

Fully Convolutional Neural Networks (FCNN)

Caso de uso: Segmentación Automática de Ortofotografías Aéreas del PNOA

WGML 2017

Jorge Naya Macías (Gradiant)

Raquel Dosil Lago (Gradiant)

Emilio Abad Vidal (CESGA)

Clasificación Automática de Ortofotografías Aéreas del PNOA

Machine Learning en Computer Vision

- Tasks

Clasificación



CAT

Detección



CAT

Segmentación



CAT, DOG, DUCK

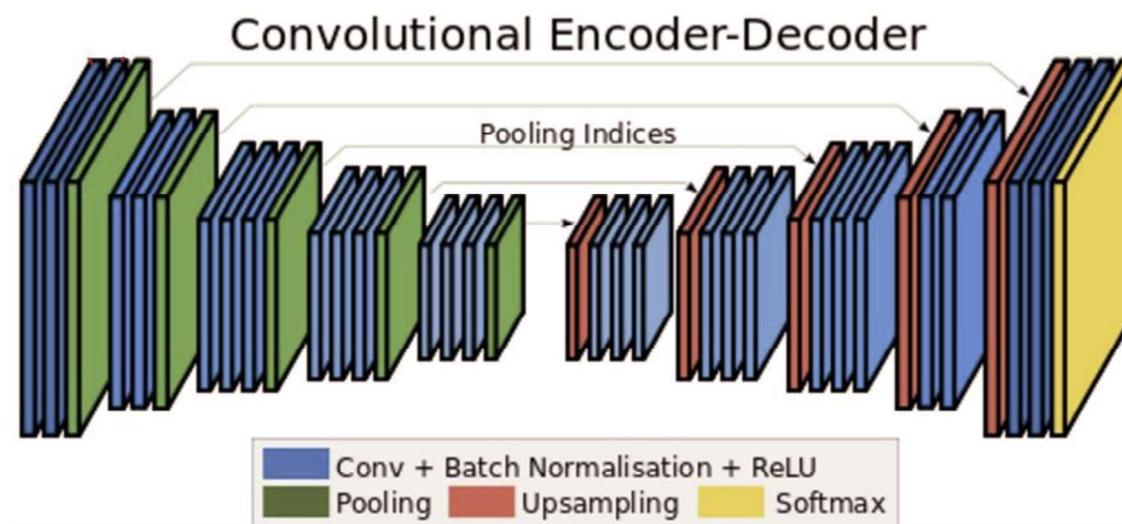


Clasificación Automática de Ortofotografías Aéreas del PNOA

Semantic Segmentation

- **SegNet Architecture**

- Symmetric
- Unpooling: store pooling indices for reconstruction



Badrinarayanan, Vijay, Alex Kendall, and Roberto Cipolla. "Segnet: A deep convolutional encoder-decoder architecture for image segmentation." *arXiv preprint arXiv:1511.00561* (2015).



Caso de Uso:
Clasificación Automática de Ortofotografías Aéreas del PNOA

Clasificación Automática de Ortofotografías Aéreas del PNOA

Introducción

Objetivo dual

- Desarrollo de una herramienta para la segmentación automática de imágenes basada en CNN's.
- Análisis de los recursos computacionales del CESGA para este tipo de aplicaciones.



Clasificación Automática de Ortofotografías Aéreas del PNOA

Caso de Uso

Elaboración automática de la capa SIOSE.

Actualidad:

- Procesado manual con diversas fuentes de referencia (satélite, PNOA,...)



Diversas fuentes



SIOSE

www.gradient.org



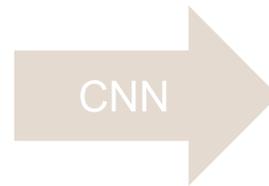
Clasificación Automática de Ortofotografías Aéreas del PNOA

Caso de Uso

Elaboración automática de la capa SIOSE.



PNOA



Predicción (arbolado forestal)

Ventajas:

- Automatización del proceso.
- Ahorro de tiempo.



Clasificación Automática de Ortofotografías Aéreas del PNOA

Procesado del Dataset

Dos fuentes de información proporcionadas por el CESGA*:

- Imágenes RGB, procedentes del PNOA (años 2005 y 2010)
- Imágenes SIOSE (años 2006 y 2011)

+ 150 imágenes de 54000x38000 pixeles (+ 2000 millones de pixeles cada una)

* Procesado realizado CESGA: (reescalado, recortado, filtrado)



Clasificación Automática de Ortofotografías Aéreas del PNOA

Dataset. Dificultades

- **Imágenes del SIOSE con fotointerpretación incompleta**

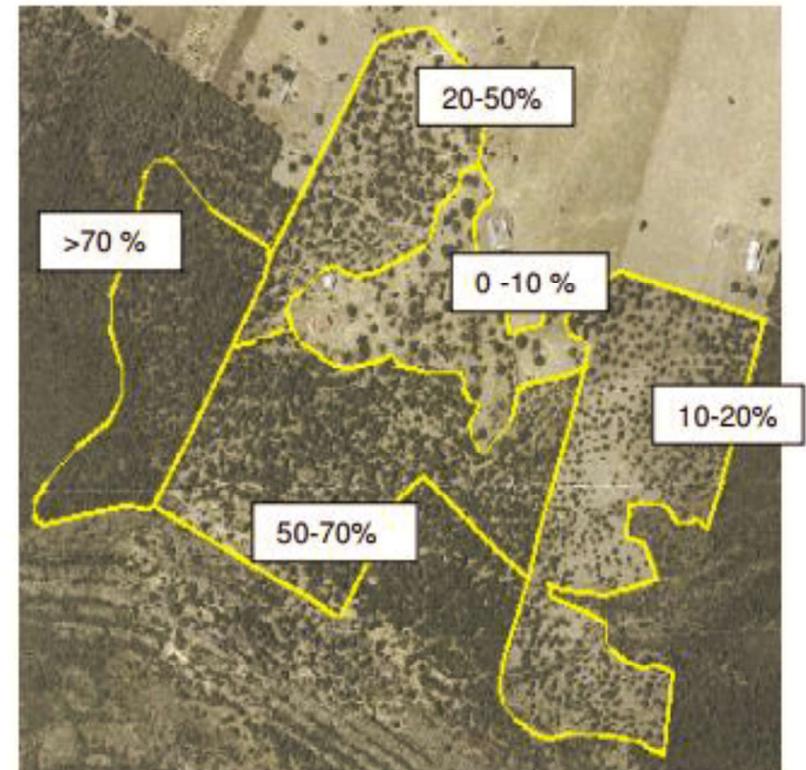
Sucede cuando no toda la superficie de una imagen está etiquetada.

- **Fotointerpretación inexacta.**

La interpretación no se corresponde al 100% con la realidad de la imagen PNOA a la que hace referencia.

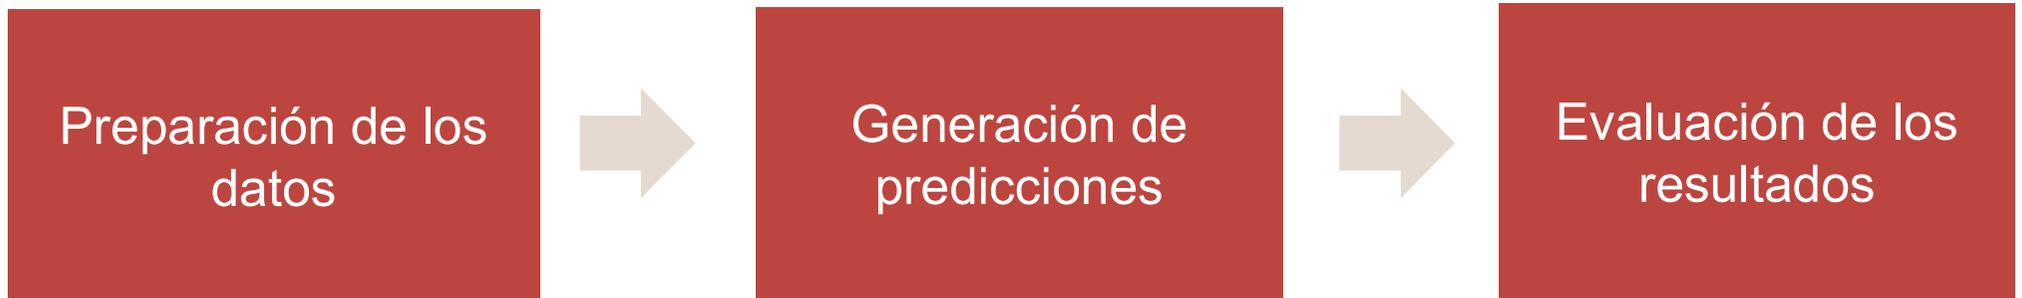
- **Existencia de coberturas compuestas**

Cuando una cierta área aparece identificada con una cobertura compuesta, es decir, se le ha asignado más de un tipo de cobertura y cada una de ellas con un cierto porcentaje.



Clasificación Automática de Ortofotografías Aéreas del PNOA

Metodología y Desarrollo del Proyecto



Re-etiquetado del ground-truth

Extracción de Imágenes

Creación de ficheros LMDB

Entrenamiento del modelo

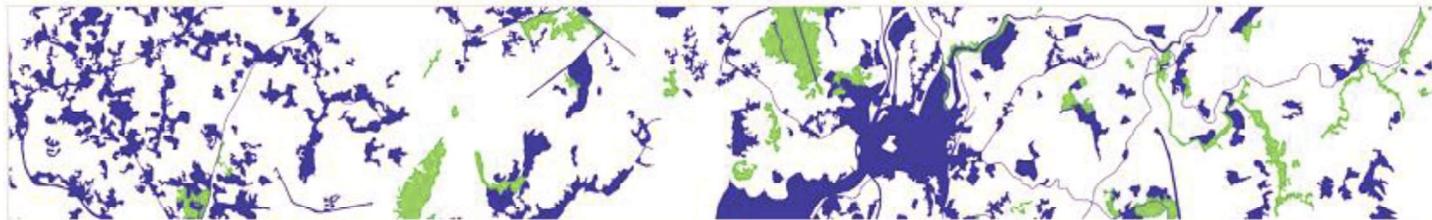


Clasificación Automática de Ortofotografías Aéreas del PNOA

Resultados: caso A



Imagen original PNOA



Fotointerpretación SIOSE: ■ No forestal; ■ Forestal; Sin fotointerpretación



Color: Píxel de *groun-truth* con color PNOA original; Negro: Píxel sin fotointerpretación SIOSE



Clasificación Automática de Ortofotografías Aéreas del PNOA

Resultados: caso A



Predicción:  No forestal;  Forestal;  Sin fotointerpretación



Predicción en parcelas forestales:  Error (FN);  Correcto (TP);  Sin fotointerpretación



Predicción en parcelas no forestales:  Correcto (TN);  Error (FP);  Sin fotointerpretación



Clasificación Automática de Ortofotografías Aéreas del PNOA

Resultados: caso A



Imagen original PNOA



Fotointerpretación SIOSE: ■ No forestal; ■ Forestal; Sin fotointerpretación

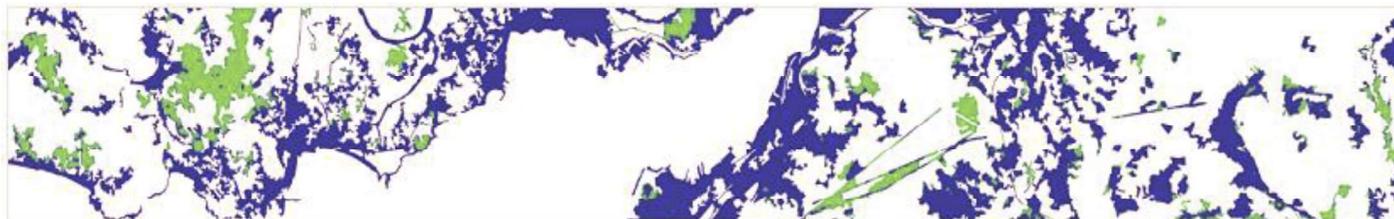


Color: Píxel de *groun-truth* con color PNOA original; Negro: Píxel sin fotointerpretación SIOSE



Clasificación Automática de Ortofotografías Aéreas del PNOA

Resultados: caso A



Predicción: No forestal; Forestal; Sin fotointerpretación



Predicción en parcelas forestales: Error (FN); Correcto (TP); Sin fotointerpretación



Predicción en parcelas no forestales: Correcto (TN); Error (FP); Sin fotointerpretación



Clasificación Automática de Ortofotografías Aéreas del PNOA

Conclusiones

Viabilidad del Sistema

- Utilización de redes neuronales profundas es una herramienta adecuada para la clasificación semántica de coberturas del terreno
- Accuracy \approx 90%
- Resultados extrapolables a otras categorías de alto nivel
- Posibilidad de clasificaciones en categorías de más bajo nivel

Ventajas en la utilización de la infraestructura del CESGA.

- Reducción de los tiempos de computación (resultado esperado)
- Capacidades CESGA (ahora mismo imposibilidad de replicar los resultados en otro entorno)

Inconvenientes.

- Dificultades adecuación de algoritmos y distribución Caffe al entorno CESGA
- Pérdida de flexibilidad debido al sistema de colas



Clasificación Automática de Ortofotografías Aéreas del PNOA

Conclusiones. Trabajo Futuro

Tiempos de Cómputo

- En la fase de preparación de datos: código secuencial altamente paralelizable
- Fase entrenamiento: análisis de hiperparámetros

Exactitud en la predicción

- Arquitectura.
- Disponibilidad de datos de entrenamiento con un nivel de fotointerpretación más elevado
- Técnicas de Data Augmentation

Otros problemas

- Clasificación simultánea de más de dos categorías, lo que requeriría modificaciones en la arquitectura.
- Explorar otros escenarios y/o conjuntos de imágenes en otras bandas espectrales.

