



Universidad
Zaragoza

Trabajo Fin de Grado

Identificación de islas de calor urbanas mediante
técnicas de aprendizaje automático

Urban heat island identification using machine
learning techniques

Autor

Andrés Yubero Segura

Director

Mario Esteban Suaza Medina

Ponente

Javier Lacasta Miguel

Titulación

Ingeniería Informática

ESCUELA DE INGENIERÍA Y ARQUITECTURA

2025

AGRADECIMIENTOS

Me gustaría agradecer a Mario Esteban Suaza, a Francisco Javier Zarazaga y a Javier Lacasta Miguel por su ayuda y orientación a lo largo de todo el proyecto. Sin ellos, este trabajo no habría sido posible.

Así mismo, quiero dar las gracias a mi hermana y mis padres por su apoyo y confianza durante todos estos años, y a mis compañeros y amigos de carrera por todas las experiencias que hemos vivido juntos, que sin duda han enriquecido tanto nuestra formación académica como personal.

Identificación de islas de calor urbanas mediante técnicas de aprendizaje automático

RESUMEN

El efecto de isla de calor urbana es un fenómeno caracterizado por un aumento considerable de temperatura en las ciudades con respecto a su entorno rural circundante. Su identificación es importante porque afecta a la salud humana y sirve de ayuda en la planificación urbana. Sin embargo, los métodos tradicionales para detectarla requieren recursos considerables.

Este trabajo propone dos métodos más eficientes basados en datos abiertos, como imágenes satelitales y estaciones meteorológicas ciudadanas, que además funcionan de manera remota. El primero utiliza kriging universal para interpolar temperaturas a partir de estaciones ciudadanas, incorporando variables auxiliares para mejorar la precisión. El segundo emplea una red neuronal convolucional que genera mapas de islas de calor usando únicamente variables espaciales, requiriendo entrenamiento previo con estudios existentes o los resultados del primer método.

La interpolación por kriging fue validada frente al estudio del Ayuntamiento de Zaragoza, con un error medio de 0,33 °C y una similaridad estructural de 0,72. Posteriormente, la red neuronal entrenada con esta interpolación logró un error medio de 0,12 °C en Sevilla y 0,24 °C en Valencia.

Ambos modelos se aplicaron a otras ciudades europeas, con buenos resultados generales, salvo en Oviedo y Graz, lo que evidencia los desafíos de extrapolación a urbes con una morfología distinta y la dependencia de la calidad y distribución de las estaciones meteorológicas ciudadanas.

Índice

1. Introducción y objetivos	1
1.1. Contexto y motivación	1
1.2. Objetivos	2
1.3. Metodología y herramientas	2
1.4. Descripción del resto de la memoria	3
2. Trabajo realizado	5
2.1. Modelo 1: Interpolación espacial empleando datos de estaciones meteorológicas	5
2.1.1. Réplica del estudio de Zaragoza	5
2.1.2. Encontrando nuevas variables explicativas	7
2.1.3. Reproducibilidad de la interpolación	8
2.2. Modelo 2: Predicción mediante una red neuronal convolucional sin datos de estaciones meteorológicas	16
2.2.1. Arquitectura de la red neuronal propuesta	16
2.2.2. Preparación del dataset	17
2.2.3. Entrenamiento	18
2.2.4. Predicción y fusión de baldosas	19
2.3. Validación de ambos modelos	20
3. Conclusiones	27
4. Bibliografía	29
Lista de Figuras	33
Lista de Tablas	37
Anexos	38

A. Fundamentos previos	41
A.1. Áreas y período de estudio	41
A.2. Fuentes de datos	44
A.3. Estaciones de referencia	49
A.4. Obtención de variables explicativas	52
A.5. Kriging universal	54
A.6. Métricas de evaluación	57
B. Tabla de correlaciones	59
C. Detección de islas de calor exclusivamente con imágenes satelitales	61
C.1. Sentinel-2	61
C.2. ¿Qué banda emplear para clasificar la isla de calor urbano?	62
C.3. Exclusión de edificios	66
C.4. Correlación entre temperatura y SWIR2	69
D. Sistema para identificar islas de calor urbanas	73
D.1. Primeros pasos	73
D.2. Requisitos previos	73
D.3. Flujo de datos	74
D.4. Ejecución	74
D.5. Notas finales	79
E. Gestión del proyecto	81

Capítulo 1

Introducción y objetivos

1.1. Contexto y motivación

El efecto de isla de calor urbano es un fenómeno caracterizado por el incremento de la temperatura en las ciudades en comparación con su entorno rural circundante. Entre sus causas más relevantes se encuentran, según Yamamoto [1]:

1. El incremento en la liberación de calor antropogénico, es decir, el calor generado por el consumo energético en las zonas urbanas.
2. Las modificaciones en la cobertura del suelo. Habitualmente, las ciudades se construyen con materiales como el hormigón o el asfalto, que tienden a almacenar calor. Además, la presencia reducida de áreas verdes limita la capacidad de evapotranspiración del entorno.
3. La configuración urbana. Las zonas con alta densidad edificatoria pueden favorecer la acumulación y el estancamiento del calor.
4. Otros factores, como la contaminación ambiental, que puede intensificar el efecto invernadero.

El estudio de las islas de calor es necesario porque permite priorizar intervenciones en aquellas zonas donde su impacto sea más perjudicial para la población. Tradicionalmente, su análisis se ha llevado a cabo mediante transectos urbanos, que consisten en recorridos por la ciudad en los que se mide de forma continua la temperatura, como en el estudio realizado en Zaragoza por Cuadrat et al. [2]. Otra metodología común es el uso de redes de estaciones meteorológicas distribuidas por el entorno urbano, como en el estudio de Barrao et al. [3], también desarrollado en Zaragoza. No obstante, estos métodos requieren considerables recursos económicos y humanos.

Ante esta limitación, la motivación de este trabajo es desarrollar una alternativa más eficiente a las metodologías convencionales, que permita detectar y cuantificar las islas de calor de forma remota, utilizando datos abiertos como imágenes satelitales y registros de temperatura procedentes de estaciones meteorológicas ciudadanas.

1.2. Objetivos

El propósito de este trabajo es desarrollar un sistema que detecte islas de calor sin necesidad de llevar a cabo estudios de campo, y que sea lo más generalizable posible a ciudades de todo el mundo. Los objetivos a cumplir para obtener tal sistema son los siguientes:

1. Tomar control sobre el proceso seguido por otros estudios para poder entenderlo y ser capaz de reproducirlo. Esta reproducibilidad deberá poderse llevar a cabo en escenarios con datos meteorológicos oficiales y/o haciendo uso de datos procedentes de estaciones ciudadanas.
2. Disponer de un modelo de inteligencia artificial capaz de predecir un mapa de islas de calor cuando no haya disponibilidad de datos de estaciones meteorológicas.
3. Evaluar la capacidad de los dos enfoques expuestos en los apartados anteriores para generalizar a otras ciudades. Esto implica, además, identificar y analizar los factores que puedan influir en dicha generalización.
4. Documentar todo el proceso, no solo para cumplir con los requisitos del Trabajo de Fin de Grado, sino también con el propósito de que cualquier persona interesada pueda replicar el estudio de islas de calor en cualquier ciudad que se desee.

1.3. Metodología y herramientas

El trabajo se ha realizado de forma iterativa, desarrollando cada componente y sometiéndolo a pruebas antes de avanzar a las siguientes etapas.

Las herramientas empleadas son las siguientes:

- Sistemas de información geográfica:
 - QGIS: Visualización y procesamiento de datos geoespaciales.
 - SAGA GIS: Análisis de iluminación y visibilidad sobre el terreno.
- Python. Bibliotecas empleadas:

- Rasterio¹: Para procesar rásteres geoespaciales.
 - Matplotlib: Para la creación de visualizaciones.
 - Pandas: Para la manipulación y el análisis de datos.
 - PyTorch: Para la construcción y entrenamiento de la red neuronal convolucional.
 - Boto3²: Para la descarga de imágenes satelitales de Sentinel 2 desde Amazon S3.
- R. Bibliotecas empleadas:
- Geostat³: Para la interpolación espacial mediante kriging.
 - Raster: Para la manipulación de los rásteres geoespaciales.
 - Caret: Para clasificación y entrenamiento de regresiones.
 - Readr: Para lectura de archivos de texto.
- Docker: Contenedorización de la aplicación y su ejecución en máquinas externas.
- Git y Github: Gestión de versiones y alojamiento del código.

1.4. Descripción del resto de la memoria

Tras esta introducción, el capítulo 2 presenta el núcleo del trabajo realizado, centrado en los dos enfoques empleados para identificar islas de calor y su validación cruzada. Para una mejor comprensión, se recomienda leer previamente el anexo A, donde se detallan las áreas y el período de estudio, las fuentes de datos utilizadas, los procesos de limpieza y transformación necesarios para obtener las variables requeridas por los modelos, así como las métricas empleadas para su evaluación. El capítulo 3 expone las conclusiones derivadas del estudio, mientras que el capítulo 4 recoge las fuentes bibliográficas consultadas para su desarrollo.

Por su parte, el anexo B contiene una tabla de correlaciones empleada en el capítulo 2, mientras que el anexo C muestra los primeros intentos realizados para detectar islas de calor exclusivamente a partir de imágenes satelitales, sin apoyo de estaciones meteorológicas locales. Luego el anexo D describe los pasos a seguir para replicar un estudio de islas de calor urbanas en cualquier ciudad, utilizando la base de código desarrollada en este trabajo. Finalmente, el anexo E muestra la gestión del proyecto.

¹<https://rasterio.readthedocs.io/en/stable/index.html>

²<https://boto3.amazonaws.com/v1/documentation/api/latest/index.html>

³<https://cran.r-project.org/package=geostats>

Capítulo 2

Trabajo realizado

Tras probar en una primera iteración, recogida en el anexo C, en la que se intentó generar mapas de islas de calor exclusivamente a partir de imágenes satelitales, se concluyó que era necesario incorporar datos de temperatura obtenidos in situ. Por ello, el primer modelo que se presenta utiliza directamente estos datos para interpolar los valores de temperatura en toda el área de estudio mediante kriging universal, un método que ha demostrado un buen desempeño en la modelización de temperaturas urbanas, según estudios como el de Zhang et al. [4].

2.1. Modelo 1: Interpolación espacial empleando datos de estaciones meteorológicas

2.1.1. Réplica del estudio de Zaragoza

En primer lugar, se empezó por obtener un mapa de la isla de calor similar al presentado en la web del Ayuntamiento de Zaragoza¹, por lo que se optó por replicar su estudio siguiendo la misma metodología [5], empleando kriging universal.

A partir de los datos de temperatura del ayuntamiento se pueden calcular las diferencias de temperatura entre la ciudad y sus alrededores para poder caracterizar la isla de calor urbano. Para ello, se tomó como referencia la estación de la ciudad deportiva del Real Zaragoza, que es la misma empleada en el estudio del ayuntamiento, y se procedió a calcular la diferencia de temperatura de cada estación con la de referencia. La distribución de estas diferencias para cada estación se muestra en la figura 2.1. Posteriormente, se calculó la media de valores para cada estación.

Además de las diferencias de temperatura, de acuerdo al documento publicado en la web del ayuntamiento, se emplearon otras tres variables auxiliares espaciales: Sky View Factor (SVF), Imperviousness Density (IMD) y Normalized Difference Vegetation

¹<https://www.zaragoza.es/sede/portal/idezar/mapa/islas-de-calor/>

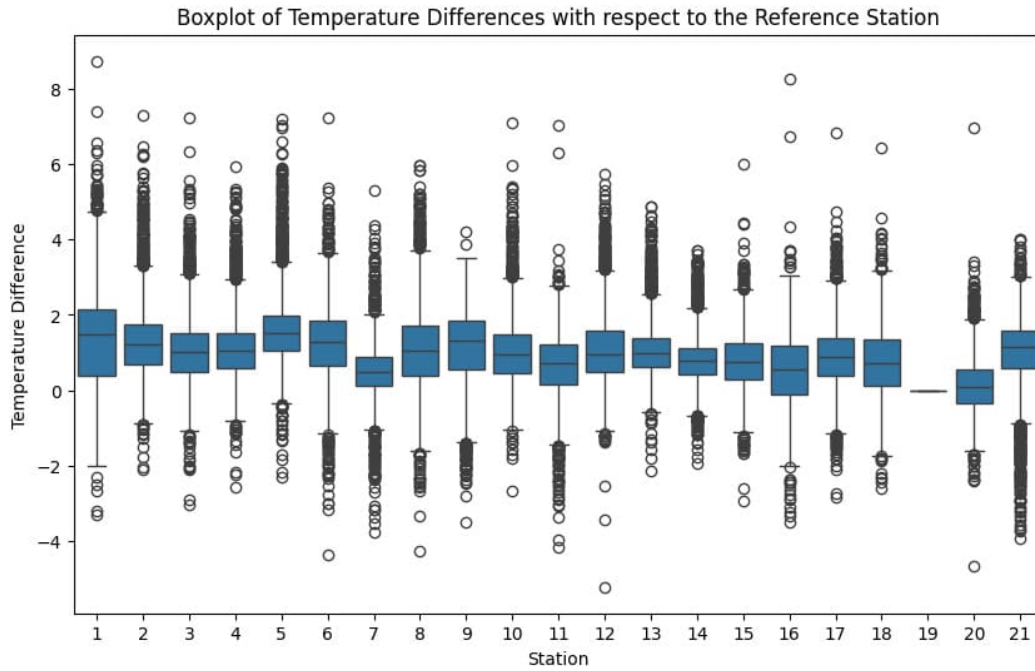



Figura 2.1: Diferencias de temperatura con respecto a la estación de referencia.

Index (NDVI). La obtención y el procesamiento de estas variables se llevó a cabo según se detalla en el anexo A, dedicado a los fundamentos previos.

Kriging universal

Inicialmente, se intentó realizar la interpolación espacial mediante kriging universal utilizando la librería *PyKrig* de Python. Sin embargo, el ecosistema de librerías de geoestadística en Python aún presenta limitaciones en comparación con otros lenguajes como R, específicamente no otorga control alguno sobre el cálculo del variograma, un aspecto clave para la correcta aplicación de kriging. Por este motivo, esta opción fue descartada. En su lugar, se repitió el experimento utilizando la librería *geostat* de R, incorporando la información espacial de SVF, IMD y NDVI. Como métrica de error se utilizó RMSE, ya que es la métrica empleada para el estudio de Zaragoza [5], en conjunto con validación cruzada dejando una muestra fuera en cada iteración o *Leave One Out Cross Validation (LOOCV)*. El RMSE obtenido fue de 0,33 °C, y el ráster resultante se muestra en la figura 2.2.b y se puede comparar con el ráster objetivo de la figura 2.2.a.

Pese a que la tendencia de la isla de calor en el entramado urbano es caracterizada correctamente, en aquellas zonas de las afueras de la ciudad donde no hay estaciones, la incertidumbre de la predicción aumenta y por tanto existen diferencias notables en las zonas de huerta de la ribera del Ebro y en las zonas esteparias del distrito sur y Juslibol.



(a) Ráster del ayuntamiento de Zaragoza (objetivo). (b) Ráster predicho con SVF, IMD y NDVI.

Figura 2.2: Las zonas más calientes están denotadas con colores más próximos al amarillo, mientras que las más frías se identifican con colores más oscuros.

También, se probó a incluir la banda SWIR2 del anexo C en el modelo, pero esto empeoró el error de un 0,339 °C de RMSE con SVF, IMD y NDVI a un error de 0.432 °C, por lo que finalmente se descartó incluir esta variable.

2.1.2. Encontrando nuevas variables explicativas

En el apartado anterior, se llevó a cabo una interpolación utilizando SVF, IMD y NDVI. No obstante, se descubrió que las variables empleadas en el estudio publicado en la web del ayuntamiento eran distintas a las de la metodología inicial [5] y se encuentran documentadas en la tesis de Samuel Barrao [6]. Estas variables, especificadas en el anexo A sobre fundamentos previos, son: SVF, MDT (Modelo Digital de Terreno), GLI (Green Leaf Index), NBAI (Normalized Built-up Area Index), NDTI (Normalize Difference Turbidity Index), y LST (Land Surface Temperature).

Una vez obtenidos y normalizados todos los rásteres de cada una de las variables, se procedió a repetir el experimento en R. La interpolación resultante se muestra en la figura 2.3 y se puede apreciar como las zonas con mayor incertidumbre, como las estepas del distrito sur, se parecen más que en el resultado de la iteración 2.1.1. Aún así, persisten diferencias con respecto al estudio del ayuntamiento [6]. Por ejemplo, mientras que el estudio del ayuntamiento emplea cokriging, este análisis utiliza kriging universal. Además, la variable LST en este estudio se ha obtenido de Landsat-9 en lugar de Landsat-8, y las variables GLI, NDTI y NBAI provienen de Sentinel-2 en vez de Landsat-8.

Atendiendo a métricas numéricas, el error cuadrático medio es de 0,12426 (°C)², lo

cual en grados centígrados equivaldría a un error medio de 0,3525 °C. Por otra parte, el SSIM resultante de 0,7143 denota que hay similitud entre las imágenes, en especial en las zonas urbanas, que son las que nos interesan, alcanzando valores de SSIM de 0,8.




Figura 2.3: Interpolación de isla de calor urbano sobre Zaragoza con las temperaturas de las estaciones del ayuntamiento de Zaragoza. Las zonas más calientes están denotadas con colores próximos al amarillo, mientras que las más frías se identifican con colores más oscuros.




Figura 2.4: SSIM entre los rásters de la figura 2.3.

2.1.3. Reproducibilidad de la interpolación

Uno de los objetivos planteados es predecir rásters de isla de calor urbano en otras ciudades. Como primer paso, se pensó en generar un ráster de isla de calor en otra

ciudad utilizando kriging universal y comparar el resultado con estudios previos o con predicciones obtenidas mediante otros modelos, como una red neuronal convolucional.

Interpolación con estaciones del ayuntamiento de Madrid

Dado que de la primera iteración, detallada en el anexo C, ya se disponía de datos de Madrid, se emplearon los datos de temperatura de las estaciones del ayuntamiento de Madrid (numeración disponible en [este enlace](#)) y se descargaron las tres variables SVF, IMD y NDVI. Con estos datos se calcularon las diferencias de temperatura respecto a la estación 106, ubicada en el Club de Campo Villa de Madrid, entre el río Manzanares y la Casa de Campo.

La figura 2.5 muestra la interpolación resultante. Sin embargo, esta no parece representar con precisión el fenómeno de la isla de calor urbano. En la imagen, las áreas más urbanizadas aparecen con temperaturas inferiores a las de la estación de referencia (colores oscuros), mientras que las zonas con cubierta vegetal y cuerpos de agua se muestran en tonos claros, lo que indicaría que su temperatura media es superior a la de la estación de referencia. Este patrón es contrario a lo esperado, lo que sugiere posibles errores en los datos.




Figura 2.5: Interpolación de isla de calor urbano sobre Madrid, tomando como referencia la estación 106.

Se realizaron pruebas tomando otras estaciones como referencia, como la 58, ubicada en El Pardo y rodeada de bosque, pero los resultados fueron similares. Dado que las estaciones 112 y 113 compartían las mismas coordenadas, al igual que las estaciones 114 y 115, se sospechó que podrían estar mal georreferenciadas. Para verificarlo, se analizaron otras estaciones, incluso revisando su ubicación en *Google Street View*, y se determinó que en algunos casos las coordenadas no eran fiables. Por ejemplo, según la información del *dataset*, la estación 113 debería estar en la Avenida de la Albufera,

pero sus coordenadas la ubicaban en la calle de Martínez de la Riva. Al inspeccionar el entorno en esa ubicación, no se encontró ninguna estación visible, lo que indica que cualquier valor obtenido para una variable espacial en esa posición sería incorrecto.

Empleo de estaciones ciudadanas

Debido a la baja calidad de los datos disponibles en Madrid y a la necesidad de obtener mediciones de temperatura en cualquier ciudad sin depender de una red de sensores previamente instalada, se optó por utilizar estaciones ciudadanas, conocidas en inglés como *Citizen Weather Stations* (CWS). Se seleccionaron específicamente las estaciones Netatmo porque están muy extendidas y han sido empleadas con éxito en otros estudios, como el realizado por Brousse et al. [7] para analizar la advección de calor urbano en Londres.

El procedimiento para la obtención y procesamiento de los datos hasta llegar al cálculo de las diferencias de temperatura necesarias para aplicar el método de kriging se detalla en el anexo A, dentro de la sección dedicada a las fuentes de datos.

El objetivo de los modelos generados es doble: por un lado, minimizar el error cuadrático medio (MSE) hasta valores cercanos a cero; y por otro, maximizar la métrica de similitud estructural (SSIM), ya que valores cercanos a 1 indican una mayor similitud visual entre las imágenes comparadas.

Estaciones	SVF	GLI	NBAI	NDTI	MDT	LST	MSE	SSIM
Ayto.	✓	✓	✓	✓	✓	✓	0.1242	0.7342
Netatmo	✓	✓					0.1129	0.7262
		✓				✓	0.1126	0.6358
		✓				✓	0.1170	0.6262
		✓				✓	0.1202	0.6179
			✓	✓	✓		0.1118	0.6140
		✓					0.1238	0.6118
		✓	✓		✓		0.1053	0.6115
		✓	✓	✓	✓	✓	0.2268	0.2150

Tabla 2.1: Resultados de comparar cada modelo desarrollado con el del portal del ayuntamiento de Zaragoza ordenados por SSIM. La última fila muestra el resultado de considerar las 6 variables.

La tabla 2.1 muestra los resultados de la comparación entre el estudio realizado por el Ayuntamiento de Zaragoza y el ráster generado en la sección 2.1.2, elaborado a partir de los valores de temperatura registrados por las estaciones municipales. Además, se presentan los resultados de la comparación entre el estudio del Ayuntamiento de Zaragoza y las interpolaciones obtenidas utilizando datos de estaciones Netatmo,

considerando diversas combinaciones de variables espaciales. Aunque existen 63 combinaciones posibles, en la tabla se muestran únicamente aquellas que han arrojado los mejores resultados, es decir, las que presentan menores errores cuadráticos medios y mayores índices de similitud estructural.

El primer modelo que se probó es aquel que emplea todas las variables espaciales propuestas por Samuel Barrao en su tesis [6] (SVF, MDT, GLI, NBAI, NDTI y LST) para complementar los datos de temperatura. No obstante, el MSE obtenido de 0.2268 $(^{\circ}\text{C})^2$ se considera demasiado alto en comparación al que se ha obtenido con otras combinaciones de variables. Otro inconveniente de este modelo reside en que los cuerpos de agua aparecen como zonas con mayor efecto de isla de calor, como se puede ver en la figura 2.6, cuando en realidad no debería ser así, ya que los cuerpos de agua actúan como moderadores térmicos. Además el índice de similaridad de 0.21 está más próximo a 0 que el resto de modelos presentados en la tabla, lo que indica que hay disimilaridad entre el resultado obtenido y el ráster objetivo. La figura 2.7 ilustra esta disimilaridad.

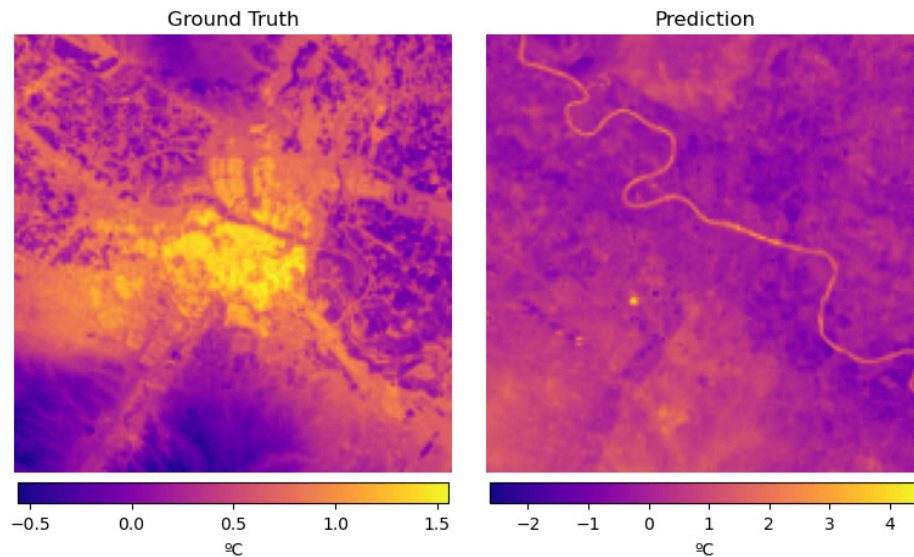


Figura 2.6: A la izquierda se muestra el ráster del ayuntamiento (objetivo), mientras que a la derecha se muestra la interpolación obtenida con los datos de temperatura de Netatmo y todas las variables propuestas por Samuel Barrao.

El modelo de Netatmo que incorpora GLI, NBAI y MDT presenta el error cuadrático medio más bajo de entre todos los modelos de Netatmo. Sin embargo, al igual que el modelo que incorpora todas las variables, identifica incorrectamente cuerpos de agua, por ejemplo el río Ebro, como zonas con el mayor efecto de isla de calor.

Finalmente, se ha determinado que el mejor modelo de los que se han probado es el que emplea SVF y GLI, ya que aunque su MSE de 0,1129 no es el más alto de todos, obtiene el SSIM más alto (0,7262) de los modelos que emplean estaciones Netatmo,




Figura 2.7: Mapa de similaridad estructural (SSIM) entre los rásters de la figura 2.6.

consiguiendo un MSE más bajo que la interpolación obtenida con las estaciones del ayuntamiento. La figura 2.8 muestra el resultado obtenido con este modelo y la figura 2.9 muestra su similaridad con el ráster del ayuntamiento de Zaragoza.

Cabe destacar que, en el mapa de SSIM de la figura 2.9, se aprecia que las zonas donde se encuentra la mayoría de las estaciones y viven más personas presentan una mayor similitud, pues se encuentran representadas con colores cercanos al blanco, mientras que las áreas con colores más oscuros, que indican una menor similitud, corresponden a regiones con escasa presencia de asentamientos humanos. Esto indica que este método funciona correctamente para las zonas más relevantes, que son donde habitan personas.




Figura 2.8: A la izquierda se muestra el ráster del ayuntamiento (objetivo), mientras que a la derecha se muestra la interpolación con los datos de temperatura de Netatmo y las variables SVF y GLI.




Figura 2.9: Mapa de similaridad estructural (SSIM) entre los rásters de la figura 2.8.

Reproducibilidad en otras ciudades

Tras comprobar que el uso de SVF y GLI como variables predictoras genera los resultados más similares al mapa de isla de calor elaborado por el Ayuntamiento de Zaragoza, se decidió emplear estas mismas variables, junto con las diferencias de temperatura obtenidas a partir de estaciones Netatmo, para detectar islas de calor en otras ciudades. En esta fase, el estudio se ha centrado exclusivamente en ciudades españolas; no obstante, en la sección 2.3, dedicada a la validación de ambos modelos, se aplicará el método de kriging con datos de estaciones Netatmo en Graz y Orleans.

Al asignar valores de SVF y GLI a las coordenadas de cada estación considerada, la resolución de los rásteres de dichas variables juega un papel importante, como se muestra en la tabla B.1. En todos los casos se ha asumido la existencia de isla de calor, aunque ello pueda implicar la aparición de falsos positivos, por lo que se espera que SVF y GLI presenten una correlación negativa con las diferencias de temperatura. Es decir, cuanto menor sea la visibilidad del cielo (SVF) y menor la presencia de vegetación (GLI), mayor debería ser el efecto de isla de calor. Por esta razón, en cada ciudad se ha seleccionado la resolución en la que la correlación de ambas variables es negativa y lo más fuerte posible, es decir, aquella en la que los coeficientes se alejan más de cero en sentido negativo. A falta de estudios de isla de calor en estas tres ciudades, en esta sección solo se mostrarán los rásteres resultantes, los cuáles se compararán más adelante con los resultados del segundo modelo.

La visualización de las estaciones Netatmo sobre el mapa de cada ciudad se puede encontrar en la sección A.3.

Sevilla Sevilla contaba con 30 estaciones Netatmo operando en el periodo de estudio, de las cuáles 4 han sido tomadas como estaciones de referencia. Excepto la estación 3,

el resto se encuentra en zonas urbanas próximas a áreas rurales.

La resolución que asume que existe isla de calor en Sevilla es la de 100m/px, ya que tanto SVF como GLI obtienen correlaciones negativas con las diferencias de temperaturas. El resultado de la interpolación se muestra en la figura 2.10.




Figura 2.10: Interpolación resultante en Sevilla.

Valencia De las 65 estaciones Netatmo encontradas en el área de estudio de Valencia, 5 de ellas, situadas principalmente en zonas de chalets, han sido empleadas como estaciones de referencia.

En Valencia tanto la resolución de 5m/px como la de 100m/px producen correlaciones negativas de SVG y GLI. Sin embargo, la resolución de 5m/px produce las correlaciones más fuertes con -0.22 y -0.1 respectivamente, como se puede ver en la tabla B.1. El resultado de la interpolación se muestra en la figura 2.11.

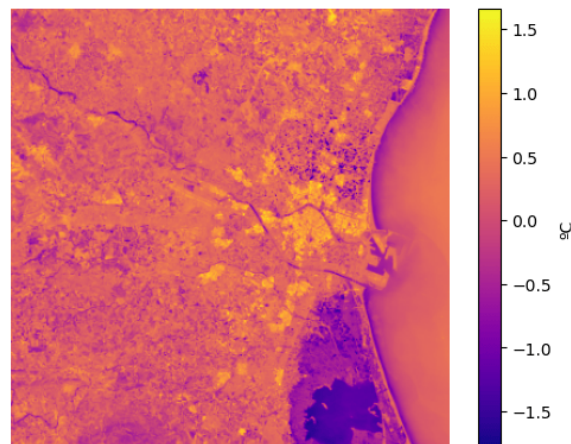


Figura 2.11: Interpolación resultante en Valencia.

Oviedo De las 31 estaciones Netatmo disponibles en el área de estudio de Oviedo, solo 2 han sido consideradas lo suficientemente rurales como para ser usadas como estaciones de referencia como se muestra en la figura A.7.

Con ambas resoluciones (5 m/px y 100 m/px), la interpolación resultante sugiere que no existe una isla de calor en Oviedo; de hecho, la ciudad aparece más fría en comparación con su entorno durante el periodo analizado. Aunque esta conclusión pueda ser correcta, es preferible obtener falsos positivos, es decir, identificar islas de calor incluso cuando no las haya, como se muestra en la sección 2.3, donde la red neuronal convolucional propuesta predice una isla de calor en Oviedo.

La figura 2.12 muestra la interpolación obtenida a partir de los valores de SVF y GLI extraídos de rásteres con una resolución de 100 m/px. Esta resolución se seleccionó considerando que, aunque el SVF presenta una correlación positiva con la temperatura, el GLI muestra una correlación negativa. Así, se asume la presencia de una isla de calor urbano, a pesar de que el resultado final indique que la ciudad registra temperaturas más bajas en comparación con su entorno.




Figura 2.12: Interpolación resultante en Oviedo durante el verano.

No obstante, dado que el efecto de isla de calor puede resultar más pronunciado en invierno, como se ha observado en otras ciudades del hemisferio norte [8], cuando la ciudad, debido a su propia actividad, mantiene temperaturas más elevadas que su entorno, se analizó también este fenómeno en Oviedo durante el período comprendido entre el 1 de diciembre de 2023 y el 28 de febrero de 2024. En este caso, las correlaciones de SVF y GLI con respecto a las diferencias de temperaturas son negativas a 5m/px, por lo que en el área urbanizada se ha obtenido una isla de calor que llega a los 0.91°C con respecto a las estaciones de referencia, como se muestra en la figura 2.13.




Figura 2.13: Interpolación resultante en Oviedo durante el periodo de estudio invernal.

2.2. Modelo 2: Predicción mediante una red neuronal convolucional sin datos de estaciones meteorológicas

Para poder detectar las islas de calor en aquellas zonas en las que no se dispone de una red de estaciones de temperatura, se propuso el uso de una red neuronal convolucional (CNN por sus siglas en inglés) que a partir de ciertas variables espaciales sea capaz de predecir un ráster con las diferencias de temperatura dentro de la ciudad con respecto a sus alrededores. Se decidió emplear una CNN, en vez de otros métodos como regresiones o bosques aleatorios, porque a diferencia de estos últimos una CNN puede aprender patrones locales y preservar las relaciones espaciales entre puntos.

Se han comparado dos redes neuronales: (1) U-Net, que es comúnmente empleada para tareas de segmentación, y (2) una arquitectura propia basada en esta última que es capaz de obtener mejores resultados.

2.2.1. Arquitectura de la red neuronal propuesta

La arquitectura de la red neuronal está inspirada en la de U-Net, propuesta por Ronneberger et al.[9] para la segmentación de imágenes biomédicas, y empleada por otros como Ulmas et al.[10] sobre imágenes satelitales para clasificar la cobertura terrestre. Para lograr el objetivo, se adaptó para predecir un ráster que contenga las diferencias de temperatura dadas dos variables predictoras (SVF y GLI). Para ello, el encoder reduce la dimensionalidad de los datos obteniendo tensores de tamaño $(32, H/2, W/2)$, el resultado del encoder es posteriormente aumentado por el decoder obteniendo una predicción de tamaño $(1, H, W)$.

La arquitectura propuesta es una versión simplificada de la U-Net original, ya que

incluye únicamente 4 capas convolucionales y 3 capas de activación ReLU, en contraste con las 19 capas convolucionales y 18 capas ReLU de la U-Net. Además, el modelo no incorpora conexiones residuales que transfieran los mapas de características desde los bloques convolucionales del encoder al decoder. Esta simplificación permite un entrenamiento e inferencia más rápidos, y, como se demostrará más adelante, logra un rendimiento superior al de la U-Net original. La figura 2.14 muestra la arquitectura del modelo propuesto.

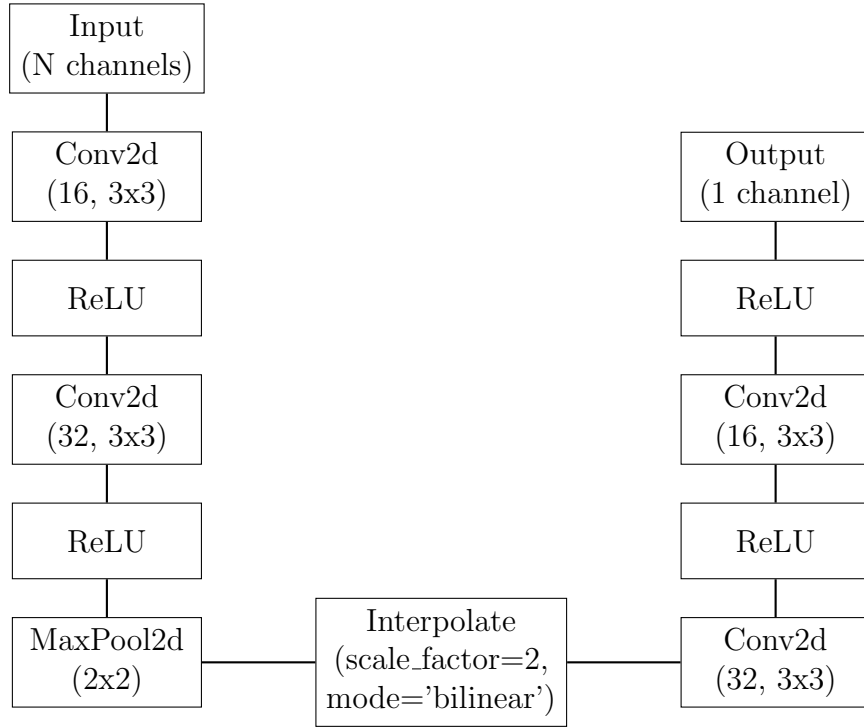


Figura 2.14: Arquitectura de la red neuronal convolucional.

2.2.2. Preparación del dataset

La preparación comienza por apilar las dos variables predictoras (SVF y GLI) para formar un ráster de dos bandas ($N \text{ channels} = 2$). Posteriormente, este ráster es dividido en baldosas de 64×64 píxeles, ya que este es el tamaño de entrada de la red neuronal. La entrada es de $[N, 64, 64]$ donde N es el número de bandas, en este caso dos. Estas baldosas son separadas en dos conjuntos, un 80 % de ellas va destinado al conjunto de entrenamiento, mientras que el 20 % restante se destina al conjunto de test. En total, se han generado 3534 muestras de entrenamiento y 884 de test a partir de la interpolación obtenida con kriging sobre Zaragoza cuya resolución es de 5m/px . Para almacenar las muestras, se ha optado por apilar una componente adicional correspondiente a la variable objetivo, i.e. la diferencia de temperatura, y emplear el formato `.npy` para almacenar los arrays de NumPy hasta su uso.

2.2.3. Entrenamiento

El entrenamiento se ejecutó sobre el conjunto de baldosas de entrenamiento, con 30 épocas, empleando error cuadrático medio (MSE) como función de coste y optimizador Adam. Los resultados del entrenamiento se muestran en la tabla 2.2. Como se puede apreciar, en ninguno de los dos modelos hay sobreajuste o subajuste notable. Sin embargo, es significativa la diferencia de resultados entre el modelo propuesto y la arquitectura U-Net original.

El error es cuadrático por lo que su unidad es $(^{\circ}\text{C})^2$. Aplicando raíces cuadradas a los errores obtenidos con el conjunto de datos de test, obtendríamos 0.529°C de error medio con U-Net y 0.11°C con la CNN propuesta, es decir, el error del modelo propuesto es aproximadamente una quinta parte del de la U-Net original. Mientras medio grado de diferencia puede marcar la diferencia, 0.11°C es prácticamente imperceptible para la mayoría de personas.

Arquitectura	MSE de entrenam.	MSE de val.	MSE de test
U-Net	0.2877	0.2812	0.2803
CNN propuesta	0.0084	0.0107	0.0122

Tabla 2.2: Resultados de las redes neuronales probadas.

Las curvas de aprendizaje de la U-Net original y la nueva arquitectura propuesta, figura 2.15, permiten visualizar el error obtenido con el conjunto de entrenamiento y validación. En el caso de la U-Net original, no solo es costosa en lo que a tiempo de entrenamiento respecta, sino que a partir de la época 10 no mejora y los resultados no son buenos en comparación con la arquitectura propuesta, por lo que se ha descartado para predecir islas de calor urbano a partir de variables espaciales.

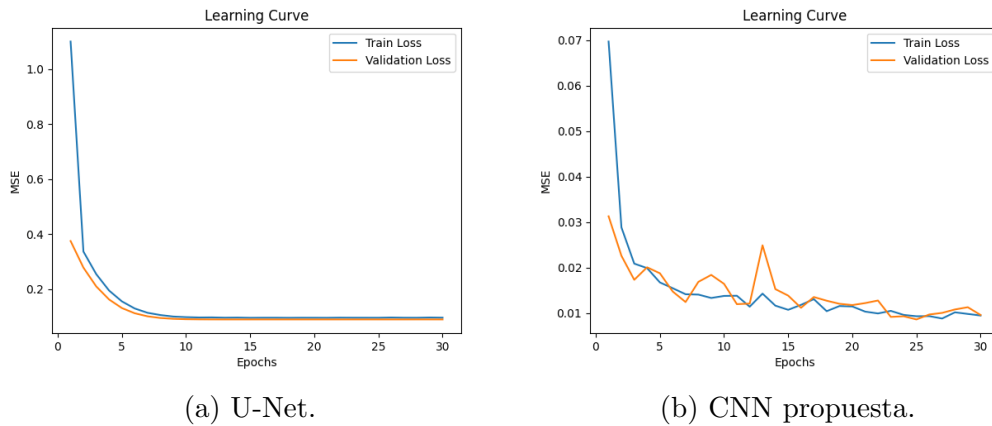


Figura 2.15: Curvas de aprendizaje.

2.2.4. Predicción y fusión de baldosas

Cuando las baldosas se combinan sin ningún tipo de fusión, como se muestra en la figura 2.16.a, se forma una cuadrícula negra que dificulta la correcta interpretación de la imagen resultante. Para solucionar este inconveniente, se puede realizar la predicción con cierto solapamiento. En este estudio, se utilizó un solapamiento del 25 %, lo que permite aplicar posteriormente una máscara para ponderar los valores de cada baldosa. De esta manera, al sumar las áreas donde se solapan, se obtiene una transición suave entre las baldosas. Las distintas máscaras evaluadas en el proceso de fusión se muestran en la figura 2.17, seleccionándose la máscara con spline, ya que produce una transición visualmente imperceptible. Este método, propuesto por Guillaume Chevalier², ha sido adaptado para funcionar de manera más eficiente con un mayor número de baldosas, evitando almacenar duplicados innecesarios en memoria.

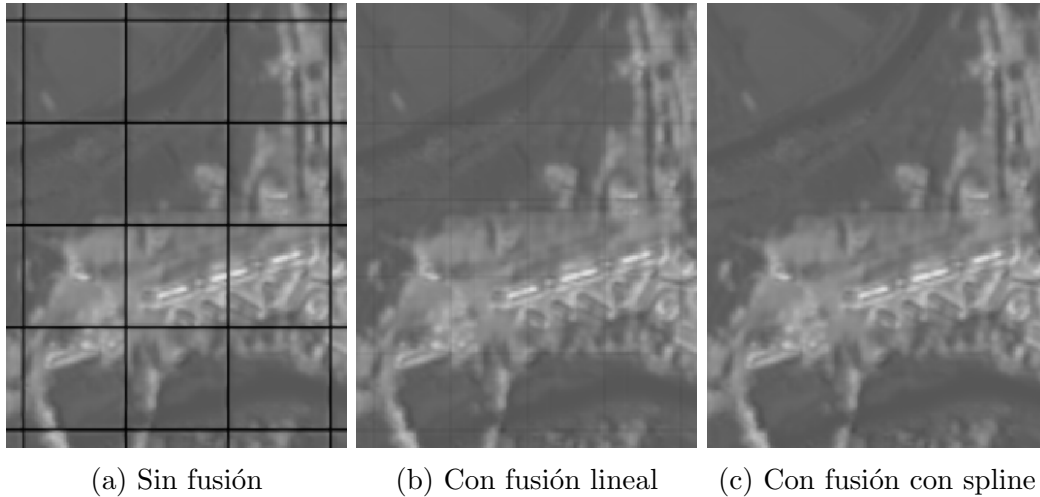


Figura 2.16: Interpolaciones obtenidas como predicción de la red neuronal. (a) no tiene ningún tipo de fusión con baldosas, mientras que (b) y (c) emplean una máscara ponderada basada en una función lineal y en un spline respectivamente.

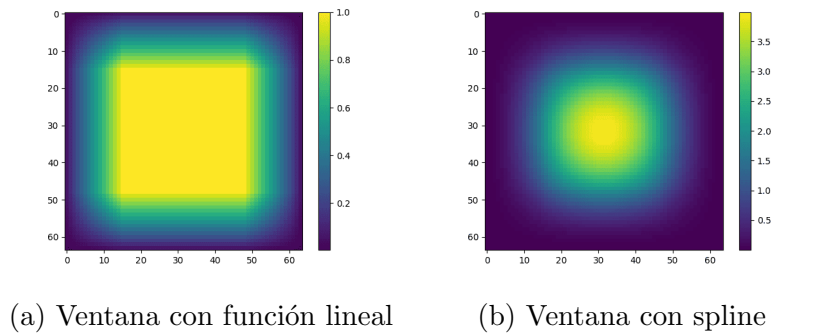


Figura 2.17: Máscaras ponderadas empleadas en la fusión de las baldosas.

²<https://github.com/Vooban/Smoothly-Blend-Image-Patches>




Figura 2.18: Spline empleado para generar la ventana de la figura 2.17.b.

2.3. Validación de ambos modelos

Para evaluar simultáneamente la capacidad de generalización de los dos modelos propuestos, la red neuronal convolucional (CNN) y el modelo de kriging con estaciones Netatmo, se han generado predicciones para las ciudades de Zaragoza, Valencia, Sevilla y Oviedo. Madrid no se ha incluido en el análisis, ya que, al tratarse de una gran metrópolis sin un límite claramente definido entre la ciudad y su entorno rural, no se encontraron estaciones Netatmo adecuadas para ser utilizadas como referencia.

Los rásters generados mediante kriging universal son los mismos presentados anteriormente para estas ciudades y cuentan con una resolución de 100 m/px. En cambio, los rásters predichos por la CNN tienen una resolución original de 5 m/px, ya que las variables predictoras (SVF y GLI) se encontraban a esa misma escala. Para asegurar una comparación equitativa, las predicciones de la CNN se han reescalado a 100 m/px mediante interpolación bilineal.

En esta nueva configuración, la red ha sido entrenada exclusivamente con datos de Zaragoza, utilizando SVF y GLI como variables predictoras, y como variable objetivo se empleó una interpolación previa generada mediante kriging universal. A continuación, se evalúa la capacidad de generalización del modelo al aplicarlo en otras ciudades con características diferentes a las de Zaragoza. La tabla 2.3 los resultados obtenidos para cada una de las ciudades.

Ciudad	MSE	SSIM
Zaragoza	0.0003	0.9836
Valencia	0.0608	0.9445
Sevilla	0.0147	0.9709
Oviedo (en verano)	0.4934	-0.2283
Oviedo (en invierno)	0.1181	0.2048
Graz	0.2763	-0.0844
Orleans	0.7937	0.6710

Tabla 2.3: Error cuadrático medio, en $(^{\circ}\text{C})^2$, e índice de similaridad entre el ráster obtenido con kriging y el ráster predicho con la CNN para cada ciudad.

Zaragoza

Como era previsible, Zaragoza presenta el MSE más bajo y el SSIM más alto. Esto se debe a que los datos de esta ciudad se utilizaron para entrenar la red, comparando sus predicciones con la interpolación inicial basada en Kriging. Por ello, los valores obtenidos reflejan un ajuste casi perfecto, aunque no exacto. Las pequeñas discrepancias se deben a los errores inherentes del modelo y al proceso de reescalado espacial de 5m/px a 100m/px, que conlleva pérdida de información. En la figura 2.19 se muestran los mapas generados por la CNN y por Kriging, así como el mapa de similitud entre ambos.




Figura 2.19: Resultados de la CNN (izda.) y Kriging (centro) en Zaragoza, junto al correspondiente mapa de similitud (dcha.).

Valencia

Poniendo el foco en Valencia, se observa que los resultados obtenidos con la CNN (sin estaciones) y la interpolación mediante kriging (utilizando estaciones Netatmo) son similares. Esto es una señal positiva de que ambos modelos logran capturar la tendencia inherente de la isla de calor, aún cuando la CNN no tiene datos de temperatura de Valencia. Esta similitud puede apreciarse visualmente en la figura 2.20, donde las zonas con mayor similitud son las de las áreas urbanizadas del centro de la ciudad y la albufera (en blanco).

El error cuadrático medio (MSE) de 0.0608, al aplicar la raíz cuadrada, equivale a un error medio de 0.24 °C entre ambas predicciones, con una similitud positiva de 0.9445. Además, cabe destacar que la CNN ha logrado generalizar relativamente bien, a pesar de que el clima de Valencia está influenciado por su proximidad al mar, un factor para el cual la red no fue específicamente entrenada al haberse utilizado datos de Zaragoza.




Figura 2.20: Resultados de la CNN (izda.) y Kriging (centro) en Valencia, junto al correspondiente mapa de similitud (dcha.).

Sevilla

En el caso de Sevilla, el índice de similitud es el más alto con 0.9709, por detrás de Zaragoza, lo que denota que ambos modelos detectan las zonas con mayor efecto de isla de calor. Esta similitud se puede apreciar en la figura 2.21. Además, su MSE de 0.0147, tras calcular su raíz cuadrada equivale a un error de 0.12 °C.

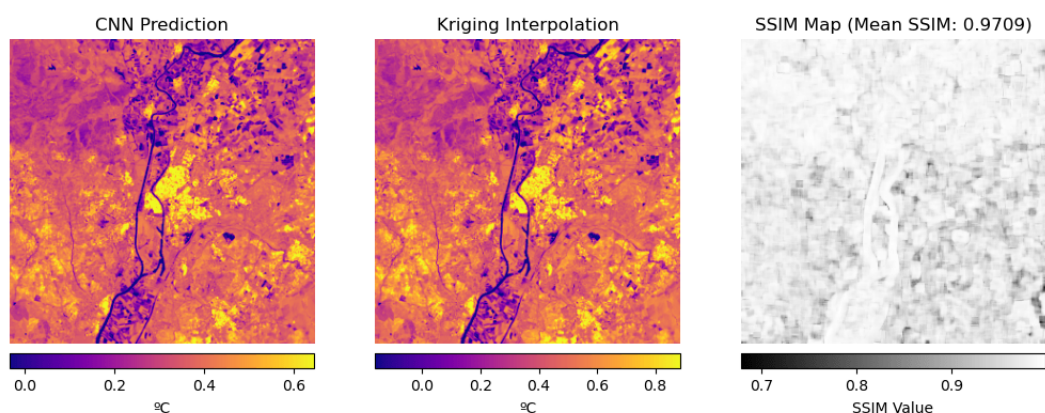


Figura 2.21: Resultados de la CNN (izda.) y Kriging (centro) en Sevilla, junto al correspondiente mapa de similitud (dcha.).

Oviedo

Como se mencionó en la sección sobre kriging, en Oviedo la correlación entre las diferencias de temperatura con la variable GLI con resolución de 100m/px es positiva. Esto significa que, a mayor vegetación, la temperatura tiende a aumentar. En consecuencia, el modelo de kriging predice que en el entramado urbano, una zona con menor vegetación y menor visibilidad celeste, el efecto de isla de calor es menos pronunciado que en las áreas rurales circundantes.

Por el contrario, la CNN predice una marcada isla de calor en el entramado urbano, mientras que las zonas periféricas son clasificadas como más frías. Esta discrepancia entre la predicción de la CNN y el modelo de Kriging genera en Oviedo el mayor error cuadrático medio y la mayor disimilaridad entre todas las ciudades analizadas. Además, la similitud entre ambos modelos es negativa, ya que el Kriging detecta una isla de calor inversa a la predicha por la CNN, como se muestra en la figura 2.22.

Es preferible obtener un falso positivo al determinar la presencia de una isla de calor, como indica la CNN, que un falso negativo que descarte su existencia. En el primer caso, se identifican zonas donde se pueden implementar medidas para mitigar el efecto de isla de calor y mejorar la calidad de vida de los ciudadanos. En cambio, en el segundo caso, el problema podría pasar desapercibido, lo que llevaría a la inacción y a la persistencia de condiciones térmicas adversas en el entorno urbano.




Figura 2.22: Resultados de la CNN (izda.) y Kriging (centro) en Oviedo durante el verano, junto al correspondiente mapa de similitud (dcha.).

Por otra parte, se ha comparado el resultado obtenido en el periodo invernal comprendido entre el 1 de diciembre de 2023 y el 28 de febrero de 2014. El error cuadrático medio se ha reducido a 0.11 en comparación al 0.49 que se había en el estudio en verano, y como se puede ver en la figura 2.23 el índice de similitud llega a ser positivo, 0.2048, debido a que tanto SVF como GLI guardan una correlación negativa con las diferencias de temperatura.

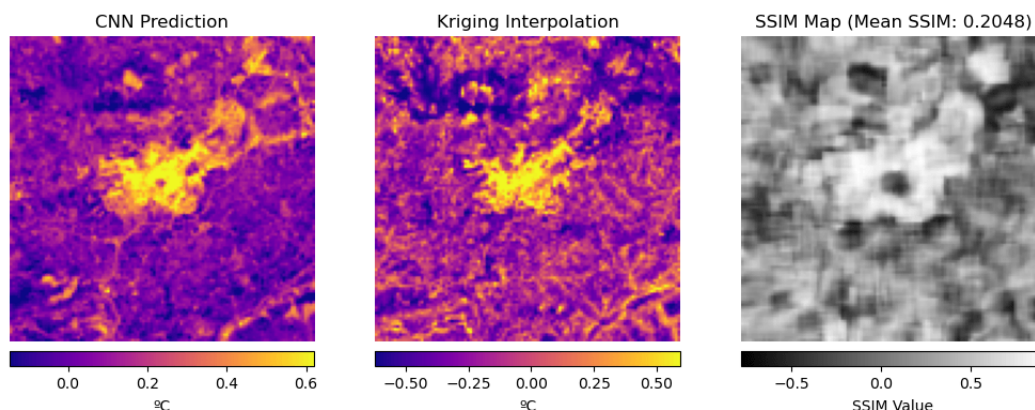


Figura 2.23: Resultados de la CNN (izda.) y Kriging (centro) en Oviedo durante el invierno, junto al correspondiente mapa de similitud (dcha.).

Graz

En Graz, como cabría esperar al aplicar kriging, la correlación entre el GLI y las diferencias de temperatura es negativa (-0.2658). En cambio, la correlación entre el SVF y la temperatura resulta positiva (0.2485), lo cual se explica, en parte, porque las estaciones más cálidas se localizan en la zona de llanura, donde la visibilidad del cielo es mayor. Es importante señalar que en la zona central de la ciudad, marcada con un círculo blanco en la figura 2.24 y caracterizada por la ausencia de vegetación y una mayor densidad y altura de edificaciones en comparación con otras áreas, no disponía de estaciones Netatmo durante el período de estudio. Si hubieran existido estaciones en esta zona, que presenta un menor SVF y reúne características típicas de una isla de calor urbana, probablemente la correlación entre el SVF y las diferencias de temperatura habría sido negativa. En tal caso, los resultados habrían sido más coherentes con los obtenidos por la CNN.

Con los datos disponibles, la similitud entre los resultados de kriging y los de la CNN es prácticamente inexistente (SSIM de -0.0844), y el error cuadrático medio (MSE de $0.2763 (^\circ\text{C})^2$) es considerablemente alto en comparación con los valores observados en las ciudades españolas. Esto evidencia la importancia de contar con estaciones distribuidas de manera uniforme en toda el área de estudio, ya que con kriging la predicción en un punto depende de su proximidad a los puntos de muestreo. Como se explica en el anexo A sobre kriging universal, la semivarianza y, por ende, la incertidumbre de la predicción, disminuye a medida que uno se acerca a un punto de muestreo, o estación en este caso. Además, el alto MSE pone de manifiesto que la CNN está limitada al predecir valores de diferencias de temperatura, debido a que no cuenta con datos de temperatura reales sobre la ciudad de estudio, a diferencia del modelo de kriging, y solo conoce el rango de temperaturas con el que ha sido entrenada.

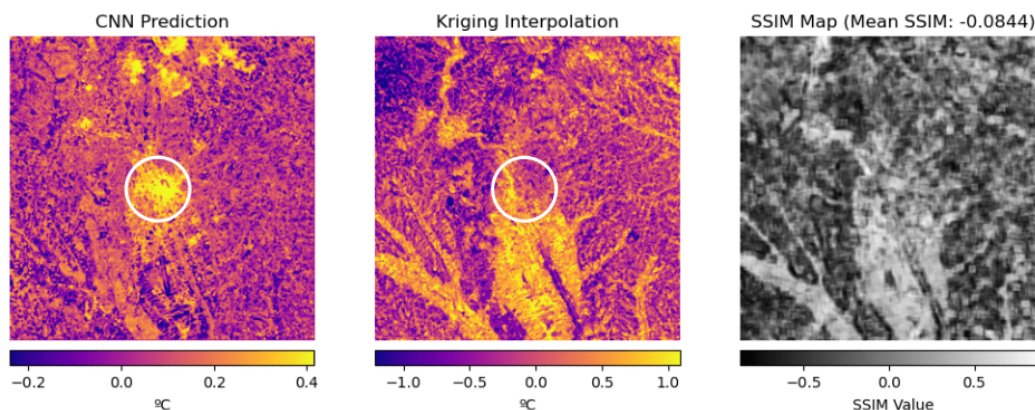


Figura 2.24: Resultados de la CNN (izda.) y Kriging (centro) en Graz, junto al correspondiente mapa de similitud (dcha.).

Orleans

En Orleans se han obtenido correlaciones negativas entre el SVF y el GLI respecto a las diferencias de temperatura, con valores de -0.2325 y -0.1732, respectivamente. Esto indica que las islas de calor identificadas por ambos modelos presentan formas muy similares, como lo refleja un índice SSIM de 0.6710. No obstante, el error cuadrático medio alcanza un valor de $0.7937\text{ (}^{\circ}\text{C)}^2$, el más alto entre todas las ciudades analizadas. Este resultado se debe, en parte, a que las redes neuronales convolucionales no disponen de datos reales de temperatura, como ya se ha mencionado en el caso de Graz.

Además, dado que la CNN fue entrenada con datos de Zaragoza, tiende a sobreestimar las temperaturas en zonas residenciales con viviendas unifamiliares y jardines, como el área delimitada por el hemiciclo de borde blanco en la figura 2.25, en comparación con la predicción del modelo de kriging. Esto demuestra también otra limitación de la CNN: su incapacidad para generalizar adecuadamente a ciudades cuya morfología urbana difiere de la de Zaragoza, e incluso de las características típicas de las ciudades españolas, que suelen ser más compactas que otras urbes europeas [11].

Estudios como el de Rosati [11] utilizan métricas como el índice de Bribiesca o una entropía de Shannon adaptada para cuantificar el grado de dispersión urbana. Estas métricas podrían emplearse para clasificar objetivamente las ciudades y entrenar modelos de CNN personalizados según el tipo urbano, evitando así depender de juicios subjetivos sobre la predominancia de viviendas unifamiliares con jardín o de edificios de varias plantas. De este modo, al realizar una predicción, el primer paso consistiría en identificar el tipo de ciudad y aplicar el modelo de CNN más adecuado para ese contexto urbano.




Figura 2.25: Resultados de la CNN (izda.) y Kriging (centro) en Orleans, junto al correspondiente mapa de similaridad (dcha.). El área contenida en el hemiciclo de borde blanco corresponde a zonas residenciales con viviendas unifamiliares.

Capítulo 3

Conclusiones

Los resultados obtenidos demuestran que es posible detectar islas de calor urbanas de forma remota y eficiente, lo que permite prescindir de los métodos tradicionales, generalmente más costosos y complejos. Excluyendo Zaragoza, la ciudad utilizada para entrenar la red neuronal convolucional, el modelo es capaz de predecir mapas de calor muy similares a los generados mediante kriging en otras ciudades como Valencia y Sevilla. En concreto, se obtuvieron errores medios de 0,24 °C en Valencia y de 0,12 °C en Sevilla, manteniendo además una alta similitud estructural, con valores de SSIM de 0,94 y 0,97 respectivamente.

Como se ha visto, el método de kriging incorpora datos de temperatura reales, lo que lo convierte en una representación más fiel de la realidad. Por tanto, el hecho de que la CNN logre resultados comparables indica que el modelo entrenado tiene una buena capacidad de generalización en ciudades con características similares a las de Zaragoza. Sin embargo, los resultados obtenidos en Oviedo, Graz y Orleans muestran las limitaciones de ambos enfoques: el error medio no llega a bajar de 0,34 °C para estas tres ciudades, y la similaridad estructural más alta es apenas de 0,67 en Orleans.

A la hora de interpretar los resultados, cuando ambos métodos coinciden en la predicción, es razonable asumir que la presencia y forma de la isla de calor están bien representadas. En los casos en los que los modelos no coincidan, se recomienda priorizar el resultado que indique la existencia de una isla de calor, incluso si existe la posibilidad de un falso positivo. Esta elección se justifica desde un enfoque precautorio, especialmente en contextos donde la detección es clave para la planificación urbana o la implementación de medidas de mitigación.

Finalmente, conviene señalar algunos factores que condicionan la precisión de ambos métodos. En el caso del modelo de kriging basado en estaciones meteorológicas, influyen variables como posibles errores de georreferenciación, la calidad de los datos registrados, la selección del conjunto de estaciones de referencia, y la cantidad y distribución espacial de las estaciones en el área de estudio, como se ha observado en Oviedo y Graz. Por

su parte, en los modelos basados en redes neuronales convolucionales, el factor más determinante es la disimilitud morfológica de la ciudad que se ha empleado en el entrenamiento y la de la ciudad donde se aplicará el modelo, como se ha demostrado en Orleans. Una posible solución a esta limitación consiste en entrenar modelos específicos para cada tipo de ciudad con una morfología distinta.

Capítulo 4

Bibliografía

- [1] Yoshika Yamamoto. Measures to mitigate urban heat islands. 2006.
- [2] José M Cuadrat Prats and Sergio M Vicente-Serrano. Los efectos de la urbanización en el clima de zaragoza (españa): La isla de calor y sus factores condicionantes. 2005.
- [3] Samuel Barrao, Roberto Serrano-Notivoli, José M. Cuadrat, Ernesto Tejedor, and Miguel A. Saz Sánchez. Characterization of the uhi in zaragoza (spain) using a quality-controlled hourly sensor-based urban climate network. *Urban Climate*, 44:101207, July 2022.
- [4] Kai Zhang, Evan M. Oswald, Daniel G. Brown, Shannon J. Brines, Carina J. Gronlund, Jalonnie L. White-Newsome, Richard B. Rood, and Marie S. O'Neill. Geostatistical exploration of spatial variation of summertime temperatures in the detroit metropolitan region. *Environmental Research*, 111(8):1046–1053, November 2011.
- [5] Ayuntamiento de Zaragoza. Informe del estudio del clima de la ciudad de zaragoza. Technical report, Ayuntamiento de Zaragoza, Zaragoza, Spain, 2021.
- [6] Samuel Barrao Simorte, Miguel Ángel Saz Sánchez, José María Cuadrat Prats, and Roberto Serrano Notivoli. Clima urbano de Zaragoza. Estudio espacio-temporal a través de una red de sensores. 2024.
- [7] Evidence of horizontal urban heat advection in london using six years of data from a citizen weather station network. 17:044041, April 2022.
- [8] Victoria Miles and Igor Esau. Seasonal and spatial characteristics of urban heat islands (uhis) in northern west siberian cities. 9:989, September 2017.

- [9] Olaf Ronneberger, Philipp Fischer, and Thomas Brox. U-net: Convolutional networks for biomedical image segmentation. In *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*, pages 234–241. Springer, 2015.
- [10] Priit Ulmas and Innar Liiv. Segmentation of satellite imagery using u-net models for land cover classification. *IEEE Access*, 2020.
- [11] Roberto Maria Rosati. Urban sprawl and routing: A comparative study on 156 european cities. *Landscape and Urban Planning*, 253:105205, January 2025.
- [12] Kangjoon Cho, Yonghyun Kim, and Yongil Kim. *Disaggregation of Landsat-8 thermal data using guided SWIR imagery on the scene of a wild fire*. Remote Sensing, vol. 10, no. 1, 2018.
- [13] Francesco Marchese, Nicola Genzano, Marco Neri, Alfredo Falconieri, Giuseppe Mazzeo, and Nicola Pergola. *A multi-channel algorithm for mapping volcanic thermal anomalies by means of sentinel-2 msi and landsat-8 oli data*. Remote Sensing, vol. 11, 2019.
- [14] Wei Zhang, Yuqing Li, Caigui Zheng, and Yubi Zhu. Surface urban heat island effect and its driving factors for all the cities in china: Based on a new batch processing method. *Ecological Indicators*, 146:109818, 2023.
- [15] Samuel Barrao Simorte, Roberto Serrano-Notivoli, José M. Cuadrat, and Ernesto Tejedor. Characterization of the uhi in zaragoza (spain) using a quality-controlled hourly sensor-based urban climate network. *Urban Climate*, 44:101207, July 2022.
- [16] Cuadrat Prats, Miguel Saz, Sergio Vicente-Serrano, and Serrano. Spatial patterns estimation of urban heat island of zaragoza (spain) using gis. *5th International Conference on Urban Climate*, 2003.
- [17] Adrien Napoly, Tom Grassmann, Fred Meier, and Daniel Fenner. Development and application of a statistically-based quality control for crowdsourced air temperature data. *Frontiers in Earth Science*, 6, 2018.
- [18] Fred Meier, Daniel Fenner, Tom Grassmann, Marco Otto, and Dieter Scherer. Crowdsourcing air temperature from citizen weather stations for urban climate research. *Urban Climate*, 19:170–191, 2017.
- [19] Michael M. Borman Mounir Louhaichi and Douglas E. Johnson. Spatially located platform and aerial photography for documentation of grazing impacts on wheat. *Geocarto International*, 16(1):65–70, 2001.

- [20] J.P. Lacaux, Y.M. Tourre, C. Vignolles, J.A. Ndione, and M. Lafaye. Classification of ponds from high-spatial resolution remote sensing: Application to rift valley fever epidemics in senegal. *Remote Sensing of Environment*, 106(1):66–74, 2007.
- [21] Mirza Waqar, J.F. Mirza, Rafia Mumtaz, and Ejaz Hussain. Development of new indices for extraction of built-up area and bare soil from landsat. *Data*, 1, 01 2012.
- [22] COTESA. Mapa de isla de calor urbano. año 2021. Technical report, Ayuntamiento de Madrid, 2021.
- [23] Daniel Eric Sangines Coral and José Antonio Turégano Romero. Metodología de evaluación de la isla de calor urbana y su utilización para identificar problemáticas energéticas y de planificación urbana. 2013.

Lista de Figuras

2.1. Diferencias de temperatura con respecto a la estación de referencia. . .	6
2.2. Las zonas más calientes están denotadas con colores más próximos al amarillo, mientras que las más frías se identifican con colores más oscuros. . .	7
2.3. Interpolación de isla de calor urbano sobre Zaragoza con las temperaturas de las estaciones del ayuntamiento de Zaragoza. Las zonas más calientes están denotadas con colores próximos al amarillo, mientras que las más frías se identifican con colores más oscuros.	8
2.4. SSIM entre los rásters de la figura 2.3.	8
2.5. Interpolación de isla de calor urbano sobre Madrid, tomando como referencia la estación 106.	9
2.6. A la izquierda se muestra el ráster del ayuntamiento (objetivo), mientras que a la derecha se muestra la interpolación obtenida con los datos de temperatura de Netatmo y todas las variables propuestas por Samuel Barrao.	11
2.7. Mapa de similaridad estructural (SSIM) entre los rásters de la figura 2.6. . .	12
2.8. A la izquierda se muestra el ráster del ayuntamiento (objetivo), mientras que a la derecha se muestra la interpolación con los datos de temperatura de Netatmo y las variables SVF y GLI.	12
2.9. Mapa de similaridad estructural (SSIM) entre los rásters de la figura 2.8. . .	13
2.10. Interpolación resultante en Sevilla.	14
2.11. Interpolación resultante en Valencia.	14
2.12. Interpolación resultante en Oviedo durante el verano.	15
2.13. Interpolación resultante en Oviedo durante el periodo de estudio invernal. . .	16
2.14. Arquitectura de la red neuronal convolucional.	17
2.15. Curvas de aprendizaje.	18
2.16. Interpolaciones obtenidas como predicción de la red neuronal. (a) no tiene ningún tipo de fusión con baldosas, mientras que (b) y (c) emplean una máscara ponderada basada en una función lineal y en un spline respectivamente.	19

2.17. Máscaras ponderadas empleadas en la fusión de las baldosas.	19
2.18. Spline empleado para generar la ventana de la figura 2.17.b.	20
2.19. Resultados de la CNN (izda.) y Kriging (centro) en Zaragoza, junto al correspondiente mapa de similaridad (dcha.).	21
2.20. Resultados de la CNN (izda.) y Kriging (centro) en Valencia, junto al correspondiente mapa de similaridad (dcha.).	22
2.21. Resultados de la CNN (izda.) y Kriging (centro) en Sevilla, junto al correspondiente mapa de similaridad (dcha.).	22
2.22. Resultados de la CNN (izda.) y Kriging (centro) en Oviedo durante el verano, junto al correspondiente mapa de similaridad (dcha.).	23
2.23. Resultados de la CNN (izda.) y Kriging (centro) en Oviedo durante el invierno, junto al correspondiente mapa de similaridad (dcha.).	24
2.24. Resultados de la CNN (izda.) y Kriging (centro) en Graz, junto al correspondiente mapa de similaridad (dcha.).	25
2.25. Resultados de la CNN (izda.) y Kriging (centro) en Orleans, junto al correspondiente mapa de similaridad (dcha.). El área contenida en el hemicíclo de borde blanco corresponde a zonas residenciales con viviendas unifamiliares.	26
A.1. Interpolaciones obtenidas calculando las diferencias de temperatura respecto a diferentes estaciones de referencia, y añadiendo SVF, IMD y NDVI como variables predictoras. La localización de la estación se indica con un punto rojo en el mapa.	48
A.2. Área de estudio de Zaragoza con sus respectivas estaciones Netatmo. Estación 1. Cuarte de Huerva. Estación 2. La Venta del Olivar. Estación 3. Villamayor de Gállego.	49
A.3. Área de estudio de Valencia con sus respectivas estaciones Netatmo. Estación 1. Xalets de Lladró. Estación 2. Bungalows Park Albufera. Estación 3. Urbanització El Pedregal. Estación 4. Urbanització Monte Rosado. Estación 5. Serra Perenxisa.	49
A.4. Área de estudio de Sevilla con sus respectivas estaciones Netatmo. Estación 1. Dos Hermanas. Estación 2. La Puebla del Río. Estación 3. Almensilla. Estación 4. Camino de Sanlúcar.	50
A.5. Área de estudio de Oviedo con sus respectivas estaciones Netatmo. Estación 1. Villamar. Estación 2. Faro de Baxo.	50

A.6. Área de estudio de Graz con sus respectivas estaciones Netatmo. Estación 1. Schöckl. Estación 2. Purgstall bei Eggersdorf. Estación 3. Edelsgrub. Estación 4. Dobl-Zwaring.	51
A.7. Área de estudio de Orleans con sus respectivas estaciones Netatmo. Estación 1. Saint-Hilaire-Saint-Mesmin. Estación 2. Sandillon. Estación 3. Chanteau.	51
A.8. Modelo de variograma esférico que muestra el efecto pepita, la meseta y el alcance.	55
C.1. Áreas de estudio.	62
C.2. Clustering de la banda roja	63
C.3. Clustering de la banda de infrarrojo cercano (NIR)	63
C.4. Clustering de la banda de infrarroja de onda corta 1 (SWIR1)	64
C.5. Clustering de la banda de infrarroja de onda corta 2 (SWIR2)	64
C.6. PCA sobre banda NIR.	65
C.7. PCA sobre banda SWIR2.	65
C.8. Serie temporal. Temperatura (en azul) vs. NIR (en rojo).	66
C.9. Edificios de Zaragoza.	67
C.10. Isla de calor media de verano de 2023 (recortada).	67
C.11. Banda SWIR2 (izquierda) y comparación mediante SSIM entre la banda SWIR2 y el ráster de isla de calor de la web del ayuntamiento de Zaragoza.	68
C.12. Banda SWIR2 sin edificios (izquierda) y comparación mediante SSIM entre la banda SWIR2 sin edificios y el ráster de isla de calor de la web del ayuntamiento de Zaragoza.	68
C.13. Bandas Sentinel-2. Fuente: https://blogs.fu-berlin.de/reseda/sentinel-2/	69
C.14.	70
C.15. Escalado del ráster temperatura (imagen del medio) empleando NDVI (imagen de la izquierda). El resultado es la imagen de la derecha. Todas las unidades de temperatura están en Kelvin.	71
C.16. Correlación entre SWIR2 y temperatura superficial (LST) para el día 24 de agosto de 2023.	71
D.1. Diagrama de flujo de datos.	75
E.1. Diagrama de Gantt del proyecto	82


Lista de Tablas

2.1. Resultados de comparar cada modelo desarrollado con el del portal del ayuntamiento de Zaragoza ordenados por SSIM. La última fila muestra el resultado de considerar las 6 variables.	10
2.2. Resultados de las redes neuronales probadas.	18
2.3. Error cuadrático medio, en $(^{\circ}C)^2$, e índice de similaridad entre el ráster obtenido con kriging y el ráster predicho con la CNN para cada ciudad.	20
B.1. Correlación entre cada variable predictora y las diferencias de temperatura teniendo en cuenta dos resoluciones (5m/px y 100m/px) en 4 ciudades distintas.	60
E.1. Tiempo dedicado al proyecto por tarea	81

Anexos


A.1.2. Valencia

- Área: 1170,32 km^2 .
- Clima Köppen-Geiger: Csa - Mediterráneo (verano cálido).
- Población de Valencia capital: 825.948 habitantes (2024. Fuente: INE).
- Nota: Permite ver la influencia del mar en los modelos.




A.1.3. Sevilla

- Área: 924,76 km^2
- Clima Köppen-Geiger: Csa - Mediterráneo (verano cálido).
- Población de Sevilla capital: 687.488 habitantes (2024. Fuente: INE).
- Nota: Similar a Zaragoza en cuanto a que se encuentra situada en la depresión de un gran río. Sin embargo, su área metropolitana contiene más población.




A.1.4. Oviedo

- Área: 129,73 km^2 .
- Clima Köppen-Geiger: Cfb - Oceánico (verano suave).
- Población de Oviedo: 220.543 habitantes (2024. Fuente: INE).
- Nota: Ciudad rodeada de un entorno con mayor cobertura vegetal en comparación a las ciudades anteriormente mencionadas.




A.1.5. Graz (Austria)

- Área: 1004,89 km^2 .
- Clima Köppen-Geiger: Dfb - Hemiboreal sin estación seca.
- Población del municipio de Graz: 305.314 habitantes (2025. Fuente: statistik.at).
- Nota: Es una ciudad más dispersa que las que se han estudiado en España. Exceptuando la zona centro de la ciudad, donde se encuentran los edificios más altos y compactos, en el resto de la ciudad predominan barrios residenciales con viviendas unifamiliares y amplias zonas ajardinadas.



A.1.6. Orleans (Francia)

- Área: 519,84 km^2 .
- Clima Köppen-Geiger: Cfb - Oceánico (verano suave).
- Población de la comuna de Orleans: 116.617 (2021. Fuente: INSEE).
- Nota: Al igual que Graz, es una ciudad más dispersa que las ciudades españolas.



A.2. Fuentes de datos

A.2.1. Copernicus

Las misiones Sentinel-2 y Sentinel-3 son parte del programa Copernicus de la Agencia Espacial Europea (ESA).

Sentinel 2

El objetivo principal de Sentinel-2 es el monitoreo de la superficie terrestre. Esta misión cuenta con dos satélites, Sentinel-2A, lanzado en 2015, y Sentinel-2B, en 2017. Ofrece una resolución espacial de hasta 10 metros y utiliza 13 bandas espectrales que cubren desde el espectro visible hasta el infrarrojo cercano y de onda corta. La frecuencia de paso es de cinco días gracias a la operación conjunta de ambos satélites.

Para poder obtener todas las imágenes satelitales en el periodo de estudio, se podrían haber descargado manualmente empleando *Copernicus Browser*. Sin embargo, esta opción no es escalable al no poderse automatizar fácilmente, por lo que finalmente se optó por emplear *OData API* de Copernicus.

El *endpoint* de descarga hay que generarlo de acuerdo a la documentación de OData¹. Además para poder acceder a este *endpoint S3*, se requiere de la generación de un token y una clave secreta de acceso².

Para cada paquete de datos descargado sobre el área de estudio correspondiente a una única fecha, se tomó cada una de las bandas que vienen por separado en ficheros .jp2, se escalaron hasta ser todas de 10 metros de resolución, se combinaron en un mismo fichero recortando al área de estudio rectangular, y se almacenó el fichero resultante para su posterior empleo.

Sentinel 3

El objetivo principal de Sentinel-3 es la medición precisa de los océanos, la atmósfera y la superficie terrestre. La misión está compuesta por los satélites Sentinel-3A, lanzado en 2016, y Sentinel-3B, en 2018. Entre sus instrumentos, el que es más relevante para este trabajo es el SLSTR (Sea and Land Surface Temperature Radiometer), encargado de medir la temperatura tanto de la superficie terrestre como oceánica.

A.2.2. CNIG

El Centro Nacional de Información Geográfica (CNIG) provee a través de su centro de descargas rásteres de toda España del Modelo Digital de Superficies (MDS) y del

¹<https://documentation.dataspace.copernicus.eu/APIs/OData.html>

²<https://documentation.dataspace.copernicus.eu/APIs/S3.html>

Modelo Digital de Terreno (MDT), ambos disponibles con resolución de 5 metros por píxel. El MDS ha sido empleado para calcular el Sky View Factor (SVF) usando SAGA GIS.

Además, en la primera iteración mostrada en el anexo C, se han empleado datos del Sistema de Información sobre Ocupación del Suelo de España (SIOSE), disponible también en el portal del CNIG.

A.2.3. OGD Österreich

El gobierno de Austria, a través de su portal de datos OGD (Open Government Data)³, ofrece modelos digitales de superficie de cada estado federado a una resolución de 0,5 m/px. Para el estudio en la ciudad de Graz, se ha descargado el modelo digital de superficie del estado de Estiria empleando su servicio de cobertura web (WCS).

A.2.4. Institut Géographique National

El Instituto Geográfico Nacional de Francia a través de su web de servicios geográficos (Géoservices)⁴, permite la descarga de modelos digitales de superficie de cada uno de los departamentos de Francia con una resolución de 0,5 m/px. Para el estudio de Orleans, se ha descargado el ráster correspondiente al departamento de Loiret.

A.2.5. Datos del ayuntamiento de Zaragoza

El Grupo de Clima, Agua, Cambio Global y Sistemas Naturales del Departamento de Geografía y Ordenación del Territorio de la Universidad de Zaragoza, en colaboración con el Servicio de Medioambiente y Sostenibilidad del Ayuntamiento de Zaragoza, gestiona una red de sensores termohigrométricos compuesta por 21 dispositivos distribuidos en puntos representativos de diversos entornos climáticos y tipologías urbanas, tanto en el núcleo urbano como en su periferia inmediata.

Los datos de temperatura del periodo de estudio han sido obtenidos del portal de datos abiertos del Ayuntamiento de Zaragoza.

A.2.6. Estaciones meteorológicas ciudadanas Netatmo

Netatmo es una empresa que fabrica dispositivos inteligentes para el hogar. Uno de sus productos más destacados es su estación meteorológica, la cual puede conectarse a internet mediante WiFi y publicar datos meteorológicos (como la temperatura y otras

³<https://data.gv.at>

⁴<https://geoservices.ign.fr/>

variables) aproximadamente cada 10 minutos. Estos datos pueden visualizarse a través de su página web.

Además de su visualización, los datos también pueden descargarse mediante su API, cuya licencia permite su uso con fines no comerciales. Trabajos como el realizado por Napoly et al. [17] describen cómo las *Citizen Weather Stations (CWS)* pueden proporcionar datos útiles para estudios como este, una vez han pasado por un proceso de control de calidad.

Los siguientes apartados explican todos los pasos en el proceso de obtención de las diferencias de temperatura a partir de CWS, desde como acceder a los datos de la API hasta el control de calidad y el cómputo de las diferencias.

Obtención de token de autenticación

El token de autenticación o *bearer token* es usado en peticiones HTTP para acceder a recursos protegidos por OAuth 2.0, tal y como establece el estándar RFC 6750⁵.

En el caso de Netatmo, este token se puede obtener mediante (1) la creación de una aplicación en la web de Netatmo, (2) la simulación de una petición a través de la documentación de su API con un usuario registrado, o (3) extrayendo el token directamente de cualquier petición que haga el navegador cuando se usa el mapa interactivo que ofrecen.

En este estudio, se empleó la segunda opción ya que es más cómodo que tener que leer el token directamente de los paquetes, y es más fácil que registrar una aplicación. No obstante, en el futuro si se quiere convertir el trabajo de este estudio en una aplicación real, lo mejor sería crear una aplicación en el portal de Netatmo. Las aplicaciones tienen un límite de 50 peticiones cada 10 segundos y 500 peticiones cada hora.

API endpoints

Todos los puntos de acceso están documentados en la página web de Netatmo⁶, para este estudio se han empleado dos:

- */getpublicdata*: Dadas las coordenadas noreste y sudoeste del rectángulo equivalente al área de estudio, este punto de acceso devuelve información de las estaciones instaladas en ese área. De la información devuelta nos interesan las coordenadas de la estación, así como la dirección MAC de la estación (*device.id*) y la dirección MAC del termómetro (*module.id*).

⁵<https://datatracker.ietf.org/doc/html/rfc6750>

⁶<https://dev.netatmo.com/apidocumentation/weather>

- */getmeasure*: Dadas las direcciones MAC de la estación y el termómetro, y una fecha de inicio y otra de fin, este punto de acceso devuelve los valores de temperatura para ese rango de fechas. De este modo, para cada estación de las obtenidas con el punto de acceso */getpublicdata*, se obtienen los valores de temperatura día a día durante el rango de fechas especificado.

Aproximación a la hora en punto más próxima

Cada sensor Netatmo mide la temperatura a distintos intervalos y a distintas horas, por ello se ha optado por tomar para cada hora en punto del día la muestra más próxima. Por ejemplo, si las muestras más cercanas a las 10:00h han sido tomadas a las 9:53 y a las 10:03, se elegirá esta última. Esto se hace para todas las horas del día durante todos los días en el rango de fechas del estudio. Adicionalmente, cabe mencionar que este paso evita la duplicidad de los datos.

Control de calidad

Este paso permite eliminar cualquier dato erróneo, incompleto o inconsistente que pueda afectar a la toma de decisiones y a los siguientes procesos, como el Kriging.

- Control de calidad **individual**:
 - Valores atípicos: Se descartan todos aquellos valores que estén por debajo de -20°C y por encima de 45°C .
 - Datos inconsistentes (test de pendiente): Se asume que no puede haber cambios bruscos de temperatura de $\pm 10^{\circ}\text{C}$ en una hora. Por tanto, todos aquellos valores que tengan una diferencia con respecto a sus mediciones anteriores o posteriores de más de 10°C serán descartados.
- Control de calidad **grupal**:
 - Análisis estadístico: Se detectan valores atípicos a la distribución de los datos mediante el empleo del *z-score*. Para calcular el Z-Score es necesario sustraer la media de los datos μ a la muestra X , y dividir el resultado entre la desviación estándar σ , como aparece en la fórmula:

$$Z = \frac{X - \mu}{\sigma} \quad (\text{A.1})$$

El z-score permite saber cuántas desviaciones típicas se desvía la muestra de la media. Para este control de calidad, se descartan todos los datos cuyo z-score esté fuera del rango entre -2.32 y 1.64. Estos umbrales han sido

definidos considerando el intervalo de confianza desde el 1 % ($\alpha = 0.01$ en la cola inferior) al 95 % ($\alpha = 0.05$ en la cola superior).


Cabe mencionar que el procedimiento trata de manera más estricta la cola superior del intervalo de confianza. Este criterio se sustenta en estudios como el de Meier et al.[18], que muestran que los espurios en datos de CWS están relacionados con el calentamiento del sensor debido a su localización en áreas sin sombra o influenciado por temperaturas superficiales adyacentes.

- Eliminación de estaciones problemáticas: Se han descartado manualmente aquellas estaciones ubicadas en vías públicas, como parques o calzadas, al considerarse georreferenciadas de forma incorrecta. Además, si los valores eliminados en los apartados anteriores superan el 25 % del total de datos registrados por una estación, esta se considera no fiable y, en consecuencia, también es excluida del análisis.

Cómputo de las diferencias de temperatura

Una vez han pasado el control de calidad, los datos pueden ser empleados para calcular las diferencias de temperatura entre la ciudad y el entorno que la rodea.

Dependiendo de la estación de referencia elegida, la interpolación resultante puede ser muy diferente como se puede ver en la figura A.1. Por ello, se ha optado por tomar como estaciones de referencia todas aquellas que se encuentran fuera de la Z-40, de manera que se calcula la media entre todas ellas a cada hora, y es esa media la que se emplea con cada estación para calcular la diferencia de temperatura.



(a) Estación de referencia en Cuarte de Huerva (b) Estación de referencia en Villamayor de Gállego (c) Estación de referencia en la Venta del Olivar

Figura A.1: Interpolaciones obtenidas calculando las diferencias de temperatura respecto a diferentes estaciones de referencia, y añadiendo SVF, IMD y NDVI como variables predictoras. La localización de la estación se indica con un punto rojo en el mapa.

A.3. Estaciones de referencia

En esta sección se muestran las estaciones Netatmo representadas como puntos rojos sobre el área de estudio de cada ciudad. Los puntos rojos más grandes y numerados denotan las estaciones rurales tomadas como referencia para calcular las diferencias de temperatura.

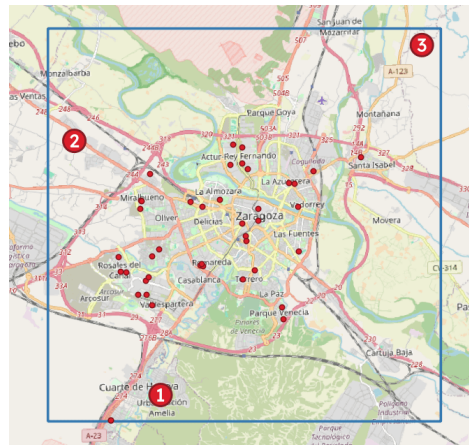


Figura A.2: Área de estudio de Zaragoza con sus respectivas estaciones Netatmo.

Estación 1. Cuarte de Huerva.

Estación 2. La Venta del Olivar.

Estación 3. Villamayor de Gállego.

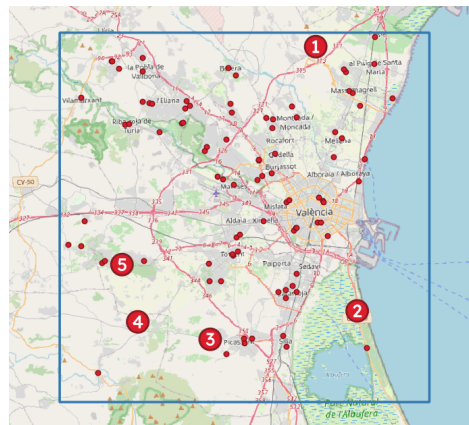


Figura A.3: Área de estudio de Valencia con sus respectivas estaciones Netatmo.

Estación 1. Xalets de Lladró.

Estación 2. Bungalows Park Albufera.

Estación 3. Urbanització El Pedregal.

Estación 4. Urbanització Monte Rosado.

Estación 5. Serra Perenxisa.




Figura A.4: Área de estudio de Sevilla con sus respectivas estaciones Netatmo.
 Estación 1. Dos Hermanas.
 Estación 2. La Puebla del Río.
 Estación 3. Almensilla.
 Estación 4. Camino de Sanlúcar.

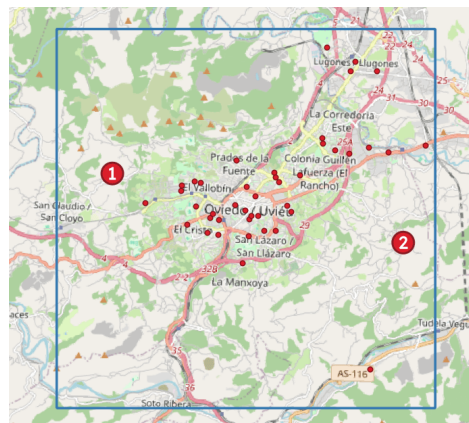


Figura A.5: Área de estudio de Oviedo con sus respectivas estaciones Netatmo.
 Estación 1. Villamar.
 Estación 2. Faro de Baxo.




Figura A.6: Área de estudio de Graz con sus respectivas estaciones Netatmo.
 Estación 1. Schöckl.
 Estación 2. Purgstall bei Eggersdorf.
 Estación 3. Edelsgrub.
 Estación 4. Dobl-Zwaring.




Figura A.7: Área de estudio de Orleans con sus respectivas estaciones Netatmo.
 Estación 1. Saint-Hilaire-Saint-Mesmin.
 Estación 2. Sandillon.
 Estación 3. Chanteau.

A.4. Obtención de variables explicativas

- **Sky View Factor (SVF)**: Es una medida del porcentaje de cielo visible desde un punto en la superficie. Para las ciudades de España, el cálculo se realizó en SAGA GIS a partir del modelo digital de superficie con una resolución de 5 m/píxel, descargado del CNIG. En el caso de Graz y Orleans, los respectivos rásteres de SVF se generaron utilizando la misma herramienta, pero reescalando previamente sus modelos digitales de superficie de 0,5 m/px a 5 m/px.

- **Modelo Digital de Terreno (MDT)**

Un Modelo Digital de Terreno (MDT) representa la elevación del terreno excluyendo objetos como edificaciones y vegetación. El ráster empleado tiene una resolución de 5m/px y ha sido descargado del CNIG.

- **Imperviousness Density (IMD)**: Representa la densidad de superficies impermeables en un área, como carreteras, edificios y pavimentos. Se expresa como un porcentaje y es un indicador clave en estudios de urbanización, drenaje pluvial y calidad del agua, ya que influye en la escorrentía y la infiltración del agua en el suelo. Se obtuvo directamente del portal de Copernicus.

- **Green Leaf Index (GLI)**

Propuesto por Louhaichi et al.[19], el Green Leaf Index es un índice de vegetación diseñado para evaluar la presencia y densidad de vegetación utilizando imágenes en el espectro visible, específicamente las bandas roja, verde y azul (RGB).

$$GLI = \frac{2 \cdot Green - Red - Blue}{2 \cdot Green + Red + Blue} \quad (A.2)$$

- **Normalized Difference Vegetation Index (NDVI)**: Es un índice utilizado para analizar la cobertura vegetal y la salud de la vegetación. Se calcula a partir de la reflectancia en las bandas del infrarrojo cercano (NIR) y el rojo (RED) de Sentinel-2, mediante la fórmula:

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (A.3)$$

Valores altos indican vegetación saludable, mientras que valores bajos sugieren poca o ninguna vegetación.

- **Normalize Difference Turbidity Index (NDTI)**

El Índice de Turbidez de Diferencia Normalizada (NDTI, por sus siglas en inglés) es una herramienta de teledetección utilizada para estimar la turbidez en cuerpos de agua. La turbidez se refiere a la claridad óptica del agua y está influenciada por

la presencia de sedimentos suspendidos, algas u otros contaminantes. El NDTI fue propuesto por Lacaux et al.[20] y se calcula utilizando las bandas espectrales roja y verde de imágenes satelitales, aplicando la siguiente fórmula:

$$NDTI = \frac{Red - Green}{Red + Green} \quad (A.4)$$

– **Normalized Built-up Area Index (NBAI)**

El Índice de Área Construida Normalizada (Normalized Built-up Area Index, NBAI) propuesto por Waqar et al.[21] es un índice espectral utilizado en teledetección para identificar y cuantificar áreas urbanizadas o construidas en imágenes satelitales.

$$NBAI = \frac{SWIR2 - \frac{SWIR1}{Green}}{SWIR2 + \frac{SWIR1}{Green}} \quad (A.5)$$

– **LST extraído de Landsat-9**

Para obtener la temperatura de la superficie terrestre (Land Surface Temperature, LST), se ha optado por la banda 10 (Thermal Infrared - TIR1) proveniente del sensor *Thermal InfraRed Sensor* (TIRS) de Landsat 9. Esta banda tiene una resolución espacial de 30 m, pese a que en la descripción del producto debería ser de 100 m⁷. En la tesis de Samuel Barrao, se emplearon datos de Landsat-8, pero de acuerdo a la documentación Landsat-9 tiene un sensor térmico más preciso, por eso se ha elegido.

⁷<https://www.usgs.gov/landsat-missions/landsat-9>

A.5. Kriging universal

A.5.1. Variograma

El variograma es un concepto clave en geoestadística que describe la dependencia espacial de un campo aleatorio. Cuantifica la disimilitud entre valores observados en dos ubicaciones diferentes, como una función de la distancia de separación espacial entre ellas.

Variograma empírico

El variograma empírico es una estimación del variograma basada en datos observados. Se calcula promediando las diferencias cuadradas entre puntos de datos a una distancia de separación especificada, h :

$$\gamma(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(x_i) - Z(x_i + h)]^2 \quad (\text{A.6})$$

Donde $N(h)$ es el número de pares de puntos de datos separados por la distancia h , y $Z(x_i)$ es el valor del campo aleatorio en la ubicación x_i .

Modelo de variograma

Dado que el variograma empírico no puede proporcionar la semivarianza para cada distancia h , es necesario aproximar un variograma continuo con una función modelo. Esto permite una estimación suave de la dependencia espacial en todas las distancias. En este estudio, se ha empleado el método *autofitVariogram* del paquete *automap* de R para encontrar la función de variograma que mejor se ajusta a los datos. Se evaluaron diferentes modelos: esférico, exponencial, gaussiano y Matérn. Tras la comparación, el modelo que presentó el mejor ajuste fue el esférico.

Efecto pepita

Idealmente, cuando la distancia entre dos puntos de muestreo es 0 ($h = 0$), la varianza debería ser nula porque deberían estar midiendo el mismo fenómeno. No obstante, en la práctica, los sensores no son perfectos, puede haber ruido en las mediciones o existir variabilidad a escalas muy pequeñas. Por ejemplo, en pocos metros se puede pasar de una zona arbolada con un cuerpo de agua que aporta frescor a un área expuesta al sol con una fábrica que emite calor.

Las imperfecciones de los sensores se acentúan especialmente cuando tratamos con sensores amateur, como los de las estaciones Netatmo. En estos casos, además, la calidad de los datos depende en gran medida de que el usuario coloque el sensor en una




Figura A.8: Modelo de variograma esférico que muestra el efecto pepita, la meseta y el alcance.

ubicación adecuada [7], es decir, en el exterior, protegido de la radiación solar directa y de fuentes de calor anómalas, como unidades de aire acondicionado. Por este motivo, resulta fundamental implementar un control de calidad que permita detectar y corregir estas deficiencias, como el descrito en la subsección A.2.6.

A.5.2. Kriging universal

El kriging universal extiende el kriging ordinario al incorporar un componente de tendencia determinista en el modelo. Esto permite modelar fenómenos espaciales que presentan una media variable en lugar de constante. En kriging universal, el valor observado en una ubicación \mathbf{x} se modela como la suma de una tendencia determinista y un residuo estocástico:

$$Z(\mathbf{x}) = m(\mathbf{x}) + \varepsilon(\mathbf{x}) \quad (\text{A.7})$$

Aquí, $m(\mathbf{x})$ es la función de tendencia, que típicamente se expresa como una combinación lineal de funciones base conocidas, y $\varepsilon(\mathbf{x})$ es un término residual estocástico de media cero con dependencia espacial.

La tendencia se modela como:

$$m(\mathbf{x}) = \sum_{k=1}^K f_k(\mathbf{x})\beta_k = \mathbf{f}^\top(\mathbf{x})\boldsymbol{\beta} \quad (\text{A.8})$$

donde $\{f_k(\mathbf{x})\}_{k=1}^K$ son funciones conocidas, β_k son coeficientes desconocidos que deben estimarse, y $\mathbf{f}(\mathbf{x})$ es el vector de funciones base evaluado en la ubicación \mathbf{x} .

El predictor del kriging universal en la ubicación \mathbf{x}_0 es nuevamente una combinación lineal de observaciones:

$$Z^*(\mathbf{x}_0) = \sum_{i=1}^n \lambda_i Z(\mathbf{x}_i) \quad (\text{A.9})$$

Sin embargo, los pesos de kriging λ_i deben satisfacer un conjunto de restricciones que garantizan que el predictor sea insesgado no solo globalmente, sino también con respecto al modelo de tendencia. Estas restricciones tienen la forma:

$$\sum_{i=1}^n \lambda_i f_k(\mathbf{x}_i) = f_k(\mathbf{x}_0) \quad \text{para } k = 1, \dots, K \quad (\text{A.10})$$

Para resolver los pesos, se construye el siguiente sistema ampliado de ecuaciones, que incorpora tanto las semivarianzas como las funciones base:

$$\begin{bmatrix} \Gamma & F \\ F^\top & 0 \end{bmatrix} \begin{bmatrix} \boldsymbol{\lambda} \\ \boldsymbol{\mu} \end{bmatrix} = \begin{bmatrix} \boldsymbol{\gamma}_0 \\ \mathbf{f}(\mathbf{x}_0) \end{bmatrix} \quad (\text{A.11})$$

donde:

- Γ es la matriz $n \times n$ de semivarianzas $\gamma(\mathbf{x}_i, \mathbf{x}_j)$,
- F es la matriz $n \times K$ cuyo elemento (i, k) es $f_k(\mathbf{x}_i)$,
- $\boldsymbol{\gamma}_0$ es el vector de semivarianzas entre cada ubicación conocida \mathbf{x}_i y la ubicación de predicción \mathbf{x}_0 ,
- $\boldsymbol{\mu}$ es un vector de multiplicadores de Lagrange que imponen las restricciones de insesgadez con respecto a la tendencia.

Resolver este sistema proporciona los pesos óptimos de kriging $\boldsymbol{\lambda}$ y los multiplicadores $\boldsymbol{\mu}$. La predicción $Z^*(\mathbf{x}_0)$ se puede calcular entonces usando la suma ponderada de las observaciones, de manera similar al kriging ordinario, pero teniendo en cuenta la tendencia espacial de los datos.

A.6. Métricas de evaluación

A.6.1. Error cuadrático medio

El Error Cuadrático Medio, o *Mean Squared Error (MSE)* en inglés, es una métrica utilizada para medir la diferencia entre los valores predichos por un modelo y los valores reales (observados). Se calcula como el promedio del cuadrado de las diferencias entre los valores reales y los valores predichos.

Su fórmula es:

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

donde:

- n es el número total de observaciones,
- y_i es el valor real de la observación i ,
- \hat{y}_i es el valor predicho por el modelo para la observación i .

En algunos casos, se ha utilizado el *Root Mean Squared Error (RMSE)*, que se obtiene como la raíz cuadrada del *Mean Squared Error (MSE)*. Esta transformación facilita la interpretación del error, ya que el RMSE conserva las mismas unidades que los datos originales, a diferencia del MSE, cuyas unidades están al cuadrado.

A.6.2. Índice de similitud estructural

El *Structural Similarity Index Measure (SSIM)* o Índice de Similitud Estructural es una métrica utilizada para medir la **similitud entre dos imágenes**. A diferencia de otras métricas como el MSE (Mean Squared Error) o PSNR (Peak Signal-to-Noise Ratio), el SSIM busca imitar la percepción visual humana evaluando no solo diferencias de píxeles, sino también aspectos estructurales.

El SSIM compara tres componentes clave:

- **Luminancia:** Evalúa las diferencias en brillo.
- **Contraste:** Evalúa la variación de intensidades.
- **Estructura:** Evalúa los patrones locales de los píxeles.

La fórmula del SSIM entre dos ventanas de imagen x e y es:

$$\text{SSIM}(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (\text{A.12})$$

donde:

- μ_x y μ_y son las medias de las imágenes x e y .
- σ_x^2 y σ_y^2 son las varianzas de x e y .
- σ_{xy} es la covarianza entre x e y .
- C_1 and C_2 son constantes para estabilizar la división.

El valor del SSIM varía entre -1 y 1 . Un valor de $SSIM$ igual a 1 indica una similitud estructural perfecta entre las imágenes, mientras que valores cercanos a 0 indican una baja similitud. Por otro lado, valores próximos a -1 indican una similitud estructural negativa.

También, cabe mencionar que antes de poder calcular el SSIM, hay que normalizar ambas imágenes en valores entre $[0, 1]$, de lo contrario los valores resultantes no saldrían en el intervalo deseado $[-1, 1]$.

Anexos B

Tabla de correlaciones

Como se ha explicado en el capítulo de trabajo realizado, en la sección sobre el modelo de Kriging, la resolución a la que se muestrean las variables explicativas en las coordenadas de cada estación de temperatura influye a la hora de calcular el variograma, puesto que las correlaciones cambian.

La tabla B.1 contiene las correlaciones obtenidas entre las seis variables explicativas consideradas y las diferencias de temperatura para las cuatro áreas de estudio. Estas correlaciones son las que se han empleado para decidir a qué resolución se han de muestrear los valores de los rásteres, por ello los valores de SVF y GLI de la resolución elegida se muestran en negrita, al guardar una correlación más fuerte y negativa.

Variable	Zaragoza		Sevilla		Valencia		Oviedo	
	5m/px	100m/px	5m/px	100m/px	5m/px	100m/px	5m/px	100m/px
SVF	-0.3015346	-0.2068422	0.3103127	-0.2234052	-0.228521	-0.07147124	0.3471606	-0.17214
GLI	-0.3226988	0.3475765	-0.08828164	-0.5454752	-0.1010363	-0.0176476	0.1902491	0.1674414
NBAI	-0.3205202	0.3211095	0.01538875	0.0868861	-0.0402149	0.07305583	-0.307606	-0.1062826
NDTI	0.3657558	-0.3520575	0.1364883	0.4609941	0.141991	0.0662343	-0.3237846	-0.1458961
MDT	0.1303409	-0.0709781	-0.5406058	-0.5406058	-0.3231398	-0.3165313	-0.09202482	-0.07787904
LST	0.03735311	-0.2411829	-0.003956157	-0.07630226	0.2224888	-0.02199545	-0.2866859	0.06836857

Tabla B.1: Correlación entre cada variable predictora y las diferencias de temperatura teniendo en cuenta dos resoluciones (5m/px y 100m/px) en 4 ciudades distintas.

Anexos C

Detección de islas de calor exclusivamente con imágenes satelitales

Inicialmente se pensó en crear un sistema que permitiese crear un mapa de la isla de calor urbana de Zaragoza, como el que hay subido en la página web del ayuntamiento, mediante imágenes satelitales sin necesidad de contar con una red de estaciones meteorológicas instaladas.

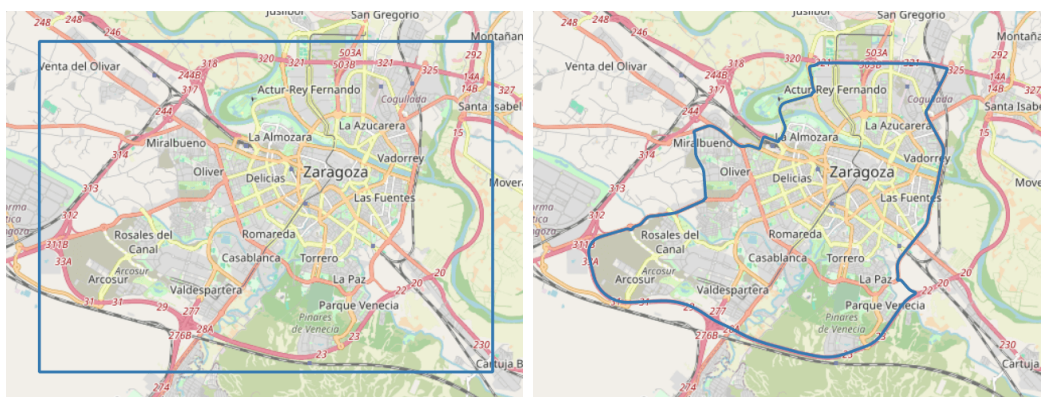
El primer paso consistió en delimitar el periodo y el área de estudio. El periodo abarca todo el verano meteorológico y coincide con el que se muestra en el anexo A sobre fundamentos previos.

Por otra parte, respecto al área de estudio se crearon dos *shapefiles* en QGIS, como se puede apreciar en la figura C.1. Uno con forma rectangular que incluye toda la Z-40 y áreas adyacentes, y otro que solo incluye las zonas más edificadas dentro de la Z-40 y los pinares de Venecia.

El propósito de tener un área de estudio que delimite exclusivamente los espacios urbanos es poder centrar el estudio en aquellas zonas en las que habitan personas, ya que la caracterización de la isla de calor tiene que ir encaminada a mejorar la vida en las zonas en las que ocurre.

C.1. Sentinel-2

En esta primera iteración no se tenía claro todavía qué fuente de información elegir. Se optó Sentinel-2 para realizar el estudio porque la resolución de la mayoría de sus bandas es de 10m/px frente a los 30m/px que tienen las bandas de Landsat 8. Además la frecuencia de paso es de 5 días en comparación a los 16 días de Landsat 8.



(a) Shapefile rectangular

(b) Shapefile con la zona edificada

Figura C.1: Áreas de estudio.

C.2. ¿Qué banda emplear para clasificar la isla de calor urbano?


C.2.1. Clustering

Estudios de la isla de calor, como el de la web del ayuntamiento de Zaragoza, muestran las diferencias de temperatura agrupadas en clústeres, de manera que determinados rangos de temperatura son convertidos a un color predefinido. Por ejemplo, el rango $(-0.5, 0.0)$ podría ser representado con un azul claro para indicar que la temperatura está ligeramente por debajo de la estación de referencia, mientras que un valor en el rango $(-1.0, -0.5)$ se podría indicar con un azul más oscuro para indicar que la diferencia de temperatura es superior a la del rango anterior.

Para poder ver qué banda podía agrupar mejor las distintas zonas afectadas por la isla de calor, se empleó el algoritmo K-Means para clusterizar las bandas seleccionadas en 4 clústeres. Las bandas seleccionadas son la roja, NIR, SWIR1 y SWIR2, ya que son las más próximas a las bandas termales, y han sido empleadas para detectar actividad volcánica y otro tipo de actividades que impliquen una fuente de calor. El número de 4 clústeres ha sido seleccionado usando el método del codo.

Cabe mencionar que antes de aplicar el algoritmo de clusterización u otros como PCA, se ha realizado una media de cada banda a lo largo del periodo de estudio para suavizar variaciones temporales y obtener una imagen más estable.


Como se ve en la figura C.2, la banda roja permite clasificar aquellas zonas cercanas a cuerpos de agua y zonas cubiertas por vegetación, en este caso la huerta del valle del Ebro y los pinares de Venecia. Sin embargo, no es útil porque las zonas urbanizadas del centro de la ciudad aparecen en la misma clase que partes del suelo desnudo o estepario que rodea a la ciudad por el sur.



(a) Banda roja

(b) Banda roja agrupada en 4 clases

Figura C.2: Clustering de la banda roja



(a) Banda NIR


(b) Banda NIR agrupada en 4 clases

Figura C.3: Clustering de la banda de infrarrojo cercano (NIR)

Por otra parte, en la figura C.3, se puede ver como los cuerpos de agua (río Ebro y el lago de Casablanca) quedan agrupados en un único clúster. Además, en la clase rosa queda agrupado el núcleo de la ciudad, tanto la zona urbanizada como los pinares de Venecia. Esto es una mejora sustancial respecto al agrupamiento de la clase roja, pero todavía es mejorable.

Al igual que con NIR, al aplicar K-Means sobre la banda SWIR1 los cuerpos de agua quedan agrupados en una clase separada del resto, como se ve en la figura C.4. Sin embargo, las clases amarilla y naranja quedan distribuidas por todo el área de estudio, sin dar una idea clara de dónde está la isla de calor.


Finalmente, se analizó la banda SWIR2, que al igual que la banda roja, posiciona en la misma clase las zonas con vegetación o cuerpos de agua. Además, en las clases



(a) Banda SWIR1

(b) Banda SWIR1 agrupada en 4 clases

Figura C.4: Clustering de la banda de infrarroja de onda corta 1 (SWIR1)



(a) Banda SWIR2

(b) Banda SWIR2 agrupada en 4 clases

Figura C.5: Clustering de la banda de infrarroja de onda corta 2 (SWIR2)


rosa y naranja quedan las zonas edificadas de la ciudad donde el efecto de isla de calor puede ser mayor. Por ello, se ha decidido analizar más en profundidad esta banda para determinar si puede ser útil para identificar la isla de calor en un entorno urbano.

C.2.2. Análisis de Componentes Principales

El análisis de componentes principales (PCA en inglés) ha sido empleado por varios estudios como en la tesis de Daniel Eric Sangines Coral [23], sobre imágenes de temperatura superficial terrestre (TST).


Se probó a extraer las componentes principales de las bandas NIR y SWIR2. No obstante el resultado no ha sido como el que aparece en el estudio anteriormente mencionado. Las figuras C.6 y C.7 muestran las dos componentes más principales que

explican la mayoría de la varianza después de aplicar el algoritmo de PCA sobre las bandas NIR y SWIR2 respectivamente.



(a) Componente 0 (explica el 90.01 % de la varianza). (b) Componente 1 (explica el 1.59 % de varianza).

Figura C.6: PCA sobre banda NIR.



(a) Componente 0 (explica el 91.9 % de la varianza). (b) Componente 1 (explica el 1.78 % de varianza).

Figura C.7: PCA sobre banda SWIR2.

C.2.3. Series temporales

Con el único dato de temperatura que se tenía a disposición en ese momento, proveniente de la estación de AEMET en el aeropuerto de Zaragoza, se procedió a comprobar si existía correlación entre temperatura ambiental y las bandas que parecen clasificar mejor la isla de calor, NIR y SWIR2.




Figura C.8: Serie temporal. Temperatura (en azul) vs. NIR (en rojo).

La figura C.8 muestra la temperatura registrada en la estación de AEMET a la misma hora y día de los que se tienen imágenes satelitales de Sentinel-2. A su vez, para las coordenadas de la estación meteorológica, se muestra el correspondiente valor de la banda NIR. Como se puede observar, no hay una correlación clara. De hecho, hay días como el día 29 de junio de 2023, en que mientras la temperatura baja el valor de NIR sube; o días como el 29 de julio de 2023, en el que ambos valores suben. Con SWIR2, los resultados tampoco guardaban correlación.

Más adelante, en la sección C.4, se emplean otras técnicas para analizar la correlación entre temperatura y bandas.

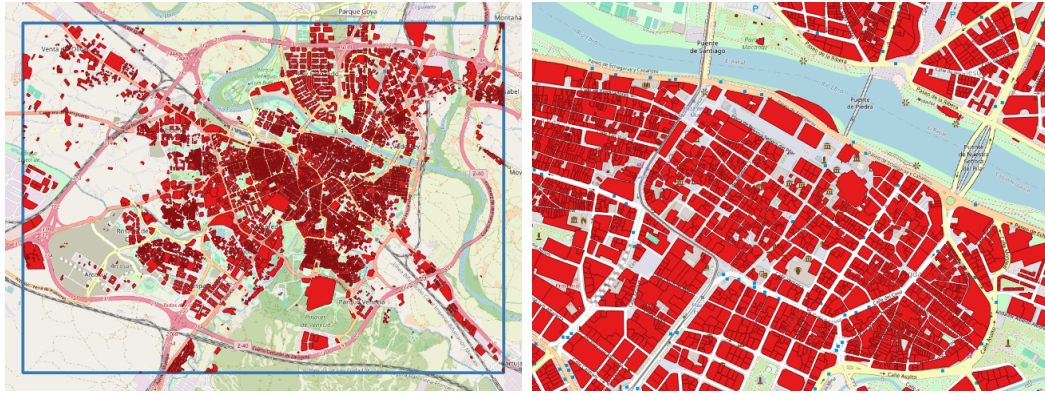
C.3. Exclusión de edificios

Como este estudio ha de ser comparable a estudios similares realizados sobre el terreno, se procedió a detectar todos aquellos espacios en los que no se pueden tomar mediciones a nivel de campo, los cuales corresponden a edificios residenciales, comerciales, de oficinas, fábricas,... etc.

Para ello, se recurrió al Sistema de Información de Ocupación del Suelo de España (SIOSE), el cual tiene a disposición el producto SIOSE AR (Alta Resolución) con datos del suelo en España del año 2017. Del producto descargado, se tomó de la zona de estudio todas aquellas formas etiquetadas como “Producción secundaria”, “Producción de energía”, “Servicios comerciales”, “Servicios financieros, profesionales y de información y otras actividades del sector terciario”, “Servicios a la comunidad”, “Infraestructuras hidráulicas y de aguas residuales” o “Uso residencial”.

Después se combinaron en un GeoPackage (“zaragoza_buildings.gpkg”) para su

posterior uso. La figura C.9 muestra los edificios identificados.



(a) Vista general de los edificios en el área de estudio rectangular (b) Detalle de los edificios en el casco histórico

Figura C.9: Edificios de Zaragoza.


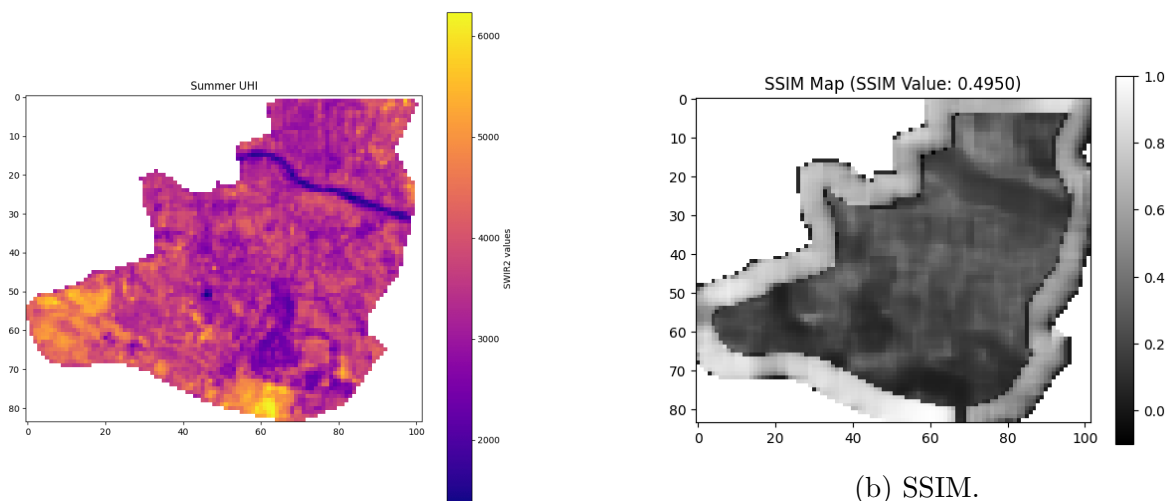


Figura C.10: Isla de calor media de verano de 2023 (recortada).

Para poder comparar los resultados, se procedió a recortar el ráster de la web del ayuntamiento de Zaragoza (isla de calor de referencia) con el shapefile de la zona edificada. El resultado se muestra en la figura C.10.

Antes de realizar la comparación, se tuvo que reescalar el ráster SWIR2 de 10m/px a 100m/px, por ello los huecos creados al eliminar los edificios fueron rellenados en su mayoría por los píxeles adyacentes correspondientes a espacios abiertos. Sin embargo, en zonas consideradas como un único edificio todavía se perciben huecos, este es el caso del cementerio de Torrero.

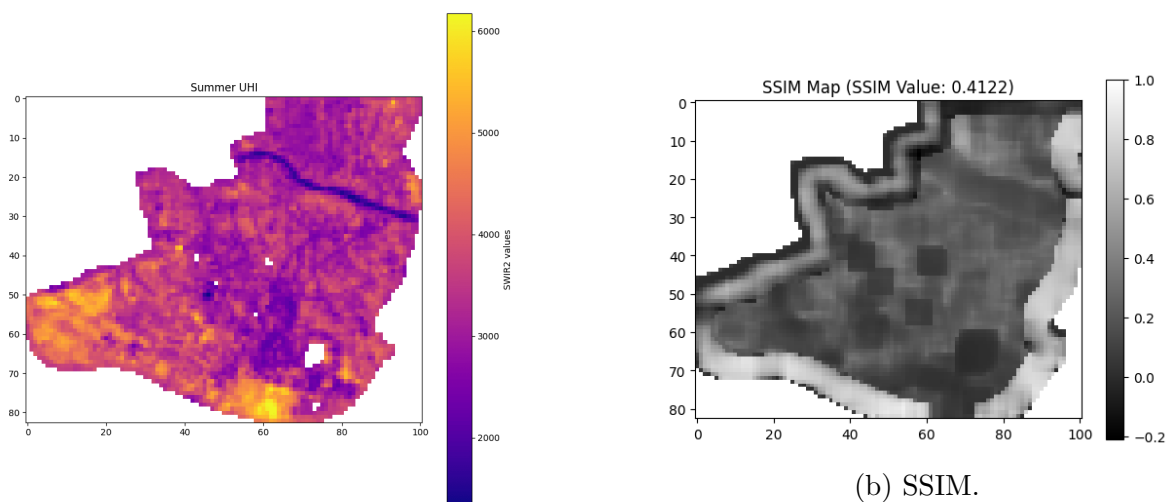
La figura C.11.b muestra la similaridad entre SWIR2 y el ráster de referencia, obteniendo un SSIM global de toda la imagen de 0,495. Excluyendo los bordes, se



(a) Banda SWIR2 recortada.

Figura C.11: Banda SWIR2 (izquierda) y comparación mediante SSIM entre la banda SWIR2 y el ráster de isla de calor de la web del ayuntamiento de Zaragoza.

puede ver que las zonas con mayor disimilaridad son el área aledaña al río Ebro y la parte sur de la ciudad (Arcosur y entorno del centro comercial Puerto Venecio). Mientras que los distritos de Delicias, Universidad, Centro, Casco Histórico y San José llegan a tener valores de SSIM de hasta 0,6.



(a) Banda SWIR2 sin edificios recortada.

Figura C.12: Banda SWIR2 sin edificios (izquierda) y comparación mediante SSIM entre la banda SWIR2 sin edificios y el ráster de isla de calor de la web del ayuntamiento de Zaragoza.

Por otra parte, la figura C.12 repite el mismo experimento pero empleando la banda SWIR2 sin edificios. No obstante, el resultado global es peor que sin eliminar los edificios, obteniendo un SSIM global de 0.4122 en comparación al anterior 0,495. Esto es en parte debido, a que los huecos como el del cementerio de Torrero resultan

en un SSIM de 0, es decir, con completa disimilaridad respecto al ráster de referencia.

Como los resultados no son concluyentes, en la siguiente sección se comprueba si existe correlación entre SWIR2 y la temperatura.

C.4. Correlación entre temperatura y SWIR2

Para poder conocer la temperatura de una superficie, lo cual podría proporcionar detalles sobre la isla de calor superficial, se pensó en emplear directamente la banda TIR provista por Landsat 8 y 9. Sin embargo, esta banda tiene una resolución espacial de 100m, por lo que no resulta adecuada para estudiar el efecto de isla de calor calle a calle.

Inspirados por varios estudios sobre el uso de SWIR (Short-Wave Infrared) para cartografiar anomalías térmicas de volcanes[13] o para disagregar imágenes de infrarrojo térmico[12], se probó a emplear las bandas SWIR de Sentinel-2, que tienen una mayor resolución espacial que las TIR de Landsat, en concreto la resolución es de 20m.




Figura C.13: Bandas Sentinel-2. Fuente: <https://blogs.fu-berlin.de/reseda/sentinel-2/>

Además, de las dos bandas SWIR de las que dispone Sentinel-2, SWIR2 es la que más cerca se encuentra de las bandas térmicas TIR, como se puede apreciar en la imagen C.13, con una longitud de onda central de 2190nm.

C.4.1. Correlación con temperatura ambiente

Para poder estudiar la correlación, los datos de temperatura se han extraído del portal de datos abiertos del Ayuntamiento de Madrid ¹, en el periodo comprendido entre el 1 de junio de 2023 y el 31 de agosto de ese mismo año.

De cada uno de los días de verano de los que tenemos valores de SWIR2 de Sentinel-2, se han tomado los valores de temperatura de las estaciones a la misma hora aproximada (11 AM UTC, que equivale a las 12 AM de Madrid).

En la figura C.14 se muestran los valores de temperatura y de SWIR2 correspondientes a la estación 36 tomados a las misma hora durante los días de estudio.

¹<https://datos.madrid.es/portal/site/egob>




Figura C.14

Como se puede apreciar, el coeficiente de Pearson es bajo en comparación con otras variables que se han tenido en cuenta en el estudio, lo cual también sucede con el resto de estaciones de Madrid. Esto sugiere que SWIR2 no es una variable relevante para poder determinar la temperatura ambiente.

C.4.2. Correlación con temperatura superficial

Un fenómeno relacionado con el del objeto de estudio es el de isla de calor urbano superficial[14], donde en vez de estudiar la isla de calor en base a la temperatura ambiental, se tiene en cuenta la temperatura superficial.

Una primera opción fue utilizar datos de temperatura superficial de Landsat-8, dado que Sentinel-2 carece de banda térmica. Sin embargo, su periodo de muestreo es de 16 días, lo que limita la coincidencia con las imágenes de Sentinel-2. Además, aunque en algunas ocasiones puedan coincidir en el mismo día, las horas de captura suelen diferir.

Por esta razón, se optó finalmente por emplear la banda térmica infrarroja de Sentinel-3, que ofrece una resolución de 1 km. Para aumentar la resolución a 20 m, comparable a la de la banda SWIR2, se aprovechó la correlación inversa entre temperatura y vegetación: a mayor cobertura vegetal, menor temperatura. Este principio permitió escalar el ráster, un procedimiento descrito en detalle en el siguiente artículo². La figura C.15 muestra los rásteres de entrada (NDVI y temperatura LST) y el resultado (ráster de temperatura escalado).

Como se aprecia en la figura C.16, con la temperatura superficial y los valores de SWIR2 para cada una de las estaciones el día 24 de agosto de 2023, se ha obtenido un coeficiente de correlación de Pearson de 0.57, significativamente superior al coeficiente

²<https://towardsdatascience.com/downscaling-a-satellite-thermal-image-from-1000-m-to-10-m-python-3b2ed19ff10>

obtenido con la temperatura ambiental, pero insuficiente para poder detectar islas de calor de manera efectiva. Por ello se descartó esta opción.




Figura C.15: Escalado del ráster temperatura (imagen del medio) empleando NDVI (imagen de la izquierda). El resultado es la imagen de la derecha. Todas las unidades de temperatura están en Kelvin.




Figura C.16: Correlación entre SWIR2 y temperatura superficial (LST) para el día 24 de agosto de 2023.

Anexos D

Sistema para identificar islas de calor urbanas

Este anexo está dedicado al código desarrollado durante todo el proyecto y que permite identificar islas de calor empleando los dos modelos mencionados anteriormente. El código se puede consultar en [este enlace](#). A continuación se especifica cómo preparar el entorno de trabajo y ejecutar el código para que cualquiera pueda replicar los estudios mostrados en este documento o hacer los suyos propios.

D.1. Primeros pasos

En primer lugar, el sistema emplea `poetry` para gestionar sus dependencias, por lo que tendrá que ser instalado antes de continuar. Una vez instalado, se ha de ejecutar `poetry install --no-root` para instalar todas las dependencias mencionadas en `pyproject.toml`. Luego, habrá que ejecutar `eval $(poetry env activate)` para activar el entorno virtual.

D.2. Requisitos previos

D.2.1. Descarga de imágenes Sentinel

En `src/download/sentinel.py`, la constante `product_url` se define conforme a la documentación oficial para localizar productos mediante la API OData de Copernicus. Esta constante puede ajustarse según los requisitos de búsqueda.

Se debe contar con un archivo `.env` en la carpeta raíz para almacenar las variables `ACCESS_TOKEN` y `SECRET_ACCESS_KEY`. Estas credenciales pueden generarse siguiendo la guía correspondiente, lo que permite realizar descargas desde el endpoint S3 de Copernicus.

D.2.2. Área de estudio

Para la detección de una isla de calor urbana (UHI), se debe definir un área de estudio correspondiente a la ciudad de interés utilizando una herramienta GIS o similar, y exportarla como un archivo shapefile en la ruta: `data/[nombre-ciudad]/shapefiles/study_area.shp`.

La cadena `[nombre-ciudad]` debe ser reemplazada por el nombre real de la ciudad analizada. Todos los datos asociados a dicha ciudad se almacenarán en la carpeta `data/[nombre-ciudad]`.

D.2.3. Configuración

Todos los parámetros de configuración están especificados en `config.yaml`, incluyendo configuraciones para el sistema de registro, descarga de datos, procesamiento y control de calidad. También contiene parámetros para el entrenamiento y predicción con redes neuronales convolucionales (CNN), así como para interpolación.

D.3. Flujo de datos

El diagrama mostrado en la figura D.1 describe el proceso completo para detectar islas de calor urbanas. Cada paso debe ejecutarse individualmente, ya que algunos requieren intervención manual o atención especial. Esto también permite, en caso de querer generar un mapa de islas de calor sin usar estaciones meteorológicas, omitir todos los pasos del lado derecho del diagrama que sí requieren datos de estaciones.

D.4. Ejecución

En esta sección se describe el propósito de cada etapa del diagrama de flujo de datos, incluyendo sus requisitos, la salida esperada y la ubicación de los resultados.

Todos los comandos siguen el formato: `python3 main.py -c [nombre-ciudad] -s [nombre-paso]`

La cadena `[nombre-ciudad]` debe ser reemplazada por el nombre de la ciudad analizada. Todos los datos correspondientes a dicha ciudad se almacenan en el directorio `data/[nombre-ciudad]/`.

Nota: Comprender los requisitos de cada paso y cómo se almacenan los resultados permite crear módulos propios e integrarlos en `main.py`.

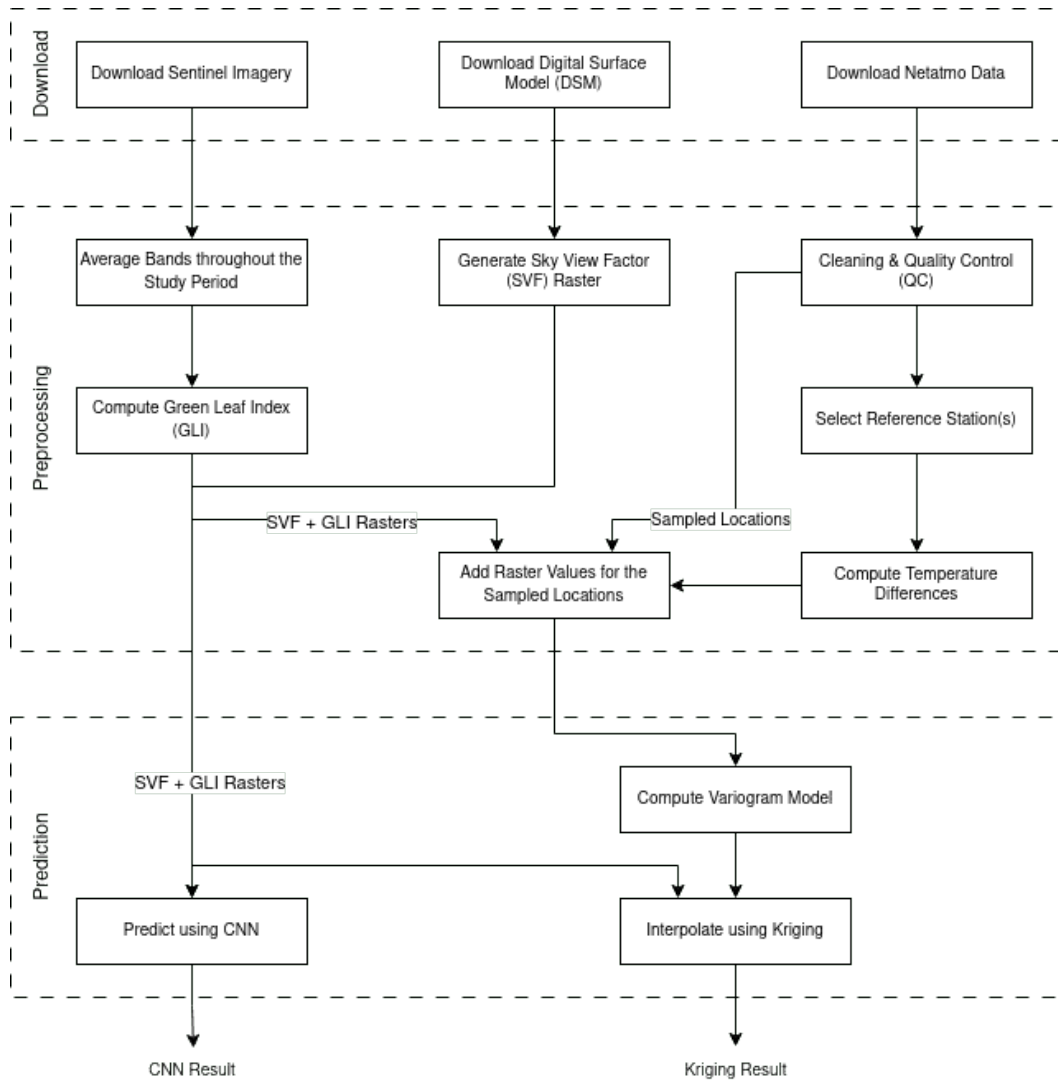


Figura D.1: Diagrama de flujo de datos.

D.4.1. Pasos de descarga

Descargar imágenes Sentinel

Paso automatizado, comando: `python3 main.py -c [nombre-ciudad] -s download-sentinel`

Requisitos: Tokens de acceso para el endpoint S3 de Copernicus (ver sección “Requisitos previos”), un shapefile del área de estudio en `data/[nombre-ciudad]/shapefiles/study_area.shp` o la ruta especificada en `config.yaml`, y un periodo de estudio definido en ese archivo de configuración.

Resultado: Las bandas satelitales descargadas se apilan en un solo archivo por día, recortadas y guardadas en la carpeta `data/[nombre-ciudad]/rasters/sentinel`. Es necesario asegurarse de que los rásters resultantes cubran completamente el área de estudio.

Descargar Modelo Digital de Superficie

Este es un paso manual. El modelo digital de superficie debe guardarse en `data/[nombre-ciudad]/rasters/` como `mds.tif`.

Descargar datos de Netatmo

Paso automatizado, comando: `python3 main.py -c [nombre-ciudad] -s download-netatmo`

Requisitos: Actualiza el token de Netatmo en el archivo `config.yaml` en `download.netatmo.token`. Puedes obtener el token en <https://dev.netatmo.com/apidocumentation/weather>.

Nota: Este token tiene tiempo de expiración. Si tu área de estudio incluye muchas estaciones o cubre un periodo largo, el token podría expirar durante el procesamiento. En tal caso, deberás renovarlo y ejecutar nuevamente el comando.

Resultado: Se crea un archivo CSV para cada estación Netatmo disponible dentro del área y periodo especificados. Cada archivo se nombra con la dirección MAC de la estación (`[MAC address].csv`) y se guarda en `data/[nombre-ciudad]/stations/`. Además, se genera un archivo resumen llamado `netatmo_stations.csv` con las direcciones MAC y coordenadas de todas las estaciones.

D.4.2. Pasos de preprocesamiento

Promediar bandas durante el periodo de estudio

Paso automatizado, comando: `python3 main.py -c [nombre-ciudad] -s average-bands`

Requisitos: Archivos ráster obtenidos en el paso “Descargar imágenes Sentinel”.

Resultado: Por cada banda (por defecto se usan las bandas para índices como GLI: azul, verde, NIR, rojo, SWIR1 y SWIR2), se genera un ráster promedio y se guarda en `data/[nombre-ciudad]/rasters` con el formato `average_[nombre-banda].tif`.

Calcular índice de hoja verde u otros índices

Paso automatizado, comando: `python3 main.py -c [nombre-ciudad] -s compute-gli`

Requisitos: Las bandas promediadas generadas en el paso anterior.

Resultado: Se genera un archivo llamado `gli.tif` en el directorio `data/[nombre-ciudad]/rasters/`.

Nota: Aunque el comando de ejemplo calcula el índice GLI, se pueden especificar otros índices con la opción `-s`:

- `compute-nbai`: Índice Normalizado de Área Construida
- `compute-ndti`: Índice Normalizado de Turbidez
- `compute-ndvi`: Índice Normalizado de Vegetación

Para calcular índices adicionales, simplemente hay que añadir un nuevo archivo `.py` al directorio `src/indices/` y registrarlo en `main.py`.

Generar ráster de Sky View Factor (SVF)

Paso automatizado, comando: `python3 main.py -c [nombre-ciudad] -s compute-svf`

Requisitos: Un archivo ráster DSM llamado `mds.tif` en el directorio `data/[nombre-ciudad]/rasters/`, generado en el paso “Descargar Modelo Digital de Superficie”.

Este paso requiere la herramienta de línea de comandos `saga_cmd`, por lo tanto, SAGA GIS debe estar instalado y ser accesible desde la terminal. En Debian/Ubuntu, puedes instalarlo con: `sudo apt-get install saga`

Resultado: Se genera un archivo llamado `svf.tif` en el directorio `data/[nombre-ciudad]/rasters/`.

Limpieza de temperaturas y control de calidad

Este es un paso automatizado, cuyo comando es: `python3 main.py -c [nombre-de-ciudad] -s perform-temperature-qc`.

Requisitos: Todos los archivos `[dirección-MAC].csv` y el archivo `netatmo_stations.csv` generados durante el paso "Descargar datos de Netatmo".

Resultado: Tras ejecutar el proceso, se generará un nuevo archivo llamado `temperatures.csv` en el directorio `data/[nombre-de-ciudad]/stations/`.

Seleccionar estaciones de referencia

Este es un paso manual. Se debe abrir el archivo `netatmo_stations.shp` generado durante el paso "Limpieza y control de calidad de temperaturas", seleccionar las estaciones de referencia situadas en zonas rurales y añadir sus direcciones MAC al archivo `config.yaml`.

Calcular diferencias de temperatura

Este es un paso automatizado, cuyo comando es: `python3 main.py -c [nombre-de-ciudad] -s compute-differences`.

Requisitos: El archivo `temperatures.csv` generado durante el paso "Limpieza y control de calidad de temperaturas", y las estaciones de referencia indicadas en el archivo de configuración durante el paso "Seleccionar estaciones de referencia".

Resultado: Tras ejecutar el proceso, se generará un nuevo archivo llamado `diffs.csv` en el directorio `data/[nombre-de-ciudad]/stations/`.

Añadir valores de ráster en ubicaciones muestreadas

Este es un paso automatizado, cuyo comando es: `python3 main.py -c [nombre-de-ciudad] -s add-raster-values`.

Requisitos: El archivo `diffs.csv` generado durante el paso "Calcular diferencias de temperatura" y los rásteres de las variables explicativas (`svf.tif` y `gli.tif`) en el directorio `data/[nombre-de-ciudad]/rasters/`. Las variables explicativas que se deben utilizar deben ser declaradas en el archivo `config.yaml`.

Resultado: Tras ejecutar el proceso, se generará un nuevo archivo llamado `full_data.csv` en el directorio `data/[nombre-de-ciudad]/`.

D.4.3. Pasos de entrenamiento y predicción

Ajuste de variograma e interpolación con kriging

Este es un paso automatizado, cuyo comando es: `python3 main.py -c [nombre-de-ciudad] -s predict-with-kriging`.

Requisitos: El archivo `full_data.csv` generado durante el paso "Agregar valores de ráster para las ubicaciones muestreadas". Los rásteres de las variables explicativas (`svf.tif` y `gli.tif`) ubicados en el directorio `data/[nombre-de-ciudad]/rasters/`. Las variables explicativas que se utilizarán deben estar especificadas en el archivo `config.yaml`.

Resultado: El resultado de la interpolación se guardará como `kriging_result.tif` en el directorio `data/[nombre-de-ciudad]/results/`. También se generará un archivo `variogram.png` en el mismo directorio, mostrando el variograma ajustado utilizado durante el kriging. Es recomendable asegurarse de que el variograma está correctamente ajustado; si no lo está, será necesario ajustar los parámetros iniciales y volver a ejecutar este paso.

Predicción con la red neuronal

Este es un paso automatizado, cuyo comando es: `python3 main.py -c [nombre-de-ciudad] -s predict-with-cnn`.

Requisitos: Los archivos `svf.tif` y `gli.tif`, o cualquier otra variable declarada en el archivo `config.yaml`, deben estar almacenados en el directorio `data/[nombre-de-ciudad]/rasters/`. Los pesos del modelo también deben estar ubicados en `src/cnn/checkpoint.pth.tar`.

Resultado: El resultado de la CNN se guardará como `cnn_result.tif` en el directorio `data/[nombre-de-ciudad]/results/`.

Nota: Si la red no ha sido entrenada previamente, y por lo tanto los pesos no están almacenados en `src/cnn/checkpoint.pth.tar`, se debe ejecutar este comando para entrenarla: `python3 main.py -c [nombre-de-ciudad] -s train-cnn`. Debe haberse realizado previamente una interpolación kriging, porque el archivo `interpolation.tif` resultante se utiliza como el objetivo, mientras que las variables explicativas (que deben existir en el directorio `data/[nombre-de-ciudad]/rasters/`) se usan como variables predictoras.

D.5. Notas finales

Este proyecto ha sido diseñado con modularidad en mente. Se puede adaptar cada uno de los pasos para nuevas ciudades, nuevos sensores satelitales, u otros modelos de predicción simplemente modificando la configuración en `config.yaml` y/o ajustando los scripts correspondientes.

Anexos E

Gestión del proyecto

El proyecto ha sido desarrollado durante el curso 2024-2025, abarcando 479 horas de trabajo, las cuales se muestran desglosadas por tarea en la tabla E.1. Adicionalmente, en la figura E.1 se muestra el diagram de Gantt del proyecto.

Tarea	Tiempo (en horas)
Estudio previo	31
1 ^a Aproximación (Detección sin estaciones)	119
Modelo 1 (Kriging)	161
Modelo 2 (CNN)	82
Comparación cruzada	10
Redacción de la memoria	50
Reuniones	26
Total	479

Tabla E.1: Tiempo dedicado al proyecto por tarea

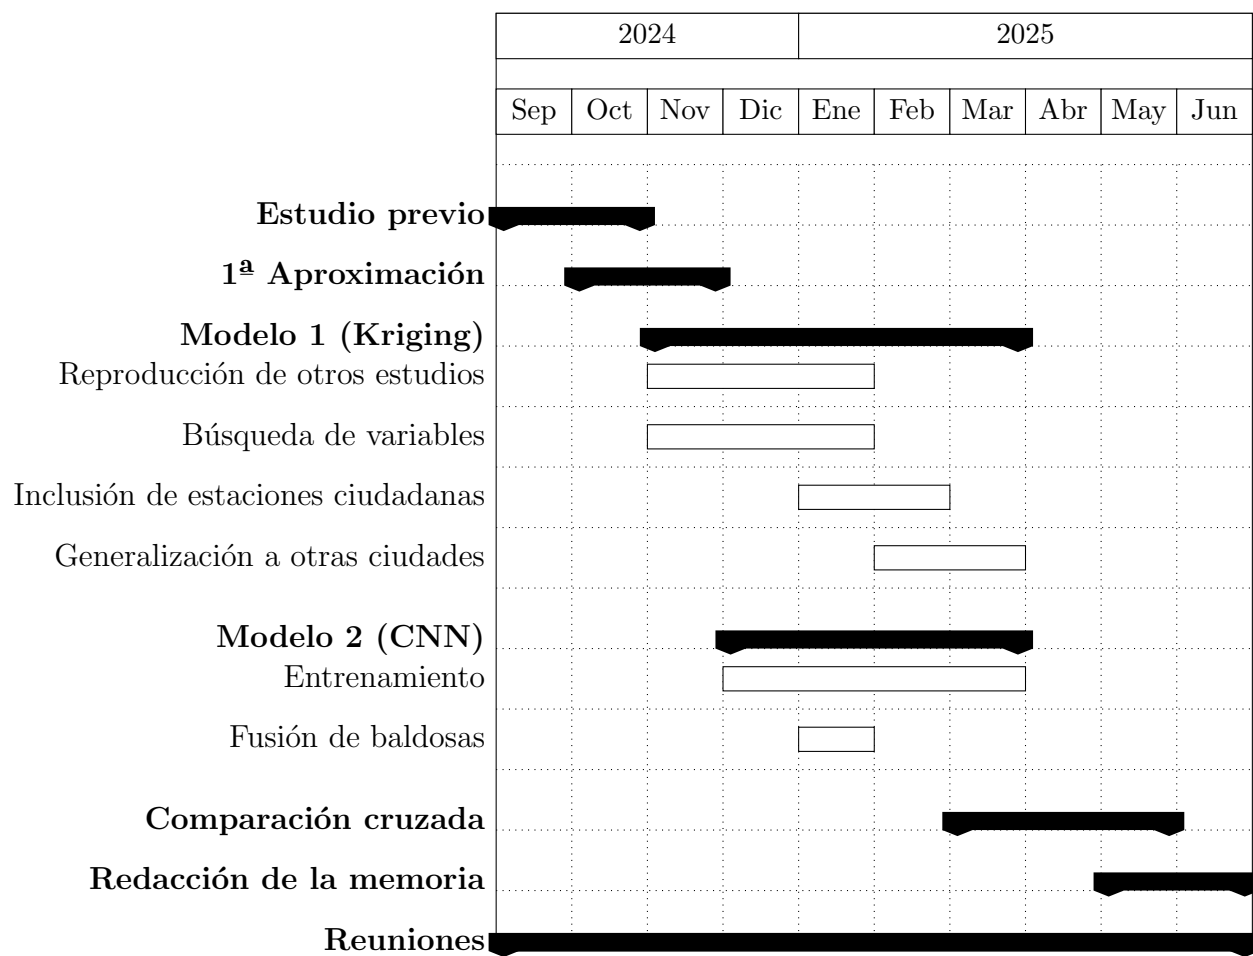


Figura E.1: Diagrama de Gantt del proyecto