

Universidad Internacional de La Rioja (UNIR)

ESIT

Máster Universitario en Inteligencia Artificial

Clasificación de tipologías de asentamientos urbanos mediante imágenes y redes neuronales convolucionales

Trabajo Fin de Máster

Presentado por: Martínez Olmos, Óscar

Director/a: Casado Vara, Roberto

Ciudad: Valencia
Fecha: 15/9/2021

Resumen

Se ha realizado una nueva metodología que pretende abordar la clasificación automática de parcelas por su tipología de asentamiento urbano. Esta clasificación viene definida en el Atlas de Expansión Urbana y se corresponde a las clases de espacio abierto, industrial, atomística y formal excluyendo las tipologías de Informal y Proyecto Urbanístico. Se pretende automatizar el proceso para permitir realizar estudios urbanísticos a una mayor escala que la del proyecto original. Se ha creado una nueva base de datos con muestras para entrenar un modelo de red convolucional capaz de clasificar las parcelas. Se han obtenido unas precisiones del 86% de acierto en el modelo.

Palabras Clave: asentamientos, Atlas de Expansión Urbana, parcelas, redes convolucionales, urbanismo.

Abstract

A new methodology has been developed that aims to create an automatic classification of plots by their type of urban settlement. This classification is defined in the Atlas of Urban Expansion. It corresponds to the classes of: open space, industrial, atomistic and formal space, excluding informal and urban project typologies. It's intended to automate the process to allow urban studies on a larger scale than the original project. A new database with samples has been created to train a convolutional network model capable of classifying the plots. Accuracies of 86% correctness have been obtained by the model.

Keywords: Atlas of Urban Expansion, convolutional networks, plot, settlement, urbanism

Índice de contenidos

1. Introducción	1
1.1 Motivación	1
Problemas asociados a la trama urbana	1
1.2 Planteamiento del trabajo	7
1.3 Estructura de la memoria.....	10
2. Contexto y estado del arte.....	11
3. Objetivos y metodología de trabajo	20
3.1. Objetivo general.....	20
3.2. Objetivos específicos	21
3.3. Metodología del trabajo	21
4. Descripción detallada del experimento	24
4.1 Tarea de digitalización	24
4.2 Limitaciones de digitalización	32
4.3 Creación de muestras	33
4.4 Preparación de la base de datos de entrenamiento.....	35
4.5 Entrenamiento del modelo.....	37
4.6 Ejecución de la clasificación.....	42
4.7 Predicción	43
5. Descripción de los resultados.....	43
5.1 Métricas obtenidas.....	44
6. Discusión	52
7. Conclusiones y trabajo futuro.....	56
7.1. Conclusiones	56
7.2. Líneas de trabajo futuro	59
8. Bibliografía	61
Anexos	64

Anexo. Artículo de investigación	64
--	----

Índice de tablas

Tabla 1 Resumen de número de muestras por cada ciudad	32
Tabla 2 Resumen de los valores de la matriz de confusión por tipología para los datos de entrenamiento y de la ciudad de validación.....	47
Tabla 3 Resumen de la tabla de confusión para Salamanca.....	54

Índice de ilustraciones

Ilustración 1 Ciudad amurallada de Kowloon. Imagen obtenida de https://es.wikipedia.org/wiki/Ciudad_amurallada_de_Kowloon	2
Ilustración 2 Rocinha, la mayor favela de Rio de Janeiro (Brasil). Imagen extraída de https://es.wikipedia.org/wiki/Rocinha	3
Ilustración 3 Imagen aérea del casco histórico de la ciudad de Valencia. Imagen obtenida del PNOA.....	4
Ilustración 4 Características avenidas radiales del ensanche de Paris. Imagen obtenida de http://blogdegeografiadejuan.blogspot.com/2013/02/comentar-el-plano-de-paris.html	5
Ilustración 5 Ciudad de Brasilia. Imagen obtenida de https://www.milenio.com/internacional/brasilia-capital-brasil-emergio-60-anos	6
Ilustración 6 Ejemplo de un caso extremo de barrio privado en Buenos Aires, Brasil, donde para moverse a parcelas cercanas es necesario el uso de vehículo o lancha. La distancia estimada andando es de 20 minutos. Imagen obtenida de Google Maps de elaboración propia.	6
Ilustración 7: Atomístico en rojo, frente a Informal en morado	13
Ilustración 8 Urban atlas de 2018 para el centro de Barcelona. Se aprecia que no hay distinción entre la trama urbana formal de la atomística.	17
Ilustración 9 Representación visual del tipo de dato con el que trabajan en el estudio de conectividad (Boeing, Street Network Models and Indicators for Every Urban Area in the World, 2021).....	18
Ilustración 10 Resumen de la metodología del proyecto	22
Ilustración 11 Descarga de productos del PNOA.....	24
Ilustración 12 Tabla de Manzanas de la ciudad de Alicante con los valores de TIPO ...	25
Ilustración 13 Leyenda aplicada a la capa de tipologías de asentamiento	26
Ilustración 14 Vista de las parcelas sin una tipología asignada aparecen sin relleno y borde rojo.	26
Ilustración 15 Selección de las parcelas que se van a etiquetar.	27
Ilustración 16 Herramienta de Calculadora de campos con el campo seleccionado a modificar, el valor y indicando que se van a modificar las entidades seleccionadas...	27

Ilustración 17 Herramienta de gvSIG Desktop realizando proceso de etiquetado.	28
Ilustración 18 Herramienta de etiquetado en gvSIG Desktop	28
Ilustración 19 Etiquetado de zona como formal.....	29
Ilustración 20 Ejemplo de un trozo de la capa de parcelas etiquetadas con su simbología.....	30
Ilustración 21 Ejemplo de tipología industrial.....	30
Ilustración 22 Ejemplo de tipología atomística	31
Ilustración 23 Ejemplo de muestras formales	31
Ilustración 24 Añadir capa de tipo WMS.....	33
Ilustración 25 Ejemplo de muestreado	34
Ilustración 26 Representación gráfica de la red utilizada.	41
Ilustración 27 Gráfico del entrenamiento del modelo SGD.	44
Ilustración 28 Matriz de confusión del modelo SGD.....	45
Ilustración 29 Salida del entrenamiento del modelo ADAM en los epochs finales.....	45
Ilustración 30 Gráfico de entrenamiento del modelo ADAM	46
Ilustración 31 Matriz de confusión del modelo ADAM para los datos de validación....	46
Ilustración 32 Matriz de confusión de Salamanca con el modelo ADAM	47
Ilustración 33 Mapa de Salamanca etiquetado.....	48
Ilustración 34 Mapa de Salamanca predicho.....	48
Ilustración 35 Imagen PNOA de la ciudad de Salamanca.....	49
Ilustración 36 Valencia con todas sus parcelas con valores predichos por el modelo	50
Ilustración 37 Detalle de la zona centro de Valencia predicha por el modelo	50
Ilustración 38 Detalle de la zona de Torrent que formaba parte del entrenamiento en Valencia	51
Ilustración 39 Detalle de la misma zona de la población de Torrent que la ilustración anterior predicha por el modelo.....	51
Ilustración 40 Imagen aérea de la zona de Torrent.....	52
Ilustración 41 Ejemplo de una ciudad con una supuesta metodología por rejilla sobre Valencia.	60

1. Introducción

1.1 Motivación

El estudio de las ciudades y su crecimiento es uno de los mayores retos que afronta el urbanismo y la arquitectura moderna. La tendencia al alza de movimientos poblacionales del entorno rural al urbano está provocando crecimientos descontrolados (Taubenböck, y otros, 2012) en las ciudades haciendo que estas cada vez estén peor preparadas para cumplir con su función de ciudad. Muchas de estas ciudades no cuentan con un plan urbanístico, no tienen la capacidad suficiente, no se desarrollan a la velocidad suficiente o se desarrollan de una manera insostenible creciendo en extensión, pero no en densidad.

Hay ejemplos de desplazamientos masivos en, por ejemplo, ciudades de Arabia Saudí donde en los últimos 10 años se han creado numerosas ciudades desde cero y que ya acumulan millones de personas. Otras ciudades como Tokio tienen una población en su área metropolitana de 36 millones de personas, lo que provoca una serie de retos de gestión para los que el urbanismo moderno parece no estar a la altura (Auerbach, 2019).

La distribución de la gente en una ciudad implica toda una serie de recursos que hay que dedicar para que la ciudad se pueda mantener. Es necesario realizar infraestructuras de transporte, electricidad o agua, por ejemplo, además de otros factores, como asegurar que los ciudadanos tengan acceso a sanidad, trabajo u otros recursos necesarios como tiendas de productos o alimentación. Cuando no se cumple el óptimo desarrollo en los asentamientos de la ciudad, la calidad del ciudadano disminuye y afecta directamente a la economía de la ciudad, de las personas e incluso de las ciudades de alrededor. Procurar que las ciudades crezcan de manera óptima ayudará directamente a que mejore la calidad de vida y se produzca un crecimiento poblacional sostenible en el tiempo.

Problemas asociados a la trama urbana

El estudio de los barrios marginales o slums es de gran importancia en el entorno urbano. Suelen ser barrios donde hay una desigualdad de riqueza importante que solo hace que la situación empeore. Así que su pronta detección y la aclimatación de zonas para evitar el crecimiento de barrios sin organización, podría suponer una mejora importante a largo plazo de la calidad de vida en estos suburbios.

Existen casos en España conflictivos como la Cañada del Real en Madrid o otros casos característicos a nivel mundial. Uno de estos casos es la ciudad amurallada de Kowloon, Ilustración 1, una ciudad sin ley que tuvo un crecimiento descontrolado. Tuvo que acabar siendo desalojada por las autoridades chinas.



Ilustración 1 Ciudad amurallada de Kowloon. Imagen obtenida de https://es.wikipedia.org/wiki/Ciudad_amurallada_de_Kowloon

Una zona muy famosa de crecimiento atomístico son los barrios marginales de las ciudades brasileñas o favelas. Estas favelas, Ilustración 2, son un ejemplo perfecto de lo que sería un crecimiento atomístico. Son zonas con un crecimiento descontrolado que ha causado, en el caso de las favelas, con un problema de seguridad importante. Por ejemplo, dada su trama de calles con callejones sin salida y calles estrechas facilitan que bandas y clanes vigilen y controlen los accesos de una forma sencilla con pocos recursos. Esto hace que servicios como la Policía no tengan acceso a estos barrios y se produzcan situaciones donde sea requerido el ejército para ello.

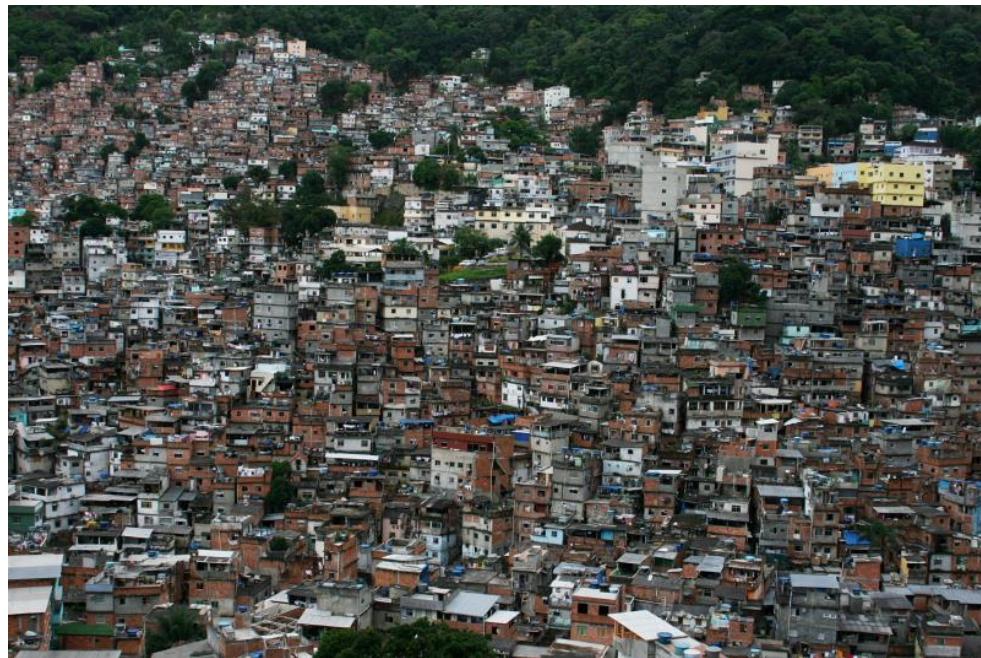


Ilustración 2 Rocinha, la mayor favela de Rio de Janeiro (Brasil). Imagen extraída de <https://es.wikipedia.org/wiki/Rocinha>

Los problemas se extienden más allá a la seguridad, ya que el acceso a estas zonas de servicios de salud como ambulancias en caso de emergencia médica o servicios de bombero en caso de incendios, hacen que sea una zona potencialmente precaria a cualquier situación. En caso de catástrofes naturales como riadas, corrimientos de tierra o terremotos, hace que estas zonas sean especialmente vulnerables. La falta de planificación o de control hace que se construyan viviendas en zonas sin estudios geológicos, sin controles de normativas de construcción o sin ser incluidas en planes de emergencia en caso de catástrofes.

La estructura de las ciudades suelen ser características de la zona. Por ejemplo, en las ciudades europeas, es característico que en el centro de la ciudad se sitúe un barrio de tipo atomístico que corresponde al centro de las ciudades históricas sobre las que han crecido las actuales y que siguen la trama urbana de calles similar a su época de crecimiento cuando aún existían las murallas de defensa. Suelen ser características ya que estas zonas suelen estar delimitadas por una calle que las rodea que correspondía al trazado de la muralla que ha sido demolida en siglos posteriores e incorporado su recorrido a la trama urbana. Por ejemplo, este es el caso de la ciudad de Valencia, Ilustración 3. En estos casos una trama urbana de tipo atomístico no está relacionada directamente con barrios marginales, pero sí que acarrean otros tipos de problemas como por ejemplo de acceso a buenos servicios de transporte. Las calles estrechas pueden llegar a dificultar el acceso de vehículos o maquinaria pesada en casos de emergencia. También suelen ser zonas con una baja cantidad de parques o

vegetación. Esto puede acarrear problemas como la zona centro de Madrid, zonas de alta congregación de personas ya sea por motivos de ocio o trabajo, que producen aumentos considerables en los niveles de polución de la zona. Una zona de características atomísticas solo hace que se agraven estos problemas.



Ilustración 3 Imagen aérea del casco histórico de la ciudad de Valencia. Imagen obtenida del PNOA.

La gestión del tramoado urbano ya ha tenido su aparición en la historia. La ciudad de París, Ilustración 4, es un ejemplo de la urbe moderna por este motivo. Durante la época de Napoleón se realizó el famoso ensanche de la ciudad realizado por Georges-Eugène Haussmann que otorgó de unas características grandes avenidas de tipo radial que permitirían el desplazamiento de tropas y ejércitos. Además, la eliminación de calles estrechas y sin salida o *cul de sacs* evitaría la creación de barricadas. Esto facilitaría, en última instancia, un mejor control de la población. Por lo que mantener una urbe con un tramoado apropiado puede llegar incluso más allá de pensar en la calidad de personas, lo que no hace más que destacar la importancia del estudio del tramoado urbano.



Ilustración 4 Características avenidas radiales del ensanche de París. Imagen obtenida de <http://blogdegeografiadejuan.blogspot.com/2013/02/comentar-el-plano-de-paris.html>

La problemática no está exclusivamente en barrios con características atomísticas. A veces, un exceso de zonas verdes o amplias carreteras también pueden ser un grave problema. Este es el caso de la capital de Brasil, Brasilia, Ilustración 5, diseñada por el urbanista Lucio Costa en 1957. Estos pilares sobre los que fue diseñada, en principio, suelen ser lo que buscan mejorar las ciudades modernas. El problema ocurre cuando son llevados al extremo. Una ciudad de estas características produce zonas de muy baja densidad poblacional con una gran separación entre ellas. Las distancias tan largas no permitían que los desplazamientos a pie fueran factibles. Produjo problemas de transporte haciendo necesario un vehículo propio para realizar tareas cotidianas como hacer la compra o ir a trabajar. Las grandes distancias y la cantidad de barrios aislados hacen que incluso el diseño de un sistema efectivo de transporte público sea complicado. La necesidad de carreteras de alta velocidad dentro de la trama urbana hacía que estos barrios aislados estuvieran rodeados de autopistas de gran velocidad que aumentaban el ruido, la contaminación y el aislamiento. En este caso, la baja densidad de población en proporción con los espacios verdes y carreteras no permitía una correcta evolución de la trama urbana. La separación de los diferentes barrios aumentó la diferencia social de clases.



Ilustración 5 Ciudad de Brasilia. Imagen obtenida de <https://www.milenio.com/internacional/brasilia-capital-brasil-emergio-60-anos>

Otro ejemplo de problemas con el tramoado urbano es el de los *cul de sac*. Un *cul de sac* es una calle que no tiene salida, se pueden ver ejemplos claros en la Ilustración 6. Como ya se ha comentado, estas calles sin salida en la ciudad de Paris creaban problemas de seguridad. Hoy en día, estos problemas de seguridad en el centro de las urbes han perdido importancia con excepciones como las favelas. En cambio, una de las preocupaciones actuales, es que producen grandes distancias de desplazamiento. Realizar desplazamientos entre dos parcelas adyacentes pueden suponer hacer recorridos muy grandes y, en último momento, aumenta la dependencia de vehículos.



Ilustración 6 Ejemplo de un caso extremo de barrio privado en Buenos Aires, Brasil, donde para moverse a parcelas cercanas es necesario el uso de vehículo o lancha. La distancia estimada andando es de 20 minutos. Imagen obtenida de Google Maps de elaboración propia.

Estos tipos de entramado como las urbanizaciones también acarrean una serie de problemas a nivel de gestión nacional. Mantener una mayor cantidad de carreteras aumenta, preparar un transporte adecuado, un acceso a servicios de salud o alimentación, produce que aumente considerablemente el coste de servicios por habitante, lo que, en último lugar, produce un empobrecimiento de estos servicios y un empeoramiento de la calidad de vida. Además, suelen estar ligadas a zonas de un alto coste económico, por lo que aumenta la separación de clases, remarcando y acrecentando la desigualdad económica y social.

1.2 Planteamiento del trabajo

Realizar un estudio global sobre el estado actual de las ciudades pondría en perspectiva el crecimiento que han tenido en los últimos años y el tipo de crecimiento que han tenido. Permitiría comprobar el tipo de expansión que se está produciendo en ellas y permitiría analizar a futuro la efectividad de diferentes medidas sociales o legislativas.

Además, se podrían localizar futuros problemas urbanísticos con antelación comparando el estado de la ciudad con las previsiones que se tienen sobre crecimiento poblacional. Esto permitiría a los urbanistas estar preparados para realizar correcciones en los planes urbanísticos en caso de ser necesarios o aumentar los servicios dedicados a unas zonas concretas. Se podrían detectar zonas con carencias de servicios como barrios marginales.

También, realizar un estudio continuado de las ciudades, permitiría ver la evolución de las medidas adoptados por los diferentes gobiernos a nivel urbanístico. Por lo que el interés no queda limitado a un estudio del estado actual de las ciudades, sino de su evolución en el tiempo.

Este dato de la tipología de asentamiento es un dato que no se está teniendo en cuenta en muchos estudios. El cruce de datos de su tipo de asentamiento con otros tipos de datos económicos, demográficos o ambientales podrían dar lugar a métricas más específicas a nivel urbanístico, que permitiesen tomar decisiones personalizadas por tipos de zonas en una misma ciudad. Las necesidades de una zona de tipo atomística pueden ser muy diferentes de otras con características más formales o de tipo industrial. El desarrollo de una ciudad puede ser muy diferente a otra. El desarrollo de diferentes zonas dentro de una misma ciudad pueden tener diferentes estructuras.

Se busca crear una metodología que pueda usarse a nivel global y, de forma automatizada, que permita la identificación del tramo urbano en las ciudades basada en las categorías establecidas en el estudio del Atlas de Expansión Urbana. Esta metodología tiene la

particularidad de tener unos requisitos bajos para su preparación. Debe de permitir usarse sobre imágenes color que puedan ser obtenidas tanto desde satélites, desde drones o aviones. Para ello se limitará el uso de imágenes en sus bandas de color (RGB). Aparte de la imagen, solo será necesario crear una capa vectorial delimitando los datos de entrenamiento de los modelos por tipologías o utilizar una proveniente de servicios públicos o estatales, en este caso CartoCiudad o el Castrato, como se explicará más adelante.

En este proyecto se va a utilizar el término general de “imágenes” para referirse a las múltiples opciones de fotografías aéreas que se pueden obtener hoy en día, desde drones, aviones o satelitales.

Para ello se va a desarrollar una prueba piloto utilizando diversas ciudades españolas. Sin embargo, siguiendo la misma metodología, se podría aplicar sobre otras ciudades directamente con los modelos obtenidos o facilitando el entrenamiento de nuevos modelos.

Uno de los principales problemas del estudio del Atlas de Expansión Urbana es que su principal fuente de datos se realizaba de manera manual mediante un gran número de digitalizadores que se encargaban de extraer información de las ciudades, entre ellas, la digitalización y la tipología de los asentamientos urbanos.

Esta extracción de la información tomaba con diferencia la mayor partida económica del proyecto dada su complejidad para gestionar y procesar los datos, así como su lentitud para obtenerlos. Además, dada la envergadura de las ciudades estudiadas, era imposible obtener los datos completos de una ciudad, por lo que se recurrió a una extracción de muestras de círculos alrededor de la malla urbana siguiendo una distribución aleatoria de círculos muestrales de un tamaño fijo.

Los problemas que esto produce son múltiples. Por una parte, la posibilidad de que un digitalizador se pueda equivocar en los datos que extrae. El digitalizador no tiene ayuda extra aparte de la imagen satélite que obtiene con la resolución que le da el proveedor de imágenes. Dado que es un estudio a escala mundial, no es posible desarrollar herramientas adicionales como consultas en el catastro u otros servicios, ya que deberían de ser especiales para cada país, además de los costes extras que conllevaría, no todos los países sobre los que se realiza el estudio disponen de forma abierta de estos datos. De esta forma, se asume que hay un rango de error para etiquetados incorrectos.

Por otra parte, el estudio está realizado sobre una extracción muestral. Eso implica que, para ciudades grandes como París, Nueva York o Tokio, la proporción de datos extraídos no llegase a una proporción significante de la ciudad. Para repetir el estudio se debería de volver a

realizar la toma de muestras de forma manual ciudad a ciudad, época a época. Dada la aleatoriedad en la selección de muestras, cabe la posibilidad de que algunas tipologías de asentamientos aparezcan sobrerepresentadas o infrarepresentadas del total.

Por lo tanto, se pretende buscar una forma de automatizar la captura de datos y clasificación mediante un algoritmo de Inteligencia Artificial que permita el procesamiento de las ciudades con un menor coste. En este estudio, aunque el algoritmo pudiera cometer errores, el obtener una digitalización de toda una ciudad en diferentes épocas ya sería un gran avance respecto al estudio muestral de estas, que al ser muestras aleatorias, implican también un error considerable al poder extraer conclusiones de ellas ya que el tramo urbano no suele estar distribuido de manera homogénea en una ciudad

Existen algunos estudios para automatizar procesos como la obtención de la malla urbana (parcelas) basados en la definición que contiene el Atlas de Expansión Urbana, pero se desconocen estudios para automatizar la obtención de las tipologías de asentamientos.

La idea de realizar un proceso automatizado para el estudio de las ciudades permitiría tener un mayor conocimiento del estudio de ciudades de todo el mundo. Permitiría realizar estudios en diferentes épocas históricas gracias a imágenes satélite de décadas anteriores y permitiendo que se pudieran repetir a futuro con nuevas imágenes.

Se pretende obtener una capa vectorial de lo que sería el análisis de una ciudad dadas sus parcelas clasificadas. También, una vez caracterizadas más ciudades de un propio país o continente, permitiría la comparación agrupada entre ellas que podría sacar a relucir problemas urbanísticos a niveles de zonas, nación o de continentes. Además, permitiría una rápida comparación de la evolución que han tenido, realizando el estudio sobre una misma zona, pero con imágenes aéreas de diferentes épocas. Permitiría ver el crecimiento o el cambio de tipologías en la trama urbana dentro de una ciudad.

La realización de este tipo de estudios cobra una gran relevancia dado la situación global en la que nos encontramos. Ya no solo el clásico movimiento de entornos rurales a entornos urbanos o el crecimiento natural de la población, sino que cualquier noticia puede tener un impacto global, ya sea por situaciones de desigualdad de derechos, desigualdad económica, trabajo, climáticas, militares, entre otras, que pueden implicar movimientos masivos de poblaciones entre diferentes ciudades, naciones o continentes en cortos períodos de tiempo.

Las ciudades se están convirtiendo en aglomeraciones de personas masivas con un gran coste de personal y económico para mantenerlas en funcionamiento. Estos estudios pueden ayudar a prever necesidades urbanísticas y adelantarse a lo que podrían ser el colapso de

ciudades. Una ciudad que no puede proveer de servicios mínimos de transporte, seguridad o habitabilidad no se puede desarrollar con éxito y puede provocar puntos de no retorno donde una ciudad puede no ser factible de mantener para un estado, con una menor entrada de dinero y un mayor coste económico de mantenimiento dada su superficie, servicios, etc. Esto ya ha ocurrido en ciudades como Brasilia que por su tipología de urbanismo durante su diseño han tenido graves problemas durante su crecimiento.

1.3 Estructura de la memoria

La estructura de la memoria va a ser una estructura típica de un proyecto piloto. A continuación, se explica que contiene cada apartado.

El apartado 1 consta de una introducción del proyecto y su justificación, explicando todos los problemas urbanísticos y que este tipo de estudios de clasificaciones por tipología urbanística pretende solucionar.

En el apartado 2 se va a explicar el estado del arte en la materia donde se van a ir exponiendo los pros y contras de las metodologías y procesos existentes, lo que va a ir conduciendo a una solución justificada para la realización de este proyecto.

En el apartado 3 se van a indicar los objetivos principales y específicos del proyecto que se han considerado necesarios para cumplir las hipótesis que podrían hacer de esta metodología candidata para un estudio global.

En el apartado 4 se explicará la metodología elegida y los pasos realizados con detalle. Se detallará el motivo de cada paso y el proceso que conlleva completarlos. Se explicará con detalle la solución de red convolucional y lo necesario para utilizarla.

En el apartado 5 se realizará un análisis de los datos obtenidos, analizando la precisión del modelo sobre los datos de las ciudades de entrenamiento y sobre la ciudad de validación. Se hará uso del modelo para etiquetar al completo una ciudad que forma parte de los datos de entrenamiento (Valencia) y otra desconocida por el modelo (Salamanca).

En el apartado 6 se expondrá una discusión de los resultados obtenidos para probar si se ha obtenido lo esperado y si se cumplen las hipótesis que esperábamos sobre el proyecto.

En última instancia, en el apartado 7, se aportarán las conclusiones del proyecto y nuevas líneas posibles de investigación que pueden tomar este como punto de inicio.

En el anexo, aparece el proyecto en formato de artículo científico.

2. Contexto y estado del arte

El crecimiento descontrolado de las ciudades y sus previsiones a futuro ha provocado que se quiera conocer el estado actual de las ciudades, su ritmo de crecimiento y tipo de evolución. Para ello se ha visto la necesidad de crear nuevas metodologías de trabajo, que permitan conocer la evolución que han tenido y se puedan replicar en el futuro para su monitoreo. De esta forma se puede comprobar si ciertas ciudades están mejor adaptadas a este crecimiento previsto que otras.

Uno de los estudios de mayor envergadura de los últimos años ha sido el del Atlas de Expansión Urbana realizado por UN-HABITAT (Programa de Naciones Unidas para Asentamientos Humanos) enmarcado en los estudios presentados en la conferencia HABITAT III (University., 2018). Este estudio impulsado por Joan Clos, ex ministro de Industria, Comercio y Turismo de España y director de UN-HABITAT, tenía el objetivo realizar un estudio de ámbito global sobre el estado 200 ciudades repartidas por todo el globo sobre un periodo de 25 años donde se mezclase información espacial sobre características urbanas con características económicas de la ciudad.

Para el proyecto fue necesaria el desarrollo de una nueva metodología planteada desde cero para poder abordar un proyecto a esta escala en un tiempo y con unos resultados adecuados.

Las métricas que se estudiaron por el proyecto fueron múltiples, entre ellas la calidad del tramo urbano, la proporción entre el espacio dedicado a calle y construcciones, la localización de intersecciones de 4 ejes, etc.

Uno de los mayores problemas para el estudio era la obtención de las tipologías de asentamiento dentro de las ciudades. Estos datos permiten estudiar el tipo de expansión urbanística y son difíciles de obtener. Existe una carencia total de este tipo de datos y, además, existe una falta de datos vectoriales sobre las ciudades a nivel global para todas las ciudades sobre las que se realiza el estudio.

Se pueden encontrar ciudades de Europa o América del Norte digitalizadas al completo en bases de datos abiertas geográficas como OpenStreetMaps o en portales Open-data de los propios gobiernos. Sin embargo, la capacidad de producción de estos datos está muy relacionada con el nivel de desarrollo, cantidad de población y riqueza en esas zonas. Incluso

dentro de zonas con estas características, puede existir ciudades con carencias de datos al estar más aisladas o con una desactualización importante en los datos. Al querer ser un estudio de ámbito global, existían gran cantidad de problemas para encontrar datos existentes, de fuentes oficiales o no, en ciudades de África o Indonesia.

Además de todo esto, para que el estudio fuera compatible entre todas las ciudades, los criterios de digitalización en los datos obtenidos debían de ser los mismos y adaptados al estudio.

Esta conjunción de problemas hacía que para el Atlas de Expansión Urbana se optara por una digitalización manual de la base de datos vectoriales para el cálculo de métricas. Por la variabilidad en el tamaño de las ciudades del estudio, se realizaba la toma de muestras siguiendo una distribución Halton que corresponde a una distribución semialeatoria sobre el terreno. Esta obtención de muestras se hacía de forma independiente para el área de diferentes épocas de crecimiento de la ciudad aproximadas a los años, 1986, 2000 y 2010, por lo que cada ciudad debía de ser muestreada en tres ocasiones (Angel, Parent, Civco, & Blei, 2016). Esto quiere decir, que las métricas que controlaban que el muestreado se daba por concluido para detener el proceso de muestreo se debía de cumplir tres veces, por lo que el aumento de la carga de trabajo para los investigadores era mayor.

Sobre estas muestras que se obtenían, se clasificaban las parcelas en diferentes tipologías. (Angel, Lamson-Hall, Madrid, M. Blei., & Parent W, 2016). Las tipologías de asentamientos urbanos son las siguientes:

- Industrial: Hace referencia principalmente a una zona industrial de la ciudad, con o sin planificación urbana. De especial interés para determinar el crecimiento y función de una ciudad. También se incluyen edificios no destinados al uso residencial como pueden ser hospitales, centros comerciales, estaciones de tren, etc.
- Atomístico: Asentamiento que no tienen ninguna planificación. Caracterizado por ser zonas sin un planeamiento urbano. Se asimila a la forma de los centros históricos de las ciudades europeas con calles estrechas, intersecciones de tres ejes y forma de las calles irregulares no paralelas con "culs de sac".
- Formal: Asentamientos con planificación y servicios. Caracterizado por una trama urbana con patrones rectangulares, calles anchas e intersecciones de 4 ejes. La calle dispone de equipamiento público tales como aceras, asfalto, iluminación, etc.
- Informal: Asentamientos con planificación, pero sin estar completos. Con las mismas características generales de la trama urbana formal, pero sin equipamientos. Por ejemplo, barrios con las parcelas cuadradas marcadas, pero sin infraestructuras como carretas asfaltadas.

- Proyectos urbanísticos: Asentamientos planificados caracterizados por producir una serie de patrones repetitivos. Normalmente situados a las afueras de las ciudades, grandes zonas construidas la misma vez y una gran proporción de espacio verde respecto al espacio construido. Por ejemplo, urbanizaciones situadas a las afueras de ciudades importantes unifamiliares con jardín.
- Espacio abierto: Zonas sin construcciones, parques, parcelas delimitadas pero no ocupadas, campos de cultivo, etc.

Las muestras denominadas “puras”, zonas donde solo aparece un tipo de asentamiento, son muestras donde se ven muy claramente la tipología de asentamiento. Sin embargo, la realidad suele ser muy diferente ya que no siempre aparecen por separado estas muestras y, más importante, no suelen ser tan claras. En muchos casos la línea que separan una tipología de la otra no está tan claramente definida como se puede observar en la Ilustración 7. Según la zona estudiada la definición de las tipologías se debe de interpretar y adecuar a la zona de estudio. Utilizar esta categoría planteada durante el Atlas de Expansión Urbana, con toda seguridad, va a ser un problema a la hora de entrenar un modelo ya que hasta para los digitalizadores formados esto era un problema y una fuente constante de preguntas.



Ilustración 7: Atomístico en rojo, frente a Informal en morado

Este estudio no busca sustituir al completo el realizado por el Atlas de Expansión Urbana, sino que se centra en dar una alternativa a la parte de clasificación por tipologías de asentamiento.

El objetivo de este tipo de estudios busca determinar cómo se está produciendo el crecimiento de las ciudades (Angel, Lamson-Hall, Blei, Shingade, & Kumar, 2021). Existe un consenso a nivel global de que las ciudades deben aumentar en densidad de población y no en tamaño. Este tipo de crecimiento favorece desde la disminución de emisiones a la mejora de servicios.

El estudio de la morfología de una ciudad según los patrones de sus calles son una aproximación seguida por muchos dada la importancia en el impacto que tiene la trama urbana con el bienestar de la ciudad. Las nuevas técnicas de procesamiento y utilización de datos masivos facilitan el acceso a datos para intentar comprender mejor las características propias de las diferentes ciudades (Boeing, Spatial information and the legibility of urban form: Big data in urban morphology, 2021).

Existen estudios sobre el estudio de la calidad de vida según los patrones urbanos (Sapena, Marta, Wurm, Michael, Taubenböck, Hannes, Tuia, Devis, & Ruiz, Luis A., 2021) que se basan en técnicas de clasificación mediante una conjunción de datos vectoriales, imágenes satelitales o datos LIDAR (Sapena, Marta & Ruiz, Luis A., Identifying urban growth patterns through land-use/land-cover spatio-temporal metrics: Simulation and analysis, 2021). Estos estudios se pueden realizar en países desarrollados y con políticas de datos abiertos. En cambio, para abordarlo de una forma global es necesario asumir que no se va a tener acceso de una forma precisa a la misma cantidad de datos, por lo que hay que basar el estudio en un recurso que sea igual y fácilmente obtenible a nivel mundial, en este caso, imágenes aéreas. Con un procesamiento mayor y limitándose a datos de imágenes satelitales (Schlosser, y otros, 2020) donde se calculan las elevaciones a partir de procesos fotogramétricos, ya se intenta restringir esta entrada de datos exclusivamente a imágenes satelitales queriendo demostrar que son más que suficientes para la extracción de edificios. En este proyecto se busca restringir incluso más este procesado, ya que se busca realizar la clasificación sin el procesamiento del modelo de elevaciones a partir de imágenes satelitales que requieren de un conocimiento técnico y herramientas más especializadas.

Se acabará asumiendo también esta carencia de necesitar datos de las geometrías de las parcelas y se utilizarán datos vectoriales obtenidos del Catastro y de CartoCiudad aunque una de las propuestas para su estudio será realizar la clasificación directamente sobre rejillas.

Además, ninguno de estos estudios encontrados que hacen uso de técnicas automáticas de clasificación intenta realizar una localización de las zonas denominadas atomísticas (zonas sin planeamiento urbano) que incluyen desde cascos históricos o barrios marginales (slums). En este tipo de clasificaciones suelen limitarse a clasificar la categoría como edificaciones y no entran en más profundidad (Zhang, Chi, Wei, Shiqing, Ji, Shunping, & Lu, Meng, 2019).

Muchas de estas clasificaciones urbanas se basan en clasificar pixel a pixel (Szabó, Zsuzsanna Csatáriné, y otros, 2020) las imágenes según sus características, pero pocas veces en el reconocimiento de qué contiene realmente la imagen.

Hay otros estudios (Kadhim, Mohammed Abbas & Abed, Mohammed Hamzah, 2020) que utilizan una aproximación más similar a la utilizada, pero se centran en la identificación de objetos concretos como son rotondas, intersecciones o edificios. También incluye clasificaciones por tipo de terreno, pero ninguno orientado a una clasificación por tipología urbanística ni su aplicación general a un estudio global.

La extracción de algunas características del terreno ya es algo común en el campo geoespacial (Jianpeng Xu,Wu Xiao, Tingting He,Xinyu Deng, & Wenqi Chen, 2020) y se utilizan para la extracción de edificios y su clasificación utilizando imágenes satelitales multisensores. En cambio, estas clasificaciones suelen realizarse mediante cálculos matemáticos según las respuestas espectrales de los objetos en diferentes bandas. Se aprovecha de las capacidades de muchos satélites para la captura en múltiples rangos como infrarrojos o ultravioletas. Son muy utilizados el cálculo de índices como el NDVI (Normalized Differenced Vegetation Index), entre otros, para la separación de zonas construidas a terrenos de cultivo (K. Rouibah & M. Belabbas, 2020). También existen problemáticas a la hora de la clasificación, ya que muchas de estas clasificaciones no son absolutas sino multiclas (Sumbul & Demır, 2020). Para ello se están utilizando aproximaciones usando métodos de inteligencia artificial como con las redes convolucionales. Como ocurre en este estudio a la hora de las tipologías de asentamiento, suelen ser muchas veces una mezcla de diferentes tipos de asentamientos en la zona designada.

La identificación de zonas urbanas usando redes convoluciones parece que ya es un hecho que investigadores están utilizando como base de sus estudios. Las redes neuronales ya se están utilizando en el campo de la Teledetección para diferentes tareas automáticas y de preprocesado de imágenes como las de limpieza de nubes en imágenes satelitales (Meraner, Ebel, Schmitt, & Xiao Xiang, Zhu, 2020). Además, estas redes han probado su funcionalidad para la detección de edificaciones a partir de imágenes satelitales (Xueyi Wang, Tianqi Xie, & Longbiao Chen, 2019) . En conjugación con redes más específicas como las de Mask R-CNN utilizadas para una segmentación de la región más detallada sobre una imagen (Kaiming He, Georgia Gkioxari, Piotr Dollár, & Ross Girshick, 2020) y no solo su clasificación de la imagen como un todo, son capaz de localizar con mayor exactitud que píxeles de las imágenes corresponden a edificaciones y cuáles no. Esto permite ya no solo localizar edificaciones, sino, de una forma sencilla, acotar mediante polígonos concretos el edificio construido u otro tipo de clasificaciones sobre imágenes satelitales según el modelo entrenado (Weixing Zhang, y

otros, 2020) por lo que se postulan como una herramienta de gran potencial en el campo de la Teledetección.

BigEarthNet es un archivo que se ha desarrollado recopilando un mosaico de imágenes satelitales con los satélites Sentinel 1 y Sentinel 2 que se extiende a todo el territorio europeo. Esta base de datos incluye varios modelos ya entrenados que se pueden utilizar para la detección de diferentes tipologías de terrenos, edificaciones, objetos, etc (Sumbul, Gencer , Charfuelan, Marcela, Demir, Begüm, & Markl, Volker, 2019). Este archivo está siendo utilizado en muchos estudios como base para imágenes satelitales. Sin embargo, para este proyecto, la calidad de la imagen de los satélites Sentinel con unos píxeles de 10 metros de resolución, no ha parecido suficiente para su uso. La calidad de imagen para los núcleos urbanos no permitía identificar correctamente la clasificación. Para zonas con tipologías formales con calles más anchas y parcelas grandes habría podido servir, pero, para las zonas más atomísticas con calles muy estrechas no se podrían ni diferenciar las calles ni detectar si alrededor de las parcelas las calles tienen equipamiento, como asfalto o iluminación, en algunas zonas lo hacían imposible. Este tipo de imágenes sí que son utilizadas para la extracción de edificios o zonas urbanas (Vigneshwaran, S & Vasantha Kumar, S, 2018), pero no se ha considerado suficiente para categorizar su entramado urbano.

De la misma forma, se ha estudiado la utilización de la herramienta de Google Earth Engine (Gorelick, y otros, 2017) para el procesamiento de las imágenes y la extracción de muestras. Esta herramienta permite mediante pocas líneas de código el procesamiento y acceso a multitud de servicios de imágenes satelitales y realizar de forma automática tareas de corrección o filtrado. Sin embargo, en esta plataforma, el acceso a imágenes de gran resolución no está disponible al tener acceso restringido o de pago. Pero dado su potencial se postula como una herramienta prometedora para el procesamiento de muestras satelitales para modelos de inteligencia artificial.

En el caso de Urban atlas (Copernicus Programme, 2021) están centrados en el uso concreto de las parcelas, Ilustración 8. Esta capa es el resultado más similar a lo que se busca obtener en este proyecto en un resultado final. Sin embargo, es un resultado que no se ajusta a lo que se busca en el proyecto ya que no guarda relación con el tipo de entramado urbano, sino con el uso de la parcela. Sin duda, es un dato muy interesante para utilizar en los análisis pudiendo cruzar los resultados del uso de la parcela con el de la tipología de la parcela.

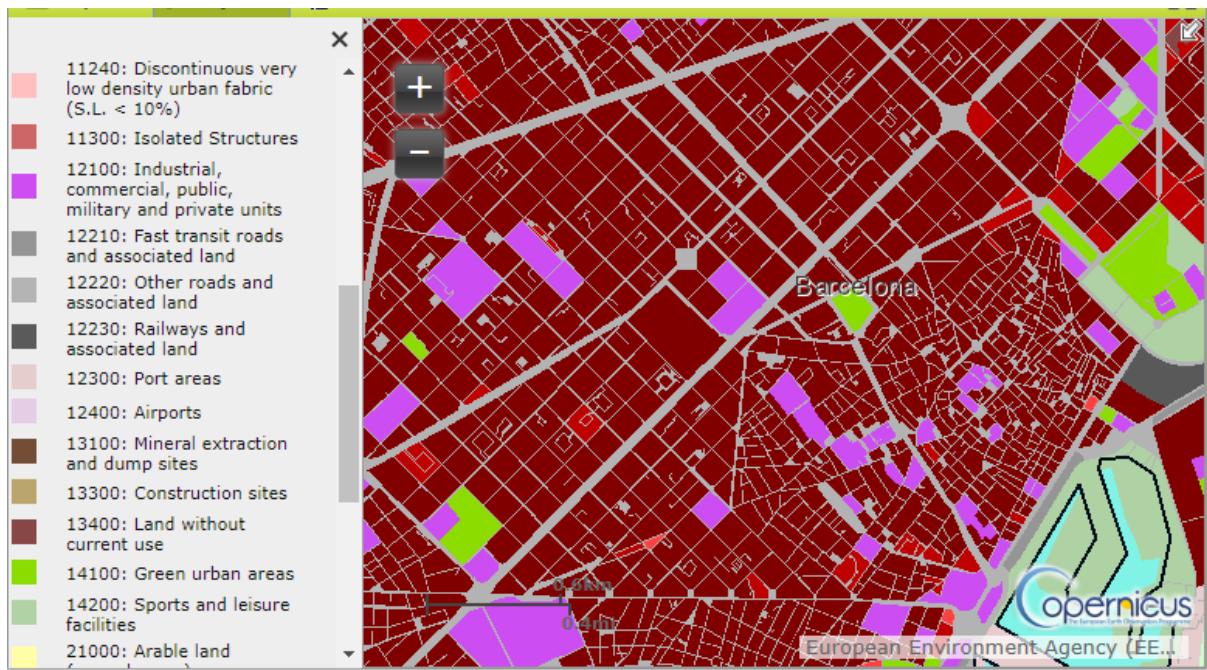


Ilustración 8 *Urban atlas de 2018 para el centro de Barcelona*. Se aprecia que no hay distinción entre la trama urbana formal de la atomística.

Existen estudios que están intentando realizar tareas similares de etiquetados por tipologías, en este caso asociados a los patrones de las calles (Boeing, Street Network Models and Indicators for Every Urban Area in the World, 2021), Ilustración 9. Se utilizan bases de datos abiertas como sobre OpenStreetMap para la obtención de las calles. Se utilizan unas ideas similares en cuanto al aprovechamiento de datos y fuentes abiertas. En este caso es un estudio puramente estadístico donde no es necesaria una aplicación de técnicas de inteligencia artificial. La conjunción de este tipo de estudio con el que se propone en este proyecto podría ser de mucho interés, ya que algunas de las características importantes de los diferentes tipos de asentamientos son calculadas en este estudio. Por ejemplo, las clasificaciones de tipo Formal se caracterizan por intersecciones de 4 ejes o más, longitudes de calles de tamaño medio o bajo y polígonos rectangulares, indicativo de calles paralelas. La tipología atomística se caracteriza por nodos con cruces de 3 ejes. Las de tipo Industrial por ejes de un mayor tamaño a la media.



Ilustración 9 Representación visual del tipo de dato con el que trabajan en el estudio de conectividad (Boeing, Street Network Models and Indicators for Every Urban Area in the World, 2021)

En última instancia, el proyecto también busca localizar las posibles carencias que se encuentran en las ciudades como son la falta de espacios abiertos y vegetación en las ciudades. Además, se ha probado que la vegetación se tiene que estudiar también con el punto de vista del ciudadano a pie y su percepción de la zona urbana (Madeleine Guyot, Araldi, Fusco, & Thomas, 2021). Esto produce que un análisis aéreo de una zona, como el que se plantea en este proyecto, puede no ser suficiente a la hora de valorar si ciertos tipos de trazados urbanos son o no son convenientes para la mejora del bienestar de una ciudad.

Pese a todos los estudios repasados, ninguno utiliza la clasificación del trazado urbano presentada por el Atlas de Expansión Urbana. Se suelen optar por clasificaciones más exactas basadas en aproximaciones estadísticas como clasificación de usos según sus métricas, pero no una definición del trazado urbano por sus características visuales, más allá de la pura estadística.

Una misma parcela según sus características de, por ejemplo, intersecciones de nodos, altura media, tamaño, longitud, etc., puede ser, a la hora de la realidad si se examina su contenido de manera visual y no puramente sus estadísticas urbanas, de cualquiera de los tipos existentes. Esto plantea posibles soluciones, pero también posibles problemas dada la subjetividad de esta clasificación entre algunos tipos concretos de tipologías de asentamiento.

Esta subjetividad está relacionada con el hecho de que esta tipología es el agrupamiento de una serie de métricas de muy diversos factores que son las que deciden el resultado. Algunas

métricas que pueden participar en esto serían factibles de calcular como longitud de tramos, anchura de calles, etc. El problema de algunas de estas métricas es su dificultad de calcular como por ejemplo el número de equipamientos que tiene una calle (asfaltada, con iluminación, aceras) que además puede ser diferente entre zonas, u otras métricas, como pueden ser la calidad de edificaciones en un mismo bloque como los hacinamientos vistos en barrios marginales como en el ejemplo de Kowloon, que pese a ser un bloque cuadrado, se encuentra edificado de forma muy irregular.

Al realizar esta tarea de forma manual por un digitalizador, entra en conjunción una serie de parámetros que no siempre se aplican de la misma forma, por lo que realizar alguna de estas clasificaciones mediante árboles de decisión o técnicas similares las harían inviables.

Se va a estudiar si las redes convolucionales gestionan mejor esta subjetividad que una serie de rangos definidos dentro de unos parámetros definidos.

3. Objetivos y metodología de trabajo

3.1. Objetivo general

El objetivo principal de este estudio es desarrollar una metodología que mediante el uso de redes convolucionales permita la clasificación de parcelas urbanísticas según su tipología de asentamiento y así demostrar su utilidad para estudios urbanísticos con imágenes de alta resolución. Esta clasificación se realizará teniendo solamente la imagen aérea de la parcela y obteniendo como resultado la categoría a la que pertenece.

Este proceso permitiría realizar estudios en diferentes épocas históricas gracias a imágenes satélite o de imágenes aéreas como las realizadas en España del PNOA (Plan Nacional de Ortofotografía Aérea) de décadas anteriores y permitiendo que se pudieran repetir a futuro con nuevas imágenes. Además, se podría aplicar de forma masiva en todo el globo, pudiéndose repetir el estudio siempre que hubiera una actualización de las parcelas o se quisiera clasificar una nueva ciudad. De esta forma, se busca una metodología que necesite de tiempos viables de procesamiento.

Se propone esta tecnología para abordar uno de los problemas principales durante la elaboración del Atlas de Expansión Urbana que era la falta de mano de obra cualificada que pudiera etiquetar una ciudad de estudio. El estudio original se limitaba a zonas muestrales de la ciudad en 200 ciudades seleccionadas de más de 100.000 habitantes, una vez creada un sistema como el que se propone, no debería de existir ninguna limitación para categorizar zonas o número de ciudades. Estas 200 ciudades se seleccionaron de entre 4000 que cumplían esas características.

En esta propuesta, el trabajo manual se debe mantener sobre todo en las partes iniciales donde se necesita crear una base de datos que permita el entrenamiento de una red neuronal o que corrobore los resultados otorgados por esta. Sin embargo, hay una gran diferencia en términos de recursos humanos que se necesitan reduciéndose en gran cantidad y pudiéndose dar el caso en llegar al punto en que ya no fuera necesario preparar más datos y convertirse en un proceso completamente automatizado.

Por lo tanto, como objetivo último, se pretende determinar si la creación de esta nueva metodología otorga resultados que permitan aumentar y abarcar una mayor cantidad de estudios que hasta ahora no eran abordables. Los motivos pueden ser varios, pero los

principales son por falta de datos procesados, los cuales hay que crear con digitalizadores expertos en el tema y una elevada cantidad de horas de trabajo manual.

También se buscan nuevas formas de realizar estos y posibles nuevos estudios que se adapten a las cada vez más grandes y más complejas ciudades con la utilización de imágenes de alta resolución.

3.2. Objetivos específicos

Los objetivos específicos son:

- Explorar los diferentes recursos de imágenes aéreas y software para este proyecto. Comprobar que los recursos seleccionados de imágenes aéreas del PNOA y de CartoCiudad son suficientes para este estudio.
- Desarrollar herramienta para el etiquetado para la creación de la base de datos y la extracción de imágenes muestras.
- Diseñar una metodología reproducible y escalable con una red convolucional.
- Calcular la precisión de la red para clasificar para cada tipo de asentamiento urbano. Comprobar que las redes convolucionales son aptas para esta tarea.
- Evaluar si una red entrenada con los datos de una ciudad es extrapolable a ciudades sin datos.
- Determinar si es factible la utilización de esta metodología para este proyecto de clasificación de asentamientos urbanos o para otros proyectos.

3.3. Metodología del trabajo

Se plantea la siguiente metodología, Ilustración 10. Entrenar un modelo de red neuronal convolucional que aprenda a diferenciar los diferentes tipos de asentamientos. Los datos de entrenamiento serán extraídos de una fuente de datos creada para este proyecto, creando una base de datos nueva que extraiga imágenes de las parcelas vectoriales etiquetadas de una tipología.

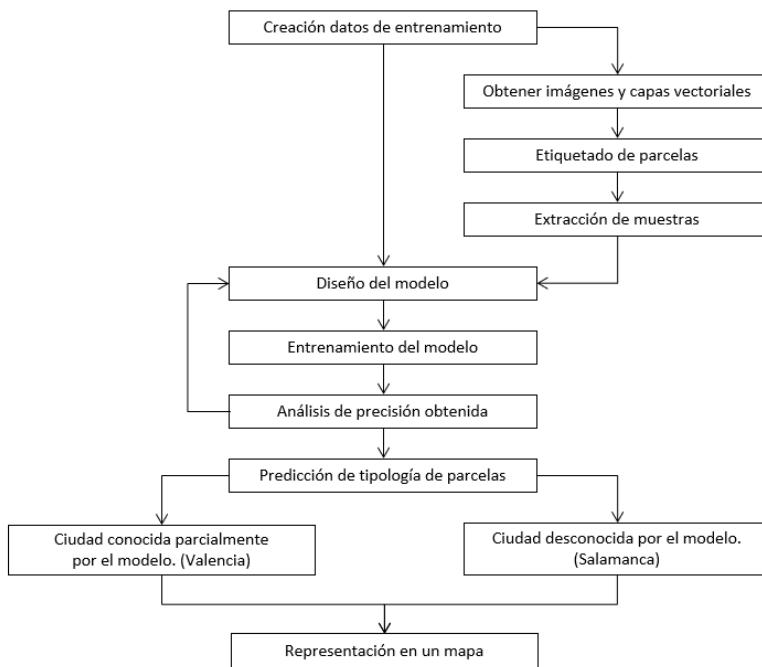


Ilustración 10 Resumen de la metodología del proyecto

Se utilizarán imágenes aéreas del PNOA (Plan Nacional de Ortofotografía Aérea), de CartoCiudad y de la Sede del Catastro. Estos recursos se explicarán luego en mayor profundidad.

Las herramientas desarrolladas en el proyecto, la creación de mapas y el procesamiento de las capas tanto vectoriales como de imágenes se ha realizado utilizando el software de gvSIG Desktop (gvSIG, 2021). Este programa *open source* es un Sistema de Información Geográfica desarrollado en la Comunidad Valencia con muchos años de recorrido actualmente a cargo de la Asociación gvSIG y que está libre para su descarga. Para este proyecto se ha utilizado una versión en desarrollo etiquetada como gvSIG Desktop 2.6.0.3218. Los programas realizados deberían de ser usables incluso en versiones anteriores a esta. El desarrollo se ha realizado haciendo uso del módulo de Scripting donde se desarrolla utilizando Jython. Estos se desarrollan con una sintaxis de Python, pero pudiendo utilizar librerías Java en él.

El etiquetado de las parcelas para su extracción se realizará en gvSIG Desktop. Se situarán la capa vectorial a etiquetar encima de la imagen y se irá realizando el etiquetado.

Una vez concluido el etiquetado de las diferentes ciudades, se realizará un recorte de las parcelas y se estructurarán en carpetas acordes al formato que acepta Keras para entrenar el modelo de red convolucional.

Se realizará la arquitectura del modelo y se procederá al entrenamiento.

Con el modelo entrenado se hará una evaluación de este, tanto de los datos obtenidos durante su entrenamiento como de la matriz de confusión obtenida entre las diferentes tipologías. Se procederá a hacer una validación sobre una ciudad la cual no haya formado parte del entrenamiento.

También se realizará una prueba de etiquetado de una ciudad que haya formado parte del entrenamiento, pero sobre toda su extensión ya que para entrenar el modelo no se utilizar todas las parcelas de las ciudades seleccionadas.

4. Descripción detallada del experimento

4.1 Tarea de digitalización

En este caso se han seleccionado las ciudades de Alicante, Barcelona, Pontevedra, Toledo y Valencia. Estas ciudades han sido seleccionadas por su variabilidad en su tipología urbanística. La ciudad de Salamanca también será etiquetada, pero con el único propósito de utilizarla como validación del modelo.

Se han obtenido del IGN (Instituto Geográfico Nacional) las imágenes del PNOA (Plan Nacional de Ortofotografía Aérea) las imágenes correspondientes a las ciudades seleccionadas que cubren la extensión estudiada, Ilustración 11. Se ha seleccionado el producto de Ortofoto PNOA Máxima Actualidad. Una vez dentro, se selecciona directamente el municipio que se quiere descargar.



Ilustración 11 Descarga de productos del PNOA

Para las parcelas vectoriales se ha utilizado la capa de CartoCiudad. Estas capas se pueden descargar también del IGN y contienen todas las parcelas urbanas de una ciudad. Se han seleccionado las capas de parcelas urbanas sin histórico. Esto da una capa con la que ya se puede trabajar directamente. El procedimiento es el mismo que para la descarga del PNOA.

Una necesidad que apareció en mitad del proyecto era la falta de parcelas con la tipología 0 (cero) de *open space* o espacio abierto. Esta tipología que, en general, pertenece a zonas de parque o parcelas no edificadas aún. La capa de CartoCiudad está principalmente centrada en parcelas urbanas y edificadas por lo que había una carencia considerable de esta tipología.

Se podrían encontrar pocas parcelas vacías y el número de parques en una ciudad suele ser bajo en comparación con el resto de las tipologías.

Para obtener una base de datos equilibrada se descargó la capa con parcelas vectoriales de Catastro de la parte de Rústica. En esta capa se presentan las parcelas que interesan como son: no construidas, campos de cultivo o zonas abiertas sin ningún tratamiento como son ríos, bosques, descampados, etc. Al ser muy uniformes solo se seleccionaron las dos ciudades de Valencia y Toledo para la obtención de este tipo de muestras.

Se utiliza gvSIG Desktop para procesar la capa de CartoCiudad e imagen del PNOA de la zona. Para ello se coloca la capa vectorial sobre una imagen del PNOA y se van etiquetando los polígonos que servirán para el entrenamiento del modelo. También se hace lo mismo sobre la capa del Catastro para etiquetar solo parcelas de tipo *open space*.

En este caso, una provincia como la de Alicante en CartoCiudad, tiene 49214 parcelas. No se etiquetan todas ellas, sino que se pueden seleccionar en grupo multitud de ellas y etiquetarlas a la vez. De forma similar se pueden obtener de forma masiva muestras de diferentes zonas siempre y cuando estén agrupadas, que suele ser lo más común.

Para una mayor facilidad en los procesos posteriores y en la creación de visualizaciones ambas capas se han reproyectado a la misma proyección. En este caso, es la capa de parcelas la que se ha reproyectado a la proyección con la que viene la imagen raster del PNOA que es 25830. En última instancia, la proyección no es importante ya que las muestras van a ser un recorte de una imagen de una parcela concreta sin importar sus coordenadas.

En la capa de CartoCiudad se ha añadida una nueva columna de datos llamada TIPO de tipo Entero rellenada con el valor por defecto de -1, Ilustración 12, para cuando no tiene un valor asignado.

Tabla de atributos:MANZANA_32630				
	ID_MANZ	ALTA_DB	INE_MUN	TIPO
5247	30.140.00...	5/05/20 0:00	3.014	-1
5248	30.140.00...	5/05/20 0:00	3.014	4
5249	30.140.00...	5/05/20 0:00	3.014	-1
5250	30.140.00...	5/05/20 0:00	3.014	4
5251	30.140.00...	5/05/20 0:00	3.014	4
5252	30.140.00...	5/05/20 0:00	3.014	4
5253	30.140.00...	5/05/20 0:00	3.014	4
5254	30.140.00...	5/05/20 0:00	3.014	1
5255	30.140.00...	5/05/20 0:00	3.014	4
5256	30.140.00...	5/05/20 0:00	3.014	-1
5257	30.140.00...	5/05/20 0:00	3.014	-1
5258	30.140.00...	5/05/20 0:00	3.014	-1

Ilustración 12 Tabla de Manzanas de la ciudad de Alicante con los valores de TIPO

Para facilitar el proceso de ha creado una leyenda, Ilustración 13, con las tipologías básicas del proyecto.

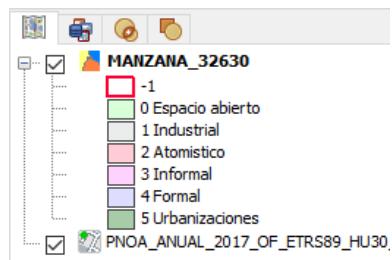


Ilustración 13 Leyenda aplicada a la capa de tipologías de asentamiento

Esta leyenda permite visualizar los datos de una manera más visual según se van etiquetando con su tipología.

Se sigue un procedimiento manual, en el que se selecciona un conjunto de datos de la capa de CartoCiudad y se le asigna un valor utilizando la herramienta de la calculadora de Campos. Esta herramienta permite modificar los valores de los campos seleccionados.



Ilustración 14 Vista de las parcelas sin una tipología asignada aparecen sin relleno y borde rojo.

El aspecto inicial es el mostrado en la Ilustración 14 donde no se ve ninguna parcela etiquetada. Se seleccionan las parcelas de una misma tipología con las diferentes herramientas disponibles de selección por punto, rectángulo o por polígono, Ilustración 15. En caso de ser necesario, se podrían utilizar las diferentes herramientas de Edición que dispone la herramienta de gvSIG para el recorte, eliminación o creación de parcelas. Esto permite

adecuar mejor el etiquetado para generar muestras que se adapten mejor a las tipologías indicadas.

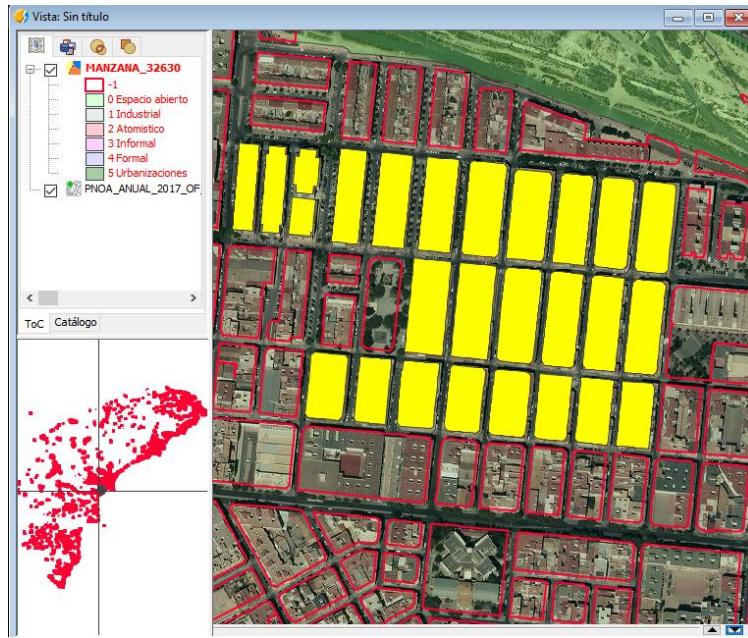


Ilustración 15 Selección de las parcelas que se van a etiquetar.

Una vez realizada la selección se pueden modificar los valores desde la calculadora de campos (Ilustración 16).

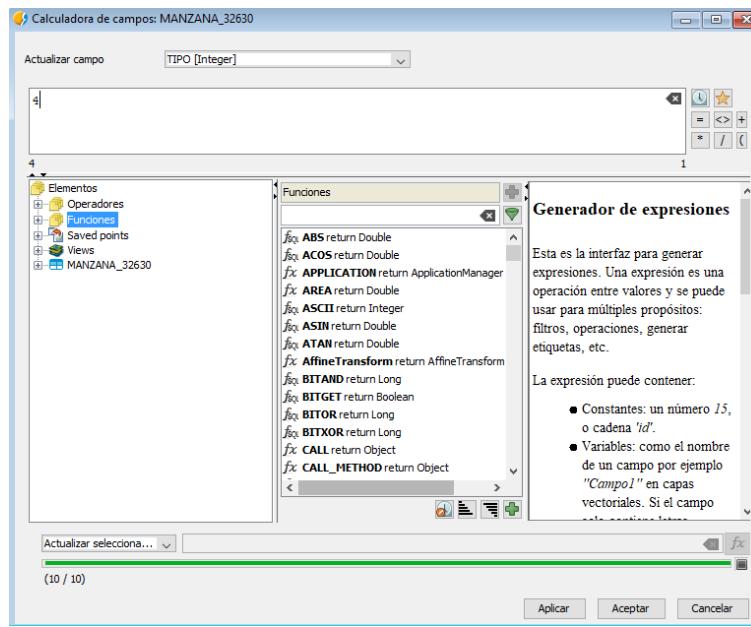


Ilustración 16 Herramienta de Calculadora de campos con el campo seleccionado a modificar, el valor y indicando que se van a modificar las entidades seleccionadas.

Para realizar este proceso se pueden situar las dos ventanas juntas y trabajar a la vez, por lo que hace que sea un proceso más fluido (Ilustración 17).

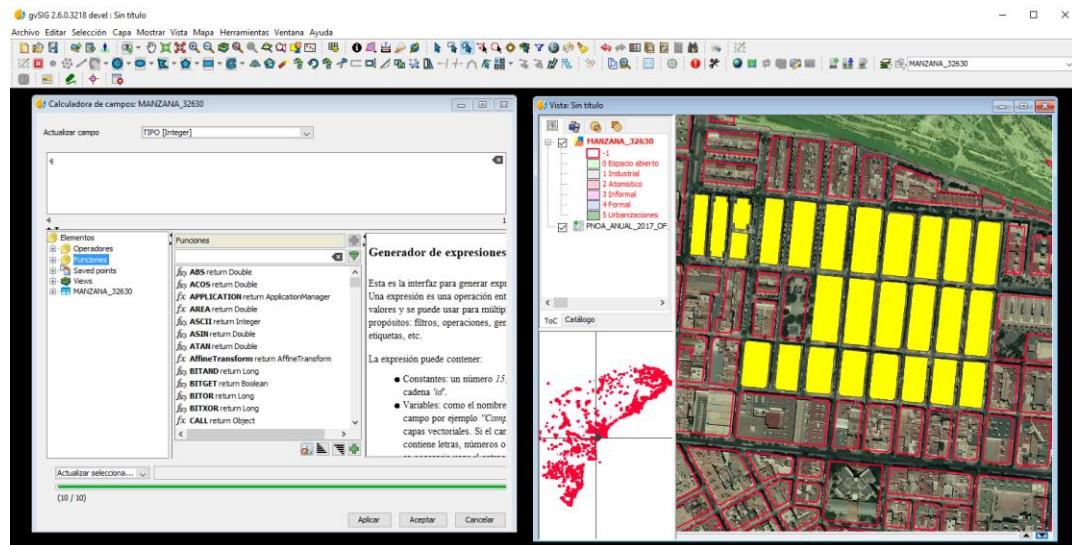


Ilustración 17 Herramienta de gvSIG Desktop realizando proceso de etiquetado.

Para facilitar el etiquetado por parte del digitalizador, se ha diseñado una herramienta (Ilustración 18) complementaria que simplifica el proceso a realizar la selección y presionar el botón de la categoría a etiquetar. También ofrece información sobre el número total de parcelas etiquetadas por cada tipología, de esta forma se puede ir comprobando la cantidad de muestras y su tipo que se van realizando.

Esta herramienta también se ha realizado sobre gvSIG Desktop y viene incluido en el repositorio de UrbanCNNProject (Martínez, 2021).

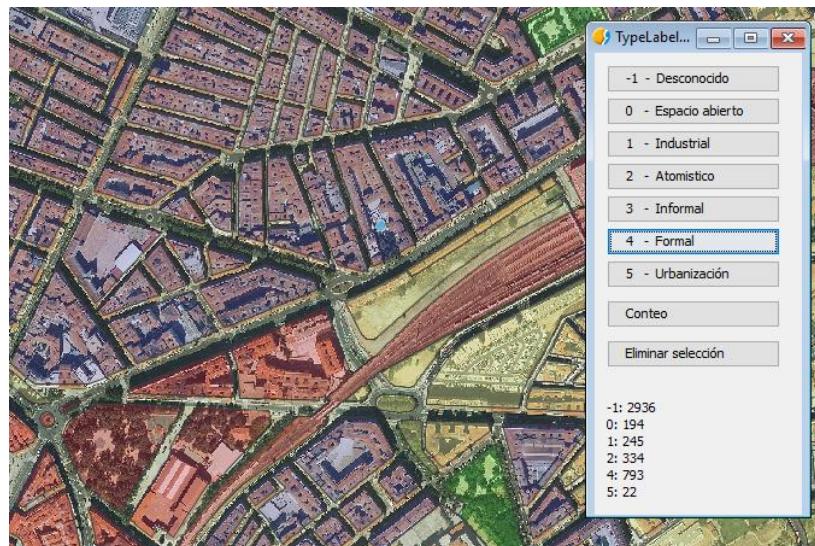


Ilustración 18 Herramienta de etiquetado en gvSIG Desktop

El código importante que ejecuta esta herramienta es el código que se ejecuta en cada uno de los botones y es el siguiente, siendo “value” el valor que le pasa cada botón:

```

def updateValueSelection(self, value):
    features = self.store.getFeatureSelection()
    for f in features:
        c = f.setEditable()
        c.set(self.typeField, value)
        features.update(c)
    features.deselectAll()
    DisposeUtils.dispose(features)
    self.updateCount()

```

Este código permite cambiar los valores del campo TIPO según el botón presionado sobre todas las parcelas seleccionadas.

Una vez asignado el valor de la tipología y al deshacer la selección, se puede comprobar como la simbología aparece con la de su etiquetado correcto (Ilustración 19).

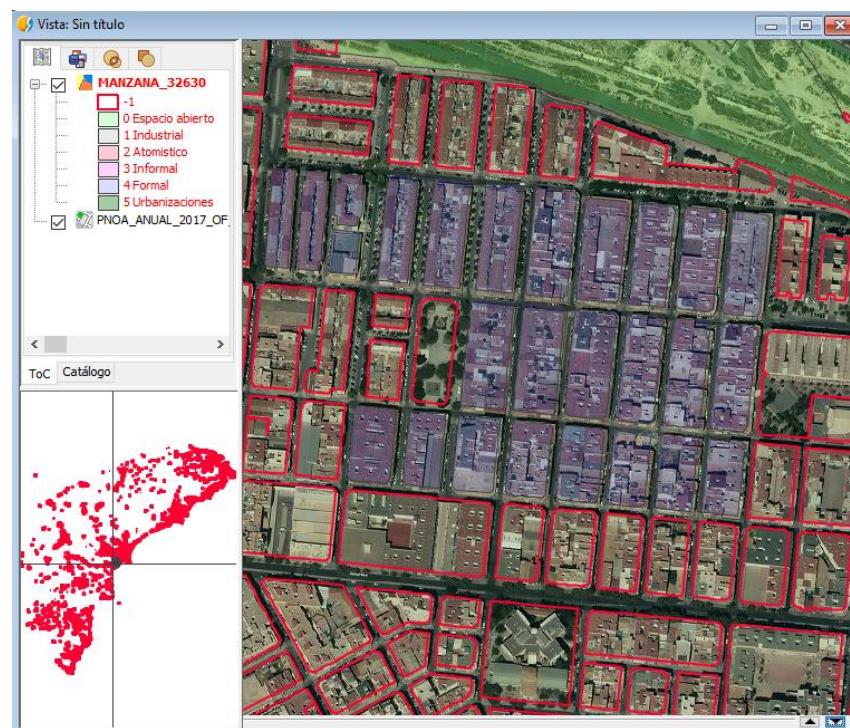


Ilustración 19 Etiquetado de zona como formal

Según se va avanzando en el proceso, la capa empezará a tener todas las capas etiquetadas y serán las que se utilizarán para la extracción de muestras (Ilustración 20).

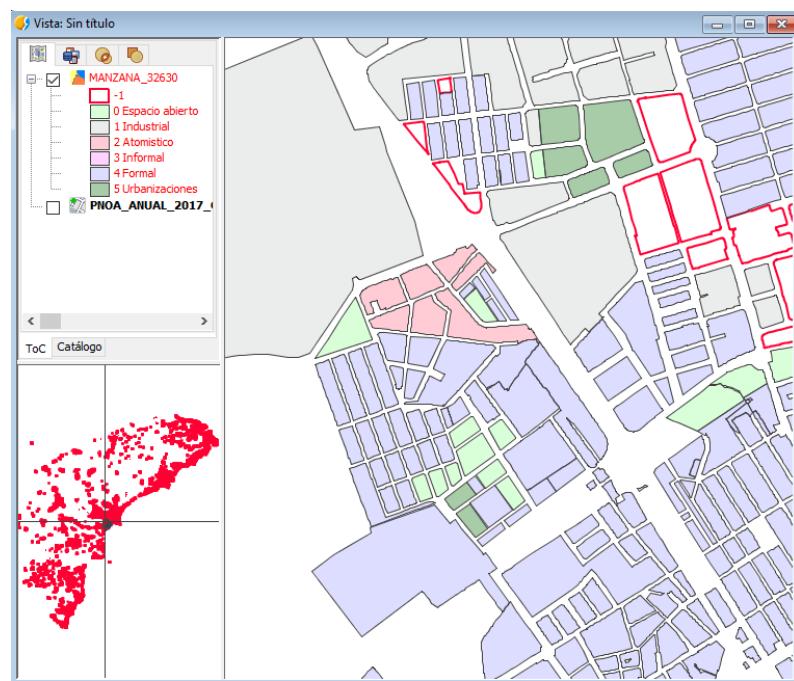


Ilustración 20 Ejemplo de un trozo de la capa de parcelas etiquetadas con su simbología.

Ahora, ya se puede ver con imágenes las diferentes tipologías existentes extraídas de muestras.

La tipología industrial, Ilustración 21, se caracteriza por parcelas grandes, bastante uniformes en colores, con formas de parcela muy diversas pero caracterizada por edificios grandes o grandes superficies de asfalto o naves grandes lo que genera una uniformidad en su estructura interna en la mayor parte de los casos. En estos casos se incluyen también edificaciones como hospitales o universidades que siguen unas características similares, muy diferentes a zonas residenciales.



Ilustración 21 Ejemplo de tipología industrial

La tipología atomística, Ilustración 22, se caracteriza por la heterogeneidad de sus formas, tanto de su perímetro como de su estructura interna.



Ilustración 22 Ejemplo de tipología atomística

La tipología formal y urbanística, Ilustración 23, está caracterizada por sus formas uniformes y cuadriculares, con una mayor ordenación en su estructura interna y muy heterogéneas en colores.



Ilustración 23 Ejemplo de muestras formales

La tipología Espacio Abierto son parcelas vacías ya sea por la falta de construcción o su uso para parques, cultivo, etc. Suelen ser parcelas verdes y muy uniformes.

Se ha intentado mantener una representación equilibrada entre las diferentes ciudades como se puede ver en la Tabla 1. Esto no siempre es posible dado que, según la ciudad, hay

tipologías claramente predominantes a otras. Se señala con el “+” las parcelas añadidas provenientes del Catastro para añadir muestras de la tipología Espacio Abierto. Se han centrado en dos ciudades dado la gran similitud entre todas ellas al provenir de campos de cultivo o parcelas pero sin edificar (en Valencia abundan estos tipos), o grandes extensiones sin cultivo (Toledo). Después de comprobar en los modelos la correcta predicción de esta tipología no se vio necesario realizar la extracción de muestras del Catastro en el resto de las ciudades.

Ciudad	Espacio abierto	Industrial	Atomística	Formal	Total
Alicante	206	248	553	1833	2840
Barcelona	66	695	752	786	2299
Pontevedra	25	25	776	27	853
Toledo	360 +709	113	645	449	2276
Valencia	306 +912	780	766	755	3519
Total	2584	1861	3492	3850	11787

Tabla 1 Resumen de número de muestras por cada ciudad

A estos datos, habría que sumar la ciudad de Salamanca con 272 muestras de espacio abierto, 328 de Industrial, 372 de Atomística y 954 de Formal. Los datos de esta ciudad no forman parte del entrenamiento y se usarán todos en exclusiva para validación.

4.2 Limitaciones de digitalización

Pese a que estas categorías están bien detalladas, existen multitud de casos en los que incluso la interpretación del digitalizador es la que decide si es de un tipo u otro. También, por limitaciones del proyecto, la información para realizar esta clasificación es limitada.

Como se ha comentado con anterioridad, esto ya fue un problema durante la digitalización del proyecto de Atlas de Expansión Urbana, por lo que ya se asumía que iba a existir cierto error en la interpretación de algunas de las muestras. Esto puede producir confusiones incluso para un humano por lo que habrá que estudiar cómo se comporta el modelo ante estos casos.

Se ha considerado que las tipologías de Informal (número 3) y Proyecto urbanístico (número 5) no van a entrar en el estudio. Los motivos son los siguientes:

- Informal: Es una categoría que se asocia con un crecimiento de la ciudad planificado como pudiera ser la tipología Formal pero que carece de los servicios públicos necesarios. El caso más común es la existencia de parcelas edificadas pero que carecen de servicios alrededor, como, por ejemplo, de calles asfaltadas y con aceras. En España es muy difícil encontrar esta tipología.
- Proyecto urbanístico: Es una categoría que hace referencia a un crecimiento planificado de la ciudad pero que tiene unas características propias. Suelen ser

parcelas de mayor tamaño que constan de múltiples bloques con sus propias calles, parques, caminos y aceras. Estos servicios extra hacen que, a nivel de parcela, un Proyecto Urbanístico pueda parecer pobremente conectado, pero en la realidad, esté muy bien conectado con gran cantidad de pasos. El problema es su gran similitud con las parcelas formales y suele ser una fuente constante de confusión a la hora de su etiquetado. También, algunos de estos proyectos urbanísticos, suelen ser de acceso privado, por lo que los caminos internos que tienen son de uso exclusivo para residentes. Esto es algo difícil de discernir en una imagen aérea.

Para los problemas expuestos, se han descartado estas tipologías de este proyecto.

4.3 Creación de muestras

Una vez realizado el etiquetado, con la capa de datos vectoriales y una imagen de la zona, se procederá a la extracción de muestras que se utilizarán para entrenar la red neuronal. En este caso se va a utilizar una imagen del PNOA. Sin embargo, esto no es un requisito para que funcione la extracción. Dadas las características de gvSIG Desktop, una vez está cargada la capa como de tipo imagen, el programa la trata y trabaja de igual forma sea cual sea su fuente de recursos. Por esta razón, se podrían utilizar imágenes satelitales, aéreas, sea cual sea su formato siempre que sea soportado por gvSIG (tif, png, ecw..) o proveniente de servicios externos como WMS, WMTS, Mapas webs como Google Maps o Bing Maps, etc (Ilustración 24).

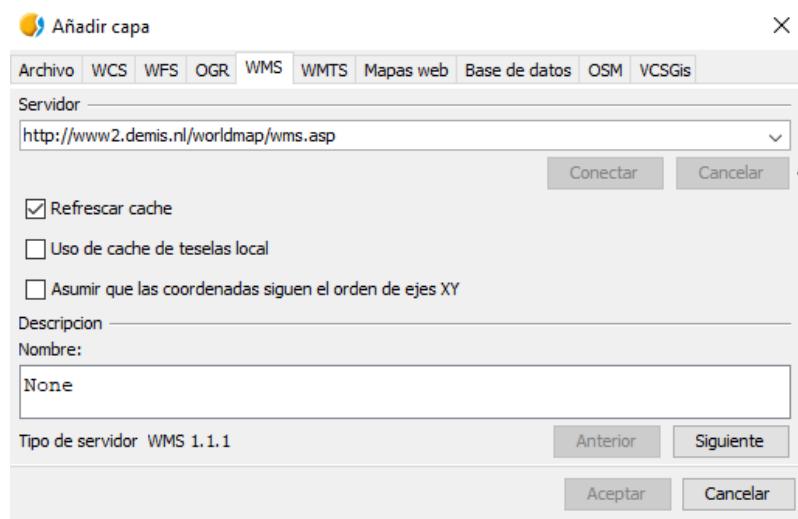


Ilustración 24 Añadir capa de tipo WMS

Con las dos capas cargadas se puede ejecutar el proceso de extracción de muestras (Ilustración 25) programado dentro de gvSIG Scripting. Esta herramienta se encuentra disponible en el repositorio del proyecto UrbanCNNProject.

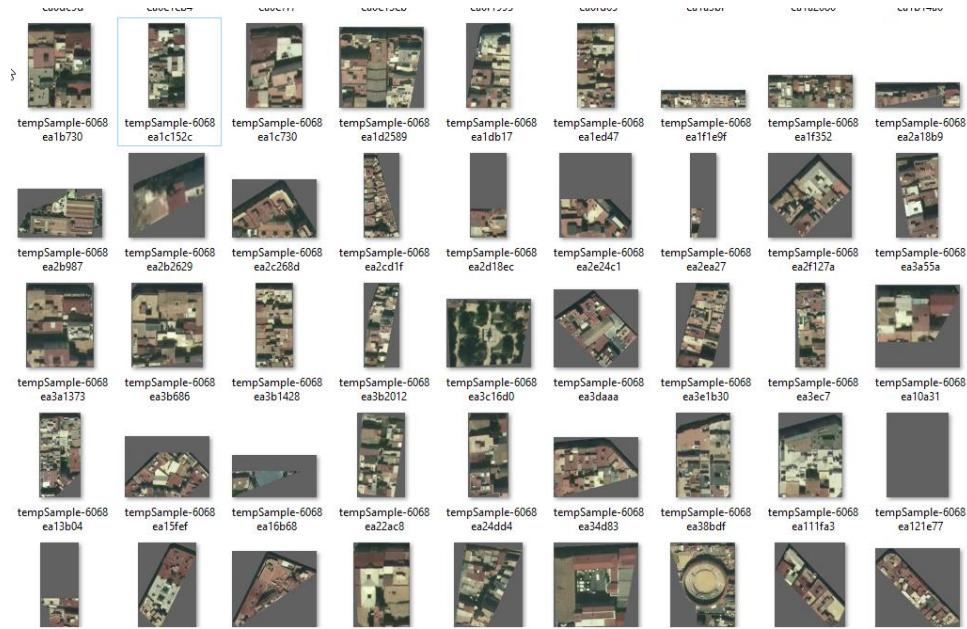


Ilustración 25 Ejemplo de muestreado

El código principal de la herramienta que extrae las muestras es el siguiente:

```

cityName = "Valencia_722_Rustica" # Nombre de la ciudad
rasterName = "PNOA_MA_OF_ETRS89_HU30_h50_0722" # Nombre de la imagen
layerName = "PARCELA" # Nombre de la capa vectorial

raster = gvsig.currentView().getLayer(rasterName)
poligonos = gvsig.currentView().getLayer(layerName)

featureTypePoligonos = poligonos.getFeatureStore().getDefaultFeatureType()
fset = poligonos.getFeatureStore().getFeatureSet()
total = fset.getSize()
n = 0
for f in fset:
    n+=1
    print ("Status: "+str((float(n)/total)*100.0))
    buildType= f.get("TIPO")
    if buildType == -1:
        continue
    temporalShape = createTemporalShape(featureTypePoligonos, f)
    tempFile = getTempFile(cityName,"_"+str(buildType)+ ".tif",
tempdir="E:\\TFM_MUESTRAS\\\"+executeName+"\\\"+ cityName)
    print tempFile
    gvpy.runalg("clipgrid", raster,temporalShape, PATH=tempFile, ADDLAYER=False)

```

La función principal de este script es ir creando capas temporales por cada parcela y ejecutar el geoprocreso de recorte “*clipgrid*”. El geoprocreso recorta una imagen según una capa con

geometrías de tipo polígono, como este es el caso. El resultado es la muestra con el nombre especificado en la variable “*tempFile*”.

Estas muestras se extraerán y se almacenarán en carpetas contiguas según su tipología. El formato que genera es el que acepta Keras para el entrenamiento. La ruta a esta carpeta es la que se le pasará para que se entrene el modelo.

Se han tenido que eliminar muestras que superasen los 100 megas de almacenamiento en disco ya que, por su tamaño, Keras lo tomaba como un error y no las procesaba. Esto podría solucionarse mejorando la herramienta para que realice un cambio de tamaño cuando se extraen las muestras, ya que para el entrenamiento del modelo, se utilizan imágenes mucho más reducidas, por ejemplo, hasta un tamaño de 220 x 220 píxeles en este caso.

4.4 Preparación de la base de datos de entrenamiento

Mediante un script, indicando las carpetas que ha creado el proceso anterior, se juntaran todas las muestras en dos carpetas principales:

- *training*: con 4 carpetas dentro con los tipos a estudiar y los datos que se utilizaran para el entrenamiento
- *validation*: con 4 carpetas dentro con los tipos a estudiar y los datos que se utilizaran para la validación.

La salida de las imágenes del programa de gvSIG se realiza con un nombre quasi aleatorio de la imagen: ciudad + código aleatorio + tipo de clasificación que se le ha otorgado en el campo TIPO. Ejemplo de nombre de fichero: Alicante-61193a76bdf_1.tif siendo 1 su tipología. Para usos posteriores, también estará la opción de incluir el número de manzana en el nombre del fichero. Esto permitirá asignar de vuelta los valores calculados por el modelo.

Quedando esta estructura en el disco duro dentro de la carpeta “test” que serán a su vez los nombres que tendrán las etiquetas. Esta estructura es la que necesitará el modelo para su entrenamiento. Se han añadido unos parámetros especiales para otorgar nombres lo que permite repetir la preparación de los datos.

- *Test*: nombre del test establecido
 - o *validation_process + número del proceso establecido*
 - 0_espacioabierto
 - 1_industrial
 - 2_atomistic

- 4_formal
 - *training_process + número del proceso establecido*
 - 0_espacioabierto
 - 1_industrial
 - 2_atomistic
 - 4_formal

El tener los datos separados de esta forma va a permitir que al ejecutar diferentes diseños de redes convolucionales se ejecute el entrenamiento y la validación sobre las mismas muestras para poder comparar la efectividad entre modelos.

Esta división se puede configurar en las siguientes líneas del script denominado “001_join_images.py”.

```
testFolder = NEW_TRAINING_FOLDER
if not os.path.exists(testFolder):
    os.makedirs(testFolder)

# Divide by 4 types
print ("Divide by 4 types")
builtup_names = [
    "0_espacioabierto",
    "1_industrial",
    "2_atomistic",
    "4_formal"
]

dic_all_files_types = {
    builtup_names[0]:[],
    builtup_names[1]:[],
    builtup_names[2]:[],
    builtup_names[3]:[]
}

for f in tif_files:
    if f.endswith("0.tif"):
        dic_all_files_types["0_espacioabierto"].append(f)
    if f.endswith("1.tif"):
        dic_all_files_types["1_industrial"].append(f)
    if f.endswith("2.tif"):
        dic_all_files_types["2_atomistic"].append(f)
    if f.endswith("4.tif"):
        dic_all_files_types["4_formal"].append(f)
```

Este código hace que el script sea configurable y no esté limitado a la estructura o número de categorías de este proyecto, pudiendo configurar las tipologías que se quieren trabajar. Con cambios menores se podría adaptar a cualquier tipo de proyecto de clasificación.

4.5 Entrenamiento del modelo

El script correspondiente al entrenamiento del modelo tiene de nombre proceso_002_entrenar_modelo.ipynb que también se puede encontrar en el repositorio UrbanCNN.

Equipamiento

Todos los procesos incluidos en este proyecto, tanto el entrenamiento como la predicción, se han ejecutada con la misma máquina. Las características son las siguientes

- Intel(R) Core(TM) i5-6600 CPU @ 3.30GHz 3.30 GHz
- 64 gb RAM
- NVIDIA GeForce GTX 1070
- DirectX 12.0
- Windows 10 Home 64bits

Librerías

Se ha utilizado la herramienta de Visual Studio para ejecutar Python 3.8.8 64-bit. A continuación, se muestra un listado con las versiones de las librerías principales utilizadas para este proyecto:

- | | |
|------------------|-------|
| - Keras | 2.4.3 |
| - matplotlib | 3.3.4 |
| - tensorflow-gpu | 2.5.0 |

Hay que destacar que se ha instalado CUDA, con todos sus requisitos asociados como la instalación de NVIDIA cuDNN (NVIDIA, 2021), para la utilización de la GPU durante el entrenamiento. Esta librería permite a algunas tarjetas gráficas de la marca NVIDIA a ser utilizadas, en este caso por Keras, para entrenar el modelo. Esto permite un incremento sustancial en el rendimiento durante el entrenamiento de modelos. Unas primeras pruebas

han producidos resultados de entrenarse a velocidades alrededor de 3 veces más rápidas como mínimo.

Para comprobar que se está utilizando la GPU durante el entrenamiento se puede comprobar ejecutando las siguientes líneas. En ellas debe de aparecer al final listada la GPU, en caso contrario, no se estará utilizando.

```
from tensorflow.python.client import device_lib  
print(device_lib.list_local_devices())
```

Inicialización de parámetros

El script que se va a ejecutar necesita de la inicialización de unos parámetros básicos que solo sirven para indicar la localización en el disco de las imágenes. También se le puede dar un nombre de proceso y de ejecución, lo que permite una mejor organización de las diferentes pruebas que se pueden hacer.

En el repositorio se pueden encontrar en la carpeta de operaciones en el fichero 002_entrenar_modelo.ipynb.

Por ejemplo:

```
# Base folder  
DATA_FOLDER = 'E:\\TFM_MUESTRAS\\'  
  
# Name of the test folder  
TEST_FOLDER = "Test_003\\"  
  
# Folder with city folders images  
TRAINING_DIR = DATA_FOLDER + TEST_FOLDER + "images\\"  
  
# New folder to be created with joined images  
PROCESS_NAME = 'process_003'  
EJECUTION_NAME = 'M05_1000e_80b_224i_ADAM'
```

Data augmentation

Para el entrenamiento de la red se aplicarán técnicas de “Data Augmentation” para mejorar la eficiencia. Este aumento de datos aplica rotaciones y cambios de tamaño para entrenar a la red con imágenes parecidas las originales y se permita un mejor entrenamiento.

Las ciudades tienen a mantener las mismas tipologías de asentamiento a lo largo de la ciudad, ya sea por casos tan diferentes como concretos de la ciudad, de la región, culturales,

climáticos, históricos, etc. Esto hace que en una misma ciudad se suelen mantener tamaños de parcelas muy parecidos o mantener de forma constante la rotación de las parcelas dado que gran parte de las avenidas en ciudades suelen seguir la misma orientación.

En este proyecto, estas técnicas de aumento de datos van a ser muy útiles de aplicar por varios motivos. Según el tamaño de las parcelas que puede depender de su orientación ya que se recorta con un cuadrado, las que encajen mejor en ese cuadrado con cero grados de ángulo podrían aparecer siempre más grandes que las que aparecen en diagonal. Según la rotación, para preparar al modelo con parcelas que siguen las mismas características, pero tienen diferentes orientaciones.

Durante la clasificación, sobre todo la rotación, es una variable que nunca se tienen en cuenta para decidir su tipología. Sin embargo, el tamaño de parcela, si que puede tener alguna repercusión en su clasificación. Aun así, estos son problemas que ya puede tener el modelo en sí mismo al comprimir todas las imágenes a un tamaño concreto, no es un problema introducido por los procesos de aumento de datos que se han comentado.

```
training_datagen = ImageDataGenerator(  
    rescale = 1./255,  
    rotation_range=40,  
    width_shift_range=0.2,  
    height_shift_range=0.2,  
    shear_range=0.2,  
    zoom_range=0.2,  
    horizontal_flip=True,  
    fill_mode='nearest')
```

Modelo planteado

Como ya se ha comentado en el proyecto, dadas las características de este estudio, se ha decidido realizar una red convolucional que permita categorizar una imagen de una parcela según una categoría.

Para este proyecto las categorías que se deben de estudiar son cuatro y corresponden a los nombres que aparecen en las carpetas de entrenamiento:

- 0_espacioabierto
- 1_industrial

- 2_atomistic
- 4_formal

Por lo tanto, es una red convolucional con una salida de 4 categorías.

La estructura de la red la podemos ver en la salida del sumario del modelo de Keras. La red consta de una consecución de capas convolucionales recibiendo una imagen RGB (3 de profundidad) y de tamaño de imagen de 224, con 4 capas de este tipo con la activación “*relu*” con sus correspondientes capas de *MaxPooling*.

Después de aplicar una capa “*flatten*” y “*dropout*”, se pasan los valores obtenidos a la red neuronal con 4 capas consecutivas también de tipo Dense y activación *relu*, excepto la final de tipo *softmax* que es la que tiene 4 neuronas correspondientes a las 4 tipologías sobre las que se hace la clasificación y darán como resultado una categoría. Esto da un total de 1,284,428 parámetros en la red para entrenar.

```
Model: "sequential"

Layer (type) Output Shape Param #
=====
conv2d (Conv2D) (None, 222, 222, 200) 5600
max_pooling2d (MaxPooling2D) (None, 111, 111, 200) 0
conv2d_1 (Conv2D) (None, 109, 109, 128) 230528
max_pooling2d_1 (MaxPooling2 (None, 54, 54, 128) 0
conv2d_2 (Conv2D) (None, 52, 52, 64) 73792
max_pooling2d_2 (MaxPooling2 (None, 26, 26, 64) 0
conv2d_3 (Conv2D) (None, 24, 24, 32) 18464
4
max_pooling2d_3 (MaxPooling2 (None, 12, 12, 32) 0
flatten (Flatten) (None, 4608) 0
dropout (Dropout) (None, 4608) 0
dense (Dense) (None, 200) 921800
dense_1 (Dense) (None, 128) 25728
dense_2 (Dense) (None, 64) 8256
```

```

dense_3 (Dense) (None, 4) 260
=====
Total params: 1,284,428
Trainable params: 1,284,428
Non-trainable params: 0

```

La visualización se ha realizado utilizando la aplicación de Netron (Roeder, 2021) que acepta un fichero .h5 y muestra una representación de la red (Ilustración 26).

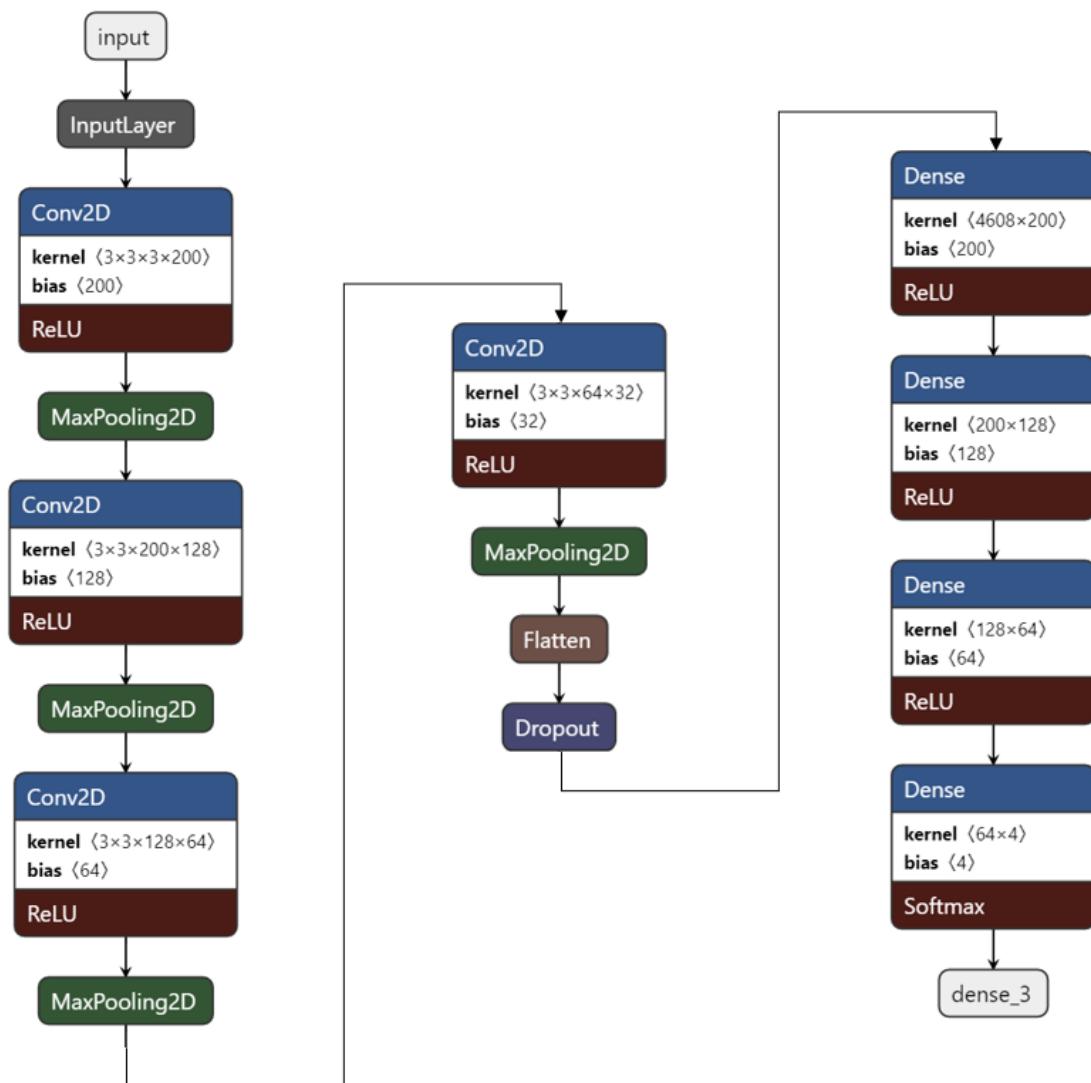


Ilustración 26 Representación gráfica de la red utilizada.

Después de múltiples iteraciones para llegar a este diseño, se han realizado dos pruebas sobre el mismo con diferentes optimizadores: ADAM y SGD. Las múltiples iteraciones se realizaron probando diferentes estructuras más simples y se fue complicando la red según las necesidades que se iban viendo. Estas pruebas se hicieron con menos capas convolucionales

y menos neuronales, aumentando progresivamente su profundidad y tamaño, así como, se aumentó el tamaño de entrada de la imagen en la red.

Con estas dos alternativas, se pasa a realizar la compilación y el entrenamiento con el siguiente código.

```
model.compile(
    loss = 'categorical_crossentropy',
    optimizer='ADAM',# o tf.keras.optimizers.SGD(),
    metrics=['accuracy']
)

history = model.fit(
    train_generator,
    epochs=1000,
    steps_per_epoch=50,
    validation_data=validation_generator,
    verbose=1,
    validation_steps=30
)

model.save("rps_"+PROCESS_NAME+EJECUTION_NAME+".h5")
```

4.6 Ejecución de la clasificación

Para obtener los parámetros de precisión del modelo también divididos por tipología, se ha realizado el siguiente código que ejecuta todas las imágenes de validación y analiza el resultado obtenido de cada una de ellas, obteniendo una matriz de confusión.

Esta matriz es de especial interés ya que algunas tipologías son más parecidas unas entre otras y es interesante saber si el modelo es capaz de diferenciarlas.

```
from sklearn.metrics import classification_report, confusion_matrix
import numpy as np
my_validation_datagen = ImageDataGenerator(rescale = 1./255)
my_validation_generator = my_validation_datagen.flow_from_directory(
    NEW_VALIDATION_FOLDER,
    target_size=(image_size, image_size),
    class_mode='categorical',
    batch_size=batch_size,
    shuffle=False
)
```

```
Y_pred = model.predict(my_validation_generator)
y_pred = np.argmax(Y_pred, axis=1)

print('Confusion Matrix')
print(confusion_matrix(my_validation_generator.classes, y_pred))
print('Classification Report')
# list(train_generator.class_indices.keys())
target_names = []
for key in builtup_names:
    target_names.append(key)

print(classification_report(my_validation_generator.classes, y_pred, target_names=target_names))
```

4.7 Predicción

Una vez se ha entrenado el modelo se guarda en un fichero .h5 que se puede recuperar en cualquier momento. Para realizar los mapas que se mostraran en el resultado del piloto, se ha debido de realizar una predicción de todas las parcelas de una ciudad de nuevo. En el repositorio se puede encontrar el código dentro de la carpeta de operaciones con el nombre 003_prediccion.ipynb.

Este proceso se apoya en realizar una predicción para un identificador único de la parcela que está prediciendo y que viene como parte del nombre de la imagen. Se obtendrá un fichero de texto o CSV (*Comma Separated Values*), fichero muy común de intercambio de datos, en el cual aparece el identificador de la manzana y el valor predicho por el modelo para su tipología urbana.

Dentro de gvSIG Desktop, mediante la herramienta de “Crear unión”, se asignarán los valores del CSV a la capa vectorial donde están las geometrías de las parcelas. De esta manera, se podrá realizar una visualización de los datos en el mapa con los valores predichos después de aplicarle una leyenda de valores.

5. Descripción de los resultados

5.1 Métricas obtenidas

Se va a mostrar la información sobre las métricas obtenidas con los dos modelos SGD y ADAM, utilizando la misma arquitectura de red explicada con anterioridad.

En el repositorio se ha incluido un apartado operaciones\resultados donde se pueden encontrar los ficheros h5 con los pesos guardados y las salidas completas de los datos de entrenamiento.

Para el modelo SGD se llegaron a obtener valores de precisión en los datos de validación durante el entrenamiento alrededor del 82%. Se puede apreciar en la Ilustración 27 esta precisión y que sube similar a la precisión del modelo. Este optimizador con sus valores por defecto parece que le cuesta aprender de la red y necesita un gran número de épocas para su entrenamiento.

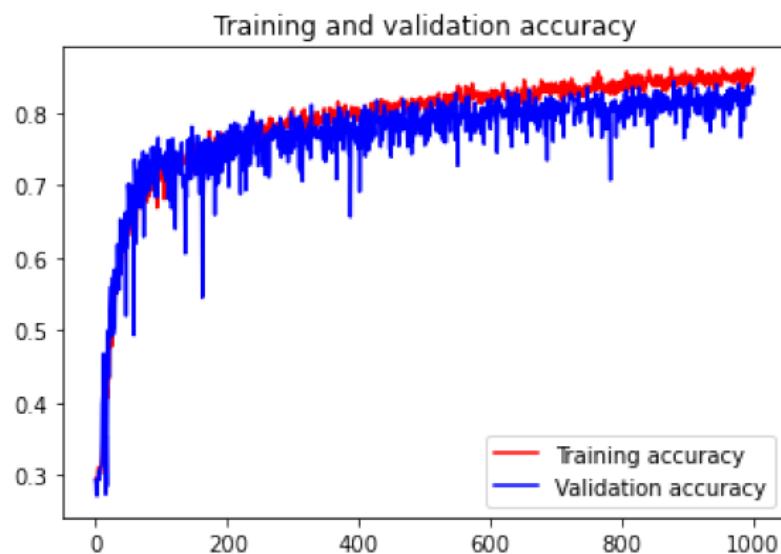


Ilustración 27 Gráfico del entrenamiento del modelo SGD.

Se añaden también, los datos aportados por la matriz de confusión, Ilustración 28, utilizando el modelo entrenado con el optimizador SGD. Es probable que haciendo pruebas con otros valores de *learning rate* y *momentum* para el optimizador SGD se pudiesen mejorar estos entrenamientos.

```

Confusion Matrix
[[618  46   7  14]
 [ 6 326  17  12]
 [23  32 559  85]
 [12  34 130 565]]
Classification Report
      precision    recall   f1-score   support
0_espacioaberto      0.94     0.90     0.92      685
1_industrial         0.74     0.90     0.82      361
2_atomistic          0.78     0.80     0.79      699
4_formal              0.84     0.76     0.80      741

accuracy                  0.83      --      2486
macro avg               0.83     0.84     0.83      2486
weighted avg            0.84     0.83     0.83      2486

```

Ilustración 28 Matriz de confusión del modelo SGD

Para el modelo ADAM obtenemos una precisión en los datos de validación durante el entrenamiento de alrededor del 86% (Ilustración 29). Este optimizador llega a valores muy altos de precisión con mayor rapidez con sus valores por defecto, siendo alrededor de la época 200 cuando ya se obtienen valores de precisión altos similares a los que obtiene el optimizador SGD en la época 1000 como se puede apreciar en la Ilustración 30.

```

Epoch 997/1000
50/50 [=====] - 125s 2s/step - loss: 0.2022 - accuracy: 0.9218 - val_loss: 0.6705 - val_accuracy: 0.8173
Epoch 998/1000
50/50 [=====] - 135s 3s/step - loss: 0.2834 - accuracy: 0.8936 - val_loss: 0.4365 - val_accuracy: 0.8527
Epoch 999/1000
50/50 [=====] - 155s 3s/step - loss: 0.2695 - accuracy: 0.8948 - val_loss: 0.4447 - val_accuracy: 0.8580
Epoch 1000/1000
50/50 [=====] - 134s 3s/step - loss: 0.2316 - accuracy: 0.9132 - val_loss: 0.5148 - val_accuracy: 0.8600

```

Ilustración 29 Salida del entrenamiento del modelo ADAM en los epochs finales.

Se empieza a observar algo de *overfitting* (sobreajuste), aumentando la precisión con los datos de entrenamiento, pero no teniendo una gran mejoría en los de validación. Pese a observar algo de overfitting, se seguía observando una mejora lenta y progresiva en la precisión de los datos de validación. El overfitting suele aparecer cuando se entrena demasiado un modelo. Esto hace que este se ajuste demasiado a los datos de entrenamiento lo que provoca que empiece a tener problemas para generalizar el resultado, lo que provoca que pierda precisión en los datos de validación pese a subir su precisión en los datos de entrenamiento.

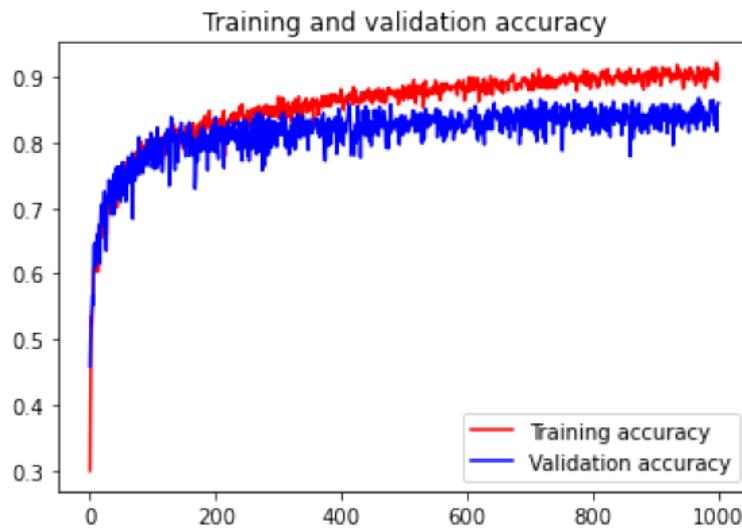


Ilustración 30 Gráfico de entrenamiento del modelo ADAM

Se puede observar que el optimizador ADAM obtiene unos resultados de forma más rápida que el SGD. Se añade también la matriz de confusión del modelo ADAM (Ilustración 31).

Confusion Matrix				
[[617 43 18 7]				
[7 318 19 17]				
[8 20 588 83]				
[18 27 93 603]]				
Classification Report				
	precision	recall	f1-score	support
0_espacioaberto	0.95	0.90	0.92	685
1_industrial	0.78	0.88	0.83	361
2_atomistic	0.82	0.84	0.83	699
4_formal	0.85	0.81	0.83	741
accuracy			0.86	2486
macro avg	0.85	0.86	0.85	2486
weighted avg	0.86	0.86	0.86	2486

Ilustración 31 Matriz de confusión del modelo ADAM para los datos de validación.

Así, para las siguientes pruebas, se ha decidido utilizar el modelo ADAM al tener una mayor precisión general.

Al utilizarse el modelo ADAM sobre los datos de la ciudad de validación de Salamanca se obtienen los siguientes resultados de la Ilustración 32. No se ha incluido ningún dato sobre esta ciudad en el entrenamiento.

```

Found 1926 images belonging to 4 classes.
Confusion Matrix
[[166 26 48 32]
 [ 33 192 78 25]
 [ 9 13 333 17]
 [ 29 44 815 66]]
Classification Report
precision    recall    f1-score   support
0_espacioaberto      0.70      0.61      0.65      272
1_industrial         0.70      0.59      0.64      328
2_atomistic          0.26      0.90      0.40      372
4_formal              0.47      0.07      0.12      954

accuracy                   0.39      1926
macro avg                 0.53      0.54      0.45      1926
weighted avg             0.50      0.39      0.34      1926

```

Ilustración 32 Matriz de confusión de Salamanca con el modelo ADAM

En la Tabla 2 se puede comparar rápidamente los valores obtenidas durante el entrenamiento del modelo y sobre la ciudad de Salamanca.

Precisión por tipología	Validación	Salamanca
0 - Espacio abierto	95%	70%
1 - Industrial	78%	70%
2 - Atomístico	82%	26%
4 - Formal	85%	47%
Total	86%	39%

Tabla 2 Resumen de los valores de la matriz de confusión por tipología para los datos de entrenamiento y de la ciudad de validación.

Se han volcado los datos de la predicción y se han mostrado en un mapa para comparar el resultado del etiquetado (Ilustración 33) con el predicho (Ilustración 34). Se añade la Ilustración 35 con la imagen del PNOA para realizar una comprobación visual. En estos mapas, igual que en la matriz de confusión, se puede observar que la principal confusión es entre las tipologías de atomístico (en rojo) y formal (en azul).

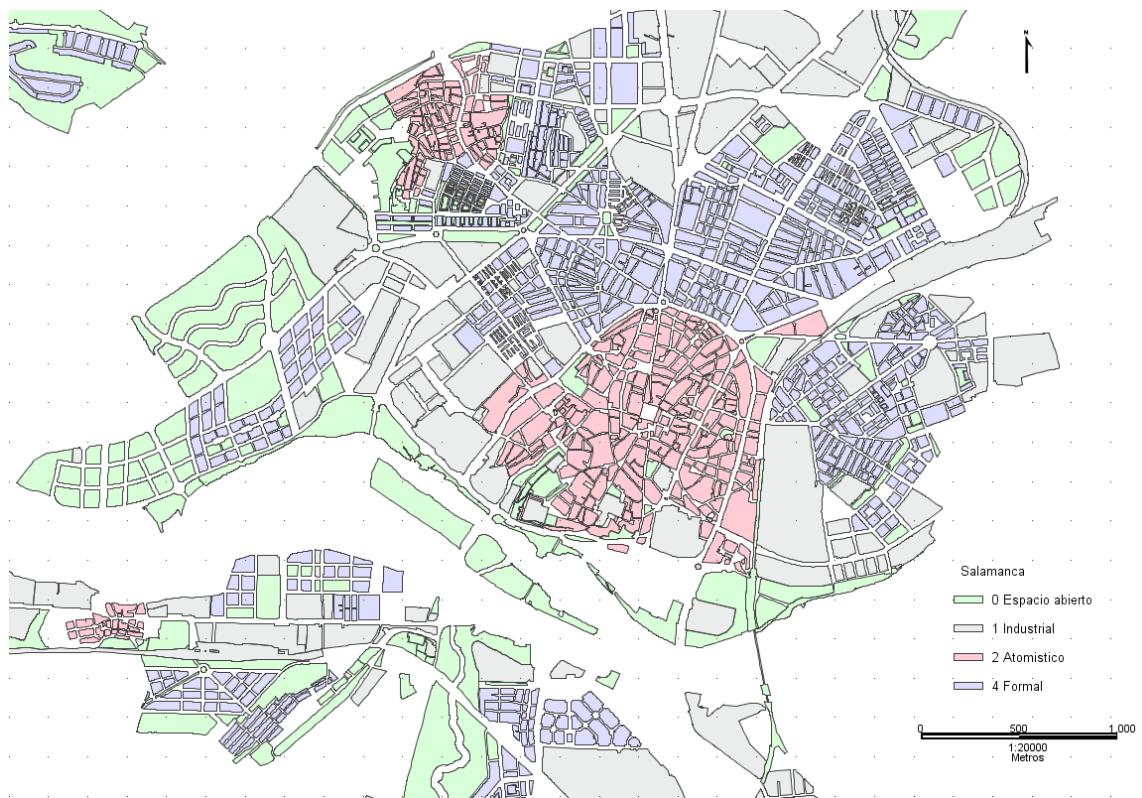


Ilustración 33 Mapa de Salamanca etiquetado

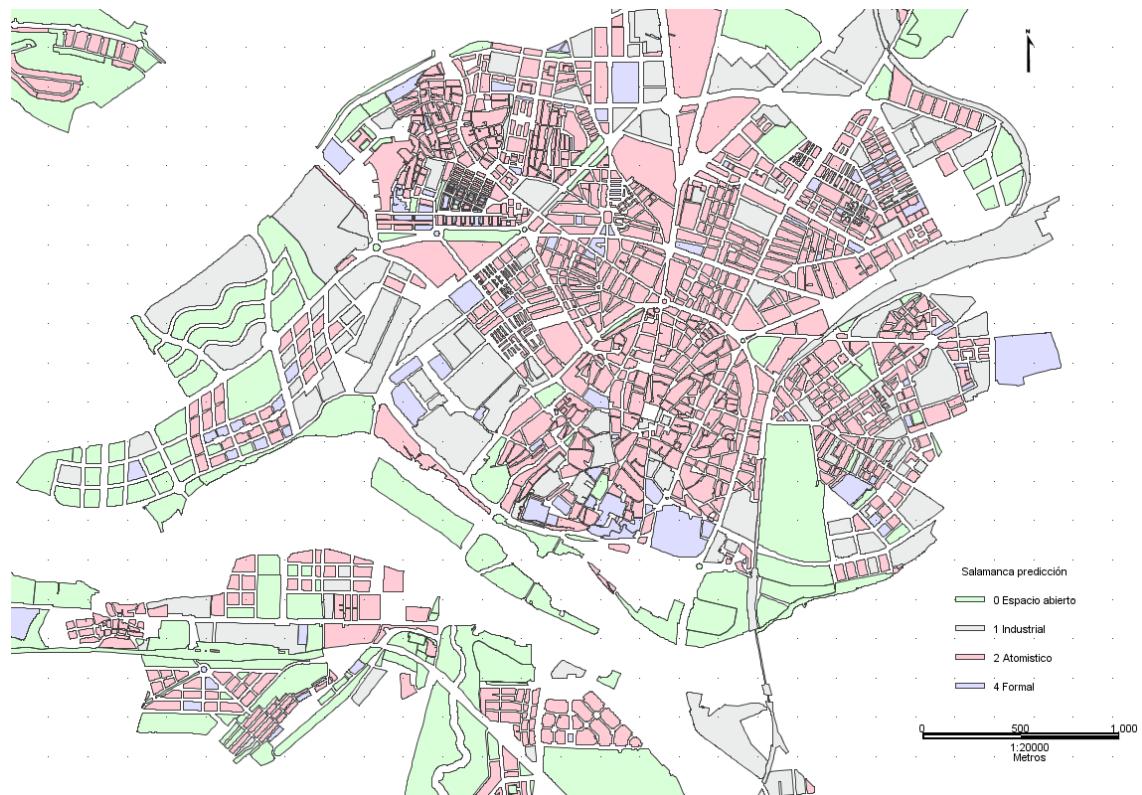


Ilustración 34 Mapa de Salamanca predicho



Ilustración 35 Imagen PNOA de la ciudad de Salamanca

Para continuar con el análisis de los resultados, se ha ejecutado una predicción sobre toda la ciudad de Valencia (Ilustración 36). Recordamos que solo una parte, alrededor de 2.600 muestras, habían sido etiquetadas y alrededor de 2.000 habían formado parte del entrenamiento del modelo. En este mapa, se le ha pedido la predicción de la capa completa que contiene unas 10.000 parcelas.

Se muestra un detalle de la zona centro Ilustración 37 y de la población con las parcelas que formaron parte del entrenamiento (Ilustración 38) y las predichas por el modelo (Ilustración 39). Se añade la Ilustración 40 para una comprobación visual de estos valores.



Ilustración 36 Valencia con todas sus parcelas con valores predichos por el modelo



Ilustración 37 Detalle de la zona centro de Valencia predicha por el modelo



Ilustración 38 Detalle de la zona de Torrent que formaba parte del entrenamiento en Valencia

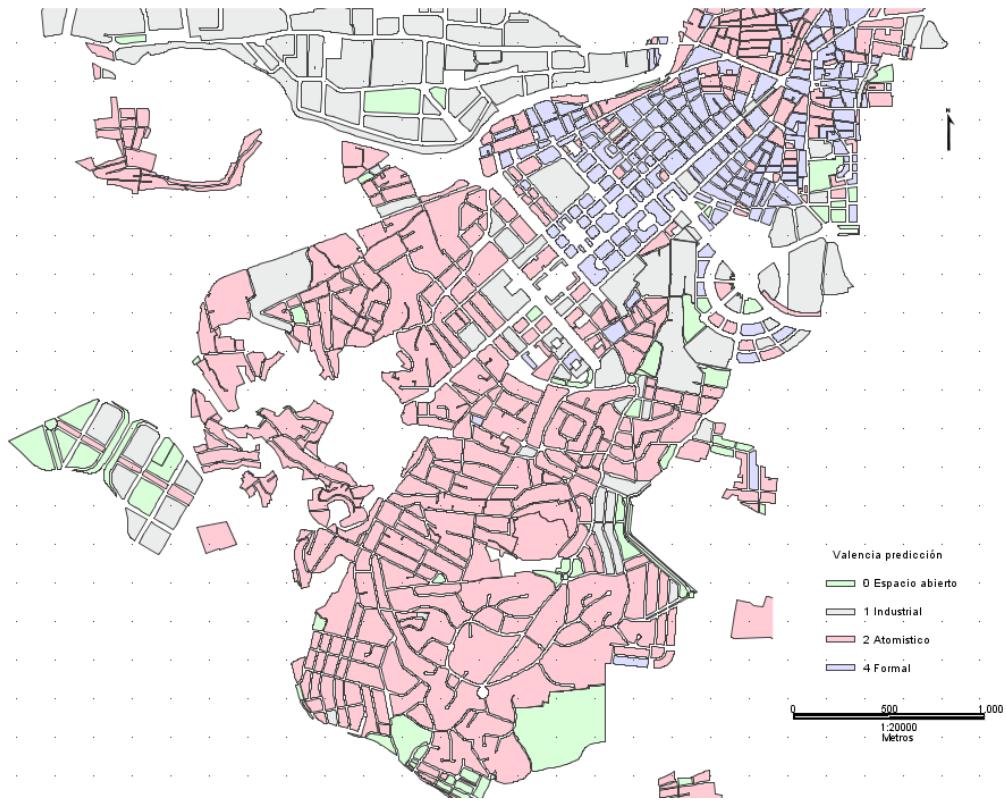


Ilustración 39 Detalle de la misma zona de la población de Torrent que la ilustración anterior predicha por el modelo



Ilustración 40 Imagen aérea de la zona de Torrent

6. Discusión

La obtención de precisiones alrededor del 85% se podría considerar un buen valor para este tipo de proyecto. Esta precisión es superior a lo que se podría haber esperado en un principio.

Al haber tanta variabilidad en las muestras por cada tipología y siendo algunas de ellas muy parecidas entre ellas, es habitual que se produzcan dudas y errores en el etiquetado incluso en especialistas formados, por lo que hablar de precisiones de este tipo, se puede considerar un éxito del modelo.

Como ya se anticipó al inicio, la realidad es más compleja que la teoría. La extracción de muestras puras es una complicación. A su vez, a la hora de etiquetar una parcela con una tipología de asentamiento es de gran dificultad al ser bastante común una ocupación mixta de ellas.

A la hora de entrenar el modelo, ya se han encontrado este tipo de problemas. Para subsanarlos se han realizado recortes en las parcelas que separan estas tipologías, pero, a la hora de predecir una parcela, este recorte no se lleva a cabo.

También durante el entrenamiento se encontraron problemas de desbalanceo de datos entre las distintas tipologías. Se tuvo que incluso buscar nuevas capas vectoriales como la del Catastro para poder sumar datos a la tipología de Espacio abierto. Para este estudio se había descartado la tipología informal, además de por los motivos alegados, por una falta de localización de zonas informales en las ciudades estudiadas.

Además, hay muestras que, sacadas del contexto respecto a sus muestras próximas, pueden considerarse de un tipo diferente al que le correspondería. Por ejemplo, muestras de tipo atomístico pueden tener una forma bastante cuadrada, pero al estar incluidas dentro de una gran zona atomística seguirían siendo atomísticas. Otro ejemplo, con este método el tamaño de las parcelas no entra en consideración ya que todas tienen el mismo tamaño de entrada en la red. Esto sería el caso de parcelas cuadradas que podrían parecer formales, pero que, por su pequeño o gran tamaño, serían de otras tipologías. Estos serían problemas que esta arquitectura de red no es capaz de tener en consideración.

Para un análisis de las ciudades, como en el estudio original, es más que suficiente con una aproximación general y un cálculo de las tipologías predominantes en cada ciudad, de ahí que el estudio se realizase anteriormente mediante muestreo. No se busca un etiquetado correcto de cada parcela, sino la proporción de ellos en una ciudad. Partir de un análisis previo para que un especialista pueda corregir posteriormente los resultados también sería otra posibilidad.

Analizando más en profundidad las matrices de confusión obtenidas, se puede observar que la matriz obtenida durante la validación no hay una diferencia o nada notable en ella. El modelo se equivoca de manera uniforme entre todas las tipologías. Solo hay un pequeño incremento en los errores de atomística y formal, pero esto es debido al número de muestras mayores que contienen estas tipologías. Esto produce que los valores de *recall* y *f1-score* sean todos muy similares.

Los datos obtenidos en la ciudad de Salamanca son muy diferentes. La precisión obtenida total baja hasta un 39%. Al tener la matriz de confusión podemos observar en detalle dónde se está cometiendo el error. Se puede observar en la matriz de confusión de Salamanca (Tabla 3) que el principal error se produce a la hora de clasificar las muestras de tipo formal, que las califica como tipo atomístico. Esto se ha mostrado ya de forma visual en los resultados de la Ilustración 33 Mapa de Salamanca etiquetado y Ilustración 34 Mapa de Salamanca predicho. El resto de los valores se comportan de una manera uniforme similar a los datos de validación. Se puede observar que el valor del *recall*, precisión que tiene en cuenta el total de la tipología etiquetada correctamente, para el atomístico llega al 90% (Ilustración 32 Matriz de confusión de Salamanca con el modelo ADAM) ya que etiqueta muy bien estos esta tipología.

El *recall* para formal cae hasta el 0.7% lo que demuestra el problema de la confusión entre ambas tipologías solo en la dirección de formales calificadas como atomísticas.

Matriz de confusión para Salamanca		Predicho			
		0 - Espacio abierto	1 - Industrial	2 - Atomístico	4 - Formal
Real	0 - Espacio abierto	166	26	48	32
	1 - Industrial	33	192	78	25
	2 - Atomístico	9	13	333	17
	4 - Formal	29	44	815	66

Tabla 3 Resumen de la tabla de confusión para Salamanca

Sin embargo, esta ciudad es muy característica ya que las zonas formales tienen estructuras que a veces parecen atomísticas. Incluso con especialistas formados para este tipo de etiquetado, existirían dudas para decidir a qué tipología corresponden. También, las manzanas formales tienen una tipología de construcción diferente al resto de ciudades y parecen peculiares de la ciudad, muy similares a las formas de las manzanas que tienen ciudades como París, con calles anchas pese a no tener siempre parcelas rectangulares o intersecciones de calle de 4 nodos. Aun así, hay zonas formales típicas que no se están clasificando correctamente, lo que solo hace agravar el error.

Otra explicación para los errores producidos en la ciudad de Salamanca sería que los datos de entrenamiento no son correctos al completo. Para el proyecto piloto se ha realizado un etiquetado rápido de las tipologías necesarias, pero se han comprobado posteriormente algunas muestras que contienen errores. La depuración de la base de datos podría mejorar en una pequeña proporción la precisión general del modelo.

Pese a esto, no está realizando un mal trabajo pese a esa baja precisión considerando que es una ciudad de la cual no tenía ninguna información y que es diferente de las ciudades que se han entrenado, equivocándose solo en las parcelas que realmente arrojan confusión. El resultado obtenido remarca la dificultad de este tipo de etiquetado en algunas ciudades y que, muchas veces, depende del digitalizador que la haga.

Respecto a los datos del detalle de la población de Torrent en Valencia. Se puede apreciar de manera visual que, en general, el modelo mantiene una buena clasificación de las parcelas, tanto de las que disponía datos, como de las que ha clasificado.

En las ilustraciones 42 y 43 se puede observar un posible uso que tendría utilizar esta metodología. El objetivo sería introducir una pequeña proporción de datos de cierta tipología, y que con estos nuevos datos, el modelo tenga suficiente para predecir el resto de las parcelas con una gran tasa de acierto. Esto puede ser muy útil porque para etiquetar ciudades grandes como París o Tokio, solo sería necesario añadir al modelo una pequeña proporción de

muestras tomadas de la ciudad, para que el resto de la ciudad se etiquete con una tasa alta de precisión.

Este resultado estaría basado en observaciones que se habían realizado previamente durante la realización del estudio del Atlas Urbano. Estas observaciones constatan que, algunas ciudades, países o continentes, tienen unas ciertas peculiaridades a la hora de construir ya sea por motivos culturales o legislativos. Esto provocaba que las reglas para etiquetar zonas por cada topología debían de ser algo flexibles y poder adaptarse mínimamente a la zona de estudio. Por ejemplo, hay zonas donde existen parcelas formales perfectamente rectangulares, pero que su ocupación interna indica que son barriadas marginales ocupadas sin ningún criterio u orden.

Todos estos factores comentados, la exclusión de tipologías y los problemas a la hora de etiquetar tipologías similares, es algo para tener en cuenta y que requeriría un mayor estudio.

7. Conclusiones y trabajo futuro

7.1. Conclusiones

El problema inicial se planteaba como un problema principalmente de recursos a la hora de la clasificación de parcelas por tipologías urbanísticas. Se han realizado estudios utilizando esta clasificación como el del Atlas de Expansión Urbana que han requerido de un gran trabajo manual para poderse realizar.

Se ha conseguido el objetivo principal en esta prueba piloto que era la demostración de que usar este tipo de redes para clasificación de parcelas urbanísticas es posible. y arroja unos resultados de alta precisión, alrededor del 85%, en su clasificación.

Se ha probado que se ha podido abordar este problema con el trabajo de una persona, en un tiempo razonable, y con recursos gratuitos y públicos, utilizando solamente imágenes y datos vectoriales, con un software libre como es gvSIG Desktop y utilizando librerías con acceso por cualquier como Keras. Esto hace que se convierta en una metodología reproducible, escalable y de bajo coste que arroja unos resultados con gran rapidez.

A su vez, se han ido cumpliendo todos los objetivos específicos planteados.

- Se ha probado que es posible realizar el estudio con recursos gratuitos y públicos, utilizando solamente imágenes y datos vectoriales, con un software libre como es gvSIG Desktop y utilizando librerías con acceso para cualquiera como Keras. Esto hace que se convierta en una metodología reproducible, escalable y de bajo coste que arroja unos resultados con gran rapidez.
- Se han conseguido desarrollar las herramientas necesarias para la extracción de muestras, su etiquetado y clasificación.
- Se ha obtenido una precisión alta que es suficiente para este tipo de estudio planteado donde antes el cálculo se realizaba mediante círculos muestrales. También se han obtenido los resultados esperados en las matrices de confusión e incluso el error de la ciudad de Salamanca era esperado con esa confusión entre tipologías atomísticas y formales.
- Se ha demostrado que existen problemas al utilizar redes sobre ciudades de las que no se disponen datos como la de Salamanca.

Con todos esto, se prueba que es posible la utilización de este tipo de redes para estudios urbanísticos cumpliendo así el objetivo principal.

Además, el aumento de información que se produce al desgranar la información por parcelas y en estos rangos de precisiones de acierto, permitirían otros tipos de estudios sobre la misma ciudad que no se habían planteado anteriormente: distribución de las tipologías a pequeña escala, cruce con datos económicos, demográficos (que suelen venir en capas divididas en parcelas similares), etc.

Sin embargo, para usos típicos con este tipo de datos, no alcanzaría los valores de precisión necesarios. Por ejemplo, hacer un estudio de cambio de tipología de parcelas. Estos cambios de uso serían puntuales en comparación con posibles errores de predicción del modelo. Sería difícil dar con cambios verdaderos ya que, además, se producen con muy poca frecuencia en el tiempo.

Existen errores como los observados en la ciudad de Salamanca, que extrapolado al posible uso de esta técnica a nivel global, implicaría que sería necesario un modelo para cada continente (o regiones más pequeñas) y no valdría un único modelo global, o mejor dicho, no valdría con entrenar la red con datos exclusivamente de una región concreta.

Con más tiempo se podrían realizar más pruebas referentes a la arquitectura de la red. La red costaba alrededor de 16 horas de entrenar, con fallos habituales del ordenador utilizado para su entrenamiento, por lo que hacer una prueba se podía alargar dos días de computación. El etiquetado de nuevas ciudades también consume mucho tiempo, así como las diferentes iteraciones hasta que se obtuvo una arquitectura con las suficientes muestras capaces de aprender con esta precisión.

Respecto a los datos, pese a que existen una gran cantidad de datos abiertos sobre parcelas o datos que podrían ser tomados de OpenStreetMap a nivel global, no todas las zonas del mundo están completamente digitalizadas y, por tanto, no se puede asumir que se vayan a tener capas vectoriales con las parcelas de las ciudades a analizar. Utilizar métodos automáticos mediante IA para la separación de parcelas o realizar análisis en forma de rejillas podrían ser soluciones al problema que se deberían de estudiar.

También, en este estudio, estamos recurriendo a imágenes aéreas del PNOA de alta resolución por debajo del metro de resolución por pixel. Se necesitaría una cobertura de todas las ciudades que se quisieran estudiar con una resolución similar a este. Hoy en día existen hasta imágenes satélites que pueden llegar a resoluciones similares que podrían ser suficientes para estos análisis, pero corresponderían a servicios de pago que podrían tener un alto coste de adquisición. Este coste sería muy alto, sobre todo, porque los análisis son interesantes de realizar en múltiples ciudades y en múltiples épocas, por lo que el coste seguiría subiendo si se quiere mantener un estudio continuado en el tiempo.

Pese a tener estas necesidades extras, abre un camino a obtener otro tipo de datos que antes no se podían plantear, se limitaban, tal y como explicamos en el estado del arte, a análisis pixel por pixel de imágenes satelitales, solo buscando si están construidas y sus vecinos, pero no su tipología.

Dado los resultados del estudio y de los conocimientos que dispongo de la materia, no creo que el camino a correcto a seguir para el análisis de ciudades sea la utilización de imágenes en exclusiva, sino una mezcla entre los datos vectoriales e imágenes satelitales.

En este proyecto ya se comienza a hacer una mezcla de ambos, separando lo que son las parcelas y las imágenes. Con unas ciudades cada vez más complejas donde existen puentes, pasos subterráneos, calles que pasar por debajo de edificios, edificios a diferentes alturas, zonas peatonales, etc es muy difícil de analizar su complejidad con exclusivamente imágenes. Un simple paso subterráneo puede crear una conexión que cambie completamente el transporte y movimiento en una zona.

Sin embargo, para el análisis del estado de las ciudades y su evolución en el tiempo, las imágenes son lo mejor que tenemos en estos momentos. Es muy difícil encontrar capas históricas vectoriales sobre el estado de, por ejemplo, las carreteras en cierto periodo. Por lo general, estos datos se suelen ir actualizando cuando se descubren que faltan datos o que se han modificado, pero no incluyen la fecha de construcción de esa vía que es lo que interesaría para conocer su evolución. Esto solo ocurre en catálogos muy especializados como podría ser una agencia estatal que se encarga del mantenimiento de las carreteras. Una imagen satélite es más completa si se tiene en cuenta que son momentos concretos en el tiempo donde se puede visualizar casi todos los datos que se necesitan, solo que son más complicados de procesar que una capa vectorial.

Tal y como se comentó al principio, se han descartado dos clasificaciones en este proyecto. Las de tipo Urban Project (proyecto urbanístico) se descartaron por su mayor complejidad a la hora de etiquetarse ya que son muy diferentes en cada zona y suele haber confusión con la etiqueta de tipología Formal. Dados los resultados obtenidos, pienso que, con unos buenos datos de entrenamiento, el modelo no tendría problemas para clasificarla. La tipología Informal, no veo el modo posible de que el modelo pudiera clasificarla bien en estos momentos. Esta tipología se define como una tipología urbanística planeada, igual que la formal, pero que no tiene desarrollados los servicios a su alrededor. Por lo general, esto se resume, en parcelas construidas con carreteras no asfaltadas. Ahora mismo en los datos de entrada no se incluyen las carreteras o servicios que rodean el edificio y, por tanto, veo imposible que con las muestras actuales se pueda clasificar correctamente. Una posible solución sería aplicar un área de influencia sobre la parcela en el momento de su extracción

de la muestra. Esto daría información al modelo de la calle que rodea las parcelas. Otra solución sería no recortar en exclusiva lo de dentro de la parcela, sino todo el recuadro de la imagen al completo sin una zona gris tapando lo que no forma parte de la parcela.

7.2. Líneas de trabajo futuro

Este proyecto permite diferentes líneas de trabajo futuro que se pueden realizar y se detallan a continuación.

- Mejora de la herramienta de gvSIG para la extracción de muestras. Se podría aumentar su funcionalidad para que permitiese una mayor cantidad de parámetros para configurar los datos de salida como el tamaño de la imagen, área de influencia a recortar, inclusión de los píxeles de alrededor, elección de las bandas de la imagen que se quieren incluir, etc.
- Plantear otras categorías de clasificado por tipo de asentamiento mejor definidas pensando en la complejidad que pueden tener este tipo de modelos de IA. La limitación a las 6 categorías que existen en el proyecto está algo limitada y tal vez demasiado resumida. Tener una IA podría permitir aumentar en mayor proporción la cantidad de tipologías existentes e incluso realizar etiquetados con combinaciones de varias de ellas según las proporciones obtenidas en la última capa de la red neuronal.
- Se podría implementar una ejecución automática a la hora de cargar imágenes o servicios de imagen en la aplicación de gvSIG Desktop. Esto permitiría que solo por el hecho de cargar una imagen se pudieran visualizar al vuelo datos categorizados.
- Modelos de expansión de ciudades según la tipología de esa ciudad. Permitiría representaciones más reales a la hora de realizar visualizaciones de las predicciones de las nuevas zonas a urbanizar con la misma tipología de edificios. Se podría resumir en designar una zona de una ciudad y que el algoritmo lo rellene con el grafismo de las construcciones típicas de esa ciudad. Esto se aplica en redes GauGAN para crear imágenes realistas.
- Sistemas automatizados de estudio de las ciudades. Tomando como base este proyecto, realizar la automatización de la localización, descarga de imágenes, procesamiento y obtención de métricas. Abriría caminos a realizar análisis global de forma masiva de manera automatizada. Se podría utilizar para las tareas de automatización GoogleEarthEngine para la descarga de imágenes por épocas y diferentes satélites que faciliten la obtención de datos.
- Nuevo tipo de categorización. Con toda la información y capacidad de cálculo que se dispone al contar con una red y no solo con trabajo humano, se podrían plantear una serie de categorías más elaboradas ya que en esta categorización a veces aparecen conceptos mezclados, por ejemplo, una zona podría ser industrial y atomística a la vez.

- Con los datos obtenidos en este mismo proyecto, se podría crear un modelo que se encargase de localizar las parcelas y separarlas entre ellas. Esto evitaría el problema de que en algunos países existiesen zonas donde no existan datos vectoriales de las ciudades a estudiar.
- Segmentación de la ciudad. Se siguen realizando análisis de crecimiento de ciudades y su construcción a nivel de imágenes satelitales con 30 metros de tamaño de pixel como son Landsat o Sentinel. Pero podemos estar en un salto tecnológico que permita etiquetar una ciudad con imágenes con pixeles de tamaño submétricos. De esta forma se podría redefinir la forma de contabilizar el crecimiento de las ciudades. Se plantea la idea de probar redes convolucionales del tipo Mask R-CNN, que, en principio, permitirían extraer los diferentes patrones de tipos de asentamiento de cada imagen. Se desconoce si ese reconocimiento de texturas o patrones de asentamiento sería posible obtenerse de ese modo. También se podrían crear otras clasificaciones interesantes como serían el nivel de construcciones de las parcelas, de alta densidad (edificios y bloques completos) o baja densidad (edificios pequeños como casas o chalets).
- Calcular otras métricas que se han quedado fuera de este estudio pero que también se necesitaban en el Atlas de Expansión Urbana. Calcular los porcentajes de parcelas construidas y espacio abierto, intersecciones, anchura de las calles, etc.
- Estudio en forma de rejilla. Plantear la posibilidad de realizar la clasificación en parcelas de mayor tamaño y en forma de rejilla. De esta forma se evitaría la necesidad de tener parcelas delimitadas para predecir una ciudad (Ilustración 41).

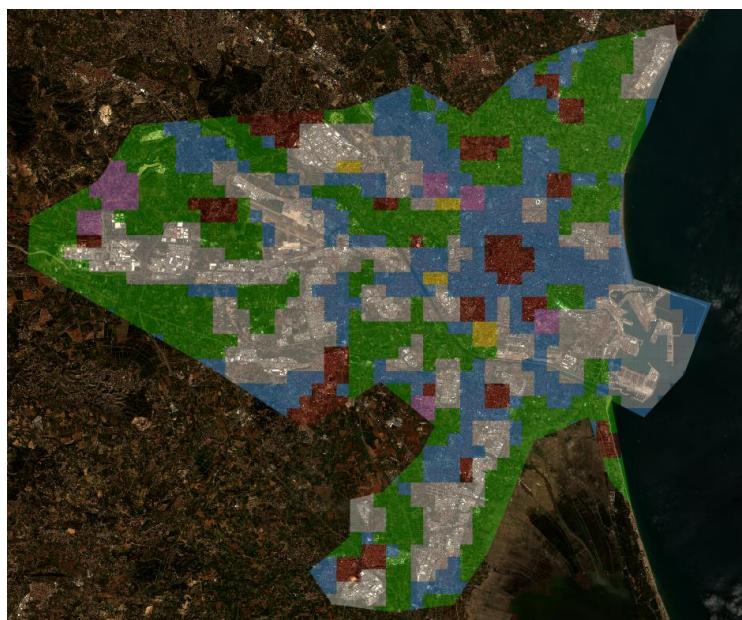


Ilustración 41 Ejemplo de una ciudad con una supuesta metodología por rejilla sobre Valencia.

Como se puede observar, la continuación de este proyecto se puede realizar por múltiples caminos, ya sean mejorando las metodologías de este o buscando aplicaciones de este nivel de detalle en esta clasificación.

8. Bibliografía

- Angel, S., Lamson-Hall, P., Blei, A., Shingade, S., & Kumar, S. (2021). Densify and Expand: A Global Analysis of Recent Urban Growth. *Sustainability, Rethinking Urban Population Density and Sustainable Cities*.
- Angel, S., Lamson-Hall, P., Madrid, M., M. Blei., A., & Parent W, J. (2016). *Atlas of Urban Expansion - Volume 2: Blocks and Roads*. Choice Reviews Online.
- Angel, S., Parent, J., Civco, D., & Blei, a. (2016). *Atlas of urban expansion - the 2016 edition, Volume 1: Areas and Densities* (Vol. 50). Choice Reviews Online.
- Auerbach, A. M. (2019). *Demanding development: The politics of public goods provision in India's urban slums*. Cambridge University Press. doi:10.1017/9781108649377
- Boeing, G. (Febrero de 2021). Spatial information and the legibility of urban form: Big data in urban morphology. *International Journal of Information Management*, 56.
- Boeing, G. (09 de March de 2021). Street Network Models and Indicators for Every Urban Area in the World. *Geographical Analysis*. doi:<https://doi.org/10.1111/gean.12281>
- Copernicus Programme. (2021). *Land Monitoring Service*. Obtenido de <https://land.copernicus.eu/local/urban-atlas>
- Doran, G. T. (1981). There's a S.M.A.R.T. way to write management's goals and objectives. *Management Review (AMA FORUM)*, 70, 35-36.
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (1 de Diciembre de 2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202, 18-27. doi:<https://doi.org/10.1016/j.rse.2017.06.031>
- gvSIG, A. (2021). *gvSIG Desktop*. Obtenido de gvSIG: www.gvsig.com
- Jianpeng Xu,Wu Xiao, Tingting He,Xinyu Deng, & Wenqi Chen. (2020). Extraction of built-up area using multi-sensor data—A case study based on Google earth engine in Zhejiang Province, China. *International Journal of Remote Sensing* , 389-404.
- K. Rouibah, & M. Belabbas. (2020). Applying Multi-Index approach from Sentinel-2 Imagery to Extract Urban Area in dry season (Semi-Arid Land in North East Algeria). *Revista de Teledetección*.

Kadhim, Mohammed Abbas, & Abed, Mohammed Hamzah. (2020). Convolutional neural network for satellite image classification. *Studies in Computational Intelligence*, 830, 165-178. doi:10.1007/978-3-030-14132-5_13

Kaiming He, Georgia Gkioxari, Piotr Dollár, & Ross Girshick. (2 de Febrero de 2020). Mask R-CNN. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 42, 386-397. doi:10.1109/TPAMI.2018.2844175

Madeleine Guyot, Araldi, A., Fusco, G., & Thomas, I. (Enero de 2021). The urban form of Brussels from the street perspective: The role of vegetation in the definition of the urban fabric. *Landscape and Urban Planning*, 205.

Martínez, Ó. (2021). *UrbanCNNProject*. Obtenido de <https://github.com/oscar9/UrbanCNNProject.git>

Meraner, A., Ebel, P., Schmitt, M., & Xiao Xiang, Zhu. (Agosto de 2020). Cloud removal in Sentinel-2 imagery using a deep residual neural network and SAR-optical data fusion. *ISPRS Journal of Photogrammetry and Remote Sensing*, 163, 333-346. doi:<https://doi.org/10.1016/j.isprsjprs.2020.05.013>

NVIDIA. (2021). <https://developer.nvidia.com/rdp/cudnn-download>. Obtenido de Descarga de CUDNN.

Roeder, L. (2021). *Netron*. Obtenido de <https://github.com/lutzroeder/Netron>

Sapena, Marta, & Ruiz, Luis A. (2021). Identifying urban growth patterns through land-use/land-cover spatio-temporal metrics: Simulation and analysis. *International Journal of Geographical Information Science*, 35, 375-396. doi:10.1080/13658816.2020.1817463

Sapena, Marta, Wurm, Michael, Taubenböck, Hannes, Tuia, Devis, & Ruiz, Luis A. (2021). Estimating quality of life dimensions from urban spatial pattern metrics. *Computers, Environment and Urban Systems*, 85, 101549. doi:10.1016/j.compenvurbsys.2020.101549

Schlosser, A., Szabó, G., Bertalan, L., Varga , Z., Enyedi , P., & Szabó , S. (26 de Julio de 2020). Building Extraction Using Orthophotos and Dense Point Cloud Derived from Visual Band Aerial Imagery Based on Machine Learning and Segmentation. *Remote Sensing*. doi:<https://doi.org/10.3390/rs12152397>

Sumbul, G., & Demir, B. (2020). A Deep Multi-Attention Driven Approach for Multi-Label Remote Sensing Image Classification. *IEEE Access*, 8, 95934 - 95946. doi:10.1109/ACCESS.2020.2995805

Sumbul, Gencer , Charfuelan, Marcela, Demir, Begüm, & Markl, Volker. (2019). Bigearthnet: A Large-Scale Benchmark Archive for Remote Sensing Image Understanding. *IEEE International Geoscience and Remote Sensing Symposium*. doi:10.1109/IGARSS.2019.8900532

Szabó, Zsuzsanna Csatáriné, Mikita, Tomáš, Négyesi, Gábor, Varga, Orsolya Gyöngyi, Burai, Péter, Takács-Szilágyi, László, & Szabó, Szilárd. (2020). Uncertainty and overfitting in fluvial landform classification using laser scanned data and machine learning: A comparison of pixel and object-based approaches. *Remote Sensing*, 12(21), 1-29. doi:10.3390/rs12213652

Taubenböck, H., Esch, T., Felbier, A., Wiesner, M., Roth, A., & Dech, S. (2012). Monitoring urbanization in mega cities from space. *Remote Sensing of Environment*, 162-176.

University., N. Y. (17-20 de 10 de 2018). The Atlas of Urban Expansion-the 2016 Edition. *HABITAT III*. Quito. Obtenido de <https://habitat3.org/the-conference/programme/all/the-atlas-of-urban-expansion-the-2016-edition/>

Vigneshwaran, S., & Vasantha Kumar, S. (2018). EXTRACTION OF BUILT-UP AREA USING HIGH RESOLUTION SENTINEL-2A AND GOOGLE SATELLITE IMAGERY. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 42, 165-169. doi:<https://doi.org/10.5194/isprs-archives-XLII-4-W9-165-2018>

Weixing Zhang, Anna K. Liljedahl, Mikhail Kanevskiy, Howard E. Epstein, Benjamin M. Jones , M. Torre Jorgenson , & Kelcy Kent. (2020). Transferability of the deep learning mask R-CNN model for automated mapping of ice-wedge polygons in high-resolution satellite and UAV images. *Remote Sensing Image Processing*. doi:<https://doi.org/10.3390/rs12071085>

Xueyi Wang, Tianqi Xie, & Longbiao Chen. (30 de Agosto de 2019). Urban Village Identification from City-Wide Satellite Images Leveraging Mask R-CNN. *Springer, Cham*, 1043. doi:https://doi.org/10.1007/978-3-030-29933-0_14

Zhang, Chi, Wei, Shiqing, Ji, Shunping, & Lu, Meng. (2019). Detecting Large-Scale Urban Land Cover Changes from Very High Resolution Remote Sensing Images Using CNN-Based Classification. *ISPRS International Journal of Geo-Information*, 189.

Anexos

Anexo. Artículo de investigación

Clasificación de tipologías de asentamientos urbanos mediante imágenes y redes neuronales convolucionales

Óscar Martínez Olmos

Universidad Internacional de la Rioja, Logroño (España)

12/9/2021

RESUMEN

Se ha realizado una nueva metodología que pretende abordar la clasificación automática de parcelas por su tipología de asentamiento urbano. Esta clasificación viene definida en el Atlas de Expansión Urbana y se corresponde a las clases de espacio abierto, industrial, atomística y formal excluyendo las tipologías de Informal y Proyecto Urbanístico. Se pretende automatizar el proceso para permitir realizar estudios urbanísticos a una mayor escala que la del proyecto original. Se ha creado una nueva base de datos con muestras para entrenar un modelo de red convolucional capaz de clasificar las parcelas. Se han obtenido unas precisiones del 86% de acierto en el modelo.

PALABRAS CLAVE

asentamientos, Atlas de Expansión Urbana, , parcelas, redes convolucionales, urbanismo.

I. INTRODUCCIÓN

El estudio de las ciudades y su crecimiento es uno de los mayores retos que afronta el urbanismo y la arquitectura moderna. La tendencia al alza de mover poblaciones del entorno rural al urbano está provocando crecimientos descontrolados [26] en las ciudades haciendo que estas cada vez sean menos óptimas para cumplir su función de ciudad. Muchas de estas ciudades no cuentan con un plan urbanístico, o no están a la altura o se desarrollan a la velocidad suficiente.

Hay ejemplos de desplazamientos masivos en, por ejemplo, ciudades de Arabia Saudí donde en los últimos 10 años se han creado numerosas ciudades desde cero y que ya acumulan millones de personas. Otras ciudades como Tokio tienen una población en su área metropolitana de 36 millones de personas, lo que provoca una serie de retos de gestión para los que el urbanismo moderno parece no estar a la altura [4].

La distribución de la gente en una ciudad implica toda una serie de recursos que hay que dedicar para que la ciudad se pueda mantener. Es necesario realizar infraestructuras de transporte, electricidad o agua por ejemplo, además de otros factores, como asegurar que los ciudadanos tengan acceso a sanidad, trabajo u otros recursos necesario como el tiendas o alimentación.

Todo esto ha provocado que se quiera conocer el estado actual de las ciudades, su ritmo de crecimiento y tipo de evolución. Para ello es necesario crear nuevas metodologías de trabajo, que permitan conocer la evolución que han tenido y se puedan replicar en el futuro para su monitoreo. La importancia de estas métricas es vital para los urbanistas que les permitirán tomar decisiones de mayor calidad.

Una característica principal que se debe de observar en las ciudades es el estudio de los tipos de asentamiento que dispone. Las tipologías de asentamientos urbanos son las siguientes:

- Industrial: Zona industrial de la ciudad, con o sin planificación urbana. Uso destinado a industria. De especial interés para determinar el crecimiento y función de una ciudad.
- Atomístico: Asentamiento que no tienen ninguna planificación. Caracterizado por ser zonas sin un planeamiento urbano. Se asimila a la forma de los centros históricos de las ciudades europeas con calles estrechas, intersecciones de tres ejes y forma de las calles irregulares no paralelas con "culs de sac".
- Formal: Asentamientos con planificación y servicios. Caracterizado por una trama urbana con patrones rectangulares, calles anchas e intersecciones de 4 ejes. La calle dispone de equipamiento público tales como aceras, asfalto, iluminación, etc.
- Informal: Asentamientos con planificación, pero sin estar completos. Con las mismas características generales de la trama urbana formal pero sin equipamientos. Por ejemplo, barrios con las parcelas cuadradas marcadas pero sin infraestructuras como carretas asfaltadas.
- Urbanizaciones: Asentamientos planificados caracterizados por producir una serie de patrones repetitivos. Normalmente situados a las afueras de las

ciudades, grandes zonas construidas la misma vez y una gran proporción de espacio verde respecto al espacio construido. Por ejemplo, urbanizaciones situadas a las afueras de ciudades importantes unifamiliares con jardín.

- Espacio abierto: Zonas sin construcciones.

Según las proporciones que tenga una ciudad en este tipo de asentamientos, sumadas a otras características como indicadores sociales o económicos, dan una idea del estado y de la calidad de vida que posee.

Para llevar a cabo el análisis de las ciudades, se puede utilizar como base el estudio Atlas de Expansión Urbana con más de 200 ciudades [1] estudio de mayor envergadura en los últimos años. En él se realizan multitud de análisis en el que intervienen desde factores espaciales a económicos.

Este tipo de estudios se deben de realizar de manera global, ya que se hace necesario conocer la evolución de las ciudades en todo el mundo para poder realizar comparaciones entre ellas. De esta forma se puede comprobar si ciertas ciudades están mejor adaptadas a este crecimiento que otras. También se puede considerar el resultado de acciones tomadas para corregir este tipo de crecimiento en el tiempo.

La problemática de este tipo de estudios es la necesidad de una gran toma de datos, en múltiples ciudades y en múltiples épocas. Uno de los principales problemas del Atlas de Expansión Urbana es que su principal fuente de datos [2] se realizaba de manera manual sobre zonas muestrales elegidas con una distribución Halton (distribución espacial cuasi aleatoria) sobre el terreno urbanizado.

Para repetir el estudio se debería de volver a realizar la toma de muestras de forma manual ciudad a ciudad, época a época. Dada la aleatoriedad en la selección de muestras, cabe la posibilidad de que algunas tipologías de asentamientos aparezcan sobrerepresentadas o infrarrepresentadas del total.

En este estudio se pretende desarrollar una metodología automatizada que solo necesite de una imagen satelital para hacer una clasificación por tipologías de asentamiento en una ciudad y una capa vectorial con las parcelas. Permitiría realizar estudios en diferentes épocas históricas gracias a imágenes satélite [28] de décadas anteriores y permitiendo que se pudieran repetir a futuro con nuevas imágenes además de poderse realizar en cualquier lugar mundo.

Se pretende crear una nueva base de datos con imágenes satelitales utilizando de base las tipologías digitalizadas manualmente durante la realización del proyecto de Atlas de Expansión Urbana. Para ello, primero se preparará una imagen satelital de Sentinel-2 o mosaico de ellas que abarque al completo toda el área de estudio de la zona designada. Se extraerá una imagen de muestra de la zona con cada tipología de asentamiento por cada ciudad. Estos datos de localización vectorial por tipología se extraen de los datos compartidos del Atlas de Expansión Urbana [3].

Con esta nueva base de datos se pretende entrenar un modelo de red neuronal convolucional que permita la clasificación de las

muestras en una clasificación por tipo de asentamiento. Permitirá que, pasada una casilla de una zona de una ciudad sin analizar, la clasifique en un tipo.

Para una ciudad nueva, se dividiría la ciudad en una cuadrícula de tamaño constante. Cada cuadrado será pasado al clasificador y obtendrá una respuesta de la tipología de asentamiento designada. Esta metodología se pone en práctica sobre una ciudad de ejemplo como es Valencia para ver los resultados obtenidos.



II. ESTADO DEL ARTE

En este tipo de clasificaciones suelen limitarse a clasificar la categoría como edificaciones y no entran en más profundidad [31]. Muchas de estas clasificaciones urbanas se basan en clasificar pixel a pixel [25] las imágenes según sus características, pero pocas veces en el reconocimiento de qué contiene realmente la imagen.

Hay otros estudios [13] que utilizan una aproximación más similar a la utilizada, pero se centran en la identificación de objetos concretos como son rotundas, intersecciones o edificios. También incluye clasificaciones por tipo de terreno, pero ninguno orientado a una clasificación por tipología urbanística ni su aplicación general a un estudio global.

La extracción de algunas características del terreno ya es algo común en el campo geoespacial [11] y se utilizan para la extracción de edificios y su clasificación utilizando imágenes satelitales multisensores. En cambio, estas clasificaciones suelen realizarse mediante cálculos matemáticos según las respuestas espectrales de los objetos en diferentes bandas. Se aprovecha de las capacidades de muchos satélites para la captura en múltiples rangos como infrarrojos o ultravioletas. Son muy utilizados el cálculo de índices como el NDVI (Normalized Difference Vegetation Index), entre otros, para la separación de zonas construidas a terrenos de cultivo [12]. También existen problemáticas a la hora de la clasificación, ya que muchas de estas clasificaciones no son absolutas sino multiclas [23]. Para ello se están utilizando aproximaciones usando métodos de inteligencia artificial como con las redes convolucionales. Como ocurre en este estudio a la hora de las tipologías de asentamiento, suelen ser muchas veces una mezcla de diferentes tipos de asentamientos en la zona designada.

La identificación de zonas urbanas usando redes convolucionales parece que ya es un hecho que investigadores están utilizando como base de sus estudios. Las redes neuronales ya se están utilizando en el campo de la Teledetección para diferentes

tareas automáticas y de preprocessado de imágenes como las de limpieza de nubes en imágenes satelitales [17]. Además, estas redes han probado su funcionalidad para la detección de edificaciones a partir de imágenes satelitales [30]. En conjugación con redes más específicas como las de Mask R-CNN utilizadas para una segmentación de la región más detallada sobre una imagen [14] y no solo su clasificación de la imagen como un todo, son capaz de localizar con mayor exactitud que píxeles de las imágenes corresponden a edificaciones y cuáles no. Esto permite ya no solo localizar edificaciones, sino, de una forma sencilla, acotar mediante polígonos concretos el edificio construido u otro tipo de clasificaciones sobre imágenes satelitales según el modelo entrenado [29] por lo que se postulan como una herramienta de gran potencial en el campo de la Teledetección.

De la misma forma, se ha estudiado la utilización de la herramienta de Google Earth Engine [7][9] para el procesamiento de las imágenes y la extracción de muestras. Esta herramienta permite mediante pocas líneas de código el procesamiento y acceso a multitud de servicios de imágenes satelitales y realizar de forma automática tareas de corrección o filtrado. Sin embargo, en esta plataforma, el acceso a imágenes de gran resolución no está disponible al tener acceso restringido o de pago. Pero dado su potencial se postula como una herramienta prometedora para el procesamiento de muestras satelitales para modelos de inteligencia artificial.

En el caso de Urban atlas [7] están centrados en el uso concreto de las parcelas, Ilustración 8. Esta capa es el resultado más similar a lo que se busca obtener en este proyecto en un resultado final. Sin embargo, es un resultado que no se ajusta a lo que se busca en el proyecto ya que no guarda relación con el tipo de entramado urbano, sino con el uso de la parcela. Sin duda, es un dato muy interesante para utilizar en los análisis pudiendo cruzar los resultados del uso de la parcela con el de la tipología de la parcela.

Existen estudios que están intentando realizar tareas similares de etiquetados por tipologías, en este caso asociados a los patrones de las calles [5] Ilustración 9. Se utilizan bases de datos abiertas como sobre OpenStreetMap para la obtención de las calles. Se utilizan unas ideas similares en cuanto al aprovechamiento de datos y fuentes abiertas. En este caso es un estudio puramente estadístico donde no es necesaria una aplicación de técnicas de inteligencia artificial. La conjunción de este tipo de estudio con el que se propone en este proyecto podría ser de mucho interés, ya que algunas de las características importantes de los diferentes tipos de asentamientos son calculadas en este estudio. Por ejemplo, las clasificaciones de tipo Formal se caracterizan por intersecciones de 4 ejes o más, longitudes de calles de tamaño medio o bajo y polígonos rectangulares, indicativo de calles paralelas. La tipología atomística se caracteriza por nodos con cruces de 3 ejes. Las de tipo Industrial por ejes de un mayor tamaño a la media.

En última instancia, el proyecto también busca localizar las posibles carencias que se encuentran en las ciudades como son la falta de espacios abiertos y vegetación en las ciudades. Además, se ha probado que la vegetación se tiene que estudiar también con el punto de vista del ciudadano a pie y su percepción de la zona urbana [15]. Esto produce que un análisis aéreo de una zona, como el que se plantea en este proyecto, puede no ser suficiente a la hora de valorar si ciertos tipos de trámites urbanos son o no son convenientes para la mejora del bienestar de una ciudad.

Pese a todos los estudios repasados, ninguno utiliza la clasificación del trámite urbano presentada por el Atlas de Expansión Urbana. Se suelen optar por clasificaciones más exactas basadas en aproximaciones estadísticas como clasificación de usos según sus métricas, pero no una definición del trámite urbano por sus características visuales, más allá de la pura estadística.

Una misma parcela según sus características de, por ejemplo, intersecciones de nodos, altura media, tamaño, longitud, etc., puede ser, a la hora de la realidad si se examina su contenido de manera visual y no puramente sus estadísticas urbanas, de cualquiera de los tipos existentes. Esto plantea posibles soluciones, pero también posibles problemas dada la subjetividad de esta clasificación entre algunos tipos concretos de tipologías de asentamiento.

Esta subjetividad está relacionada con el hecho de que esta tipología es el agrupamiento de una serie de métricas de muy diversos factores que son las que deciden el resultado. Algunas métricas que pueden participar en esto serían factibles de calcular como longitud de tramos, anchura de calles, etc. El problema de algunas de estas métricas es su dificultad de calcular como por ejemplo el número de equipamientos que tiene una calle (asfaltada, con iluminación, aceras) que además puede ser diferente entre zonas, u otras métricas, como pueden ser la calidad de edificaciones en un mismo bloque como los hacinamientos vistos en barrios marginales como en el ejemplo de Kowloon, que pese a ser un bloque cuadrado, se encuentra edificado de forma muy irregular.

Al realizar esta tarea de forma manual por un digitalizador, entra en conjunción una serie de parámetros que no siempre se aplican de la misma forma, por lo que realizar alguna de estas clasificaciones mediante árboles de decisión o técnicas similares las harían inviables.

Se va a estudiar si las redes convolucionales gestionan mejor esta subjetividad que una serie de rangos definidos dentro de unos parámetros definidos.

III. OBJETIVOS Y METODOLOGÍA

En este estudio se desarrolla una metodología que mediante el uso de redes convolucionales permita la clasificación de parcelas urbanísticas según su tipología de asentamiento. Esta clasificación se realizará teniendo solamente la imagen aérea de la parcela y obteniendo como resultado la categoría a la que pertenece. Se busca demostrar que la aplicación de metodologías de Inteligencia Artificial en este tipo de estudios puede ser de gran utilidad.

Este proceso permitiría realizar estudios en diferentes épocas históricas gracias a imágenes satélite o de imágenes aéreas como las realizadas en España del PNOA (Plan Nacional de Ortofotografía Aérea) de décadas anteriores y permitiendo que se pudieran repetir a futuro con nuevas imágenes. Además, se podría aplicar de forma masiva en todo el globo, pudiéndose repetir el estudio siempre que hubiera una actualización de las parcelas o se quisiera clasificar una nueva ciudad. De esta forma, se busca una metodología que, en un tiempo factible de procesamiento, permita un estudio de las ciudades de manera automatizada.

Se propone esta tecnología para abordar uno de los problemas principales durante la elaboración del Atlas de Expansión Urbana que era la falta de mano de obra cualificada que pudiera etiquetar una ciudad de estudio. El estudio original se limitaba a zonas muestrales de la ciudad en 200 ciudades seleccionadas de más de 100.000 habitantes, una vez creada un sistema como el que se propone, no debería de existir ninguna limitación para categorizar zonas o número de ciudades. Estas 200 ciudades se seleccionaron de entre 4000 que cumplían esas características.

En esta propuesta, el trabajo manual se debe mantener sobre todo en las partes iniciales donde se necesita crear una base de datos que permita el entrenamiento de una red neuronal o que corrobore los resultados otorgados por esta. Sin embargo, hay una gran diferencia en términos de recursos humanos que se necesitan reduciéndose en gran cantidad y pudiéndose dar el caso en llegar

al punto en que ya no fuera necesario preparar más datos y convertirse en un proceso completamente automatizado.

Incluso así, la preparación de los datos y la obtención de muestras se ha convertido en un proceso muy rápido de hacer al haberse eliminado las partes de preparación de muestras, círculos muestrales y procesamiento de datos estadísticos necesarios después de realizar cada muestra para comprobar si había que seguir creando más muestras. De esta forma, se convierte en un proyecto factible de realizar en unas escalas de trabajo en número de ciudades analizadas y de tiempo realizado que antes no se podría haber hecho. Además, suple la carencia del proceso anterior que solo utilizaba zonas muestrales de una ciudad, pudiendo estudiarse todas y cada una de las parcelas de forma individual.

La realización de este tipo de estudios cobra una gran relevancia dado la situación global en la que nos encontramos. Ya no solo el clásico movimiento de entornos rurales a entornos urbanos o el crecimiento natural de la población, sino que cualquier noticia puede tener un impacto global, ya sea por situaciones de desigualdad de derechos, desigualdad económica, trabajo, climáticas, militares, entre otras, que pueden implicar movimientos masivos de poblaciones entre diferentes ciudades, naciones o continentes en cortos períodos de tiempo.

Las ciudades se están convirtiendo en aglomeraciones de personas masivas con un gran coste de personal y económico para mantenerlas en funcionamiento. Estos estudios pueden ayudar a prever necesidades urbanísticas y adelantarse a lo que podrían ser el colapso de ciudades. Una ciudad que no puede proveer de servicios mínimos de transporte, seguridad o habitabilidad no se puede desarrollar con éxito y puede provocar puntos de no retorno donde una ciudad puede no ser factible de mantener para un estado, con una menor entrada de dinero y un mayor coste económico de mantenimiento dada su superficie, servicios, etc. Esto ya ha ocurrido en ciudades como Brasilia que por su tipología de urbanismo durante su diseño han tenido graves problemas durante su crecimiento.

Por lo tanto, como objetivo último, se pretende determinar si la creación de esta nueva metodología otorga resultados que permitan aumentar y abarcar una mayor cantidad de estudios que hasta ahora no eran abordables. Los motivos pueden ser varios, pero los principales son por falta de datos procesados, los cuales hay que crear con digitalizadores expertos en el tema y una elevada cantidad de horas de trabajo manual.

También se buscan nuevas formas de realizar estos y posibles nuevos estudios que se adapten a las cada vez más grandes y más complejas ciudades.

Los objetivos específicos son:

- Explorar los diferentes recursos de imágenes aéreas y software para este proyecto. Comprobar que los recursos seleccionados de imágenes aéreas del PNOA y de CartoCiudad son suficientes para este estudio.
- Desarrollar herramienta para el etiquetado para la creación de la base de datos y la extracción de imágenes muestras.
- Diseñar una metodología reproducible y escalable con una red convolucional.
- Calcular la precisión de la red para clasificar para cada tipo de asentamiento urbano. Comprobar que las redes convolucionales son aptas para esta tarea.
- Evaluar si una red entrenada con los datos de una ciudad es extrapolable a ciudades sin datos.

- Determinar si es factible la utilización de esta metodología para este proyecto de clasificación de asentamientos urbanos o para otros proyectos. Se plantea la siguiente metodología. Entrenar un modelo de red neuronal convolucional que aprenda a diferenciar los diferentes tipos de asentamientos. Los datos de entrenamiento serán extraídos de una fuente de datos creada para este proyecto, creando una base de datos nueva que extraiga imágenes de las parcelas vectoriales etiquetadas de una tipología.

Se utilizarán imágenes aéreas del PNOA (Plan Nacional de Ortofotografía Aérea), de CartoCiudad y de la Sede del Catastro. Estos recursos se explicarán luego en mayor profundidad.

Las herramientas desarrolladas en el proyecto, la creación de mapas y el procesamiento de las capas tanto vectoriales como de imágenes se ha realizado utilizando el software de gvSIG Desktop [10]. Este programa open source es un Sistema de Información Geográfica desarrollado en la Comunidad Valencia con muchos años de recorrido actualmente a cargo de la Asociación gvSIG y que está libre para su descarga. Para este proyecto se ha utilizado una versión en desarrollo etiquetada como gvSIG Desktop 2.6.0.3218. Los programas realizados deberían de ser usables incluso en versiones anteriores a esta. El desarrollo se ha realizado haciendo uso del módulo de Scripting donde se desarrolla utilizando Jython. Estos se desarrollan con una sintaxis de Python pero pudiendo utilizar librerías Java en él.

El repositorio con las herramientas utilizadas es público y de acceso gratuito [16]. Se ha utilizado un ordenador i7 con 64gb de RAM y una tarjeta gráfica ATI GeForce GTX 1070 con Windows 10 64bits y CudaCNN instalado [18].

El etiquetado de las parcelas para su extracción se realizará en gvSIG Desktop. Se situarán la capa vectorial a etiquetar encima de la imagen y se irá realizando el etiquetado.

Una vez concluido el etiquetado de las diferentes ciudades, se realizará un recorte de las parcelas y se estructurarán en carpetas acordes al formato que acepta Keras para entrenar el modelo de red convolucional.

Se realizará la arquitectura del modelo y se procederá al entrenamiento.

Con el modelo entrenado se hará una evaluación de este, tanto de los datos obtenidos durante su entrenamiento como de la matriz de confusión obtenida entre las diferentes tipologías. Se procederá a hacer una validación sobre una ciudad la cual no haya formado parte del entrenamiento.

También se realizará una prueba de etiquetado de una ciudad que haya formado parte del entrenamiento, pero sobre toda su extensión ya que para entrenar el modelo no se utilizar todas las parcelas de las ciudades seleccionadas.

IV. CONTRIBUCIÓN

Se ha desarrolla una metodología que pretende solucionar uno de los problemas a la hora de etiqueta del proyecto del Atlas de Expansión Urbana. Se aporta una solución libre de bajo coste que podría ser implementada en diversos proyectos de estudio urbanísticos.

V. RESULTADOS

Descripción de los resultados (Tipo 1. Piloto Experimental)

En la Tabla 1 se puede comparar rápidamente los valores obtenidas durante el entrenamiento del modelo y sobre la ciudad de Salamanca.

Precisión por tipología	Validación	Salamanca
0 - Espacio abierto	95%	70%
1 - Industrial	78%	70%
2 - Atomístico	82%	26%
4 - Formal	85%	47%
Total	86%	39%

Tabla 1. Resumen de los datos de precisión obtenidos divididos por tipologías para los datos de validación y los de Salamanca.

En la Tabla 2 se puede comparar rápidamente los valores obtenidas durante el entrenamiento del modelo y sobre la ciudad de Salamanca.

Matriz de confusión	de	Predicho			
		0	1	2	4
Real	0	166	26	48	32
	1	33	192	78	25
	2	9	13	333	17
	4	29	44	815	66

Tabla 2. Matriz de confusión para la clasificación de los datos de validación de Salamanca.

En las siguientes Ilustraciones 1 y 2 se puede observar el aspecto que tienen los datos etiquetados de la ciudad de Salamanca y los predichos por el modelo.



Ilustración 1 Mapa de Salamanca etiquetado

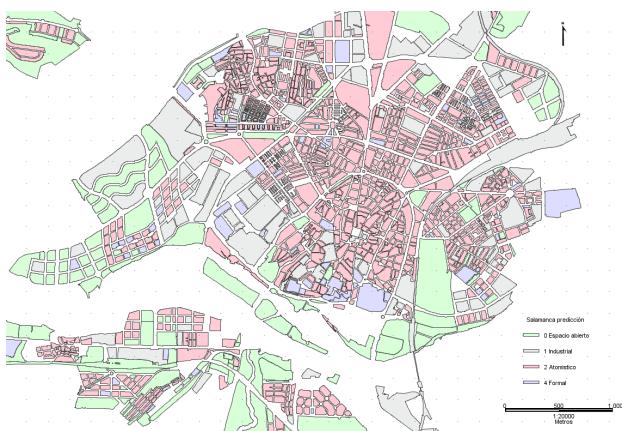


Ilustración 2 Mapa de Salamanca predicho

VI. DISCUSIÓN

La obtención de precisiones alrededor del 85% se podría considerar un buen valor para este tipo de proyecto. Esta precisión es superior a lo que se podría haber esperado en un principio.

Al haber tanta variabilidad en las muestras por cada tipología y siendo algunas de ellas muy parecidas entre ellas, es habitual que se produzcan dudas y errores en el etiquetado incluso en especialistas formados, por lo que hablar de precisiones de este tipo, se puede considerar un éxito del modelo.

Analizando más en profundidad las matrices de confusión obtenidas, se puede observar que la matriz obtenida durante la validación no hay una diferencia o nada notable en ella. El modelo se equivoca de manera uniforme entre todas las tipologías. Solo hay un pequeño incremento en los errores de atomística y formal, pero esto es debido al número de muestras mayores que contienen estas tipologías. Esto produce que los valores de recall y f1-score sean todos muy similares.

Los datos obtenidos en la ciudad de Salamanca son muy diferentes. La precisión obtenida total baja hasta un 39%. Al tener la matriz de confusión podemos observar en detalle dónde se está cometiendo el error. Se puede observar en la matriz de confusión de Salamanca (Tabla 3) que el principal error se produce a la hora de clasificar las muestras de tipo formal, que las califica como tipo atomística. Esto se ha mostrado ya de forma visual en los resultados de la Ilustración 33 Mapa de Salamanca etiquetado y Ilustración 34 Mapa de Salamanca predicho. El resto de los valores se comportan de una manera uniforme similar a los datos de validación. Se puede observar que el valor del recall, precisión que tiene en cuenta el total de la tipología etiquetada correctamente, para el atomístico llega al 90% (Ilustración 32 Matriz de confusión de Salamanca con el modelo ADAM) ya que etiqueta muy bien estos esta tipología. El recall para formal cae hasta el 0.7% lo que demuestra el problema de la confusión entre ambas tipologías solo en la dirección de formales calificadas como atomísticas.

Sin embargo, esta ciudad es muy característica ya que las zonas formales tienen estructuras que a veces parecen atomísticas. Incluso con especialistas formados para este tipo de etiquetado, existirían dudas para decidir a qué tipología corresponden. También, las manzanas formales tienen una tipología de construcción diferente al resto de ciudades y parecen peculiares de la ciudad, muy similares a las formas de las manzanas que tienen ciudades como París, con calles anchas pese a no tener siempre parcelas rectangulares o intersecciones de calle de 4 nodos. Aun así, hay zonas formales típicas que no se están clasificando correctamente, lo que solo hace agravar el error.

Pese a esto, no está realizando un mal trabajo pese a esa baja precisión considerando que es una ciudad de la cual no tenía ninguna información y que es diferente de las ciudades que se han entrenado, equivocándose solo en las parcelas que realmente arrojan confusión. El resultado obtenido remarca la dificultad de este tipo de etiquetado en algunas ciudades y que, muchas veces, depende del digitalizador que la haga.

Respecto a los datos del detalle de la población de Torrent en Valencia. Se puede apreciar de manera visual que, en general, el modelo mantiene una buena clasificación de las parcelas, tanto de las que disponía datos, como de las que ha clasificado.

Esto puede ser muy útil porque para etiquetar ciudades grandes como París o Tokio, solo sería necesario añadir al modelo una pequeña proporción de muestras tomadas de la ciudad, para que el resto de la ciudad se etique con una

tasa alta de precisión.

VII. CONCLUSIONES

El problema inicial se planteaba como un problema

principalmente de recursos a la hora de la clasificación de parcelas por tipologías urbanísticas. Se han realizado estudios utilizando esta clasificación como el del Atlas de Expansión Urbana que han requerido de un gran trabajo manual para poderse realizar.

Con esta prueba piloto se demuestra que una metodología de este tipo es factible para su uso en este tipo de estudios y que los rangos de precisión que dan de alrededor del 85% son un muy buen resultado.

Se ha probado que se ha podido abordar este problema con el trabajo de una persona, en un tiempo razonable, y con recursos gratuitos y públicos, utilizando solamente imágenes y datos vectoriales, con un software libre como es gvSIG Desktop y utilizando librerías con acceso por cualquier como Keras. Esto hace que se convierta en una metodología reproducible, escalable y de bajo coste que arroja unos resultados con gran rapidez.

Tal y como se comentó al principio, se han descartado dos clasificaciones en este proyecto. Las de tipo Urban Project (proyecto urbanístico) se descartaron por su mayor complejidad a la hora de etiquetarse ya que son muy diferentes en cada zona y suele haber confusión con la etiqueta de tipología Formal. Dados los resultados obtenidos, pienso que, con unos buenos datos de entrenamiento, el modelo no tendría problemas para clasificarla. La tipología Informal, no veo el modo posible de que el modelo pudiera clasificarla bien en estos momentos. Esta tipología se define como una tipología urbanística planeada, igual que la formal, pero que no tiene desarrollados los servicios a su alrededor. Por lo general, esto se resume, en parcelas construidas con carreteras no asfaltadas. Ahora mismo en los datos de entrada no se incluyen las carreteras o servicios que rodean el edificio y, por tanto, veo imposible que con las muestras actuales se pueda clasificar correctamente. Una posible solución sería aplicar un área de influencia sobre la parcela en el momento de su extracción de la muestra. Esto daría información al modelo de la calle que rodea las parcelas. Otra solución sería no recortar en exclusiva lo de dentro de la parcela, sino todo el recuadro de la imagen al completo sin una zona gris tapando lo que no forma parte de la parcela.

Durante este proyecto se ha llegado con éxito a todos los objetivos específicos que se buscaban. Se ha demostrado que un modelo mediante redes convolucionales con datos de entrenamiento preparados por un experto en el tema, pueden llegar a dar un resultado de alta precisión para la categorización de parcelas por tipología urbanística lo suficientemente preciso para realizar estudios sobre una o varias ciudades.

REFERENCIAS

- [1] Angel, S., Lamson-Hall, P., Blei, A., Shingade, S., & Kumar, S. (2021). Densify and Expand: A Global Analysis of Recent Urban Growth. *Sustainability, Rethinking Urban Population Density and Sustainable Cities*.
- [2] Angel, S., Lamson-Hall, P., Madrid, M., M. Blei, A., & Parent W, J. (2016). *Atlas of Urban Expansion - Volume 2: Blocks and Roads*. Choice Reviews Online.
- [3] Angel, S., Parent, J., Civco, D., & Blei, a. (2016). *Atlas of urban expansion - the 2016 edition, Volume 1: Areas and Densities* (Vol. 50). Choice Reviews Online.
- [4] Auerbach, A. M. (2019). Demanding development: The politics of public goods provision in India's urban slums. Cambridge University Press. doi:10.1017/9781108649377
- [5] Boeing, G. (Febrero de 2021). Spatial information and the legibility of urban form: Big data in urban morphology. *International Journal of Information Management*, 56.
- [6] Boeing, G. (09 de March de 2021). Street Network Models and Indicators for Every Urban Area in the World. *Geographical Analysis*. doi:<https://doi.org/10.1111/gean.12281>
- [7] Copernicus Programme. (2021). Land Monitoring Service. Obtido de <https://land.copernicus.eu/local/urban-atlas>
- [8] Doran, G. T. (1981). There's a S.M.A.R.T. way to write management's goals and objectives. *Management Review (AMA FORUM)*, 70, 35-36.
- [9] Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (1 de Diciembre de 2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202, 18-27. doi:<https://doi.org/10.1016/j.rse.2017.06.031>
- [10] gvSIG, A. (2021). gvSIG Desktop. Obtido de [gvSIG: www.gvsig.com](http://www.gvsig.com)
- [11] Jianpeng Xu, Wu Xiao, Tingting He, Xinyu Deng, & Wenqi Chen. (2020). Extraction of built-up area using multi-sensor data—A case study based on Google earth engine in Zhejiang Province, China. *International Journal of Remote Sensing*, 389-404.
- [12] K. Rouibah, & M. Belabbas. (2020). Applying Multi-Index approach from Sentinel-2 Imagery to Extract Urban Area in dry season (Semi-Arid Land in North East Algeria). *Revista de Teledetección*.
- [13] Kadhim, Mohammed Abbas, & Abed, Mohammed Hamzah. (2020). Convolutional neural network for satellite image classification. *Studies in Computational Intelligence*, 830, 165-178. doi:10.1007/978-3-030-14132-5_13
- [14] Kaiming He, Georgia Gkioxari, Piotr Dollár, & Ross Girshick. (2 de Febrero de 2020). Mask R-CNN. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 42, 386-397. doi:10.1109/TPAMI.2018.2844175
- [15] Madeleine Guyot, Araldi, A., Fusco, G., & Thomas, I. (Enero de 2021). The urban form of Brussels from the street perspective: The role of vegetation in the definition of the urban fabric. *Landscape and Urban Planning*, 205.
- [16] Martínez, Ó. (2021). UrbanCNNProject. Obtido de <https://github.com/oscar9/UrbanCNNProject.git>
- [17] Meraner, A., Ebel, P., Schmitt, M., & Xiao Xiang, Zhu. (Agosto de 2020). Cloud removal in Sentinel-2 imagery using a deep residual neural network and SAR-optical data fusion. *ISPRS Journal of Photogrammetry and Remote Sensing*, 333-346. doi:<https://doi.org/10.1016/j.isprsjprs.2020.05.013>
- [18] NVIDIA. (2021). <https://developer.nvidia.com/cudnn-download>. Obtido de Descarga de CUDNN.
- [19] Roeder, L. (2021). Netron. Obtido de <https://github.com/lutzroeder/Netron>
- [20] Sapena, Marta, & Ruiz, Luis A. (2021). Identifying urban growth patterns through land-use/land-cover spatio-temporal metrics: Simulation and analysis. *International Journal of Geographical Information Science*, 35, 375-396. doi:10.1080/13658816.2020.1817463
- [21] Sapena, Marta, Wurm, Michael, Taubenböck, Hannes, Tuia, Devis, & Ruiz, Luis A. (2021). Estimating quality of life dimensions from urban spatial pattern metrics. *Computers, Environment and Urban Systems*, 85, 101549. doi:10.1016/j.compenvurbsys.2020.101549
- [22] Schlosser, A., Szabó, G., Bertalan, L., Varga , Z., Enyedi , P., & Szabó , S. (26 de Julio de 2020). Building Extraction Using Orthophotos and Dense Point Cloud Derived from Visual Band Aerial Imagery Based on Machine Learning and Segmentation. *Remote Sensing*. doi:<https://doi.org/10.3390/rs12152397>
- [23] Sumbul, G., & Demir, B. (2020). A Deep Multi-Attention Driven Approach for Multi-Label Remote Sensing Image Classification. *IEEE Access*, 8, 95934 - 95946. doi:10.1109/ACCESS.2020.2995805
- [24] Sumbul, Gencer , Charfuelan, Marcela, Demir, Begüm, & Markl, Volker. (2019). Bigearthnet: A Large-Scale Benchmark Archive for Remote Sensing Image Understanding. *IEEE International Geoscience and Remote Sensing Symposium*. doi:10.1109/IGARSS.2019.8900532
- [25] Szabó, Zsuzsanna Csatáriné, Mikita, Tomáš, Négyesi, Gábor, Varga, Orsolya Gyöngyi, Burai, Péter, Takács-Szilágyi, László, & Szabó, Szilárd. (2020). Uncertainty and overfitting in fluvial landform classification using laser scanned data and machine learning: A comparison of pixel and object-based approaches. *Remote Sensing*, 12(21), 1-29. doi:10.3390/rs12213652
- [26] Taubenböck, H., Esch, T., Felbier, A., Wiesner, M., Roth, A., & Dech, S. (2012). Monitoring urbanization in mega cities from space. *Remote Sensing of Environment*, 162-176.

- [27] University., N. Y. (17-20 de 10 de 2018). The Atlas of Urban Expansion-the 2016 Edition. HABITAT III. Quito. Obtenido de <https://habitat3.org/the-conference/programme/all/the-atlas-of-urban-expansion-the-2016-edition/>
- [28] Vigneshwaran, S., & Vasantha Kumar, S. (2018). EXTRACTION OF BUILT-UP AREA USING HIGH RESOLUTION SENTINEL-2A AND GOOGLE SATELLITE IMAGERY. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives, 42, 165-169. doi:<https://doi.org/10.5194/isprs-archives-XLII-4-W9-165-2018>
- [29] Weixing Zhang, Anna K. Liljedahl, Mikhail Kanevskiy, Howard E. Epstein, Benjamin M. Jones , M. Torre Jorgenson , & Kelcy Kent. (2020). Transferability of the deep learning mask R-CNN model for automated mapping of ice-wedge polygons in high-resolution satellite and UAV images. Remote Sensing Image Processing. doi:<https://doi.org/10.3390/rs12071085>
- [30] Xueyi Wang, Tianqi Xie, & Longbiao Chen. (30 de Agosto de 2019). Urban Village Identification from City-Wide Satellite Images Leveraging Mask R-CNN. Springer, Cham, 1043. doi:https://doi.org/10.1007/978-3-030-29933-0_14
- [31] Zhang, Chi, Wei, Shiqing, Ji, Shuping, & Lu, Meng. (2019). Detecting Large-Scale Urban Land Cover Changes from Very High Resolution Remote Sensing Images Using CNN-Based Classification. ISPRS International Journal of Geo-Information, 189.