusing the two methods. *Renewable and Sustainable Energy Reviews*, 165, 112520. <https://doi.org/10.1016/j.rser.2022.112520>
- Ahiablame, L., & Shakya, R. (2016). Modeling flood reduction effects of low impact development at a watershed scale. *Journal of Environmental Management*, 171, 81–91. <https://doi.org/10.1016/j.jenvman.2016.01.036>
- Ahmed, S. (2018). Assessment of urban heat islands and impact of climate change on socioeconomic over Suez Governorate using remote sensing and GIS techniques. *The Egyptian Journal of Remote Sensing and Space Science*, 21(1), 15–25. <https://doi.org/10.1016/j.ejrs.2017.08.001>
- AIRBUS Defence and Space. (2021). *WorldDEM™ Neo Technical Product Description*. 1–5. https://storage.googleapis.com/p-oaf-ibe-back-00e-strap-i-uploads/worlddem_neo_technical_description_092021_5dd1c151d5/worlddem_neo_technical_description_092021_5dd1c151d5.pdf (Fecha de último acceso: 20 de noviembre 2023)
- Ajtai, I., Ștefănie, H., Maloș, C., Botezan, C., Radovici, A., Bizău-Cârstea, M., & Baciuc, C. (2023). Mapping social vulnerability to floods. A comprehensive framework using a vulnerability index approach and PCA analysis. *Ecological Indicators*, 154, 110838. <https://doi.org/10.1016/j.ecolind.2023.110838>
- Akbari, H., Pomerantz, M., & Taha, H. (2001). Cool surfaces and shade trees to reduce energy use and improve air quality in urban areas. *Solar Energy*, 70(3), 295–310. [https://doi.org/10.1016/S0038-092X\(00\)00089-X](https://doi.org/10.1016/S0038-092X(00)00089-X)
- Akhter, M. S., & Hewa, G. A. (2016). The use of PCSWMM for assessing the impacts of land use changes on hydrological responses and performance of WSUD in managing the impacts at myponga catchment, South Australia. *Water (Switzerland)*, 8(11). <https://doi.org/10.3390/w8110511>
- Akoglu, H. (2018). User's guide to correlation coefficients. *Turkish Journal of Emergency Medicine*, 18(3), 91–93. <https://doi.org/10.1016/j.tjem.2018.08.001>
- Alexander, C. (2020). Normalised difference spectral indices and urban land cover as indicators of land surface temperature (LST). *International Journal of Applied Earth Observation and Geoinformation*, 86, 102013. <https://doi.org/10.1016/j.jag.2019.102013>
- Allende-Prieto, C., Méndez-Fernández, B. I., Sañudo-Fontaneda, L. A., & Charlesworth, S. M. (2018).

- Development of a geospatial data-based methodology for stormwater management in urban areas using freely-available software. *International Journal of Environmental Research and Public Health*, 15(8). <https://doi.org/10.3390/ijerph15081703>
- Alshemali, B., & Kalita, J. (2020). Improving the reliability of deep neural networks in NLP: A review. *Knowledge-Based Systems*, 191, 105210. <https://doi.org/10.1016/j.knosys.2019.105210>
- Alvaredo, F., Chancel, L., Piketty, T., Saez, E., & Zucman, G. (2018). The Elephant Curve of Global Inequality and Growth. *AEA Papers and Proceedings*, 108, 103–108. <https://doi.org/10.1257/pandp.20181073>
- Álvarez, M., Fonquernie, L., & Zaratiegui, A. G. (2021, Noviembre 2). *Más de una hora de inundación en El Sardinero*. El Diario Montañés. <https://www.eldiariomontanes.es/santander/lluvia-inunda-sardinero-20211104142552-nt.html>
- Andersson-Sköld, Y., Thorsson, S., Rayner, D., Lindberg, F., Janhäll, S., Jonsson, A., Moback, U., Bergman, R., & Granberg, M. (2015). An integrated method for assessing climate-related risks and adaptation alternatives in urban areas. *Climate Risk Management*, 7, 31–50. <https://doi.org/10.1016/j.crm.2015.01.003>
- Arnold Jr, C. L., & Gibbons, C. J. (1996). Impervious surface coverage: the emergence of a key environmental indicator. *Journal of the American Planning Association*, 62(2), 243–258. <https://doi.org/10.1080/01944369608975688>
- Arup. (2023). *Urban Heat Snapshot*. <https://www.arup.com/perspectives/publications/research/section/urban-heat-snapshot> (Fecha de último acceso: 20 de noviembre 2023)
- Ashley, S. T., & Ashley, W. S. (2008). Flood fatalities in the United States. *Journal of Applied Meteorology and Climatology*, 47(3), 805–818. <https://doi.org/10.1175/2007JAMC1611.1>
- Au, T. C. (2018). Random forests, decision trees, and categorical predictors: the "absent levels" problem. *The Journal of Machine Learning Research*, 19(1), 1737–1766. <https://doi.org/10.48550/arXiv.1706.03492>
- Ayuntamiento de Madrid. (2022). Hoja de Ruta hacia la neutralidad climática en 2050. <https://www.madrid.es/portales/munimadrid/es/Inicio/Medio-ambiente/Hoja-de-Ruta-hacia-la-neutralidad-climatica-en-2050/?vgnnextoid=7c1395b79fde7710VgnVCM2000001f4a900aRCRD&vgnnextchannel=3edd31d3b28fe410VgnVCM1000000b205a0aRCRD> (Fecha de último acceso: 20 de noviembre 2023).
- Ayuntamiento de Madrid. (2023, Octubre 31). *Banco de Datos del Ayuntamiento de Madrid*. https://www-s.madrid.es/CSEBD_WBINTER/inicio.html (Fecha de último acceso: 20 de noviembre 2023)
- Ayuntamiento de Santander. (2016). *Plan de Emergencias Municipal de Santander (PEMUSAN)*. <https://www.santander.es/ciudad/plan-emergencias> (Fecha de último acceso: 20 de noviembre 2023)
- Ayuntamiento de Santander. (2023). *Las inundaciones de Nueva Montaña se debieron a unas lluvias extremas, según el IH*. <https://www.santander.es/content/inundaciones-nueva-montana-se-debieron-lluvias-extremas-segun-ih> (Fecha de último acceso: 20 de noviembre 2023)

- Azizi, K., Diko, S. K., Saija, L., Zamani, M. G., & Meier, C. I. (2022). Integrated community-based approaches to urban pluvial flooding research, trends and future directions: A review. *Urban Climate*, 44(December 2021), 101237. <https://doi.org/10.1016/j.uclim.2022.101237>
- Azizian, A. (2018). Uncertainty analysis of time of concentration equations based on first-order-analysis (FOA) method. *American Journal of Engineering and Applied Sciences*, 11(1), 327–341. <https://doi.org/10.3844/ajeassp.2018.327.341>
- Azizian, A., & Shokoohi, A. (2014). DEM resolution and stream delineation threshold effects on the results of geomorphologic-based rainfall runoff models. *Turkish Journal of Engineering and Environmental Sciences*, 38(1), 64–78. <https://doi.org/10.3906/MUH-1401-13>
- Bahi, H., Mastouri, H., & Radoine, H. (2020). Review of methods for retrieving urban heat islands. *Materials Today: Proceedings*, 27, 3004–3009. <https://doi.org/10.1016/j.matpr.2020.03.272>
- Baik, J.-J., Kim, Y.-H., & Chun, H.-Y. (2001). Dry and moist convection forced by an urban heat island. *Journal of Applied Meteorology*, 40(8), 1462–1475. [https://doi.org/10.1175/1520-0450\(2001\)040%3C1462:DAMCFB%3E2.0.CO;2](https://doi.org/10.1175/1520-0450(2001)040%3C1462:DAMCFB%3E2.0.CO;2)
- Baklanov, A., Sue, G., Alexander, M., & Athanassiadou, M. (2009). *Meteorological and air quality models for urban areas*. Springer. <https://doi.org/10.1007/978-3-642-00298-4>
- Balica, S. F., Douben, N., & Wright, N. G. (2009). Flood vulnerability indices at varying spatial scales. *Water Science and Technology*, 60(10), 2571–2580. <https://doi.org/10.2166/wst.2009.183>
- Ballard, B. W., Wilson, S., Udale-Clarke, H., Illman, S., Scott, T., Ashley, R., & Kellagher, R. (2015). The SUDS manual. CIRIA: London, UK. https://www.ciria.org/CIRIA/CIRIA/Item_Detail.aspx?iProductCode=C753F&Category=FREEPUBS (Fecha de último acceso: 20 de noviembre 2023)
- Ballester, J., Quijal-zamorano, M., Fernando, R., Turrubiates, M., Pegenaute, F., Herrmann, F. R., Robine, J. M., & Basagaña, X. (2023). *Heat-related mortality in Europe during the summer of 2022*. 29(July). <https://doi.org/10.1038/s41591-023-02419-z>
- Bandi, A. S., Meshapam, S., & Deva, P. (2019). A geospatial approach to flash flood hazard mapping in the city of Warangal, Telangana, India. *Environmental and Socio-Economic Studies*, 7(3), 1–13. <https://doi.org/10.2478/environ-2019-0013>
- Barreto, W., Ramos, N., Castro, K., Torres, J., Torres, R., & Picón, R. (2020). Development of a GIS Tool for Sustainable Urban Drainage Systems Evaluation. *IOP Conference Series: Earth and Environmental Science*, 503(1), 12033. <http://dx.doi.org/10.1088/1755-1315/503/1/012033>
- Bayulken, B., Huisingh, D., & Fisher, P. M. J. (2021). How are nature based solutions helping in the greening of cities in the context of crises such as climate change and pandemics? A comprehensive review. *Journal of Cleaner Production*, 288, 125569. <https://doi.org/10.1016/j.jclepro.2020.125569>
- Beck, H. E., Zimmermann, N. E., McVicar, T. R., Vergopolan, N., Berg, A., & Wood, E. F. (2018). Present and future Köppen-Geiger climate classification maps at 1-km resolution. *Scientific Data*, 5(1), 1–12. <https://doi.org/10.1038/sdata.2018.214>
- Beck, M. W. (2018). NeuralNetTools: Visualization and analysis tools for neural networks. *Journal of Statistical Software*, 85(11), 1. <https://doi.org/10.18637/jss.v085.i11>

- Behzad, M., Asghari, K., Eazi, M., & Palhang, M. (2009). Generalization performance of support vector machines and neural networks in runoff modeling. *Expert Systems with Applications*, *36*(4), 7624–7629. <https://doi.org/10.1016/j.eswa.2008.09.053>
- Bigi, V., Comino, E., Fontana, M., Pezzoli, A., & Rosso, M. (2021). Flood vulnerability analysis in urban context: A socioeconomic sub-indicators overview. *Climate*, *9*(1), 1–18. <https://doi.org/10.3390/cli9010012>
- Bindajam, A. A., Mallick, J., AlQadhi, S., Singh, C. K., & Hang, H. T. (2020). Impacts of vegetation and topography on land surface temperature variability over the semi-arid mountain cities of Saudi Arabia. *Atmosphere*, *11*(7), 762. <https://doi.org/10.3390/atmos11070762>
- Blaikie, P., Cannon, T., Davis, I., & Wisner, B. (2014). *At risk: natural hazards, people's vulnerability and disasters*. Routledge. ISBN 9780415252164
- Bodoque, J. M., Amérigo, M., Díez-Herrero, A., García, J. A., Cortés, B., Ballesteros-Cánovas, J. A., & Olcina, J. (2016). Improvement of resilience of urban areas by integrating social perception in flash-flood risk management. *Journal of Hydrology*, *541*, 665–676. <https://doi.org/10.1016/j.jhydrol.2016.02.005>
- Bottyán, Z., & Unger, J. (2003). A multiple linear statistical model for estimating the mean maximum urban heat island. *Theoretical and Applied Climatology*, *75*, 233–243. <https://doi.org/10.1007/s00704-003-0735-7>
- Botzen, W. J. W., Aerts, J., & van den Bergh, J. C. J. M. (2009). Dependence of flood risk perceptions on socioeconomic and objective risk factors. *Water Resources Research*, *45*(10). <https://doi.org/10.1029/2009WR007743>
- Bouaakkaz, B., Zine El Abidine, E. M., & Lhoussaine, B. (2022). Social vulnerability assessment to flood hazard in Souss basin, Morocco. *Journal of African Earth Sciences*, *198*(November 2022), 104774. <https://doi.org/10.1016/j.jafrearsci.2022.104774>
- Boughton, W. C. (1989). A review of the USDA SCS curve number method. *Soil Research*, *27*(3), 511–523. <https://doi.org/10.1071/SR9890511>
- Brears, R. C. (2018). *Blue and green cities: the role of blue-green infrastructure in managing urban water resources*. Springer. <https://doi.org/10.1057/978-1-137-59258-3>
- Breiman, L. (1996). Bagging predictors. *Machine Learning*, *24*, 123–140. <https://doi.org/10.1007/BF00058655>
- Breiman, L. (2001). Random forests. *Machine Learning*, *45*, 5–32. <https://doi.org/10.1023/A:1010933404324>
- Breiman, L., Friedman, J., Stone, C. J., & Olshen, R. A. (1984). *Classification and regression trees*. CRC press. <https://doi.org/10.1201/9781315139470>
- Briggs, P. R., & Cogley, J. G. (1996). Topographic bias in mesoscale precipitation networks. *Journal of Climate*, *9*(1), 205–218. [https://doi.org/10.1175/1520-0442\(1996\)009<0205:TBIMPN>2.0.CO;2](https://doi.org/10.1175/1520-0442(1996)009<0205:TBIMPN>2.0.CO;2)
- Bucherie, A., Hultquist, C., Adamo, S., Neely, C., Ayala, F., Bazo, J., & Kruczkiewicz, A. (2022). A comparison of social vulnerability indices specific to flooding in Ecuador: principal component analysis (PCA) and expert knowledge. *International Journal of Disaster Risk Reduction*,

- 73(March), 102897. <https://doi.org/10.1016/j.ijdr.2022.102897>
- Bulti, D. T., & Abebe, B. G. (2020). A review of flood modeling methods for urban pluvial flood application. *Modeling Earth Systems and Environment*, 6(3), 1293–1302. <https://doi.org/10.1007/s40808-020-00803-z>
- Burke, K. D., Williams, J. W., Chandler, M. A., Haywood, A. M., Lunt, D. J., & Otto-Bliesner, B. L. (2018). Pliocene and Eocene provide best analogs for near-future climates. *Proceedings of the National Academy of Sciences*, 115(52), 13288–13293. <https://doi.org/10.1073/pnas.1809600115>
- Burton, C. G. (2010). Social vulnerability and hurricane impact modeling. *Natural Hazards Review*, 11(2), 58–68. [https://doi.org/10.1061/\(ASCE\)1527-6988\(2010\)11:2\(58\)](https://doi.org/10.1061/(ASCE)1527-6988(2010)11:2(58))
- Buttstädt, M., & Schneider, C. (2014). Thermal load in a medium-sized European city using the example of Aachen, Germany. *Erdkunde*, 68(2), 71–83. <https://doi.org/10.3112/erdkunde.2014.02.01>
- Cardelino, C. A., & Chameides, W. L. (1990). Natural hydrocarbons, urbanization, and urban ozone. *Journal of Geophysical Research*, 95, 13971–13979. <https://doi.org/10.1029/JD095iD09p13971>
- Castro-Fresno, D., Andrés-Valeri, V. C., Sañudo-Fontaneda, L. A., & Rodríguez-Hernández, J. (2013). Sustainable drainage practices in Spain, specially focused on pervious pavements. *Water*, 5(1), 67–93. <https://doi.org/10.3390/w5010067>
- Cea, L., & Costabile, P. (2022). Flood Risk in Urban Areas: Modelling, Management and Adaptation to Climate Change: A Review. *Hydrology*, 9(3). <https://doi.org/10.3390/hydrology9030050>
- Chakraborty, L., Rus, H., Henstra, D., Thistlethwaite, J., & Scott, D. (2020). A place-based socioeconomic status index: Measuring social vulnerability to flood hazards in the context of environmental justice. *International Journal of Disaster Risk Reduction*, 43(July 2019), 101394. <https://doi.org/10.1016/j.ijdr.2019.101394>
- Chan, S. W., Abid, S. K., Sulaiman, N., Nazir, U., & Azam, K. (2022). A systematic review of the flood vulnerability using geographic information system. *Heliyon*, 8(3). <https://doi.org/10.1016/j.heliyon.2022.e09075>
- Chen, J., Hill, A. A., & Urbano, L. D. (2009). A GIS-based model for urban flood inundation. *Journal of Hydrology*, 373(1–2), 184 – 192. <https://doi.org/10.1016/j.jhydrol.2009.04.021>
- Chen, W., Wang, X., Deng, S., Liu, C., Xie, H., & Zhu, Y. (2019). Integrated urban flood vulnerability assessment using local spatial dependence-based probabilistic approach. *Journal of Hydrology*, 575(May), 454–469. <https://doi.org/10.1016/j.jhydrol.2019.05.043>
- Chen, Y., Liu, H., Ye, Z., Zhang, H., Jiang, B., & Zhang, Y. (2022). Social Justice in Urban–Rural Flood Exposure: A Case Study of Nanjing, China. *Land*, 11(9), 1588. <https://doi.org/10.3390/land11091588>
- Chicco, D., Warrens, M. J., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, 7, e623. <https://doi.org/10.7717/peerj-cs.623>
- Chimnyerem, N. U., Ndukwe, C. E., & Adannaya, N. U. (2016). Exploring the Inadequacy of

- Pertinent Capacities for Urban Flood Risk Management in the Developing Countries. *Journal of Social Sciences*, 12(3), 136–151. <https://doi.org/10.3844/jssp.2016.136.151>
- Cho, S. Y., & Chang, H. (2017). Recent research approaches to urban flood vulnerability, 2006–2016. *Natural Hazards*, 88(1), 633–649. <https://doi.org/10.1007/s11069-017-2869-4>
- Chuanyan, Z., Zhongren, N., & Guodong, C. (2005). Methods for modelling of temporal and spatial distribution of air temperature at landscape scale in the southern Qilian mountains, China. *Ecological Modelling*, 189(1–2), 209–220. <https://doi.org/10.1016/j.ecolmodel.2005.03.016>
- Cichosz, P., & Pawełczak, Ł. (2014). Imitation learning of car driving skills with decision trees and random forests. *International Journal of Applied Mathematics and Computer Science*, 24(3), 579–597. <https://doi.org/10.2478/amcs-2014-0042>
- Collins, T. W., Grineski, S. E., & Aguilar, M. de L. R. (2009). Vulnerability to environmental hazards in the Ciudad Juárez (Mexico)–El Paso (USA) metropolis: a model for spatial risk assessment in transnational context. *Applied Geography*, 29(3), 448–461. <https://doi.org/10.1016/j.apgeog.2008.10.005>
- Consejería de Sanidad de la Comunidad de Madrid. (2021). Vigilancia y Control de los Efectos de las Olas de Calor 2021. In *Comunidad.madrid*. https://www.comunidad.madrid/sites/default/files/doc/sanidad/calor/plan_de_vigilancia_y_control_efectos_olas_de_calor_2021.pdf (Fecha de último acceso: 20 de noviembre 2023)
- Copernicus. (2023a). *CORINE Land Cover 2018 (raster 100 m), Europe, 6-yearly - version 2020_20u1, May 2020*. <https://doi.org/10.2909/960998c1-1870-4e82-8051-6485205ebbac>
- Copernicus. (2023b). *CORINE Land Cover 2018 (vector), Europe, 6-yearly - version 2020_20u1, May 2020*. <https://doi.org/10.2909/71c95a07-e296-44fc-b22b-415f42acdf0>
- Copernicus. (2023c). *Urban Atlas*. <https://land.copernicus.eu/en/products/urban-atlas> (Fecha de último acceso: 20 de noviembre 2023)
- Coppock, J. T. (1995). Gis and Natural Hazards: An overview from a Gis Perspective. In *Geographical Information Systems in Assessing Natural Hazards* (pp. 21–34). Springer, Dordrecht. https://doi.org/10.1007/978-94-015-8404-3_2
- Cortez P (2020). *_rminer: Data Mining Classification and Regression Methods_*. R package version 1.4.6, <<https://CRAN.R-project.org/package=rminer>>. (Fecha de último acceso: 20 de noviembre 2023)
- Cortez, P., & Embrechts, M. J. (2013). Using sensitivity analysis and visualization techniques to open black box data mining models. *Information Sciences*, 225, 1–17. <https://doi.org/10.1016/j.ins.2012.10.039>
- CRED. (2023). *Disasters1 Year in Review 2022*. <https://cred.be/sites/default/files/CredCrunch70.pdf> (Fecha de último acceso: 20 de noviembre 2023)
- Cunge, J. A., Holly, F. M., & Verwey, A. (1980). Practical aspects of computational river hydraulics.. ISBN 978-0273084426
- Cutter, S. L., Boruff, B. J., & Lynn, S. W. (2006). Social Vulnerability to Environmental Hazards. In Routledge (Ed.), *Hazards Vulnerability and Environmental Justice* (p. 18). ISBN 9781844073115

- Cutter, S. L. (2003). The vulnerability of science and the science of vulnerability. *Annals of the Association of American Geographers*, 93(1), 1–12. <https://doi.org/10.1111/1467-8306.93101>
- Cutter, S. L., Mitchell, J. T., & Scott, M. S. (2000). Revealing the vulnerability of people and places: A case study of georgetown county, South Carolina. *Annals of the Association of American Geographers*, 90(4), 713–737. <https://doi.org/10.1111/0004-5608.00219>
- DAAC, O. (2018). *MODIS and VIIRS Land Products Global Subsetting and Visualization Tool*. ORNL Distributed Active Archive Center. <https://doi.org/10.3334/ORNLDAAC/1379>
- Dalu, M. T. B., & Shackleton, C. M. (2018). The potential use of natural resources in urban informal settlements as substitutes for financial capital during flooding emergencies. *Physics and Chemistry of the Earth*, 104 (November 2017), 18–27. <https://doi.org/10.1016/j.pce.2018.03.002>
- Damm, M. (2010). *Mapping social-ecological vulnerability to flooding. A sub-national approach for Germany*. - Bonn, 2010. - Dissertation, Rheinische Friedrich-Wilhelms-Universität Bonn. Online edition: <https://nbn-resolving.org/urn:nbn:de:hbz:5N-19978>
- De Gregorio, L., Callegari, M., Mazzoli, P., Bagli, S., Broccoli, D., Pistocchi, A., & Notarnicola, C. (2018). Operational river discharge forecasting with support vector regression technique applied to alpine catchments: Results, advantages, limits and lesson learned. *Water Resources Management*, 32, 229–242. <https://doi.org/10.1007/s11269-017-1806-3>
- de Groot, R. S., Wilson, M. A., & Boumans, R. M. J. (2002). A typology for the classification, description and valuation of ecosystem functions, goods and services. *Ecological Economics*, 41(3), 393–408. [https://doi.org/10.1016/S0921-8009\(02\)00089-7](https://doi.org/10.1016/S0921-8009(02)00089-7)
- Debbage, N., & Shepherd, J. M. (2015). The urban heat island effect and city contiguity. *Computers, Environment and Urban Systems*, 54, 181–194. <https://doi.org/10.1016/j.compenvurbsys.2015.08.002>
- del Pozo Gómez, M. (2009). Mapa Litoestratigráfico, de Permeabilidad e Hidrogeológico de España continuo digital a escala 1: 200.000. Convenio de colaboración entre el Ministerio de Medio Ambiente y el Instituto Geológico y Minero de España para la realización de trabajos técnicos. *IGME. Madrid*.
- Deria, A., Ghannad, P., & Lee, Y. C. (2020). Evaluating implications of flood vulnerability factors with respect to income levels for building long-term disaster resilience of low-income communities. *International Journal of Disaster Risk Reduction*, 48(December 2019), 101608. <https://doi.org/10.1016/j.ijdrr.2020.101608>
- Deshmukh, A., Oh, E. H., & Hastak, M. (2011). Impact of flood damaged critical infrastructure on communities and industries. *Built Environment Project and Asset Management*, 1(2), 156–175. <https://doi.org/10.1108/20441241111180415>
- Dewan, A., Kiselev, G., Botje, D., Mahmud, G. I., Bhuian, M. H., & Hassan, Q. K. (2021). Surface urban heat island intensity in five major cities of Bangladesh: Patterns, drivers and trends. *Sustainable Cities and Society*, 71, 102926. <https://doi.org/10.1016/j.scs.2021.102926>
- Dirksen, M., Ronda, R. J., Theeuwes, N. E., & Pagani, G. A. (2019). Sky view factor calculations and its application in urban heat island studies. *Urban Climate*, 30, 100498. <https://doi.org/10.1016/j.uclim.2019.100498>

- Dirección General de Carreteras, F. O. M. (2016). 298/2016, de 15 de febrero, por la que se aprueba la norma 5.2-IC drenaje superficial de la Instrucción de Carreteras. Ministerio de Fomento. *Boletín Oficial Del Estado. Madrid, Revisión De*.
- Donigian, A. S., & Imhoff, J. (2006). History and evolution of watershed modeling derived from the Stanford Watershed Model. *Watershed Models*, 21–45. <http://dx.doi.org/10.1201/9781420037432.ch2>
- Donner, W., & Rodríguez, H. (2008). Population Composition, Migration and Inequality: The Influence of Demographic Changes on Disaster Risk and Vulnerability. *Social Forces*, 87(2), 1089–1114. <https://doi.org/10.1353/sof.0.0141>
- Dottori, F., Martina, M. L. V., & Figueiredo, R. (2018). A methodology for flood susceptibility and vulnerability analysis in complex flood scenarios. *Journal of Flood Risk Management*, 11, S632–S645. <https://doi.org/10.1111/jfr3.12234>
- Dozier, J., & Frew, J. (1990). Rapid calculation of terrain parameters for radiation modeling from digital elevation data. *IEEE Transactions on Geoscience and Remote Sensing*, 28(5), 963–969. <http://dx.doi.org/10.1109/36.58986>
- Duscher, K., Günther, A., Richts, A., Clos, P., Philipp, U., & Struckmeier, W. (2015). The GIS layers of the “International Hydrogeological Map of Europe 1:1,500,000” in a vector format. *Hydrogeol. J.*, 23(8), 1867–1875. <https://doi.org/10.1007/s10040-015-1296-4>
- Efstathiou, C. E. (2006). Estimation of type I error probability from experimental Dixon’s “Q” parameter on testing for outliers within small size data sets. *Talanta*, 69(5), 1068–1071. <https://doi.org/10.1016/j.talanta.2005.12.031>
- Eggermont, H., Balian, E., Azevedo, J. M. N., Beumer, V., Brodin, T., Claudet, J., Fady, B., Grube, M., Keune, H., & Lamarque, P. (2015). Nature-based solutions: new influence for environmental management and research in Europe. *GAIA-Ecological Perspectives for Science and Society*, 24(4), 243–248. <https://doi.org/10.14512/gaia.24.4.9>
- Eghdami, S., Scheld, A. M., & Louis, G. (2023). Socioeconomic vulnerability and climate risk in coastal Virginia. *Climate Risk Management*, 39, 100475. <https://doi.org/10.1016/j.crm.2023.100475>
- Eini, M., Kaboli, H. S., Rashidian, M., & Hedayat, H. (2020). Hazard and vulnerability in urban flood risk mapping: Machine learning techniques and considering the role of urban districts. *International Journal of Disaster Risk Reduction*, 50(May), 101687. <https://doi.org/10.1016/j.ijdr.2020.101687>
- Eisenberg, B. ., & Polcher, V. (2020). *Nature-Based Solutions Technical Handbook*. <https://unalab.eu/system/files/2020-02/unalab-technical-handbook-nature-based-solutions2020-02-17.pdf>
- El Diario Montañes. (2023, Noviembre 2). *Inundaciones en Santander*. <https://www.eldiariomontanes.es/videos/santander/201508/13/inundaciones-santander-4418293006001-mm.html> (Fecha de último acceso: 20 de noviembre 2023)
- El Kenawy, A. M., Hereher, M., Robaa, S. M., McCabe, M. F., Lopez-Moreno, J. I., Domínguez-Castro, F., Gaber, I. M., Al-Awadhi, T., Al-Buloshi, A., Al Nasiri, N., Al-Hatrushi, S., Schuwerack, P.-M., Peña-Angulo, D., Abdelaal, M. M., & Vicente-Serrano, S. M. (2020). Nocturnal Surface Urban Heat Island over Greater Cairo: Spatial Morphology, Temporal Trends and Links to Land-Atmosphere Influences. *Remote Sensing*, 12(23). <https://doi.org/10.3390/rs12233889>

- Eli, R. N., & Lamont, S. J. (2010). Curve numbers and urban runoff modeling - Application limitations. *Low Impact Development 2010: Redefining Water in the City - Proceedings of the 2010 International Low Impact Development Conference*, 405 – 418. [https://doi.org/10.1061/41099\(367\)36](https://doi.org/10.1061/41099(367)36)
- Elliott, A. H., & Trowsdale, S. A. (2007). A review of models for low impact urban stormwater drainage. *Environmental Modelling and Software*, 22(3), 394–405. <https://doi.org/10.1016/j.envsoft.2005.12.005>
- Equere, V., Mirzaei, P. A., & Riffat, S. (2020). Definition of a new morphological parameter to improve prediction of urban heat island. *Sustainable Cities and Society*, 56, 102021. <https://doi.org/10.1016/j.scs.2020.102021>
- Equere, V., Mirzaei, P. A., Riffat, S., & Wang, Y. (2021). Integration of topological aspect of city terrains to predict the spatial distribution of urban heat island using GIS and ANN. *Sustainable Cities and Society*, 69, 102825. <https://doi.org/10.1016/j.scs.2021.102825>
- ESA. (2023). *Copernicus digital elevation model*. <https://spacedata.copernicus.eu/collections/copernicus-digital-elevation-model> (Fecha de último acceso: 20 de noviembre 2023)
- Esri. (2019). Package “arcgisbinding.” In *Esri.com*. <https://r.esri.com/assets/arcgisbinding.pdf> (Fecha de último acceso: 20 de noviembre 2023)
- European Union, & Copernicus Land Monitoring Service. (2020). *Surface Albedo | Copernicus Global Land Service*. <https://land.copernicus.eu/global/products/sa> (Fecha de último acceso: 20 de noviembre 2023)
- European Union, & Copernicus Land Monitoring Service. (2023). *Urban Atlas | Copernicus Local Land Service*. <https://land.copernicus.eu/local/urban-atlas> (Fecha de último acceso: 20 de noviembre 2023)
- Fabrizi, R., Bonafoni, S., & Biondi, R. (2010). Satellite and Ground-Based Sensors for the Urban Heat Island Analysis in the City of Rome. In *Remote Sensing* (Vol. 2, Issue 5, pp. 1400–1415). <https://doi.org/10.3390/rs2051400>
- Farinós, E., & Eds, J. (2022). *Conflictos territoriales y geografías del poder*. En Farinós, J.; Olcina, J. (Eds.) (2022): *Ordenación del territorio y medio ambiente*. págs. 209-238. ISBN 978-84-19376-78-7
- Fekete, A. (2009). Validation of a social vulnerability index in context to river-floods in Germany. *Natural Hazards and Earth System Sciences*, 9(2), 393–403. <https://doi.org/10.5194/nhess-9-393-2009>, 2009
- Feloni, E., Mousadis, I., & Baltas, E. (2019). Flood vulnerability assessment using a GIS-based multi-criteria approach—The case of Attica region. *Journal of Flood Risk Management*, 13(July 2019), 1–15. <https://doi.org/10.1111/jfr3.12563>
- Fick, S. E., & Hijmans, R. J. (2017). WorldClim 2: new 1-km spatial resolution climate surfaces for global land areas. *International Journal of Climatology*, 37(12), 4302–4315. <https://doi.org/10.1002/joc.5086>
- Finch, C., Emrich, C. T., & Cutter, S. L. (2010). Disaster disparities and differential recovery in New

- Orleans. *Population and Environment*, 31, 179–202. <https://doi.org/10.1007/s11111-009-0099-8>
- Fisher, A., Rudin, C., & Dominici, F. (2019). All Models are Wrong, but Many are Useful: Learning a Variable's Importance by Studying an Entire Class of Prediction Models Simultaneously. *J. Mach. Learn. Res.*, 20(177), 1–81. <https://doi.org/10.48550/arXiv.1801.01489>
- Fisher, R.A. (1992). Statistical Methods for Research Workers. In: Kotz, S., Johnson, N.L. (eds) Breakthroughs in Statistics. Springer Series in Statistics. Springer, New York, NY. https://doi.org/10.1007/978-1-4612-4380-9_6
- Flanagan, B. E., Gregory, E. W., Hallisey, E. J., Heitgerd, J. L., & Lewis, B. (2011). A social vulnerability index for disaster management. *Journal of Homeland Security and Emergency Management*, 8(1), <https://doi.org/10.2202/1547-7355.1792>.
- Fletcher, T. D., Shuster, W., Hunt, W. F., Ashley, R., Butler, D., Arthur, S., Trowsdale, S., Barraud, S., Semadeni-Davies, A., Bertrand-Krajewski, J. L., Mikkelsen, P. S., Rivard, G., Uhl, M., Dagenais, D., & Viklander, M. (2015). SUDS, LID, BMPs, WSUD and more – The evolution and application of terminology surrounding urban drainage. *Urban Water Journal*, 12(7), 525–542. <https://doi.org/10.1080/1573062X.2014.916314>
- Fox, J., & Weisberg, S. (2011). *An R companion to applied regression*. Sage publications. ISBN: 9781544336473
- Frigerio, I., & De Amicis, M. (2016). Mapping social vulnerability to natural hazards in Italy: A suitable tool for risk mitigation strategies. *Environmental Science and Policy*, 63, 187–196. <https://doi.org/10.1016/j.envsci.2016.06.001>
- Gaffin, S. R., Rosenzweig, C., Khanbilvardi, R., Parshall, L., Mahani, S., Glickman, H., Goldberg, R., Blake, R., Slosberg, R. B., & Hillel, D. (2008). Variations in New York city's urban heat island strength over time and space. *Theoretical and Applied Climatology*, 94, 1–11. <https://doi.org/10.1007/s00704-007-0368-3>
- Gall, M. (2007). *Indices of social vulnerability to natural hazards: a comparative evaluation*. University of South Carolina PhD Dissertation.
- García Ballesteros, A., & Jiménez Blasco, B. C. (2016). Envejecimiento y urbanización: Implicaciones de dos procesos coincidentes. *Investigaciones Geograficas*, 89(89), 58–73. <https://doi.org/10.14350/rig.47362>
- Gardes, T., Schoetter, R., Hidalgo, J., Long, N., Marquès, E., & Masson, V. (2020). Statistical prediction of the nocturnal urban heat island intensity based on urban morphology and geographical factors-An investigation based on numerical model results for a large ensemble of French cities. *Science of The Total Environment*, 737, 139253. <https://doi.org/10.1016/j.scitotenv.2020.139253>
- Gayathri, K. D., Ganasri, B. P., & Dwarakish, G. S. (2015). A Review on Hydrological Models. *Aquatic Procedia*, 4(1cwrcoe), 1001–1007. <https://doi.org/10.1016/j.aapro.2015.02.126>
- Gevrey, M., Dimopoulos, I., & Lek, S. (2003). Review and comparison of methods to study the contribution of variables in artificial neural network models. *Ecological Modelling*, 160(3), 249–264. [https://doi.org/10.1016/S0304-3800\(02\)00257-0](https://doi.org/10.1016/S0304-3800(02)00257-0)

- Ghebreyesus, D. T., & Sharif, H. O. (2021). Development and Assessment of High-Resolution Radar-Based Precipitation Intensity-Duration-Curve (IDF) Curves for the State of Texas. *Remote Sensing*, 13(15). <https://doi.org/10.3390/rs13152890>
- Gleick, P. H. (2014). Water, drought, climate change, and conflict in Syria. *Weather, Climate, and Society*, 6(3), 331–340. <https://doi.org/10.1175/WCAS-D-13-00059.1>
- Gobierno de Cantabria. (2021). *Información gratuita de datos georeferenciados*. <https://mapas.cantabria.es> (Fecha de último acceso: 20 de noviembre 2023)
- Golz, S., Naumann, T., Neubert, M., & Günther, B. (2016). Heavy rainfall: An underestimated environmental risk for buildings? *E3S Web of Conferences*, 7. <https://doi.org/10.1051/e3sconf/20160708001>
- Graf, A. B. A., Smola, A. J., & Borer, S. (2003). Classification in a normalized feature space using support vector machines. *IEEE Transactions on Neural Networks*, 14(3), 597–605. <https://doi.org/10.1109/tnn.2003.811708>
- Grimaldi, S., & Petroselli, A. (2015). Do we still need the Rational Formula? An alternative empirical procedure for peak discharge estimation in small and ungauged basins. *Hydrological Sciences Journal*, 60(1), 67–77. <https://doi.org/10.1080/02626667.2014.880546>
- Grimm, N. B., Faeth, S. H., Golubiewski, N. E., Redman, C. L., Wu, J., Bai, X., & Briggs, J. M. (2008). Global change and the ecology of cities. *Science*, 319(5864), 756–760. <https://doi.org/10.1126/science.1150195>
- Grimmond, S. (2007). Urbanization and global environmental change: Local effects of urban warming. *Geographical Journal*, 173(1), 83–88. https://doi.org/10.1111/j.1475-4959.2007.232_3.x
- Guillard-Gonçalves, C., Cutter, S. L., Emrich, C. T., & Zêzere, J. L. (2015). Application of Social Vulnerability Index (SoVI) and delineation of natural risk zones in Greater Lisbon, Portugal. *Journal of Risk Research*, 18(5), 651–674. <https://doi.org/10.1080/13669877.2014.910689>
- Guillard-Gonçalves, C., & Zêzere, J. L. (2018). Combining social vulnerability and physical vulnerability to analyse landslide risk at the municipal scale. *Geosciences (Switzerland)*, 8(8). <https://doi.org/10.3390/geosciences8080294>
- Guna, D. (2018). *Migration and Its Impact on Cities—An Insight Report-In Collaboration with PwC*. <https://www.weforum.org/publications/migration-and-its-impact-on-cities/> (Fecha de último acceso: 20 de noviembre 2023)
- Guo, G., Liu, L., Li, Y., Gao, J., Lin, S., & Wu, S. (2021). A Vulnerability Curve Method to Assess Risks of Climate-Related Hazards at County Level. *Atmosphere*, 12(8), 1022. <https://doi.org/10.3390/atmos12081022>
- Guo, J. C. Y. (2001). Rational hydrograph method for small urban watersheds. *Journal of Hydrologic Engineering*, 6(4), 352–356. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2001\)6:4\(352\)](https://doi.org/10.1061/(ASCE)1084-0699(2001)6:4(352))
- Guo, K., Guan, M., & Yu, D. (2021). Urban surface water flood modelling—a comprehensive review of current models and future challenges. *Hydrology and Earth System Sciences*, 25(5), 2843–2860. <https://doi.org/10.5194/hess-25-2843-2021>
- Gupta, S., Kazi, F., Wagh, S., & Singh, N. (2018). Analysis and prediction of vulnerability in smart

- power transmission system: A geometrical approach. *International Journal of Electrical Power & Energy Systems*, 94, 77–87. <https://doi.org/10.1016/j.ijepes.2017.06.033>
- Gutiérrez Llorente, J. M., Herrera García, S., San-Martín, D., Sordo, C. M., Rodríguez Velasco, J. J., Frochoso, M., Ancell, R., Fernández, J., Cofiño, A. S., & Pons Reynés, M. R. (2010). Escenarios regionales probabilísticos de cambio climático en Cantabria: termopluiometría. <http://hdl.handle.net/20.500.11765/1367>
- Ha, H., Bui, Q. D., Nguyen, H. D., Pham, B. T., Lai, T. D., & Luu, C. (2023). A practical approach to flood hazard, vulnerability, and risk assessing and mapping for Quang Binh province, Vietnam. *Environment, Development and Sustainability*, 25(2), 1101–1130. <https://doi.org/10.1007/s10668-021-02041-4>
- Hakim, W. L., & Lee, C. W. (2020). A review on remote sensing and GIS applications to monitor natural disasters in Indonesia. *Korean Journal of Remote Sensing*, 36(6–11), 1303–1322. <https://doi.org/10.7780/kjrs.2020.36.6.1.3>
- Hammami, S., Zouhri, L., Souissi, D., Souei, A., Zghibi, A., Marzougui, A., & Dlala, M. (2019). Application of the GIS based multi-criteria decision analysis and analytical hierarchy process (AHP) in the flood susceptibility mapping (Tunisia). *Arabian Journal of Geosciences*, 12(21). <https://doi.org/10.1007/s12517-019-4754-9>
- Han, G. F., Ye, L., & Sun, Z. W. (2014). Influence of aspect on land surface temperature in mountainous city: A case study in central area of Chongqing City. *Acta Ecologica Sinica*, 34(14), 4017–4024. <http://dx.doi.org/10.5846/stxb201211271679>
- Han, J. Y., Baik, J. J., & Lee, H. (2014). Urban impacts on precipitation. *Asia-Pacific Journal of Atmospheric Sciences*, 50, 17–30. <https://doi.org/10.1007/s13143-014-0016-7>
- Hansen, J., Sato, M., Hearty, P., Ruedy, R., Kelley, M., Masson-Delmotte, V., Russell, G., Tselioudis, G., Cao, J., Rignot, E., Velicogna, I., Tormey, B., Donovan, B., Kandiano, E., Von Schuckmann, K., Kharecha, P., Legrande, A. N., & Bauer, M. (2016). Ice melt, sea level rise and superstorms: Evidence from paleoclimate data, climate modeling, and modern observations that 2 °C global warming could be dangerous. *Atmospheric Chemistry and Physics*, 16(6), 3761–3812. <https://doi.org/10.5194/acp-16-3761-2016>
- Hart, M. A., & Sailor, D. J. (2009). Quantifying the influence of land-use and surface characteristics on spatial variability in the urban heat island. *Theoretical and Applied Climatology*, 95, 397–406. <https://doi.org/10.1007/s00704-008-0017-5>
- He, X., Chen, C., Liu, Y., & Chu, Y. (2020). Inundation analysis method for urban mountainous areas based on Soil Conservation Service Curve Number (SCS-CN) model using remote sensing data. *Sensors and Materials*, 32(11), 3813 – 3822. <https://doi.org/10.18494/SAM.2020.2769>
- Heaviside, C., Vardoulakis, S., & Cai, X. M. (2016). Attribution of mortality to the urban heat island during heatwaves in the West Midlands, UK. *Environmental Health: A Global Access Science Source*, 15(Suppl 1). <https://doi.org/10.1186/s12940-016-0100-9>
- Hemmati, M., Mahmoud, H. N., Ellingwood, B. R., & Crooks, A. T. (2021). Unraveling the complexity of human behavior and urbanization on community vulnerability to floods. *Scientific Reports*, 11(1), 1–15. <https://doi.org/10.1038/s41598-021-99587-0>
- Hengl, T., Leal Parente, L., Krizan, J., & Bonannella, C. (2021). *Continental Europe Digital Terrain*

- Model at 30 m resolution based on GEDI, ICESat-2, AW3D, GLO-30, EUDEM, MERIT DEM and background layers.* Zenodo. <https://doi.org/10.5281/zenodo.4724549>
- Herath, H., Halwatura, R. U., & Jayasinghe, G. Y. (2018). Modeling a tropical urban context with green walls and green roofs as an urban heat island adaptation strategy. *Procedia Engineering*, 212, 691–698. <https://doi.org/10.1016/j.proeng.2018.01.089>
- Hidayat, D. J., & Soekirno, S. (2021). Development of temperature monitoring and prediction system for urban heat island (UHI) based on the internet of things. *Journal of Physics: Conference Series*, 1816(1), 12054. <https://doi.org/10.1088/1742-6596/1816/1/012054>
- Hindustan Times. (2023, October 4). Delhi flood news highlights: Over 25.4k people evacuated so far, says government. *Hindustan Times*. <https://www.hindustantimes.com/india-news/delhi-flood-live-updates-yamuna-water-level-rising-delhi-weather-monsoon-news-101689292817014.html> (Fecha de último acceso: 20 de noviembre 2023)
- Hiroyuki Kusaka, Hiroaki Kondo, Yokihiko Kikegawa, & Fujio kimura. (2001). A simple single-layer urban canopy model for atmospheric models: comparison with multi-layer and slab models. *Boundary-Layer Meteorology*, 101, 329–358. <https://doi.org/10.1023/A:1019207923078>
- Hjort, J., Suomi, J., & Käyhkö, J. (2011). Spatial prediction of urban–rural temperatures using statistical methods. *Theoretical and Applied Climatology*, 106, 139–152. <https://doi.org/10.1007/s00704-011-0425-9>
- Hobbie, S. E., & Grimm, N. B. (2020). Nature-based approaches to managing climate change impacts in cities. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 375(1794). <https://doi.org/10.1098/rstb.2019.0124>
- Hong, H., Tsangaratos, P., Ilia, I., Liu, J., Zhu, A. X., & Chen, W. (2018). Application of fuzzy weight of evidence and data mining techniques in construction of flood susceptibility map of Poyang County, China. *Science of the Total Environment*, 625, 575–588. <https://doi.org/10.1016/j.scitotenv.2017.12.256>
- Hotelling, H. (1933). Analysis of a complex of statistical variables into principal components. *Journal of Educational Psychology*, 24 (6), 417–441. <https://doi.org/10.1037/h0071325>
- Huynh-Thu, V. A., & Geurts, P. (2019). Unsupervised gene network inference with decision trees and random forests. *Gene Regulatory Networks: Methods and Protocols*, 195–215. https://doi.org/10.1007/978-1-4939-8882-2_8
- IGME. (2023). *MapasIGME - Portal de cartografía del IGME: GEODE - Cartografía geológica digital continua a escala 1:50.000*. <http://info.igme.es/cartografiadigital/geologica/geode.aspx> (Fecha de último acceso: 20 de noviembre 2023)
- India Today News. (2023). *Delh-uge, despair and sinking feeling: Why is Delhi flooded?* <https://www.indiatoday.in/india/story/delhi-flood-rain-yamuna-river-water-level-danger-mark-cause-2406118-2023-07-13> (Fecha de último acceso: 20 de noviembre 2023)
- INE. (2018). *Cifras oficiales de población de los municipios españoles: Revisión del padrón municipal*. INE Madrid. https://ine.es/dyngs/INEbase/es/operacion.htm?c=Estadistica_C&cid=1254736177011&menu=resultados&idp=1254734710990 (Fecha de último acceso: 20 de noviembre 2023)

- INE, (2011a). *Cartografía digitalizada de secciones censales 2015*. https://www.ine.es/censos2011_datos/cen11_datos_resultados_seccen.htm (Fecha de último acceso: 20 de noviembre 2023)
- INE, (2011b). *Indicadores para secciones censales 2011*. Indicadores Para Secciones Censales 2011. https://www.ine.es/dyngs//INEbase/es/operacion.htm?c=Estadistica_C&cid=1254736176992&menu=resultados&idp=1254735572981#ltab=1254736195710 (Fecha de último acceso: 20 de noviembre 2023)
- INE, (2015). *Atlas de Distribución de Renta de los Hogares 2015*. Atlas de Distribución de Renta de Los Hogares 2015. https://www.ine.es/experimental/atlas/exp_atlas_tab.htm (Fecha de último acceso: 20 de noviembre 2023)
- INE, (2016). *Censales, Cartografía digitalizada de secciones*. https://www.ine.es/ss/Satellite?L=es_ES&c=Page&cid=1259952026632&p=1259952026632&pagename=ProductosYServicios%2FPYSLayou (Fecha de último acceso: 20 de noviembre 2023)
- IPCC. (2018). *Global warming of 1.5°C. In Special Report on Global Warming of 1.5°C*. <https://www.ipcc.ch/sr15/chapter/spm/spm-introduction/> (Fecha de último acceso: 20 de noviembre 2023)
- IPCC. (2021). *2021: Summary for Policymakers. In: Climate Change 2021: The Physical Science Basis*. <https://doi.org/10.1017/9781009157896.001>
- IPCC. (2022a). *2022: Summary for Policymakers. In: Climate Change 2022: Impacts, Adaptation, and Vulnerability*. <https://doi.org/10.1017/9781009325844.001>
- IPCC. (2022b). *2022: Summary for Policymakers. In :Climate Change 2022 - Mitigation of Climate Change*. <https://doi.org/10.1017/9781009157926.001>
- IPCC. (2023). *2023: Summary for Policymakers. In: Climate Change 2023: Synthesis Report. A Report of the Intergovernmental Panel on Climate Change*. <https://doi.org/10.59327/IPCC/AR6-9789291691647.001>
- Jacobson, C. R. (2011). Identification and quantification of the hydrological impacts of imperviousness in urban catchments: A review. *Journal of Environmental Management*, 92(6), 1438–1448. <https://doi.org/10.1016/j.jenvman.2011.01.018> (Fecha de último acceso: 20 de noviembre 2023)
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An introduction to statistical learning* (Vol. 112). Springer. <https://doi.org/10.1007/978-1-4614-7138-7>
- Jato-Espino, D. (2019). Spatiotemporal statistical analysis of the Urban Heat Island effect in a Mediterranean region. *Sustainable Cities and Society*, 46(January), 101427. <https://doi.org/10.1016/j.scs.2019.101427>
- Jato-Espino, D., Lobo, A., & Ascorbe-Salcedo, A. (2019). Urban flood risk mapping using an optimised additive weighting methodology based on open data. *Journal of Flood Risk Management*, 12(S1), 1–14. <https://doi.org/10.1111/jfr3.12533>
- Jato-Espino, D., & Pathak, S. (2021). Geographic Location System for Identifying Urban Road Sections Sensitive to Runoff Accumulation. *Hydrology*, 8(2), 72.

<https://doi.org/10.3390/hydrology8020072>

- Jato-Espino, D., Sillanpää, N., Charlesworth, S. M., & Andrés-Doménech, I. (2016). Coupling GIS with stormwater modelling for the location prioritization and hydrological simulation of permeable pavements in urban catchments. *Water (Switzerland)*, 8(10). <https://doi.org/10.3390/w8100451>
- Jessup, K., Parker, S. S., Randall, J. M., Cohen, B. S., Roderick-Jones, R., Ganguly, S., & Sourial, J. (2021). Planting Stormwater Solutions: A methodology for siting nature-based solutions for pollution capture, habitat enhancement, and multiple health benefits. *Urban Forestry and Urban Greening*, 64, 127300. <https://doi.org/10.1016/j.ufug.2021.127300>
- Jolliffe, I. T., & Cadima, J. (2016). Principal component analysis: A review and recent developments. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 374(2065). <https://doi.org/10.1098/rsta.2015.0202>
- Julià, P. B., & Ferreira, T. M. (2021). From single-to multi-hazard vulnerability and risk in Historic Urban Areas: a literature review. *Natural Hazards*, 108(1), 93–128. <https://doi.org/10.1007/s11069-021-04734-5>
- Kabir, A., Mahdavi, M., Bahremand, A., & Noora, N. (2011). Application of a geographical information system(GIS) based hydrological model for flow prediction in Gorganrood river basin, Iran. *African Journal of Agricultural Research*, 6(1), 35–45. <https://doi.org/10.5897/AJAR10.668>
- Kalogeropoulos, K., Stathopoulos, N., Psarogiannis, A., Pissias, E., Louka, P., Petropoulos, G. P., & Chalkias, C. (2020). An integrated GIS-hydro modeling methodology for surface runoff exploitation via small-scale reservoirs. *Water (Switzerland)*, 12(11), 1–18. <https://doi.org/10.3390/w12113182>
- Karger, D. N., Conrad, O., Böhrer, J., Kawohl, T., Kreft, H., Soria-Auza, R. W., Zimmermann, N. E., Linder, H. P., & Kessler, M. (2017). Climatologies at high resolution for the earth's land surface areas. *Scientific Data*, 4(1), 170122, 1–20. <https://doi.org/10.1038/sdata.2017.122>
- Karmakar, S., Sherly, M. A., & Mohanty, M. (2022). Urban Flood Risk Mapping: A State-of-the-Art Review on Quantification, Current Practices, and Future Challenges. In P. Banerji & A. Jana (Eds.), *Advances in Urban Design and Engineering: Perspectives from India* (pp. 125–156). Springer Singapore. https://doi.org/10.1007/978-981-19-0412-7_5
- Karunarathne, A. Y., & Lee, G. (2020). Developing a multi-facet social vulnerability measure for flood disasters at the micro-level assessment. *International Journal of Disaster Risk Reduction*, 49(January), 101679. <https://doi.org/10.1016/j.ijdr.2020.101679>
- Kassambara, A. (2019). ggcorrplot: Visualization of a Correlation Matrix using 'ggplot2'. *R Package Version 0.1, 3*. <https://github.com/kassambara/ggcorrplot> (Fecha de último acceso: 20 de noviembre 2023)
- Kastendeuch, P. P. (2013). A method to estimate sky view factors from digital elevation models. *International Journal of Climatology*, 33(6), 1574–1578. <https://doi.org/10.1002/joc.3523>
- Kaźmierczak, A., & Cavan, G. (2011). Surface water flooding risk to urban communities: Analysis of vulnerability, hazard and exposure. *Landscape and Urban Planning*, 103(2), 185–197. <https://doi.org/10.1016/j.landurbplan.2011.07.008>

- Khalil, U., Aslam, B., Azam, U., & Khalid, H. M. D. (2021). Time Series Analysis of Land Surface Temperature and Drivers of Urban Heat Island Effect Based on Remotely Sensed Data to Develop a Prediction Model. *Applied Artificial Intelligence*, 35(15), 1803–1828. <https://doi.org/10.1080/08839514.2021.1993633>
- Khan, A., Chatterjee, S., Filho, W. L., Khatun, R., Dinda, A., & Minhas, A. (2020). *City-scale Modeling of Urban Heat Islands for Kolkata BT - Climate Change, Hazards and Adaptation Options: Handling the Impacts of a Changing Climate* (W. Leal Filho, G. J. Nagy, M. Borga, P. D. Chávez Muñoz, & A. Magnuszewski (Eds.); pp. 89–133). Springer International Publishing. https://doi.org/10.1007/978-3-030-37425-9_5
- Khan, J., Ketzler, M., Kakosimos, K., Sørensen, M., & Jensen, S. S. (2018). Road traffic air and noise pollution exposure assessment – A review of tools and techniques. *Science of the Total Environment*, 634, 661–676. <https://doi.org/10.1016/j.scitotenv.2018.03.374>
- Kim, H., Park, J., Yoo, J., & Kim, T. W. (2015). Assessment of drought hazard, vulnerability, and risk: A case study for administrative districts in South Korea. *Journal of Hydro-Environment Research*, 9(1), 28–35. <https://doi.org/10.1016/j.jher.2013.07.003>
- Kim, J. H. (2019). Multicollinearity and misleading statistical results. *Korean Journal of Anesthesiology*, 72(6), 558–569. <https://doi.org/10.4097%2Fkja.19087>
- Kim, S. W., & Brown, R. D. (2021). Urban heat island (UHI) intensity and magnitude estimations: A systematic literature review. *Science of The Total Environment*, 779, 146389. <https://doi.org/10.1016/j.scitotenv.2021.146389>
- Kirch, W. (2008). *Pearson's Correlation Coefficient BT - Encyclopedia of Public Health* (pp. 1090–1091). Springer Netherlands. https://doi.org/10.1007/978-1-4020-5614-7_2569
- Kotthaus, S., & Grimmond, C. S. B. (2014). Energy exchange in a dense urban environment—Part II: Impact of spatial heterogeneity of the surface. *Urban Climate*, 10, 281–307. <https://doi.org/10.1016/j.uclim.2013.10.001>
- Kuhn, M. (2015). Caret: classification and regression training. *Astrophysics Source Code Library*, ascl-1505. <https://ui.adsabs.harvard.edu/abs/2015ascl.soft05003K/abstract> (Fecha de último acceso: 20 de noviembre 2023)
- Kuller, M., Bach, P. M., Ramirez-Lovering, D., & Deletic, A. (2017). Framing water sensitive urban design as part of the urban form: A critical review of tools for best planning practice. *Environmental Modelling & Software*, 96, 265–282. <https://doi.org/10.1016/j.envsoft.2017.07.003>
- Kumpulainen, S. (2006). Vulnerability concepts in hazard and risk assessment. *Special Paper of the Geological Survey of Finland*, 42, 65–74. ISBN 951-690-944-2
- Kunapo, J., Fletcher, T. D., Ladson, A. R., Cunningham, L., & Burns, M. J. (2018). A spatially explicit framework for climate adaptation. *Urban Water Journal*, 15(2), 159–166. <https://doi.org/10.1080/1573062X.2018.1424216>
- Kyriakodis, G. E., & Santamouris, M. (2018). Using reflective pavements to mitigate urban heat island in warm climates—Results from a large scale urban mitigation project. *Urban Climate*, 24, 326–339. <https://doi.org/10.1016/j.uclim.2017.02.002>

- Lauzet, N., Rodler, A., Musy, M., Azam, M.-H., Guernouti, S., Mauree, D., & Colinart, T. (2019). How building energy models take the local climate into account in an urban context – A review. *Renewable and Sustainable Energy Reviews*, *116*, 109390. <https://doi.org/10.1016/j.rser.2019.109390>
- Lawson, F. H. (2017). Egypt versus Ethiopia: The Conflict over the Nile Metastasizes. *International Spectator*, *52*(4), 129–144. <https://doi.org/10.1080/03932729.2017.1333272>
- Lebart, L., Morineau, A., & Piron, M. (1995). Statistique exploratoire multidimensionnelle. In *Dunod* (3rd ed.). ISBN 9782100053513
- Lek, S., Delacoste, M., Baran, P., Dimopoulos, I., Lauga, J., & Aulagnier, S. (1996). Application of neural networks to modelling nonlinear relationships in ecology. *Ecological Modelling*, *90*(1), 39–52. [https://doi.org/10.1016/0304-3800\(95\)00142-5](https://doi.org/10.1016/0304-3800(95)00142-5)
- Lhomme, J., Sayers, P., Gouldby, B. P., Samuels, P. G., Wills, M., & Mulet-Marti, J. (2008). Recent development and application of a rapid flood spreading method. *Flood Risk Management: Research and Practice*. ISBN 9780429207129
- Li, H., Ding, L., Ren, M., Li, C., & Wang, H. (2017). Sponge city construction in China: A survey of the challenges and opportunities. *Water*, *9*(9), 594. <https://doi.org/10.3390/w9090594>
- Liang, Q., & Smith, L. S. (2015). A High-Performance Integrated hydrodynamic Modelling System for urban flood simulations. *Journal of Hydroinformatics*, *17*(4), 518–533. <https://doi.org/10.2166/hydro.2015.029>
- Liaw A. & Wiener M. (2002). Classification and Regression by randomForest. *R News* *2*(3), 18–22. <https://cran.r-project.org/web/packages/randomForest/randomForest.pdf> (Fecha de último acceso: 20 de noviembre 2023)
- Liu, D., Hu, S., & Liu, J. (2020). Contrasting the performance capabilities of urban radiation field between three microclimate simulation tools. *Building and Environment*, *175*, 106789. <https://doi.org/10.1016/j.buildenv.2020.106789>
- Liu, J., Zhang, L., Zhang, Q., Zhang, G., & Teng, J. (2021). Predicting the surface urban heat island intensity of future urban green space development using a multi-scenario simulation. *Sustainable Cities and Society*, *66*, 102698. <https://doi.org/10.1016/j.scs.2020.102698>
- Liu, K., Wang, S., Li, X., & Wu, T. (2019). Spatially disaggregating satellite land surface temperature with a nonlinear model across agricultural areas. *Journal of Geophysical Research: Biogeosciences*, *124*(11), 3232–3251. <https://doi.org/10.1029/2019JG005227>
- Liu, Z., He, C., Zhou, Y., & Wu, J. (2014). How much of the world's land has been urbanized, really? A hierarchical framework for avoiding confusion. *Landscape Ecology*, *29*(5), 763–771. <https://doi.org/10.1007/s10980-014-0034-y>
- Luo, P., Luo, M., Li, F., Qi, X., Huo, A., Wang, Z., He, B., Takara, K., Nover, D., & Wang, Y. (2022). Urban flood numerical simulation: Research, methods and future perspectives. *Environmental Modelling and Software*, *156*(September 2021), 105478. <https://doi.org/10.1016/j.envsoft.2022.105478>
- Luo, X. T., Ge, Y., Xie, Y., Wei, Y., Huang, R., Ma, N., Ramachandran, C. S., & Li, C. J. (2021). Dynamic evolution of oxide scale on the surfaces of feed stock particles from cracking and segmenting

- to peel-off while cold spraying copper powder having a high oxygen content. *Journal of Materials Science and Technology*, 67, 105–115. <https://doi.org/10.1016/j.jmst.2020.06.019>
- Lyu, H. M., Sun, W. J., Shen, S. L., & Arulrajah, A. (2018). Flood risk assessment in metro systems of mega-cities using a GIS-based modeling approach. *Science of the Total Environment*, 626, 1012–1025. <https://doi.org/10.1016/j.scitotenv.2018.01.138>
- Maantay, J., & Maroko, A. (2009). Mapping urban risk: Flood hazards, race, & environmental justice in New York. *Applied Geography*, 29(1), 111–124. <https://doi.org/10.1016/j.apgeog.2008.08.002>
- Makido, Y., Shandas, V., Ferwati, S., & Sailor, D. (2016). Daytime variation of urban heat islands: the case study of Doha, Qatar. *Climate*, 4(2), 32. <https://doi.org/10.3390/cli4020032>
- Manchado, C., Roldán-Valcarce, A., Jato-Espino, D., & Andrés-Doménech, I. (2021). ArcDrain: A GIS Add-In for Automated Determination of Surface Runoff in Urban Catchments. *International Journal of Environmental Research and Public Health*, 18(16), 8802. <https://doi.org/10.3390/ijerph18168802>
- Manfré, L. A., Hirata, E., Silva, J. B., Shinohara, E. J., Giannotti, M. A., Larocca, A. P. C., & Quintanilha, J. A. (2012). An Analysis of geospatial technologies for risk and natural disaster management. *ISPRS International Journal of Geo-Information*, 1(2), 166–185. <https://doi.org/10.3390/ijgi1020166>
- Marando, F., Heris, M. P., Zulian, G., Udías, A., Mentaschi, L., Chrysoulakis, N., Parastatidis, D., & Maes, J. (2022). Urban heat island mitigation by green infrastructure in European Functional Urban Areas. *Sustainable Cities and Society*, 77, 103564. <https://doi.org/10.1016/j.scs.2021.103564>
- Marchioni, M., & Becciu, G. (2015). Experimental results on permeable pavements in urban areas: A synthetic review. *International Journal of Sustainable Development and Planning*, 10(6), 806–817. <https://doi.org/10.2495/SDP-V10-N6-806-817>
- Marcot, B. G., & Hanea, A. M. (2021). What is an optimal value of k in k-fold cross-validation in discrete Bayesian network analysis? *Computational Statistics*, 36(3), 2009–2031. <https://doi.org/10.1007/s00180-020-00999-9>
- Mason, K., Lindberg, K., Haenfling, C., Schori, A., Marsters, H., Read, D., & Borman, B. (2021). Social vulnerability indicators for flooding in aotearoa New Zealand. *International Journal of Environmental Research and Public Health*, 18(8). <https://doi.org/10.3390/ijerph18083952>
- Masson, V. (2000). A physically-based scheme for the urban energy budget in atmospheric models. *Boundary-Layer Meteorology*, 94, 357–397. <https://doi.org/10.1023/A:1002463829265>
- Mathew, A., Sreekumar, S., Khandelwal, S., & Kumar, R. (2019). Prediction of land surface temperatures for surface urban heat island assessment over Chandigarh city using support vector regression model. *Solar Energy*, 186, 404–415. <https://doi.org/10.1016/j.solener.2019.04.001>
- Matsler, A. M., Meerow, S., Mell, I. C., & Pavao-Zuckerman, M. A. (2021). A ‘green’ chameleon: Exploring the many disciplinary definitions, goals, and forms of “green infrastructure.” *Landscape and Urban Planning*, 214, 104145. <https://doi.org/10.1016/j.landurbplan.2021.104145>

- McGrath, H., Bourgon, J.-F., Proulx-Bourque, J.-S., Nastev, M., & Abo El Ezz, A. (2018). A comparison of simplified conceptual models for rapid web-based flood inundation mapping. *Natural Hazards*, 93(2), 905–920. <https://doi.org/10.1007/s11069-018-3331-y>
- Mean, P. E., & Efficiencies, B. M. P. P. R. (2006). *Pennsylvania stormwater best management practices manual*. Harrisburg: Pennsylvania Department of Environmental Protection. https://www.stormwaterpa.org/assets/media/BMP_manual/ (Fecha de último acceso: 20 de noviembre 2023)
- Mena, L. (2023, November 2). *Las tormentas dejan un reguero de inundaciones en Santander*. <https://www.eldiariomontanes.es/santander/tormenta-provoca-pequenas-inundaciones-centro-santander-20230911220321-nt.html> (Fecha de último acceso: 20 de noviembre 2023)
- Méndez-Lázaro, P., Muller-Karger, F. E., Otis, D., McCarthy, M. J., & Rodríguez, E. (2018). A heat vulnerability index to improve urban public health management in San Juan, Puerto Rico. *International Journal of Biometeorology*, 62(5), 709–722. <https://doi.org/10.1007/s00484-017-1319-z>
- Meng, X, Zhang, M., Wen, J., Du, S., Xu, H., Wang, L., & Yang, Y. (2019). A simple GIS-based model for urban rainstorm inundation simulation. *Sustainability (Switzerland)*, 11(10). <https://doi.org/10.3390/su11102830>
- Meng, Xiangjin, Meng, F., Zhao, Z., & Yin, C. (2021). Prediction of urban heat island effect over Jinan City using the markov-cellular automata model combined with urban biophysical descriptors. *Journal of the Indian Society of Remote Sensing*, 49, 997–1009. <https://doi.org/10.1007/s12524-020-01274-6>
- Menon, S. P., Bharadwaj, R., Shetty, P., Sanu, P., & Nagendra, S. (2017). Prediction of temperature using linear regression. *2017 International Conference on Electrical, Electronics, Communication, Computer, and Optimization Techniques (ICEECOT)*, 1–6. <https://doi.org/10.1109/ICEECOT.2017.8284588>
- Menze, B. H., Kelm, B. M., Masuch, R., Himmelreich, U., Bachert, P., Petrich, W., & Hamprecht, F. A. (2009). A comparison of random forest and its Gini importance with standard chemometric methods for the feature selection and classification of spectral data. *BMC Bioinformatics*, 10, 213, 1–16. <https://doi.org/10.1186/1471-2105-10-213>
- Meyer D, Dimitriadou E, Hornik K, Weingessel A, Leisch F (2023). `_e1071`: Misc Functions of the Department of Statistics, Probability Theory Group (Formerly: E1071), TU Wien. R package version 1.7-13, <<https://CRAN.R-project.org/package=e1071>>. (Fecha de último acceso: 20 de noviembre 2023)
- Ministerio de Hacienda y Función Pública. (2023). *Difusión de datos catastrales*. <https://www.sedecatastro.gob.es/Accesos/SECAccDescargaDatos.aspx> (Fecha de último acceso: 20 de noviembre 2023)
- Mirzaei, P. A., & Haghghat, F. (2010). Approaches to study urban heat island–abilities and limitations. *Building and Environment*, 45(10), 2192–2201. <https://doi.org/10.1016/j.buildenv.2010.04.001>
- Mohajerani, A., Bakaric, J., & Jeffrey-Bailey, T. (2017). The urban heat island effect, its causes, and

- mitigation, with reference to the thermal properties of asphalt concrete. *Journal of Environmental Management*, 197, 522–538. <https://doi.org/10.1016/j.jenvman.2017.03.095>
- Montavon, G., Samek, W., & Müller, K.-R. (2018). Methods for interpreting and understanding deep neural networks. *Digital Signal Processing*, 73, 1–15. <https://doi.org/10.1016/j.dsp.2017.10.011>
- Monte, B. E. O., Goldenfum, J. A., Michel, G. P., & Cavalcanti, J. R. de A. (2021). Terminology of natural hazards and disasters: A review and the case of Brazil. *International Journal of Disaster Risk Reduction*, 52, 101970. <https://doi.org/10.1016/j.ijdr.2020.101970>
- Moradkhani, H., & Sorooshian, S. (2008). General review of rainfall-runoff modeling: model calibration, data assimilation, and uncertainty analysis. *Hydrological Modelling and the Water Cycle* (pp. 1-24). Springer. ISBN 978-3-540-77843-1_1
- Morini, E., Touchaei, A. G., Rossi, F., Cotana, F., & Akbari, H. (2018). Evaluation of albedo enhancement to mitigate impacts of urban heat island in Rome (Italy) using WRF meteorological model. *Urban Climate*, 24, 551–566. <https://doi.org/10.1016/j.uclim.2017.08.001>
- Mucherera, B., & Mavhura, E. (2020). Flood survivors' perspectives on vulnerability reduction to floods in Mbire district, Zimbabwe. *Jamba: Journal of Disaster Risk Studies*, 12(1), 1–12. <https://doi.org/10.4102/JAMBA.V12I1.663>
- Mudasser, M., Hossain, M. Z., Rahaman, K. R., & Ha-Mim, N. M. (2020). Investigating the Climate-Induced Livelihood Vulnerability Index in Coastal Areas of Bangladesh. *World*, 1(2), 149–170. <https://doi.org/10.3390/world1020012>
- Mukherjee, F., & Singh, D. (2020). Detecting flood prone areas in Harris County: a GIS based analysis. *GeoJournal*, 85(3), 647–663. <https://doi.org/10.1007/s10708-019-09984-2>
- Mutani, G., Todeschi, V., & Matsuo, K. (2019). Urban heat island mitigation: A GIS-based Model for Hiroshima. *Instrumentation Measure Metrologie*, 18(4), 323 – 335. <https://doi.org/10.18280/i2m.180401>
- Mutiibwa, D., Strachan, S., & Albright, T. (2015). Land surface temperature and surface air temperature in complex terrain. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(10), 4762–4774. <https://doi.org/10.1109/JSTARS.2015.2468594>
- Myers, C. A., Slack, T., & Singelmann, J. (2008). Social vulnerability and migration in the wake of disaster: the case of Hurricanes Katrina and Rita. *Population and Environment*, 29, 271–291. <https://doi.org/10.1007/s11111-008-0072-y>
- Nakata-Osaki, C. M., Souza, L. C. L., & Rodrigues, D. S. (2018). THIS – Tool for Heat Island Simulation: A GIS extension model to calculate urban heat island intensity based on urban geometry. *Computers, Environment and Urban Systems*, 67, 157–168. <https://doi.org/10.1016/j.compenvurbsys.2017.09.007>
- Nakayama, T., & Fujita, T. (2010). Cooling effect of water-holding pavements made of new materials on water and heat budgets in urban areas. *Landscape and Urban Planning*, 96(2), 57–67. <https://doi.org/10.1016/j.landurbplan.2010.02.003>
- Nasiri, H., Mohd Yusof, M. J., & Mohammad Ali, T. A. (2016). An overview to flood vulnerability

- assessment methods. *Sustainable Water Resources Management*, 2(3), 331–336. <https://doi.org/10.1007/s40899-016-0051-x>
- Nemunaitis-Berry, K. L., Klein, P. M., Basara, J. B., & Fedorovich, E. (2017). Sensitivity of predictions of the urban surface energy balance and heat island to variations of urban canopy parameters in simulations with the WRF Model. *Journal of Applied Meteorology and Climatology*, 56(3), 573–595. <https://doi.org/10.1175/JAMC-D-16-0157.1>
- Nguyen, H. D., Cho, Y., Kim, H., Han, I., Kim, D., Ahn, S., & Shin, J. (2021). Comparison of multivariate linear regression and a machine learning algorithm developed for prediction of precision warfarin dosing in a Korean population. *Journal of Thrombosis and Haemostasis*, 19(7), 1676–1686. <https://doi.org/10.1111/jth.15318>
- Nguyen, K. A., & Liou, Y. A. (2019). Global mapping of eco-environmental vulnerability from human and nature disturbances. *Science of the Total Environment*, 664, 995–1004. <https://doi.org/10.1016/j.scitotenv.2019.01.407>
- Niyazi, B. A., Masoud, M. H., Ahmed, M., Basahi, J. M., & Rashed, M. A. (2020). Runoff assessment and modeling in arid regions by integration of watershed and hydrologic models with GIS techniques. *Journal of African Earth Sciences*, 172. <https://doi.org/10.1016/j.jafrearsci.2020.103966>
- Nkwunonwo, U. C., Whitworth, M., & Baily, B. (2020). A review of the current status of flood modelling for urban flood risk management in the developing countries. *Scientific African*, 7, e00269. <https://doi.org/10.1016/j.sciaf.2020.e00269>
- Nobre, A. D., Cuartas, L. A., Momo, M. R., Severo, D. L., Pinheiro, A., & Nobre, C. A. (2016). HAND contour: a new proxy predictor of inundation extent. *Hydrological Processes*, 30(2), 320–333. <https://doi.org/10.1002/hyp.10581>
- Noro, M., & Lazzarin, R. (2015). Urban heat island in Padua, Italy: Simulation analysis and mitigation strategies. *Urban Climate*, 14, 187–196. <https://doi.org/10.1016/j.uclim.2015.04.004>
- Oh, J. W., Ngarambe, J., Duhirwe, P. N., Yun, G. Y., & Santamouris, M. (2020). Using deep-learning to forecast the magnitude and characteristics of urban heat island in Seoul Korea. *Scientific Reports*, 10(1), 3559. <https://doi.org/10.1038/s41598-020-60632-z>
- Oke, T. R. (1982). The energetic basis of the urban heat island (Symons Memorial Lecture, 20 May 1980). *Quarterly Journal, Royal Meteorological Society*, 108(455), 1–24.
- Oke, T. R. (2002). *Boundary layer climates*. Routledge. <https://doi.org/10.4324/9780203407219>
- OpenStreetMap contributors. (2017). *Planet dump retrieved from <https://planet.osm.org>* . (Fecha de último acceso: 20 de noviembre 2023)
- CNIG. (2023). Centro de Descargas del Organismo Autónomo Centro Nacional de Información Geográfica. <http://centrodedescargas.cnig.es/CentroDescargas/buscadorCatalogo.do?codFamilia=LIDAR#> (Fecha de último acceso: 20 de noviembre 2023)
- Osborne, J. W., & Waters, E. (2019). Four assumptions of multiple regression that researchers should always test. *Practical Assessment, Research, and Evaluation*, 8(1), 2. <https://doi.org/10.7275/r222-hv23>

- Otterpohl, R., Grottker, M., & Lange, J. (1997). Sustainable water and waste management in urban areas. *Water Science and Technology*, 35(9), 121–133. [https://doi.org/10.1016/S0273-1223\(97\)00190-X](https://doi.org/10.1016/S0273-1223(97)00190-X)
- Paixão, M. A., Corseuil, C. W., Kobiyama, M., Gonzalez Avila, I., Vanelli, F. M., Oliveira, H. U., Vasconcellos, S. M., Campagnolo, K., & Fagundes, M. R. (2021). Occurrence of Multi-Disasters in the Mampituba River Basin, Southern Brazil, During the COVID-19 Pandemic. *International Journal of Erosion Control Engineering*, 13(4), 84–92. <https://doi.org/10.13101/ijece.13.84>
- Pandey, A. C., Singh, S. K., & Nathawat, M. S. (2010). Waterlogging and flood hazards vulnerability and risk assessment in Indo Gangetic plain. *Natural Hazards*, 55(2), 273–289. <https://doi.org/10.1007/s11069-010-9525-6>
- Parsons, M., Glavac, S., Hastings, P., Marshall, G., McGregor, J., McNeill, J., Morley, P., Reeve, I., & Stayner, R. (2016). Top-down assessment of disaster resilience: A conceptual framework using coping and adaptive capacities. *International Journal of Disaster Risk Reduction*, 19, 1–11. <https://doi.org/10.1016/j.ijdrr.2016.07.005>
- Patra, K. C. (2001). *Hydrology and water resources engineering*. India: CRC Press; ISBN 1-84265-023-8.
- Peduzzi, P., Dao, H., Herold, C., & Mouton, F. (2009). Assessing global exposure and vulnerability towards natural hazards: The Disaster Risk Index. *Natural Hazards and Earth System Science*, 9(4), 1149–1159. <https://doi.org/10.5194/nhess-9-1149-2009>
- Pena Acosta, M., Vahdatikhaki, F., Santos, J., Jarro, S. P., & Doree, A. (2023). Data-Driven Analysis of <https://dx.doi.org/10.2139/ssrn.4544405>
- Peng, S., Piao, S., Ciais, P., Friedlingstein, P., Oettle, C., Bréon, F.-M., Nan, H., Zhou, L., & Myneni, R. B. (2012). Surface urban heat island across 419 global big cities. *Environmental Science & Technology*, 46(2), 696–703. <https://doi.org/10.1021/es2030438>
- Pesquera, E., Alonso, M., & Guerra, E. (2020, November 2). *Inundaciones en Nueva Montaña - Santiago el Mayor*. <https://www.ifomo.es/album/santander/inundaciones-nueva-montana-santiago-mayor/20201209153429168428.html>
- Pham, Q. B., Ali, S. A., Bielecka, E., Calka, B., Orych, A., Parvin, F., & Łupikasza, E. (2022). Flood vulnerability and buildings' flood exposure assessment in a densely urbanised city: comparative analysis of three scenarios using a neural network approach. In *Natural Hazards* (Issue 0123456789). Springer Netherlands. <https://doi.org/10.1007/s11069-022-05336-5>
- Pigliautile, I., Chàfer, M., Pisello, A. L., Pérez, G., & Cabeza, L. F. (2020). Inter-building assessment of urban heat island mitigation strategies: Field tests and numerical modelling in a simplified-geometry experimental set-up. *Renewable Energy*, 147, 1663–1675. <https://doi.org/10.1016/j.renene.2019.09.082>
- Policia Nacional Española. (2023). *Unidad de subsuelo y protección ambiental; Policía Nacional*. https://www.policia.es/_es/tupolicia_conocenos_estructura_dao_cgseguridadciudadana_subsuelo.php (Fecha de último acceso: 20 de noviembre 2023)
- Pothukuchi, K. (2021). City light or star bright: a review of urban light pollution, impacts, and planning implications. *Journal of Planning Literature*, 36(2), 155–169. <https://doi.org/10.1177/0885412220986421>

- Qasim, S., Nawaz Khan, A., Prasad Shrestha, R., & Qasim, M. (2015). Risk perception of the people in the flood prone Khyber Pukhthunkhwa province of Pakistan. *International Journal of Disaster Risk Reduction*, 14, 373–378. <https://doi.org/10.1016/j.ijdrr.2015.09.001>
- Qasim, S., Qasim, M., Shrestha, R. P., Khan, A. N., Tun, K., & Ashraf, M. (2016). Community resilience to flood hazards in Khyber Pukhthunkhwa province of Pakistan. *International Journal of Disaster Risk Reduction*, 18, 100–106. <https://doi.org/10.1016/j.ijdrr.2016.03.009>
- QGIS Development Team. (2023). *QGIS Geographic Information System*. <https://www.qgis.org> (Fecha de último acceso: 20 de noviembre 2023)
- Qi, W., Ma, C., Xu, H., Chen, Z., Zhao, K., & Han, H. (2021). A review on applications of urban flood models in flood mitigation strategies. In *Natural Hazards* (Vol. 108, Issue 1). Springer Netherlands. <https://doi.org/10.1007/s11069-021-04715-8>
- R Core Team, A., (2022). *R: A language and environment for statistical computing*. R Foundation for Statistical Computing, Vienna, Austria. 2012. <https://www.r-project.org/foundation/> (Fecha de último acceso: 20 de noviembre 2023)
- Rahimi, A., & Recht, B. (2007). Random features for large-scale kernel machines. Proceedings of the 20th International Conference on *Neural Information Processing Systems*, Pags 1177-1184 https://proceedings.neurips.cc/paper_files/paper/2007/file/013a006f03dbc5392effeb8f18fd a755-Paper.pdf. (Fecha de último acceso: 20 de noviembre 2023)
- Reid, W. V, Mooney, H. A., Cropper, A., Capistrano, D., Carpenter, S. R., Chopra, K., Dasgupta, P., Dietz, T., Duraiappah, A. K., Hassan, R., Kasperson, R., Leemans, R., May, R. M., McMichael, A. J., Pingali, P., Samper, C., Scholes, R., Watson, R. T., Zakri, A. H., ... Zurek, M. B. (2005). *Ecosystems and human well-being - Synthesis: A Report of the Millennium Ecosystem Assessment*. Island Press. <https://edepot.wur.nl/45159> (Fecha de último acceso: 20 de noviembre 2023)
- Requena y Díez de Revenga, M. (2002). Juventud y dependencia familiar en España. *Revista de Estudios de Juventud*, ISSN-e 0211-4364, N^o. 58, 2002 (Ejemplar Dedicado a: Emancipación y Familia), Págs. 10-23, 58, 10–23.
- Rezaei, M., Amiraslani, F., Samani, N. N., & Alavipanah, K. (2020). Application of two fuzzy models using knowledge-based and linear aggregation approaches to identifying flooding-prone areas in Tehran. *Natural Hazards*, 100(1), 363–385. <https://doi.org/10.1007/s11069-019-03816-9>
- Rezazadeh Helmi, N., Verbeiren, B., Wirion, C., van Griensven, A., Weerasinghe, I., & Bauwens, W. (2019). WetSpa-Urban: An Adapted Version of WetSpa-Python, A Suitable Tool for Detailed Runoff Calculation in Urban Areas. *Water*, 11(12). <https://doi.org/10.3390/w11122460>
- Rhee, J., Park, S., & Lu, Z. (2014). Relationship between land cover patterns and surface temperature in urban areas. *GIScience & Remote Sensing*, 51(5), 521–536. <https://doi.org/10.1080/15481603.2014.964455>
- Richards, L. A. (1931). Capillary conduction of liquids through porous mediums. *Physics*, 1(5), 318–333. <https://doi.org/10.1063/1.1745010>
- Rizwan, A. M., Dennis, L. Y. C., & Liu, C. (2008). A review on the generation, determination and mitigation of Urban Heat Island. *Journal of Environmental Sciences*, 20(1), 120–128. [https://doi.org/10.1016/S1001-0742\(08\)60019-4](https://doi.org/10.1016/S1001-0742(08)60019-4)

- Rodríguez-Rojas, M. I., & Grindlay Moreno, A. L. (2022). A Discussion on the Application of Terminology for Urban Soil Sealing Mitigation Practices. In *International Journal of Environmental Research and Public Health* (Vol. 19, Issue 14). <https://doi.org/10.3390/ijerph19148713>
- Ross, C. W., Prihodko, L., Anchang, J., Kumar, S., Ji, W., & Hanan, N. P. (2018). *Global hydrologic soil groups (HYSOGs250m) for curve number-based runoff modeling*. ORNL Distributed Active Archive Center. <https://doi.org/10.3334/ORNLDAAC/1566>
- Ruiz, A., & Rajib, A. (2022). Developing a Spatially Explicit Flood Susceptibility Index for Critical Infrastructure in US Cities. *World Environmental and Water Resources Congress 2022*, 1242–1251. <https://ascelibrary.org/doi/epdf/10.1061/9780784484258.115>
- Ryu, Y.-H., Baik, J.-J., & Lee, S.-H. (2011). A new single-layer urban canopy model for use in mesoscale atmospheric models. *Journal of Applied Meteorology and Climatology*, 50(9), 1773–1794. <https://doi.org/10.1175/2011JAMC2665.1>
- Salmeron, R., García, C. B., & García, J. (2018). Variance inflation factor and condition number in multiple linear regression. *Journal of Statistical Computation and Simulation*, 88(12), 2365–2384. <https://doi.org/10.1080/00949655.2018.1463376>
- Salvadore, E., Bronders, J., & Batelaan, O. (2015). Hydrological modelling of urbanized catchments: A review and future directions. *Journal of Hydrology*, 529(P1), 62–81. <https://doi.org/10.1016/j.jhydrol.2015.06.028>
- Sánchez-Guevara Sánchez, C., Núñez Peiró, M., & Neila González, F. J. (2017). Urban heat island and vulnerable population. The case of Madrid. *Sustainable Development and Renovation in Architecture, Urbanism and Engineering*, 3–13. https://doi.org/10.1007/978-3-319-51442-0_1
- Santamouris, M. (2013). Using cool pavements as a mitigation strategy to fight urban heat island - A review of the actual developments. *Renewable and Sustainable Energy Reviews*, 26, 224–240. <https://doi.org/10.1016/j.rser.2013.05.047>
- Santamouris, Mattheos, & Kolokotsa, D. (2013). Passive cooling dissipation techniques for buildings and other structures: The state of the art. *Energy and Buildings*, 57, 74–94. <https://doi.org/10.1016/j.enbuild.2012.11.002>
- Sañudo, E., Cea, L., & Puertas, J. (2020). Modelling pluvial flooding in urban areas coupling the models iber and SWMM. *Water*, 12(9), 2647. <https://doi.org/10.3390/w12092647>
- Sarmah, T., Das, S., Narendr, A., & Aithal, B. H. (2020). Assessing human vulnerability to urban flood hazard using the analytic hierarchy process and geographic information system. *International Journal of Disaster Risk Reduction*, 50(August), 101659. <https://doi.org/10.1016/j.ijdrr.2020.101659>
- Sauti, N. S., Daud, M. E., & Kaamin, M. (2020). Construction of an Integrated social vulnerability index to identify spatial variability of exposure to seismic hazard in Pahang, Malaysia. *International Journal of Design and Nature and Ecodynamics*, 15(3), 365–372. <https://doi.org/10.18280/ijdne.150310>
- Scalenghe, R., & Ajmone-Marsan, F. (2009). The anthropogenic sealing of soils in urban areas. *Landscape and Urban Planning*, 90(1–2), 1–10. <https://doi.org/10.1016/j.landurbplan.2008.10.011>

- Schmidtlein, M. C., Shafer, J. M., Berry, M., & Cutter, S. L. (2011). Modeled earthquake losses and social vulnerability in Charleston, South Carolina. *Applied Geography*, 31(1), 269–281. <https://doi.org/10.1016/j.apgeog.2010.06.001>
- Schneiderbauer, S., Ehrlich, D., & Birkmann, J. (2006). Social levels and hazard (in) dependence in determining vulnerability. *Measuring Vulnerability to Natural Hazards: Towards Disaster Resilient Societies*, 78–102, JRC32736, ISBN 978-92-808-1135-3
- Schwaab, J., Meier, R., Mussetti, G., Seneviratne, S., Bürgi, C., & Davin, E. L. (2021). The role of urban trees in reducing land surface temperatures in European cities. *Nature Communications*, 12(1), 6763. <https://doi.org/10.1038/s41467-021-26768-w>
- Sehili, F., Madani, S., & Meschinet de Richemond, N. (2022). Vulnerabilities of cities to disaster: the 2003 earthquake in Boumerdes (Algeria). *GeoJournal*, 87(3), 1759–1776. <https://doi.org/10.1007/s10708-020-10333-x>
- Shaker, R. R., Altman, Y., Deng, C., Vaz, E., & Forsythe, K. W. (2019). Investigating urban heat island through spatial analysis of New York City streetscapes. *Journal of Cleaner Production*, 233, 972–992. <https://doi.org/10.1016/j.jclepro.2019.05.389>
- Shatnawi, N., & Abu Qdais, H. (2019). Mapping urban land surface temperature using remote sensing techniques and artificial neural network modelling. *International Journal of Remote Sensing*, 40(10), 3968–3983. <https://doi.org/10.1080/01431161.2018.1557792>
- Shen, P., Liu, J., & Wang, M. (2021). Fast generation of microclimate weather data for building simulation under heat island using map capturing and clustering technique. *Sustainable Cities and Society*, 71. <https://doi.org/10.1016/j.scs.2021.102954>
- Sheu, Y. (2020). Illuminating the black box: interpreting deep neural network models for psychiatric research. *Frontiers in Psychiatry*, 11, 551299. <https://doi.org/10.3389/fpsy.2020.551299>
- Singapore. Public Utilities Board. (2014). *Active Beautiful Clean Waters: Design Guidelines*. PUB Singapore. <https://www.clc.gov.sg/research-publications/publications/urban-systems-studies/view/the-active-beautiful-clean-waters-programme-water-as-an-environmental-asset> (Fecha de último acceso: 20 de noviembre 2023)
- Singh, N., Singh, S., & Mall, R. K. (2020). Urban ecology and human health: implications of urban heat island, air pollution and climate change nexus. In *Urban Ecology: Emerging Patterns and Social-Ecological Systems*. Elsevier Inc. <https://doi.org/10.1016/B978-0-12-820730-7.00017-3>
- Skilodimou, H. D., Bathrellos, G. D., Chousianitis, K., Youssef, A. M., & Pradhan, B. (2019). Multi-hazard assessment modeling via multi-criteria analysis and GIS: a case study. *Environmental Earth Sciences*, 78(2). <https://doi.org/10.1007/s12665-018-8003-4>
- Smith, M. B., Seo, D.-J., Koren, V. I., Reed, S. M., Zhang, Z., Duan, Q., Moreda, F., & Cong, S. (2004). The distributed model intercomparison project (DMIP): motivation and experiment design. *Journal of Hydrology*, 298(1–4), 4–26. <https://doi.org/10.1016/j.jhydrol.2004.03.040>
- Software de cartografía SIG web | ArcGIS Online*. (2023). <https://www.esri.com/es-es/arcgis/products/arcgis-online/overview> (Fecha de último acceso: 20 de noviembre 2023)
- Sorribes, E. P. (2023). *Riada en Zaragoza*. <https://elpais.com/espana/2023-07-06/una-fuerte-tromba-de-agua-anega-zaragoza-y-obliga-al-rescate-de-varios-conductores-atrapados-en->

- sus-vehiculos.html (Fecha de último acceso: 20 de noviembre 2023)
- Souissi, D., Zouhri, L., Hammami, S., Msaddek, M. H., Zghibi, A., & Dlala, M. (2020). GIS-based MCDM–AHP modeling for flood susceptibility mapping of arid areas, southeastern Tunisia. *Geocarto International*, 35(9), 991–1017. <https://doi.org/10.1080/10106049.2019.1566405>
- Stefanidis, S., & Stathis, D. (2013). Assessment of flood hazard based on natural and anthropogenic factors using analytic hierarchy process (AHP). *Natural Hazards*, 68(2), 569 – 585. <https://doi.org/10.1007/s11069-013-0639-5>
- Straub, A., Berger, K., Breitner, S., Cyrus, J., Geruschkat, U., Jacobeit, J., Kühnbach, B., Kusch, T., Philipp, A., & Schneider, A. (2019). Statistical modelling of spatial patterns of the urban heat island intensity in the urban environment of Augsburg, Germany. *Urban Climate*, 29, 100491. <https://doi.org/10.1016/j.uclim.2019.100491>
- Sun, Y., Gao, C., Li, J., Wang, R., & Liu, J. (2019). Quantifying the effects of urban form on land surface temperature in subtropical high-density urban areas using machine learning. *Remote Sensing*, 11(8), 959. <https://doi.org/10.3390/rs11080959>
- Sung, C.-H., & Liaw, S.-C. (2020). A GIS-based approach for assessing social vulnerability to flood and debris flow hazards. *International Journal of Disaster Risk Reduction*, 46, 101531. <https://doi.org/10.1016/j.ijdrr.2020.101531>
- Sussman, H. S., Dai, A., & Roundy, P. E. (2021). The controlling factors of urban heat in Bengaluru, India. *Urban Climate*, 38, 100881. <https://doi.org/10.1016/j.uclim.2021.100881>
- Szymanowski, M., & Kryza, M. (2012). Local regression models for spatial interpolation of urban heat island-an example from Wrocław, SW Poland. *Theoretical and Applied Climatology*, 108(1–2), 53–71. <https://doi.org/10.1007/s00704-011-0517-6>
- Tan, J. K. N., Belcher, R. N., Tan, H. T. W., Menz, S., & Schroepfer, T. (2021). The urban heat island mitigation potential of vegetation depends on local surface type and shade. *Urban Forestry & Urban Greening*, 62, 127128. <https://doi.org/10.1016/j.ufug.2021.127128>
- Tanaka, T., Kiyohara, K., & Tachikawa, Y. (2020). Comparison of fluvial and pluvial flood risk curves in urban cities derived from a large ensemble climate simulation dataset: A case study in Nagoya, Japan. *Journal of Hydrology*, 584. <https://doi.org/10.1016/j.jhydrol.2020.124706>
- Tate, E. (2012). Social vulnerability indices: A comparative assessment using uncertainty and sensitivity analysis. *Natural Hazards*, 63(2), 325–347. <https://doi.org/10.1007/s11069-012-0152-2>
- Teng, J., Jakeman, A. J., Vaze, J., Croke, B. F. W., Dutta, D., & Kim, S. (2017). Flood inundation modelling: A review of methods, recent advances and uncertainty analysis. *Environmental Modelling and Software*, 90, 201–216. <https://doi.org/10.1016/j.envsoft.2017.01.006>
- Teng, J., Vaze, J., Dutta, D., & Marvanek, S. (2015). Rapid Inundation Modelling in Large Floodplains Using LiDAR DEM. *Water Resources Management*, 29(8), 2619–2636. <https://doi.org/10.1007/s11269-015-0960-8>
- Tepanosyan, G., Muradyan, V., Hovsepyan, A., Pinigin, G., Medvedev, A., & Asmaryan, S. (2021). Studying spatial-temporal changes and relationship of land cover and surface Urban Heat Island derived through remote sensing in Yerevan, Armenia. *Building and Environment*, 187,

107390. <https://doi.org/10.1016/j.buildenv.2020.107390>
- Times of India. (2023). *Delhi News: PM Modi inquires about flood situation in national capital; Yamuna water level starts receding*. <https://timesofindia.indiatimes.com/city/delhi/rains-news-live-updates-monsoon-imd-alert-rain-fall-schools-closed-floods-waterlogging-landslides-trains-cancelled-in-india-today-12-july/liveblog/101683229.cms> (Fecha de último acceso: 20 de noviembre 2023)
- Tiwari, A., Dadhania, A. V., Ragnathrao, V. A. B., & Oliveira, E. R. A. (2021). Using machine learning to develop a novel COVID-19 Vulnerability Index (C19VI). *Science of The Total Environment*, 773, 145650. <https://doi.org/10.1016/j.scitotenv.2021.145650>
- Török, I. (2018). Qualitative assessment of social vulnerability to flood hazards in Romania. *Sustainability (Switzerland)*, 10(10), 3780. <https://doi.org/10.3390/su10103780>
- Tsoka, S., Tsikaloudaki, A., & Theodosiou, T. (2018). Analyzing the ENVI-met microclimate model's performance and assessing cool materials and urban vegetation applications—A review. *Sustainable Cities and Society*, 43, 55–76. <https://doi.org/10.1016/j.scs.2018.08.009>
- UN-DESA. (2018a). World Urbanization Prospects: The 2018 Revision. In *Demographic Research* (Vol. 12). <https://doi.org/10.4054/demres.2005.12.9>
- UN-DESA. (2018b). *World youth report: youth and the 2030 Agenda for Sustainable Development*. <https://www.un.org/development/desa/youth/world-youth-report/wyr2018.html>. (Fecha de último acceso: 20 de noviembre 2023)
- UN-DESA. (2020). *The Sustainable Development Goals Report 2020*. <https://unstats.un.org/sdgs/report/2020/> (Fecha de último acceso: 20 de noviembre 2023)
- UN-DESA. (2022). World Population Prospects 2022. In *United Nation* (Issue 9). www.un.org/development/desa/pd/ (Fecha de último acceso: 20 de noviembre 2023)
- UN-HABITAT. (2009). *Planning Sustainable Cities: Policy Directions: Global Report on Human Settlements 2009*. UN-HABITAT. <https://unhabitat.org/planning-sustainable-cities-global-report-on-human-settlements-2009> (Fecha de último acceso: 20 de noviembre 2023)
- Unger, J. (2004). Intra-urban relationship between surface geometry and urban heat island: review and new approach. *Climate Research*, 27(3), 253–264. <http://dx.doi.org/10.3354/cr027253>
- UNISDR. (2007). Towards a Culture of Prevention : Disaster Risk Reduction Begins at School - Good Practices and Lessons Learned. https://www.unisdr.org/files/761_education-good-practices.pdf (Fecha de último acceso: 20 de noviembre 2023)
- UNISDR. (2009). *UNISDR terminology on disaster risk reduction*. <https://www.degruyter.com/document/doi/10.7591/9781501701498-008/html> (Fecha de último acceso: 20 de noviembre 2023)
- Urban GreenUP. (2018). *D1.1: NBS Catalogue*. https://www.urbangreenup.eu/kdocs/1907476/urban_greenup_d1.1_nbs_catalogue_31-05-2018.pdf (Fecha de último acceso: 20 de noviembre 2023)
- Urban Water Infrastructure Management Committee. (2001). A Guide for Best Management Practice (BMP) Selection in Urban Developed Areas. *American Society of Civil Engineers: Reston, VA, USA*. ISBN 0-7844-0557-3

- Üstün, B., Melssen, W. J., & Buydens, L. M. C. (2007). Visualisation and interpretation of support vector regression models. *Analytica Chimica Acta*, 595(1–2), 299–309. <https://doi.org/10.1016/j.aca.2007.03.023>
- Van Doninck, J. (2018). *horizon: Horizon Search Algorithm*. <https://www.rdocumentation.org/packages/horizon/versions/1.2> (Fecha de último acceso: 20 de noviembre 2023)
- Verbeke, S., & Audenaert, A. (2018). Thermal inertia in buildings: A review of impacts across climate and building use. *Renewable and Sustainable Energy Reviews*, 82, 2300–2318. <https://doi.org/10.1016/j.rser.2017.08.083>
- Victoria State Government. (2017). Green-Blue City. *Environment, Land, Water and Planning*, 1–76. <https://www.clearwatervic.com.au/user-data/resource-files/green-blue-guidelines-feb17-low-res.pdf> (Fecha de último acceso: 20 de noviembre 2023)
- Voogt, J. A., & Oke, T. R. (1998). Effects of urban surface geometry on remotely-sensed surface temperature. *International Journal of Remote Sensing*, 19(5), 895–920. <https://doi.org/10.1080/014311698215784>
- Vyas, A., Shastri, B., & Joshi, Y. (2014). Spatio-Temporal Analysis of UHI using Geo-Spatial Techniques: A case study of Ahmedabad. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XL–8, 997–1002. <https://doi.org/10.5194/isprsarchives-XL-8-997-2014>
- Wang, C., Wang, Z.-H., Kaloush, K. E., & Shacat, J. (2021). Cool pavements for urban heat island mitigation: A synthetic review. *Renewable and Sustainable Energy Reviews*, 146, 111171. <https://doi.org/10.1016/j.rser.2021.111171>
- Wang, Rongtao, Liu, R., Chen, Q., Cheng, Q., & Du, M. (2023). Effects of Sky View Factor on Thermal Environment in Different Local Climate Zoning Building Scenarios—A Case Study of Beijing, China. In *Buildings* (Vol. 13, Issue 8). <https://doi.org/10.3390/buildings13081882>
- Wang, Rui, Gao, W., & Peng, W. (2020). Downscale MODIS Land Surface Temperature Based on Three Different Models to Analyze Surface Urban Heat Island: A Case Study of Hangzhou. *Remote Sensing*, 12(13). <https://doi.org/10.3390/rs12132134>
- Wang, S., & Wang, H. (2018). Extending the Rational Method for assessing and developing sustainable urban drainage systems. *Water Research*, 144, 112–125. <https://doi.org/10.1016/j.watres.2018.07.022>
- Wisner, B., Blaikie, P., T., C., & Davis, I. (2004). *At Risk: Natural hazards, people's vulnerability and disasters* (2nd ed.). Routledge. <https://doi.org/10.4324/9780203714775>
- Wood, E., Sanders, M., & Frazier, T. (2021). The practical use of social vulnerability indicators in disaster management. *International Journal of Disaster Risk Reduction*, 63(July), 102464. <https://doi.org/10.1016/j.ijdrr.2021.102464>
- Xiao, H., Kopecká, M., Guo, S., Guan, Y., Cai, D., Zhang, C., Zhang, X., & Yao, W. (2018). Responses of urban land surface temperature on land cover: A comparative study of Vienna and Madrid. *Sustainability (Switzerland)*, 10(2). <https://doi.org/10.3390/su10020260>
- Xie, W., & Meng, Q. (2023). An Integrated PCA—AHP Method to Assess Urban Social

- Vulnerability to Sea Level Rise Risks in Tampa, Florida. *Sustainability*, 15(3). <https://doi.org/10.3390/su15032400>
- Yagüe, C., Zurita, E., & Martínez, A. (1991). Statistical analysis of the Madrid urban heat island. *Atmospheric Environment. Part B. Urban Atmosphere*, 25(3), 327–332. [https://doi.org/10.1016/0957-1272\(91\)90004-X](https://doi.org/10.1016/0957-1272(91)90004-X)
- Yang, F., & Chen, L. (2016). Developing a thermal atlas for climate-responsive urban design based on empirical modeling and urban morphological analysis. *Energy and Buildings*, 111, 120–130. <https://doi.org/10.1016/j.enbuild.2015.11.047>
- Yin, D., Evans, B., Wang, Q., Chen, Z., Jia, H., Chen, A. S., Fu, G., Ahmad, S., & Leng, L. (2020). Integrated 1D and 2D model for better assessing runoff quantity control of low impact development facilities on community scale. *Science of the Total Environment*, 720. <https://doi.org/10.1016/j.scitotenv.2020.137630>
- Yoo, S. (2018). Investigating important urban characteristics in the formation of urban heat islands: A machine learning approach. *Journal of Big Data*, 5(1), 2. <https://doi.org/10.1186/s40537-018-0113-z>
- Yuan, C., Adelia, A. S., Mei, S., He, W., Li, X.-X., & Norford, L. (2020). Mitigating intensity of urban heat island by better understanding on urban morphology and anthropogenic heat dispersion. *Building and Environment*, 176, 106876. <https://doi.org/10.1016/j.buildenv.2020.106876>
- Yuan, C., & Chen, L. (2011). Mitigating urban heat island effects in high-density cities based on sky view factor and urban morphological understanding: a study of Hong Kong. *Architectural Science Review*, 54(4), 305–315. <http://dx.doi.org/10.1080/00038628.2011.613644>
- Yue, H. H., & Tomoyasu, M. (2004). Weighted principal component analysis and its applications to improve FDC performance. *Proceedings of the IEEE Conference on Decision and Control*, 4, 4262–4267. <https://doi.org/10.1109/cdc.2004.1429421>
- Zhang, Y., Liu, J., & Wen, Z. (2021). Predicting surface urban heat island in Meihokou city, China: A combination method of monte carlo and random forest. *Chinese Geographical Science*, 31, 659–670. <https://doi.org/10.1007/s11769-021-1215-7>
- Zhou, D., Xiao, J., Bonafoni, S., Berger, C., Deilami, K., Zhou, Y., Frolking, S., Yao, R., Qiao, Z., & Sobrino, J. A. (2019). Satellite remote sensing of surface urban heat islands: Progress, challenges, and perspectives. *Remote Sensing*, 11(1), 1–36. <https://doi.org/10.3390/rs11010048>
- Zhu, H., Yu, M., Zhu, J., Lu, H., & Cao, R. (2019). Simulation study on effect of permeable pavement on reducing flood risk of urban runoff. *International Journal of Transportation Science and Technology*, 8(4), 373–382. <https://doi.org/10.1016/j.ijtst.2018.12.001>
- Zhu, Z., Chen, Z., Chen, X., & Yu, G. (2019). An assessment of the hydrologic effectiveness of low impact development (LID) practices for managing runoff with different objectives. *Journal of Environmental Management*, 231, 504–514. <https://doi.org/10.1016/j.jenvman.2018.10.046>
- Zope, P. E., Eldho, T. I., & Jothiprakash, V. (2016). Impacts of land use-land cover change and urbanization on flooding: A case study of Oshiwara River Basin in Mumbai, India. *Catena*, 145, 142–154. <https://doi.org/10.1016/j.catena.2016.06.009>

Žuvela-Aloise, M., Koch, R., Buchholz, S., & Früh, B. (2016). Modelling the potential of green and blue infrastructure to reduce urban heat load in the city of Vienna. *Climatic Change*, *135*, 425–438. <https://doi.org/10.1007/s10584-016-1596-2>

7 Anexos

7.1 Anexo 1

Tabla 10. Valor inicial del umbral de escorrentía (mm)

Código	Uso de suelo	Práctica de cultivo	Pendiente (%)	Grupo de suelo			
				A	B	C	D
11100	Tejido urbano continuo			1	1	1	1
11200	Tejido urbano discontinuo			24	140	8	6
11200	Urbanizaciones			24	14	8	6
11210	Estructura urbana abierta			24	14	8	6
11220	Urbanizaciones exentas y/o ajardinadas			24	14	8	6
12100	Zonas industriales y comerciales			6	4	3	3
12100	Granjas agrícolas			24	14	8	6
12110	Zonas industriales			12	7	5	4
12120	Grandes superficies de equipamiento y servicios			6	4	3	3
12200	Redes viarias, ferroviarias y terrenos asociados			1	1	1	1
12210	Autopistas, autovías y terrenos asociados			1	1	1	1
12220	Complejos ferroviarios			12	7	5	4
12300	Zonas portuarias			1	1	1	1
12400	Aeropuertos			24	14	8	6
13100	Zonas de extracción minera			16	9	6	5
13200	Escombreras y vertederos			20	11	8	6
13300	Zonas de construcción			24	14	8	6
14100	Zonas verdes urbanas			53	23	14	10
14200	Instalaciones deportivas y recreativas			79	32	18	13
14210	Campos de golf			79	32	18	13
14220	Resto de instalaciones deportivas y recreativas			53	23	14	10

Tabla 10. (Continúa)

Código	Uso de suelo	Práctica de cultivo	Pendiente (%)	Grupo de suelo			
				A	B	C	D
21100	Tierras de labor en secano (cereales)	R	≥ 3	29	17	10	8
21100	Tierras de labor en secano (cereales)	N	≥ 3	32	19	12	10
21100	Tierras de labor en secano (cereales)	R/N	< 3	34	21	14	12
21100	Tierras de labor en secano (viveros)		≥ 3	62	28	15	10
21100	Tierras de labor en secano (viveros)		< 3	75	34	19	14
21100	Tierras de labor en secano (hortalizas)	R	≥ 3	23	13	8	6
21100	Tierras de labor en secano (hortalizas)	N	≥ 3	25	16	11	8
21100	Tierras de labor en secano (hortalizas)	R/N	< 3	29	19	14	11
21100	Tierras abandonadas		≥ 3	16	10	7	5
21100	Tierras abandonadas		< 3	20	14	11	8
21200	Terrenos regados permanentemente	R	≥ 3	37	20	12	9
21200	Terrenos regados permanentemente	N	≥ 3	42	23	14	11
21200	Terrenos regados permanentemente	R/N	< 3	47	25	16	13
21210	Cultivos herbáceos en regadío	R	≥ 3	37	20	12	9
21210	Cultivos herbáceos en regadío	N	≥ 3	42	23	14	11
21210	Cultivos herbáceos en regadío	R/N	< 3	47	25	16	13
21220	Otras zonas de irrigación (*)	R	≥ 3	37	20	12	9
21220	Otras zonas de irrigación (*)	N	≥ 3	42	23	14	11
21220	Otras zonas de irrigación (*)	R/N	< 3	47	25	16	13
21300	Arrozales			47	25	16	13
22100	Viñedos		≥ 3	62	28	15	10
22100	Viñedos		< 3	75	34	19	14
22110	Viñedos en secano		≥ 3	62	28	15	10

Tabla 10. (Continúa)

Código	Uso de suelo	Práctica de cultivo	Pendiente (%)	Grupo de suelo			
				A	B	C	D
22110	Viñedos en secano		< 3	75	34	19	14
22120	Viñedos en regadío		≥ 3	62	28	15	10
22120	Viñedos en regadío		< 3	75	34	19	14
22200	Frutales y plantaciones de bayas		≥ 3	80	34	19	14
22200	Frutales y plantaciones de bayas		< 3	95	42	22	15
22210	Frutales en secano		≥ 3	62	28	15	10
22210	Frutales en secano		< 3	75	34	19	14
22220	Frutales en regadío		≥ 3	80	34	19	14
22220	Frutales en regadío		< 3	95	42	22	15
22221	Cítricos		≥ 3	80	34	19	14
24120	Cultivos anuales asociados con cultivos permanentes en regadío		< 3	106	48	22	15
24211	Mosaico de cultivos anuales con prados o praderas en secano	R	≥ 3	26	15	9	6
24211	Mosaico de cultivos anuales con prados o praderas en secano	N	≥ 3	28	17	11	8
24211	Mosaico de cultivos anuales con prados o praderas en secano	R/N	< 3	30	19	13	10
24212	Mosaico de cultivos permanentes en secano		≥ 3	62	28	15	10
24212	Mosaico de cultivos permanentes en secano		< 3	75	34	19	14
24213	Mosaico de cultivos anuales con cultivos permanentes en secano		≥ 3	39	20	12	8
24213	Mosaico de cultivos anuales con cultivos permanentes en secano		< 3	66	29	15	10
24221	Mosaico de cultivos anuales con prados o praderas en regadío	R	≥ 3	37	20	12	9

Tabla 10. (Continúa)

Código	Uso de suelo	Práctica de cultivo	Pendiente (%)	Grupo de suelo			
				A	B	C	D
24221	Mosaico de cultivos anuales con prados o praderas en regadío	N	≥ 3	42	23	14	11
24221	Mosaico de cultivos anuales con prados o praderas en regadío	R/N	< 3	47	25	16	13
24222	Mosaico de cultivos permanentes en regadío		≥ 3	80	34	19	14
24222	Mosaico de cultivos permanentes en regadío		< 3	95	42	22	15
24223	Mosaico de cultivos anuales con cultivos permanentes en regadío		≥ 3	75	33	18	14
24223	Mosaico de cultivos anuales con cultivos permanentes en regadío		< 3	106	48	22	15
24230	Mosaico de cultivos mixtos en seco y regadío	R	≥ 3	31	17	10	8
24230	Mosaico de cultivos mixtos en seco y regadío	N	≥ 3	34	20	13	10
24230	Mosaico de cultivos mixtos en seco y regadío	R/N	< 3	37	22	14	11
24310	Mosaico de cultivos agrícolas en seco con espacios significativos de vegetación natural y seminatural	R	≥ 3	26	15	9	6
24310	Mosaico de cultivos agrícolas en seco con espacios significativos de vegetación natural y seminatural	N	≥ 3	28	17	11	8
24310	Mosaico de cultivos agrícolas en seco con espacios significativos de vegetación natural y seminatural	R/N	< 3	30	19	13	10
24320	Mosaico de cultivos agrícolas en regadío con espacios significativos de vegetación natural y seminatural	R	≥ 3	37	20	12	9

Tabla 10. (Continúa)

Código	Uso de suelo	Práctica de cultivo	Pendiente (%)	Grupo de suelo			
				A	B	C	D
24320	Mosaico de cultivos agrícolas en regadío con espacios significativos de vegetación natural y seminatural	N	≥ 3	42	23	14	11
24320	Mosaico de cultivos agrícolas en regadío con espacios significativos de vegetación natural y seminatural	R/N	< 3	47	25	16	13
24330	Mosaico de prados o praderas con espacios significativos de vegetación natural y seminatural		≥ 3	70	33	18	13
24330	Mosaico de prados o praderas con espacios significativos de vegetación natural y seminatural		< 3	120	55	22	14
24400	Sistemas agroforestales		≥ 3	53	23	14	9
24400	Sistemas agroforestales		< 3	80	35	17	10
24410	Pastizales, prados o praderas con arbolado adhesionado		≥ 3	53	23	14	9
24410	Pastizales, prados o praderas con arbolado adhesionado		< 3	80	35	17	10
24420	Cultivos agrícolas con arbolado adhesionado		≥ 3	53	23	14	9
24420	Cultivos agrícolas con arbolado adhesionado		< 3	80	35	17	10
31100	Fronosas			90	47	31	23
31110	Perennifolias			90	47	31	23
31120	Caducifolias y marcescentes			90	47	31	23
31130	Otras frondosas de plantación		≥ 3	79	34	19	14
31130	Otras frondosas de plantación		< 3	94	42	22	15
31140	Mezclas de frondosas			90	47	31	23
31150	Bosques de ribera			76	34	22	16
31160	Laurisilva macaronésica			90	47	31	23

Tabla 10. (Continúa)

Código	Uso de suelo	Práctica de cultivo	Pendiente (%)	Grupo de suelo			
				A	B	C	D
31200	Bosques de coníferas			90	47	31	23
31210	Bosques de coníferas de hojas aciculares			90	47	31	23
31220	Bosques de coníferas de hojas tipo cupresáceo			90	47	31	23
31300	Bosque mixto			90	47	31	23
32100	Pastizales naturales		≥ 3	53	23	14	9
32100	Pastizales naturales		< 3	80	35	17	10
32100	Prados alpinos		≥ 3	70	33	18	13
32100	Prados alpinos		< 3	120	55	22	14
32100	Formaciones herbáceas de llanuras aluviales inundadas y llanuras costeras, tierras bajas		≥ 3	70	33	18	13
32100	Formaciones herbáceas de llanuras aluviales inundadas y llanuras costeras, tierras bajas		< 3	120	55	22	14
32110	Pastizales supraforestales		≥ 3	70	33	18	13
32110	Pastizales supraforestales		< 3	120	55	22	14
32111	Pastizales supraforestales templado-oceánicos, pirenaicos y orocantábricos		≥ 3	70	33	18	13
32111	Pastizales supraforestales templado-oceánicos, pirenaicos y orocantábricos		< 3	120	55	22	14
32112	Pastizales supraforestales mediterráneos		≥ 3	24	14	8	6
32112	Pastizales supraforestales mediterráneos		< 3	57	25	12	7
32121	Otros pastizales templado oceánicos		≥ 3	53	23	14	9
32121	Otros pastizales templado oceánicos		< 3	79	35	17	10
32122	Otros pastizales mediterráneos		≥ 3	24	14	8	6
32122	Otros pastizales mediterráneos		< 3	57	25	12	7
32200	Landas y matorrales mesófilas			76	34	22	16

Tabla 10. (Continúa)

Código	Uso de suelo	Práctica de cultivo	Pendiente (%)	Grupo de suelo			
				A	B	C	D
32210	Landas y matorrales en climas húmedos. Vegetación mesófila			76	34	22	16
32220	Fayal-brezal macaronésico			60	24	14	10
32300	Vegetación esclerófila			60	24	14	10
32311	Grandes formaciones de matorral denso o medianamente denso			75	34	22	16
32312	Matorrales subarbusivos o arbustivos muy poco densos			60	24	14	10
32320	Matorrales xerófilos macaronésicos			40	17	8	5
32400	Matorral boscoso de transición			75	34	22	16
32400	Claras de bosques			40	17	8	5
32400	Zonas empantanadas fijas o en transición			60	24	14	10
32410	Matorral boscoso de frondosas			75	34	22	16
32420	Matorral boscoso de coníferas			75	34	22	16
32430	Matorral boscoso de bosque mixto			75	34	22	16
33110	Playas y dunas			152	152	152	152
33120	Ramblas con poca o sin vegetación			15	8	6	4
33200	Roquedo			2	2	2	2
33210	Rocas desnudas con fuerte pendiente			2	2	2	2
33220	Afloramientos rocosos y canchales		≥ 3	2	2	2	2
33220	Afloramientos rocosos y canchales		< 3	4	4	4	4
33230	Coladas lávicas cuaternarias		≥ 3	3	3	3	3
33230	Coladas lávicas cuaternarias		< 3	5	5	5	5
33300	Espacios con vegetación escasa		≥ 3	24	14	8	6
33300	Espacios con vegetación escasa		< 3	58	25	12	7

Tabla 10. (Continúa)

Código	Uso de suelo	Práctica de cultivo	Pendiente (%)	Grupo de suelo			
				A	B	C	D
33310	Xeroestepa subdesértica		≥ 3	24	14	8	6
33310	Xeroestepa subdesértica		< 3	58	25	12	7
33320	Cárcavas y/o zonas en proceso de erosión			15	8	6	4
33330	Espacios orófilos altitudinales con vegetación escasa		≥ 3	24	14	8	6
33330	Espacios orófilos altitudinales con vegetación escasa		< 3	58	25	12	7
33400	Zonas quemadas			15	8	6	4
33500	Glaciares y nieves permanentes			0	0	0	0
41100	Humedales y zonas pantanosas			2	2	2	2
41200	Turberas y prados turbosos			248	99	25	16
42100	Marismas			2	2	2	2
42200	Salinas			5	5	5	5
42300	Zonas llanas intermareales			0	0	0	0
51100	Cursos de agua			0	0	0	0
51110	Ríos y cauces naturales			0	0	0	0
51120	Canales artificiales			0	0	0	0
51210	Lagos y lagunas			0	0	0	0
51220	Embalses			0	0	0	0
52100	Lagunas costeras			0	0	0	0
52200	Estuarios			0	0	0	0
52300	Mares y océanos			0	0	0	0

7.2 Anexo 2

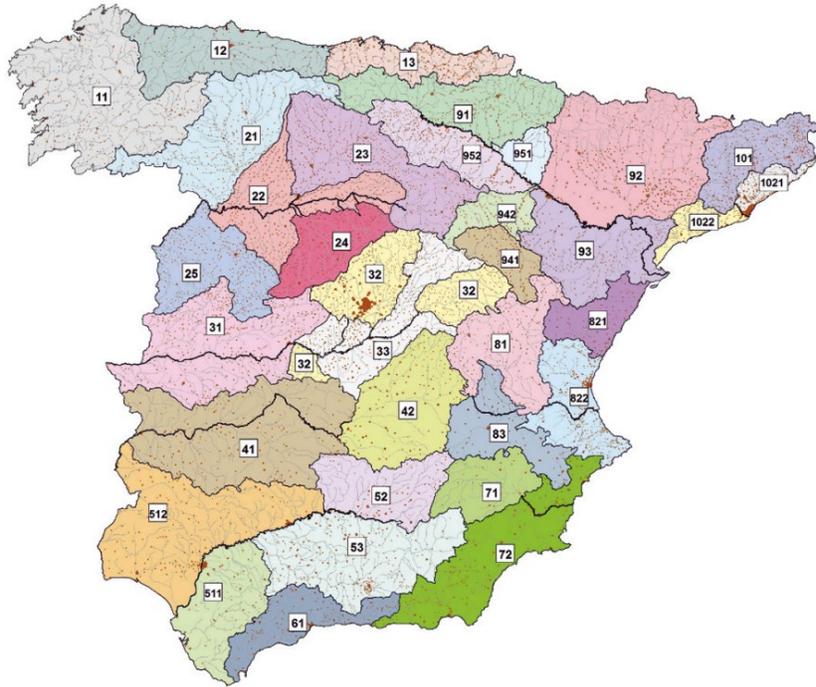


Figura 35. Regiones consideradas para la caracterización del coeficiente corrector. Extracción de la Norma 5.2IC (ORDEN, 2016).

Tabla 11. Coeficiente corrector del umbral de escorrentia.

REGIÓN	VALOR MEDIO, (B_M)	DESVIACIÓN RESPECTO AL VALOR MEDIO PARA EL INTERVALO DE CONFIANZA			PERÍODO DE RETORNO T (AÑOS), (F_T)				
		50%	67%	90%	2	5	25	100	500
		$(\Delta 50)$	$(\Delta 67)$	$(\Delta 90)$					
11	0,90	0,20	0,30	0,50	0,80	0,90	1,13	1,34	1,59
12	0,95	0,20	0,25	0,45	0,75	0,90	1,14	1,33	1,56
13	0,60	0,15	0,25	0,40	0,74	0,90	1,15	1,34	1,55
21	1,20	0,20	0,35	0,55	0,74	0,88	1,18	1,47	1,90
22	1,50	0,15	0,20	0,35	0,74	0,90	1,12	1,27	1,37
23	0,70	0,20	0,35	0,55	0,77	0,89	1,15	1,44	1,82
24	1,10	0,15	0,20	0,35	0,76	0,90	1,14	1,36	1,63
25	0,60	0,15	0,20	0,35	0,82	0,92	1,12	1,29	1,48
31	0,90	0,20	0,30	0,50	0,87	0,93	1,10	1,26	1,45
32	1,00	0,20	0,30	0,50	0,82	0,91	1,12	1,31	1,54
33	2,15	0,25	0,40	0,65	0,70	0,88	1,15	1,38	1,62
41	1,20	0,20	0,25	0,45	0,91	0,96	1,00	1,00	1,00
42	2,25	0,20	0,35	0,55	0,67	0,86	1,18	1,46	1,78
511	2,15	0,10	0,15	0,20	0,81	0,91	1,12	1,30	1,50
512	0,70	0,20	0,30	0,50	1,00	1,00	1,00	1,00	1,00
52	0,95	0,20	0,25	0,45	0,89	0,94	1,09	1,22	1,36
53	2,10	0,25	0,35	0,60	0,68	0,87	1,16	1,38	1,56
61	2,00	0,25	0,35	0,60	0,77	0,91	1,10	1,18	1,17
71	1,20	0,15	0,20	0,35	0,82	0,94	1,00	1,00	1,00
72	2,10	0,30	0,45	0,70	0,67	0,86	1,00	-	-
81	1,30	0,25	0,35	0,60	0,76	0,90	1,14	1,34	1,58
821	1,30	0,35	0,50	0,85	0,82	0,91	1,07	-	-
822	2,40	0,25	0,35	0,60	0,70	0,86	1,16	-	-
83	2,30	0,15	0,25	0,40	0,63	0,85	1,21	1,51	1,85
91	0,85	0,15	0,25	0,40	0,72	0,88	1,19	1,52	1,95

Tabla 11. (Continúa)

REGIÓN	VALOR MEDIO, (B_M)	DESVIACIÓN RESPECTO AL VALOR MEDIO PARA EL INTERVALO DE CONFIANZA			PERÍODO DE RETORNO T (AÑOS), (F_T)				
		50%	67%	90%	2	5	25	100	500
		($\Delta 50$)	($\Delta 67$)	($\Delta 90$)					
92	1,45	0,30	0,40	0,70	0,82	0,94	1,00	1,00	1,00
93	1,70	0,20	0,25	0,45	0,77	0,92	1,00	1,00	1,00
941	1,80	0,15	0,20	0,35	0,68	0,87	1,17	1,39	1,64
942	1,20	0,15	0,25	0,40	0,77	0,91	1,11	1,24	1,32
951	1,70	0,30	0,40	0,70	0,72	0,88	1,17	1,43	1,78
952	0,85	0,15	0,25	0,40	0,77	0,90	1,13	1,32	1,54
101	1,75	0,30	0,40	0,70	0,76	0,90	1,12	1,27	1,39
1021	1,45	0,15	0,25	0,40	0,79	0,93	1,00	1,00	1,00
1022	2,05	0,15	0,25	0,40	0,79	0,93	1,00	1,00	1,00

En Ceuta y Melilla se adoptarán valores similares a los de la región 61.

Pueden obtenerse valores intermedios por interpolación adecuada a partir de los datos de esta tabla

En todos los casos $F_{10}=1,00$

7.3 Anexo 3

Figuras de los patrones espaciales de las variables derivadas de los conjuntos de datos correspondientes a los años 2006 y 2012.

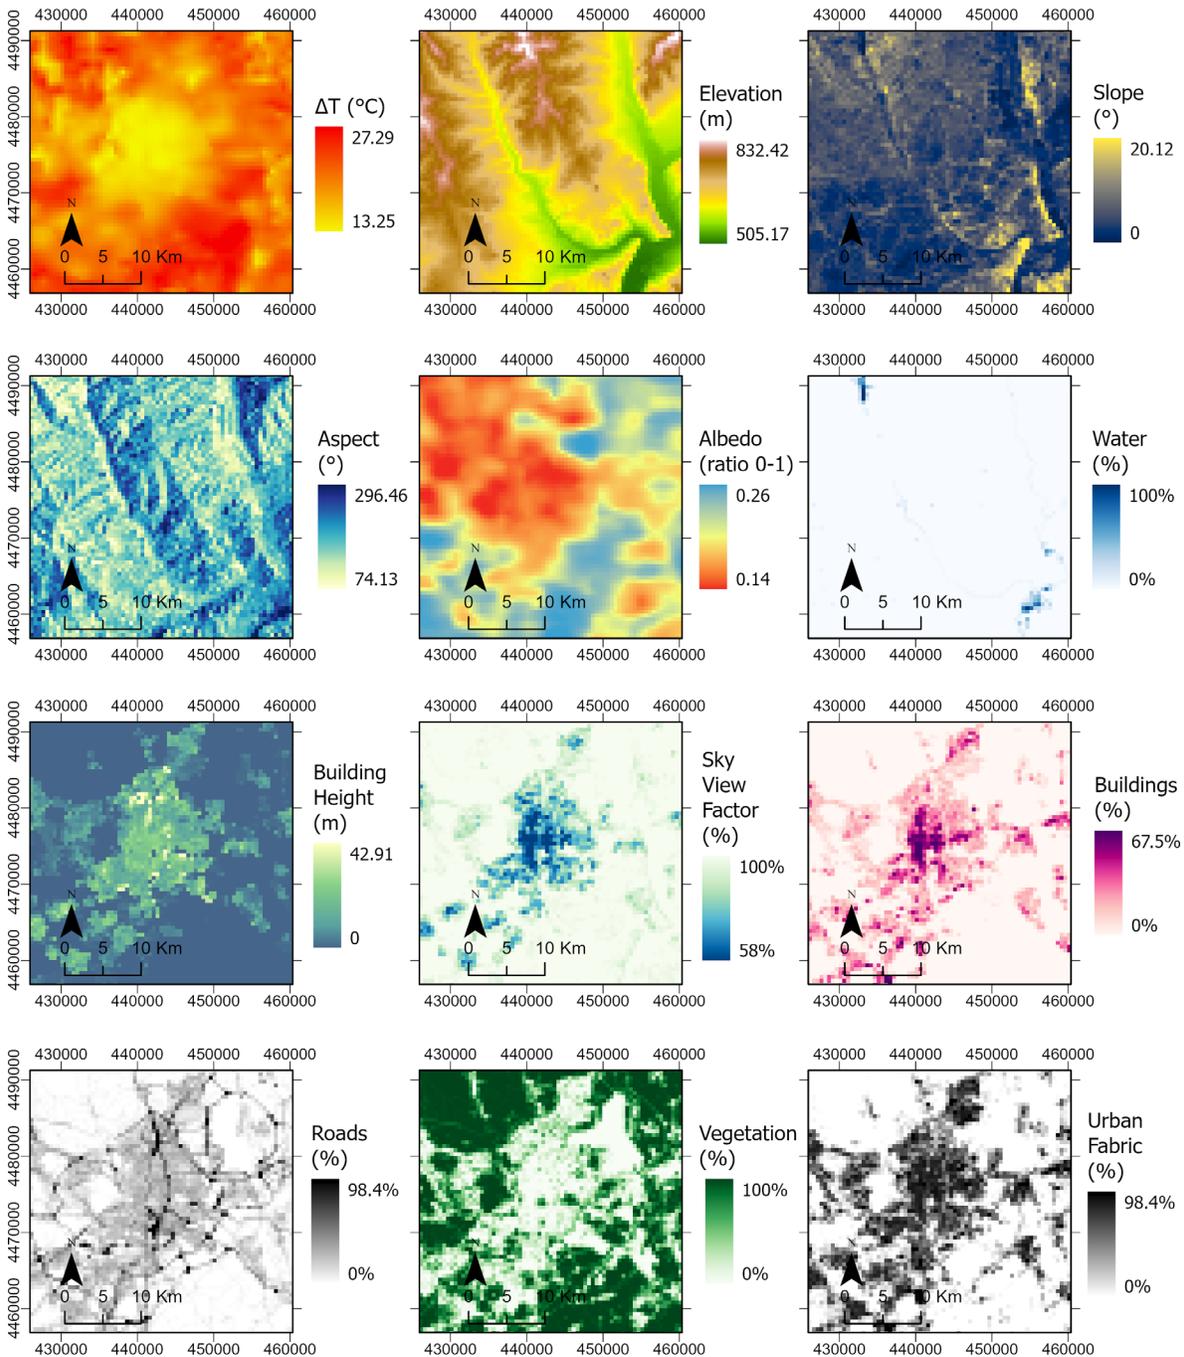


Figura 36. Distribución espacial de las variables que intervienen en la modelización del efecto isla de calor urbano (UHI) en toda la zona de estudio, expresada en valores medios o porcentajes del área ocupada por píxel. (2006)

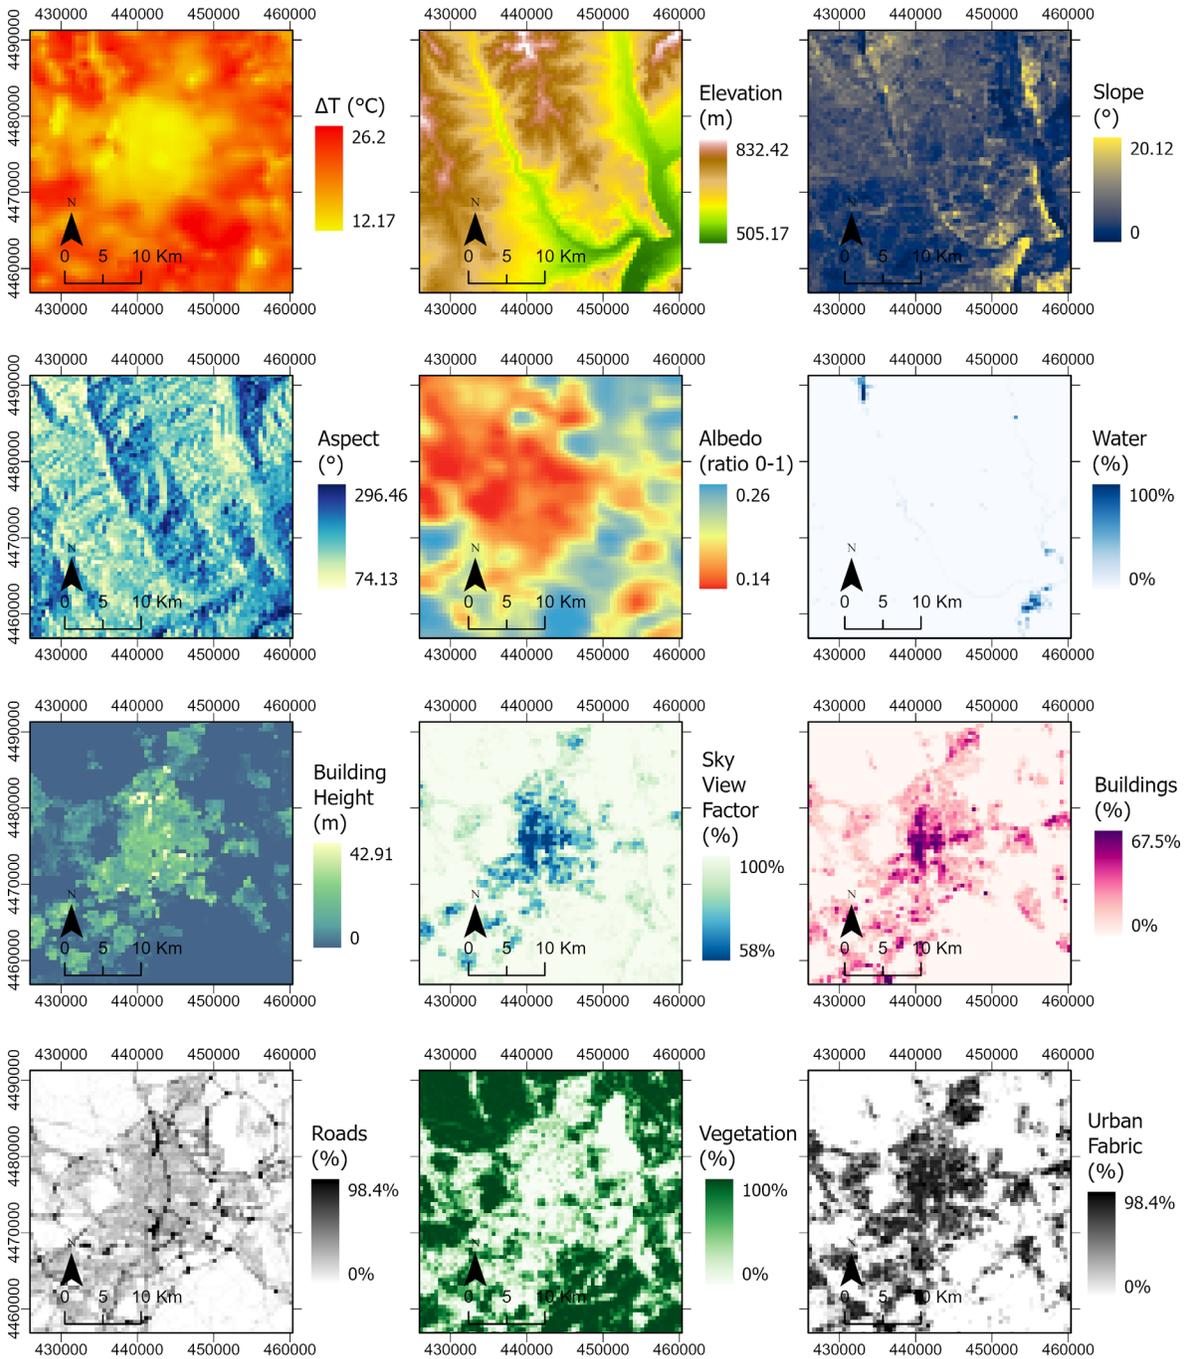


Figura 37. Distribución espacial de las variables que intervienen en la modelización del efecto Isla de Calor Urbano (UHI) en toda la zona de estudio, expresada en valores medios o porcentajes del área ocupada por píxel. (2012)