

Evaluación de algoritmos de inteligencia artificial para predecir la expansión urbana

Assessing Artificial Intelligence's Algorithms for Urban Expansion Prediction

Recibido: 05/11/2024 | Aceptado: 08/05/2025
 <https://doi.org/10.48162/rev.55.072>

Ignacio Iturrioz

Consejo Nacional de Investigaciones Científicas y Técnicas, Instituto de Geografía, Historia y Ciencias Sociales (IGEHCS). Centro de Investigaciones Geográficas, Facultad de Ciencias Humanas Universidad Nacional del Centro de la Provincia de Buenos Aires Tandil, Buenos Aires, Argentina.

 <https://orcid.org/0000-0003-0000-7811>
igiturrioz@fch.unicen.edu.ar

Santiago Linares

Consejo Nacional de Investigaciones Científicas y Técnicas - Instituto de Geografía, Historia y Ciencias Sociales (IGEHCS). Centro de Investigaciones Geográficas - Facultad de Ciencias Humanas - Universidad Nacional del Centro de la Provincia de Buenos Aires. Tandil, Argentina

 <https://orcid.org/0000-0003-4989-1230>
sllinares@fch.unicen.edu.ar

Liliana Ramírez

Consejo Nacional de Investigaciones Científicas y Técnicas - Instituto de Investigación para el Desarrollo Territorial y del Hábitat Humano - Instituto de Geografía - Facultad de Humanidades - Universidad Nacional del Nordeste. Resistencia, Chaco.

 <https://orcid.org/0000-0002-6312-1657>
lramirez@hum.unne.edu.ar

Cómo citar: Iturrioz, I.; Linares, S. y Ramírez, L. (2025). Evaluación de algoritmos de inteligencia artificial para predecir la expansión urbana. *Revista Proyección, Estudios Geográficos y de Ordenamiento Territorial*, (37), Instituto CIFOT, Universidad Nacional De Cuyo, 96-126, ISSN 1852-0006.

Resumen: El crecimiento urbano y su modelización es un fenómeno que ha sido objeto de numerosos estudios por parte de la comunidad científica durante décadas (Linares, 2016). Podemos identificar que un proceso de modelización de la expansión urbana se necesita como mínimo de una secuenciación de seis fases: adquisición y normalización de datos de entrada, ponderación de los factores y construcción de mapas de transición potencial, elección del método para calcular la cantidad de cambio, inclusión de parámetros adicionales, validación del modelo y simulación de escenarios. Son amplios los antecedentes que aplican esta secuenciación, aunque resultan aún escasas las contribuciones que comparan y discuten la sensibilidad de modelos implementados sobre una misma área de estudio. A los fines de contribuir sobre este aspecto es que presentamos en este artículo una aplicación de modelización de la expansión urbana sobre la Ciudad de Tandil (provincia de Buenos Aires, Argentina), con el objetivo de realizar una comparación y discusión de seis algoritmos basados en inteligencia artificial que

permiten ponderar diferencialmente factores para predecir la expansión. A partir de dicha aplicación fue posible construir seis mapas de transición potencial de suelo no edificado a edificado, utilizando el software *TerrSet* y su módulo *Land Change Modeler*.

Palabras clave: crecimiento urbano, modelo de simulación, inteligencia artificial

Abstract: Urban growth is a multifaceted subject extensively studied and modeled by scientists for decades (Linares, 2017). The modeling process of urban expansion typically involves a sequence of six phases: acquiring and normalizing input data, weighting factors and constructing potential transition maps, selecting a method to calculate change, incorporating additional parameters, validating the model, and simulating scenarios. While there is substantial literature applying these phases to generate hypothetical future city scenarios, few studies compare and discuss the sensitivity of models applied to the same area. This article contributes to this field by applying an urban expansion modeling process to the City of Tandil (Buenos Aires Province, Argentina), comparing and discussing six artificial intelligence-based algorithms for differential factor weighting to predict expansion: distance to road networks, routes, city center, built surfaces, electrical services, water services, sewer services, slope, and elevation. Using *TerrSet* software and the *Land Change Modeler* module, we constructed six potential transition maps from unbuilt to built land. Notably, the potential transition models derived from vector-based automated learning, logistic regression, and decision trees suggest a predominantly diffuse expansion pattern, whereas the weighted normalized probability model and case-based learning approach suggest a different expansion trend.

Keywords: Urban growth, Simulation models, Artificial intelligence

Introducción

Las tendencias comunes en las formas de expansión urbana en América Latina de las últimas décadas han sido estudiadas por una diversidad de investigadores, y pueden abordarse en ciertas líneas concretas (Spósito y Spósito, 2020; Potocko y Tella, 2019; Di Virgilio y Perelman, 2014; Buzai, 2014; Müller y Mertins, 2005; Janoschka, 2002). En primer lugar, los procesos de fragmentación urbana o ciudad difusa, en los que se analiza la expansión dispersa de las ciudades hacia las áreas periféricas en forma de “salto de rana” más que la forma de expansión tradicional en forma de “mancha de aceite”; en donde se desarrollan barrios residenciales, complejos industriales y comerciales. Vinculado con esto, en segundo lugar, el crecimiento desordenado y no planificado es otra de las tendencias comunes, emparentado a la inexistencia de un plan de desarrollo urbano o a la omisión de indicadores urbanísticos en los planes existentes, ello da lugar al crecimiento urbano sin acceso a servicios básicos, equipamientos o infraestructura básica, como también irregularidades y ocupación de tierras. Estas nuevas formas de crecimiento urbano dispersas están vinculadas directamente con otros procesos como la fragmentación socioespacial en la que los espacios de expansión urbana carecen de contigüidad, alternando entre zonas de segregación, pobreza y vulnerabilidad, y áreas de mayores ingresos o estratos socioeconómicos altos.

En este contexto, otros ejes de estudios son los procesos de densificación y verticalización de áreas centrales principalmente en centros dinámicos, a la par de la renovación y revalorización de espacios públicos o degradados vinculados

a la gentrificación, al mismo tiempo que existe un crecimiento de la urbanización informal con viviendas precarias, falta de acceso a servicios e incapacidad del Estado de dar respuesta a las problemáticas habitacionales. Finalmente, otra línea es el análisis de la proliferación de subcentros comerciales, las nuevas centralidades, multicentralidades y renovación de centros es otra de las temáticas abordadas en estas tendencias, también vinculada directamente con las antes mencionadas. Este conjunto de fenómenos plantea desafíos significativos para la planificación urbana y el desarrollo sostenible de la ciudad, haciendo urgente la investigación de soluciones efectivas que permitan afrontar estos problemas de manera integral.

Se han realizado avances significativos sobre la identificación de los factores comunes que promueven estos procesos de expansión de las ciudades argentinas y determinan que un área urbana complementaria o rural se transforme en un lapso de tiempo en superficie edificada (Gómez Delgado y Rodríguez Espinosa, 2012; Gallardo, 2018). El análisis tanto conceptual como empírico ha permitido en principio detectar y clasificar dos grandes jerarquías de factores: macro factores y micro factores. Dentro de los macro factores comunes que suelen promover la expansión urbana podemos mencionar al crecimiento demográfico, el desarrollo económico, la diversificación económica, el cambio cultural, el acceso a tecnologías de la información y las comunicaciones, los cambios en la economía global, la migración internacional y otras tendencias globales que pueden influir en la expansión urbana al afectar la demanda de mano de obra y recursos en las ciudades. Por su parte, dentro de los microfactores se encuentran aquellos relacionados con la accesibilidad, características biofísicas, socioeconómicas y normas de planificación urbana, como pueden ser la infraestructura de transporte, la disponibilidad de tierras, las políticas de desarrollo urbano, la infraestructura de servicios urbanos, la dinámica del sector inmobiliario, la atracción turística; los factores ambientales, la seguridad y tranquilidad, las amenidades socialmente construidas, la accesibilidad a equipamientos colectivos.

El propósito de los estudios de expansión urbana es anticiparse a los potenciales impactos negativos en el medio ambiente, la sociedad y la economía (Henríquez, 2014; Veldkamp y Verburg, 2004, Pauleit, Ennos y Golding, 2005). Dentro de los más destacados podríamos citar la pérdida de biodiversidad, entendiendo por ello a la conversión de áreas naturales en áreas urbanizadas, fragmentando los hábitats naturales, dificultando la movilidad de la fauna, reduciendo la diversidad genética, lo cual conlleva a la disminución de la biodiversidad y la extinción de especies locales. La deforestación y pérdida de espacios verdes es otro impacto estudiado, dado que la expansión urbana a menudo implica la tala de bosques y la destrucción de áreas verdes, contribuyendo a la reducción de la cobertura vegetal y a la disminución de la calidad del aire y del agua; asimismo, al eliminar

la vegetación protectora se alteran también los patrones naturales de drenaje y ello puede aumentar el riesgo de inundaciones y deslizamientos de tierra.

Otros efectos no deseados se asocian al aumento de vehículos, industrias y actividades urbanas que pueden incrementar la contaminación atmosférica y del agua, lo que afecta negativamente la salud de los residentes y el medio ambiente. La congestión vehicular es un impacto negativo, debido al aumento de movilidad diaria de la población desde distancias cada vez mayores y la falta de infraestructura adecuada para gestionar el flujo de tráfico, los tiempos de movilidad entorpecen la vida cotidiana. El rápido crecimiento urbano puede también ejercer una presión significativa sobre la infraestructura y servicios básicos como agua, saneamiento, electricidad y atención médica, lo que puede resultar en una saturación de la capacidad de carga y generar una dotación de servicios insuficientes para la población recientemente localizada; de la misma manera puede impactar en escasez de espacios públicos, parques y áreas de recreación, lo que afecta negativamente la calidad de vida de los residentes y su bienestar social. Desde un punto de vista sociocultural, la expansión urbana sin planificación puede profundizar la desigualdad socioeconómica al aglomerar la pobreza en áreas periféricas marginales, mientras que otros ejes de desarrollo residencial promovidos desde el sector inmobiliario concentran población de estratos socioeconómicos de mayor ingreso, generando barreras económicas y simbólicas para la interacción.

Como hemos intentado describir en los párrafos anteriores, la investigación acerca de la expansión urbana, sus causas y consecuencias, es tan amplia y diversa que implica un recorte necesario a partir de los objetivos que se planean alcanzar en cada indagación. En este universo de abordajes, a partir de la segunda mitad del siglo XX, la aplicación de métodos cuantitativos en la Geografía permitió una comprensión más profunda de los procesos de expansión urbana. Esto incluyó el uso de modelos matemáticos, estadísticos y econométricos para analizar factores condicionantes, como la demografía, la economía y la infraestructura. Estos enfoques cuantitativos brindaron herramientas poderosas para la predicción y planificación del desarrollo urbano (Wegener, 1994; Li y Gong, 2016). Al emplear técnicas cuantitativas avanzadas y modelos matemáticos, los profesionales e investigadores pueden realizar análisis precisos y detallados de los procesos urbanos, desde la distribución de la población hasta la dinámica del uso del suelo. Esta combinación de enfoques cuantitativos y racionales ayuda a fundamentar las decisiones de planificación urbana con evidencia empírica sólida.

La introducción de Tecnologías de la Información Geográfica (TIG) en las últimas décadas ha revolucionado aún más la forma en que se abordan los procesos de expansión urbana. Los Sistemas de Información Geográfica (SIG) permiten la

captura, almacenamiento, análisis y visualización de datos geoespaciales a una escala sin precedentes. Esto ha facilitado la creación de modelos de simulación, análisis de patrones espaciales y evaluaciones de impacto ambiental y socioeconómico provocados por la expansión urbana en diferentes ciudades del planeta (Camacho Olmedo *et al.*, 2018).

En la actualidad, la integración de métodos cuantitativos y TIG ha llevado a un enfoque multidimensional basado en datos para comprender los procesos de expansión urbana. Los investigadores y planificadores urbanos utilizan herramientas avanzadas de análisis espacial y modelado para identificar tendencias, evaluar escenarios futuros y tomar decisiones informadas sobre políticas de desarrollo urbano (Hassan y Elhassan, 2020). Estos recursos surgen de una alianza virtuosa entre la inteligencia artificial (IA) y la inteligencia geográfica que se entrelazan de manera sinérgica para ofrecer soluciones innovadoras en el análisis y la comprensión de datos geoespaciales (Alastal y Shaqfa, 2022). La IA, mediante algoritmos de aprendizaje automático y procesamiento de datos masivos, potencia la capacidad de la inteligencia geográfica para extraer conocimientos significativos de la información espacial. Esta combinación permite a los investigadores y planificadores urbanos en la actualidad analizar patrones complejos de expansión urbana y tomar decisiones informadas sobre el desarrollo de las ciudades del futuro.

Si bien la irrupción masiva de la IA puede datar de los años 2010, en términos de evolución, el concepto de automatización que puede imitar la inteligencia humana se encuentra en la mitología y la filosofía de civilizaciones antiguas, como la idea de autómatas en la mitología griega. En efecto, la IA ha adquirido un gran protagonismo en muchas áreas de la tecnología, y las TIG no son una excepción. La fusión de estos dos campos se conoce como *Geospatial Artificial Intelligence* (GeoAI).

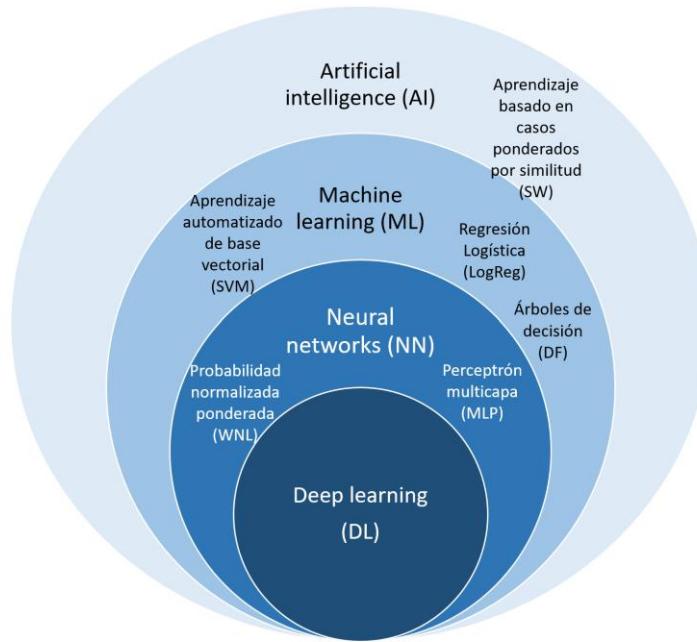
El concepto de GeoAI se puede definir como el uso de técnicas de inteligencia artificial, incluyendo aprendizaje automático y aprendizaje profundo, en el análisis de datos geoespaciales para resolver problemas que tienen componentes espaciales o geográficos con el objetivo de mejorar el análisis, interpretación y predicción de fenómenos espaciales complejos. Aunque no hay un único creador del concepto, fue popularizado por investigadores como Dr. Shaowen Wang, del CyberGIS Center for Advanced Digital and Spatial Studies en la Universidad de Illinois quien junto con su equipo han contribuido significativamente a su desarrollo teórico y práctico. No obstante, en el desarrollo y la amplia difusión de la GEOIA podemos citar tres actores importantes: instituciones, académicos y empresas. Así por ejemplo la NASA, con proyectos de observación terrestre usando redes neuronales para monitorear el cambio climático y la deforestación; la academia, a través de

publicaciones en revistas como *Computers, Environment and Urban Systems*, *International Journal of Geographical Information Science* o *Transactions in GIS* que han tratado ampliamente el tema desde 2016 en adelante; y la empresa que Esri que ha publicado múltiples documentos técnicos y promovido el uso de GeoAI en su software (ArcGIS) mediante integraciones con Python, scikit-learn y TensorFlow.

En el campo de estudios de la ciencia geográfica la GeoAI puede utilizarse para una amplia gama de aplicaciones, como la detección de cambios en el paisaje, la monitorización de recursos naturales, la agricultura de precisión, la gestión de desastres, la planificación urbana y rural, entre otros (Li *et al.*, 2024)

Sin dudas que en las últimas décadas las TIG se han visto muy beneficiadas por los diferentes tipos de IA dentro de la cual sobresalen el *Machine Learning* (ML), *Neural Network* (NN) y *Deep Learning* (DL), cada uno de estos tipos de IA envuelven una importante cantidad de técnicas y procedimientos automatizados que, previa transcripción a algoritmos avanzados en entornos computacionales, son empleados para procesar, interpretar, extraer, clasificar, ponderar y predecir patrones y procesos socioeconómicos y ambientales en el espacio geográfico y, particularmente en este artículo, emplearemos alguno de ellos que consideramos idóneos para modelar las complejas relaciones funcionales (lineales y no lineales) entre los factores que promueven el cambio de uso del suelo y expansión urbana (Figura N.^o 1).

Figura N.º 1. Diagrama de Venn de algoritmos de aprendizaje automático empleados para generar mapas de transición potencial de expansión urbana



Fuente: elaborado por Linares (2017), Santiago con base en Chiu, Chao y Chen, 2022, p. 3.

Considerando específicamente el propósito de este trabajo que pretende revisar y comparar las bondades de los diferentes algoritmos para descifrar las relaciones funcionales entre factores y cambios, y así poder construir digitalmente un mapa de transición potencial y modelar el crecimiento de las ciudades, emplearemos los métodos que se encuentran contenidos en el módulo de *Land Change Modeler* del programa *TerrSet 2020 Geospatial Monitoring and Modeling Software*, específicamente los siguientes: perceptrón multicapa (*Multi-Layer Perceptron*, MLP), árboles de decisión (*Dicison Forest*, DF), regresión logística (*Logistic Regression*, LogReg), probabilidad normalizada ponderada (*Weighted Normalized Likelihood*, WNL), aprendizaje basado en casos ponderados por similitud (*Similarity Weighted instance-based learning*, SW) y aprendizaje automatizado de base vectorial (*Support Vector Machine classifier*, SVM).

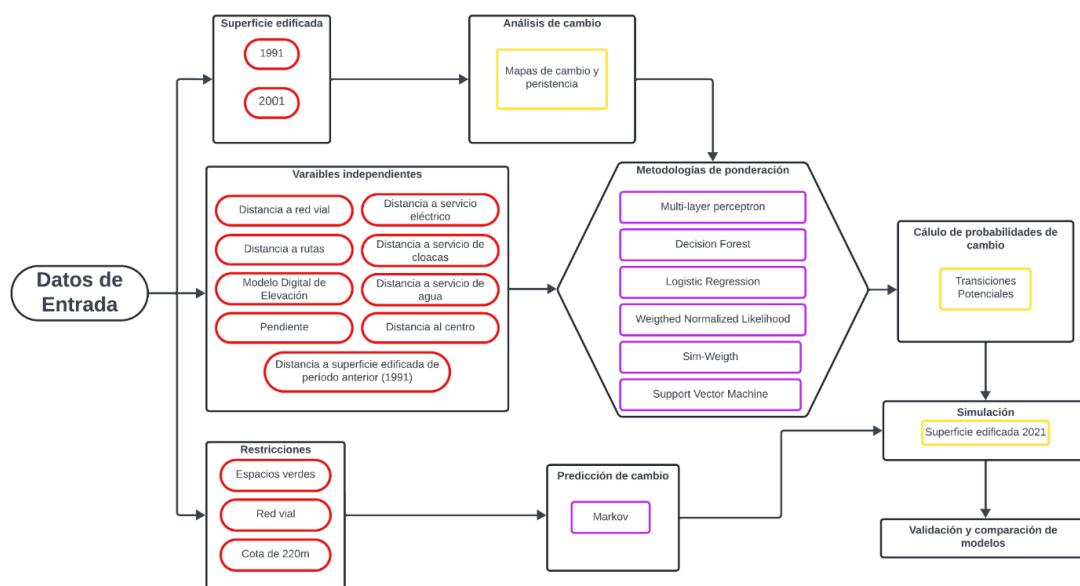
Área de estudio y metodología

La evaluación de los modelos, factores y la ejecución de las predicciones se realizó a partir de la ciudad de Tandil (provincia de Buenos Aires). El área de estudio incluye el área urbana y complementaria de la ciudad, así como también urbanizaciones por fuera de estos espacios, alcanzando un total de 399,75 km². La selección de esta área corresponde a que la ciudad aparece como un área

predilecta para el estudio de las transformaciones en el crecimiento urbano dentro de la provincia de Buenos Aires. Ciudades medianas como Tandil han experimentado en las últimas décadas un proceso de reestructuración tanto a escala interurbana e intraurbana (Spósito, 2007) que dan como resultados transformaciones espaciales notables, reflejadas tanto en los cambios en sus funciones y dinámicas urbanas como en los procesos y formas de expansión urbana. Procesos como el crecimiento de barrios cerrados y su consecuente segregación socioespacial, o el cambio en las dinámicas de consumo tradicionales que dan lugar al surgimiento de nuevas centralidades y procesos de fragmentación urbana, sitúan a Tandil como un espacio de transformaciones en el que resulta interesante evaluar sus procesos de crecimiento. La inclusión de una amplia área por fuera de la ciudad actual responde al propósito de incorporar espacios que funcionan como reserva para la expansión del área urbanizada en el futuro.

Para dar cuenta e ilustrar el proceso metodológico seguido en la Figura N.^o 2 se muestra el flujo de los procesos de análisis, evaluación de los factores, superficies edificadas y restricciones que fue llevado a cabo, así como también los modelos, las validaciones y las predicciones.

Figura N.^o 2. Diagrama de flujo del análisis de comparación de modelos de expansión urbana



Fuente: elaborado por Iturrioz, Ignacio a partir del flujo de trabajo de modelización de la expansión urbana de la ciudad de Tandil, 2025.

Datos de entrada

Fuentes de información y extracción de superficie edificada

Tanto para el desarrollo de los modelos como para realizar las validaciones posteriores, se utilizaron como insumos principales mapas *raster* de superficie edificada de la ciudad de Tandil, elaborados mediante un proceso de clasificación no supervisada y reclasificación manual de imágenes de los satélites Landsat 5 y Sentinel-2, ellos sirven como instrumento para conocer cuantitativamente y morfológicamente el crecimiento de la ciudad, y permiten llevar a cabo las modelizaciones de escenarios futuros. Se emplearon mapas de los años 1991, 2001 y 2010, mientras que el mapa de superficie edificada del 2021 fue utilizado para la validación posterior de los modelos ejecutados.

Así, en primera instancia, se descargaron imágenes satelitales obtenidas desde EO Browser (<https://apps.sentinel-hub.com/eo-browser/>) de los satélites Landsat 5 y Sentinel-2. El cambio de satélite corresponde a una mejora de resolución espacial (de celdas de 30 m x 30 m en el Landsat por celdas de 10m x 10m en el Sentinel), permitiendo un análisis más preciso y un ajuste de las superficies edificadas de años anteriores en los que el Sentinel-2 no se encontraba disponible (1991, 2001 y 2010) así como tampoco otras fuentes con resoluciones de 10 m x 10 m. En ambos satélites se utilizaron las bandas del espectro visible, infrarrojo cercano e infrarrojo de onda corta.

En este punto conviene señalar que la resolución espacial recomendable para modelar o simular el crecimiento urbano depende de varios factores, como son la escala del estudio, el objetivo específico de la simulación y los recursos disponibles. Rindfuss *et al.* (2004) señalan que la resolución espacial impacta en el área que puede ser distinguida, la temporal determina en nivel de dinamismo que puede ser observado, y la espectral afecta a la discriminación del paisaje. Una resolución espacial para estudios de cambio de uso del suelo y crecimiento urbano a nivel regional o metropolitano de 30 metros o menor permite identificar áreas urbanizadas y sus cambios a gran escala. Si bien esta no da detalles a nivel de calles o edificios individuales, es suficiente para distinguir patrones generales de expansión.

Diversos estudios de modelización de crecimiento urbano han utilizado resoluciones espaciales de este tipo (30 m x 30 m) con resultados satisfactorios (Pontius *et al.*, 2008; Rojas, Opazo y Jaque, 2009; Aguayo, 2007; Dubovyk *et al.*, 2011).

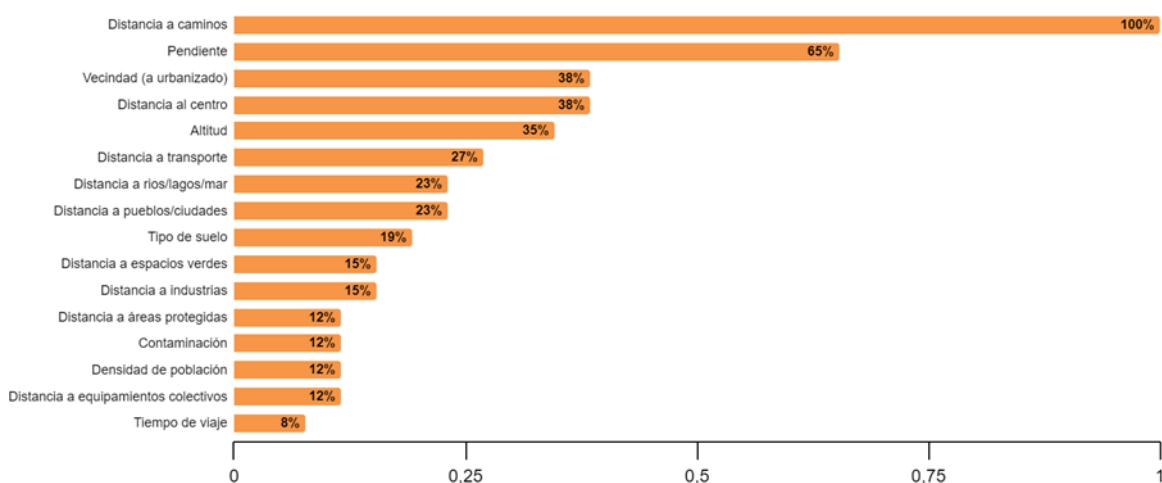
En una instancia de preprocesamiento de las imágenes, se realizó una estandarización de las resoluciones espaciales, para dar lugar luego a la composición de bandas. Seguidamente realizó un recorte y extracción de datos utilizando como máscara el área de estudio de Tandil. En una fase siguiente se

procedió a la clasificación no supervisada para discriminar y categorizar cada celda del raster según su información espectral, ello dio lugar a una multiplicidad de clases a partir de las cuales, de forma manual, se seleccionan las que corresponden a la superficie edificada presente en el área de estudio. Una vez seleccionadas, se reclasificaron las imágenes distinguiendo áreas edificadas y no edificadas, clases o categorías con las que se realizó el análisis final (Linares, Iturrioz y Di Nucci, 2022).

Factores

Teniendo como base los mapas de superficie edificada y las transformaciones de espacios no urbanos a urbanos, se planteó la utilización de una serie de factores y variables independientes que pretenden ser explicativas de los procesos de crecimiento urbano, es decir, la variable dependiente a trabajar. A partir de una recopilación y selección de cuarenta y un artículos académicos sobre modelizaciones del crecimiento urbano (Figura N.º 3), podemos observar que el factor más recurrente a la hora de evaluar la expansión de superficie edificada es la “distancia a caminos”, seguido por la “pendiente”, la “vecindad” y la “distancia al centro”. A partir de analizar la frecuencia, las particularidades de la ciudad y la disponibilidad de información, seleccionamos nueve factores con potencialidad explicativa de los procesos de crecimiento. Estos mismos son procesados mediante diferentes métodos de modelado de forma conjunta, dando lugar a mapas de transiciones potenciales que permiten realizar predicciones futuras de escenarios de crecimiento urbano en la ciudad.

Figura N.º 3. Frecuencia de uso de factores explicativos para modelar la expansión urbana



Fuente: elaborado por Linares, Santiago con base en Hassan y Elhassan (2020), Gallardo (2018) y Triantakonstantis y Mountrakis (2012).

Los factores utilizados pueden ser divididos en tres grandes grupos: los asociados a la accesibilidad, los biofísicos y los vinculados a la planificación urbana. Cheng *et al.* (2003) considera a los factores vinculados a la proximidad tanto física como temporal como condicionantes del crecimiento urbano: el acceso al transporte, servicios y comunicación son factores explicativos fundamentales. Considerando estas variables independientes asociadas a la accesibilidad, seleccionamos las vinculadas a la distancia a la red vial de la ciudad, la distancia a rutas, la distancia a la superficie edificada del período previo (1991), la distancia al centro histórico, comercial y financiero de la ciudad, y la distancia a los servicios básicos (electricidad, cloacas y agua por separado) para realizar el trabajo. La información para la elaboración de estas variables fue obtenida y descargada del sitio de Infraestructura de Datos Espaciales de la municipalidad de Tandil (<https://mapa.tandil.gov.ar/>). A partir de esta información descargada, se realizaron mapas de distancia utilizando el software ArcGIS (10.5) para obtener variables continuas adecuadas para el análisis. La distancia a la superficie edificada del año 1991 se realizó también calculando las distancias, pero la fuente de información fue de elaboración propia al igual que todos los mapas de superficie edificada utilizados.

Por otro lado, factores asociados a cuestiones físicas fueron seleccionados teniendo en cuenta las particularidades del área de estudio y su influencia, utilizando el modelo digital de elevación (DEM) del área de trabajo y la pendiente calculada a partir de este. La selección de estos factores responde a la necesidad de determinar el grado de aptitud de cada celda para poder devenir en uso de suelo urbano. Por último, factores asociados a la planificación urbana fueron introducidos, no directamente como variables para construir los modelos de transición, sino que fueron añadidos posteriormente mediante la aplicación de incentivos y restricciones al crecimiento urbano. Cabe destacar que las nueve variables utilizadas son representadas en valores continuos entre 1 y 0. En el Cuadro N.º 1 y en la Figura N.º 4 se observan, respectivamente, los factores y mapas que los representan.

Cuadro N.º 1. Factores de expansión urbana, ciudad de Tandil

Variables	Descripción	Fuente	Dimensión
1. Distancia a Red vial de la Ciudad	Distancia a caminos de la red vial de la ciudad de Tandil	Elaboración propia a partir de Infraestructura de Datos Espaciales, municipio de Tandil ¹	Accesibilidad
2. Distancia a rutas	Distancia a rutas principales (RN 226, RP 30 y RP 74)	Elaboración propia a partir de Infraestructura de Datos Espaciales, municipio de Tandil	Accesibilidad

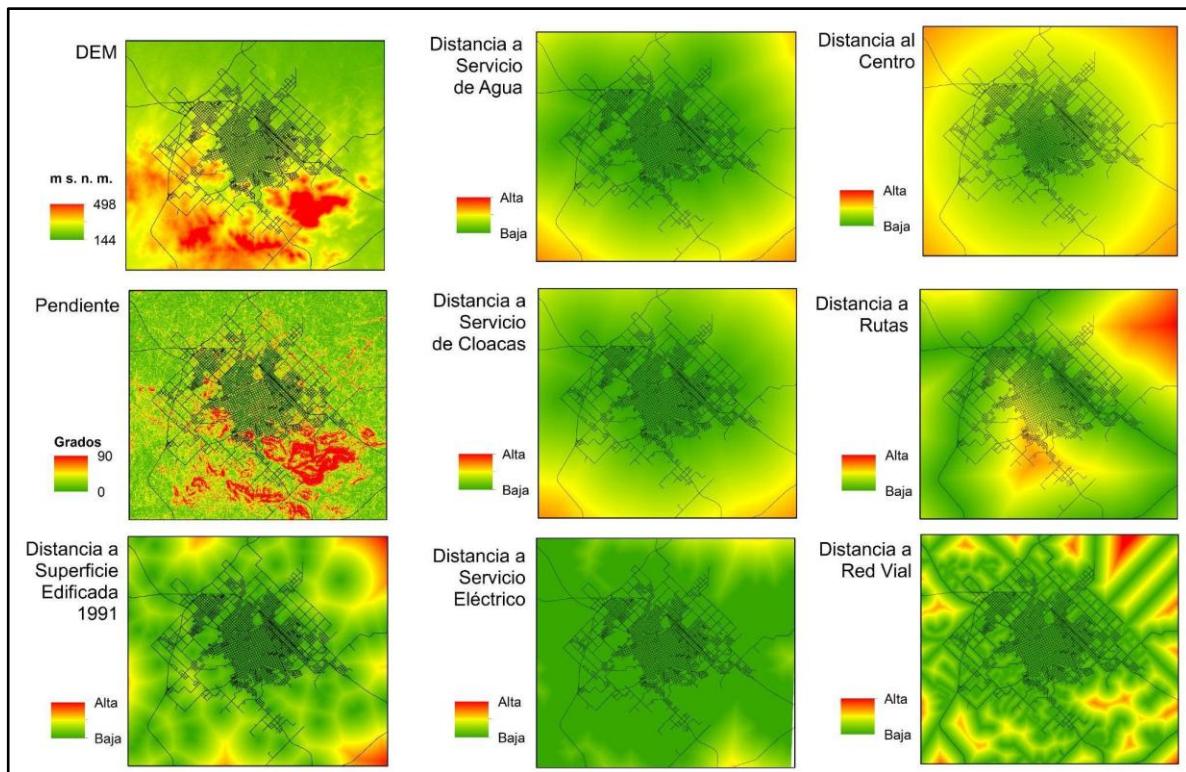
¹ V. <https://mapa.tandil.gov.ar/>

3. Distancia al centro de la ciudad	Distancia al centro comercial histórico tradicional	Elaboración propia mediante buffer	Accesibilidad
4. Distancia a superficie edificada de período anterior (1991)	Distancia en metros a cobertura de suelo clasificada como "urbana" en el mapa de cobertura de 1991	Elaboración propia mediante cálculo de distancias	Accesibilidad
5. Distancia a servicio eléctrico	Distancia en metros a cobertura de servicio eléctrico	Elaboración propia a partir de Infraestructura de Datos Espaciales, municipio de Tandil	Accesibilidad
6. Distancia a servicio de agua	Distancia en metros a cobertura de servicio de agua	Elaboración propia a partir de Infraestructura de Datos Espaciales, municipio de Tandil	Accesibilidad
7. Distancia a servicio de cloacas	Distancia en metros a cobertura de servicio de cloacas	Elaboración propia a partir de Infraestructura de Datos Espaciales, municipio de Tandil	Accesibilidad
8. Pendiente	Tasa de cambio de elevación de una celda a la siguiente	Elaboración propia a partir de datos de altitud	Biofísico
9. Altitud	Metros sobre el nivel del mar	USGS Earth Explorer, Shuttle Radar Topography Mission (SRTM). Landsat 5 EO Browser ²	Biofísico

Fuente: elaborado por Iturrioz a partir del geoprocесamiento de factores de expansión urbana de la ciudad de Tandil, 2025.

La selección de estos factores, así como la omisión de otros que podrían sumar elementos explicativos de las realidades particulares, corresponden –además de las razones ya expuestas– a una decisión más metodológica que teórica. La disponibilidad de información georreferenciada en bases de datos accesibles, así como también a su adaptabilidad a los procesos de modelización concretos, dificulta la aplicación de factores al momento de la ponderación. Otras variables explicativas de la fragmentación urbana y los procesos de segregación socioespacial como la variación de la renta del suelo, el crecimiento de barrios populares en simultáneo de las urbanizaciones cerradas, o las transformaciones en la movilidad que devienen en procesos de multicentralidades no fueron abarcadas en el caso de estudio.

² V. <https://earthexplorer.usgs.gov/>

Figura N.º 4. Factores explicativos de expansión urbana, ciudad de Tandil

Fuente: elaborado por Iturrioz a partir del geoprocесamiento de factores de expansión urbana de la ciudad de Tandil, 2025.

En este punto queremos señalar que la escasez de datos actualizados que en no pocas ocasiones nos irrumpen, la aún poca sensibilidad de los modelos de IA para captar la fragmentación de las ciudades, las multicentralidades, o la gran diversidad de patrones espaciales, no deben ser una limitación para avanzar en la investigación y en la producción de conocimientos que permitan ir progresando en la búsqueda de los mejores caminos hacia la modelización y simulación de escenarios futuros. Precisamente, la idea de la comparación de modelos de herramientas de IA para explorar los estudios de expansión urbana y su avance permite saber en qué tipos de ciudades son las aceptables y en qué tipos debería emplearse otra tecnología.

Restricciones

Además de los factores ponderados que buscan ser explicativos del crecimiento urbano, resulta significativo añadir aspectos que actúan como restricciones a la expansión de la superficie edificada. En este caso, las restricciones y desincentivos abordados están vinculadas a la imposibilidad de crecimiento en ciertas áreas –Espacios verdes públicos y Red Vial de la ciudad–, como a aspectos normativos de la planificación urbanística –Zona Protegida sobre la cota de 220 metros sobre el nivel del mar, establecido por el Plan de Desarrollo

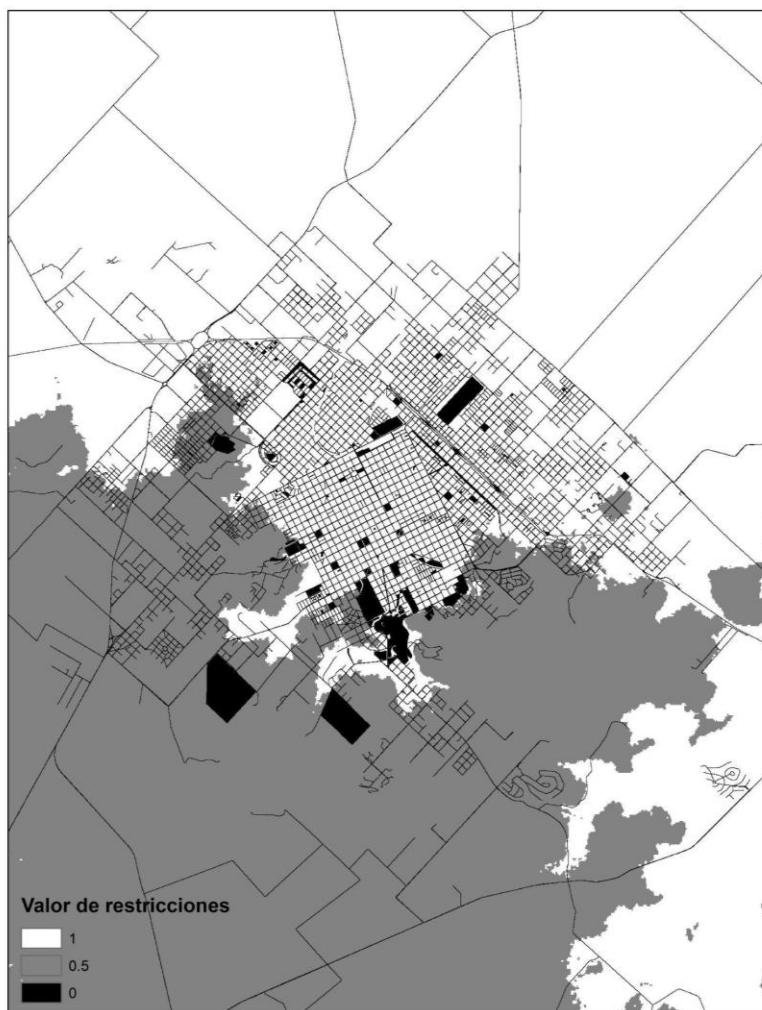
Territorial de la ciudad – (PDT, 2005). Las restricciones e incentivos son incluidos en la etapa de modelización mediante un mapa de valores continuos –entre 0 y 1–, los valores 0 se entienden como restricciones absolutas (no hay posibilidad de crecimiento urbano en esas celdas) y los valores mayores a 0 hasta 1 se entienden como desincentivos (cuanto más cercano a 0, mayor el desincentivo). Bajo esta forma de categorizar las restricciones, se le asignó un valor de 0 tanto a los espacios que integran los espacios verdes públicos de la ciudad como a la red vial de la misma, dada la imposibilidad de que exista crecimiento sobre estos espacios, mientras que al área superior a los 220 metros sobre el nivel del mar se le asignó un valor de 0.5 debido a que a pesar de que existe un desincentivo por parte de la normativa local, existe un desarrollo urbano sobre esta cota. En el Cuadro N.º 2 y en la Figura N.º 5 se observan las tres categorías utilizadas para clasificar las restricciones seleccionadas.

Cuadro N.º 2: Restricciones a la expansión urbana, ciudad de Tandil

Restricciones	Descripción	Fuente	Dimensión
1. Espacios verdes públicos	Mapa vectorial de espacios verdes de la ciudad. Restricción absoluta (1)	Infraestructura de Datos Espaciales, municipio de Tandil	Planificación urbana
2. Cota de 220 metros	Superficie por encima de los 220m sobre el nivel del mar. Desincentivo al crecimiento (0.5)	Elaboración propia a partir de datos de altitud	Planificación urbana
3. Red vial, rutas nacionales y rutas provinciales	Mapa vectorial de la red vial de la ciudad, rutas provinciales y nacionales. Restricción absoluta (1)	Infraestructura de Datos Espaciales, municipio de Tandil	Planificación urbana

Fuente: elaborado por Iturrioz a partir del geoprocесamiento de restricciones de expansión urbana de la ciudad de Tandil, 2025.

Figura N.º 5. Restricciones utilizadas para la modelización, ciudad de Tandil



Fuente: elaborado por Iturrioz a partir del geoprocесamiento de restricciones de expansión urbana de la ciudad de Tandil, 2025.

Procesamiento de datos

Elaboración de mapas de cambio entre 1991 y 2001

A partir de los mapas de superficie edificada de la ciudad de Tandil correspondientes a los años 1991 y 2001, se realiza un primer análisis de cambios de uso de suelo utilizando Land Change Modeler y teniendo en cuenta las dos categorías en cuestión: urbano y no urbano. Esto nos permite conocer el grado de crecimiento de la ciudad en el período indicado, para ello se contabiliza la cantidad de celdas que han transicionado de la categoría no urbano a urbano, también es posible observar la localización del crecimiento a partir de la generación de mapas de cambio que ilustran esta transformación. Conocer el

grado de cambio permite además establecer los valores base de la proyección de crecimiento urbano para las simulaciones a escenarios futuros.

Parámetros para elaboración de transiciones potenciales y aplicación de variables

Estos mapas de cambios pueden ser combinados con los diferentes factores explicativos para alcanzar un modelo particular de ponderación que permita crear mapas de transición potencial. Estos potenciales son los que posibilitan elaborar un índice que se asigna a cada celda del área de estudio, ello permite conocer su probabilidad (individualmente) de cambio a futuro a través de diferentes métodos de cálculo. Este índice establece valores continuos entre "0" y "1", donde los valores más altos indican celdas en las cuales se produce una combinación de variables exploratorias que han potenciado, estimulado y promovido la transformación de celdas no-urbanas a urbanas en el período de calibración, mientras que los valores más bajos representan lugares donde esta transición no ocurrió (National Research Council, 2014). A pesar de esto, un valor cercano a "1" no significa necesariamente un cambio de uso de suelo imperativo, ya que la localización de celdas transformadas dependerá de la forma que el modelo posteriormente haga uso y pondere estos valores, y la cantidad del cambio variará según los valores de las Cadenas de Markov. En otras palabras, estas transiciones potenciales se basan en un período de calibración y en variables exploratorias para otorgar un valor determinado a cada celda y así conocer su probabilidad de cambio en el futuro, donde su asignación de valores depende del modelo de transición seleccionado y su forma de ponderación (Camacho Olmedo, 2018).

Como previamente señalamos, las variables exploratorias seleccionadas fueron la distancia al centro de la ciudad, la distancia a rutas, la distancia a la red vial, la distancia a servicios (servicio de agua, de cloacas y eléctrico), la distancia a la superficie edificada del período anterior (1991), la pendiente y el modelo de elevación digital (DEM) del área de la ciudad. Una vez integradas las variables y el cambio de uso de suelo correspondiente, se procede a ejecutar la elaboración de los mapas de transición potenciales utilizando seis métodos o tipos de algoritmos que nos permiten modelizar el crecimiento urbano a futuro. A continuación, se describen los mismos.

Análisis y descripción de cada método

Con el fin de analizar y comparar las metodologías, se realizaron seis mapas de transición potenciales con las opciones brindadas por el programa *TerrSet* en el módulo *Land Change Modeler*: perceptrón multicapa, árboles de decisión, regresión logística, probabilidad normalizada ponderada, aprendizaje automatizado de base vectorial y aprendizaje basado en casos ponderados por similitud. En los mapas de transición potenciales logrados, cada método toma,

tanto la localización como los valores de las variables exploratorias seleccionadas en conjunto con los mapas de cambio del período de calibración para realizar su ponderación. A partir de ello es que, según distintos criterios y algoritmos de cálculo, surgen resultados diferenciados en el mapa final, lo que modificará la localización del cambio de uso de suelo en los modelos posteriores.

La metodología de perceptrón multicapa (*Multi-Layer Perceptron, MLP*) es una de las formas de evaluación de variables basada en redes neuronales y *Machine Learning* más utilizadas. Este algoritmo está formado por una capa de entrada, capas ocultas y una capa final de salida. El MLP extrae muestras aleatorias tanto del área que sufrió transformaciones de uso de suelo como también de las que fueron seleccionadas, pero no cambiaron. La mitad de estas muestras son utilizadas para entrenar el modelo y la otra mitad para validarla. Su uso más frecuente es la clasificación de imágenes satelitales o la predicción de cambios en el uso del suelo, como en este caso.

Para reconocer los patrones de cambio, el perceptrón multicapa en primera instancia realiza un entrenamiento del sistema. En esta fase de aprendizaje de la red, se ajustan los pesos de entrada en cada neurona hasta que los valores de salida se aproximen a los deseados (similares a la capa de salida). Las variables exploratorias seleccionadas son normalizadas y vinculadas a las neuronas en la capa de entrada, que, mediante ciclos de ajuste de matrices de ponderación, son comparadas con la capa de salida hasta tener una tasa de precisión del 80 % o superior. Una vez que los valores de ponderación son aceptables, se procede a realizar la etapa de validación utilizando la otra parte de la muestra seleccionada, dando lugar a los mapas de transición potenciales (Gómez, 2020).

La metodología árboles de decisión (*Decision Forest, DF*) es un algoritmo de Inteligencia Artificial, basado en *Machine Learning*, en la que se establece una base de árboles decisarios que a partir de muestras predicen los cambios de uso de suelo mediante procesos de clasificación y regresión. Los valores seleccionados son los que brinda, de forma predeterminada, el módulo *Land Change Modeler*, tanto en lo referido a la cantidad inicial de árboles (100), como en las celdas utilizadas para el entrenamiento y posterior validación. Cada árbol se entrena con las muestras aleatorias brindadas de forma independiente, para después dar un resultado final producto de la combinación de las predicciones de cada uno, permitiendo una evaluación y ponderación de las variables independientes seleccionadas.

La metodología de regresión logística (*Logistic Regression, LogReg*) es una de las más utilizadas para conocer el grado de correlación entre las variables independientes y el crecimiento urbano, llevando a cabo en la mayoría de las ocasiones una clasificación binaria. Esta técnica estadística permite analizar

relaciones funcionales entre variables, que, en este caso, son los factores seleccionados (variables independientes explicativas) y el área de crecimiento urbano (representado como valor binario de 0 o 1). A partir del análisis de estas relaciones, se modela la probabilidad de que suceda un evento en particular (en este caso, la transformación de no construido a construido) en función de cada uno de los factores explicativos analizados independientemente, para luego conocer el grado de correlación entre ellos. Finalmente, se realiza un análisis empleando todos los factores para generar una evaluación de la correlación global, dando como resultado final un mapa de transiciones potenciales mediante el cual posteriormente se modelará el crecimiento (Aguilera, 2006). Un aspecto para tener en cuenta es que para realizar la regresión logística se debe elegir el tamaño de la muestra, en este caso fue establecido en un 10 %, suficiente para ser representativo y no sobrecargar los procesos.

La probabilidad normalizada ponderada (*Weighted Normalized Likelihood, WNL*) es una técnica estadística utilizada para modelar la probabilidad de ocurrencia de eventos en un contexto espacial, considerando múltiples variables explicativas y su relación espacial. Es una técnica que puede ser clasificada como *Machine Learning* y suele integrarse con diferentes técnicas estadísticas para mejorar la precisión y la capacidad predictiva de los modelos espaciales, se ha utilizado con frecuencia para estimar la probabilidad de ocurrencia de eventos, considerando la distribución espacial de las variables. Es una metodología que presenta similitudes con la anteriormente utilizada Perceptrón Multicapa, y al igual que esta hace uso de capas ocultas y variables que se entrecruzan para calcular las probabilidades de cambio utilizando nodulos. Su principal diferencia es la metodología de cálculos, donde los algoritmos particulares permiten una mayor velocidad de procesamiento que no interfiere en su capacidad de análisis y permite el trabajo con grandes cantidades de variables³.

El método de aprendizaje automatizado de base vectorial (*Support Vector Machine classifier, SVM*) es otra de las metodologías brindadas por *TerrSet*, también catalogada dentro de las técnicas de *Machine Learning*. Se trata de un tipo de algoritmo de aprendizaje supervisado utilizado para la clasificación y regresión, y es conocido por su capacidad para manejar eficientemente datos en espacios con alta dimensionalidad. Su objetivo principal es encontrar un hiperplano en un espacio multidimensional que sea el que mejor separe las distintas clases de datos. Este hiperplano se define de manera que maximice la distancia entre los puntos de las clases diferentes, denominados vectores de soporte, esta distancia se conoce como el margen. Además de clasificación, las SVM también se pueden utilizar para regresión, mediante el uso de funciones

³ Una explicación y discusión más profunda sobre este método puede obtenerse en Eastman *et al.*, 2019.

kernel para transformar el espacio de atributos y encontrar una relación no lineal entre las variables de entrada y salida. Su capacidad para manejar datos de alta dimensionalidad y encontrar relaciones no lineales los hace especialmente útiles en contextos donde los datos geográficos son complejos y variados, como, por ejemplo, clasificación de cobertura del suelo, predicción de incendios forestales, detección de cambios en el uso del suelo, modelado de distribución de especies, análisis de riesgos naturales, segmentación y análisis de imágenes satelitales.

Por último, se utilizó la metodología de aprendizaje basada en casos ponderados por similitud (*Similarity Weighted instance-based learning*, SW). Esta metodología no puede ser clasificada como inteligencia artificial, sino que basa su construcción de transiciones potenciales al asignar un peso específico a cada variable mediante la lógica *K-Nearest Neighbor*. El proceso escoge celdas de cada variable seleccionada para ser evaluadas (asignada su cantidad previamente por el usuario) y analiza su relación con las celdas de cambio o persistencia cercanas (correspondientes a la variable dependiente del uso de suelo). A partir de ello, determina el peso de cada variable brindada: una mayor cantidad de celdas de cambio alrededor de las celdas evaluadas corresponde un peso mayor, mientras que la aparición de celdas de persistencia significa un peso menor⁴.

Cadenas de Markov, calibración y limitaciones

Tras construir los mapas de transiciones potenciales, el próximo paso para llegar a la modelización de la expansión urbana es establecer la magnitud de este crecimiento. Las metodologías antes mencionadas nos permiten establecer dónde se produce este crecimiento a partir de los factores espaciales, pero para conocer en qué medida la superficie edificada se modifica y expande en estos períodos es necesario tener en cuenta el crecimiento de las últimas décadas.

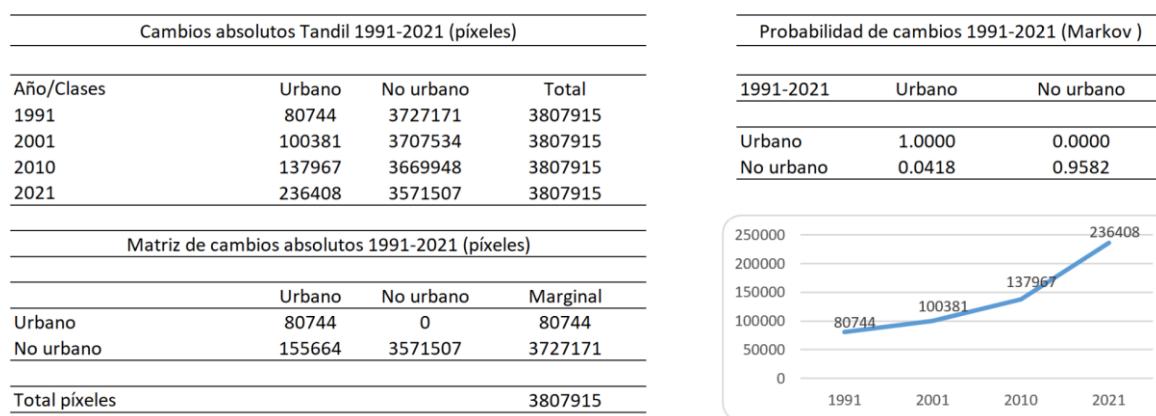
El análisis en cadena Markov se basa en la idea de que el estado de un sistema en un tiempo determinado puede ser estimado por el estado de este mismo en un momento previo (Eastman, 2012). El módulo utiliza imágenes de uso de suelo de fechas diferentes (requiere dos mapas de cobertura de la tierra) y produce una matriz de probabilidad de transición a partir de los cambios que existieron entre ellas, logrando predecir cambios en la cubierta terrestre del mismo tipo para un estado futuro. La predicción de cambio es lineal y cuantitativa, permitiendo predecir para diferentes fechas futuras el cambio de usos de suelo. En el caso trabajado, se hizo énfasis en las transformaciones de cambio de uso de suelo «no urbano» (haciendo referencia por ello a superficie no edificadas) a «urbano» (indicando superficies edificadas), asumiendo la persistencia de la categoría «urbano» en todos los períodos.

⁴ Una explicación y discusión más profunda sobre este método puede obtenerse en Sangermano *et al.*, 2010.

A partir de los mapas de uso de suelo brindados (1991 y 2021), se calcula la matriz de probabilidades de transición (Figura N.º 6). Empleamos el período completo evitando con ello los cambios de ritmos entre las décadas consideradas. La matriz resultante determina una probabilidad de transición anual de «no urbano» a «urbano» de 0.0014 (0.14 % puntos porcentuales), pronosticando un cambio de píxeles a la categoría «urbano» del 4.18 % durante los 30 años analizados.

En la Figura N.º 6 también se muestran los cambios absolutos en términos de píxeles (entre “urbano” y “no urbano”) en los diferentes períodos, así como una matriz de cambios absolutos de ellos entre 1991 y 2021.

Figura N.º 6. Matriz de transición Markov (probabilidades), ciudad de Tandil (1991-2001)



Fuente: elaborado por Linares, Santiago a partir del geoprocесamiento de las manchas urbanas 1991, 2001, 2010 y 2021 de la ciudad de Tandil, 2025.

Resultados

Evaluación de factores explicativos y generación de transiciones potenciales

A partir de la Tabla N.º 1 se puede observar que los factores “Distancia a edificaciones 1991”, “Distancia a rutas” y “Distancia a red vial” son más influyentes en cinco de los seis modelos implementados, SVM es el único que presenta una correlación más alta con las distancias a servicios y distancia al centro de la ciudad. El método WNL no posee una correlación lineal con los factores individuales, mientras que, los coeficientes de correlación más fuertes se observan en los modelos aplicando SW y MLP.

Tabla N.º 1. Coeficientes de Correlación de Pearson entre modelos de transición potencial y factores de expansión, ciudad de Tandil, 1991-2001

Modelo/Factor	WNL	SVM	SW	LogReg	MLP	DF
Altitud	-0.02	-0.02	0.30	0.20	0.27	0.14
Pendiente	0.01	0.04	-0.06	-0.07	-0.03	-0.02
Distancia a servicio eléctrico	0.00	-0.21	-0.04	-0.01	-0.01	-0.01
Distancia a servicio de cloacas	0.01	0.35	-0.22	-0.10	-0.18	-0.06
Distancia a servicio de agua	0.01	0.35	-0.22	-0.10	-0.18	-0.07
Distancia a rutas	0.03	0.25	-0.46	-0.26	-0.37	-0.16
Distancia a red Vial	0.03	0.25	-0.51	-0.29	-0.42	-0.18
Distancia al centro de la ciudad	0.01	0.34	-0.23	-0.10	-0.18	-0.07
Distancia a edificaciones 1991	0.04	0.20	-0.53	-0.32	-0.44	-0.19

Fuente: elaborado por Linares, Santiago a partir de la evaluación de factores de expansión urbana para la ciudad de Tandil, 2025.

La Tabla N.^o 2 muestra las correlaciones existentes entre los seis mapas de transición potencial obtenidos para la ciudad de Tandil durante el período 1991-2001. Al analizar la tabla observamos que los mapas obtenidos mediante LogReg y MLP están muy fuertemente correlacionados (0.91), de la misma manera que SW y MLP (0.82). En términos generales podríamos afirmar que (exceptuando, SW con DF y SW con SVM) existe una fuerte correlación entre los mapas obtenidos en los últimos cinco modelos analizados (~0.65), excepto el mapa resultante de aplicar WNL, el cual presenta coeficientes de correlación insignificantes con todos los demás, demostrando una independencia en su pronóstico de expansión con respecto a todos los otros modelos implementados.

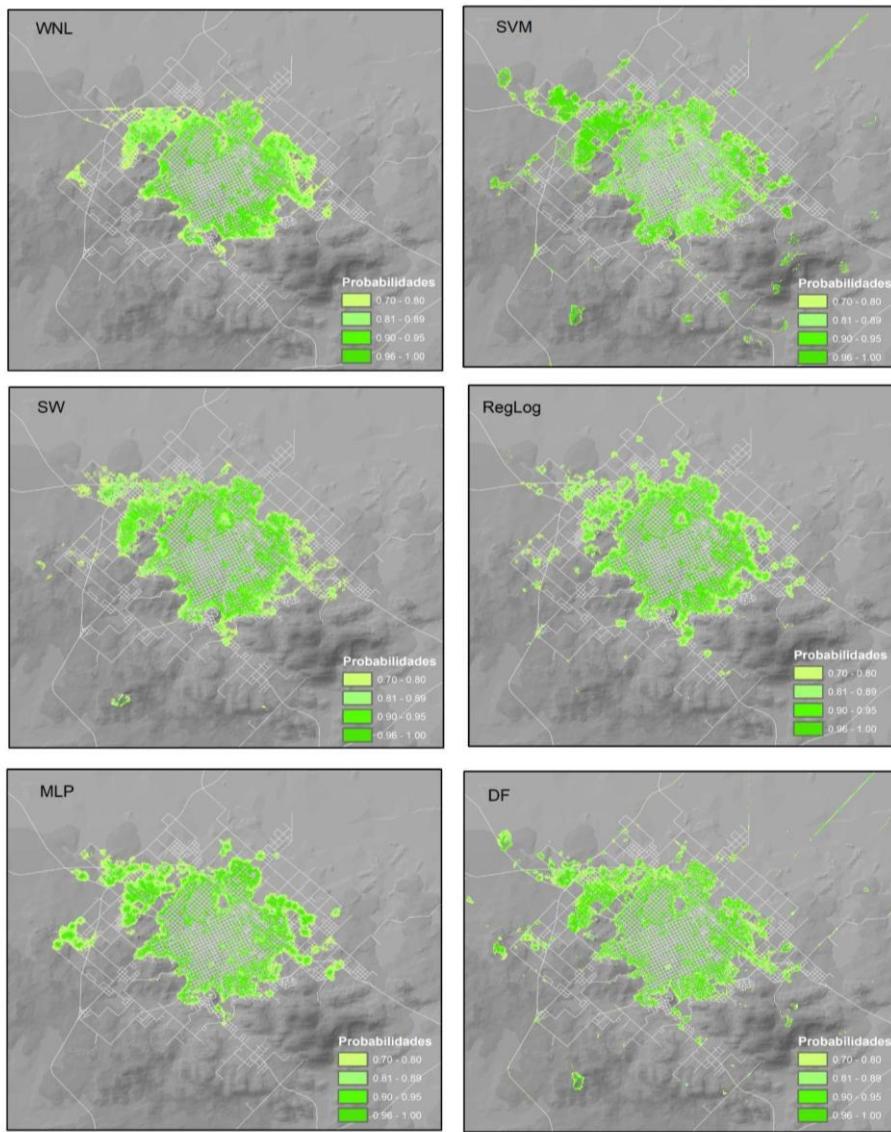
Tabla N.^o 2. Coeficientes de Correlación de Pearson entre mapas de transición potencial, ciudad de Tandil, 1991-2001

Modelo/Factor	WNL	SVM	SW	LogReg	MLP	DF
WNL	1.00	0.01	0.01	0.00	0.01	0.00
SVM		1.00	0.26	0.63	0.60	0.61
SW			1.00	0.65	0.82	0.39
LogReg				1.00	0.91	0.68
MLP					1.00	0.65
DF						1.00

Fuente: elaborado por Linares, Santiago a partir de la generación de mapas de transición potencial de expansión urbana para la ciudad de Tandil, 2025.

Por otro lado, los mapas incluidos en la Figura N.^o 7 nos brindan información sobre las probabilidades de transición de áreas no edificadas a edificadas, seleccionando los 200000 pixeles con valores más altos en cada modelo respectivamente (a partir de datos del crecimiento real observado durante el período a simular 2001-2021). Del análisis de los valores de transición potencial, observamos que los modelos SVM, LogReg y DF prevén un patrón de expansión mayoritariamente difuso, mientras que WNL, SW y MLP pronostican procesos de expansión en donde prevalece la contigüidad y compacidad.

Figura N.^o 7. Mapas de transición potencial según modelos, ciudad de Tandil, 1991-2001



Fuente: elaborado por Iturrioz, Ignacio a partir de la generación de mapas de transición potencial de expansión urbana para la ciudad de Tandil, 2025.

Validación de modelos

A partir de las transiciones potenciales y la modelación de cada escenario desde 2001 a 2021, se realiza una validación con la verdad de campo del año 2021. Dado que el valor de la matriz de transición de Markov es la misma en cada modelo utilizado, la probabilidad/cantidad del crecimiento estimado para los 20 años simulados por cada técnica será la misma, proyectando un aumento de 136027 píxeles, que corresponden a un incremento de 1360,27 hectáreas. Las diferencias entre los resultados de cada uno de las simulaciones resultantes, estará dada por la localización de dichos cambios, generando un patrón espacial distinto de expansión urbana según el algoritmo seleccionado.

Una primera validación puede realizarse con base en las matrices de confusión (Figura N.º 8) entre el escenario simulado de expansión urbana para el año 2021 y la imagen de referencia de la superficie edificada extraída mediante una clasificación no supervisada del mismo año. Del análisis observamos que la exactitud global gira en torno al 95 % considerando la totalidad del área de estudio y ambas categorías (construido y no construido); también se aprecia que la exactitud del usuario es del 61% y la del productor de 63 % para cinco de los seis escenarios generados, siendo significativamente más preciso aquel obtenido mediante árboles de decisión (DF), en donde la exactitud del usuario fue del 64,7 % y la del productor del 67 %.

Figura N.º 8. Matrices de confusión entre expansión simulada y expansión real, ciudad de Tandil, 2021

Matriz de confusión DF					Matriz de confusión LogReg						
	Construido	No construido	Total	Exactitud usuario		Construido	No construido	Total	Exactitud usuario	Error comisión	
Construido	158319	86371	244690	64.7%	35.3%	150667	94023	244690	61.6%	38.4%	
No construido	78089	3485136	3563225	97.8%	2.2%	85741	3477484	3563225	97.6%	2.4%	
Total	236408	3571507	3807915			236408	3571507	3807915			
Exactitud productor	67.0%	97.6%				63.7%	97.4%				
Error omisión	33.0%	2.4%				36.3%	2.6%				
Exactitud global	95.68%					95.28%					
Matriz de confusión MLP											
	Construido	No construido	Total	Exactitud usuario	Error comisión		Construido	No construido	Total	Exactitud usuario	Error comisión
Construido	151299	93391	244690	61.8%	38.2%	150865	93825	244690	61.7%	38.3%	
No construido	85109	3478116	3563225	97.6%	2.4%	85543	3477682	3563225	97.6%	2.4%	
Total	236408	3571507	3807915			236408	3571507	3807915			
Exactitud productor	64.0%	97.4%				63.8%	97.4%				
Error omisión	36.0%	2.6%				36.2%	2.6%				
Exactitud global	95.31%					95.29%					
Matriz de confusión SW											
	Construido	No construido	Total	Exactitud usuario	Error comisión		Construido	No construido	Total	Exactitud usuario	Error comisión
Construido	150950	93740	244690	61.7%	38.3%	151622	93068	244690	62.0%	38.0%	
No construido	85458	3477767	3563225	97.6%	2.4%	84786	3478439	3563225	97.6%	2.4%	
Total	236408	3571507	3807915			236408	3571507	3807915			
Exactitud productor	63.9%	97.4%				64.1%	97.4%				
Error omisión	36.1%	2.6%				35.9%	2.6%				
Exactitud global	95.29%					95.33%					
Matriz de confusión SVM											
	Construido	No construido	Total	Exactitud usuario	Error comisión		Construido	No construido	Total	Exactitud usuario	Error comisión
Construido	150865	93825	244690	61.7%	38.3%	151622	93068	244690	62.0%	38.0%	
No construido	85543	3477682	3563225	97.6%	2.4%	84786	3478439	3563225	97.6%	2.4%	
Total	236408	3571507	3807915			236408	3571507	3807915			
Exactitud productor	63.8%	97.4%				64.1%	97.4%				
Error omisión	36.2%	2.6%				35.9%	2.6%				
Exactitud global	95.29%					95.33%					
Matriz de confusión LogReg											
	Construido	No construido	Total	Exactitud usuario	Error comisión		Construido	No construido	Total	Exactitud usuario	Error comisión
Construido	150667	94023	244690	61.6%	38.4%	151622	93068	244690	62.0%	38.0%	
No construido	85741	3477484	3563225	97.6%	2.4%	84786	3478439	3563225	97.6%	2.4%	
Total	236408	3571507	3807915			236408	3571507	3807915			
Exactitud productor	63.7%	97.4%				64.1%	97.4%				
Error omisión	36.3%	2.6%				35.9%	2.6%				
Exactitud global	95.28%					95.33%					

Fuente: elaborado por Linares, Santiago a partir de la validación de escenarios de expansión urbana para la ciudad de Tandil, 2025.

A diferencia de un gran número de antecedentes bibliográficos en donde solamente emplea la exactitud global obtenida de una matriz de confusión como medida de validación de la predicción, el módulo *Land Change Modeler* permite realizar una validación focalizada en el análisis de los píxeles que han sido simulados como cambios, esto nos permite comparar y evaluar de manera minuciosa los resultados de los seis modelos predictivos con la verdad de terreno. A partir de ello, surgen tres categorías que buscan diferenciar cada una de las posibilidades:

- (a) los aciertos corresponden a las celdas en las que el modelo predijo una transformación de uso de suelo «no urbano» a «urbano», y efectivamente este cambio sucedió;
- (b) las omisiones corresponden a las celdas que han cambiado a «urbano» en la realidad, pero que no fueron advertidas por las simulaciones; y,
- (c) las falsas alarmas corresponden a celdas que el modelo predijo un cambio pero que no ocurrieron al contrastar con la verdad de campo.

La Tabla N.^o 3 muestra las celdas totales que corresponden a cada categoría, mientras que la Tabla N.^o 4 compara estos mismos valores en términos relativos, lo que permite comparar y analizar las diferencias en la exactitud de cada modelo empleando los mismos factores y cantidad de cambio proyectado. Asimismo, la Figura N.^o 9 muestra los mapas con la localización de los aciertos, omisiones y falsas alarmas según la técnica implementada, este resultado es un indicador de suma utilidad para mejorar la metodología de simulación, dado que, a partir de allí, es posible detectar errores significativos y estructurales en los escenarios y reflexionar acerca de posibles factores latentes que podrían ser tenidos en cuenta durante la fase de calibración del modelo.

Tabla N.^o 3. Evaluación de valores absolutos de cambio: aciertos, omisiones y falsas alarmas, ciudad de Tandil, 2021

	Aciertos	Omisiones	Falsa alarma	Crecimiento modelado
Decision Forest	54613	73607	81414	136027
Logistic Regression	47400	80820	88627	136027
MLP	47996	80225	88031	136027
SVM	47587	80634	88440	136027
SimWeigth	47667	80554	88360	136027
WNL	48300	79920	87727	136027

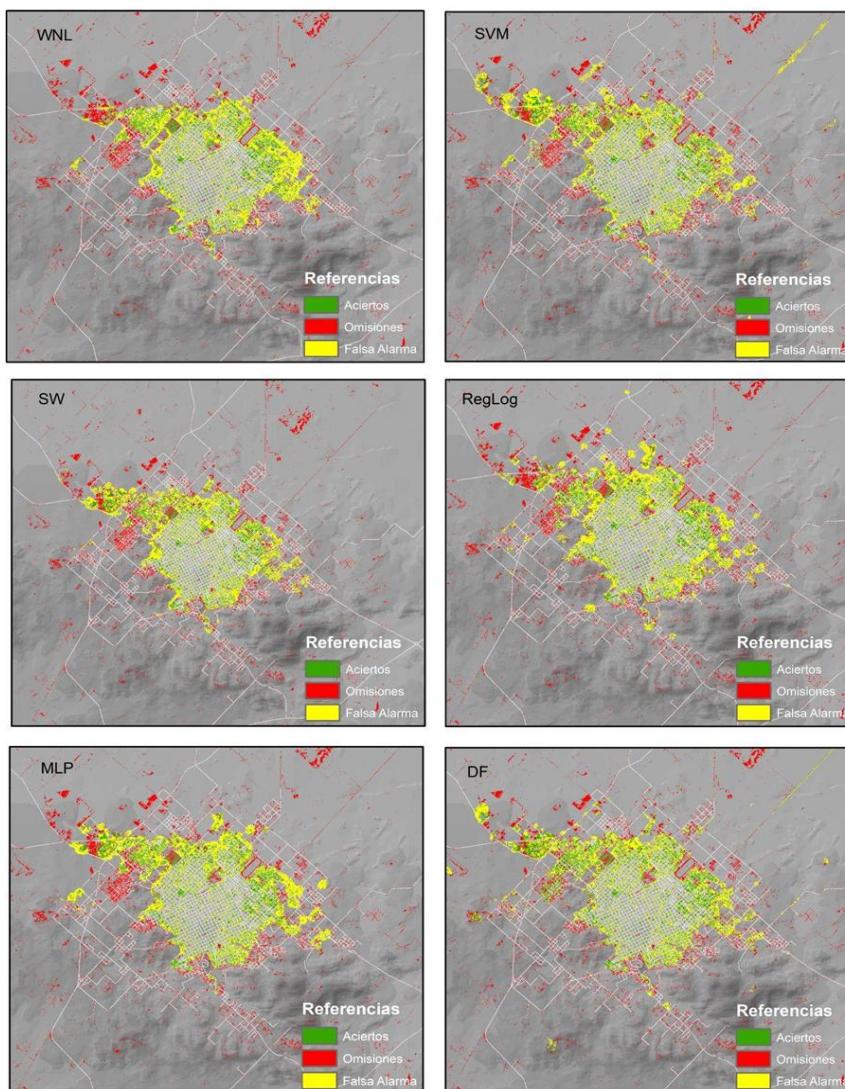
Fuente: elaborado por Linares, Santiago a partir de la validación de escenarios de expansión urbana para la ciudad de Tandil, 2025.

Tabla N.º 4. Evaluación de valores relativos de cambio: aciertos, omisiones y falsas alarmas, ciudad de Tandil, 2021

	Aciertos	Omisiones	Falsa alarma
Decision Forest	40.1%	54.1%	59.9%
Logistic Regression	34.8%	59.4%	65.2%
MLP	35.3%	59.0%	64.7%
SVM	35.0%	59.3%	65.0%
SimWeigth	35.0%	59.2%	65.0%
WNL	35.5%	58.8%	64.5%

Fuente: elaborado por Linares, Santiago a partir de la validación de escenarios de expansión urbana para la ciudad de Tandil, 2025.

Figura N.º 9. Mapas de validación según modelos, ciudad de Tandil, 1991-2021



Fuente: elaborado por Iturrioz, Ignacio a partir de la validación de escenarios de expansión urbana para la ciudad de Tandil, 2025.

Los resultados nos muestran la incapacidad que poseen los modelos actuales para detectar la urbanización difusa y crecimientos espontáneos, siendo el algoritmo de DF el que mejor se aproxima en términos comparativos entre los utilizados. Cabe recordar que esta validación se realiza a partir de las celdas originales, con una resolución de 10 metros. En términos generales, podemos observar que el modelo con una mayor cantidad de aciertos corresponde al algoritmo DF, con un 40,1 % de aciertos, mientras que el resto de los modelos cuentan con una exactitud de entre el 34 % y 35 %.

Discusión y conclusión

Al analizar comparativamente los resultados de exactitud global de los seis algoritmos implementados con respecto a los valores obtenidos en la literatura especializada, observamos que el desempeño en todos los casos puede ser considerado como muy bueno, dado que los valores típicos en estudios de simulación urbana oscilar entre 70 % y 95 % mayoritariamente. Tanto del análisis de nuestra aplicación, como de la revisión bibliográfica realizada, podemos concluir que una exactitud superior al 85 % puede considerarse como buena, mientras que un valor menor a 70 % de esta medida indicaría un modelo con limitaciones severas, lo cual requeriría una revisión en el proceso de calibración del modelo.

Si analizamos los valores de exactitud del usuario para la categoría edificada o urbana, la cual indica la probabilidad de que un píxel clasificado en esta categoría realmente pertenezca a esa categoría (evita falsos positivos); se observa que los valores en los estudios relevados poseen menor exigencia y mayor amplitud que la exactitud global, los valores aceptables oscilan entre 65 % y 89 %, aunque existe un acuerdo en que valores superiores al 80 % pueden ser considerados como muy buenos para aplicaciones urbanas. A partir de este marco de interpretación, los resultados obtenidos en este artículo demuestran que solo el modelo basado en árboles de decisión se encuentra entre el rango de los valores aceptables.

Complementariamente, al analizar la medida de exactitud del productor, que mide cuán bien una categoría de referencia es representada por la clasificación (evita falsos negativos). Los estudios suelen reportar valores entre 60 % y 85 %, considerando valores superiores al 75 % como adecuados. Con base en este indicador, todos los algoritmos superaron el umbral del 60 %, y especialmente el de árboles de decisión muestra el mejor desempeño al alcanzar el 67 %

Finalmente, si solo se contemplan las medidas de aciertos, omisiones o falsas alarmas, los valores observados en la literatura varían significativamente dependiendo del contexto geográfico, la resolución espacial, la escala del estudio y la complejidad del modelo de simulación. No obstante, definiremos

que, para escala urbana, las tasas de aciertos aceptados en la literatura especializada oscilan entre el 50 al 80 %, mientras que se espera que las omisiones y falsas alarmas estén en el rango de 10 al 30 %. A la luz de nuestra experiencia, de los seis modelos implementados ninguno logró superar el umbral inferior del rango normalmente aceptado, siendo el método de árboles de decisiones el más aproximado con 40 % de aciertos, pero muy distante a las omisiones y falsas alarmas permitidas (54 % y 59 % respectivamente).

De los resultados obtenidos, concluimos que la mera disponibilidad de los algoritmos de aprendizaje para asignar probabilidades de expansión urbana en los softwares especializados, especialmente en el módulo *Land change Modeler*, no resultan suficientes, sin antes incorporar algunas adendas técnicas-metodológicas que detallaremos a continuación.

Los modelos basados en aprendizaje automático aplicados tienden a reproducir patrones lineales o de contigüidad espacial, esto produce un desacople en determinados entornos urbanos signados por los procesos de expansión fragmentada o múltiples centralidades; una alternativa que se presenta para superar estas limitaciones es integrar enfoques que consideren la complejidad y heterogeneidad de los procesos urbanos. La combinación de autómatas celulares con técnicas como redes neuronales, sistemas multiagente, algoritmos estocásticos y teoría de juegos permite simular patrones de expansión urbana más realistas, incluyendo la fragmentación y la aparición de múltiples centralidades, algunas contribuciones en esta dirección podemos encontrar en Meentemeyer et al. (2013), quienes desarrollan un algoritmo estocástico de crecimiento de parches que simula la estructura emergente del paisaje urbano-rural, abordando la fragmentación y la aparición de múltiples núcleos urbanos, también en Liu et al. (2008), quienes introducen autómatas celulares no lineales basados en funciones kernel, permitiendo simular desarrollos urbanos complejos y fragmentados, superando las limitaciones de los modelos lineales tradicionales.

En lo que respecta a los insumos para la modelización, consideramos de suma importancia mejorar la calidad y cantidad de los factores, no solamente incluyendo variables estáticas sino dinámicas, como cambios en las infraestructuras urbanas en la medida que la simulación se ejecuta. Esta alternativa de cambio dinámico de los factores también puede ser aplicada en las probabilidades de cambios de píxeles entre clases, en lugar de utilizar una única matriz de Markov.

En cuanto a la conceptualización de algunos factores de expansión urbana, también existen recomendaciones que podrían implementarse para mejorar los resultados obtenidos en el presente artículo. Tales como las limitaciones que impone el uso de una única área central sin tener en cuenta las nuevas

centralidades urbanas, como así también, consideramos de suma importancia densificar los incentivos a la urbanización, como, por ejemplo, indicadores urbanísticos que promuevan o limiten la expansión de la ciudad.

Los recientes procesos de reestructuración urbana tanto a escala interna como entre ciudades medias han transformado la forma y función histórica de las mismas. Estas transformaciones signadas por las telecomunicaciones y la movilidad creciente, puede dar lugar a repensar variables que influyen en la evolución y crecimiento de las ciudades, al mismo tiempo que destacan la especificidad de las ciudades medias a la hora de establecer factores que puedan explicar el dinamismo de su expansión (Henriquez e Hidalgo, 2023). Procesos como el surgimiento de nuevas y múltiples centralidades, la proliferación de urbanizaciones cerradas, la fragmentación urbana, la gentrificación o la segregación socioespacial, entre otros procesos, constituyen nuevas lógicas que pueden ser explicativas de las más recientes transformaciones en ciudades latinoamericanas y requieren ser posibles de incluir en los procesos de modelización de escenarios. Es necesario, para trabajos futuros tanto de la ciudad de Tandil como otras ciudades argentinas, considerar la importancia y peso de tales procesos la designación de nueva superficie edificada, para lograr resultados con mayor validez, y a partir de allí, se constituyan efectivos aportes para la toma de decisión en políticas territoriales urbanas.

Dichos procesos suceden con particular relevancia en ciudades medias, por lo que la generalización de los resultados de las modelizaciones en ciudades con escalas mayores o menores podría ser dificultosa o incompleta en tanto las explicaciones de sus transformaciones pueden deberse a otras variables. Un ejemplo de ello puede ser la preponderancia de los sistemas de transporte público de pasajeros (subte, trenes), autopistas y avenidas estructurantes, conexión a centros comerciales e industriales en las grandes ciudades y metrópolis, o lo determinante de zonas de riesgo geofísico o suelos no aptos, disponibilidad de tierras y políticas municipales, cercanía a servicios básicos como escuelas, centros de salud o área comerciales para ciudades pequeñas y pueblos.

Para finalizar, podemos constatar que la modelización espacial de la expansión urbana tiende a reproducir patrones históricos, lo cual podría reforzar sesgos estructurales preexistentes, como la priorización de zonas con infraestructura instalada o la exclusión sistemática de áreas marginales. Sin embargo, esta limitación se puede solventar si se consideran los tres enfoques fundamentales en la generación de escenarios: predictivo, exploratorio y normativo (Wack, 1985; Alcamo, 2001). Mientras que el enfoque predictivo busca representar el futuro más probable a partir de tendencias históricas y relaciones empíricas

observadas (enfoque adoptado en este trabajo), los enfoques exploratorios, por el contrario, permiten investigar futuros posibles mediante la alteración de supuestos clave o ponderaciones de variables, arribando a escenarios independientes de influencias originales. De la misma manera que el enfoque normativo, el cual busca construir futuros deseados, basados en objetivos de planificación o racionalidades alternativas de uso del suelo; este marco metodológico habilita un espacio para integrar consideraciones de equidad territorial, sostenibilidad y justicia espacial mediante el diseño de escenarios que cuestionen las trayectorias actuales. En este sentido, los modelos no deben utilizarse únicamente como herramientas de predicción, sino también como instrumentos heurísticos y deliberativos (van Notten et al., 2003) que fomenten el debate sobre alternativas territoriales posibles y deseables.

Referencias

- Adams, J. S. (2005). Hoyt, H. 1939: The structure and growth of residential neighborhoods in American cities. Washington, DC: Federal Housing Administration. *Progress in Human Geography*, 29(3), 321-325. <https://doi.org/10.1191/0309132505ph552xx>
- Aguayo, M. I., Wiegand, T., Azocar, G. D., Wiegand, K. y Vega, C. E. (2007). Revealing the driving forces of mid-cities urban growth patterns using spatial modelling: A case study of Los Angeles, Chile. *Ecology and Society*, 12(1), 13-42.
- Aguilera, B. F. (2006). Predicción del crecimiento urbano mediante sistemas de información geográfica y modelos basados en autómatas celulares. *GeoFocus*, 6, 81-112. <https://www.geofocus.org/index.php/geofocus/article/view/90>
- Alastal, A. I., y Shaqfa, A. H. (2022). GeoAI technologies and their application areas in urban planning and development: Concepts, opportunities and challenges in smart city (Kuwait, study case). *Journal of Data Analysis and Information Processing*, 10, 110-126. <https://www.scirp.org/journal/paperinformation?paperid=116308>
- Alcamo, J. (2001). *Scenarios as tools for international environmental assessments*. Environmental Issue Report No. 24. Office for the Official Publications of the European Communities.
- Beltrão Spósito, M. E. (2007). Cidades médias: reestruturação das cidades e reestruturação urbana. En M. E. Beltrão Spósito (Ed.), *Cidades Médias, espaços em transição* (pp. 233-257). Expressão Popular.
- Burgess, E. W. (2008). The Growth of the City: An Introduction to a Research Project. En J. M. Marzluff, E. Shulenberger y C. ZumBrunnen (Eds.), *Urban Ecology: An International Perspective on the Interaction Between Humans and Nature* (pp. 71-78). Springer International Publishing. https://doi.org/10.1007/978-0-387-73412-5_5
- Buzai, G. D. (2014). *Mapas Sociales Urbanos*. Lugar Editorial.
- Camacho Olmedo, M. T., Paegelow, M., Mas, J.-F. y Escobar, F. (Eds.). (2018). *Geomatic Approaches for Modeling Land Change Scenarios*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-60801-3>
- Cheng, J., y Masser, I. (2003). Urban growth pattern modeling: a case study of Wuhan city, PR China. *Landscape and Urban Planning*, 62(4), 199-217. [https://doi.org/10.1016/S0169-2046\(02\)00150-0](https://doi.org/10.1016/S0169-2046(02)00150-0)

- Chiu, H.-Y., Chao, H.-S. y Chen, Y.-M. (2022). Application of Artificial Intelligence in Lung Cancer. *Cancers*, 14(6), 1370. <https://doi.org/10.3390/cancers14061370>
- Clark Labs. (2020). *TerrSet Geospatial Monitoring and Modeling System* (2020). Clark University.
- Clarke, K. C. (2014). Why simulate cities? *GeoJournal*, 79(2), 129-136. <https://doi.org/10.1007/s10708-013-9499-5>
- Di Virgilio, M. M. y Perelman, M. (2014). *Ciudades latinoamericanas: desigualdad, segregación y tolerancia*. Consejo Latinoamericano de Ciencias Sociales.
- Dubovyk, O., Sliuzas, R. y Flacke, J. (2011). Spatio-temporal modelling of informal settlement development in Sancaktepe district, Istanbul, Turkey. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(2), 235-246. <https://doi.org/10.1016/j.isprsjprs.2010.10.002>
- Eastman, J. R., Crema, S. C., Rush, H. R. y Zhang, K. (2019). A weighted normalized likelihood procedure for empirical land change modeling. *Modeling Earth Systems and Environment*, 5(3), 985-996. <https://doi.org/10.1007/s40808-019-00584-0>
- Eastman, R. J. (2012). *IDRISI Selva GIS and image processing software version 17.0* [software]. Clark Labs, Clark University.
- Engelen, G., White, R. y Nijs, T. (2003). Environment Explorer: Spatial Support System for the Integrated Assessment of Socio-Economic and Environmental Policies in the Netherlands. *Integrated Assessment*, 4(2), 97-105. <https://doi.org/10.1076/iaij.4.2.97.16707>
- ESRI. (2016). *ArcGIS Desktop* (10.5) [software]. Environmental Systems Research Institute.
- Gallardo, M. (2018). Revisión y análisis de estudios de modelos de cambios de usos del suelo y de escenarios a futuro. *Geographicalia*, (70), 1-26. https://doi.org/10.26754/ojs_geoph/geoph.2018703278
- Gómez Delgado, M. y Rodríguez Espinosa, V. M. (2012). *Análisis de la dinámica urbana y simulación de escenarios de desarrollo futuro con tecnologías de la información geográfica*. RA-MA Editorial.
- Gómez, L. F. (2020). Simulación de escenarios futuros de cambios de usos del suelo usando Redes Neuronales Artificiales. Aplicación en la ciudad de Curuzú Cuatiá, Corrientes, Argentina. *Estudios Socioterritoriales. Revista de Geografía*, 28, 1-21. <https://repositorio.unne.edu.ar/handle/123456789/53092>
- Harris, C. D. y Ullman, E. L. (1945). The nature of cities. *The Annals of the American Academy of Political and Social Science*, 242(1), 7-17. <https://journals.sagepub.com/doi/10.1177/000271624524200103>
- Hassan, M. I. y Elhassan, S. M. M. (2020). Modelling of Urban Growth and Planning: A Critical Review. *Journal of Building Construction and Planning Research*, 8(4), 245-262. <https://doi.org/10.4236/jbcpr.2020.84016>
- Henríquez Ruiz, C. (2014). *Modelando el crecimiento de ciudades medias. Hacia un desarrollo urbano sostenible*. Ediciones UC. <https://doi.org/10.2307/j.ctt17t772d>
- Henríquez, C. e Hidalgo, R. (2023). Escenarios de crecimiento en ciudades medias chilenas: lectura de trayectorias futuras para diferentes tipologías urbanas. En C. Henríquez, W. Ribeiro da Silva, V. Aprigliano Fernandes y G. Salazar (Eds.), *Urbanización y ciudades medias, territorios y espacialidades en cuestionamiento* (pp.135-153) (Serie GEOlibros, 39). Instituto de Geografía, Pontificia Universidad Católica de Chile.
- Janoschka, M. (2002). El nuevo modelo de la ciudad latinoamericana: fragmentación y privatización. *EURE (Santiago)*, 28(85), 11-20. <https://doi.org/10.4067/S0250-71612002008500002>
- Li, W., Arundel, S. T., Gao, S. Goodchild, M. F., Hu, Y., Wang, S. y Zipf, A. (2024). GeoAI for Science and the Science of GeoAI. *Journal of Spatial Information Science*, (29), 1-17. <https://doi.org/10.5311/JOSIS.2024.29.349>

- Li, X. y Gong, P. (2016). Urban growth models: progress and perspective. *Science Bulletin*, 61(21), 1637-1650. <https://doi.org/10.1007/S11434-016-1111-1>
- Linares, S. (2017). Evolución histórica sobre la modelización del espacio urbano en geografía. *Sociedade e Território*, 28(2), 23-41. <https://ri.conicet.gov.ar/handle/11336/27002>
- Linares, S., Iturrioz, I. y Di Nucci, J. (2022). La expansión urbana de la ciudad de Tandil 1991-2020 mediante el uso del Landscape Expansion Index (LEI). *Pleamar*, 2(2), 59-77. <https://fh.mdp.edu.ar/revistas/index.php/pleamar/article/view/6437>
- Liu, X., Li, X., Shi, X., Wu, S. y Liu, T. (2008). Simulating complex urban development using kernel-based non-linear cellular automata. *Ecological Modelling*, 211(1-2), 169-181. <https://doi.org/10.1016/j.ecolmodel.2007.08.024>
- Meentemeyer, R. K., Tang, W., Dornig, M. A., Vogler, J. B., Cunniffe, N. J. y Shoemaker, D. A. (2013). FUTURES: Multilevel Simulations of Emerging Urban–Rural Landscape Structure Using a Stochastic Patch-Growing Algorithm. *Annals of the Association of American Geographers*, 103(4), 785-807. <http://dx.doi.org/10.1080/00045608.2012.707591>
- Müller, U. y Mertins G. (2005). Tendencias recientes del desarrollo estructural urbano y de los conflictos sociales en las aglomeraciones del Cono Sur. En *Experiencias de Inclusión Social con Jóvenes de Sectores Careciados en las Mercociudades* (pp. 37-51). Deutsche Gesellschaft für Technische Zusammenarbeit.
- Ordenanza N.º 9865 del año 2005 [Municipio de Tandil]. Plan de Desarrollo Territorial. Concejo Deliberante de Tandil, 2005.
- Pauleit, S., Ennos, R., y Golding, Y. (2005). Modeling the environmental impacts of urban land use and land cover change—a study in Merseyside, UK. *Landscape and Urban Planning*, 71(2-4), 295-310. <https://doi.org/10.1016/J.LANDURBPLAN.2004.03.009>
- Potocko, A. y Tella, G. (2019). *Expansión urbana en Argentina. Lógicas, oportunidades y desafíos*. Cámara Argentina de la Construcción.
- Rindfuss, R. R., Walsh, S. J., Turner, B. L. I., Fox, J. y Mishra, V. (2004). Developing a science of land change: Challenges and methodological issues. *Proceedings of the National Academy of Sciences*, 101(39), 13976-13981. <https://doi.org/10.1073/pnas.0401545101>
- Rojas, C., Opazo, S. y Jaque, E. (2009). Dinámica de crecimiento urbano del área metropolitana de Concepción: tendencias de las últimas décadas. En R. Hidalgo, C. De Mattos y F. Arenas (Eds.), *Chile: del país urbano al país metropolitano* (pp. 257-268). Pontificia Universidad Católica de Chile.
- Sangermano, F., Eastman, J. R. y Zhu, H. (2010). Similarity Weighted Instance-based Learning for the Generation of Transition Potentials in Land Use Change Modeling. *Transactions in GIS*, 14(5), 569-580. <https://doi.org/10.1111/j.1467-9671.2010.01226.x>
- Spósito, E. S. y Spósito, M. E. B. (2020). Sociospatial Fragmentation. *Mercator*, 19(6), 1-12. <https://doi.org/10.4215/rm2020.e19015>
- Triantakonstantis, D. y Mountrakis, G. (2012). Urban Growth Prediction: A Review of Computational Models and Human Perceptions. *Journal of Geographic Information System*, 4(6), 555-587. <https://doi.org/10.4236/jgis.2012.46060>
- van Notten, P. W. F., Rotmans, J., van Asselt, M. B. A. y Rothman, D. S. (2003). An updated scenario typology. *Futures*, 35(5), 423-443. [https://doi.org/10.1016/S0016-3287\(02\)00090-3](https://doi.org/10.1016/S0016-3287(02)00090-3)
- Veldkamp, A. y Verburg, P. H. (2004). Modelling land use change and environmental impact. *Journal of Environmental Management*, 72(1-2), 1-3. <https://doi.org/10.1016/J.JENVMAN.2004.04.004>
- Wack, P. (1985). Scenarios: uncharted waters ahead. *Harvard business review*, 63(5), 72-89. <https://hbr.org/1985/09/scenarios-charted-waters-ahead>
- Wegener, M. (1994). Operational Urban Models State of the Art. *Journal of the American Planning Association*, 60(1), 17-29. <https://doi.org/10.1080/01944369408975547>
-