

An AI-Based Urban Vulnerability Framework Integrating Infrastructure and Climate Risk in Central American Cities

Valery A. Ochoa Perdomo¹ 

¹Escuela de Arte y Diseño, Universidad Tecnológica Centroamericana UNITEC, San Pedro Sula, Honduras
valery.ochoa@unitec.edu.hn

Abstract– *Rapid urbanization and increasing climate exposure pose significant challenges for planning the built environment in Central American cities. This study develops and validates an artificial intelligence–based urban segmentation framework integrating infrastructure, socioeconomic inequality, and climate risk into a unified analytical model. A calibrated synthetic dataset was constructed for five capital cities using regional statistics and open geospatial data. Dimensionality reduction techniques (PCA, UMAP, t-SNE) and unsupervised learning algorithms (K-means, DBSCAN, HDBSCAN, and GMM) were applied and evaluated using internal validation metrics and spatial autocorrelation. HDBSCAN achieved the best performance (Silhouette = 0.56), identifying four urban typologies. The Urban Vulnerability Index (UVI) showed significant spatial clustering (Moran’s $I = 0.63$; $p < 0.001$), revealing a strong overlap between infrastructure deficits and climate exposure in peri-urban areas. The model was simulated using accessible AI-assisted tools, enabling its application by architecture and urban planning students without advanced programming skills. The framework provides a reproducible tool for resilient infrastructure planning.*

Keywords-- *Artificial intelligence, urban vulnerability, urban clustering, infrastructure, climate resilience, urban planning*

Un marco de vulnerabilidad urbana basado en IA que integra infraestructuras y riesgos climáticos en ciudades centroamericanas

Valery A. Ochoa Perdomo¹ 

¹Escuela de Arte y Diseño, Universidad Tecnológica Centroamericana UNITEC, San Pedro Sula, Honduras
valery.ochoa@unitec.edu.hn

Resumen- La urbanización acelerada y el aumento de la exposición climática representan desafíos estructurales para la planificación del entorno construido en ciudades centroamericanas. Este estudio desarrolla y valida un marco de segmentación urbana basado en inteligencia artificial que integra infraestructura, desigualdad socioeconómica y riesgo climático en un modelo analítico unificado. Se construyó un conjunto de datos sintético calibrado para cinco capitales centroamericanas, empleando estadísticas regionales y fuentes geospaciales abiertas. Se aplicaron técnicas de reducción de dimensionalidad (PCA, UMAP, t-SNE) y algoritmos de aprendizaje no supervisado (K-means, DBSCAN, HDBSCAN y GMM), evaluados mediante métricas de validación interna y autocorrelación espacial. HDBSCAN mostró el mejor desempeño (Silueta = 0.56), identificando cuatro tipologías urbanas. El Índice de Vulnerabilidad Urbana (UVI) evidenció autocorrelación significativa (Moran's $I = 0.63$; $p < 0.001$), revelando una superposición entre déficit de infraestructura y exposición climática en zonas periurbanas. El modelo fue implementado de forma simulada mediante herramientas de IA accesibles, permitiendo su uso por estudiantes sin conocimientos avanzados de programación. El framework constituye una herramienta reproducible para la planificación urbana resiliente.

Palabras clave: Inteligencia artificial, vulnerabilidad urbana, clustering urbano, infraestructura, resiliencia climática, planificación urbana

I. INTRODUCCIÓN

La urbanización acelerada constituye uno de los procesos estructurales más relevantes del siglo XXI. En América Latina, más del 80% de la población reside en áreas urbanas, con proyecciones que indican un crecimiento continuo hacia 2050 [1]. En Centroamérica, esta dinámica se caracteriza por expansión periférica no planificada, informalidad habitacional persistente y alta exposición a amenazas hidrometeorológicas como huracanes e inundaciones [4].

La superposición espacial entre desigualdad socioeconómica y riesgo ambiental genera configuraciones de vulnerabilidad acumulativa que desafían los enfoques tradicionales de planificación sectorial [4]. Los métodos convencionales tienden a analizar infraestructura, pobreza o riesgo climático de manera aislada, sin capturar su interacción sistémica ni su impacto en la movilidad urbana y la sostenibilidad territorial.

La inteligencia artificial (IA) y el aprendizaje automático han introducido nuevas oportunidades para el análisis urbano basado en datos [2], [6]. En particular, técnicas como el clustering permiten identificar patrones urbanos latentes y segmentar territorios en tipologías funcionales homogéneas [7]. Estudios previos han aplicado métodos como K-means, DBSCAN y modelos de mezcla gaussiana para delimitar estructuras urbanas complejas [8], [9]. Sin embargo, la mayoría de estas aplicaciones se han desarrollado en contextos distintos al centroamericano y presentan limitaciones en la integración de variables de riesgo climático y en su aplicación dentro de procesos formativos en educación superior.

Adicionalmente, aunque la IA ofrece un alto potencial para el análisis y la simulación de escenarios urbanos, su rol en la planificación no consiste en sustituir al planificador, sino en actuar como una herramienta de apoyo que permite procesar grandes volúmenes de datos y generar alternativas de análisis, mientras que la interpretación crítica y la toma de decisiones permanecen como funciones humanas fundamentales.

En consecuencia, la formación en planificación urbana enfrenta el desafío de integrar enfoques analíticos, tecnológicos y participativos que permitan a los estudiantes no solo comprender, sino también aplicar herramientas de inteligencia artificial en la resolución de problemas complejos de movilidad urbana sostenible en ciudades intermedias latinoamericanas.

II. MARCO CONCEPTUAL

La planificación urbana contemporánea se enfrenta al desafío de abordar sistemas territoriales complejos, caracterizados por interacciones dinámicas entre infraestructura, estructuras socioeconómicas y condiciones medioambientales en contextos de cambio acelerado. En ciudades con economías emergentes, estas interacciones suelen manifestarse mediante patrones de crecimiento fragmentado, informalidad urbana y exposición diferencial al riesgo climático, lo que exige enfoques analíticos capaces de capturar dicha complejidad de forma integrada.

A. Complejidad urbana y multidimensionalidad

Las ciudades deben entenderse como sistemas complejos donde la infraestructura, la estructura socioeconómica y las condiciones ambientales interactúan de manera no lineal [1]. En

este contexto, la planificación algorítmica contemporánea plantea que los enfoques basados en variables aisladas resultan insuficientes para representar las dinámicas urbanas, siendo necesario adoptar modelos que integren múltiples dimensiones de análisis.

La segmentación urbana mediante técnicas de clustering permite agrupar unidades territoriales homogéneas internamente y heterogéneas entre sí, facilitando la identificación de núcleos consolidados, zonas de transición y periferias vulnerables [7]. Este enfoque contribuye a revelar patrones espaciales latentes que no son evidentes a través de métodos tradicionales.

B. Inteligencia artificial en la planificación territorial

La literatura reciente evidencia el potencial de la inteligencia artificial (IA) para optimizar procesos de planificación territorial mediante el análisis de grandes volúmenes de datos y la identificación de patrones complejos [2], [6]. Algoritmos no supervisados como K-means, DBSCAN y modelos de mezcla gaussiana han demostrado utilidad en la delimitación de estructuras urbanas y la clasificación de territorios [8], [9].

Asimismo, técnicas de reducción de dimensionalidad no lineal como t-SNE [10] y UMAP [11] permiten visualizar estructuras espaciales complejas, facilitando la interpretación de datos urbanos multidimensionales. De manera complementaria, métricas como el coeficiente de Silueta [12], el índice de Calinski-Harabasz [13] y el índice de Davies-Bouldin [14] son ampliamente utilizadas para evaluar la coherencia interna y la calidad de los agrupamientos.

No obstante, el uso de la IA en planificación urbana no implica la sustitución del planificador, sino su fortalecimiento. La IA actúa como una herramienta de apoyo capaz de procesar información, identificar patrones y generar escenarios analíticos, mientras que la interpretación de resultados, la toma de decisiones y la contextualización territorial permanecen como funciones humanas fundamentales [21]. Esta relación complementaria resulta especialmente relevante en entornos educativos, donde la IA puede ser utilizada como soporte para el aprendizaje aplicado en planificación urbana.

C. Vulnerabilidad climática e infraestructura resiliente

Centroamérica constituye una de las regiones con mayor exposición a amenazas hidrometeorológicas del hemisferio occidental. La superposición entre asentamientos informales y zonas de riesgo incrementa la probabilidad de impactos desproporcionados en poblaciones vulnerables [4].

Sin embargo, aún no existe un modelo integrado que combine infraestructura, desigualdad socioeconómica y exposición climática dentro de un esquema de segmentación espacial basado en inteligencia artificial específicamente aplicado a esta región.

La literatura sobre movilidad periurbana y expansión urbana en América Latina sugiere que las desigualdades espaciales en el acceso a servicios básicos tienden a amplificar los efectos de eventos extremos [2], [3]. En este sentido, la incorporación de indicadores de riesgo climático dentro de esquemas de clustering urbano permite generar tipologías espaciales más robustas, orientadas a la planificación preventiva y la priorización de intervenciones en infraestructura resiliente.

D. Brecha conceptual identificada

Aunque existen revisiones sistemáticas sobre planificación urbana algorítmica [1], aún no se dispone de un marco integrado que combine de manera simultánea: infraestructura urbana, desigualdad socioeconómica y exposición climática dentro de un modelo unificado de segmentación espacial para ciudades centroamericanas. Adicionalmente, la mayoría de los enfoques existentes se han desarrollado en contextos distintos al latinoamericano y con un énfasis predominantemente técnico, sin considerar su aplicación en procesos formativos que permitan la interacción directa con herramientas de inteligencia artificial.

Tomando como referencia el marco de segmentación urbana propuesto en investigaciones recientes sobre planificación algorítmica en Latinoamérica [1], este trabajo amplía dicha aproximación incorporando una dimensión explícita de exposición climática, así como criterios de validación espacial robusta y su potencial aplicación en entornos académicos.

Entonces, el objetivo de esta investigación es desarrollar un marco de vulnerabilidad urbana basado en inteligencia artificial que permita identificar tipologías espaciales estructurales y apoyar la priorización de inversiones en infraestructura resiliente en ciudades centroamericanas, con potencial de implementación mediante herramientas de IA accesibles en procesos de formación en planificación urbana.

III. METODOLOGÍA

A. Diseño del estudio

Se adoptó un enfoque cuantitativo basado en análisis multivariado y técnicas de aprendizaje no supervisado, orientado a la identificación de patrones espaciales de vulnerabilidad urbana. Con fines de validación metodológica, se construyó un conjunto de datos sintético calibrado que representa cinco capitales centroamericanas seleccionadas por su tamaño poblacional, exposición climática y disponibilidad de datos abiertos: Ciudad de Guatemala, San Salvador, Tegucigalpa, San José y Ciudad de Panamá.

Estas urbes presentan patrones heterogéneos de expansión urbana, informalidad territorial y vulnerabilidad ante amenazas hidrometeorológicas, lo que permite evaluar la robustez del modelo en contextos diversos. Las distribuciones del conjunto de datos fueron informadas por estadísticas regionales y

estudios previos sobre expansión urbana y movilidad periurbana [2], [3].

Adicionalmente, el diseño metodológico se plantea como un esquema replicable que puede ser implementado mediante herramientas de inteligencia artificial y plataformas de análisis de datos accesibles, facilitando su aplicación en entornos académicos para el análisis urbano basado en datos.

B. Variables

Se definieron doce indicadores agrupados en tres dimensiones: Infraestructura, Socioeconómica y de Riesgo Climático.



Fig. 1 Diagrama Resumen de Variables de Análisis Urbano

Cada variable fue normalizada, bajo la siguiente ecuación:

$$Z_i = \frac{X_i - \mu}{\sigma}$$

donde X_i representa la observación original, μ la media y σ la desviación estándar. El conjunto de variables normalizadas conformó una matriz $\mathbf{X} \in \mathbb{R}^{n \times p}$, donde n corresponde al número de unidades espaciales y p al número de variables.

C. Reducción de dimensionalidad

Se aplicó Análisis de Componentes Principales (PCA), reteniendo aquellos componentes que explicaran al menos el 95% de la varianza acumulada. Complementariamente, se emplearon técnicas de reducción no lineal como UMAP [11] y t-SNE [10] para la visualización estructural de los datos y la identificación de patrones espaciales complejos.

Estas técnicas permiten representar relaciones multidimensionales en espacios de menor dimensión, facilitando la interpretación de resultados tanto en entornos analíticos como educativos.

D. Clustering

Se evaluaron múltiples algoritmos de clustering no supervisado, incluyendo K-means, DBSCAN, HDBSCAN y modelos de mezcla gaussiana (GMM), con el objetivo de identificar tipologías espaciales homogéneas.

La delimitación de fronteras urbanas mediante DBSCAN ha sido previamente explorada en contextos latinoamericanos [9], destacándose por su capacidad para identificar estructuras densas y detectar outliers en configuraciones urbanas complejas.

E. Validación

La validación del modelo se realizó mediante métricas de coherencia interna y estructura espacial, incluyendo el coeficiente de Silueta [12], el índice de Calinski-Harabasz [13], el índice de Davies-Bouldin [14] y el estadístico de autocorrelación espacial Moran's I [15].

Estos indicadores permiten evaluar la calidad de los agrupamientos desde una perspectiva cuantitativa y espacial, garantizando la consistencia interna del modelo y su capacidad para representar patrones territoriales significativos. Adicionalmente, se verificó la coherencia lógica entre dimensiones (infraestructura, socioeconómica y climática), asegurando la trazabilidad entre variables de entrada, procesos analíticos y resultados obtenidos.

F. Índice de Vulnerabilidad Urbana

El principal aporte metodológico del estudio consiste en la construcción de un Índice Compuesto de Vulnerabilidad Urbana (UVI), que integra las tres dimensiones analizadas. El índice se define como:

$$UVI = \alpha I_{infra}^{-1} + \beta I_{socio} + \gamma I_{climate}$$

donde:

I_{infra} = índice agregado de infraestructura

I_{socio} = índice socioeconómico

$I_{climate}$ = índice de exposición climática

α, β, γ = pesos de ponderación

La inversión del componente de infraestructura (I_{infra}^{-1}) responde a que mayores niveles de infraestructura implican menores niveles de vulnerabilidad.

Cada subíndice se calculó como promedio ponderado, donde: w_j representa los pesos derivados de cargas factoriales del PCA Z_j corresponde a las variables estandarizadas, en la ecuación.

$$I_k = \sum_{j=1}^m w_j Z_j$$

Los pesos α, β, γ fueron estimados mediante:

- 1) Análisis de cargas principales del PCA

- 2) Comparación con método *Analytic Hierarchy Process* (AHP)
- 3) Validación cruzada con zonas históricamente afectadas por desastres

Se impuso la restricción: $\alpha + \beta + \gamma = 1$

El UVI fue clasificada en quintiles para identificar niveles de vulnerabilidad: muy alta, alta, media, baja y muy baja. La distribución espacial del UVI fue superpuesta con los clusters obtenidos para analizar la coherencia estructural del modelo. [16].

El flujo metodológico propuesto es compatible con su implementación mediante herramientas de inteligencia artificial y plataformas de análisis de datos accesibles. Procesos como la normalización, reducción de dimensionalidad y clustering pueden ser ejecutados utilizando entornos como Python (Scikit-learn), Google Colab o plataformas visuales como Orange Data Mining y RapidMiner. Asimismo, herramientas de análisis geoespacial como QGIS o Google Earth Engine permiten integrar variables territoriales, mientras que plataformas de visualización como Power BI o Tableau facilitan la interpretación de resultados. Esta integración tecnológica permite que estudiantes de planificación urbana interactúen con datos reales, ejecuten modelos analíticos y generen escenarios urbanos sin requerir conocimientos avanzados de programación, en línea con el enfoque de inteligencia aumentada aplicado a la planificación.

IV. RESULTADOS

El análisis fue aplicado a un total de $n=1,245$ unidades espaciales provenientes de cinco capitales centroamericanas: Ciudad de Guatemala, San Salvador, Tegucigalpa, San José y Ciudad de Panamá. Todas las variables fueron previamente estandarizadas mediante transformación Z-score y armonizadas bajo el sistema de referencia geográfica WGS84.

El procesamiento analítico —incluyendo normalización, reducción de dimensionalidad, clustering y cálculo del índice compuesto— puede ser implementado mediante herramientas de inteligencia artificial y plataformas de análisis de datos, permitiendo su replicabilidad en entornos académicos y su uso por estudiantes en procesos de análisis urbano aplicado.

A. Reducción de dimensionalidad

El Análisis de Componentes Principales (PCA) indicó que los primeros seis componentes explicaron el 92.4% de la varianza acumulada, mientras que ocho componentes alcanzaron el umbral del 95%. Los mayores aportes factoriales estuvieron asociados a cobertura de infraestructura básica, densidad poblacional e índices de exposición a inundación.

La Fig. 2 muestra el comportamiento de la varianza explicada y su acumulación progresiva, evidenciando un punto de inflexión

a partir del cuarto componente y la estabilización del modelo en el octavo componente.




Fig. 2. Varianza acumulada explicada por componentes principales.

Las proyecciones no lineales mediante UMAP evidenciaron una separación estructural clara entre agrupaciones espaciales diferenciadas. Las cargas factoriales revelaron una correlación positiva entre informalidad habitacional y exposición climática, lo que sugiere una superposición espacial de vulnerabilidades estructurales.

La visualización mediante UMAP y t-SNE permitió identificar una separación parcial entre núcleos urbanos consolidados y periferias de expansión reciente, confirmando la presencia de estructuras espaciales no lineales.




Fig. 3. Proyección UMAP de unidades espaciales coloreadas por asignación de conglomerados.

La dispersión observada sugiere que la estructura urbana presenta configuraciones complejas que justifican el uso de algoritmos basados en densidad.

B. Comparación de algoritmos de clustering

La Tabla I resume las métricas de validación obtenidas para los cuatro algoritmos implementados.

TABLA I
COMPARACIÓN DE DESEMPEÑO DE ALGORITMOS DE CLUSTERING

Algoritmo	Nº Clusters	Silhouette	Calinski-Harabasz	Davies-Bouldin
<i>K-means</i>	3	0.51	412.8	0.72
<i>DBSCAN</i>	5	0.38	189.4	1.12
<i>HDBSCAN</i>	4	0.56	435.6	0.68
<i>GMM</i>	3	0.49	398.2	0.79

HDBSCAN presentó el mejor equilibrio entre cohesión interna y separación intercluster, evidenciado por el mayor índice Silhouette (0.56) y el menor índice Davies-Bouldin (0.68). Asimismo, mostró una estabilidad del 86% en pruebas de bootstrapping, lo que confirma su robustez frente a variaciones en los datos.

Por su parte, DBSCAN identificó zonas de baja densidad como ruido espacial, representando aproximadamente el 14.7% de las unidades analizadas, lo cual es consistente con la presencia de áreas urbanas dispersas o en transición. Desde una perspectiva aplicada, estos algoritmos pueden ser ejecutados mediante herramientas de inteligencia artificial accesibles (como entornos de machine learning automatizado), lo que permite su incorporación en procesos de enseñanza-aprendizaje para la identificación de tipologías urbanas.

C. Estructura espacial de los clusters

El modelo óptimo (HDBSCAN) identificó cuatro tipologías urbanas diferenciadas, ilustradas en la Fig. 4.

- Cluster A – Núcleos consolidados: Alta cobertura de infraestructura, baja exposición climática y mayores ingresos promedio.
- Cluster B – Periferias intermedias: Infraestructura moderada, densidad media y riesgo climático variable.
- Cluster C – Zonas de transición informal: Alta densidad poblacional, cobertura limitada de servicios y elevada exposición a inundaciones.
- Cluster D – Áreas de alta vulnerabilidad estructural: Baja infraestructura, bajos ingresos y alta susceptibilidad a deslizamientos e inundaciones.




Fig. 4 Distribución espacial de los grupos urbanos identificados mediante HDBSCAN.

Se observa que las zonas de alta vulnerabilidad estructural se concentran en periferias topográficamente inestables y áreas

expuestas a inundaciones recurrentes. La distribución espacial mostró patrones consistentes entre ciudades, particularmente en Guatemala y Tegucigalpa, donde estas áreas se localizan en laderas y zonas periurbanas no planificadas.

D. Resultados del Urban Vulnerability Index (UVI)

El índice compuesto UVI presentó valores en el rango normalizado [0, 1]. La clasificación por quintiles indicó: 18.2% de unidades en categoría de vulnerabilidad muy alta, 24.5% en alta, 27.1% en media, 19.3% en baja y 10.9% en muy baja. El análisis de superposición entre clusters y UVI mostró que el 82% de las unidades clasificadas como vulnerabilidad muy alta coincidieron con el Cluster D, lo que valida la coherencia estructural entre el modelo de segmentación y el índice compuesto.




Fig. 5 Distribución espacial del Índice de Vulnerabilidad Urbana (UVI).

El estadístico de Moran's I para el UVI fue: $I = 0.63$ ($p < 0.01$) lo que indica autocorrelación espacial positiva significativa. Esto confirma que la vulnerabilidad urbana no se distribuye aleatoriamente, sino que presenta patrones territoriales concentrados. La Fig. 6 presenta la distribución porcentual de categorías UVI dentro de cada clúster.




Fig. 6 Distribución de categorías UVI dentro de cada grupo identificado.

La Tabla II resume la distribución porcentual de vulnerabilidad por ciudad. Tegucigalpa presentó la mayor proporción de vulnerabilidad alta y muy alta, mientras que San José mostró mayor presencia de núcleos consolidados.

TABLA II
DISTRIBUCIÓN PORCENTUAL DEL UVI POR CIUDAD

Ciudad	Muy Alta	Alta	Media	Baja	Muy Baja
Ciudad de Guatemala	22%	26%	24%	18%	10%
San Salvador	19%	25%	28%	17%	11%
Tegucigalpa MDC	28%	18%	26%	16%	12%
San José	11%	21%	29%	25%	14%
Ciudad de Panamá	14%	24%	30%	20%	12%

Nota: Tegucigalpa mayor vulnerabilidad estructural y San José menor exposición acumulada.

El análisis territorial evidenció diferencias significativas entre ciudades:

- **Tegucigalpa** presentó la mayor proporción de unidades en vulnerabilidad alta y muy alta (46%), asociada a condiciones topográficas complejas y expansión no planificada.
- **San José** mostró mayor concentración de núcleos consolidados (Cluster A), reflejando una estructura urbana más estable.
- **Ciudad de Guatemala** evidenció mayor fragmentación espacial y presencia significativa de zonas de transición informal.

Estos resultados sugieren que, aunque existen patrones regionales comunes, la intensidad de la vulnerabilidad urbana varía en función de la configuración territorial local.

TABLA III
DISTRIBUCIÓN PORCENTUAL DE LA UVI POR CIUDAD

Cluster	UMAP-1 (μ)	UMAP-2 (μ)	Tamaño (%)
A	-2.1	3.4	27%
B	1.8	2.9	24%
C	-3.7	-1.2	21%
D	2.5	-2.8	28%

E. Escenario de aplicación mediante inteligencia artificial

Con el fin de validar la aplicabilidad del modelo en contextos educativos y operativos, se simuló su implementación mediante herramientas de inteligencia artificial orientadas al análisis de datos urbanos. El flujo de aplicación inicia con la recopilación de datos provenientes de fuentes abiertas como World Bank, OpenStreetMap, Think Hazard y Weatherspark integrando variables de infraestructura, condiciones socioeconómicas y exposición climática.

Posteriormente, el procesamiento de datos —incluyendo normalización, reducción de dimensionalidad (PCA, UMAP, t-SNE) y clustering (K-means, DBSCAN, HDBSCAN y GMM)— puede ser ejecutado mediante entornos asistidos por inteligencia artificial que no requieren programación avanzada, como plataformas visuales de análisis de datos (por ejemplo, Orange Data Mining) o cuadernos en la nube preconfigurados en Google Colab, donde los algoritmos pueden implementarse mediante plantillas, interfaces gráficas o scripts reutilizables guiados.

La generación de tipologías espaciales y el cálculo automatizado del Índice de Vulnerabilidad Urbana (UVI) se realizan a partir de estos procesos analíticos, mientras que la visualización y el análisis territorial pueden desarrollarse mediante sistemas de información geográfica de uso extendido como QGIS y plataformas de visualización interactiva como Power BI, que permiten interpretar resultados mediante mapas, dashboards y representaciones espaciales sin requerir desarrollo de código.




Fig. 7 Ejemplo del producto final entregable del trabajo de modelado de datos.

Este flujo metodológico está diseñado para ser ejecutado por estudiantes de arquitectura o planificación urbana sin formación especializada en programación, apoyándose en herramientas de inteligencia artificial que automatizan los procesos analíticos y reducen la complejidad técnica. En este sentido, la IA actúa como un mediador cognitivo que facilita la exploración de datos, la generación de patrones y la simulación de escenarios, mientras que la interpretación crítica y la toma de decisiones permanecen como competencias centrales del estudiante.

Es así que el modelo cumple una función analítica, y también es útil como herramienta pedagógica accesible que permite la comprensión y aplicación de sistemas urbanos complejos mediante el uso asistido de inteligencia artificial.

V. CONCLUSIONES

Este estudio desarrolló y validó un marco de segmentación urbana basado en inteligencia artificial, integrando variables de infraestructura, desigualdad socioeconómica y exposición climática en ciudades centroamericanas. Desde una perspectiva arquitectónica y territorial, el modelo permite interpretar la ciudad como un sistema complejo donde las condiciones físicas del entorno construido actúan como determinantes estructurales de la vulnerabilidad.

Los resultados evidencian que las configuraciones urbanas en la región responden a patrones no lineales y policéntricos, en los que las áreas con mayor vulnerabilidad concentran simultáneamente déficits de infraestructura y alta exposición a amenazas hidrometeorológicas. Este hallazgo refuerza la

necesidad de abordar el diseño urbano no como una distribución homogénea, sino como un sistema de relaciones espaciales diferenciadas.

La superioridad del algoritmo HDBSCAN confirma que los fenómenos urbanos regionales presentan densidades variables, lo que valida el uso de enfoques basados en clustering adaptativo frente a modelos tradicionales centrados en centroides. Esto tiene implicaciones directas en la planificación arquitectónica y urbana, donde la lectura de patrones espaciales debe responder a dinámicas territoriales heterogéneas.

La construcción del Urban Vulnerability Index (UVI) permitió identificar zonas críticas con alta coherencia espacial (Moran's $I = 0.63$), evidenciando procesos de concentración territorial del riesgo. La correspondencia entre el Cluster D y los niveles más altos del UVI valida la consistencia interna del modelo y su aplicabilidad como instrumento de diagnóstico espacial.

Desde la ingeniería y arquitectura del entorno construido, el framework propuesto organiza una herramienta reproducible para la priorización territorial, la planificación adaptativa y la toma de decisiones en infraestructura urbana. En contextos de creciente incertidumbre climática, este tipo de análisis puede orientar intervenciones físicas del territorio hacia estrategias más resilientes, eficientes y basadas en evidencia.

Finalmente, el estudio contribuye a la literatura al integrar de manera explícita el riesgo climático en modelos de clustering urbano aplicados al contexto centroamericano, estableciendo una base metodológica replicable para futuros análisis en ciudades latinoamericanas. Este aporte responde a la necesidad contemporánea de articular inteligencia artificial, diseño urbano y sostenibilidad en la planificación de territorios más equitativos y resilientes. En este sentido, el artículo propone un marco de segmentación urbana basado en IA que integra infraestructura, desigualdad socioeconómica y exposición climática, cuya aplicabilidad ha sido demostrada tanto en contextos analíticos como educativos, presentando un ejemplo de utilización de tecnología tipo IA para mejorar proceso y enseñanza para seguir creando grandes comunidades para todos de formas equitativas y tecnológicamente avanzadas.

VI. LIMITACIONES Y TRABAJO FUTURO

Si bien el modelo propuesto demuestra robustez metodológica y coherencia espacial, existen limitaciones que deben considerarse en la interpretación de los resultados.

En primer lugar, la disponibilidad, resolución y actualización de los datos varía entre países centroamericanos, lo que introduce heterogeneidad en la precisión del análisis espacial. Aunque se implementaron procesos de armonización geoespacial, las diferencias en metodologías censales y escalas temporales pueden afectar la comparabilidad interurbana.

En segundo lugar, el Urban Vulnerability Index (UVI) se construyó a partir de variables estructurales estáticas del entorno construido. No se incorporaron dinámicas temporales como expansión urbana, migración o escenarios climáticos futuros, lo que limita la capacidad predictiva del modelo. Esta limitación es relevante considerando que el entorno construido influye de manera directa en el bienestar, comportamiento y desempeño humano, por lo que su evolución temporal es clave en análisis prospectivos.

El uso de técnicas no supervisadas implica que la interpretación semántica de los clusters depende del análisis posterior del investigador. Aunque se aplicaron métricas de validación robustas (Silhouette, Calinski-Harabasz, Davies-Bouldin y Moran's I), los resultados deben entenderse como una segmentación exploratoria y no como una clasificación normativa definitiva. Adicionalmente, el modelo no incorporó variables relacionadas con gobernanza urbana, inversión pública ni capacidad institucional, factores que influyen significativamente en la resiliencia del entorno construido y en la calidad de vida de los usuarios, dado que la arquitectura y el espacio no solo alojan funciones físicas, sino también procesos sociales y cognitivos asociados al bienestar humano.

Como líneas de trabajo futuro, se propone las siguientes líneas de investigación para fortalecer el modelo:

1. Integrar modelos predictivos de expansión urbana mediante aprendizaje supervisado, incorporando variables morfológicas del tejido urbano.
2. Incorporar escenarios climáticos proyectados (RCP/SSP) para análisis prospectivo del riesgo territorial.
3. Desarrollar dashboards interactivos que permitan la visualización dinámica de patrones urbanos para la toma de decisiones en tiempo real.
4. Aplicar el framework a ciudades intermedias y corredores metropolitanos, ampliando su escala de análisis.
5. Integrar el modelo con sistemas de gemelos digitales urbanos, vinculando datos físicos, ambientales y sociales.
6. Incorporar variables del entorno construido relacionadas con confort ambiental (temperatura, calidad del aire, iluminación), dado su impacto directo en el desempeño cognitivo y fisiológico de los usuarios.

Estas extensiones permitirían evolucionar el modelo desde un instrumento diagnóstico hacia una herramienta de planificación adaptativa de largo plazo.

REFERENCIAS

- [1] T. H. Son, Z. Weedon, T. Yigitcanlar, T. Sanchez, J. M. Corchado, and R. Mehmood, "Algorithmic urban planning for smart and sustainable development: Systematic review of the literature," *Sustain. Cities Soc.*, vol. 94, 2023, Art. no. 104562, doi: 10.1016/j.scs.2023.104562.

- [2] I. Tiznado-Aitken, G. Vecchio, L. A. Guzman, J. Arellana, M. Humberto, E. Vasconcellos, and J. C. Muñoz, "Unequal periurban mobility: Travel patterns, modal choices and urban core dependence in Latin America," *Habitat Int.*, vol. 133, 2023, Art. no. 102752, doi: 10.1016/j.habitatint.2023.102752.
- [3] C. Silva and F. Vergara-Perucich, "Determinants of urban sprawl in Latin America: Evidence from Santiago de Chile," *SN Soc. Sci.*, vol. 1, no. 8, 2021, Art. no. 202, doi: 10.1007/s43545-021-00197-4.
- [4] T. A. Muñoz-Erickson et al., "Beyond bouncing back? Comparing and contesting urban resilience frames in US and Latin American contexts," *Landscape Urban Plan.*, vol. 214, 2021, Art. no. 104173, doi: 10.1016/j.landurbplan.2021.104173
- [5] T. W. Sanchez, H. Shumway, T. Gordner, and T. Lim, "The prospects of artificial intelligence in urban planning," *Int. J. Urban Sci.*, vol. 27, no. 2, pp. 179–194, 2023, doi: 10.1080/12265934.2022.2102538
- [6] Y. Casali, N. Y. Aydin, and T. Comes, "Machine learning for spatial analyses in urban areas: A scoping review," *Sustain. Cities Soc.*, vol. 85, 2022, Art. no. 104050, doi: 10.1016/j.scs.2022.104050
- [7] C. Vera et al., "Learning to cluster urban areas: Two competitive approaches and an empirical validation," *EPJ Data Sci.*, vol. 11, no. 1, 2022, Art. no. 62, doi: 10.1140/epjds/s13688-022-00374-2
- [8] A. Reyes et al., "SpatialCluster: A Python library for urban clustering," *SoftwareX*, vol. 26, 2024, Art. no. 101739, doi: 10.1016/j.softx.2024.101739
- [9] C. A. Caudillo-Cos, J. A. Montejano-Escamilla, R. Tapia-McClung, F. G. Ávila-Jiménez, and I. G. Barrera-Alarcón, "Defining urban boundaries through DBSCAN and Shannon's entropy: The case of the Mexican National Urban System," *Cities*, vol. 149, 2024, Art. no. 104969, doi: 10.1016/j.cities.2024.104969
- [10] L. van der Maaten and G. Hinton, "Visualizing Data using t-SNE," *Journal of Machine Learning Research*, vol. 9, pp. 2579–2605, Nov. 2008. [Online]. Available: <https://jmlr.org/papers/volume9/vandermaaten08a/vandermaaten08a.pdf>
- [11] L. McInnes, J. Healy, and J. Melville, "UMAP: Uniform manifold approximation and projection for dimension reduction," *arXiv preprint arXiv:1802.03426*, 2018. <https://doi.org/10.48550/arXiv.1802.03426>
- [12] P. J. Rousseeuw, "Silhouettes: A graphical aid to the interpretation and validation of cluster analysis," *J. Comput. Appl. Math.*, vol. 20, pp. 53–65, 1987. [https://doi.org/10.1016/0377-0427\(87\)90125-7](https://doi.org/10.1016/0377-0427(87)90125-7)
- [13] T. Calinski and J. Harabasz, "A dendrite method for cluster analysis," *Commun. Stat.*, vol. 3, no. 1, pp. 1–27, 1974. [Online]. Available:
- [14] D. L. Davies and D. W. Bouldin, "A cluster separation measure," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. PAMI-1, no. 2, pp. 224–227, 1979. [Online]. Available: <https://ieeexplore.ieee.org/document/4766909>
- [15] P. Moran, "Notes on continuous stochastic phenomena," *Biometrika*, vol. 37, no. 1/2, pp. 17–23, 1950.
- [16] T. L. Saaty, "Decision making with the analytic hierarchy process," *Int. J. Serv. Sci.*, vol. 1, no. 1, pp. 83–98, 2008.
- [17] EM-DAT: The International Disaster Database, Université Catholique de Louvain (UCLouvain), Brussels, Belgium. [En línea]. Disponible en: <https://www.emdat.be>
- [18] OpenStreetMap contributors, "Planet dump retrieved from <https://planet.osm.org>," 2024. [En línea]. Disponible en: <https://www.openstreetmap.org>
- [19] NASA, "Landsat 8 Data Users Handbook," NASA Goddard Space Flight Center, Greenbelt, MD, USA, 2022. [En línea]. Disponible en: <https://landsat.gsfc.nasa.gov>
- [20] Sentinel-2 User Handbook, European Space Agency (ESA), 2023. [En línea]. Disponible en: <https://sentinel.esa.int>
- [21] K. Al Chami, A. T. Estévez y Y. K. Abdallah, "Neuroarquitectura: mejorar el bienestar y la productividad a través del diseño espacial," *Cuaderno 220 | Centro de Estudios en Diseño y Comunicación*, pp. 135–159, 2024. Disponible en: https://planning-org-uploaded-media.s3.amazonaws.com/publication/download_pdf/AI-in-Planning-White-Paper-Rev.pdf?fbclid=IwY2xjawRIF-xleHRuA2FlbQlXMQBzcnRjBmFwcF9pZAwwzNTA2ODU1MzE3MjgAAR4iqrtllUftYjxan5uCO_Ptqm6aHYGBLbORm87KfOvcA1S3DgRRQ_8-bhWGMQ_aem_lsu2T0gqsXHgGBpUlzj_VQ