

IA explica variación de zonas verdes urbanas en ciudades españolas

AI explains variation of urban green spaces in Spanish cities

Alejandro Carbonell Martínez^a, José Miguel Ferrer Gisbert^b, Juan José García Milla^c, Artur Temporal Coelho^d, Carmen Isabel Sanz Albillo^e, María José González Legidos^f y Alejandro Barón Orozco^g

^aGreen Urban Data SL, gud@greenurbandata.com; ^bGreen Urban Data SL, gud@greenurbandata.com; ^cMilmoh SL, juanjose.milla@milmoh.com; ^dMilmoh SL, artur.temporal@milmoh.com; ^eMilmoh SL, carmen.sanz@milmoh.com; ^fGreen Urban Data SL, gud@greenurbandata.com y ^gGreen Urban Data SL, gud@greenurbandata.com.

How to cite: Carbonell Martínez, A.; Ferrer Gisbert, J.M.; García Milla, J.J.; Temporal Coelho, A.; Sanz Albillo, C.I.; González Legidos, M.J.; Barón Orozco, A. (2025). IA explica variación de zonas verdes urbanas en ciudades españolas. En libro de actas: *XVII Seminario Internacional de Investigación en Urbanismo*. Valencia, 19-20 de junio 2025. <https://doi.org/10.4995/SIIU2025.2025.19773>

Abstract

The paper presents the development and implementation of AI4GreenEquityScore, an artificial intelligence-based model designed to explain variations in urban green coverage across Spanish cities. By leveraging socio-demographic, environmental, and urban planning indicators, the model provides personalized insights to optimize urban green areas. AI4GreenEquityScore employs machine learning methodologies, such as Extra Trees regression, with SHAP value analysis for variable importance, ensuring interpretability and adaptability. This innovation supports decision-making for equitable urban greenery distribution, addressing environmental and social challenges through the model's explanatory power in multiple urban settings.

Keywords: artificial intelligence; urban green areas; decision-making; green equity.

Resumen

Este artículo presenta el desarrollo y la implementación de AI4GreenEquityScore, un modelo basado en inteligencia artificial diseñado para explicar las variaciones en la cobertura verde urbana en las ciudades españolas. Aprovechando indicadores sociodemográficos, medioambientales y urbanísticos, el modelo proporciona información personalizada para optimizar las zonas verdes urbanas. AI4GreenEquityScore emplea metodologías de aprendizaje automático, como la regresión Extra Trees, con análisis de valor SHAP para asegurar una interpretación adecuada de los resultados y una ponderación justificada de su importancia. Esta innovación apoya la toma de decisiones para una distribución equitativa del verde urbano, abordando los retos medioambientales y sociales mediante la capacidad explicativa del modelo en múltiples entornos urbanos.

Palabras clave: inteligencia artificial; zonas verdes urbanas; toma de decisiones; equidad verde

Bloque temático: MAPPING DE CIUDADES Y TERRITORIOS. Cartografías

1. Introducción

La urbanización acelerada ha transformado el paisaje de las ciudades, intensificando los retos relacionados con la calidad ambiental, la equidad social y el bienestar de la población. En este contexto, la Infraestructura Verde Urbana (IVU) se ha posicionado como un componente crucial para abordar estos desafíos. Las zonas verdes urbanas no solo aportan beneficios ambientales como la reducción del efecto isla de calor y la mejora de la calidad del aire, sino que también promueven la cohesión social, la salud mental y la calidad de vida de los residentes. Sin embargo, la distribución desigual de estas áreas genera disparidades significativas en el acceso y aprovechamiento de sus beneficios.

Tradicionalmente, la gestión de la IVU se ha centrado en aspectos ornamentales y técnicos, como el mantenimiento y la estética, dejando de lado un enfoque integral basado en indicadores sociales, económicos y ambientales. La Ley de Restauración de la Naturaleza Europea (LRN) y la Estrategia de Biodiversidad 2030 han introducido un cambio de paradigma al establecer objetivos específicos para la monitorización y mejora de las zonas verdes urbanas, promoviendo su integración como un eje central en las estrategias de desarrollo sostenible.

En este marco, surge este proyecto como una respuesta innovadora para abordar estas necesidades. El modelo combina técnicas avanzadas de inteligencia artificial con un enfoque explicativo que permite identificar y analizar los factores determinantes de la variación de las zonas verdes en distintas ciudades españolas. Esta herramienta busca capacitar a los tomadores de decisiones con información detallada y personalizable, facilitando la planificación estratégica y fomentando una distribución equitativa y sostenible de la IVU.

2. Objetivos

Los objetivos principales que este proyecto pretende alcanzar son:

- **Explicación de la variabilidad del porcentaje de zonas verdes:** Desarrollar un modelo que explique las diferencias en la cobertura verde urbana considerando las particularidades de cada ciudad.
- **Identificación de indicadores clave:** Integrar un conjunto de variables relevantes, como factores socioeconómicos, demográficos y ambientales, que influyen en la distribución de las áreas verdes y muestran cómo cada variable influye en el comportamiento del modelo.
- **Personalización de estrategias:** Diseñar una herramienta adaptativa que permita priorizar intervenciones basadas en indicadores específicos para cada contexto urbano.
- **Justicia ambiental – Equidad Verde:** Proporcionar una herramienta que contribuya a reducir las desigualdades ambientales de acceso y disfrute de zonas verdes en áreas urbanas.
- **Priorización de inversiones:** Identificar y priorizar áreas con mayor necesidad de infraestructura verde para dirigir inversiones, especialmente en áreas vulnerables.
- **Transformación digital en la planificación urbana:** AI4GreenEquityScore introduce avances innovadores en el uso de datos y machine learning en la toma de decisiones urbanas.
- **Optimización de recursos:** Facilita una gestión eficiente de las áreas verdes mediante la identificación de patrones y predicciones sobre su impacto ambiental y social.

3. Desarrollo del Proyecto

El desarrollo del proyecto AI4GreenES ha requerido una metodología integral que combina la recopilación de datos, el análisis mediante IA y la validación en escenarios reales. A continuación, se detallan las fases clave del proceso:

3.1 Definición de la Arquitectura del Sistema

La arquitectura del sistema se basó en una estructura cloud escalable que permite la integración de múltiples fuentes de datos. El sistema se compone de:

- Transformación y análisis de datos: Gestiona la recopilación, procesamiento y almacenamiento de datos. Se diseñó para recibir información de fuentes externas y alimentar el modelo de Inteligencia Artificial.
- Generación del modelo: Esta capa consiste en el entrenamiento y validación del modelo basándose en los datos recopilados y normalizados mediante la aplicación del modelo extra trees en los datos y seguido de pruebas y validaciones. Con todo este proceso, se obtienen los datos de salida y se genera el archivo del modelo que puede ser aplicado posteriormente.
- Base de datos escalable: Optimizada para almacenar grandes volúmenes de datos geoespaciales y sociodemográficos en formato estructurado. Su diseño permite una rápida recuperación de información mediante peticiones, asegurando la disponibilidad y consistencia de los datos en todo momento.

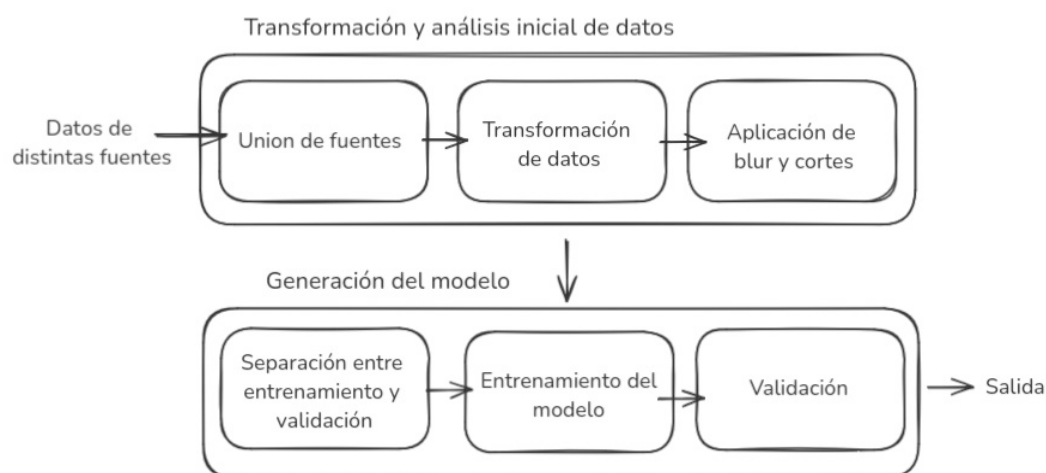


Fig. 1 Arquitectura del sistema. Fuente: elaboración propia

3.2. Análisis y Selección de Datos

La recopilación de datos ha sido un proceso fundamental en el desarrollo del modelo. Se ha trabajado con diversas fuentes oficiales, incluyendo el Instituto Nacional de Estadística (INE), ministerios del gobierno y bases de datos de ayuntamientos. Se han seleccionado indicadores clave, como la renta media, densidad poblacional, porcentaje de población extranjera y temperatura media, los cuales han sido normalizados y procesados para su integración en el modelo.

El proceso de análisis de datos incluyó las siguientes etapas:

- Revisión de literatura y fuentes nacionales: Se examinaron estudios previos y se identificaron las bases de datos más relevantes.
- Categorización de variables agrupadas en las siguientes dimensiones:
 - Demográficas y económicas: Renta media, densidad de población, porcentaje de población extranjera, edad media, porcentaje de población mayor de 65 años, tamaño medio del hogar.

- Ambientales y urbanísticas: Temperatura media, proximidad a zonas verdes, disponibilidad de suelo urbano, tipo de ocupación (residencial, comercial o industrial), etc.
- Cobertura verde: Porcentaje de cobertura verde y valores suavizados mediante la técnica de Blur.
- Transformación de datos: Se aplicaron técnicas de limpieza, normalización y estandarización para garantizar coherencia en los modelos.
 - Aplicación de métodos de "Blur": Esta técnica de suavizado mediante medias ponderadas se ha utilizado para mitigar las variaciones no deseadas en los datos de cobertura verde. Su implementación ha resultado en una reducción significativa de la variabilidad aleatoria, mejorando sustancialmente la estabilidad y aumentando su explicabilidad.
 - Establecimiento de umbrales en valores extremos: Se han aplicado cortes específicos en los valores bajos de cobertura verde (inferiores al 3%), lo que ha permitido una mejora notable en la precisión de las predicciones, especialmente en áreas críticas con menor densidad de vegetación.
- Las variables (indicadores) seleccionadas para la realización del modelo han sido las siguientes:
 - % Cobertura verde
 - Renta Neta Media por Persona
 - Población por Hectárea
 - Porcentaje Población Extranjeros
 - Edad Media de la Población
 - Porcentaje de Población de 65 y más años
 - Tamaño Medio del Hogar
 - Temperatura
 - Proximidad
 - Suelo Urbano
 - Tipo de ocupación (residencial, comercial o industrial)
 - Punto Corte
 - Geográficos
 - NOTA: Los criterios de selección de variables han tenido en cuenta principalmente la disponibilidad de los datos en abierto para las ciudades, y la independencia entre cada una. De un conjunto de 28 variables analizadas se han seleccionado las que tenían mayor influencia en el modelo para el conjunto de ciudades estudiadas. Ej:

| Indicadores | Agrupación indicadores | Categoría |
|----------------------|------------------------|------------------------|
| Población Total | POBLACIÓN | DEMOGRAFÍA Y POBLACIÓN |
| Población por Género | POBLACIÓN | DEMOGRAFÍA Y POBLACIÓN |
| Población por Edad | POBLACIÓN | DEMOGRAFÍA Y POBLACIÓN |
| Nacionalidad | POBLACIÓN | DEMOGRAFÍA Y POBLACIÓN |
| Nacimientos | POBLACIÓN | DEMOGRAFÍA Y POBLACIÓN |
| Defunciones | POBLACIÓN | DEMOGRAFÍA Y POBLACIÓN |

No obstante, se prevé la posibilidad de mejorar el modelo y desarrollarlo de forma personalizada o adaptada a cada ciudad, incluyendo otras variables particularizadas a nivel local que puedan ser de interés.

3.3. Desarrollo y Optimización del Modelo

Se evaluaron diversos algoritmos de IA para identificar el más adecuado. Se escogió la ciudad de Valencia como punto de partida para el entrenamiento y análisis de los modelos iniciales. Esta elección se basó en la disponibilidad de datos representativos y la diversidad de factores urbanos presentes en la ciudad, lo que permitiría una evaluación más completa de los modelos, además del conocimiento experto de la ciudad por parte del equipo que ha desarrollado el proyecto.

Después de numerosas pruebas entre varios modelos de referencia en los estudios de regresión, se seleccionó el modelo Extra Trees debido a su alta precisión y robustez. Este algoritmo permite manejar grandes volúmenes de datos y proporciona resultados interpretables mediante técnicas de análisis de importancia de variables SHAP (SHapley Additive Explanations).

El modelo Extra Trees, cuyo nombre completo es Extremely Randomized Trees, es un algoritmo de aprendizaje automático basado en árboles de decisión, muy parecido a Random Forest, pero con una mayor dosis de aleatoriedad. Es un modelo de ensamblado que combina múltiples árboles de decisión para hacer predicciones más robustas. La diferencia clave entre Extra Trees y Random Forest radica en cómo se generan los árboles de decisión dentro del modelo. Mientras que Random Forest utiliza un muestreo aleatorio de los datos (Bootstrap) y busca la mejor división posible en cada nodo, Extra Trees introduce aún más aleatoriedad: utiliza todos los datos disponibles (sin Bootstrap, por defecto) y, en lugar de buscar la mejor división, elige los puntos de corte de manera completamente aleatoria entre los valores posibles de cada característica. Esta estrategia hace que Extra Trees sea más rápido de entrenar y menos propenso al sobreajuste, aunque a veces con una ligera pérdida de precisión.

El modelo de IA se desarrolló siguiendo las siguientes fases:

- Pruebas de algoritmos de machine learning: Se probaron distintos modelos, como Random Forest, XGBoost y Extra Trees. Se seleccionó Extra Trees por su precisión y capacidad explicativa. El modelo de Extra Trees destacó por su capacidad de adaptarse mejor a la baja cantidad de datos disponibles, generando menos overfitting debido a su aleatoriedad inherente en el proceso de entrenamiento. Esta característica es particularmente valiosa en escenarios con conjuntos de datos limitados. El tipo de modelo, basado en árboles, también permite la realización de análisis de variables de manera más fácil y precisa, por medio del framework SHAP.

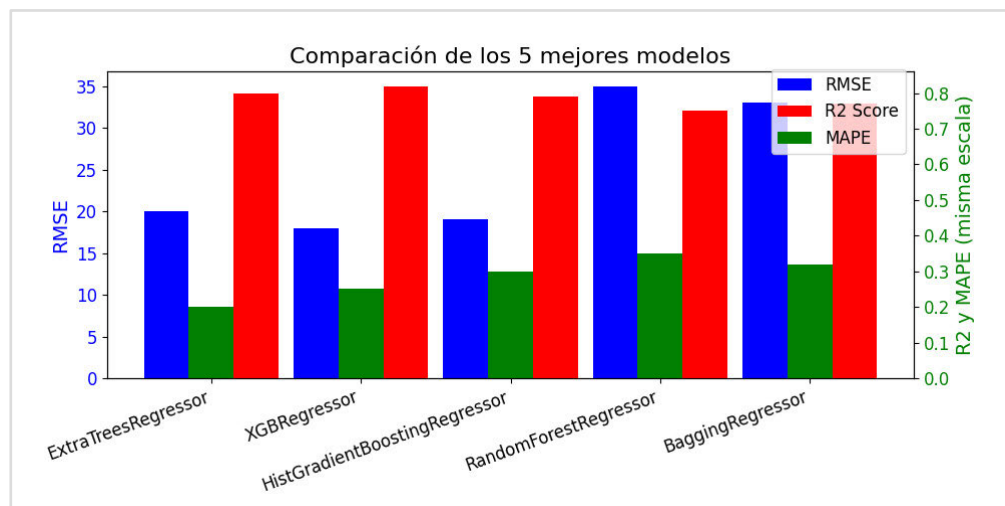


Fig. 2 Comparación de modelos. Fuente: elaboración propia

- Optimización de hiperparámetros: Se utilizó la técnica Grid Search para encontrar la mejor configuración del modelo. Esto permitió mejorar la eficiencia y la precisión del modelo,

asegurando que estuviera optimizado para manejar tanto los datos actuales como futuras variaciones. El enfoque en la optimización fue crucial para maximizar el rendimiento y la capacidad predictiva del modelo y también para aumentar la precisión del análisis de variables por medio de un mayor número de árboles en el bosque obteniendo así una capacidad de replicabilidad y precisión mayor.

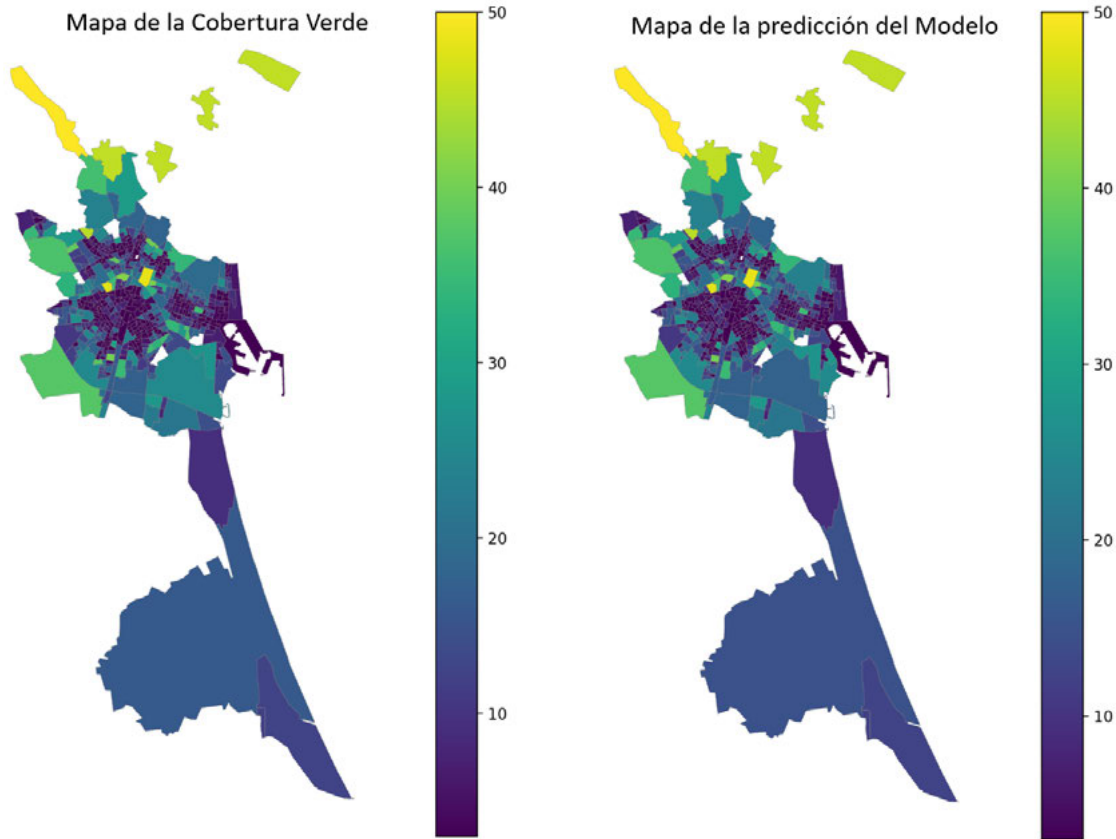


Fig. 3 Modelo Extra Trees sobre la ciudad de Valencia. Fuente: elaboración propia

- Evaluación de importancia de variables: Fue utilizado el framework SHAP para identificar qué factores tienen mayor impacto en las predicciones. Esta técnica permitió entender el impacto de cada variable en las predicciones del modelo, proporcionando una visión clara de los factores más influyentes. Este análisis no solo confirmó la efectividad del modelo, sino que también aportó insights valiosos para posibles mejoras y aplicaciones futuras.

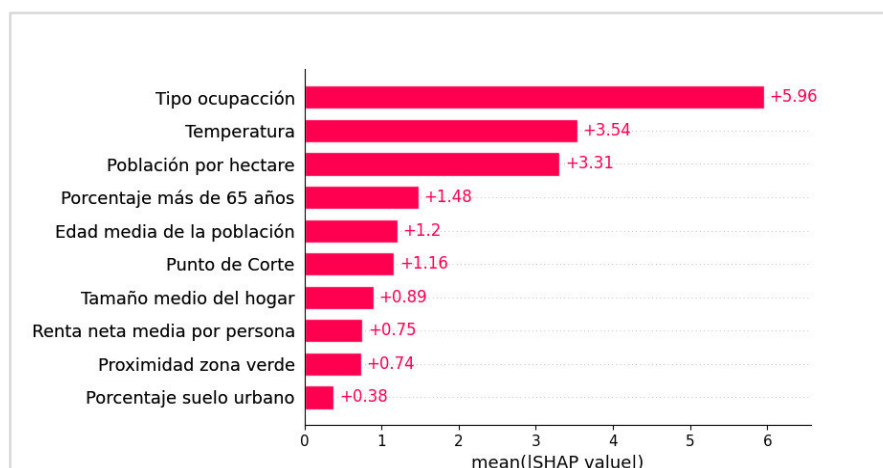


Fig. 4 Análisis SHAP sobre Indicadores seleccionados en la ciudad de Valencia. Fuente: elaboración propia

La figura 4 muestra la importancia de las variables para esta instancia del modelo, es la media de los valores SHAP. Estos valores son calculados con base al modelo, y son la influencia media esperada de la variable en el modelo, o sea, para un valor de la variable, cuánto se espera que el resultado del modelo cambie. Por ejemplo, en este caso, para un valor cualquiera de la temperatura en el dataset utilizado, podemos esperar que la predicción de la cobertura verde sea de 3,54 puntos porcentuales distantes del valor promedio de las predicciones.

3.4. Implementación y Validación

El modelo se implementó en varias ciudades, incluyendo Valencia, Madrid, Barcelona, Zaragoza y Bilbao, entre otras.

Con la finalidad de optimizar la precisión y robustez del modelo, se implementaron estrategias basadas en estadísticas geoespaciales para el procesamiento y ajuste del output obtenido.

Con el empleo para el análisis de métricas MAPE se pretende proporcionar una medida clara del error relativo de las predicciones. En la formulación de esta métrica, la “y” es el valor real, la “p” es la predicción y “n” es el número de puntos evaluados.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - P_i}{Y_i} \right| \quad (1)$$

El MAPE es el error promedio ponderado, o sea, nos indica en porcentaje, el valor esperado de error en cada predicción. Por ejemplo, para un modelo con MAPE = 0,1, un valor de predicción de 100 se puede visualizar que el valor real está entre 90 y 110. Es una métrica más interesante en nuestro caso pues estamos comparando varias ciudades con valores distintos de cobertura verde. Otras métricas que apenas consideran el valor de error absoluto, aunque útiles, para comparar varios modelos distintos, no reflejan bien las diferencias de la aplicación de un mismo modelo en varias ciudades.

Estas intervenciones técnicas han potenciado la capacidad del modelo para manejar eficazmente la distribución heterogénea de los datos, manteniendo un alto rendimiento incluso en entornos urbanos complejos y desafiantes

4. Resultados

Los resultados obtenidos han demostrado la eficacia de AI4GreenES en la explicación de la variabilidad de la cobertura verde urbana. Se han identificado patrones clave que influyen en la distribución de la IVU, lo que permite a los gestores urbanos tomar decisiones informadas para mejorar la planificación urbana.

Los MAPEs obtenidos por el modelo, debido a las variaciones naturales de cada ciudad, varían entre valores de 0,23 hasta 0,36 para cortes de los menores valores, para las ciudades de Valencia y Bilbao, respectivamente, ya para Madrid obtenemos 0,24 en el caso de datos tratados, hasta 0,37 para datos sin tratamiento.

Los MAPEs obtenidos por el modelo muestran variaciones entre las ciudades analizadas debido a sus características particulares. Para los cortes de valores menores, se obtienen resultados que oscilan entre el 0,23 en la ciudad de Valencia y el 0,36 de Bilbao. En el caso de la ciudad de Madrid, se observa que cuando se utilizan datos sin tratamiento, el MAPE aumenta hasta 0,37, y si se manejan datos tratados, se obtiene el 0,24.

| Barcelona | | | | | Madrid | | | | | Valencia | | | | |
|--------------|------|------|------|------|--------------|------|------|------|------|--------------|------|------|------|------|
| Corte / Blur | 10 | 20 | 30 | 50 | Corte / Blur | 10 | 20 | 30 | 50 | Corte / Blur | 10 | 20 | 30 | 50 |
| 1.0 | 0,64 | 0,61 | 0,52 | 0,42 | 1.0 | 0,49 | 0,41 | 0,35 | 0,29 | 1.0 | 0,61 | 0,59 | 0,57 | 0,51 |
| 2.0 | 0,50 | 0,48 | 0,45 | 0,40 | 2.0 | 0,37 | 0,37 | 0,33 | 0,28 | 2.0 | 0,48 | 0,43 | 0,40 | 0,32 |
| 3.0 | 0,42 | 0,39 | 0,38 | 0,36 | 3.0 | 0,34 | 0,31 | 0,30 | 0,27 | 3.0 | 0,35 | 0,33 | 0,30 | 0,24 |
| 5.0 | 0,30 | 0,30 | 0,29 | 0,28 | 5.0 | 0,28 | 0,27 | 0,25 | 0,24 | 5.0 | 0,24 | 0,23 | 0,21 | 0,16 |

Tabla 1. Resultados MAPE por Corte y Blur de tres ciudades analizadas. Fuente: elaboración propia

Los principales hallazgos incluyen:

- Alta correlación entre temperatura y cobertura verde, indicando que los cambios climáticos tienen un impacto significativo en la cantidad y calidad de las zonas verdes.
- Impacto significativo de la densidad poblacional en la disponibilidad de espacios verdes, lo que sugiere que en áreas altamente urbanizadas es necesario adoptar estrategias específicas para maximizar los beneficios de la IVU.
- La implementación del modelo ha permitido detectar desigualdades en el acceso a la infraestructura verde entre diferentes regiones. Esto facilita la identificación de áreas prioritarias para posibles actuaciones futuras.
- Se han generado mapas de calor y modelos predictivos que facilitan la toma de decisiones basada en datos objetivos y actualizados.

La solución ha sido sometida a un riguroso proceso de validación en múltiples ciudades españolas, incluyendo: Valencia, Madrid, Barcelona, Zaragoza, Palma de Mallorca, Murcia, Bilbao, Valladolid y Vitoria.

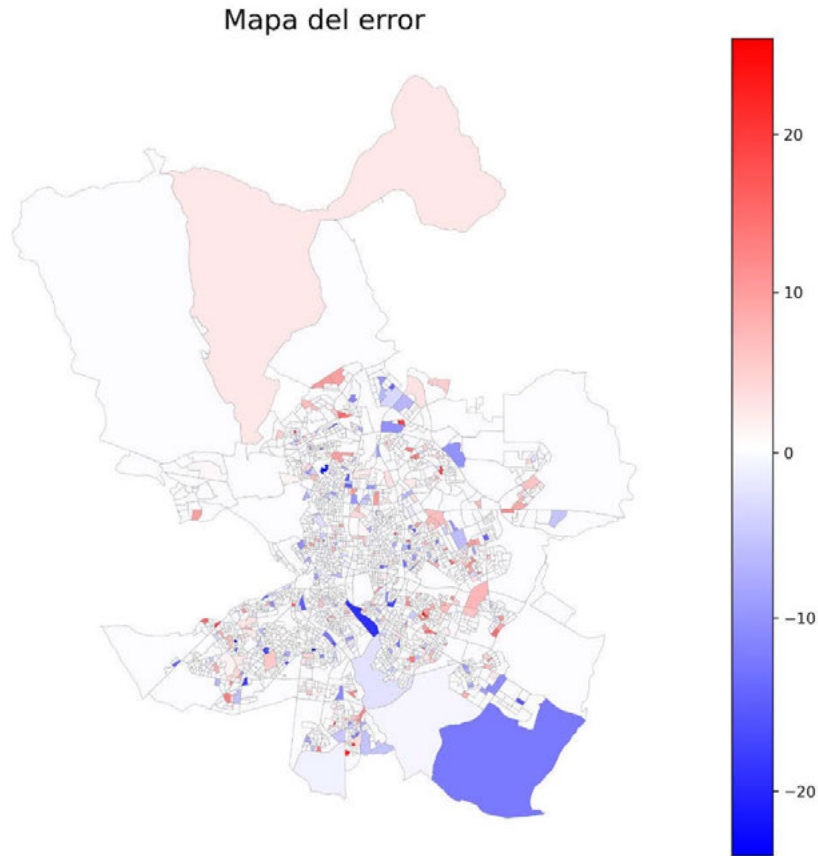


Fig. 5 Resultados con blur y corte para la ciudad de Madrid. Fuente: elaboración propia

La figura 5 muestra la diferencia absoluta de la predicción y el valor real. Podemos notar para la ciudad de Madrid en esta aplicación de modelo en específico (en general áreas en blanco), con error muy cercano a cero; eso se produce, en parte, por la distribución de datos entre entrenamiento y validación, y en parte, por la eficiencia del modelo. Con estos mapas obtenemos una visualización del funcionamiento interno del modelo, pudiendo hacer análisis más complejos, mejoras y perfeccionamientos al modelo.

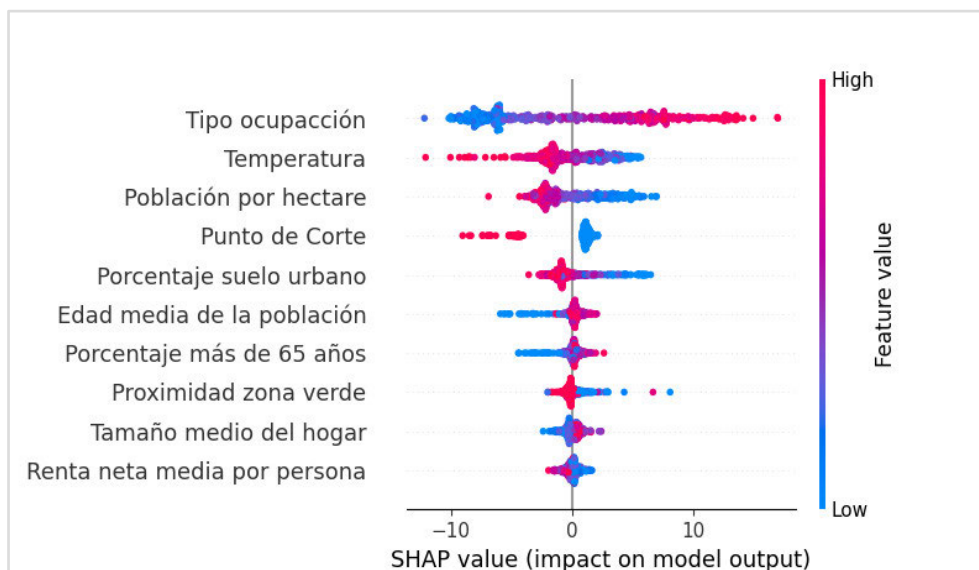


Fig. 6 Valores SHAP para la ciudad de Zaragoza. Fuente: elaboración propia

La figura 6 representa una distribución de tipo 'Colmena' de los valores SHAP, cada punto refleja la influencia de un valor de la variable en la predicción del modelo, y el color dado entre rojo y azul es la distribución del valor entre los posibles valores de la variable. Este tipo de visualización nos permite detectar rápidamente el tipo, dirección y calidad de la influencia de una variable, por ejemplo, podemos ver que la variable 'tipo ocupación' tiene una relación directamente proporcional, pues los puntos rojos son valores SHAP positivos, al mismo tiempo que son más importantes pues son valores SHAP más grandes. Por otro lado, la renta media es inversamente proporcional pues los valores rojos (renta más alta) son en su mayoría valores SHAP negativos, además, los valores están agrupados cerca de cero, lo que indica una influencia más pequeña sobre el total en la predicción.

Este enfoque de validación multi ciudad ha permitido:

- Analizar el desempeño del modelo en contextos urbanos diversos.
- Evaluar su adaptabilidad a diferentes patrones de urbanización y vegetación.

Los análisis realizados han sido fundamentales para:

- Verificar la adaptabilidad del modelo a escenarios cambiantes.
- Confirmar la robustez de las predicciones en condiciones variables.
- Asegurar la aplicabilidad de la solución en un amplio espectro de contextos urbanos.

La exhaustiva validación en diferentes escenarios reales ha proporcionado evidencia sólida sobre la capacidad explicativa y versatilidad de la solución desarrollada, respaldando su potencial para su implementación efectiva en diversas ciudades y entornos urbanos.

5. Conclusiones

Los resultados obtenidos con AI4GreenES han demostrado que la IA puede ser una aliada clave en la planificación urbana, permitiendo una mejor asignación de recursos y una mayor eficiencia en la toma de decisiones. Mediante técnicas de optimización de modelos, se ha logrado una mejora significativa en la precisión de las predicciones. Además, la implementación de estrategias como el uso de "Blur" en los datos de cobertura verde ha permitido reducir el error porcentual absoluto medio (MAPE) a valores entre el 30% y 40%, haciendo que el modelo sea más robusto y aplicable a distintos contextos urbanos.

El modelo AI4GreenES ha mostrado que la variabilidad en la cobertura verde urbana está fuertemente condicionada por las características urbano-territoriales de cada ciudad. Factores como la densidad poblacional, la temperatura media, la renta neta media, el tipo de ocupación del suelo (residencial, comercial o industrial), y la proximidad a zonas verdes emergen como determinantes clave en la distribución del verde urbano. Por ejemplo, ciudades con alta densidad y menor renta tienden a presentar menor cobertura verde, lo que resalta la necesidad de intervenciones específicas para garantizar la equidad ambiental.

La capacidad de adaptación del modelo a diferentes ciudades es uno de sus principales valores diferenciales. A través de la selección y calibración de variables específicas para cada contexto urbano, AI4GreenES permite una personalización sin precedentes en la planificación de la IVU.

El modelo ha sido personalizado y validado en múltiples ciudades españolas, como Valencia, Madrid, Barcelona, Zaragoza y Bilbao, lo que ha permitido comprobar su capacidad de adaptación a contextos urbanos diversos. Este enfoque permitió identificar variaciones en el rendimiento del modelo en función de la complejidad territorial de cada ciudad.

Por ejemplo, en Madrid y Bilbao se observaron valores MAPE más elevados en comparación con Valencia, lo cual está directamente relacionado con las diferencias en la estructura urbana, el tamaño del municipio y la heterogeneidad de sus barrios. En estos contextos, el modelo permitió detectar zonas

con déficit de infraestructura verde y desigualdad en el acceso, ofreciendo a los planificadores herramientas para priorizar actuaciones e inversiones.

Uno de los principales aportes de esta solución es la combinación de modelos predictivos con técnicas de Location Intelligence, lo que permite evaluar distintos escenarios y establecer prioridades en la mejora de la IVU. El uso de algoritmos de machine learning, como el modelo Extra Trees, ha optimizado la precisión del sistema, reduciendo errores de predicción y mejorando la interpretación de los resultados mediante técnicas de análisis como SHAP. Estos avances han facilitado la toma de decisiones basada en datos, proporcionando información estratégica para administraciones públicas, urbanistas y gestores del medio ambiente.

En conclusión, AI4GreenES se posiciona como una herramienta esencial para los municipios que buscan optimizar su infraestructura verde con criterios de equidad y sostenibilidad. Su capacidad de personalización y su enfoque basado en datos lo convierten en un referente en la gestión de la IVU. Se recomienda su implementación en más ciudades y la exploración de nuevas variables que puedan mejorar aún más la precisión del modelo. Además, se sugiere continuar con el desarrollo de herramientas basadas en IA que permitan evaluar de manera integral la sostenibilidad y resiliencia de las ciudades, contribuyendo a la creación de entornos urbanos más saludables y equitativos.

Los resultados obtenidos han demostrado que la IA es una aliada clave en la planificación urbana sostenible, favoreciendo una asignación más eficiente de recursos y maximizando los beneficios de la infraestructura verde para la salud y el bienestar de la ciudadanía.

Bibliografía

- Genuer, R., Poggi, J.-M. y Tuleau-Malot, C. (2010). Variable selection using random forests. *Pattern Recognition Letters*, 31(14), 2225–2236
- Geurts, P., Ernst, D. & Wehenkel, L. (2006). Extremely randomized trees. *Machine Learning*, 63, 3–42.
- Liu, Y., Liu, Z., Luo, X. & Zhao, H. (2022). Diagnosis of Parkinson's disease based on SHAP value feature selection. *Biocybernetics and Biomedical Engineering*, 42(3), 856–869.
- Lundberg, S. M., Erion, G., Chen, H., DeGrave, A., Prutkin, J. M., Nair, B., Katz, R., Himmelfarb, J., Bansal, N. & Lee, S.-I. (2020). From local explanations to global understanding with explainable AI for trees. *Nature Machine Intelligence*, 2(1), 56–67.
- Lundberg, S. M., Erion, G. G. & Lee, S.-I. (2018a). Consistent individualized feature attribution for tree ensembles. *arXiv preprint arXiv:1802.03888*.
- Lundberg, S. M., Nair, B., Vavilala, M. S., Horibe, M., Eisses, M. J., Adams, T., Liston, D. E., Low, D. K.-W., Newman, S.-F., Kim, J. et al. (2018b). Explainable machine-learning predictions for the prevention of hypoxemia during surgery. *Nature Biomedical Engineering*, 2(10), 749–760.

Fuentes electrónicas

- Battiston, A. & Schifanella, R. (2023). On the need to move from a single indicator to a multi-dimensional framework to measure accessibility to urban green. *arXiv preprint arXiv:2308.05538*. Disponible en: <https://arxiv.org/abs/2308.05538>
- González Álvarez, S. & Del Caz Enjuto, M.R., (2023). El verde urbano desde el punto de vista ambiental, social y de la salud: políticas urbanas convergentes. *ACE: Arquitectura, Ciudad y Entorno*, 18(53), 1-18. Disponible en: <https://revistes.upc.edu/index.php/ACE/article/view/12129/2787>
- Lundberg, S. (2018). SHAP module. Disponible en: <https://shap.readthedocs.io/en/latest/>. (Consulta: 06/12/2024).
- Ministerio para la Transición Ecológica y el Reto Demográfico (MITECO). (2021). Infraestructura verde en zonas urbanas. *Policy Brief sobre Estrategias de Infraestructura Verde*, 1-12. Disponible en: https://www.miteco.gob.es/content/dam/miteco/es/reto-demografico/temas/8269esppolicybrief_tcm30-547604.pdf