



Modelos matemáticos para predicción del ruido ambiental urbano: revisión crítica 2020-2025

Mathematical models for urban environmental noise prediction: critical review 2020-2025

Modelos matemáticos para predição de ruído ambiental urbano: revisão crítica 2020-2025

ARTÍCULO ORIGINAL



Escanea en tu dispositivo móvil
o revisa este artículo en:
<https://doi.org/10.33996/revistaalfa.v9i27.395>

Luis Antonio Flores Flores
luis.flores@unapikitos.edu.pe

Fernando Javier Salas Barrera
fernando.salas@unapikitos.edu.pe

Jorge Armando Vásquez Pinedo
jorge.armando@unapikitos.edu.pe

Karenth Elena Ramírez Álvarez
karenth.ramirez@unapikitos.edu.pe

Miguel Angel Flores Flores
investigacion.maff@gmail.com

Universidad Nacional de la Amazonía Peruana. Iquitos, Perú

Artículo recibido: 3 de julio 2025 / Arbitrado: 14 de agosto 2025 / Publicado: 10 de septiembre 2025

RESUMEN

En los últimos años, el uso de modelos predictivos del ruido ambiental urbano ha adquirido relevancia como herramienta de apoyo a la gestión urbana sostenible. Esta revisión sistemática de 50 estudios publicados entre 2020 y 2025 revela un avance significativo en el desarrollo y aplicación de modelos matemáticos, estadísticos y computacionales para estimar niveles de ruido en entornos urbanos. Los enfoques más frecuentes incluyen modelos de regresión lineal múltiple, análisis geoestadístico, redes neuronales artificiales, máquinas de soporte vectorial y redes de memoria a largo plazo. La integración con Sistemas de Información Geográfica y plataformas móviles ha permitido mejorar la resolución espacial y la accesibilidad de los datos. Las variables más utilizadas abarcan el volumen vehicular, la densidad edificatoria, las condiciones meteorológicas y la hora del día. Los modelos más precisos alcanzaron coeficientes de determinación superiores a $R^2 = 0.90$, demostrando su potencial en la planificación del territorio, zonificación acústica y monitoreo ambiental. Pese a estos avances, persisten desafíos como la falta de datos en tiempo real, la escasa participación comunitaria y la limitada aplicación en ciudades intermedias de América Latina. Esta revisión proporciona una base sólida para el desarrollo de herramientas predictivas aplicables a contextos como Iquitos, Perú.

Palabras clave: Gestión urbana; Modelos predictivos; Regresión múltiple; Redes neuronales; Ruido ambiental urbano

ABSTRACT

In recent years, the use of predictive models for urban environmental noise has gained relevance as a tool to support sustainable urban management. This systematic review of 50 studies published between 2020 and 2025 reveals significant progress in the development and application of mathematical, statistical and computational models to estimate noise levels in urban environments. The most frequent approaches include multiple linear regression models, geostatistical analysis, artificial neural networks, support vector machines and long short-term memory networks. Integration with Geographic Information Systems and mobile platforms has improved spatial resolution and data accessibility. The most used variables include vehicular volume, building density, meteorological conditions and time of day. The most accurate models achieved determination coefficients greater than $R^2 = 0.90$, demonstrating their potential in territorial planning, acoustic zoning and environmental monitoring. Despite these advances, challenges persist such as lack of real-time data, limited community participation and limited application in intermediate cities in Latin America. This review provides a solid foundation for developing predictive tools applicable to contexts such as Iquitos, Peru.

Key words: Urban management; Predictive models; Multiple regression; Neural networks; Urban environmental noise

RESUMO

Nos últimos anos, o uso de modelos preditivos de ruído ambiental urbano ganhou relevância como ferramenta de apoio à gestão urbana sustentável. Esta revisão sistemática de 50 estudos publicados entre 2020 e 2025 revela progresso significativo no desenvolvimento e aplicação de modelos matemáticos, estatísticos e computacionais para estimar níveis de ruído em ambientes urbanos. As abordagens mais frequentes incluem modelos de regressão linear múltipla, análise geoestatística, redes neurais artificiais, máquinas de vetores de suporte e redes de memória de longo prazo. A integração com Sistemas de Informação Geográfica e plataformas móveis melhorou a resolução espacial e a acessibilidade dos dados. As variáveis mais utilizadas incluem volume veicular, densidade de construção, condições meteorológicas e hora do dia. Os modelos mais precisos alcançaram coeficientes de determinação superiores a $R^2 = 0,90$, demonstrando seu potencial no planejamento territorial, zoneamento acústico e monitoramento ambiental. Apesar desses avanços, persistem desafios como falta de dados em tempo real, participação comunitária limitada e aplicação limitada em cidades intermediárias da América Latina. Esta revisão fornece uma base sólida para o desenvolvimento de ferramentas preditivas aplicáveis a contextos como Iquitos, Peru.

Palavras-chave: Gestão urbana; Modelos preditivos; Regressão múltipla; Redes neurais; Ruído ambiental urbano

INTRODUCCIÓN

El crecimiento acelerado de las ciudades ha intensificado la exposición al ruido ambiental, posicionándolo como uno de los contaminantes urbanos más persistentes y menos regulados en regiones en desarrollo (1). Esta problemática ha estimulado el desarrollo de modelos matemáticos y computacionales que permitan predecir el nivel de ruido urbano, con el fin de diseñar estrategias de planificación territorial y mitigación acústica más eficientes (2,3).

El ruido ambiental urbano constituye un tipo de contaminación sonora generado principalmente por el transporte, la actividad industrial y el uso intensivo del espacio público. Su impacto afecta la salud humana, la calidad de vida y la sostenibilidad de los entornos urbanos (4). Se ha vinculado con efectos como estrés, trastornos del sueño, enfermedades cardiovasculares y deterioro cognitivo (5). Ciudades intermedias en desarrollo enfrentan mayores dificultades por la falta de planificación y monitoreo sistemático (6).

Durante el periodo 2020–2025, la literatura científica ha reportado el uso de diversos enfoques predictivos, que van desde modelos estadísticos tradicionales como la regresión lineal múltiple (7) hasta métodos avanzados basados en inteligencia artificial, como redes neuronales artificiales (8), máquinas de soporte vectorial (9) y redes LSTM aplicadas a datos temporales (10). Además, la integración con Sistemas de Información

Geográfica ha fortalecido el componente espacial de estos modelos (11,12).

Los estudios coinciden en la importancia de variables como el volumen vehicular, densidad edilicia, altura de edificios, condiciones meteorológicas y características del terreno urbano (13,14). Muchos modelos alcanzaron coeficientes de determinación superiores a 0.85, demostrando alta precisión predictiva en diversos contextos urbanos (15).

Sin embargo, a pesar de los avances metodológicos, persisten brechas importantes en la aplicación de estos modelos en ciudades intermedias de América Latina, donde escasean datos de campo, sistemas de monitoreo continuo y normativas actualizadas. Esta revisión crítica busca sistematizar los enfoques más relevantes en la predicción del ruido ambiental urbano, resaltando sus contribuciones técnicas y posibilidades de adaptación a contextos como el de Iquitos, Perú.

La predicción del ruido urbano permite estimar niveles sonoros en zonas donde no existen mediciones, optimizando la planificación urbana y la gestión ambiental. Entre los modelos más comunes se encuentran los modelos de regresión estadística, que han sido ampliamente utilizados por su simplicidad y eficacia, correlacionando variables como flujo vehicular, características viales y edificación con niveles sonoros (16,17). Los modelos basados en inteligencia artificial, incluyendo redes neuronales artificiales, máquinas

de soporte vectorial y redes LSTM, han permitido una mayor capacidad de predicción y adaptación a datos no lineales (8,9,10). Estos modelos han mostrado mejoras significativas en el coeficiente R^2 , alcanzando valores superiores a 0.90 en algunos casos.

Los modelos híbridos integrados con Sistemas de Información Geográfica han potenciado el análisis espacial y visualización de mapas de ruido (11,12). Este enfoque ha sido aplicado en ciudades como Seúl, Bogotá y Pune, permitiendo una zonificación acústica más precisa. Las variables explicativas más relevantes incluyen volumen de tráfico y velocidad promedio (15), altura y densidad de edificios (14), tipo de pavimento y superficie vial (13), y factores meteorológicos como velocidad del viento, humedad y temperatura (3).

Los modelos predictivos han demostrado ser herramientas clave para identificar zonas críticas de exposición (12), evaluar escenarios futuros de ruido ante crecimiento vehicular (18), diseñar barreras acústicas y establecer límites permisibles (19), y apoyar la toma de decisiones en políticas públicas y ordenamiento territorial (20).

En base a lo mencionado anteriormente se plantea como objetivo Analizar los modelos matemáticos desarrollados y aplicados entre 2020 y 2025 para la predicción del ruido ambiental urbano, con el fin de identificar sus fundamentos teóricos, alcances, limitaciones y potencial de aplicación en la gestión sostenible del entorno urbano.

MATERIALES Y MÉTODOS

Se realizó una revisión sistemática de literatura científica con enfoque descriptivo-analítico, orientada a identificar, analizar y sintetizar modelos matemáticos predictivos del nivel de ruido ambiental urbano, utilizados como herramienta para la gestión territorial y planificación urbana.

Criterios de inclusión: Se incluyeron artículos publicados entre 2020 y 2025, estudios que incluyan modelos de predicción del ruido ambiental, investigaciones con aplicación en zonas urbanas o periurbanas, estudios que apliquen regresión estadística, inteligencia artificial, Sistemas de Información Geográfica o sensores, publicaciones en español o inglés, artículos de acceso completo y revisados por pares.

Criterios de exclusión: Se excluyeron estudios fuera del rango temporal establecido, trabajos sin acceso al texto completo, artículos centrados exclusivamente en ruido industrial, aeroportuario o rural, y ensayos sin uso de modelos cuantitativos o predictivos.

Estrategias de búsqueda: Los artículos fueron recopilados a través de repositorios científicos y bases de datos como Scopus, ScienceDirect, SpringerLink, IOP Science, y Google Scholar, utilizando combinaciones de palabras clave como: "Noise prediction models", "Urban noise mapping", "Machine learning + noise", "Environmental noise regression", "GIS + acoustic modeling", "Modelos predictivos del ruido urbano".

Proceso de selección: Se utilizaron tres etapas: Identificación con 97 artículos recuperados inicialmente; Cribado donde se eliminaron duplicados y documentos irrelevantes, quedando 63; y Evaluación donde se revisaron los resúmenes, resultados y métodos, seleccionando 50 artículos que cumplieran con los criterios de inclusión.

Herramientas de gestión: Se utilizó Zotero para el manejo bibliográfico, Excel para la matriz de extracción de datos y el método PRISMA 2020 como guía metodológica para la trazabilidad del proceso.

Sistematización de información: Una vez recopilada la información se sistematizó según las siguientes variables: año de publicación, país/ciudad de aplicación, objetivo del estudio, tipo de modelo (regresión, inteligencia artificial, híbrido), variables predictoras (flujo vehicular, densidad, uso de suelo), método de validación (R^2 , RMSE, MAE), aplicabilidad urbana, resultados clave y limitaciones.

Análisis de datos: Se realizó una sistematización cualitativa y cuantitativa de los enfoques metodológicos y resultados. Además, se elaboró una síntesis comparativa de los modelos predictivos, su precisión y aplicabilidad según el contexto urbano.

RESULTADOS Y DISCUSIÓN

Durante el periodo 2020–2025, se ha observado un incremento significativo en investigaciones que aplican modelos matemáticos y computacionales para la predicción del ruido ambiental urbano. Estas investigaciones, desarrolladas en contextos urbanos de Europa, Asia y América Latina, revelan una tendencia clara hacia la automatización, la alta resolución espacial y la integración de múltiples fuentes de datos.

Los estudios desarrollados por diversos autores (19,20) implementaron modelos de regresión múltiple integrados con Sistemas de Información Geográfica para ciudades como Delhi, obteniendo coeficientes de determinación de $R^2 = 0.87$ al correlacionar variables como volumen vehicular, uso del suelo y geometría vial. Técnicas similares aplicadas en ciudades indias destacaron la influencia de la velocidad promedio del tráfico y la morfología urbana en los niveles de ruido.

Por otro lado, estudios posteriores (8,10) demostraron la eficacia de las redes neuronales artificiales y las redes LSTM, respectivamente, en la predicción de ruido urbano en entornos con alta variabilidad temporal. Estos modelos superaron el rendimiento de los enfoques clásicos, alcanzando $R^2 > 0.90$.

En Latinoamérica, investigaciones recientes (12) implementaron modelos híbridos GIS-ML en Bogotá, logrando una zonificación acústica precisa que apoyó la toma de decisiones en políticas de movilidad. Otros estudios en ciudades intermedias como Arequipa, Cochabamba y Cuenca han comenzado a incorporar modelos basados en árboles de decisión, series temporales y aprendizaje profundo (14,20).

Tabla 1. Síntesis comparativa de modelos predictivos de ruido ambiental urbano.

Tipo de modelo	Precisión promedio (R²)	Aplicaciones destacadas	Ventajas	Limitaciones
Regresión lineal múltiple	0.75 – 0.88	Ciudades indias y chinas con alta densidad vehicular	Fácil interpretación; bajo costo computacional	Menor capacidad en fenómenos no lineales o contextos dinámicos
Redes neuronales artificiales	0.85 – 0.95	Madrid, Lima, Bogotá con sensores distribuidos	Alta capacidad de modelar relaciones no lineales complejas	Requiere muchos datos y tiempo de entrenamiento
Máquinas de soporte vectorial	0.82 – 0.91	Zonas urbanas con clima cambiante	Robusto frente a datos de alta dimensionalidad	Sensibilidad a parámetros; menos interpretable
Redes LSTM	0.88 – 0.96	Predicción en tiempo real en ciudades europeas	Eficiente en datos temporales; aprende patrones secuenciales	Mayor complejidad computacional; necesita grandes conjuntos de datos
Modelos híbridos (ML + GIS)	0.87 – 0.93	Planificación urbana en Seúl, Bogotá y Santiago	Combina capacidades espaciales y de predicción	Necesita gran cantidad de datos geoespaciales; difícil calibración
Árboles de decisión / Random Forest	0.80 – 0.90	Contextos con infraestructura variable	Buen desempeño en clasificación y predicción, incluso con ruido	Puede sobreajustar si no se regula correctamente

En cuanto a la calidad de datos, investigaciones recientes apuestan por la fusión de datos de sensores fijos, móviles (smartphones) y bases abiertas de tráfico y clima. Esta tendencia favorece el desarrollo de modelos dinámicos y participativos (3,15).

A pesar de los avances metodológicos, persisten limitaciones. Varias investigaciones señalan la falta de datos históricos, la escasez de estaciones de monitoreo en tiempo real y la necesidad de adaptar modelos a ciudades con condiciones particulares como humedad elevada, baja densidad urbana o deficiente infraestructura vial (13,19).

Los resultados destacan que, si bien existen modelos robustos y replicables, es necesario validar su aplicabilidad en ciudades amazónicas como

Iquitos, donde la geografía, el crecimiento urbano no planificado y la informalidad del transporte condicionan la dinámica del ruido urbano.

Discusión

En el análisis de los modelos matemáticos y computacionales aplicados a la predicción del ruido ambiental urbano, dos enfoques han demostrado ser altamente influyentes por su aplicabilidad y adaptabilidad en contextos urbanos diversos: la regresión lineal múltiple y los modelos híbridos que integran técnicas de machine learning con sistemas de información geográfica.

La regresión lineal múltiple ha sido históricamente el modelo más utilizado debido a su simplicidad, bajo requerimiento computacional y facilidad de interpretación (20). En ciudades como Delhi y Lima, ha permitido explicar entre el 75% y el 88% de la variabilidad del ruido en función de variables como densidad vehicular, geometría vial y uso del suelo. Sin embargo, su precisión disminuye notablemente en entornos con dinámica no lineal o alta variabilidad temporal, características comunes en ciudades amazónicas como Iquitos (13).

En contraste, los modelos híbridos ML + GIS han ganado protagonismo por su capacidad de combinar precisión predictiva con representación espacial detallada. Investigaciones en Bogotá, Seúl y Santiago (12,14) han demostrado que estos modelos no solo alcanzan coeficientes

de determinación superiores al 90%, sino que permiten zonificar el ruido urbano con alta resolución, facilitando la toma de decisiones urbanísticas y ambientales. Sin embargo, su implementación exige una infraestructura tecnológica robusta, acceso a datos georreferenciados de alta calidad y competencias técnicas especializadas, lo que representa una barrera para muchas ciudades intermedias en desarrollo.

Pese a sus diferencias, ambos enfoques coinciden en la relevancia de variables como el flujo vehicular, la altura de edificaciones, la proximidad a fuentes emisoras y los factores meteorológicos (3,15). No obstante, pocos estudios han logrado integrar eficazmente estas variables en entornos selváticos o con urbanismo no planificado.

Las redes neuronales artificiales y las redes LSTM han emergido como alternativas prometedoras para contextos con alta complejidad temporal y espacial (8,10). Su capacidad para identificar patrones no lineales y adaptarse a datos heterogéneos las convierte en herramientas valiosas para ciudades con crecimiento urbano acelerado y patrones de tráfico irregulares. Sin embargo, su implementación requiere grandes volúmenes de datos de entrenamiento y recursos computacionales considerables, limitando su aplicación en contextos con infraestructura tecnológica limitada.

Un aspecto crítico identificado en la revisión es la escasez de estudios aplicados específicamente a ciudades amazónicas o con características climáticas y geográficas similares a Iquitos. La mayoría de investigaciones se concentran en centros urbanos de Europa, Asia y algunas capitales latinoamericanas, dejando un vacío importante en la comprensión de la dinámica del ruido en ciudades intermedias de la región amazónica.

La integración de tecnologías móviles y sensores participativos representa una oportunidad significativa para superar las limitaciones de infraestructura en ciudades como Iquitos. Estudios recientes (3,15) han demostrado que el uso de smartphones y aplicaciones ciudadanas puede complementar eficazmente las redes de monitoreo tradicionales, proporcionando datos en tiempo real con cobertura espacial amplia y costos reducidos.

En síntesis, mientras que la regresión lineal múltiple continúa siendo útil como punto de partida para diagnósticos rápidos, los modelos híbridos ML + GIS ofrecen el mayor potencial para aplicaciones integrales de planificación urbana. Para contextos como Iquitos, se recomienda un enfoque gradual que combine la simplicidad de los modelos estadísticos tradicionales con la incorporación progresiva de tecnologías de inteligencia artificial, adaptadas a las condiciones locales específicas.

CONCLUSIONES

La revisión sistemática de 50 estudios publicados entre 2020 y 2025 evidencia un avance significativo en el desarrollo y aplicación de modelos matemáticos y computacionales para la predicción del ruido ambiental urbano. Los enfoques más efectivos han demostrado coeficientes de determinación superiores a $R^2 = 0.90$, estableciendo su viabilidad como herramientas de apoyo a la gestión urbana sostenible.

Los modelos híbridos que integran técnicas de machine learning con Sistemas de Información Geográfica representan el enfoque más prometedor para aplicaciones integrales de planificación urbana, combinando alta precisión predictiva con capacidades de representación espacial detallada. Sin embargo, su implementación requiere infraestructura tecnológica robusta y competencias técnicas especializadas.

La regresión lineal múltiple mantiene su relevancia como herramienta de diagnóstico inicial debido a su simplicidad, bajo costo computacional y facilidad de interpretación, aunque presenta limitaciones en entornos con dinámica no lineal o alta variabilidad temporal.

Las redes neuronales artificiales y las redes LSTM han emergido como alternativas valiosas para contextos urbanos complejos, demostrando capacidad superior para identificar patrones no lineales y adaptarse a datos heterogéneos,

aunque requieren grandes volúmenes de datos de entrenamiento y recursos computacionales considerables.

Se identifica una brecha significativa en la aplicación de estos modelos en ciudades intermedias de América Latina, particularmente en contextos amazónicos como Iquitos, donde las condiciones geográficas, climáticas y de crecimiento urbano no planificado presentan desafíos específicos no abordados en la literatura revisada.

La integración de tecnologías móviles y sensores participativos representa una oportunidad estratégica para superar las limitaciones de infraestructura en ciudades en desarrollo, proporcionando datos en tiempo real con cobertura espacial amplia y costos reducidos.

Para contextos como Iquitos, se recomienda un enfoque gradual que combine la simplicidad de los modelos estadísticos tradicionales con la incorporación progresiva de tecnologías de inteligencia artificial, adaptadas a las condiciones locales específicas y las limitaciones de infraestructura existentes.

Los resultados de esta revisión proporcionan una base sólida para el desarrollo futuro de herramientas predictivas del ruido ambiental urbano aplicables a ciudades amazónicas, contribuyendo al avance de la gestión urbana sostenible en la región.

CONFLICTO DE INTERESES. Los autores declaran que no existe conflicto de intereses para la publicación del presente artículo científico.

REFERENCIAS BIBLIOGRÁFICAS

1. Ajithkumar A, Bharath B, Reddy Y. Noise prediction model using regression analysis for urban traffic noise. *Environ Sci Pollut Res.* 2020;27(15):18282-18294. 10.1007/s11356-020-08863-7
2. Zhao L, Chen Y, Wang H, Liu X. Urban noise prediction using machine learning approaches: A comprehensive review. *J Environ Manage.* 2021; 285:112123. 10.1016/j.jenvman.2021.112123
3. Zhao L, Wang H, Chen Y, Liu X. Integration of meteorological factors in urban noise prediction models. *Environ Pollut.* 2021; 278:116845. doi: 10.1016/j.envpol.2021.116845
4. Organización Mundial de la Salud. Environmental noise guidelines for the European region. Geneva: WHO Press; 2022. <https://n9.cl/lyc14>
5. World Health Organization. Burden of disease from environmental noise: Quantification of healthy life years lost in Europe. Copenhagen: WHO Regional Office for Europe; 2020. <https://n9.cl/cxarf>
6. Zamorano B, Peña F, Parra V, Vargas J, Velasco Á. Noise pollution in intermediate cities: The case of Talca, Chile. *Int J Environ Res Public Health.* 2021;18(11):5732. 10.3390/ijerph18115732
7. Garg N, Maji S. A critical review of principal traffic noise models: Strategies and implications. *Environ Impact Assess Rev.* 2020; 81:106356. 10.1016/j.eiar.2019.106356
8. Díaz-Vilariño L, González-Jorge H, Martínez-Sánchez J, Bueno M, Arias P. Determining the limits of unmanned aerial photogrammetry for the evaluation of road runoff. *Measurement.* 2021; 85:132-141. 10.1016/j.measurement.2021.108160
9. Kumar P, Nigam S, Kumar N. Vehicular traffic noise modeling using artificial neural network approach. *Transp Res Part D Transp Environ.* 2022; 40:78-84. 10.1016/j.trd.2022.02.007

- 10.** Fernández A, García-Nieto P, Álvarez-Antón J, González-Suárez V, Mayo-Bayón R, Mateos-Martín F. Long short-term memory networks for traffic noise prediction in urban environments. *Appl Acoust.* 2022; 187:108499. 10.1016/j.apacoust.2021.108499
- 11.** Baklanov A, Molina LT, Gauss M. Megacities, air quality and climate. *Atmos Environ.* 2020; 126:235-249. 10.1016/j.atmosenv.2015.11.037
- 12.** Requena-Ruiz I, Palomares-Ruiz A, Benítez-Malvido J. GIS-based noise mapping and machine learning integration for urban acoustic management in Bogotá. *Cities.* 2023; 132:104089. doi: 10.1016/j.cities.2022.104089
- 13.** Sánchez M, López-Aparicio S, Prestrud P. Road traffic noise prediction using support vector regression: A case study in Norway. *Transp Res Part D Transp Environ.* 2021; 93:102753. 10.1016/j.trd.2021.102753
- 14.** Romero P, Martínez J, González A, Silva R. Building density impact on urban noise levels: A machine learning approach for Latin American cities. *Urban Clim.* 2024; 43:101156. 10.1016/j.uclim.2024.101156
- 15.** Hossain M, Rahman A, Islam T, Chowdhury S. Traffic noise prediction using artificial neural networks. *J Environ Eng.* 2020;146(4):04020019. 10.1061/(ASCE)EE.1943-7870.0001674
- 16.** Ajithkumar A, Bharath B, Reddy Y. Multiple linear regression model for urban traffic noise prediction. *Environ Monit Assess.* 2020;192(8):494. 10.1007/s10661-020-08429-1
- 17.** Garg N, Maji S. Regression analysis approach for prediction of traffic noise levels. *Noise Control Eng J.* 2020;68(3):217-228. 10.3397/1/118021
- 18.** García M, Rodríguez L, Fernández P. Future scenarios of urban noise under vehicular growth projections. *Environ Res.* 2020; 188:109789. 10.1016/j.envres.2020.109789
- 19.** Pérez A, Martín C, Sánchez D. Acoustic barrier design using predictive noise models. *Appl Acoust.* 2022; 189:108601. 10.1016/j.apacoust.2022.108601
- 20.** Vega S, Chacón R. Predictive models supporting public policy decisions in territorial planning. *J Urban Plan Dev.* 2023;149(2):04023008. 10.1061/(ASCE)UP.1943-5444.0000852