

Diagnóstico de miopía patológica en imágenes de fondo de ojo mediante aprendizaje profundo

Daniel López Robles

TFG Área de **Inteligencia Artificial**

Grado en **Ingeniería Informática**

Dirigido por el **Dr. Joan M. Núñez Do Río**

Universitat Oberta de Catalunya - 21/06/2020



Índice


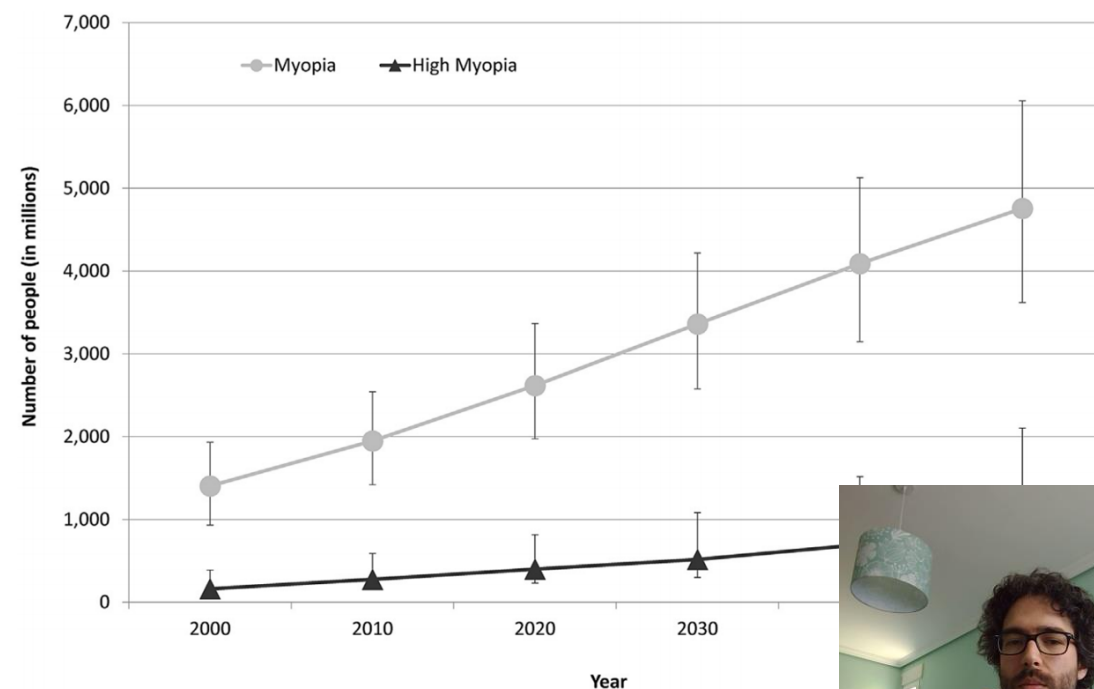
1. Introducción.
2. Miopía patológica.
3. *Machine Learning*.
4. Metodología.
5. Experimentos y resultados.
6. Discusión y conclusiones.



Introducción

Contexto, justificación y objetivos

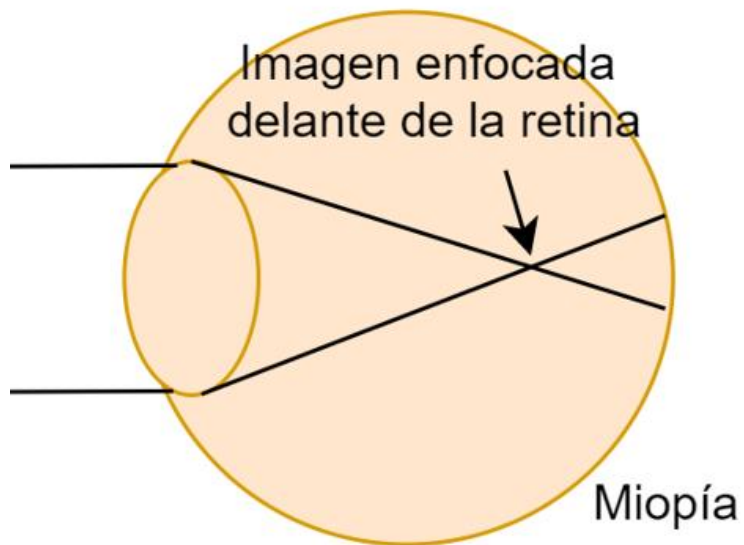
- ⚠️ En 2050 la mitad de la población mundial será miope.
- ⚠️ Alta miopía: principal causa de afiliación a la ONCE.
- ⚠️ Miopía patológica: puede causar ceguera irreversible.
- ⚠️ La tasa de población mayor de 60 años está creciendo el doble que la de profesionales de oftalmología.
- ✅ *Deep Learning* ofrece herramientas prometedoras.
- 🔍 Investigar *Machine Learning* y su aplicación al diagnóstico de miopía patológica.
- 🔍 Explorar soluciones basadas en redes neuronales convolucionales para la detección de la miopía patológica en imágenes de fondo de ojo.



Miopía patológica

Forma más grave de miopía

Miopía



<

Alta miopía

> 6 dioptrías

o

> 26,5 mm de longitud axial

<

Miopía patológica

Alta miopía

+

Patología asociada



3% de la población



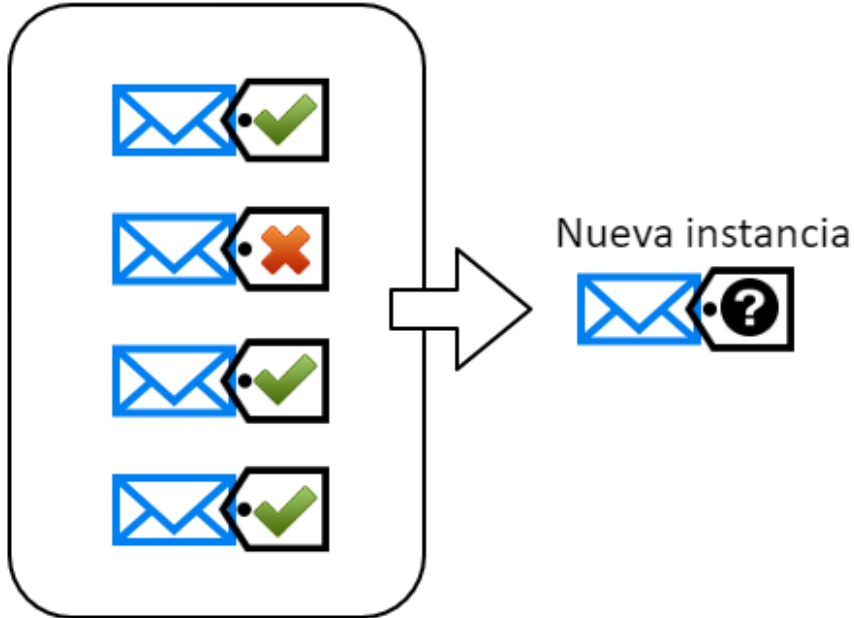
4ª causa de ceguera en países desarrollados



Machine Learning

Aprendizaje **automático** a partir de los datos


Conjunto de entrenamiento



Aprendizaje supervisado

- Clasificación: valores categóricos
- Regresión: valores numéricos

Conjunto de entrenamiento

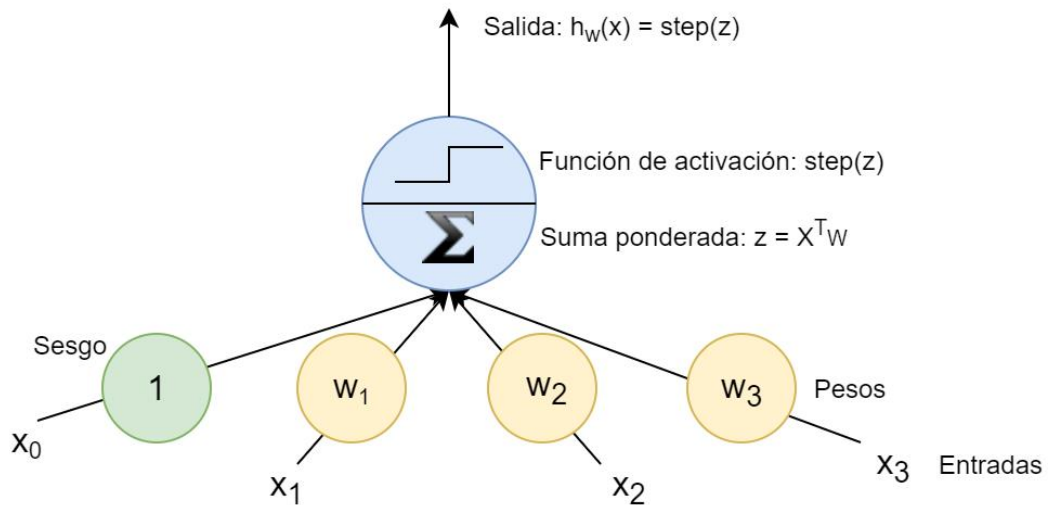


Aprendizaje no supervisado

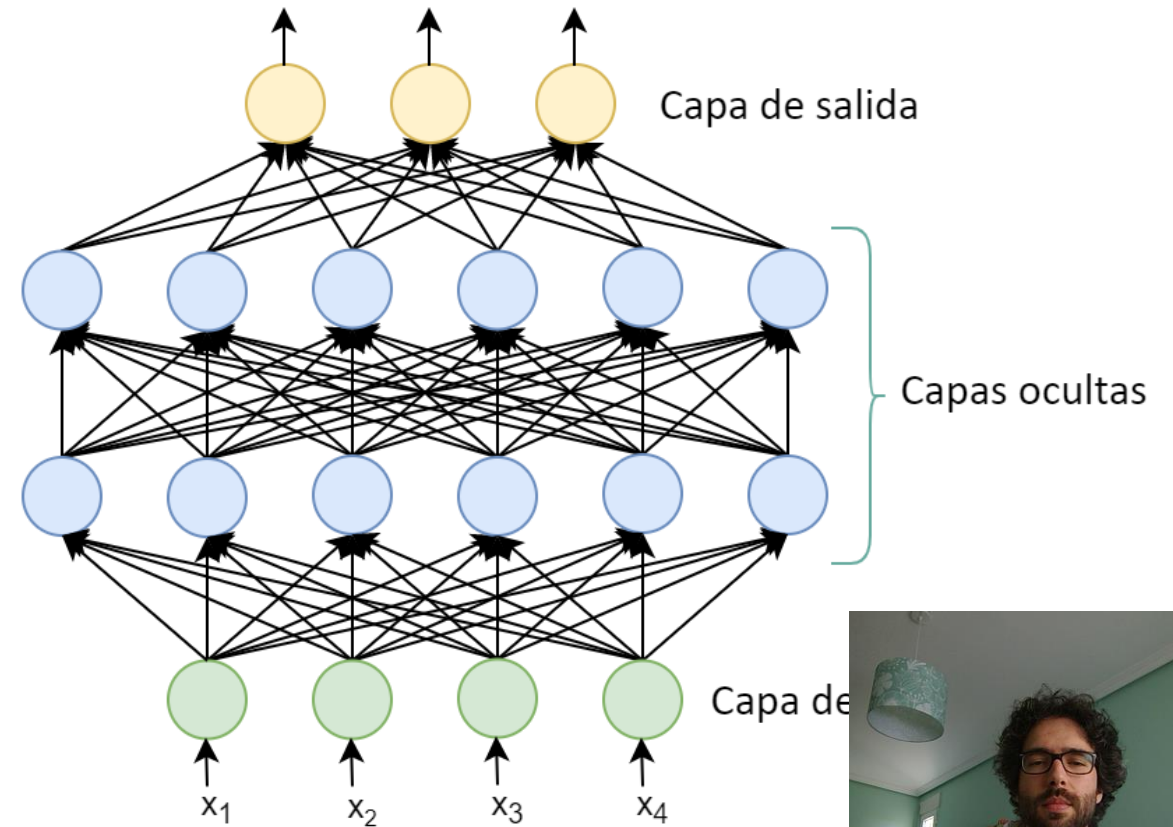


Deep Learning

Tratamiento de problemas complejos mediante **redes neuronales artificiales**



Threshold Logic Unit (TLU)




Red neuronal artificial




Convolutional Neural Networks

Redes neuronales artificiales especializadas en el tratamiento de imágenes



Convolución



Reducción de muestreo



Arquitecturas CNN estándar

VGGNet

ILSVRC 2014:


- 1º localización
- 2º clasificación

Conjuntos de 2 ó 3 capas convolucionales seguidas de *pooling layer*.

ResNet

ILSVRC 2015:

- 1º localización
- 1º clasificación
- 1º detección

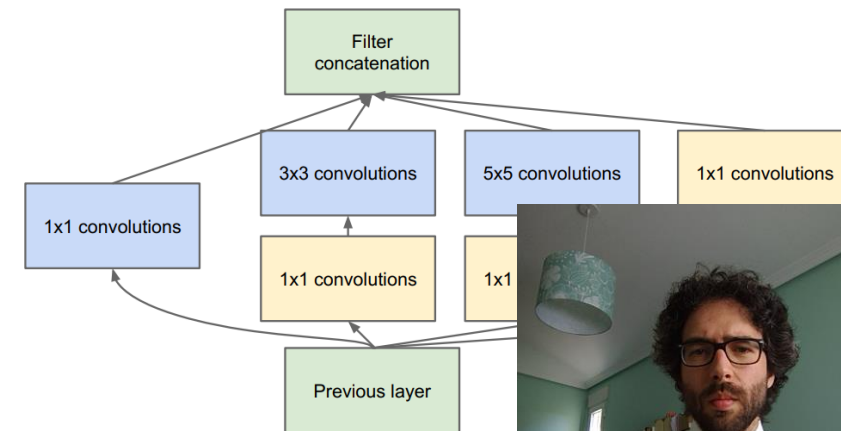


Bloque de construcción de ResNet

GoogleNet

ILSVRC 2014:

- 1º clasificación
- 1º clasificación



Módulo inception de





Entrenamiento

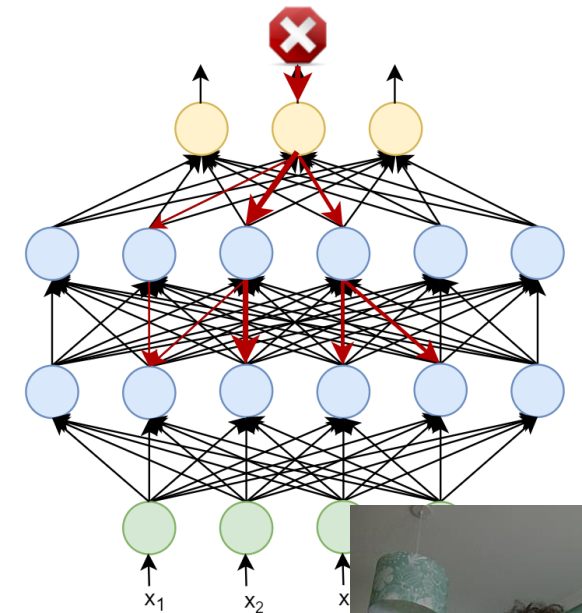
Adaptar los parámetros de un modelo para que se ajuste al conjunto de datos

A	B	C	D	E	F	G	H	I	J	K	
1	Id	MSSubClass	MSZoning	LotFrontage	LotArea	Street	Alley	LotShape	LandContour	Utilities	LotConfig
2	1	60	RL	65	8450	Pave	NA	Reg	Lvl	AllPub	Inside
3	2	20	RL	80	9600	Pave	NA	Reg	Lvl	AllPub	FR2
4	3	60	RL	68	11250	Pave	NA	IR1	Lvl	AllPub	Inside
5	4	70	RL	60	9550	Pave	NA	IR1	Lvl	AllPub	Corner
6	5	60	RL	84	14260	Pave	NA	IR1	Lvl	AllPub	FR2
7	6	50	RL	85	14115	Pave	NA	IR1	Lvl	AllPub	Inside
8	7	20	RL	75	10084	Pave	NA	Reg	Lvl	AllPub	Inside
9	8	60	RL	NA	10382	Pave	NA	IR1	Lvl	AllPub	Corner
10	9	50	RM	51	6120	Pave	NA	Reg	Lvl	AllPub	Inside
11	10	190	RL	50	7420	Pave	NA	Reg	Lvl	AllPub	Corner
12	11	20	RL	70	11200	Pave	NA	Reg	Lvl	AllPub	Inside
13	12	60	RL	85	11924	Pave	NA	IR1	Lvl	AllPub	Inside
14	13	20	RL	NA	12968	Pave	NA	IR2	Lvl	AllPub	Inside
15	14	20	RL	91	10652	Pave	NA	IR1	Lvl	AllPub	Inside


Datos del mundo real



Modelo



Backpropag



Descenso del gradiente




Validación

Split 1	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5
Split 2	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5
Split 3	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5
Split 4	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5
Split 5	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5

Validación
 Entrenamiento

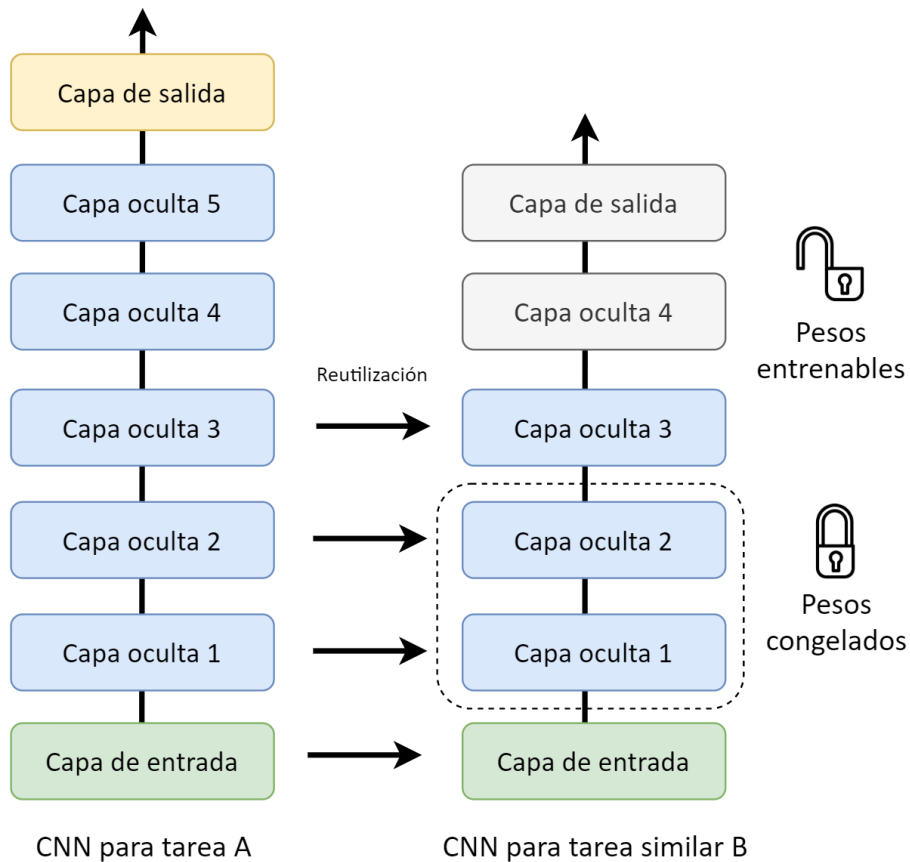
Validación cruzada



Validación cruzada estratificada



Transfer Learning / Optimización



Transfer Learning

Optimización de hiperparámetros:

- **Randomized Search:** exploración de combinaciones de hiperparámetros aleatorias sobre un espacio de búsqueda amplio.
- **Grid Search:** exploración exhaustiva de combinaciones de hiperparámetros sobre un espacio de búsqueda más reducido.



Metodología

Dataset

PALM: PAtHoLogic Myopia Challenge.


- Miopía patológica: 213 imágenes (53,25%).
- Alta miopía: 26 imágenes (6,5%).
- Vista normal: 161 imágenes (40,25%).

➔ 2 clases: PM y non-PM

Data augmentation

- *Shearing*: de forma aleatoria dentro de un rango
- *Zoom*: de forma aleatoria dentro de un rango
- *Horizontal flip*.

Stratified Cross Validation



Randomized Search y Grid Search

- Tamaño de imágenes de entrada: 16x16, 32x32, 64x64, 128x128, 256x256 píxeles.
- Número de conjuntos de capas convolucional+*MaxPooling*: 1, 2, 3.
- Número y tamaño de los filtros:
 - Filtros en la primera capa: 16, 32, 64.
 - Tamaño de filtros de la primera capa: 7x7, 5x5.
 - Filtros del resto de capas: 16, 32, 64.
 - Tamaño de filtros del resto de capas: 3x3, 2x2.
 - Tamaño *MaxPool* de la primera capa: 3x3, 2x2.
- Función de optimización: SGD, Adam.
- *Learning rate*: 0,001, 0,01, 0,1, 0,3.
- *Momentum*, solo para el caso de SGD: 0,0, 0,4, 0,8.
- Tasa de *dropout*: 0,3, 0,5, 0,7.
- Épocas: 15, 30, 50.
- Tamaño de *batch*: 2, 4, 8, 16, 32.


Transfer Learning


VGG16

ResNet50

VGG19

InceptionV3
(42 capas)





Randomized Search

Accuracy	Capas	Filtros L1	Tamaño filtros L1	Filtros n	Tamaño filtros n	Optimizer	Mom.	MaxPool 1	MaxPool n	LR	Epochs	Dropout	Batch
0.948 (0.02)	3	16	5x5	16	2x2	Adam	-	3x3	2x2	0.001	'30	0.5	32
0.925 (0.02)	3	16	5x5	64	3x3	Adam	-	3x3	2x2	0.001	'50	0.7	32
0.895 (0.04)	1	64	5x5	-	-	SGD	0.0	3x3	2x2	0.001	'15	0.3	16
0.893 (0.04)	2	64	5x5	64	2x2	Adam	-	2x2	2x2	0.001	'30	0.7	2
0.748 (0.17)	3	16	5x5	64	3x3	Adam	-	2x2	2x2	0.01	'15	0.3	2


Mejores combinaciones de hiperparámetros para entrada de 128x128 píxeles

Accuracy	Capas	Filtros L1	Tamaño filtros L1	Filtros n	Tamaño filtros n	Optimizer	Mom.	MaxPool 1	MaxPool n	LR	Epochs	Dropout	Batch
0.935 (0.01)	3	32	7x7	16	2x2	Adam	-	2x2	2x2	0.001	50	0.5	32
0.923 (0.01)	2	16	5x5	32	2x2	Adam	-	3x3	2x2	0.001	15	0.7	8
0.908 (0.03)	2	16	5x5	16	3x3	Adam	-	3x3	2x2	0.001	30	0.7	4
0.883 (0.03)	3	32	7x7	16	2x2	Adam	-	3x3	2x2	0.01	30	0.7	16
0.880 (0.047)	1	32	7x7	-	-	SGD	0.8	2x2	2x2	0.001	50	0.7	32

Mejores combinaciones de hiperparámetros para entrada de 256x256 píxeles

- 128x128 ó 256x256 píxeles.
- 2 ó 3 conjuntos de capa convolucional + reducción de muestreo.
- Función de optimización Adam y un *learning rate* base de 0.001.
- Valores altos de épocas y tamaño de batch.





Grid Search


Accuracy	Batch	Epochs	Layers	Filtros L1	Filtros n
0.940 (0.017)	32	50	2	16	16
0.940 (0.009)	16	50	2	16	32
0.938 (0.025)	32	50	3	32	32
0.938 (0.014)	16	30	3	32	16
0.935 (0.035)	32	30	3	32	32

Mejores combinaciones de hiperparámetros para entrada de 128x128 píxeles

Accuracy	Batch	Epochs	Layers	Filtros L1	Filtros n
0.953 (0.027)	32	50	3	32	16
0.943 (0.034)	32	30	3	16	32
0.940 (0.023)	32	30	2	16	32
0.938 (0.022)	16	50	3	16	32
0.935 (0.034)	16	50	2	32	32

Mejores combinaciones de hiperparámetros para entrada de 256x256 píxeles

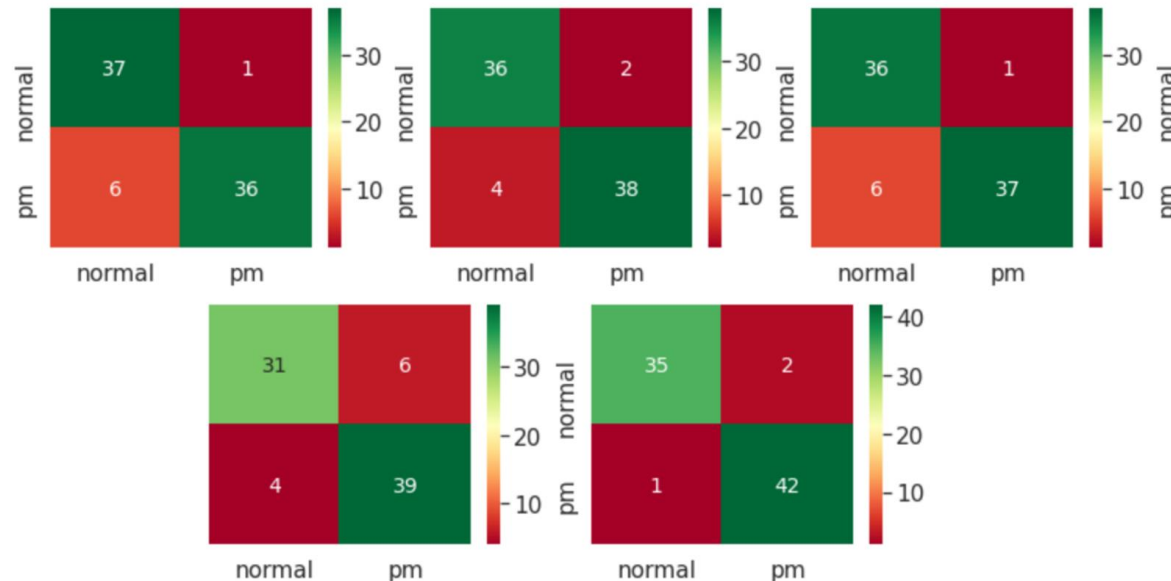
- 256x256 píxeles de entrada.
- 3 conjuntos de capas convolucional+*MaxPooling*.
- 1ª capa convolucional 32 filtros de 5x5. El resto de capas, 16 filtros de 2x2. Filtro de *max pool* de la primera capa de 3x3 y el resto 2x2.
- Adam con LR 0,001 como función de optimización.
- 0,5 tasa de *dropout*.
- 50 épocas.
- 32 tamaño de batch.



Métricas del modelo obtenido

	Accuracy	Precision	Recall	AUC
Media (SD)	0.92 (0.029)	0.944 (0.04)	0.906 (0.045)	0.923 (0.026)

Medias y desviación estándar de la CNN optimizada mediante Randomized Search y Grid Search



Matrices de confusión



VGG16 y VGG19


Experimentos de *Transfer Learning* con arquitecturas VGGNet

VGG16

	Accuracy	Precision	Recall	AUC
Media (SD)	0.938 (0.034)	0.940 (0.031)	0.941 (0.032)	0.982 (0.015)

Medias y desviación estándar de las métricas para VGG16

ROC AUC score: 0.9974858579509743




AUC-ROC para VGG16

VGG19


	Accuracy	Precision	Recall	AUC
Media (SD)	0.850 (0.040)	0.861 (0.032)	0.855 (0.037)	0.911 (0.035)

Medias y desviación estándar de las métricas para VGG19

ROC AUC score: 0.9270898805782526



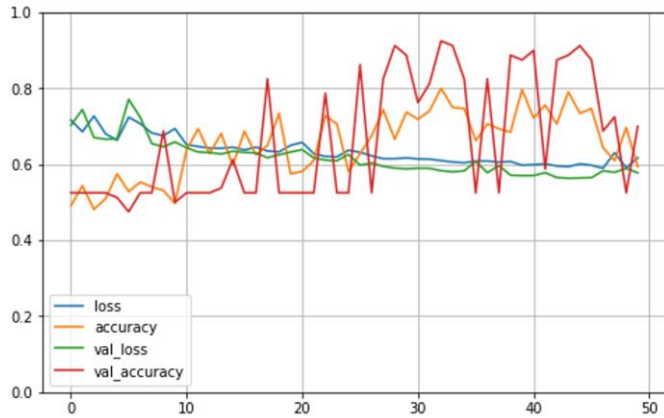
AUC-ROC para VGG19




ResNet50 e InceptionV3

Experimentos de *Transfer Learning* con arquitecturas ResNet y GoogleNet

ResNet50



Curva de aprendizaje para ResNet50




Matriz de confusión

InceptionV3

	Accuracy	Precision	Recall	AUC
Media (SD)	0.547 (0.047)	0.570 (0.042)	0.549 (0.038)	0.613 (0.064)

Medias y desviación estándar de las métricas para InceptionV3



AUC-ROC para InceptionV3



Discusión y conclusiones

	Accuracy	Precision	Recall	AUC
RS y GS	0.920 (0.029)	0.944 (0.04)	0.906 (0.045)	0.923 (0.026)
VGG16	0.938 (0.034)	0.940 (0.031)	0.941 (0.032)	0.982 (0.015)
VGG19	0.850 (0.040)	0.861 (0.032)	0.855 (0.037)	0.911 (0.035)
ResNet50	-	-	-	-
InceptionV3	0.547 (0.047)	0.570 (0.042)	0.549 (0.038)	0.613 (0.064)

- *Randomized Search*: 777.600 combinaciones de hiperparámetros.
- *Grid Search*: 64 combinaciones de hiperparámetros.
- Mejores resultados con modelos menos complejos.

✓ Los resultados alcanzados demuestran el potencial del **aprendizaje profundo** para contribuir en el diagnóstico precoz de la **miopía patológica**.

Líneas de trabajo futuro:

- Otras tareas sobre el mismo conjunto de datos: detección y segmentación de lesiones de retina o localización de la fovea.
- Ampliar la investigación de *transfer learning*.
- Incrementar el conjunto de entrenamiento.

