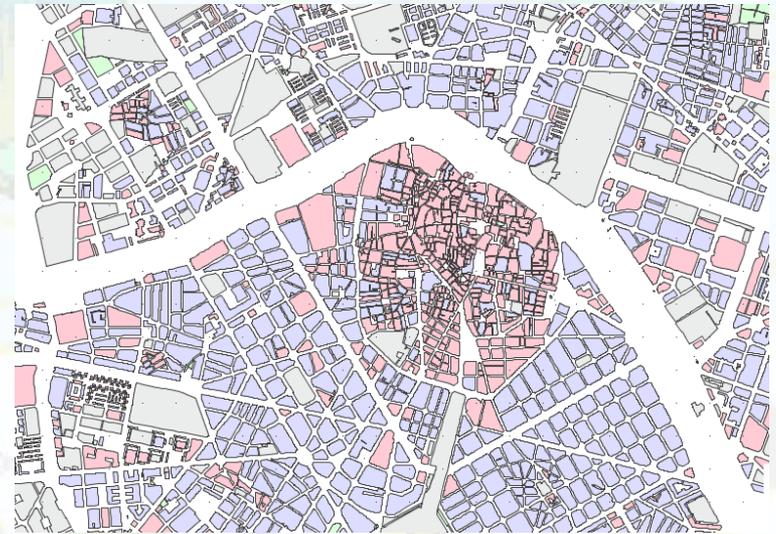


Clasificación de tipologías de asentamientos urbanos mediante imágenes y redes neuronales convolucionales



En contexto..

- ▶ Proyecto de fin de Master en Inteligencia Artificial
- ▶ Proyecto de prototipo piloto
- ▶ Experiencia en proyecto de **Atlas of Urban Expansion**

<https://www.lincolnst.edu/research-data/data/atlas-urban-expansion>

Índice

- ▶ 1. Introducción
- ▶ 2. Contexto y Estado del arte
- ▶ 3. Objetivos
- ▶ 4. Metodología y descripción del experimento
- ▶ 5. Resultados
- ▶ 6. Discusión
- ▶ 7. Conclusiones y trabajo futuro

1. Introducción



1.1. Introducción: Motivación

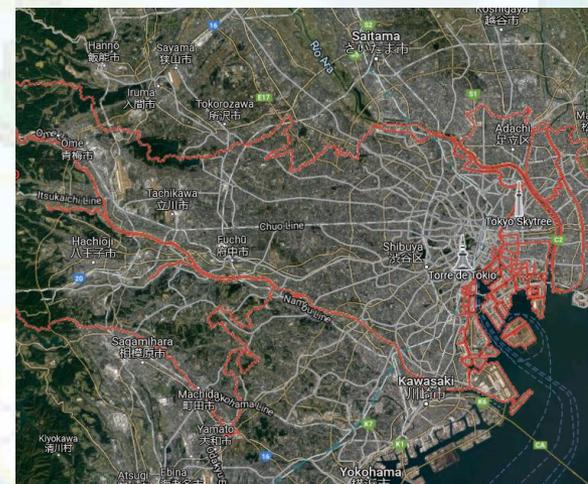
Problemas urbanísticos del siglo XXI:

- Aumento de población descontrolado en las ciudades
- Crecimiento insostenible: en expansión no en densidad

Dubai, Arabia Saudita



Tokyo, Japón



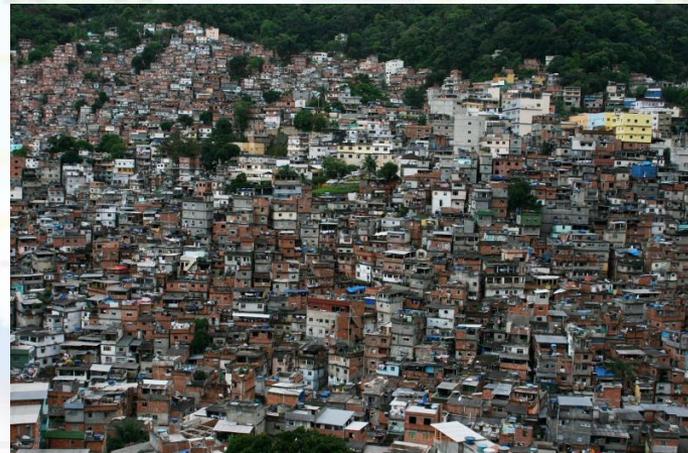
1.1. Introducción: Motivación

Producen problemas asociados a la trama urbana:

- Carencia de infraestructuras básicas
- Aumento de costes de mantenimiento
- Desigualdad social
- Movilidad
- Barrios marginales (slums)



Kowloon, China



Rocinha, Rio de Janeiro , Brasil



1.1. Introducción: Motivación

Mala planificación urbanística

- De diseño
- Histórica
- Por crecimiento
- ...



Brasilia, Brasil



1.1. Introducción: Motivación

Casco antiguo de Valencia, España



2. Contexto y Estado del arte

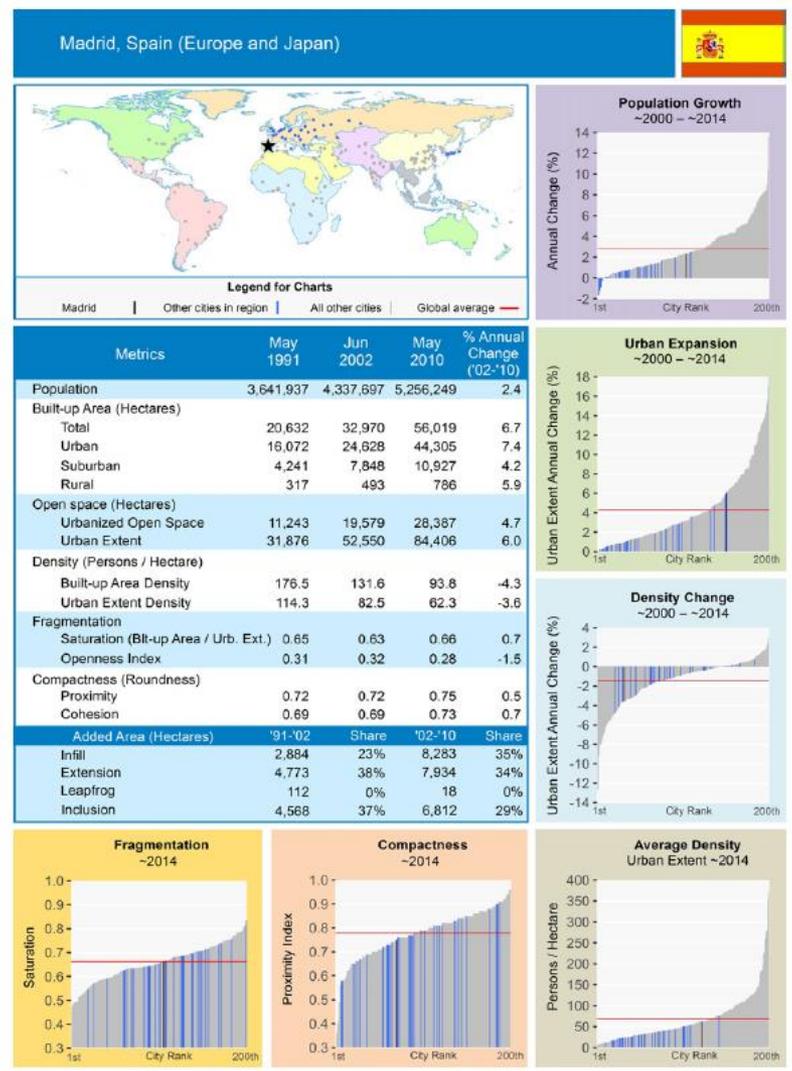
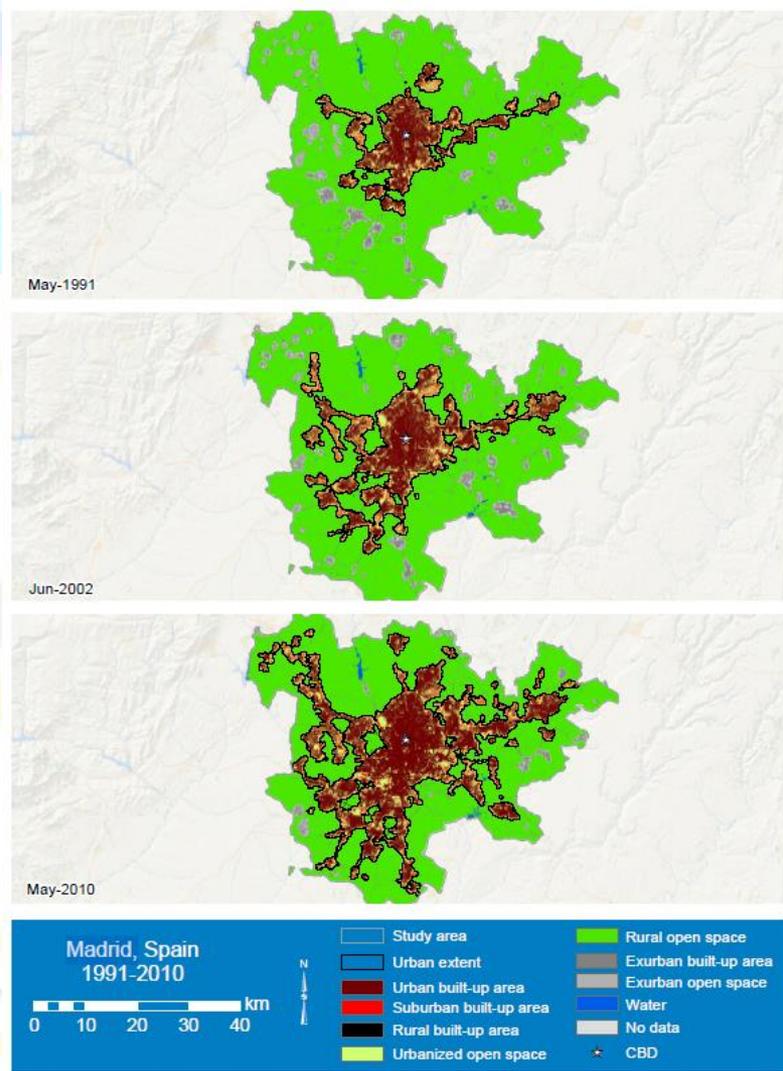


2.1. Contexto

Estudio de las ciudades: Atlas de Expansión Urbana

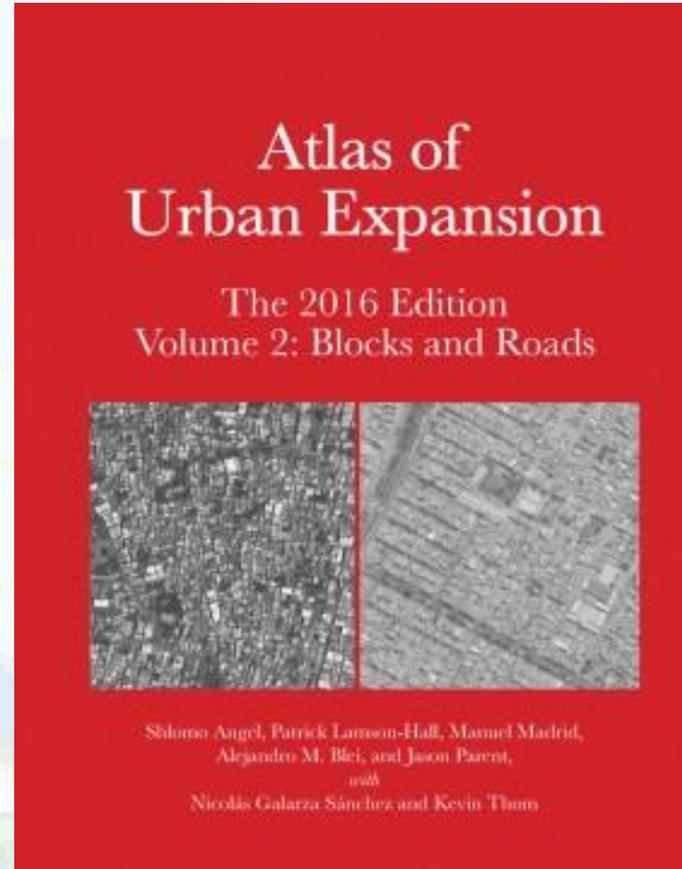
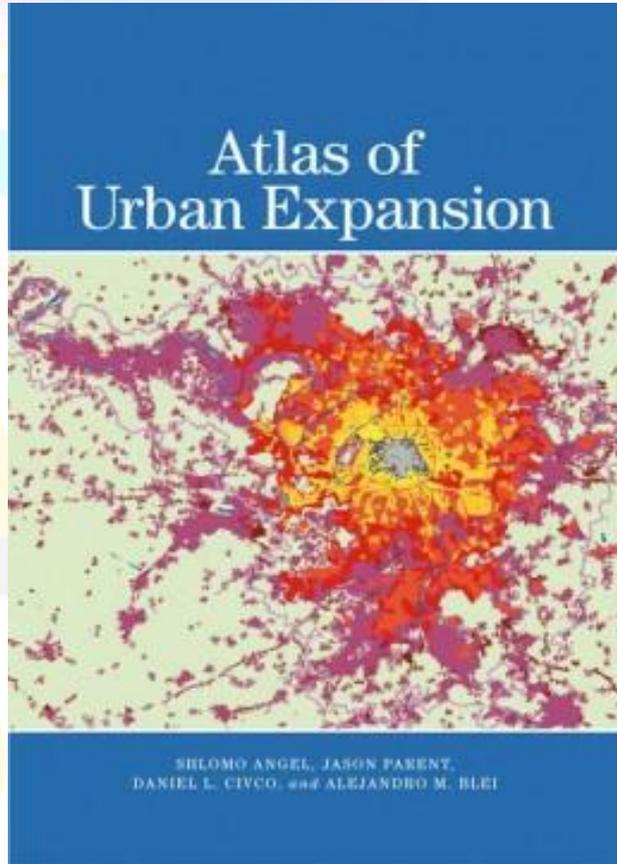
- UN-HABITAT (Programa de Naciones Unidas para Asentamientos Humanos) y Universidad de Nueva York
- Estudio de 200 ciudades repartidas por todo el mundo
- Periodo de 25 años
- Diferentes partes de estudio:
 - Tramas urbanas
 - Crecimiento de población en el tiempo
 - Económico
 - ...

2.1. Contexto



Atlas of Urban Expansion. The 2016 Edition Volume 1: Areas and Densities

2.1. Contexto



<https://www.lincolnst.edu/publications/other/atlas-urban-expansion-2016-edition>

<https://www.lincolnst.edu/publications/other/atlas-urban-expansion-2016-edition-0>

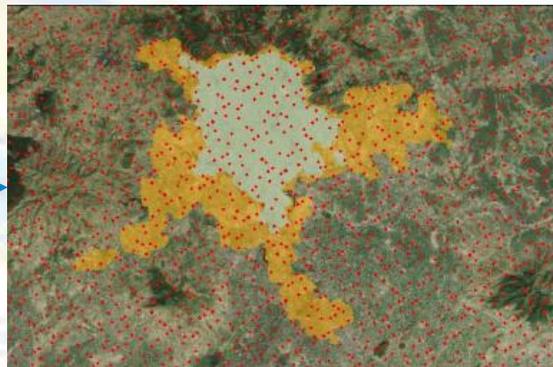
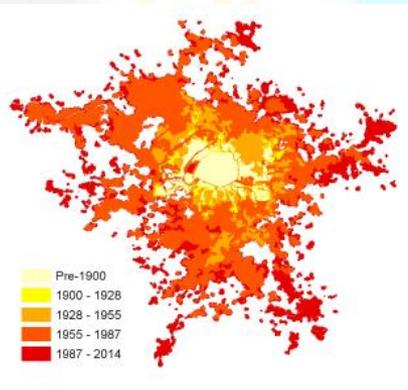
<https://www.lincolnst.edu/research-data/data/atlas-urban-expansion>

2.1. Contexto

Este proyecto se centra en la parte del estudio de la trama urbana

Para poder abordar el proyecto se plantea un estudio muestral:

- Estudio del crecimiento
- Extracción de círculos muestrales por cada zona
- Digitalización de las parcelas por un digitalizador
- **Etiquetado manual** por un digitalizador





2.1. Contexto

Tipo 0. Espacio abierto





2.1. Contexto

Tipo 1. Industrial / Uso no residencial



Valencia, España



2.1. Contexto

Tipo 2. Atomística.



Valencia, España



2.1. Contexto

Tipo 3. Informal

León, Nicaragua



Guanajuato, México





2.1. Contexto

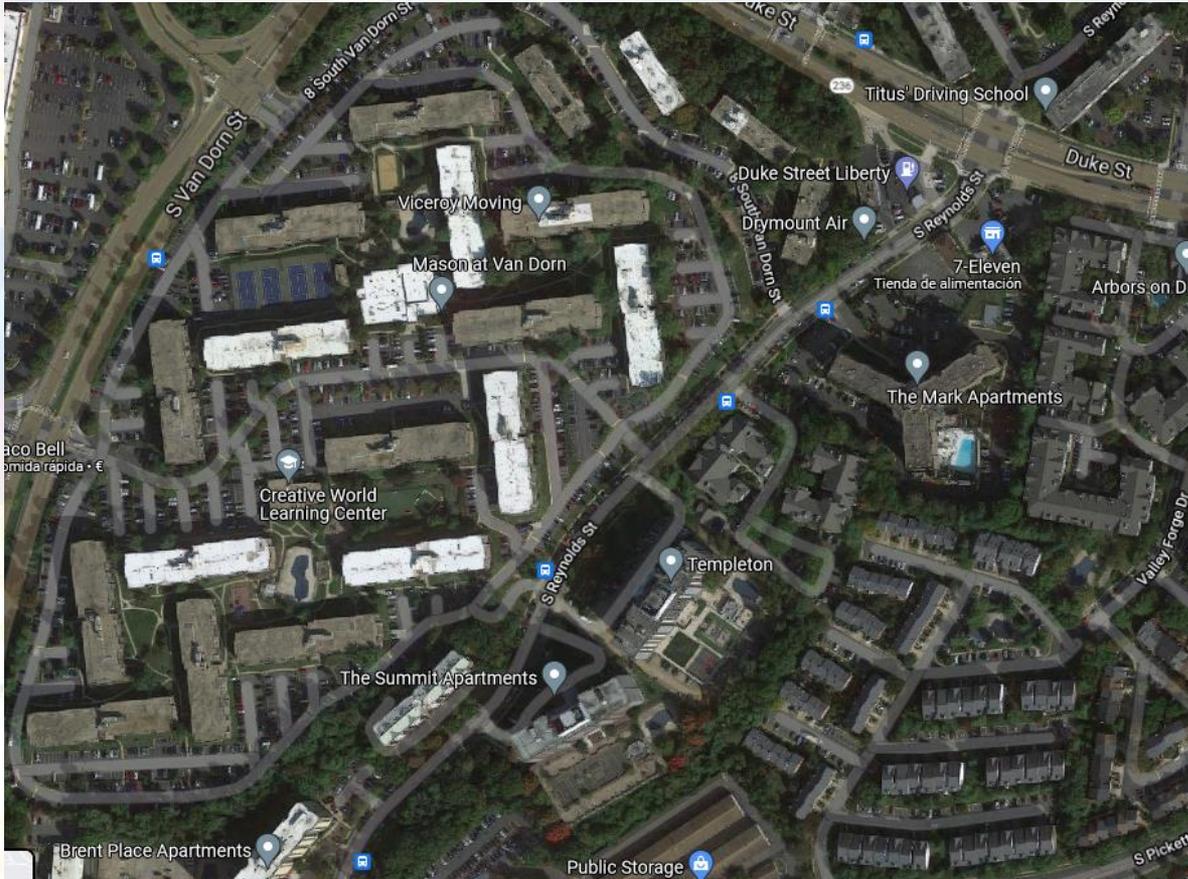
Tipo 4. Formal



Valencia, España

2.1. Contexto

Tipo 5. Proyecto urbanístico

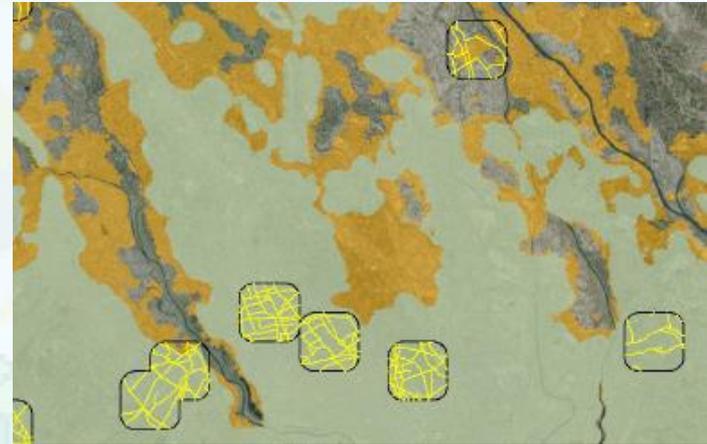


Washington D.C.

2.1. Contexto

Problemática del estudio:

- Ciudades heterogéneas
- Ciudades de gran extensión
- Trabajo manual costoso
- Estudio muestral se para cuando se cumplen unos requisitos estadísticos
- No se estudia toda la zona
- No se pueden hacer estudios de barrios concretos
- Resultado son estadísticas y no mapas



2.2. Estado del arte

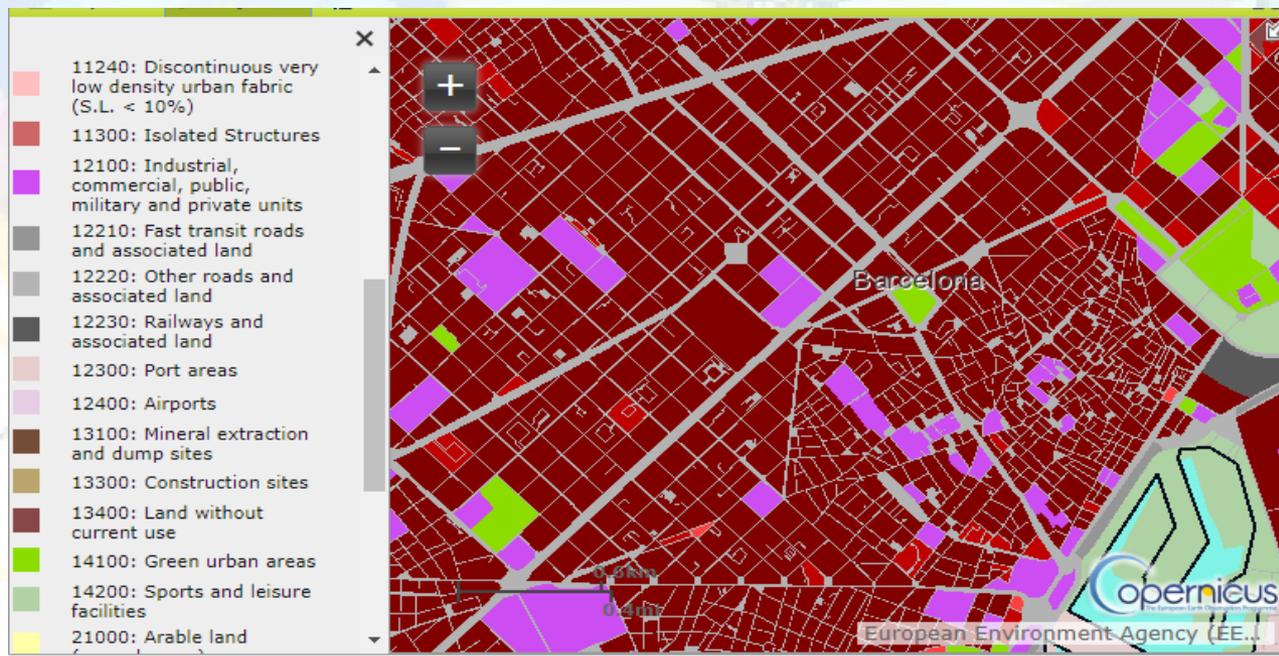
Estudios sobre análisis de ciudades con técnicas geoespaciales y de IA:

- Estudio de la calidad de vida según los patrones urbanos basados en técnicas de clasificación mediante una conjunción de datos vectoriales, imágenes satelitales o datos LIDAR (Sapena, Marta, Wurm, Michael, Taubenböck, Hannes, Tuia, Devis, & Ruiz, Luis A., 2021)
- Estudio de patrones de calles (Boeing, Spatial information and the legibility of urban form: Big data in urban morphology, 2021).
- Estudios con técnicas automáticas de clasificaciones suelen limitarse a clasificar la categoría como (Zhang, Chi, Wei, Shiqing, Ji, Shunping, & Lu, Meng, 2019)
- Clasificaciones urbanas basadas en clasificar pixel a pixel (Szabó, Zsuzsanna Csatáriné, y otros, 2020)
- Extracción de edificios (Jianpeng Xu, Wu Xiao, Tingting He, Xinyu Deng, & Wenqi Chen, 2020)

2.2. Estado del arte

Estudios sobre análisis de ciudades con técnicas geoespaciales y de IA:

- BigEarthNet, pixeles de 10 metros de resolución
- Urban atlas, similar al proyecto pero no guarda relación con el tipo de entramado urbano



2.2. Estado del arte

Multitud de estudios sobre la calidad de las ciudades

- Se plantean estudios en zonas/países concretos
- No tienen en cuenta los patrones en las imágenes: no es posible diferenciar tipologías urbanas
- Basados en estudios pixel a pixel, no por parcelas
- Imágenes de baja resolución
- Necesidad de datos no disponibles a nivel global (LIDAR)
- Gran coste o carga de trabajo de recopilación e integración

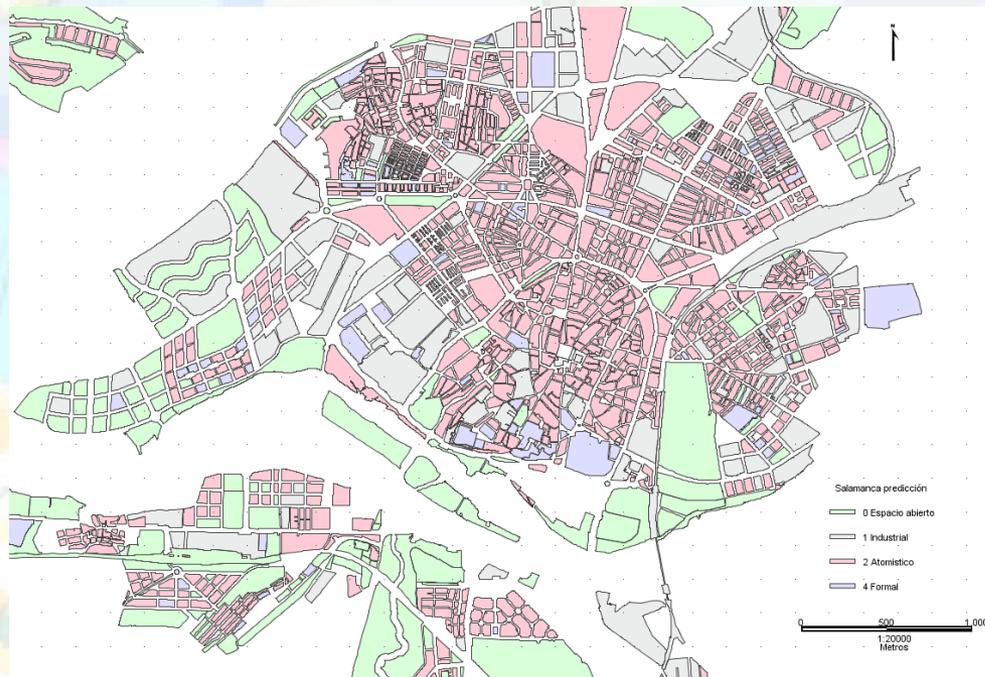
Para este proyecto

- Se necesita una congregación de diferentes estudios
- No se han encontrado estudios buscando un análisis global

3. Objetivos

Objetivo principal:

- 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



3. Objetivos

Objetivos secundarios:

- Explorar los diferentes recursos de imágenes aéreas
- Desarrollar herramienta para el etiquetado
- Calcular la precisión de la clasificación para validar el uso de redes convolucionales para esta tarea.
- Evaluar si una red entrenada con los datos de una ciudad es extrapolable a ciudades sin datos.
- Diseñar una metodología reproducible y escalable a un modelo urbanístico global con una red convolucional

4. Metodología y descripción del experimento

4.1. Preparación de datos de entrenamiento

Creación base de datos de entrenamiento: Tarea de digitalización

- Obtención de imágenes aéreas: PNOA
- Parcelas: CartoCiudad (proceso potencialmente automatizable)



Ortofoto PNOA Máxima Actualidad

Descripción: mosaicos de ortofotos más recientes disponibles del Plan Nacional de Ortofotografía Aérea.

SGR: ETRS89 en la Península, Islas Baleares, Ceuta y Melilla, y WGS84 en las Islas Canarias. Proyección UTM en su huso correspondiente.

Ud. descarga: cada mosaico cubre una hoja del MTN50 (Mapa Topográfico Nacional 1:50.000).

Formato: ECW

[Ver +](#)
Metadatos
Información auxiliar



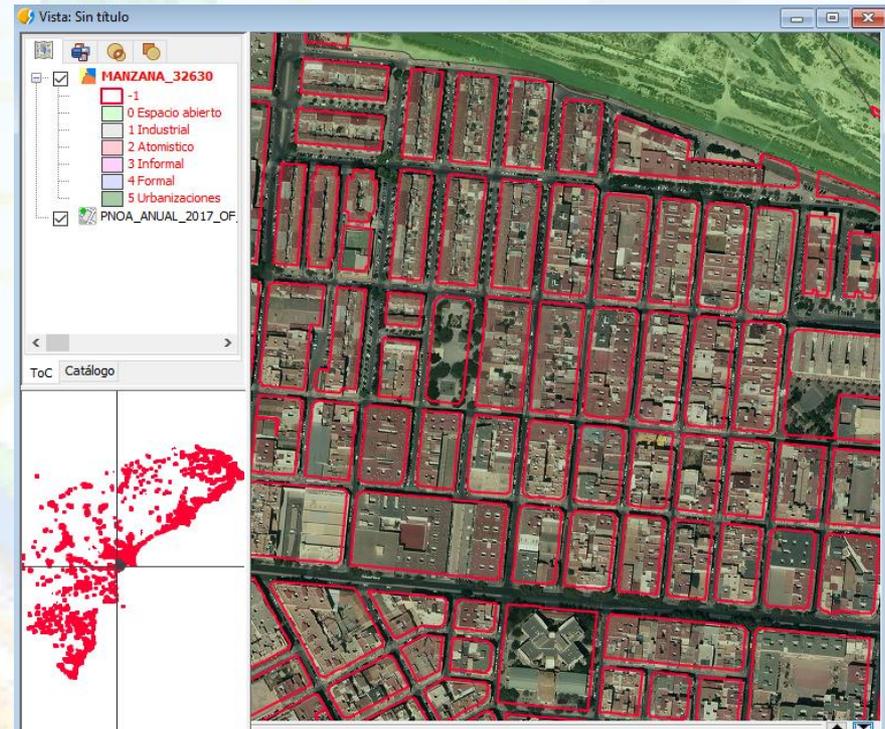
Todos



Por listado



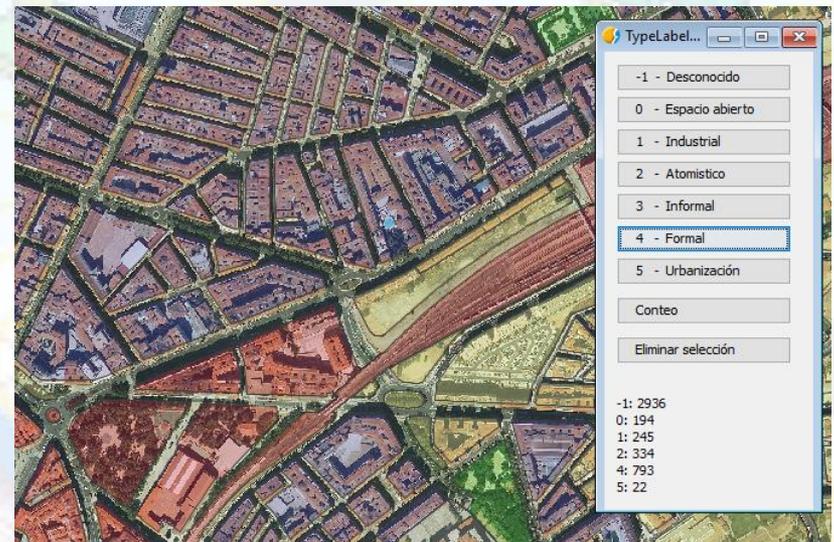
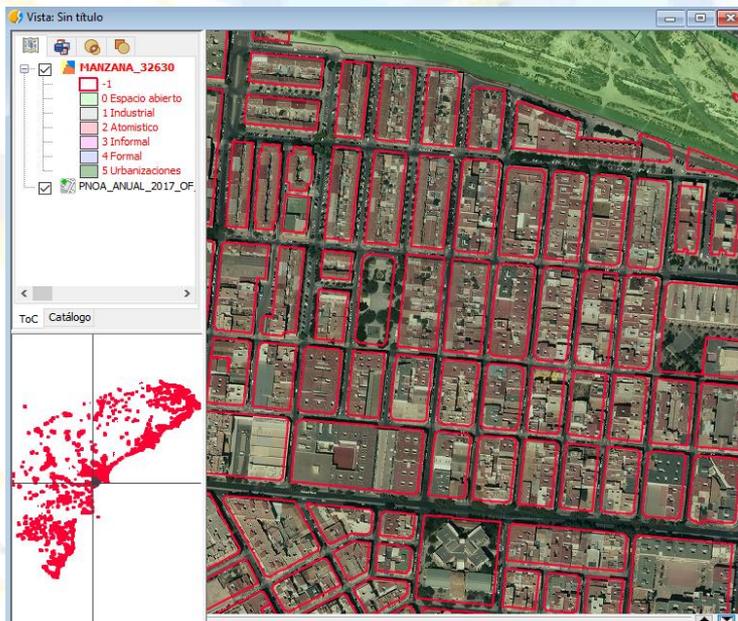
Por mapa



4.1. Preparación de datos de entrenamiento

Etiquetado

- Desarrollo de herramientas en gvSIG Desktop
- Etiquetado por tipología



4.1. Preparación de datos de entrenamiento

TypeLabelToolPanel

```
import gvsig
from gvsig.libs.formpanel import FormPanel
from org.gvsig.tools.dispose import DisposeUtils
```

```
class TypeLabelToolPanel(FormPanel):
```

```
    def __init__(self):
```

```
        FormPanel.__init__(self, gvsig.getResource(__file__, "typeLabelTool.xml"))
        self.layer = gvsig.currentLayer()
        if self.layer == None:
```

```
            return
```

```
        self.store = self.layer.getFeatureStore()
        self.typeField = "TIPO"
```

```
    def btnTypeU_click(self, *args):
```

```
        print "desconocido"
        self.updateValueSelection(-1)
```

```
    def updateValueSelection(self, value):
```

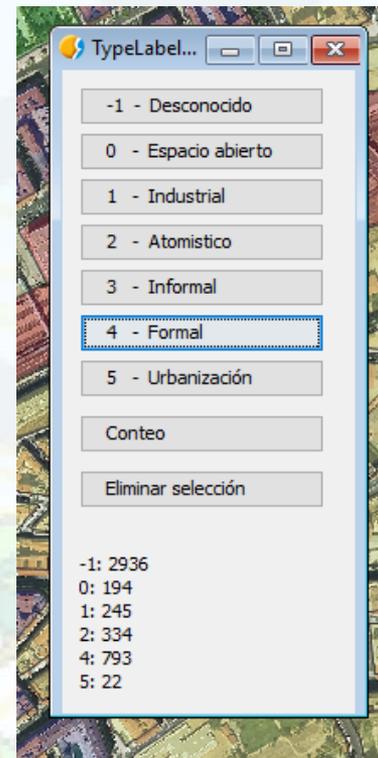
```
        features = self.store.getFeatureSelection()
        for f in features:
            c = f.getEditable()
            c.set(self.typeField, value)
            features.update(c)
        features.deselectAll()
        DisposeUtils.dispose(features)
        self.updateCount()
```

```
    def btnType0_click(self, *args):
```

```
        print "espacio abierto"
        self.updateValueSelection(0)
```

```
    def updateCount(self):
```

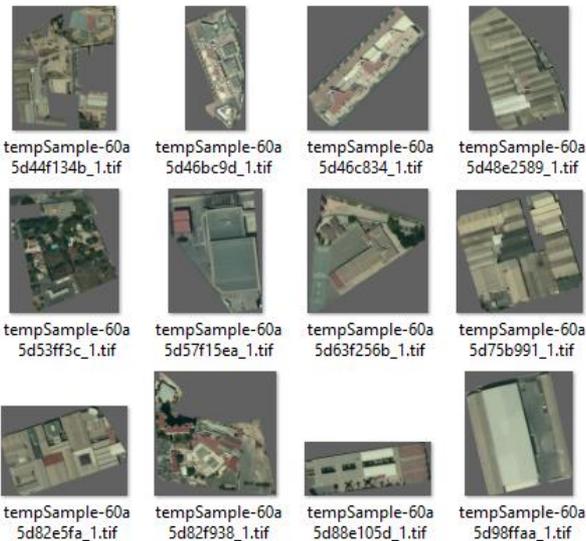
```
        fset = self.store.getFeatureSet()
        count = {}
        for f in fset:
            tipo = f.get("TIPO")
            if tipo in count:
                count[tipo] = count[tipo]+1
            else:
                count[tipo] = 1
        s = ""
        for k in count.keys():
            s = s + "<br>" + str(k)+": "+str(count[k])+"<br>"
        self.lblStatus.setText("<html>"+s+"</html>")
        DisposeUtils.dispose(fset)
```



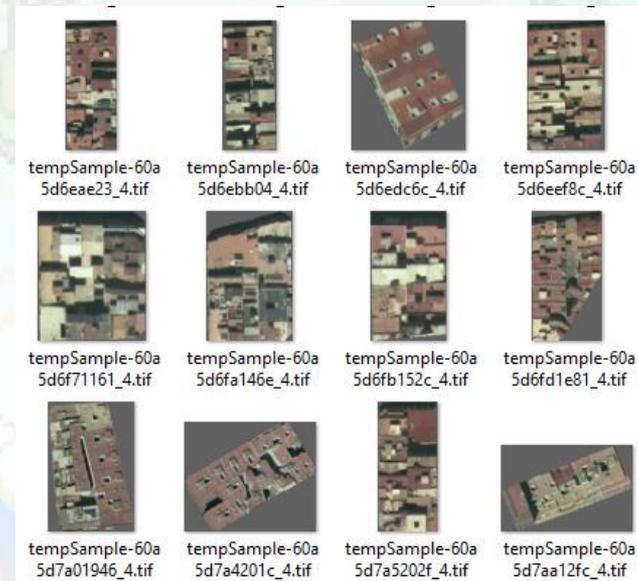
4.1. Preparación de datos de entrenamiento

Extracción de muestras

- Geoproceso de recorte por parcela
 - Scripts en el repositorio de Github/UrbanCNN:
 - <https://github.com/oscar9/UrbanCNNProject>



Industrial



Formal

4.1. Preparación de datos de entrenamiento

UrbanCNNProject/extractSamples

...

```
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
```

```
    buildType= f.get("TIPO")
```

```
    manz = f.get("ID_MANZ")
```

```
    if buildType == -1:
```

```
        continue
```

```
    temporalShape = createTemporalShape(featureTypePoligonos, f)
```

```
    tempFile = getTempFile(cityName,"_" +str(manz)+"_" +str(buildType)+ ".tif",
```

```
        tempdir="E:\\TFM_MUESTRAS\\"+executeName+"\\"+ cityName)
```

```
gvsig.runalg("clipgrid", raster,temporalShape, PATH=tempFile, ADDLAYER=False)
```



4.1. Preparación de datos de entrenamiento

Extracción de muestras

- Análisis

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

Salamanca con 272 muestras de espacio abierto, 328 de Industrial, 372 de Atomística y 954 de Formal usados solo para validación.

Añadidas muestras del Catastro para espacio abierto de Toledo y Valencia.

Limitación

- No se han realizado etiquetas para Informal y Proyecto urbanístico

4.1. Preparación de datos de entrenamiento

Organización de las muestras para el modelo:

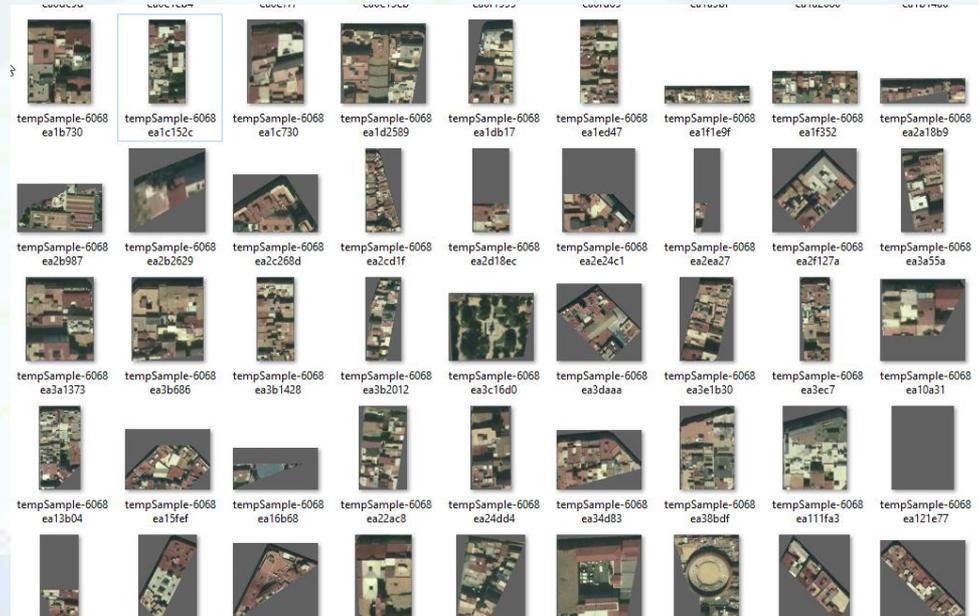
Carpetas de datos

Entrenamiento

- 0_espacioabierto
- 1_industrial
- 2_atomistic
- 4_formal

Validación

- 0_espacioabierto
- 1_industrial
- 2_atomistic
- 4_formal



4.2. Entrenamiento del modelo

Ordenador:

- 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 de Python:

- Keras 2.4.3
- matplotlib 3.3.4
- tensorflow-gpu 2.5.0
- Uso de NVIDIA cuDNN y CUDA

4.2. Entrenamiento del modelo

Data augmentation

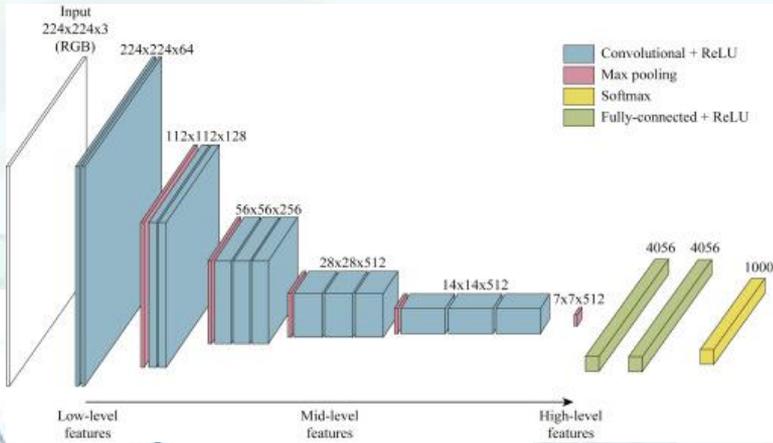
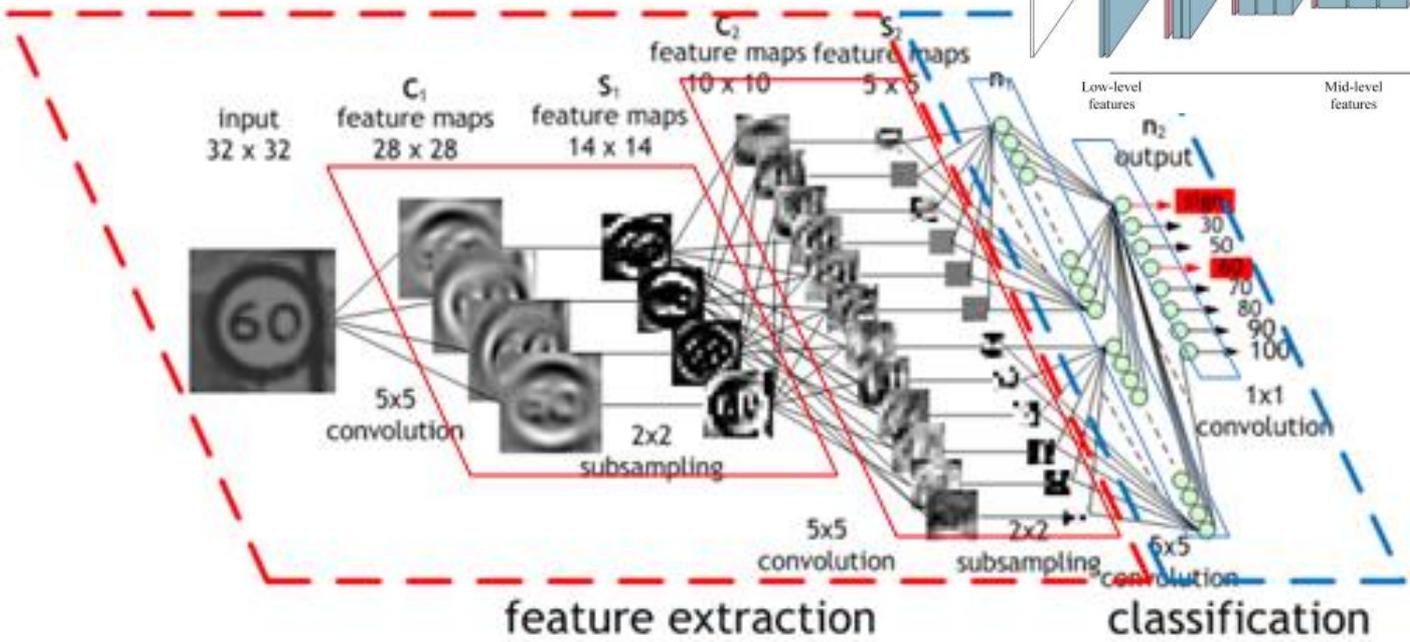
- Necesario por haber pocas muestras
- Se pueden encontrar en cualquier orientación
- En cualquier tamaño
 - Por diseño del proyecto no se tiene en cuenta el tamaño de las parcelas

Problema de desbalanceo de datos: Necesario añadir datos de espacio abierto obtenidos de parcelas de capas del Catastro

```
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')
```

4.2. Entrenamiento del modelo

Red convolucional



Más información recomendando DOTCSV en Youtube:

<https://www.youtube.com/c/DotCSV/videos>

4.2. Entrenamiento del modelo

Modelo final:

- Después de diferentes iteraciones para llegar a esta arquitectura
- 4 salidas: espacio abierto / industrial / atomístico / formal

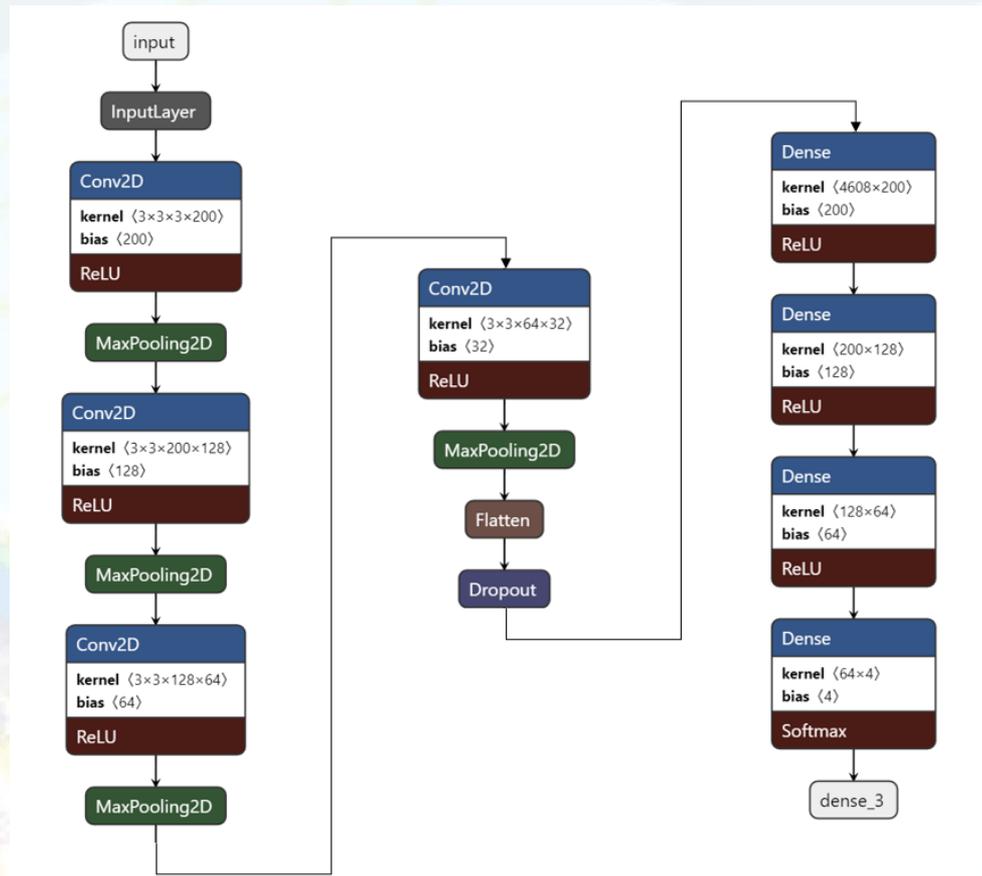
Model: "sequential"

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 (MaxPooling2D)	(None, 54, 54, 128)	0
conv2d_2 (Conv2D)	(None, 52, 52, 64)	73792
max_pooling2d_2 (MaxPooling2D)	(None, 26, 26, 64)	0
conv2d_3 (Conv2D)	(None, 24, 24, 32)	18464
max_pooling2d_3 (MaxPooling2D)	(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



4.2. Entrenamiento del modelo

```
model = tf.keras.models.Sequential([
    tf.keras.layers.Conv2D(200, (3,3), activation='relu', input_shape=(image_size, image_size, 3)),
    tf.keras.layers.MaxPooling2D(2, 2),

    tf.keras.layers.Conv2D(128, (3,3), activation='relu'),
    tf.keras.layers.MaxPooling2D(2, 2),

    tf.keras.layers.Conv2D(64, (3,3), activation='relu'),
    tf.keras.layers.MaxPooling2D(2, 2),

    tf.keras.layers.Conv2D(32, (3,3), activation='relu'),
    tf.keras.layers.MaxPooling2D(2,2),

    tf.keras.layers.Flatten(),
    tf.keras.layers.Dropout(0.5),

    tf.keras.layers.Dense(200, activation='relu'),
    tf.keras.layers.Dense(128, activation='relu'),
    tf.keras.layers.Dense(64, activation='relu'),
    tf.keras.layers.Dense(4, activation='softmax')
])
```

```
model.compile(
    loss = 'categorical_crossentropy',
    optimizer='ADAM', #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")
```

4.2. Entrenamiento del modelo

Parámetros generales

- Epochs 1000
- Steps per epoch 50
- Validation steps 30

Optimizadores

- ADAM
- SGD: Descenso de gradiente

El modelo se ejecutará siempre sobre los mismos valores de entrenamiento y validación.

- 80% entrenamiento %20
- En este proyecto es interesante ver la confusión entre diferentes modelos entrenados, con diferentes datos, sobre diferentes datos de validación y analizar los errores en la clasificación entre las tipologías

4.3. Predicción y mapa

Para terminar

- Se realizará una predicción del modelo sobre los datos de las mismas ciudades que se han entrenada.
 - El objetivo es asegurar la reproducibilidad del estudio en el tiempo sobre una misma ciudad. Tiene que ser capaz de repetir sus predicciones.
- Se realizara una predicción sobre la ciudad de Salamanca que no entra en el modelo
 - El objetivo es asegurar poder predecir ciudades de las que no se tienen muestras
- Calcularán las matrices de confusión
- Se unirán los datos de la predicción con las capas vectoriales
 - Se mostrarán en un mapa

5. Resultados

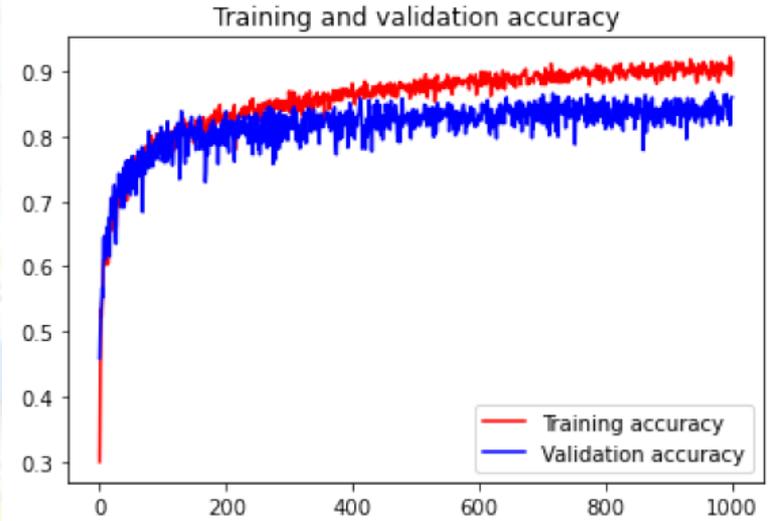
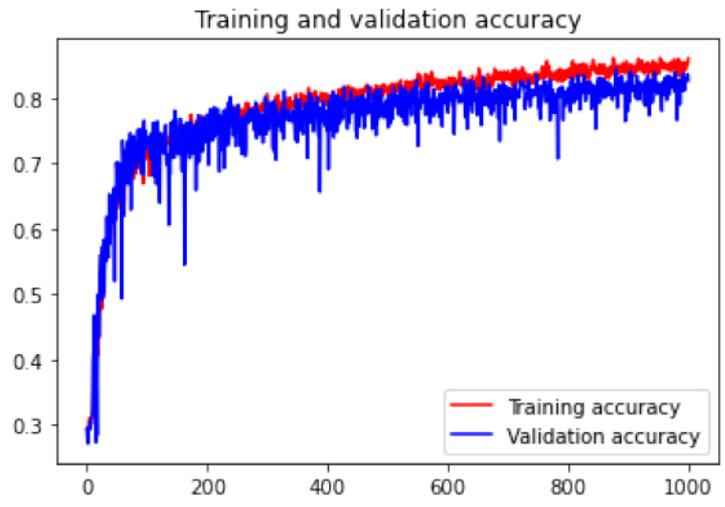
Predicción: Análisis global - ciudades del modelo

Modelo SGD

Porcentaje de acierto del 82%

Modelo ADAM

Porcentaje de acierto del 86%



- Empiezan a mostrar signos de sobreajuste

5. Resultados

Predicción: Análisis global - ciudades del modelo

Modelo SGD

Porcentaje de acierto del 82%

Modelo ADAM

Porcentaje de acierto del 86%

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_espacioabierto	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

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_espacioabierto	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

5. Resultados

Predicción: Análisis Salamanca - ciudad fuera del modelo

- Usando el modelo anterior entrenado sobre una ciudad sobre la que no se tienen datos previos

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%

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_espacioabierto	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

6. Discusión

Consideraciones a discutir

- 85% se podría considerar un buen valor para este tipo de proyecto.
 - Durante el trabajo del Atlas de Expansión Urbana se tenía en cuenta la posibilidad de un mal etiquetado por parte del digitalizador. **La realidad es compleja.**
 - No es necesaria una predicción total sino que permita un estudio de variabilidad en el tiempo

6. Discusión

Predicción: Análisis global - ciudades del modelo

- No hay diferencia notable entre diferentes tipologías

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_espacioabierto	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

6. Discusión

Predicción: Análisis global - ciudades del modelo



Detalle de casco histórico de Valencia

6. Discusión

Predicción: Análisis global - ciudades del modelo



Valores etiquetados

Valores predichos

Torrente, Valencia



6. Discusión

Predicción: Análisis global - ciudades del modelo



Torrente, Valencia

6. Discusión

Predicción: Análisis Salamanca - ciudad fuera del modelo

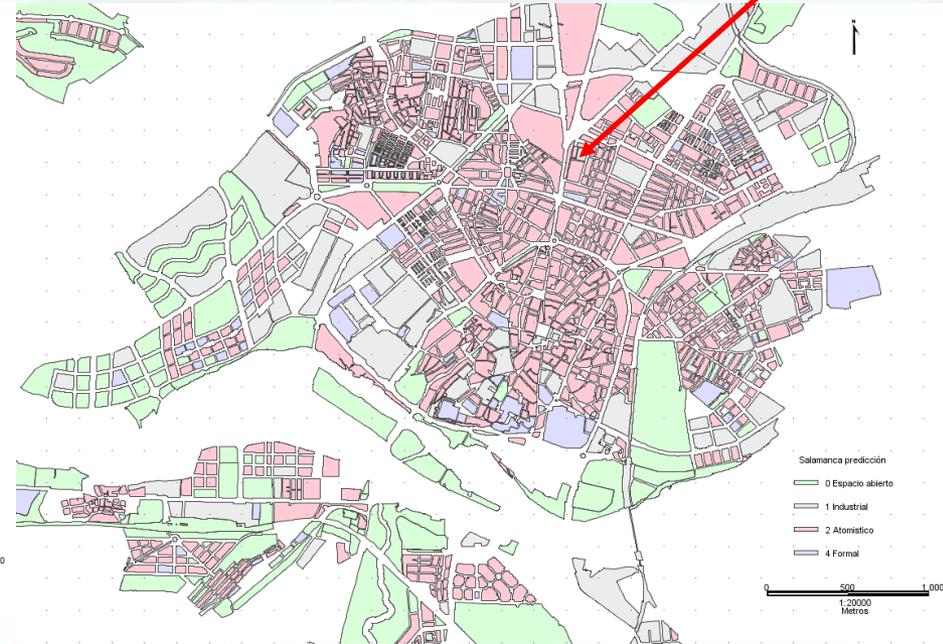
- Errores en diferenciar Atomístico y Formal
 - Muestras formales etiquetadas como atomísticas
 - No es todo culpa del modelo. Consideraciones del etiquetado.
 - Zona formal bastante atomística

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%

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

6. Discusión

Predicción: Análisis Salamanca - ciudad fuera del modelo



Digitalizado

Predicho



6. Discusión

Predicción: Análisis Salamanca - ciudad fuera del modelo



6. Discusión

Problemas con los modelos y la arquitectura planteada

- Se recortan las parcelas para su entrenamiento pero no para su etiquetado.
 - En una misma parcela múltiples tipologías.
- No se tiene en cuenta el tamaño
- Sacadas de contexto: independientes de sus parcelas contiguas
- Difícil etiquetado dada la complejidad de la clasificación
 - Muchos factores mezclados
 - Usos: residencial, industrial, ..
 - Patrones: forma de las parcelas, número intersecciones, tamaño
 - Servicios: calidad de las vías de acceso, aceras, calzada, anchura de calzadas

7. Conclusiones y trabajo futuro

Objetivo principal: usar este tipo de redes convolucionales para clasificación de parcelas es posible.

Se han cumplido los objetivos específicos

- Se ha demostrado que es posible realizar un estudio de gran ámbito con recursos gratuitos y públicos. Para un estudio global podría ser diferente.
- Se han desarrollado las herramientas necesarias para la extracción de muestras, su etiquetado y clasificación.
- Se ha obtenido una precisión alta. Incluso el error de la ciudad de Salamanca era esperado.
- Se ha demostrado que pueden existir problemas al utilizar redes sobre ciudades de las que no se disponen datos. Problemas al expandir el modelo a nivel global.

7. Conclusiones y trabajo futuro

Otras consideraciones:

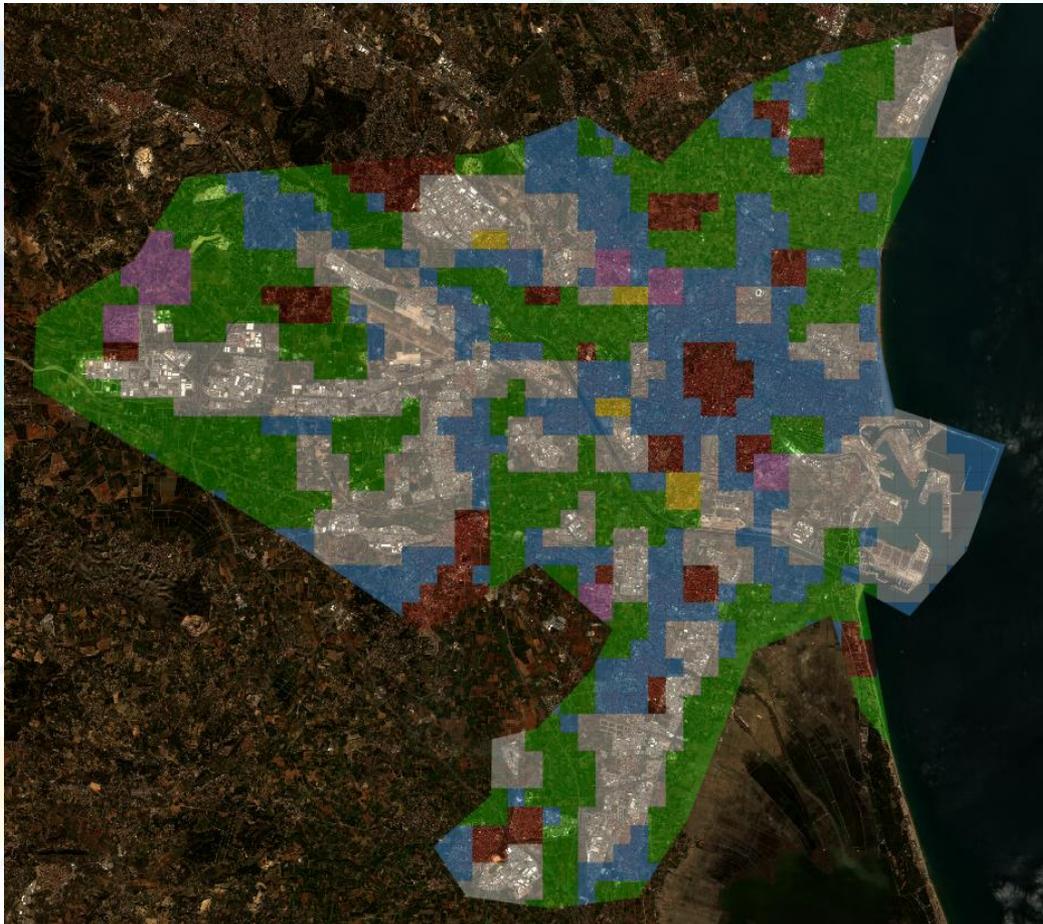
- Se ha necesitado el apoyo de datos vectoriales
- Para proyectos de gran precisión son necesarias múltiples fuentes
- Para estudios generalizados puede ser más que suficiente
 - Mejora respecto a un estudio muestral considerablemente.
- Necesidad de replantear el modelo para incluir etiquetas de formal y proyecto urbanístico



7. Conclusiones y trabajo futuro

Posibles trabajos futuros:

- Clasificación por rejilla
- Eliminar necesidad de trabajar con parcelas



7. Conclusiones y trabajo futuro

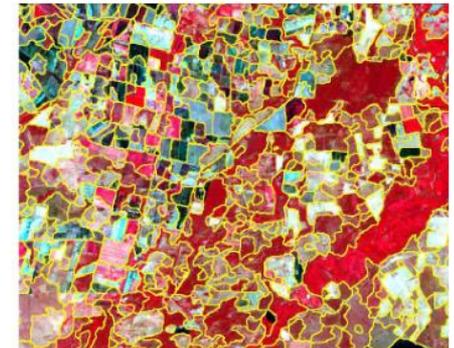
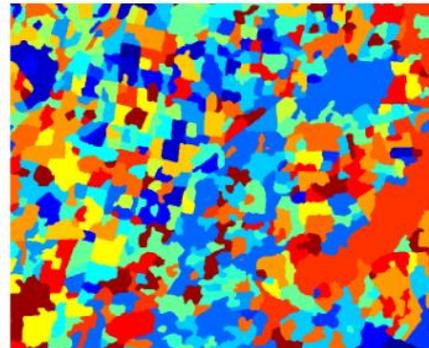
Posibles trabajos futuros:

- Aplicaciones de segmentación de imagen sobre la ciudad para separar los diferentes patrones, con redes de tipo Mask R-CNN



Semantic Segmentation	Classification + Localization	Object Detection	Instance Segmentation
			
GRASS, CAT, TREE, SKY	CAT	DOG, DOG, CAT	DOG, DOG, CAT
No objects, just pixels	Single Object	Multiple Object	

This image is CC0 public domain



7. Conclusiones y trabajo futuro

Posibles trabajos futuros:

- Mejoras en las herramientas desarrolladas de extracción de muestras
- Plantear otras categorías diferentes aprovechando la mayor capacidad de trabajo de la IA. Tanto con modelos supervisados como no supervisados.
- Redes GauGAN para creación de imágenes realistas/artísticas sobre la expansión de las ciudades
- Automatización de todo el proceso para su ejecución automática y repetida en el tiempo.
- Integración en gvSIG Desktop para clasificación automática

Viernes, 3 de diciembre

11:00-12:00

12:00-13:00

13:00-14:00 Mapeamento do Leito e Área de Proteção Permanente-APP do Rio Ribeira de Iguape no Município de Registro/SP/Brasil. Dr Vilmar Antonio Rodrigues, Gilberto Cugler (Universidade Estadual Paulista "Julio de Mesquita Filho", Câmpus Registro / Brasil).

14:00-15:00 gvSIG Online como Herramienta de acceso e interpretación cartográfica de la Herencia Cultural del Estado de Hidalgo, México. Yatzin Montiel Vargas, Sandra Lucía Hernández Zetina (Universidad Autónoma del Estado de México)

15:00-16:00 Explotación de datos con gvSIG Desktop: búsqueda asistida, dashboard y gráficas. Óscar Martínez (Asociación gvSIG)

<https://event.webinarjam.com/register/165/479qla8k>

Gracias por asistir

<http://www.gvsig.com/es/comunidad/listas-de-correo>

Más información..
omartinez@gvsig.com
@masquesig