
Diagnóstico automático de corriorretinitis por toxoplasmosis utilizando técnicas de inteligencia artificial

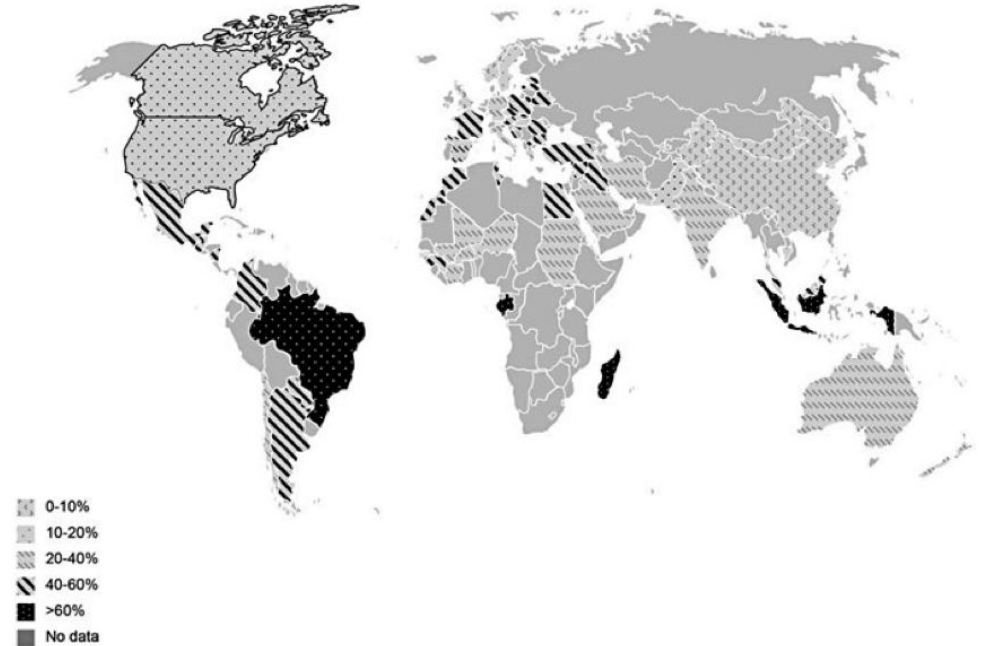

Ing. Verena Ojeda
Octubre 2021

Agenda

- Introducción
- Métodos
 - Conjunto de datos
 - Modelo
 - Experimentos
- Resultados
- Conclusiones


Introducción

Toxoplasmosis Ocular (OT)



C. Ozgonul and C.G. Besirli, Recent Developments in the Diagnosis and Treatment of Ocular Toxoplasmosis, Ophthalmic Res. 57(1) (2017), 1-12.

Diagnóstico



Clasificación de imágenes de fondo de ojo (OT)



Sano



Enfermo
Lesión inactiva



Enfermo
Lesión activa



Enfermo
Lesión activa e
inactiva

Métodos

Conjunto de datos

413 imágenes de fondo de ojo.


Recolectadas por el Hospital de Clínicas y el Hospital General Pediátrico Acosta Ñu.

Usando cámaras Zeiss y Píktor.

Imágenes segmentadas manualmente por oftalmólogos (lesiones activas e inactivas).

Disponibles públicamente en la pataforma Zenodo para investigación.


Clase	Cant.
Sano	132
Activo	91
Inactivo	190



Datos (cont..)



Inactivo
Enfermo
Lesión inactiva



Activo
Enfermo
Lesión activa




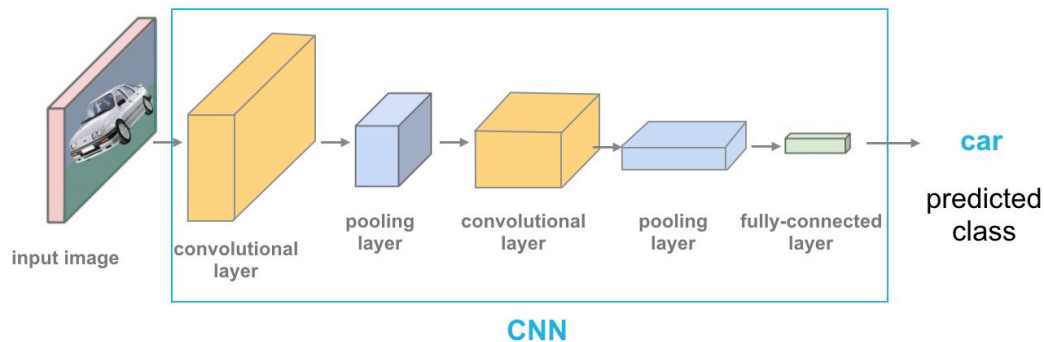
Activo
Enfermo
Lesión activa e
inactiva

Modelo

Deep Learning

Redes N. Convolucionales

- CNN
- VGG16
- **Resnet18**



Modelo (cont.)

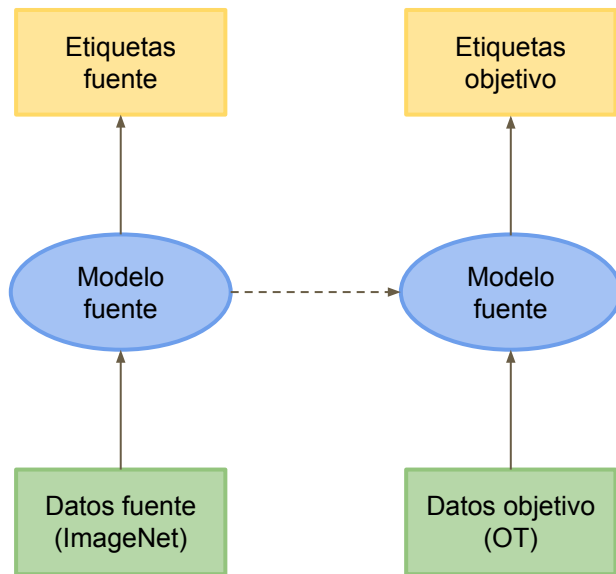
Resnet18

Pre-entrenado con ImageNet


Ajuste fino con nuestro dataset

Imágenes redimensionadas a 512x512 píxeles


Utilizamos data augmentation




Data augmentation




Original



Flip vertical



Flip horizontal



Rotación

Experimentos

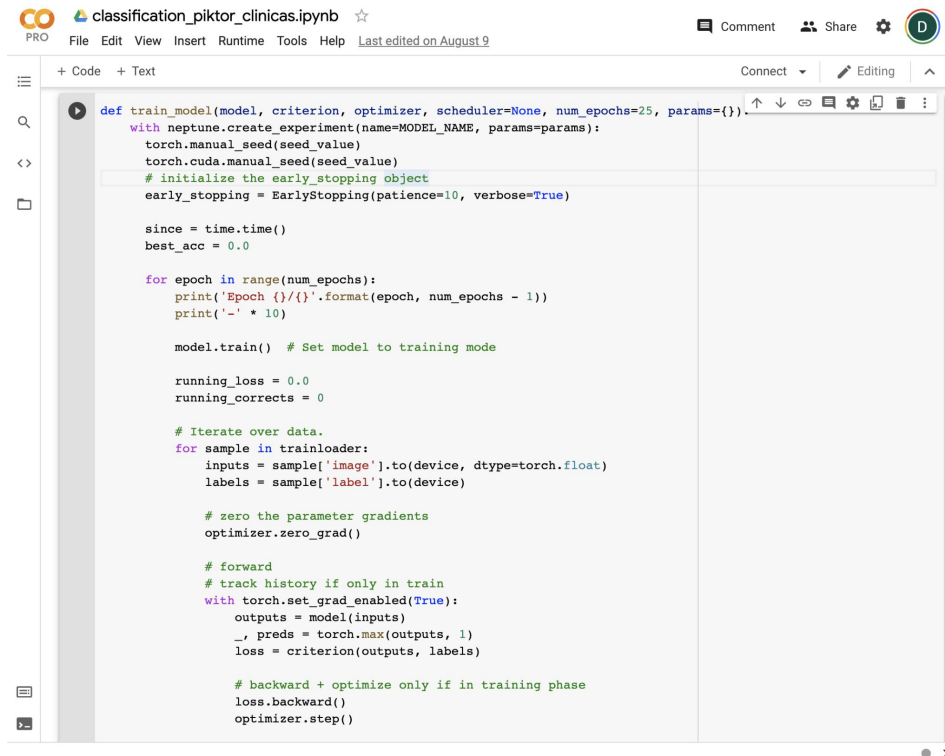
Google Colab Pro

- Nvidia T4 P100 graphic cards
- 25 GB de RAM

Pytorch 1.7

División 70/10/20 para conjuntos de entrenamiento, validación y prueba respectivamente

Código fuente disponible públicamente



```

classification_piktor_clinicas.ipynb ☆
PRO File Edit View Insert Runtime Tools Help Last edited on August 9
+ Code + Text Connect Editing
def train_model(model, criterion, optimizer, scheduler=None, num_epochs=25, params={}):
    with neptune.create_experiment(name=MODEL_NAME, params=params):
        torch.manual_seed(seed_value)
        torch.cuda.manual_seed(seed_value)
        # initialize the early stopping object
        early_stopping = EarlyStopping(patience=10, verbose=True)

        since = time.time()
        best_acc = 0.0

        for epoch in range(num_epochs):
            print('Epoch {}/{}'.format(epoch, num_epochs - 1))
            print('-' * 10)

            model.train() # Set model to training mode

            running_loss = 0.0
            running_corrects = 0

            # Iterate over data.
            for sample in trainloader:
                inputs = sample['image'].to(device, dtype=torch.float)
                labels = sample['label'].to(device)

                # zero the parameter gradients
                optimizer.zero_grad()

                # forward
                # track history if only in train
                with torch.set_grad_enabled(True):
                    outputs = model(inputs)
                    _, preds = torch.max(outputs, 1)
                    loss = criterion(outputs, labels)

                # backward + optimize only if in training phase
                loss.backward()
                optimizer.step()

```

https://drive.google.com/drive/folders/1gfk13adBM3uw5AFcWJG_mzgpHoFVxltC?usp=sharing

Experimentos (cont.)

50 epochs

learning rate: 0.001

Early stopping

Primera fase

Clasificación binaria

Segunda fase

Clasificación multiclase

Optimizadores

SGD

SGD with momentum

RMSProp

Adam

Arquitecturas

CNN

VGG16

Resnet18

Resultados

Clasificación multiclase

Optimizador	Exactitud	Sensibilidad	Especificidad
SGD	0.867	0.912	0.980
SGD w/ momentum	0.843	0.938	0.961
RMSProp	0.566	0.636	0.897
Adam	0.434	0	0.614

Clasificación multiclase (2)

Arquitectura	Exactitud	Sensibilidad	Especificidad
Resnet18	0.867	0.912	0.980
VGG16	0.759	0.857	0.958
CNN	0.518	0.645	0.769

Conclusiones

- Utilizamos un red neuronal Resnet18 para realizar una clasificación multiclase de imágenes de fondo de ojo.
- Los resultados obtenidos satisfacen los criterios de sensibilidad y especificidad de UK para tests de retinopatía diabética.
- Comparamos Resnet18 con otras dos arquitecturas (CNN y VGG16) y pudimos confirmar que obtiene mejores resultados.

- Generamos y disponibilizamos públicamente los datos y el código fuente utilizado.
- Generamos una herramienta web open source disponible para el asistir a los oftalmólogos en el diagnóstico.

Muchas gracias