



Aprendizaje profundo aplicado a las vías de comunicaciones secundarias del IGN:

Flujo de trabajo y herramienta de etiquetado de ortoimágenes

R. Alcarria, V. de la Fuente, F. Serradilla, MA. Manso (UPM)
F. Mariño, G. Moreno, FJ García, FJ González (IGN)

Índice de la presentación

- Contexto general
- ¿Qué es el Deep Learning?
- ¿Cómo puede ayudar el Deep Learning en la actualización continua de las vías de comunicaciones secundarias del IGN?
- ¿Cómo entrenar las Redes Neuronales Convolucionales (CNN)?
- Necesidad: Generar banco de datos de entrenamiento
Herramienta de etiquetado de teselas de ortoimágenes.
- Resultados a nivel de banco de datos.
- Primeros resultados de los entrenamientos de CNNs con el “pequeño” banco de datos de pruebas disponible.

Contexto General

- Subdirección General de Geodesia y Cartografía del IGN (2017)
 - Programa para el cambio productivo de Bases de Datos de Información Geoespacial (BDIG):
 - metodología de actualización continua de los objetos geográficos recogidos en las bases de datos de Información Geoespacial
 - **CARTOBOT:**
 - explotación de información no estructurada mediante la utilización de BOTs y
 - técnicas de Inteligencia Artificial (*o Deep Learning/Machine Learning*)

¿Qué es el Deep Learning?

Machine Learning: Técnicas que permiten a los ordenadores aprender solos.

Programación tradicional

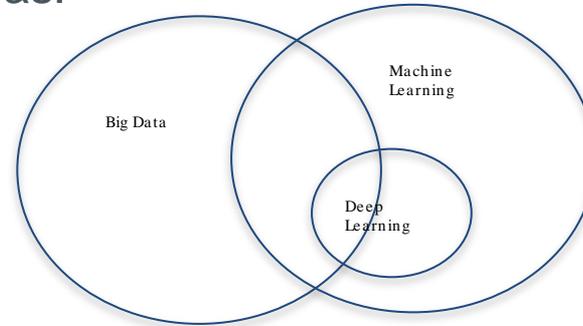


Machine Learning



¿Qué es el Deep Learning?

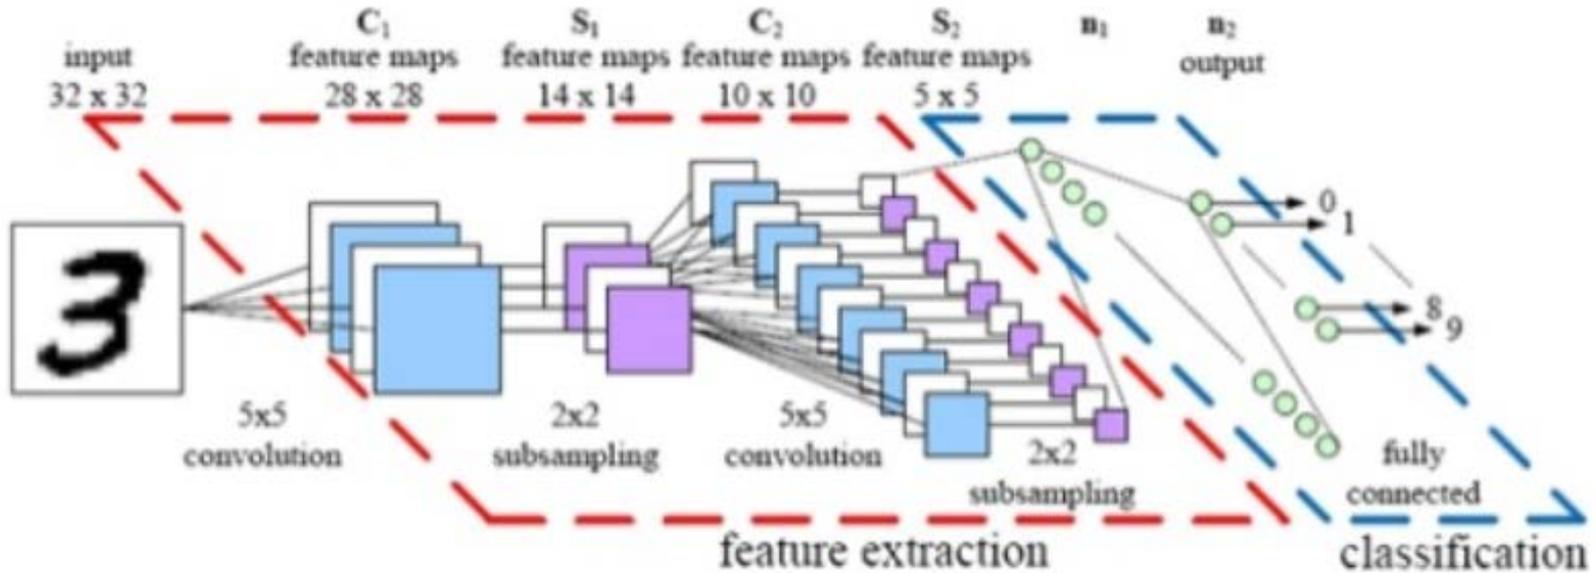
- Técnica consistente en el uso de redes neuronales artificiales con varias capas ocultas.



- Es un subcampo de la IA, que intenta imitar el funcionamiento del cerebro humano con neuronas
- Aplicaciones: permiten a los ordenadores distinguir objetos, textos, vídeos, audio...
- Algunos ejemplos de ANNs (*Artificial Neuronal Networks*): Perceptron multicapa (MLP), AutoEncoders (AE), Redes Neuronales Convolucionales (CNN), Redes Neuronales Recurrentes (RNN).

Redes Neuronales Convolucionales (CNN)

- Mejoran significativamente la capacidad de generalización de los Perceptrones multicapa gracias a las capas convolucionales.
- Son especialmente útiles para el reconocimiento de imágenes y datos espaciales.
- Utiliza la operación de convolución (operación lineal) distinta al producto de matrices.
- Consta generalmente de dos partes: extracción de características y clasificación.



Source: Deeply-Supervised Nets. Zhuowen Tu.

¿Cómo puede ayudar el Deep Learning .. en la actualización de las vías secundarias del IGN?

p.e. Identificando teselas de ortoimágenes que contienen vías secundarias y contrastando si existe cartografía en esa región.

p.e. Mediante segmentación semántica y redes de neuronas profundas: segmentar directamente los píxeles de un camino dentro de una tesela, unirlos (vectorizar) y contrastar geometrías.

¿Cómo entrenar redes CNNs?

- Necesidad de un conjunto de datos etiquetados
- Diversas alternativas para entrenamiento y evaluación de resultados de las redes:
 - Entrenamiento/validación/test (*p.ej. 70/20/10%*)
 - Validación cruzada K-Fold
 - Dividir en k conjuntos
 - Entrenar de cero en k-1 conjuntos y evaluar en el restante
 - Repite el proceso k veces (cada conjunto se usa k-1 veces para entrenar y 1 para evaluar)
- Entrenar empleando descenso del gradiente o alguna de sus variantes (*p.ej. Adam*)

Necesidad de un banco de teselas etiquetadas

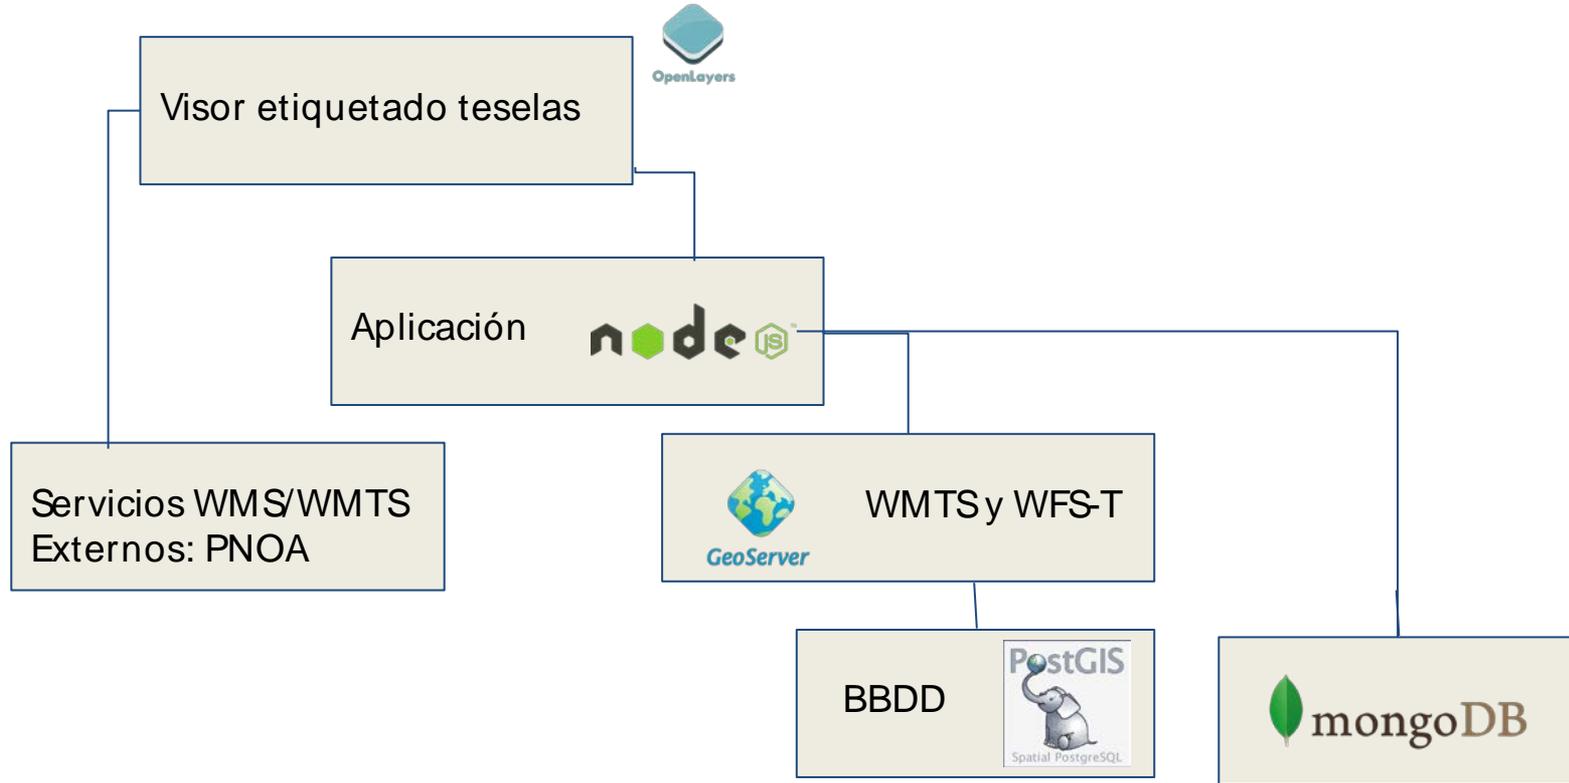
- Las CNNs profundas, necesitan grandes conjuntos de datos de entrenamiento para aprender a identificar formas, características, etc.. ,principalmente, cuando se trata de imágenes.
- Así por ejemplo ImageNet dispone de 15 millones de imágenes etiquetadas.

Cómo etiquetar y generar un banco de imágenes..?

El objetivo es: anotar de algún modo si una imagen, teselas de imagen aérea del PNOA, contiene viales secundarios, hacerlo de forma aleatoria a una escala de trabajo y tener un control del trabajo realizado (no repetir), y poder seleccionar distintas zonas/regiones.

Con este fin, se ha creado una herramienta web, que consta de un doble visor de mapas sincronizados (OpenLayers) con la capacidad de seleccionar una tesela y ordenar su anotación sobre una base de datos externa y el registro de las teselas visitadas.

Arquitectura de la aplicación



Componentes de la aplicación

- MongoDB: para almacenar JSON con ID tesela ortoimagen PNOA y anotación.
- PostGIS: almacenar las geometrías de la red de transportes y ofrecerla con Geoserver WMTS con estilos personalizados.
- PostGIS: para almacenar los BBOX de las teselas ya etiquetadas.
- NodeJS: Aislar conexión Visor del WFS-T, seleccionar área de trabajo, seleccionar aleatoriamente zona, acceso a reportes sobre MongoDB.
- Fijar escala 1:~4.514 (nivel de zoom= 18) de trabajo.

Apariencia y funcionalidad de la aplicación

Ortofoto



Zoom actual = 18
Zoom requerido = 18

Mapa



Registre la categoría

Vial no existe y no registrado

Vial existe y registrado correctamente

Vial existe y no registrado

Seleccione tipo de vial

Carretera Camino Senda Urbano

Vial existe y registrado incorrectamente

Seleccione tipo de vial

Carretera Camino Senda Urbano

Vial no existe y registrado incorrectamente

Categoría poco clara

Gestión teselas etiquetas y estadísticas

Últimos trabajos

[Descargar todos los trabajos](#)
[Descargar solo nivel 18](#)

Categorizados

No existe / No registrado: 9572 Existe / Registrado: 8703 Existe / No registrado: 359
 Existe / Registrado incorrecto: 610 No existe / Registrado incorrecto: 94 Categoría poco clara: 3144

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40		
41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56	57	58	59	60	61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78				
79	80	81	82	83	84	85	86	87	88	89	90	91	92	93	94	95	96	97	98	99	100	101	102	103	104	105	106	107	108	109	110	111	112	113	114						
115	116	117	118	119	120	121	122	123	124	125	126	127	128	129	130	131	132	133	134	135	136	137	138	139	140	141	142	143	144	145	146										
147	148	149	150	151	152	153	154	155	156	157	158	159	160	161	162	163	164	165	166	167	168	169	170	171	172	173	174	175	176	177	178										
179	180	181	182	183	184	185	186	187	188	189	190	191	192	193	194	195	196	197	198	199	200	201	202	203	204	205	206	207	208	209	210										
211	212	213	214	215	216	217	218	219	220	221	222	223	224	225	226	227	228	229	230	231	232	233	234	235	236	237	238	239	240	241	242										
243	244	245	246	247	248	249	250	251	252	253	254	255	256	257	258	259	260	261	262	263	264	265	266	267	268	269	270	271	272	273	274										
275	276	277	278	279	280	281	282																																		

No existe / No registrado

Centro (EPSG:3857):
-140873.44312958047,
4530957.725660393

Fecha: 2019-9-3
16:02:42

[Actualizar](#) [Eliminar](#)

Existe / Registrado

Centro (EPSG:3857):
-148670.02001466602,
4528817.488868408

Fecha: 2019-9-3
16:02:35

[Actualizar](#) [Eliminar](#)

Existe / Registrado

Centro (EPSG:3857):
-143930.9242609851,
4521785.282266172

Fecha: 2019-9-3
16:02:31

[Actualizar](#) [Eliminar](#)

Existe / Registrado

Centro (EPSG:3857):
-146529.78322268277,
4527594.496415844

Fecha: 2019-9-3
16:02:27

[Actualizar](#) [Eliminar](#)

2019-10-23/ 23

Caceres



Resultados a nivel de banco de entrenamiento

Se dispone de unas 18.300 teselas de imágenes aéreas etiquetadas.

8700 con viales

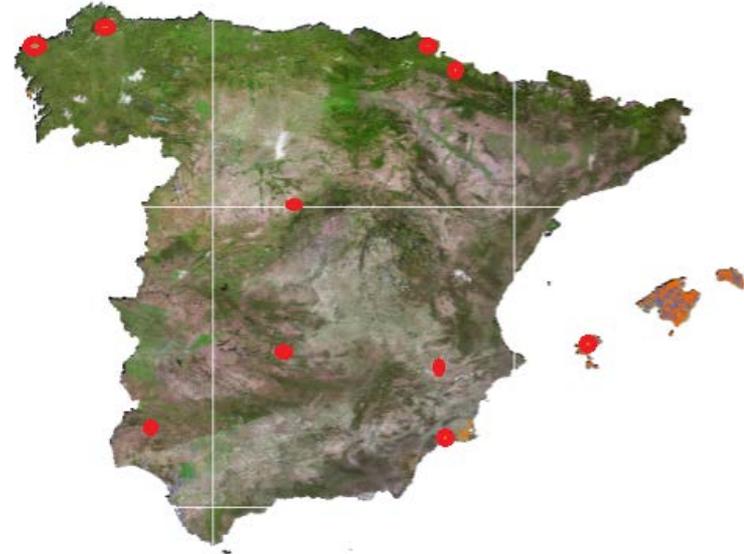
9600 sin viales

De 8 regiones distintas:

H533, Ochagavia, Etxal

Almonaster, Baleares,

Mazarón, Laxe y Valseca.

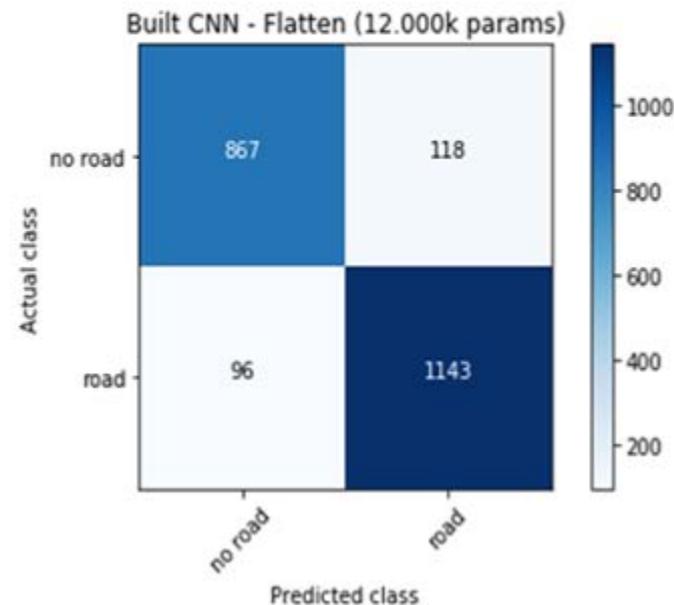


Redes entrenadas y resultados

Ejemplo de red neuronal construida desde cero:



Scenario	Tag	precision	recall	f1-score
Built CNN	no road	0.90	0.88	0.89
	road	0.91	0.92	0.91



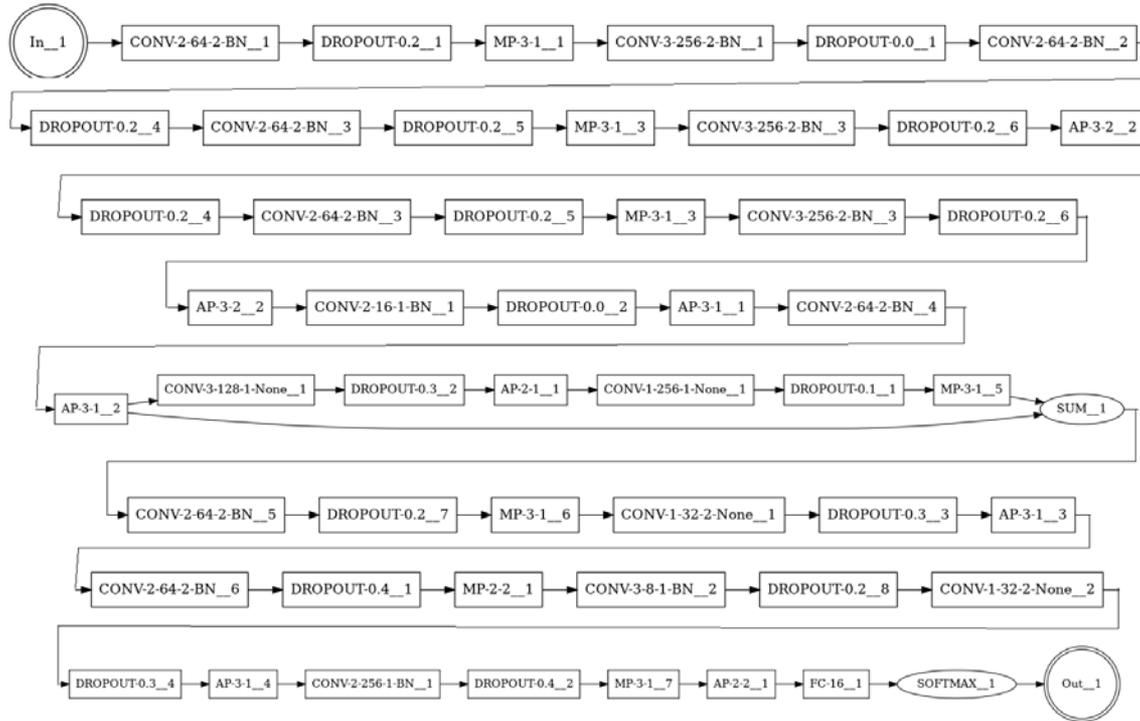
Redes entrenadas y resultados

Ejemplos de aplicación de redes pre-entrenadas en grandes conjuntos de datos mediante técnicas de transferencia de aprendizaje:

"Fine-tuning" pretrained models	Test accuracy	Parameters	
		Total (millions)	Trainable
VGGNet	94.09%	15	49.02%
Inception	91.19%	22.9	60.69%
Xception	92.20%	21.9	35.62%
Inception-ResNet	91.28%	55.1	20.05%

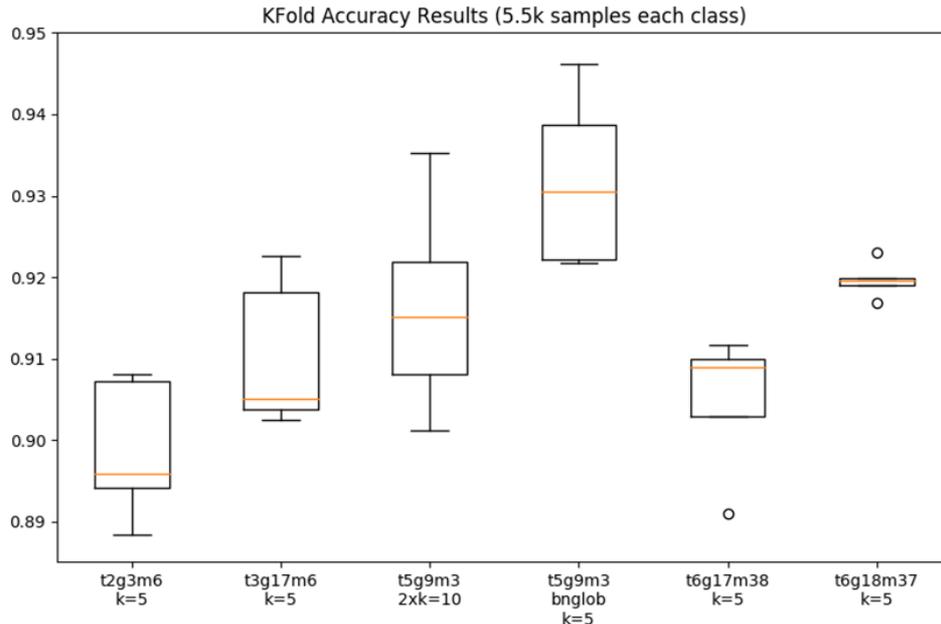
Redes diseñadas automáticamente

Ejemplo de red original diseñada mediante algoritmo genético:



Resultados para redes diseñadas automáticamente

Precisión por validación cruzada en detección de vías sobre teselas para redes diseñadas en varios experimentos sin emplear pre-entrenamiento.



Las columnas indican:

- Código del experimento
- Valor de k con que se aplica k-fold

Conclusiones

- Los sistemas aplicados ofrecen soluciones al problema de detección de vías de transporte en imágenes de PNOA.
- Transfer learning nos permite aprovechar la potencia de grandes arquitecturas de red pre-entrenadas sobre datasets como ImageNet.
- El diseño automático nos permite obtener redes a medida para resolver el problema.

- Aplicación de los sistemas desarrollados al etiquetado semántico a nivel de píxel.
- Incorporación de las redes en sistemas basados en metclasificadores.
- Generación de sistemas híbridos que incorporan conocimiento simbólico a la información generada por las redes para su refinado.

Gracias por su atención

ramon.alcarria@upm.es
fmarino@fomento.es