

Modelado de expansión urbana mediante autómatas celulares y redes neuronales artificiales^o

Noelia Principi*

Resumen

El crecimiento urbano incontrolado en áreas con deficiencias en la infraestructura y servicios inadecuados y/o sobrecargados, es actualmente uno de los temas centrales en los estudios territoriales. Según estimaciones de la Organización de Naciones Unidas en el 2030, un 60 % de la población mundial vivirá en ciudades y el 95 % de esa expansión se producirá en los países en desarrollo. El artículo presenta un modelo, basado en el uso de autómatas celulares y una red neuronal artificial, que permite simular la expansión urbana a partir de criterios que definirían las configuraciones espaciales futuras. El desarrollo metodológico se aplica a la ciudad de Luján (Buenos Aires, Argentina) y se realiza en Sistemas de Información Geográfica a partir de la automatización de los procedimientos para el análisis de cambios de uso de suelo disponible en la herramienta MOLUSCE (*Methods Of Land Use Change Evaluation*) en QGIS. Los resultados evidencian que la tendencia de expansión al 2030 es de un 20 %, lo que equivale a la incorporación de 6,72 km² de cobertura urbana, si no se realizara ningún tipo de intervención. La relevancia de este tipo de trabajo radica en que los resultados brindan apoyo técnico-científico para los organismos de planificación y gestión en relación a la toma de decisiones espaciales.

Palabras clave: Expansión urbana; Red neuronal artificial; Autómatas celulares; Sistemas de Información Geográfica; Ciudad de Luján.

Modeling of urban expansion using cellular automata and artificial neural networks

Abstract

Uncontrolled urban growth in areas with deficient infrastructure and inadequate and/or overloaded services is currently one of the central issues in territorial studies. According to the United Nations estimates, by 2030, 60% of the world's

^o DOI: <https://doi.org/10.52292/j.rug.2022.31.1.0036>

* Docente-investigadora auxiliar. Instituto de Investigaciones Geográficas. Universidad Nacional de Luján. Luján, Argentina. nprincipi@unlu.edu.ar

population will be living in cities and 95% of this expansion will take place in developing countries. This article presents a model based on the use of cellular automata and an artificial neural network, which allows the simulation of urban expansion based on criteria that would define future spatial configurations. The methodological development is applied to the city of Luján (Buenos Aires, Argentina) and is carried out in Geographic Information Systems from the automation of the procedures for the analysis of land use changes available in the MOLUSCE tool (Methods for Land Use Change Evaluation) in QGIS. The results show that the expansion trend to 2030 is 20%, which is equivalent to the incorporation of 6.72 km² of urban coverage, if no type of intervention is carried out. The relevance of this type of work lies in the fact that the results provide technical-scientific support for planning and management agencies in relation to spatial decision making.

Keywords: Urban expansion; Artificial neural network; Cellular automata; Geographic Information Systems; City of Luján

Introducción

La expansión urbana es actualmente uno de los temas centrales en los estudios territoriales. Según las consideraciones de Hábitat III¹ se estima que para el 2030 un 60 % de la población mundial vivirá en ciudades y el 95 % de la expansión urbana se producirán en los países en desarrollo (Naciones Unidas – Hábitat, 2016). La temática está presente en las medidas adoptadas por la “Agenda 2030” de la Organización de las Naciones Unidas (Naciones Unidas, 2016). En el marco de la agenda, se plantearon 17 “Objetivos de Desarrollo Sostenible” (ODS) entre los que se encuentra lograr “ciudades y comunidades sostenibles”², resaltando la importancia de abordar la problemática del crecimiento urbano incontrolado, especialmente en los países en desarrollo, en áreas con infraestructuras y servicios inadecuados y/o sobrecargados.

El artículo presenta un modelo de crecimiento urbano basado en inteligencia artificial y autómatas celulares que permite simular la expansión urbana. Se realiza la aplicación a Luján (Buenos Aires), una ciudad intermedia de la República Argentina, para modelizar la expansión urbana al año 2030, a partir de diferentes parámetros que definirían configuraciones espaciales futuras.

Se detallan las diferentes etapas metodológicas del modelado, que actualmente se realiza de forma automatizada con la herramienta MOLUSCE (Modules for Land Use Change Evaluation) desarrollada especialmente para el análisis de cambios en el uso de suelo, disponible en el Sistema de Información Geográfica (SIG) libre y de código abierto, QGIS, en su versión 2.18.

Modelado de expansión urbana

El modelado de expansión urbana basado en autómatas celulares, explicado detalladamente por Aguilera Benavente (2006), comienza en la década de 1940 con el matemático húngaro John Von Neumann que intentaba modelar máquinas trabajando de forma autónoma (autómatas) y que tuvieran la posibilidad de auto-reproducirse. Continúa con los aportes del matemático polaco Stanislaw Ulam que enmarcó el trabajo en un ambiente de células, considerando una red infinita como malla cuadrículada con una base espacial discreta.

La combinación de estos desarrollos dio lugar a la aparición del primer modelo de Autómata Celular de Von Neumann, un modelo matemático para un sistema dinámico compuesto por un conjunto de celdas (o células) que adquieren distintos

¹ Hábitat III fue la Conferencia de las Naciones Unidas sobre la Vivienda y el Desarrollo Urbano Sostenible desarrollada Quito, Ecuador, del 17 al 20 de octubre del 2016.

² Resolución 70/1. Transformar nuestro mundo: La Agenda 2030 para el Desarrollo Sostenible. Asamblea General de las Naciones Unidas. 21 de octubre del 2015.

estados o valores, que son alterados de un instante a otro en unidades de tiempo discreto. De esta manera, las celdas logran una evolución, según una determinada expresión matemática, que es sensible a los estados de las células vecinas a través de una regla de transición local. Existen diferentes tipos de análisis de vecindad. Una posibilidad metodológica es utilizar la vecindad de Moore la cual considera a todas las celdas que rodean a la celda central, con diferentes proximidades desde esa celda (Figura 1) y que mostró utilidad en las aplicaciones realizadas por Aguilera Ontiveros (2002) y Aguilera Benavente, Plata Rocha, Bosque Sendra y Gómez Delgado (2009) para el análisis de cambios de usos del suelo.

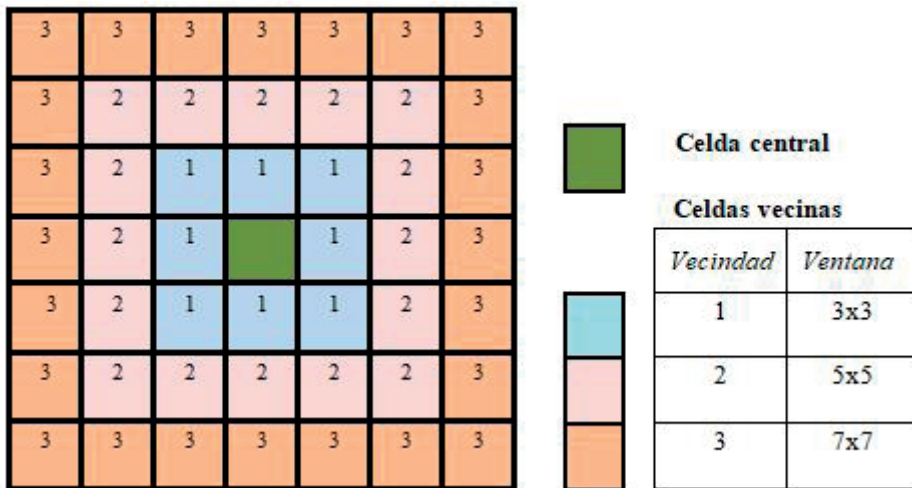


Figura 1. Vecindad de Moore con diferentes proximidades (ventanas). Fuente: Elaborado por Principi.

Por su parte, el análisis e implementación de redes neuronales artificiales, en el marco de la inteligencia artificial, también comienza a desarrollarse en la década de 1940 con aportes de varios investigadores entre los que se destacan McCulloch y Pitts (1943), Householder y Landahl (1945), Von Neumann (1945) y Culbertson (1956), quienes elaboraron los primeros modelos matemáticos de neuronas y redes neuronales. En la década de los '50 se combinaron los resultados obtenidos por matemáticos, biólogos y psicólogos y se desarrollaron modelos de simulación de neuronas y redes neuronales en computadora, dando lugar a la forma más generalizada de trabajar con estos sistemas que es su simulación en el ámbito computacional (Lara, 2011).

El perceptrón multicapa (Fig. 2) es un tipo de Red Neuronal Artificial (RNA) que utiliza capas de entradas, capas ocultas y capa de salida, compuestas por una serie de

neuronas que se encargan de recibir, procesar y enviar datos hacia otras neuronas a partir de un flujo de información unidireccional que se activa al recibir información de la capa anterior, ponderarla, sumarla y luego a partir de una función de activación se producen las salidas de la neurona, es decir, la predicción (Mas, 2017).

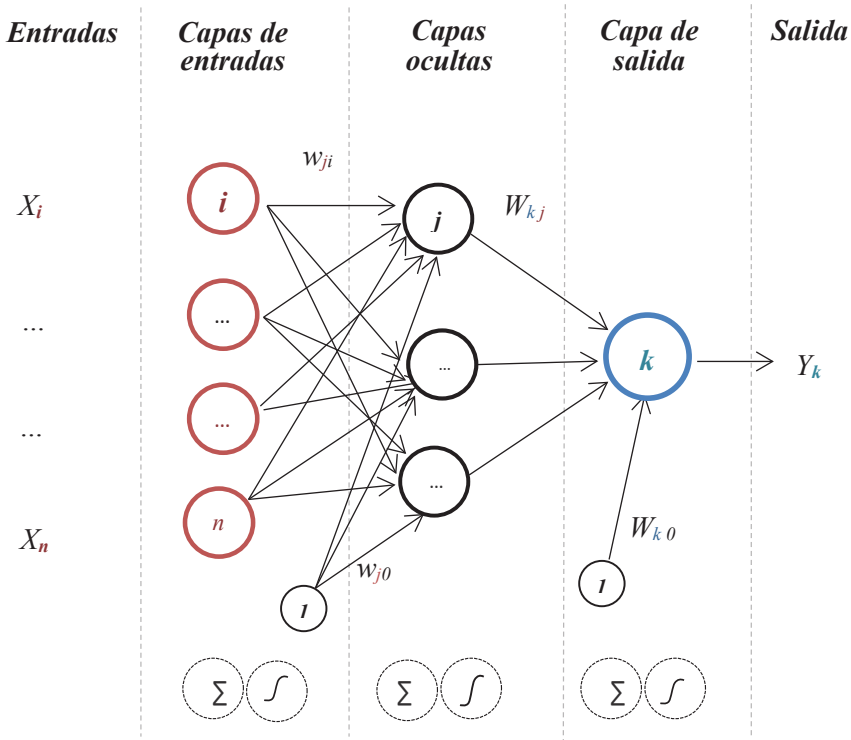


Figura 2. Representación de un perceptrón multicapa. Fuente: Mas, J.-F. 2017:56 (adaptación)

En el esquema representativo de un perceptrón multicapa se observan las X como capas de entrada, que corresponden a las variables explicativas; w_{ji} , que corresponde al peso de conexión entre la capa, o neurona, de entrada i y la capa o neurona oculta j ; w_{kj} , al peso de conexión entre la neurona oculta j y la neurona de salida k ; y el peso w_{j0} se considera como un peso asociado con una neurona ficticia con un valor de salida igual a 1. Debajo aparecen representados el símbolo de sumatoria, que corresponde a la función de red, y el de la función sigmoidea, que corresponde al procedimiento de activación.

Las conexiones entre las neuronas se modelan mediante pesos numéricos que establecen el grado de correlación, a su vez estos pesos son ajustados durante la etapa de entrenamiento de la red y luego cada neurona envía a las neuronas de la siguiente capa un valor conocido como valor de activación.

Herramienta MOLUSCE en QGIS

MOLUSCE (Modules for Land Use Change Evaluation) fue especialmente diseñado para analizar, evaluar, modelizar y simular cambios y escenarios futuros de uso del suelo (Villalobos, 2019). Los métodos y algoritmos utilizados que se explicitan a continuación fueron detallados por Asia Air Survey y NextGIS (2014). El primer procedimiento consiste en la normalización de las variables explicativas con el objetivo de lograr un entrenamiento más eficiente y un resultado de predicción más preciso. Para la estandarización se utiliza el puntaje Z [1]:

$$[1] Z = \frac{X - \bar{X}}{\sigma}$$

donde Z es la variable normalizada, X es la variable considerada, \bar{X} media de X y σ es la desviación estándar de X .

Seguidamente, se realiza el análisis de cambios de cobertura de la tierra en dos momentos o tiempos, denominados tiempo inicial, o tiempo 1 (T1), y tiempo final, o tiempo 2 (T2), con el objetivo de calcular la superficie y localización de los procesos de cambio. Se realiza una matriz de transición que calcula la cantidad de superficie ocupada por cada uso del suelo en T1 y en el T2, obteniendo valores de superficie y valores porcentuales de cambio. Es fundamental identificar estas tendencias en los cambios de cobertura porque es la base sobre la que se realiza la proyección futura, que considera el mismo rango de tiempo. Es decir, si el T1 es el año 2010 y T2 es el año 2020, la proyección será hacia el 2030.

Luego, a partir de variables de entrada consideradas como factores de cambio, se aplica la RNA, utilizando un algoritmo de retropropagación clásico que tiene la capacidad autónoma para analizar la precisión alcanzada, y realizar su propia validación del modelo, ya que almacena la mejor red neuronal en la memoria. Durante este procedimiento autónomo de aprendizaje se realiza la corrección de pesos de la red [2]:

$$[2] w(n+1) = r * dw(n) + m * dw(n-1)$$

donde w es un vector de pesos de neuronas, dw es un vector de cambios de pesos, n es un número de iteración, r es la tasa de aprendizaje, m es el momento. Se utiliza un aprendizaje en línea estocástico, lo que significa que se selecciona una muestra aleatoria del conjunto de aprendizaje y los pesos de la red se van actualizando durante el entrenamiento de la red.

El error de ajuste, para una muestra, es el error cuadrático medio de las salidas parciales de la red [3]:

$$[3] E = \frac{t_i - o_i}{d}$$

donde E es un error de muestra, t_i es el valor objetivo de una neurona de salida para una muestra determinada, o_i es el valor de salida real de la neurona, d es el recuento de neuronas de salida.

Una vez realizado el entrenamiento de la red se obtiene diferente información sobre el aprendizaje: un gráfico de los errores cuadrados medios, el error general de validación mínima que considera el mejor resultado obtenido por la red y la precisión global delta, que es la diferencia entre el error de validación mínimo y el error de validación actual.

Finalizado el análisis de las variables explicativas a través de la RNA perceptrón multicapa, se continúa con el modelado a partir de los Autómatas Celulares (AC) utilizando los datos de entrada correspondiente al mapa del T2 de donde obtiene la información sobre las categorías actuales de cobertura de la tierra, las variables explicativas normalizadas y el modelo resultado de la RNA.

El modelo predictor basado en AC considera las probabilidades de cambio según la matriz de transición y realiza el recuento de celdas que deben cambiarse para cada clase de transición; escanea las celdas vecinas y calcula los potenciales de transición. Para cada clase de transición el modelo busca las transiciones más probables realizando un recuento de celdas con la mayor confianza y cambia la categoría de las mismas según corresponda. Al final de cada iteración del modelo, que corresponde a 1 año de crecimiento, las celdas con mayor potencial de transición se transforman en urbanas, dando lugar al mapa final que muestra el modelo urbano futuro.

Como paso final se realiza la validación del modelo. Se verifica la precisión de la simulación a partir de estadísticas Kappa que permiten establecer la correspondencia de los resultados con la siguiente característica:

$$[4] -1 \leq k \leq 1$$

Cuando el valor de Kappa es más cercano a 1 indica mayor nivel de correspondencia. La tabla I presenta la escala de valoración ampliamente utilizada para expresar cualitativamente la fuerza de la concordancia.

Valor de Kappa	Grado de acuerdo
< 0,00	Pobre
0 – 0.20	Leve
0,21 – 0,40	Aceptable
0,41 – 0,60	Moderado
0,61 – 0,80	Considerable
0,81 - 1	Excelente

Tabla I. Grado de acuerdo del índice Kappa. Fuente: Landis y Koch (1977).

La validación computacional del modelo utiliza tres estadísticas de Kappa. El índice Kappa general, el Kappa histograma y el Kappa localización.

El índice Kappa general mide la correspondencia del mapa resultado de la simulación con el mapa de validación y se define como [5]:

$$[5] \quad k = \frac{P(A) - P(E)}{1 - P(E)}$$

El índice Kappa localización mide la similitud de la asignación espacial de las categorías en los dos mapas comparados y se define como [6]:

$$[6] \quad k_{loc} = \frac{P(A) - P(E)}{P_{max} - P(E)}$$

El índice Kappa histograma se calcula directamente desde los histogramas de los mapas y mide la similitud cuantitativa de los dos mapas comparados. Se define como [7]:

$$[7] \quad k_h = \frac{P_{max} - P(E)}{1 - P(E)}$$

donde:

$$P(A) = n \sum_{i=1}^c p_{ii}$$

$$P(E) = n \sum_{i=1}^c p_{iT} p_{Ti}$$

$$P_{max} = n \sum_{i=1}^c \min(p_{iT}, p_{Ti})$$

p_i son los valores de la diagonal principal, P_{iT} el total de las observaciones en la fila i , p_{Ti} el total de observaciones en la columna i , n el total de píxeles del área de estudio y c la cantidad de filas de la matriz de cruce tabular.

Con la finalización de la validación con estadísticas Kappa culmina el proceso de modelado de coberturas de la tierra a partir de AC y RNA, automatizado en QGIS a través del complemento MOLUSCE.

Aplicación del modelado a la ciudad de Luján

Área de estudio

La ciudad de Luján es una aglomeración de tamaño intermedio de la República Argentina (Fig. 3) que, según los datos del último Censo Nacional de Población, Hogares y Viviendas del año 2010, cuenta con 78.346 habitantes. En Argentina, a partir de la clasificación realizada por Vapñarsky y Gorojovsky (1990), se consideran Aglomeraciones de Tamaño Intermedio (ATIs) a los aglomerados que tienen entre 50.000 y 999.999 habitantes. A su vez, esa categoría se subdivide en ATIs mayores (de 400.000 hasta 999.999 habitantes) y ATIs menores (de 50.000 hasta 399.999 habitantes). Esta última subcategoría, en la que se encuentra enmarcada la ciudad de Luján, presenta un crecimiento y dinamismo muy importante en los últimos períodos intercensales. Entre 1980-2010 han tenido un crecimiento poblacional del 90 %. Según datos del Censo 2010, 7.5 millones de personas residen en ATIs menores en Argentina, lo que representa un 18,7 % de la población total del país (Linares, Di Nucci y Velázquez, 2016).

Luján se encuentra a 68 km de la Ciudad Autónoma de Buenos Aires (CABA) pero si consideramos su mancha urbana, es decir, la ciudad desde un punto de vista físico, se encuentra separada por sólo dos kilómetros del Aglomerado Gran Buenos Aires (AGBA). En un trabajo reciente se mostraron evidencias que indican que Luján forma parte de la Megaciudad Buenos Aires, teniendo en cuenta la infraestructura gris al considerar conjuntamente el espacio adaptado y el sistema de flujos (Buzai y Montes Galbán, 2020).

La ciudad de Luján se originó a fines del siglo XVII, a orillas del río homónimo, un río de llanura que realiza su recorrido total por la planicie ondulada de la pampa en la provincia de Buenos Aires. El río sufre recurrentes desbordes, por causas principalmente pluviométricas, generando importantes inundaciones urbanas tanto en áreas centrales como periféricas de la ciudad; por tal motivo, simular la expansión urbana resulta importante para considerar estrategias de planificación territorial que consideren y minimicen el crecimiento hacia zonas inundables, desde un enfoque geográfico prospectivo.

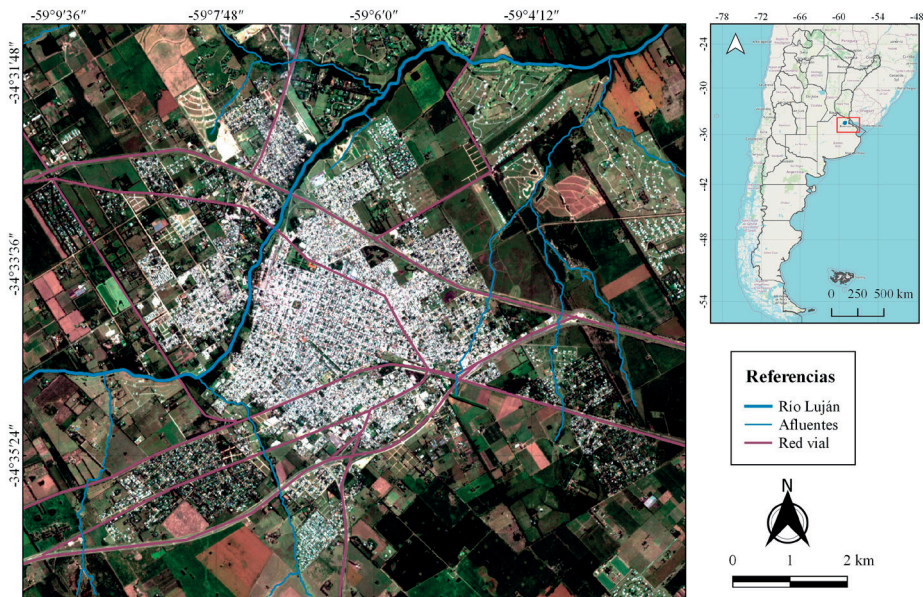


Figura 3. Ciudad de Luján. Fuente: Elaborado por Principi en base a imagen satelital Sentinel-2 color natural de la *European Space Agency* (ESA) con fecha 20/03/20.

Datos de entrada

El modelado de expansión urbana en MOLUSCE inicia con datos de entrada en formato ráster. Se consideran dos mapas de cobertura de tierra urbana en la ciudad de Luján, en el 2010 como T1 y el del 2020 como T2 (Fig. 4 a y b) para realizar la predicción al 2030. El mapa de cobertura urbana del 2010 fue realizado por Humacata (2017) a partir de una clasificación digital y visual de imágenes satelitales Landsat 5 (sensor TM) con fecha 8/12/2010 y un pixel de 20 metros de lado. El mapa del 2020 se realizó a partir de la interpretación visual de imágenes satelitales de Sentinel 2 con fecha 4/3/20, con un pixel de 20 metros de lado.

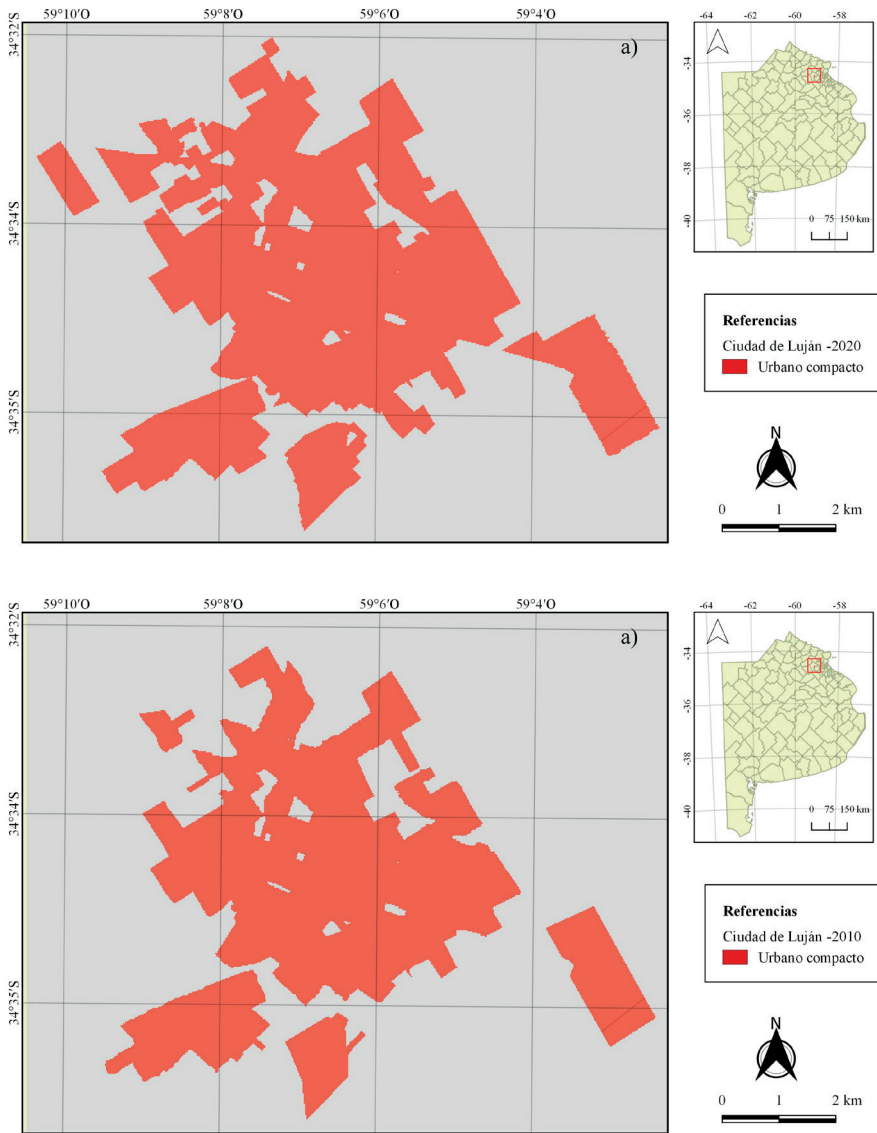


Figura 4. a) Área urbana 2010 y b) Área urbana 2020. Fuente: Elaborado por Principi en QGIS 2.18 sobre la base de Humacata (2017).

En esta instancia se incorporan los factores que se consideran impulsores o limitantes de cambio. En este trabajo los criterios son los siguientes:

- *Distancia al área urbana actual*, considerando que la expansión urbana de tipo compacta se da como forma de mancha de aceite en zonas contiguas al área urbana consolidada.

- *Distancia a las áreas complementarias*, consideradas en el Código de Ordenamiento Urbano (COU) del partido de Luján (2019) con el código AC-RE1³ (Áreas complementarias Residenciales Extraurbanas 1) y AC-RE2⁴ (Áreas complementarias Residenciales Extraurbanas 2), como áreas de posible expansión urbano-residencial.
- *Distancia a las principales vías de comunicación* como factor importante respecto a la movilidad que tiene la ciudad vinculada principalmente a su posición en el extremo oeste de la Región Metropolitana de Buenos Aires (RMBA) y vínculo con CABA.
- *Pendiente del terreno*, obtenida a partir de un Modelo de Elevación Digital aerofotogramétrico de acceso libre obtenido del Instituto Geográfico Nacional de la República Argentina⁵, del año 2013 con 5 metros de grilla. Se consideran las áreas con menor pendiente como las que tienen mayores posibilidades de expansión urbana.
- *Distribución de las áreas protegidas y de recreación*, las primeras por su condición no pueden convertirse en uso urbano y las segundas son usos consolidados de difícil reversibilidad.
- *Distribución del uso urbano disperso*, esta variable considera áreas de urbanizaciones privadas como barrios cerrados, clubes de campo y *countryside* que se localizan en el área periurbana, o zonas de interfase urbano-rural, restringiendo la expansión urbana hacia esos lugares.

Los mapas fueron generados con el mismo número de filas, columnas, píxeles y sistema de coordenadas. Además, se realizó un procedimiento de estandarización difusa en las variables para obtener valores que oscilen entre 0 y 1 (menos a más significativo). En el caso de las variables que son restrictivas se realizaron mapas *booleanos* con valores 0 y 1. La figura 5 presenta los factores utilizados.

Evaluación de la correlación

Para la evaluación de la correlación, se utilizó el coeficiente de Pearson. Los valores pueden oscilar entre -1 (correlación negativa perfecta) y 1 (correlación positiva perfecta). Los resultados se presentan en la tabla II.

Si observamos los resultados obtenidos vemos que se alejan de -1 y 1, lo cual significa que existen niveles medios y bajos de correlación entre las variables, ya que los criterios definidos no son homogéneos entre sí. Si la correlación se acer-

³ AC-RE1: Destinado a la localización de segunda residencia y prepara las condiciones para una futura expansión del área urbana. Se admite localización de urbanizaciones especiales (COU, 2019:16).

⁴ AC-RE2: Contempla una primera subdivisión en quintas y grandes parcelas cuya geometría admite fraccionamientos posteriores. Se permite desarrollo de urbanizaciones especiales. (COU, 2019:16).

⁵ El MDE Aerofotogramétrico está disponible para su descarga en el sitio oficial del IGN: <https://www.ign.gob.ar/category/tem%C3%A1tica/geodesia/mde-ar>. Luján pertenece sector 1.3 del AMBA.

cara a los valores perfectos, estaríamos ante la presencia variables explicativas muy parecidas lo que podría reducirse a considerar menos variables, ya que todas se comportarían de forma similar. En este caso la diversidad indica que existirá influencia de todas las variables al momento de la predicción al 2030.

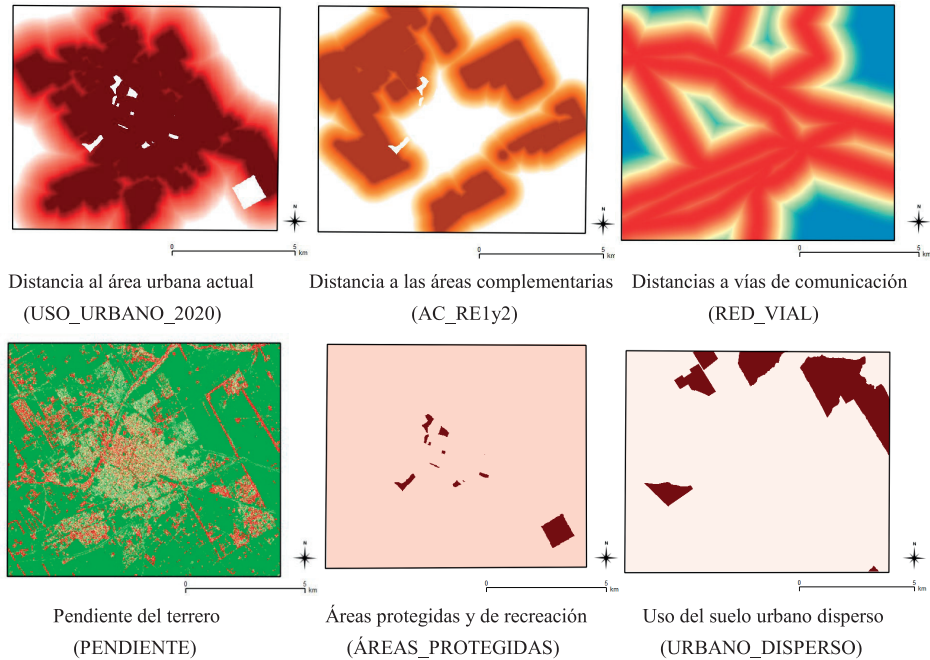


Figura 5. Factores utilizados para simular expansión urbana.

Fuente: Elaborado por Principi en QGIS 2.18.

	Ac_ Re1y2	Urbano_ Disperso	Areas_ Protegidas	Red_vial	Uso_ Urbano_2020	Pendiente
Ac_rely2	--	0,04	0,15	0,34	0,34	0,06
Urbano_ Disperso		--	-0.04	0,25	0.36	0,05
Areas_ Protegidas			--	0,07	0.23	0,05
Red_vial				--	0,65	-0,10
Uso_urbano_2020					--	-0,18
Pendiente						--

Tabla II. Evaluación de correlación entre variables. Fuente: Elaborado por Principi a partir del resultado de MOLUSCE en QGIS 2.18.

Cambios de área

Luego, se realiza el análisis de cambios entre coberturas de la tierra a través de estadísticas básicas (Tabla III) y la matriz de transición (Tabla IV) que arroja valores entre 0 y 1, indicando probabilidad de cambio de una categoría a otra. En este caso particular sólo incluye el cambio de “no urbano” (valor 0) a “urbano” (valor 1) en kilómetros cuadrados. Se obtiene el mapa de cambios (Fig. 6).

	2010 Superficie en km ²	2020 Superficie en km ²	Cambios 2010- 2020 en Superficie en km ²	2010 Superficie en %	2020 Superficie en %	Cambios 2010- 2020 en %
0 (No-urbano)	77,47	72,47	-5,24	73,64	68,67	-4,96
1 (Urbano)	27,82	33,06	5,24	26,36	31,33	4,96

Tabla III. Estadísticas básicas de cambios de uso del suelo. Fuente: Elaborado por Principi a partir del resultado de MOLUSCE en QGIS 2.18.

	0-No-urbano	1-Urbano
0-No-urbano	0,932	0,068
1-Urbano	0,002	0,998

Tabla IV. Matriz de transición. Fuente: Elaborado por Principi a partir del resultado de MOLUSCE en QGIS 2.18.

En la figura 6 se puede observar la variación de superficie de área urbana entre el 2010 (color rojo) y el 2020 (color amarillo), con un aumento de 5,24 km² que porcentualmente corresponde al 4,96 %. La información acerca de la tendencia en el cambio de cobertura es importante al momento de realizar la proyección futura.

Modelo de transición

El modelo de transición utiliza la RNA perceptrón multicapa. Se seleccionaron aleatoriamente 5000 puntos de muestra que se utilizarán para la calibración y validación del modelo. Durante la aplicación se utiliza el algoritmo de aprendizaje que analiza la precisión alcanzada en el entrenamiento, valida las muestras y almacena la mejor red neuronal en la memoria. El proceso de entrenamiento termina cuando se alcanza la mejor precisión. Para el periodo de análisis se hicieron diferentes pruebas para estimar el mejor entrenamiento de la red para la posterior aplicación de autómatas celulares.

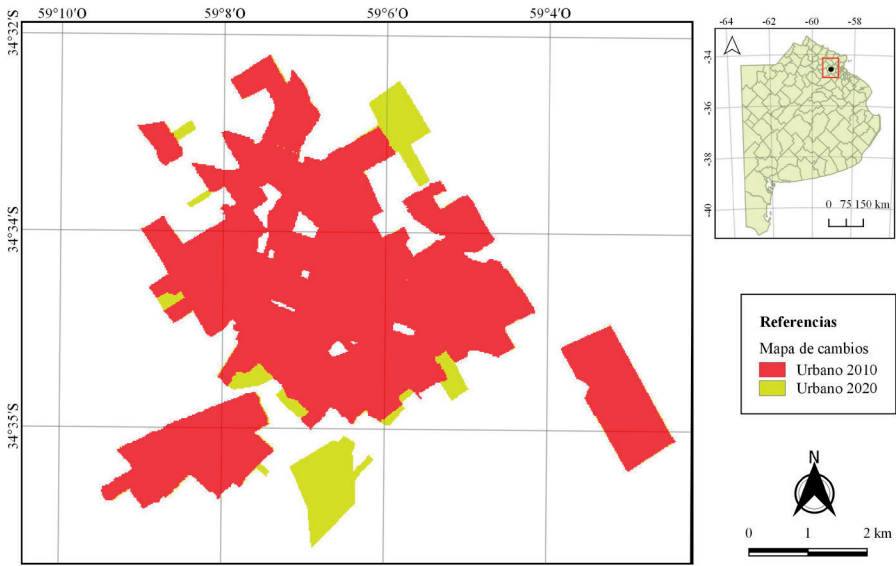


Figura 6. Mapa de cambios 2010-2020. Fuente: Elaborado por Principi a partir del resultado de MOLUSCE en QGIS 2.18.

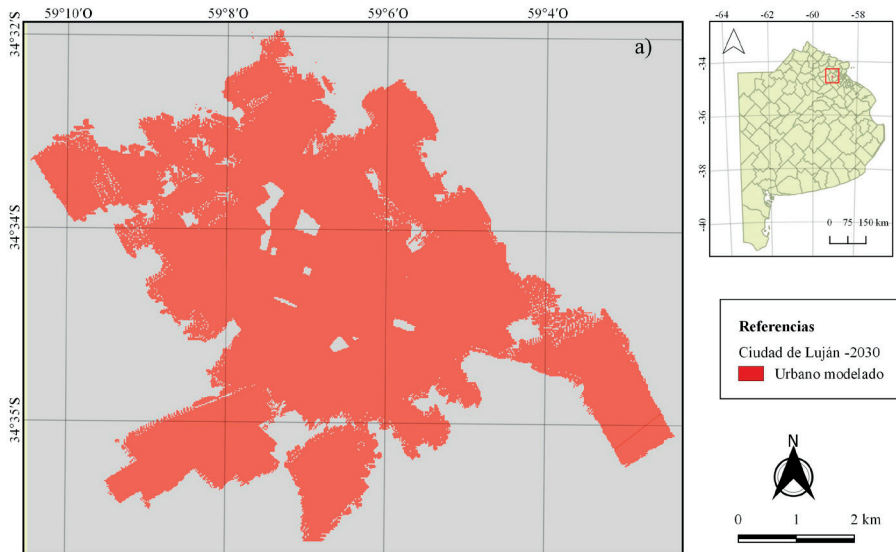


Figura 7. Captura del proceso de entrenamiento de la red neuronal artificial. Fuente: MOLUSCE en QGIS 2.18.

Este proceso consistió en hacer ajustes del tipo de vecindario donde se definió una vecindad de 1, es decir 9 píxeles (3x3), el ritmo e impulso de aprendizaje de 0,005, el número de iteraciones que se estableció en 10.000 y la cantidad de capas ocultas que quedaron definidas en ocho. Un ritmo e impulso de aprendizaje con valores grandes permiten un aprendizaje rápido, pero el proceso de aprendizaje puede ser inestable con resultados que mostrarían picos en el gráfico. En cambio, valores pequeños, como el utilizado, significa un aprendizaje estable pero que resulta más lento al momento de procesar. La figura 7 presenta el resultado del entrenamiento de la red neuronal que arrojó un error global menor a 5 % (0,05) y un índice Kappa general de 0,89.

Simulación de uso del suelo

El último procedimiento consiste en aplicar el modelo de autómatas celulares para obtener el mapa de uso del suelo urbano al año 2030. Una vez finalizada la proyección, es posible validar el modelo si se tienen datos con los cuáles comparar. La figura 8 nos muestra el resultado de la simulación de expansión urbana para el año 2030.

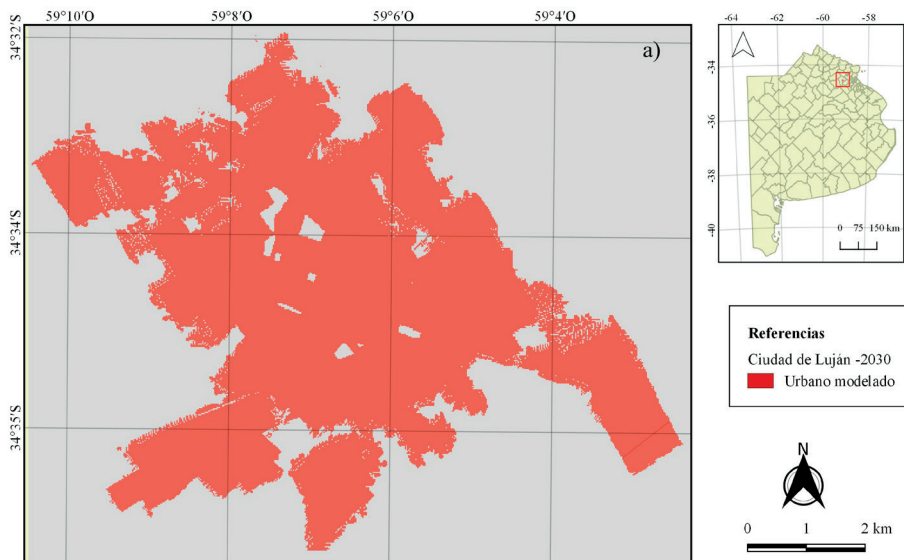


Figura 8. Modelado de expansión urbana al 2030. Fuente: Elaborado por Principi a partir del resultado de MOLUSCE en QGIS 2.18.

Los datos (Tabla V) indican que entre el 2010 y 2020 la superficie urbana creció 5,24 km², lo que equivale a un 18 % de superficie total (27,82 km²) y el resultado del modelado de expansión urbana al 2030 indica que el crecimiento sería de 6,72 km², es decir, un 20 % mayor.

	2010	2020	2030 (simulación)
Superficie en km ²	27,82	33,06	39,78
Aumento en km ²	-	5,24	6,72
Aumento en %	-	18	20

Tabla V. Datos de expansión urbana en la ciudad de Luján. Fuente: Elaborado por Principi a partir del resultado de MOLUSCE en QGIS 2.18.

Conclusiones

La implementación de modelos de simulación para la predicción de escenarios urbanos futuros se constituye como una excelente herramienta de apoyo a las decisiones espaciales en el marco del ordenamiento territorial. Los procedimientos metodológicos explicitados tienen especial relevancia en la etapa del diagnóstico territorial ya que a partir de estos se generan nuevos conocimientos que permiten avanzar en la elaboración de propuestas que favorezcan la planificación territorial a escala local.

La combinación del modelado basado en una red neuronal artificial y autómatas celulares, permitió la generación de un escenario futuro de expansión urbana en la ciudad de Luján. Los valores de crecimiento de la superficie urbana de las últimas dos décadas (2010-2020) y su proyección al 2030 son altos, 5,24 km² (18 %) y 6,72 km² (20 %) respectivamente y se corresponden con el gran dinamismo que tienen las aglomeraciones de tamaño intermedio en el país y sobre todo una ciudad como Luján que integra la RMBA y que, según estudios recientes, ya forma parte de la Megaciudad Buenos Aires.

Contar con este tipo de información resulta de especial interés para que los decisores puedan analizar el espacio geográfico con una mirada prospectiva, teniendo una aproximación a la tendencia del crecimiento urbano si no se realiza ninguna intervención. De esta forma, es posible impulsar cambios con el objetivo de favorecer la expansión urbana en áreas que presenten características favorables para el desarrollo de ese uso del suelo, con el objetivo de mejorar la calidad de vida de la población.

Finalmente, se resalta la potencialidad que brindan los SIG para realizar análisis espaciales complejos, en este caso, a partir de la automatización de procedimientos de análisis de cambios de usos del suelo, donde se analizaron y relacionaron factores impulsores o limitantes del cambio.

Referencias

Aguilera Benavente, F. (2006). Predicción del crecimiento urbano mediante SIG y modelos basados en AC. *Geofocus*, 6, 81-112.

Aguilera Benavente, F.; Plata Rocha, W.; Bosque Sendra, J. y Gómez Delgado, M. (2009). Diseño y simulación de escenarios de demanda de suelo urbano en ámbitos metropolitanos. *Revista Internacional Sostenibilidad, Tecnología y Humanismo*, 4, 57-80.

Aguilera Ontiveros, A. (2002). *Ciudades como tableros de ajedrez: introducción al modelado de dinámicas urbanas con autómatas celulares*. San Luis Potosí: El Colegio de San Luis.

Asia Air Survey y NextGIS (2014). *Molusce. Modules for Land Use Change Evaluation*. Recuperado de https://wiki.gis-lab.info/w/Landscape_change_analysis_with_MOLUSCE_-_methods_and_algorithms

Buzai, G. D. y Montes Galbán, E. (2020). Megaciudad Buenos Aires: Cartografía de su última expansión y conurbación mediante el procesamiento digital de imágenes satelitales nocturnas. *Revista Cartográfica*, 100, 215-238.

COU (2019). *Código de Ordenamiento Urbano*. Partido de Luján. Gobierno Municipal. Recuperado de <http://luj-bue-datos.paisdigital.innovacion.gob.ar/dataset/codigo-de-ordenamiento-urbano>

Culbertson, J. T. (1956). Some uneconomical robots. En Shannon, C. E. y McCarthy, J. (eds). *Automata Studies*. Princeton: Princeton University Press.

Householder, A. S. y Landahl, H. D. (1945). *Mathematical Biophysics of the Central Nervous System. Mathematical Biophysics Monograph Series No.1*. Bloomington, USA: Principia Press.

Humacata, L. (2017). *Análisis espacial de los cambios de usos del suelo en partidos de interfase urbano-rural de la Región Metropolitana de Buenos Aires, en el periodo 2000-2010, mediante la aplicación de Tecnologías de la Información Geográfica*. [Tesis de Maestría, Universidad Nacional del Centro de la Provincia de Buenos Aires] Recuperado de <https://www.researchgate.net/publication/326169509>

Landis J.R. y Koch G.G. (1977). The measurement of observer agreement for categorical data. *Biometrics*. 33,159-174.

Lara, F. (2011). *Fundamentos de redes neuronales artificiales*. México: Laboratorio de Cibernética Aplicada-Centro de Instrumentos-Universidad Autónoma de México.

Linares, S.; Di Nucci, J. y Velázquez, G. (2016). Cambios en el Sistemas Urbano. En *Geografía y calidad de vida en Argentina. Análisis regional y departamental (2010)* (67-81). Tandil: Instituto de Geografía, Historia y Ciencias Sociales (CONICET/UNCPBA).

Naciones Unidas (2016). *Objetivos del desarrollo sostenible 17 objetivos para transformar el mundo*. Recuperado de: <http://www.un.org/sustainabledevelopment/es/cities/>

Naciones Unidas – Habitat. (2016). *Urbanization and Development: Emerging Issues. World Cities Report 2016*. Nairobi: Naciones Unidas. Recuperado de: <https://unhabitat.org/world-cities-report>

Mas, J.-F. (comp) (2017). *Análisis y modelación de patrones y procesos de cambio. México: Centro de Investigaciones en Geografía Ambiental - Universidad Nacional Autónoma de México*. Recuperado de <http://www.ciga.unam.mx/publicaciones/>.

McCulloch, W. S. y Pitts, W. H. (1943). A Logical Calculus of the Ideas Immanent in Nervous Activity. *Bulletin of Mathematical Biophysics*. 5,115-133.

Vapñarsky, C. A. y Gorojovsky, N. (1990). *El crecimiento urbano en la Argentina*. Buenos Aires: Grupo Editor Latinoamericano.

Villalobos, A. (2019). *Análisis del potencial de escurrimiento en la microcuenca del río Tiribí entre 2005 al 2029 para la conservación de los servicios ecosistémicos de regulación hídrica*. (Tesis de licenciatura en Ciencias Geográficas con énfasis en ordenamiento del territorio). Costa Rica: Universidad Nacional.

Von Neumann, J. (1945). First draft of a report on the EDVAC. Republicado en Randall, B. (ed)(1982). *The Origins of Digital Computers: Selected Papers*.. Berlín: Springer.

Fecha de Recepción: 20 de mayo de 2021

Fecha de Aceptación: 14 de octubre de 2021

© 2022 por los autores; licencia otorgada a la Revista Universitaria de Geografía. Este artículo es de acceso abierto y distribuido bajo los términos y condiciones de una licencia Atribución-NoComercial 2.5 Argentina de Creative Commons. Para ver una copia de esta licencia, visite http://creativecommons.org/licenses/by-nc/2.5/ar/deed.es_AR

