

# Detección y segmentación automática de lesiones en pacientes con esclerosis múltiple en imágenes de resonancia magnética

José Carlos García Pérez

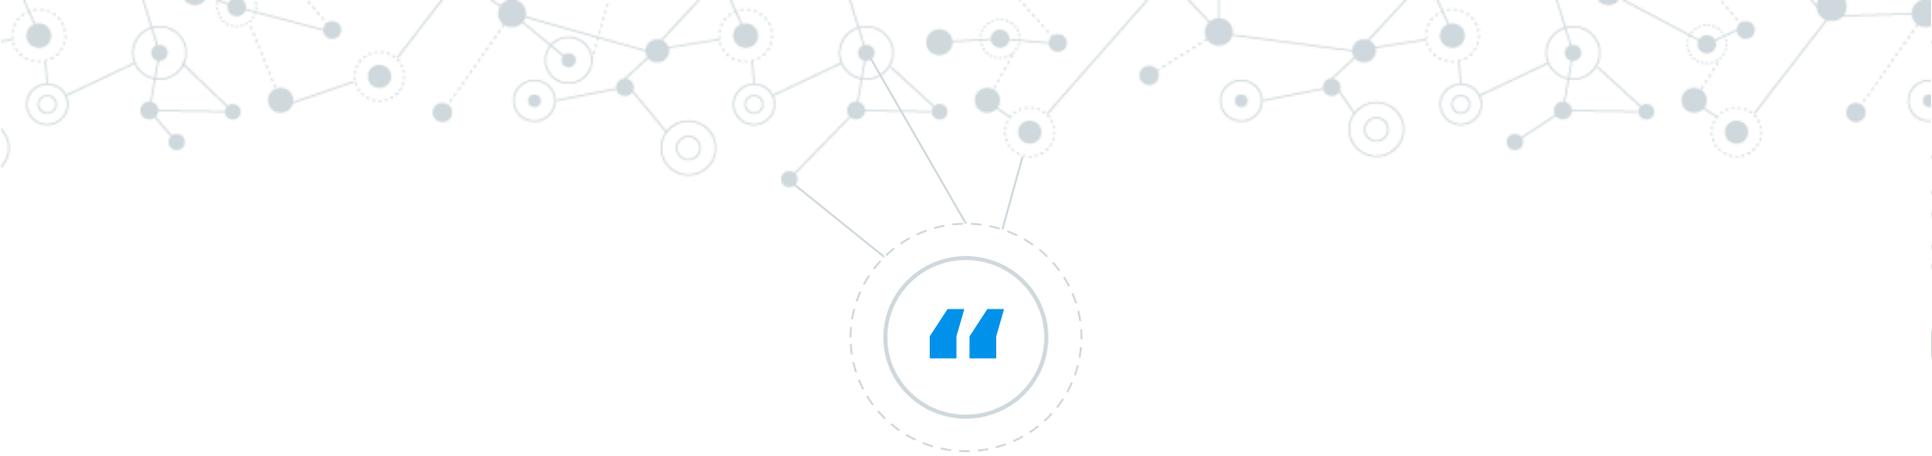
Máster Universitario en Ciencia de Datos  
Área de minería de datos y machine learning

# Índice

- ⊙ Contexto
- ⊙ Objetivos
- ⊙ Metodología
- ⊙ Resultados
- ⊙ Conclusiones



# 1. Contexto



“

*Cada año se diagnostican  
en España **1800 nuevos  
casos de esclerosis  
múltiple***

*Sociedad Española de Neurología (SEN)*



**47.000**

pacientes en España

**600.000**

pacientes en Europa

**2.500.000**

pacientes en todo el mundo

Fuente: Esclerosis Múltiple España  
[www.esclerosismultiple.com](http://www.esclerosismultiple.com)

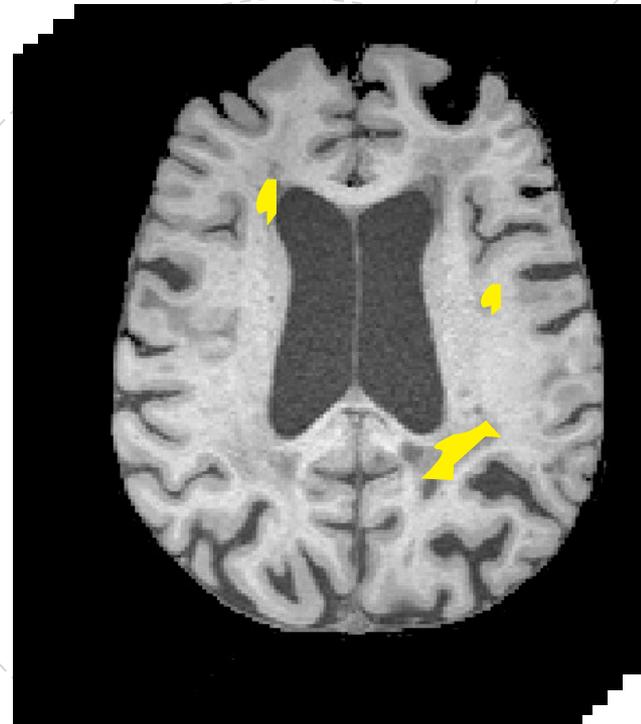
## Contexto

- La esclerosis múltiple es una enfermedad crónica neurodegenerativa del sistema nervioso central
- Es una de las causas más importantes de discapacidad en adultos jóvenes
- Presenta lesiones visibles en imágenes de RM

## Contexto

La detección  
por parte de  
un especialista  
es un proceso

**lento**  
y  
**muy**  
**complejo**



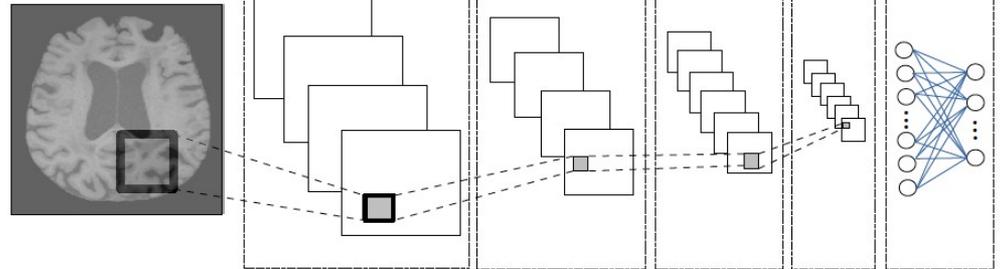


# 2. **Objetivos**

Objetivos

# Detección automática

Redes neuronales convolucionales



## Objetivos

### **Detección**

y segmentación  
de lesiones  
mediante redes  
neuronales  
convolucionales

### **Ajuste**

de hiperparámetros  
que permitan  
optimizar el  
resultado de la  
segmentación

### **Procesamiento**

Definir tareas de  
pre y  
postprocesamiento  
que permitan  
mejorar el  
rendimiento

A decorative network diagram in the top-left corner, consisting of various sized nodes (some solid grey, some hollow white) connected by thin grey lines, forming a complex web structure.

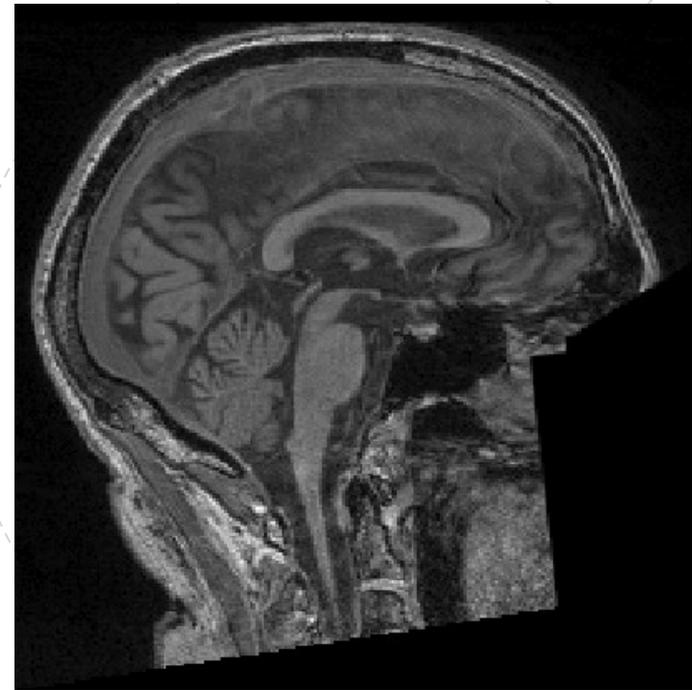
3.

# Metodología

## Anonimización de datos

En cumplimiento con el RGPD, se han anonimizado las imágenes para preservar la identidad del paciente:

- ⦿ Numeración consecutiva
- ⦿ *Deface*: extracción de los rasgos faciales



## Proceso iterativo



## Preprocesamiento

### **Skull stripping**

Eliminación de tejidos no cerebrales presentes en las imágenes de RM

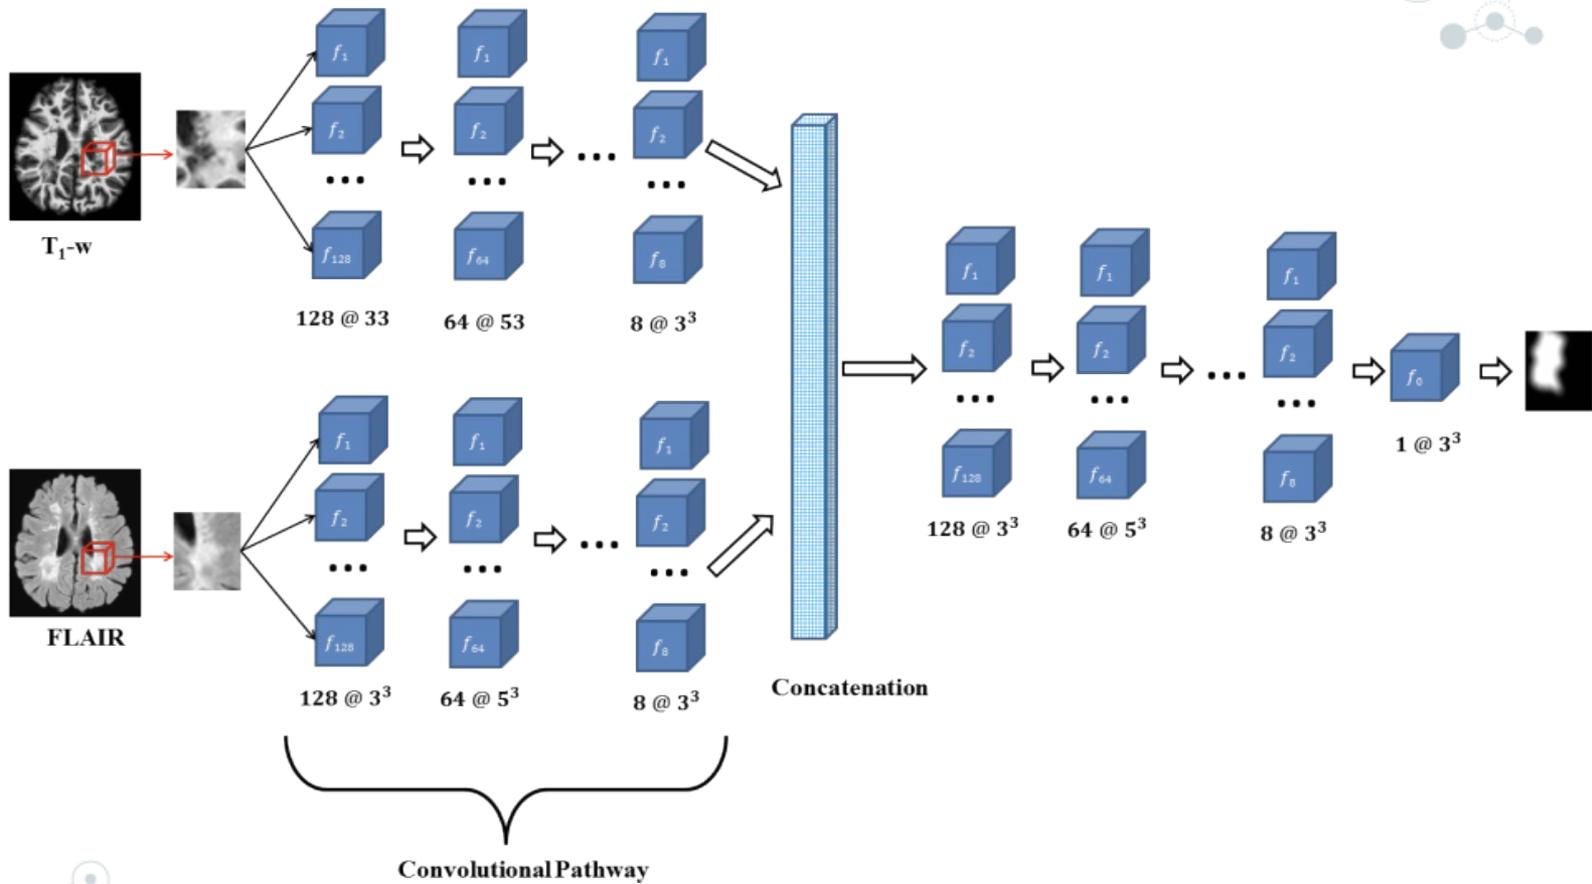
### **Registro**

Ajuste de todas las imágenes de las diferentes modalidades a un espacio común

### **Intensity correction**

Corrección de las inhomogeneidades del campo magnético, que provocan variaciones de intensidad en la imagen para un mismo tejido

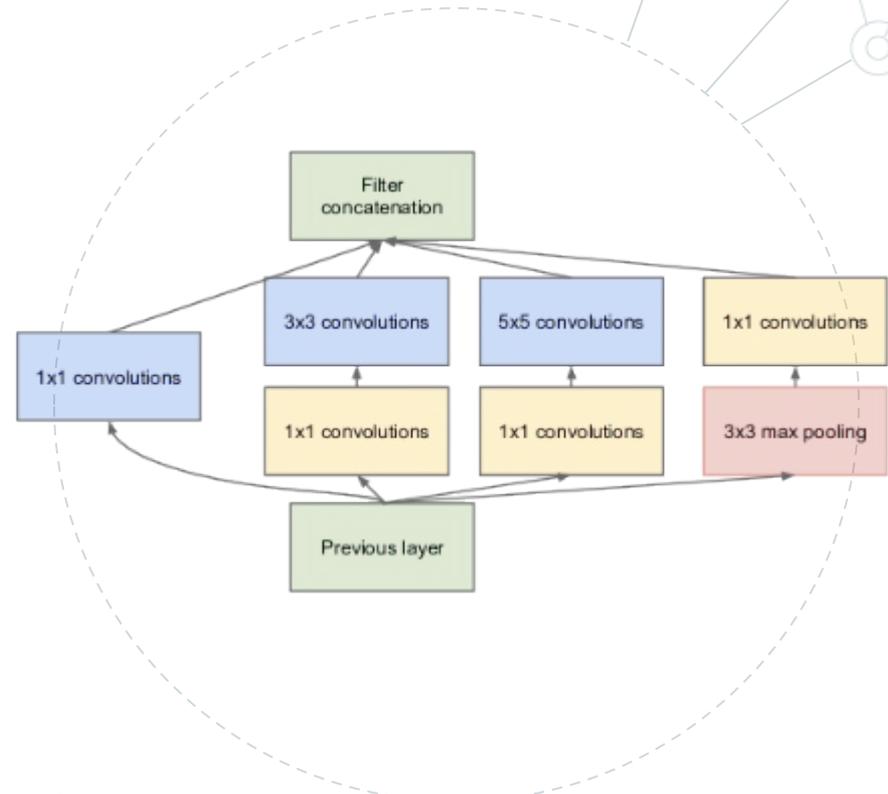
# Entrenamiento



Arquitectura FLEXCONN [Roy, Snehashis, John A. Butman, Daniel S. Reich, Peter A. Calabresi, and Dzung L. Pham. 2018. "Multiple Sclerosis Lesion Segmentation from Brain MRI via Fully Convolutional Neural Networks"]

## Entrenamiento

Se han incorporado módulos ***inception*** en las dos secuencias paralelas de FLEXCONN



*Módulo inception con reducción de dimensionalidad [Szegedy, Christian, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent Vanhoucke, and Andrew Rabinovich. 2014. "Going Deeper with Convolutions"]*

## Postprocesamiento

### **Volumen**

Aplicación de criterios volumétricos para descartar lesiones

### **Región de interés**

Aplicación de máscaras del parénquima cerebral

# Reducción falsos positivos



# Evaluación

## Métrica basada en solapamiento

Cuatro medidas básicas:

- TP
- TN
- FP
- FN



## Índice Dice

Métrica muy útil para medir el solapamiento entre dos superficies

$$DSC = \frac{2|X \cap Y|}{|X| + |Y|}$$

$$DSC = \frac{2TP}{2TP + FP + FN}$$

# Experimentos



## Complejidad

Se ha añadido complejidad al modelo, incorporando módulos *inception*



## Funciones de coste

Se han evaluado diferentes funciones de coste:

MSE, BCE, Jaccard, Dice



## Tamaño del parche

Se han evaluado distintos tamaños de parches:

21x21, 25x25

31x31, 35x35

41x41 y 45x45



## Imágenes 2D

Se han usado imágenes 2D, debido a las limitaciones de la infraestructura hardware utilizada



## Modelo

Train

Test



## Tasa de aprendizaje

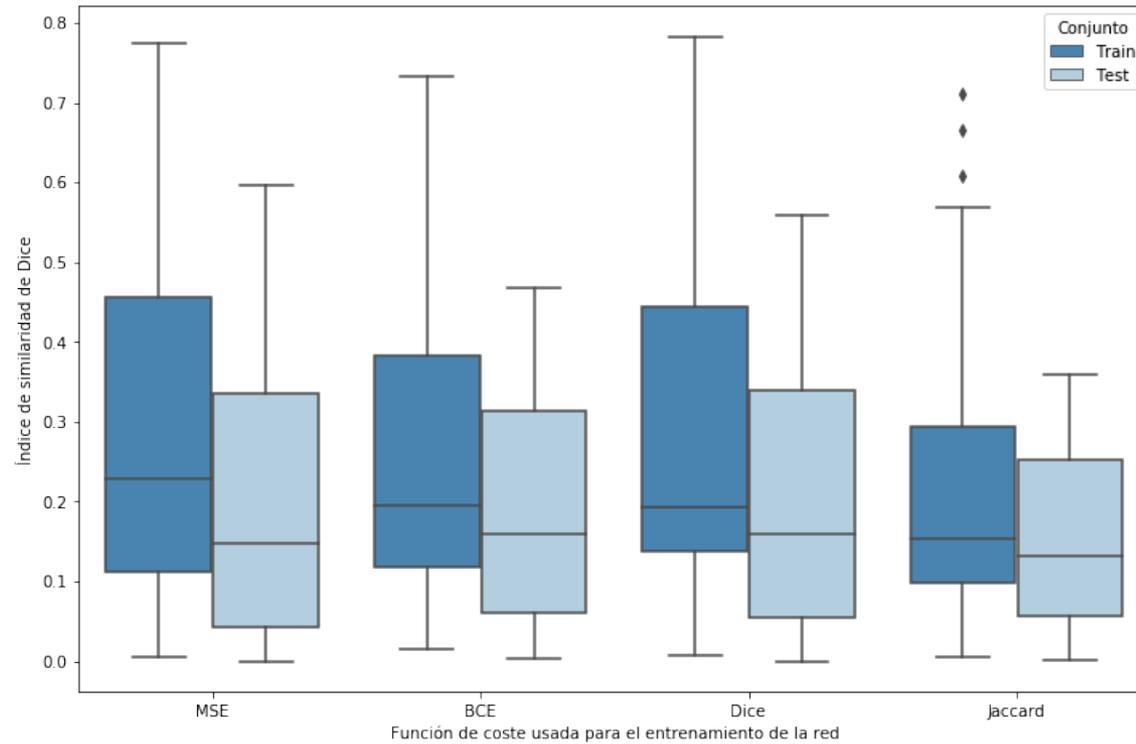
Se ha ajustado la tasa de aprendizaje durante el entrenamiento para que el modelo alcance una solución más robusta

A decorative network diagram in the top-left corner, consisting of various sized circles (nodes) connected by thin lines (edges). Some nodes are solid grey, while others are hollow with a grey outline. The connections form a complex, interconnected web.

4.

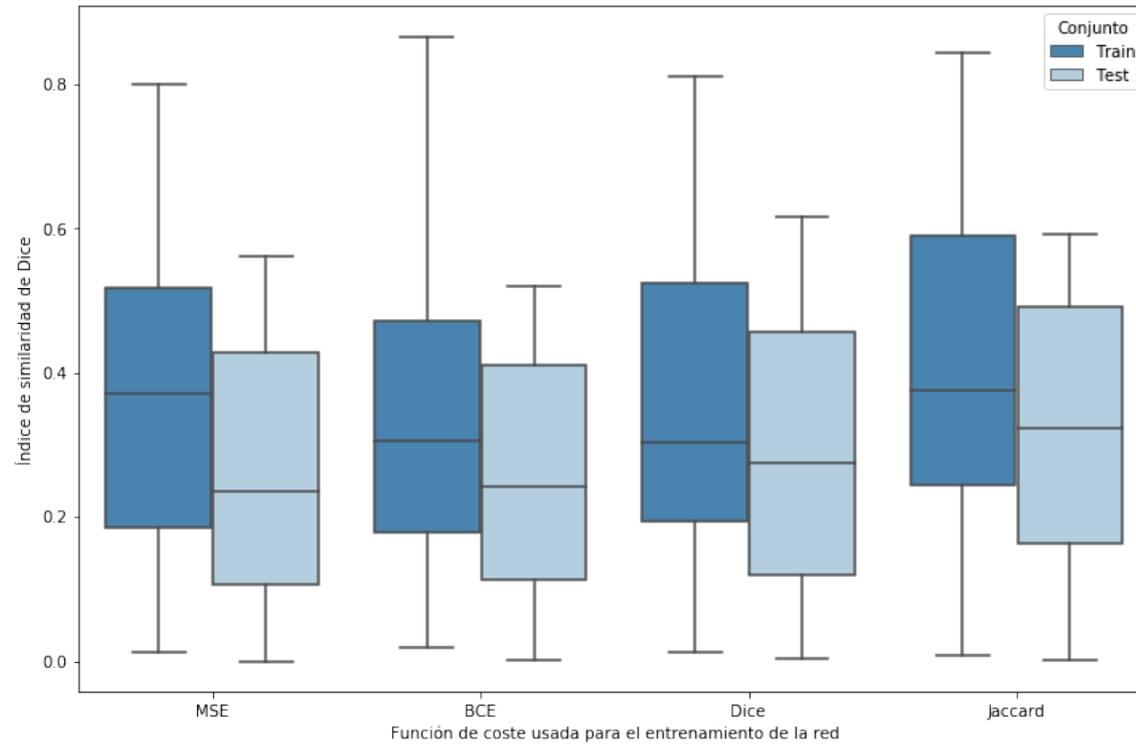
# Resultados

# Resultados - FLEXCONN



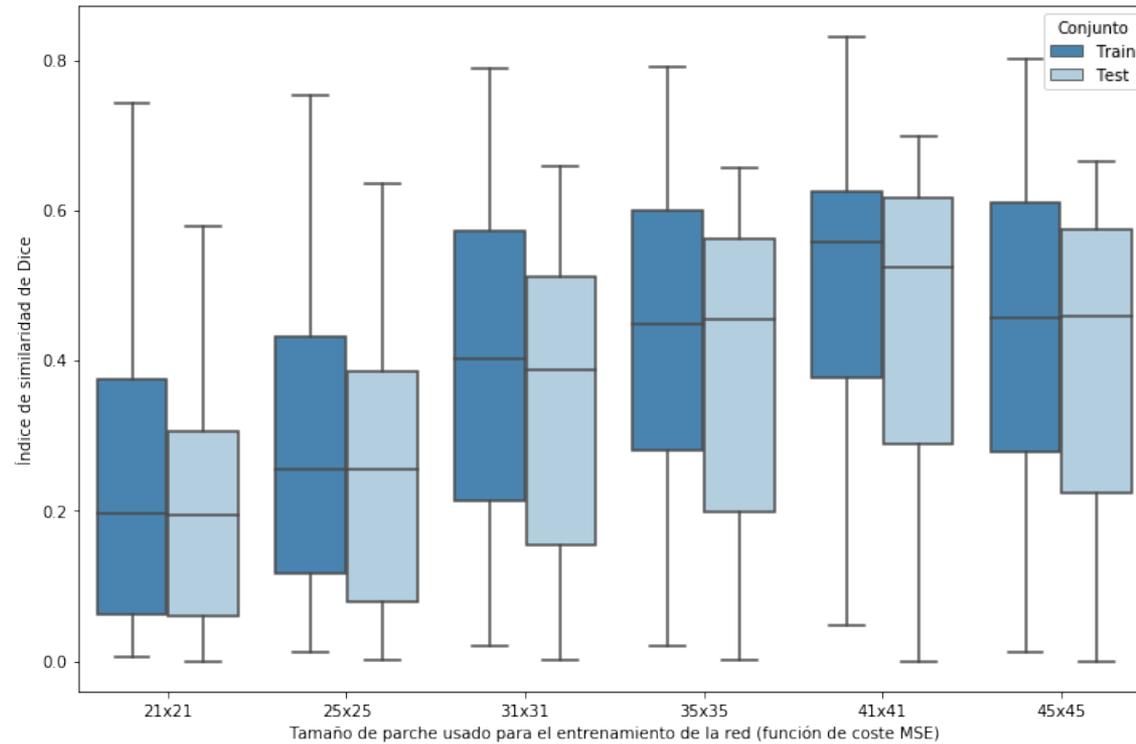
	MSE	BCE	Dice	Jaccard
Dice promedio	0,25	0,22	0,18	0,24

# Resultados - Inception



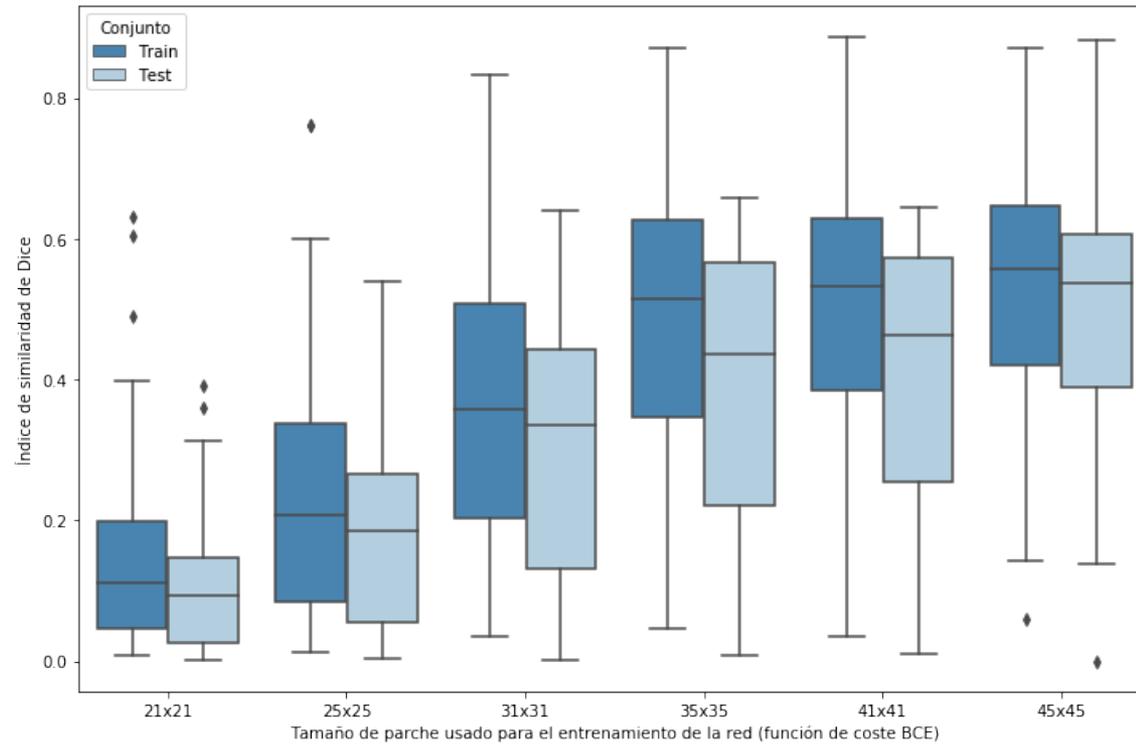
	MSE	BCE	Dice	Jaccard
Dice promedio	0,31	0,30	0,35	0,32

# Resultados - MSE



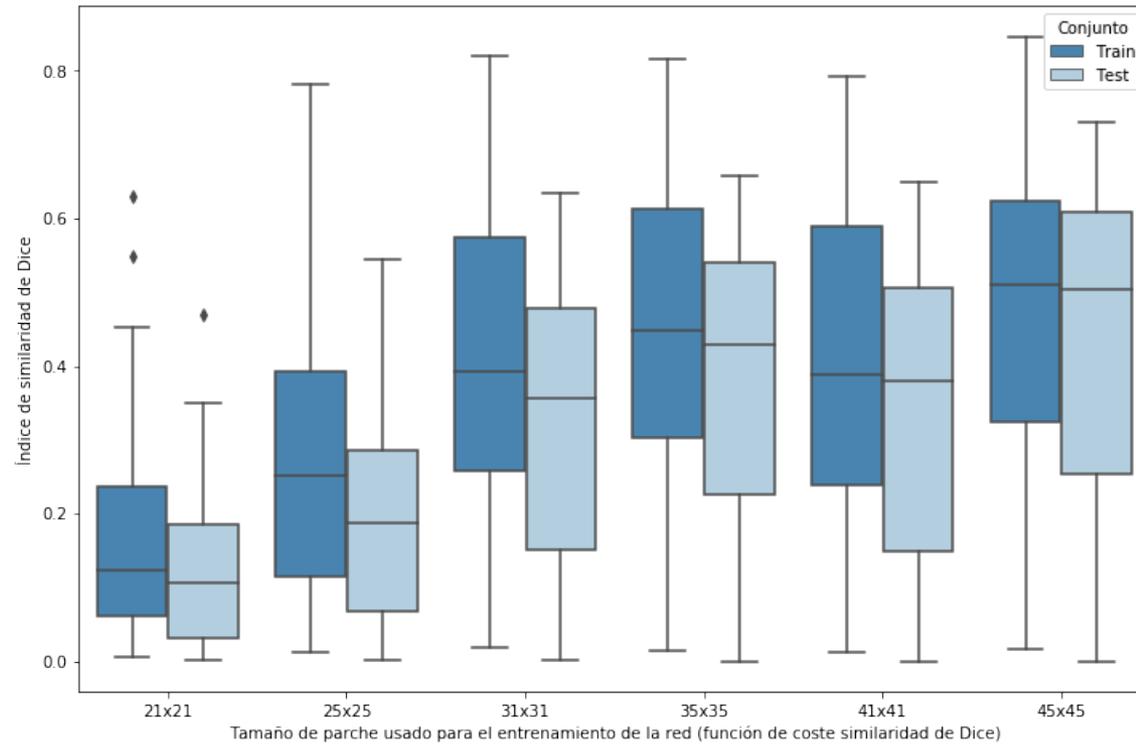
	21x21	25x25	31x31	35x35	41x41	45x45
Dice promedio	0,22	0,27	0,37	0,40	0,48	0,41

# Resultados - BCE



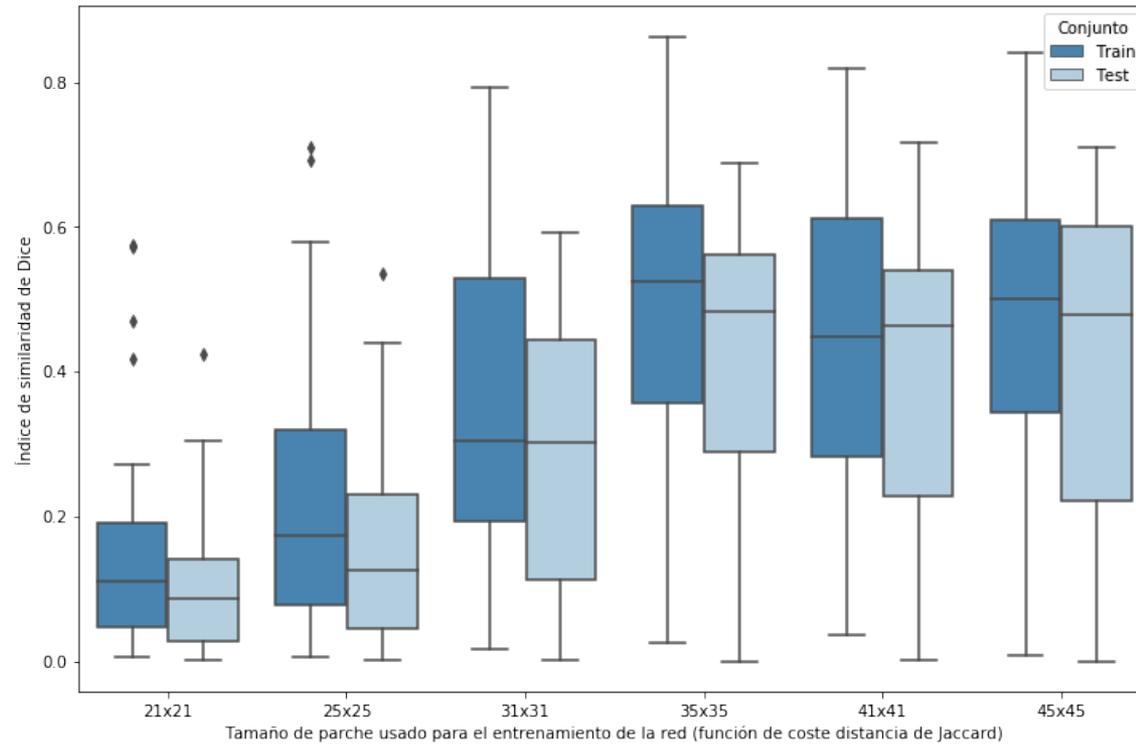
	21x21	25x25	31x31	35x35	41x41	45x45
Dice promedio	0,13	0,21	0,33	0,43	0,45	0,51

# Resultados - Dice



	21x21	25x25	31x31	35x35	41x41	45x45
Dice promedio	0,14	0,23	0,36	0,40	0,37	0,47

# Resultados - Jaccard



	21x21	25x25	31x31	35x35	41x41	45x45
Dice promedio	0,12	0,18	0,32	0,45	0,43	0,45



# 5. Conclusiones

Las CNN son una técnica muy prometedora para la identificación y segmentación automática de lesiones

Una infraestructura hardware más potente permitirá mejorar el resultado

3

4

1

2

La calidad de la segmentación aumentará si se descartan las lesiones detectadas en la región de la sustancia gris

Múltiples líneas de trabajo futuro muy prometedoras

## Agradecimientos

- ⊙ Dr. Eloy Martínez de las Heras
- ⊙ Instituto de Investigaciones Biomédicas August Pi i Sunyer (IDIBAPS)
- ⊙ Universitat Oberta de Catalunya
- ⊙ Plantilla de la presentación: [SlidesCarnival](#)

A decorative network diagram in the top right corner, featuring a series of interconnected nodes and lines, some solid and some dashed, in shades of blue and grey.

# ¡Muchas gracias!

[jcarlosgarcia@uoc.edu](mailto:jcarlosgarcia@uoc.edu)