

# 運用CNN進行 胸腔X光辨識



110034566 黃采琳



# Outline



研究背景



模型建立與  
參數優化



資料前處理



結論

1


# 研究背景



# 背景描述



疫情初期  
民眾恐慌



一有相關呼吸道症狀  
就前往醫院進行篩檢



對醫院造成  
極大的負擔



放射科醫師一天約需看  
數百張至數千張的X光片

# 5W1H



<b>What</b>	醫師判讀的胸腔X光片過多，可能會有判讀錯誤的情形
<b>Who</b>	臨床醫師、放射科醫師
<b>When</b>	欲檢測是否罹患COVID19
<b>Where</b>	各大醫院
<b>Why</b>	協助降低醫院人力負擔，能將資源放在嚴重患者身上
<b>How</b>	運用深度學習方法

2

# 資料前處理




# 資料來源




- From Kaggle : Chest X-Ray (Pneumonia,Covid-19,Tuberculosis)資料集



Covid19  
共有558張



Normal  
共有1530張



Pneumonia  
共有1257張



Tuberculosis  
共有 586張

# 資料前處理(1/4)



以8:1:1切分  
訓練、驗證、測試集

```
#訓練、驗證、測試: 8:1:1
#train
def moveFile(fileDir):
    pathDir = os.listdir(fileDir)          #取圖片的原始路徑
    filenumber=len(pathDir)
    rate=0.8          #自定義抽取圖片的比例, 比方說100張抽10張, 那就是0.1
    picknumber=int(filenumber*rate) #按照rate比例從資料夾中取一定數量圖片
    sample = random.sample(pathDir, picknumber) #隨機選取picknumber數量的樣本圖片
    print (sample)
    for name in sample:
        shutil.move(fileDir+name, tarDir+name)
    return
NAME = ["COVID19", "NORMAL", "PNEUMONIA", "TURBERCULOSIS"]
name = ["covid19", "normal", "pneumonia", "turberculosis"]
if __name__ == '__main__':
    for i in range(4):
        fileDir = "/content/drive/MyDrive/chest_x_ray/{}/" . format(NAME[i])          #源圖片資料夾路徑
        tarDir = '/content/drive/MyDrive/chest_x_ray/train/{}/'.format(name[i])      #移動到新的資料夾路徑
        moveFile(fileDir)
```



# 資料前處理(2/4)



Augmentor 是一個 Python Package，  
用於幫助機器學習任務的影像增強與生成。

- 透視偏斜 ( Perspective Skewing )
- 彈性變形 ( Elastic Distortions )
- 旋轉 ( Rotating )
- 裁剪 ( Cropping )
- 鏡像 ( Mirroring )



```
p.rotate90(probability=0.5)
```

```
p.rotate(probability=0.5,max_left_rotation=25,  
max_right_rotation=10)
```

```
p.sample(938)
```

# 資料前處理(3/4)



## 新增前

```
#各類別訓練集數量
name = ["covid19", "normal", "pneumonia", "turberculosis"]
for i in range(4):
    train_path = "/content/drive/MyDrive/chest_x_ray/train/{}" .format(name[i])
    read = os.listdir(train_path)
    num = len(read)
    print(num)
```

```
552
1512
1200
560
```

## 新增後

```
#新增後 #各類別訓練集數量
name = ["covid19", "normal", "pneumonia", "turberculosis"]
for i in range(4):
    train_path = "/content/drive/MyDrive/chest_x_ray/train/{}" .format(name[i])
    read = os.listdir(train_path)
    num = len(read)
    print(num)
```

```
1500
1514
1500
1500
```

# 資料前處理(4/4)



```
data_gen = ImageDataGenerator(rescale=1./255)
training_set = data_gen.flow_from_directory(path_train,
                                           class_mode='categorical',
                                           shuffle=True,
                                           target_size=(224, 224),
                                           batch_size=64,
                                           )
val_set = data_gen.flow_from_directory(path_val,
                                       class_mode='categorical',
                                       shuffle=True,
                                       target_size=(224, 224),
                                       batch_size=64,
                                       )
testing_set = data_gen.flow_from_directory(path_test,
                                           class_mode='categorical',
                                           shuffle=True,
                                           target_size=(224, 224),
                                           batch_size=64,
                                           )

training_set.class_indices
```

```
Found 6014 images belonging to 4 classes.
Found 752 images belonging to 4 classes.
Found 752 images belonging to 4 classes.
{'covid19': 0, 'normal': 1, 'pneumonia': 2, 'tuberculosis': 3}
```

- 進行圖像歸一化
- 調整圖片大小

3


# 模型建立與 參數優化



# Densenet(1/3)



- DenseNet 全名為  
Densely Connected Convolutional Network
- 許多「層與層的連結」來達到特徵重用性。
- 比如我們有L層卷積神經網路，  
那就有L個(層與層之間的)連結，  
但DenseNet設計成有 $L(L+1)/2$ 個連結



# Densenet(2/3)



Layers	Output Size	DenseNet-121	DenseNet-169	DenseNet-201	DenseNet-264
Convolution	$112 \times 112$		$7 \times 7$ conv, stride 2		
Pooling	$56 \times 56$		$3 \times 3$ max pool, stride 2		
Dense Block (1)	$56 \times 56$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$
Transition Layer (1)	$56 \times 56$		$1 \times 1$ conv		
	$28 \times 28$		$2 \times 2$ average pool, stride 2		
Dense Block (2)	$28 \times 28$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$
Transition Layer (2)	$28 \times 28$		$1 \times 1$ conv		
	$14 \times 14$		$2 \times 2$ average pool, stride 2		
Dense Block (3)	$14 \times 14$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 24$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 48$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 64$
Transition Layer (3)	$14 \times 14$		$1 \times 1$ conv		
	$7 \times 7$		$2 \times 2$ average pool, stride 2		
Dense Block (4)	$7 \times 7$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 16$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 48$
Classification Layer	$1 \times 1$		$7 \times 7$ global average pool		
			1000D fully-connected, softmax		

# Densenet(3/3)



## (1) 減緩梯度消失的問題

由於Densely connected，反向梯度傳播十分容易，模型收斂效果佳。

## (2) 特徵重用性

從低階特徵到高階特徵都會被直連到最後一層卷積層，  
這讓下一層接受到更全面的圖像資訊。

## (3) 減少參數量

對於舊的特徵圖(feature-map)是不需要再去重新學習，能減少許多參數。

# 模型建立



```
#Densenet121
from tensorflow.keras.applications import DenseNet121
def get_model():
    densenet = DenseNet121(weights='imagenet',
                           include_top=False,
                           input_shape=(224, 224, 3)
                           )
    model = tf.keras.models.Sequential([densenet,
                                        GlobalAveragePooling2D(),
                                        Dense(512, activation='relu'),
                                        BatchNormalization(),
                                        Dropout(0.3),
                                        Dense(4, activation='sigmoid')
                                        ])

    model.compile(optimizer=Adam(lr=0.001),
                 loss='binary_crossentropy',
                 metrics=['accuracy']
                 )

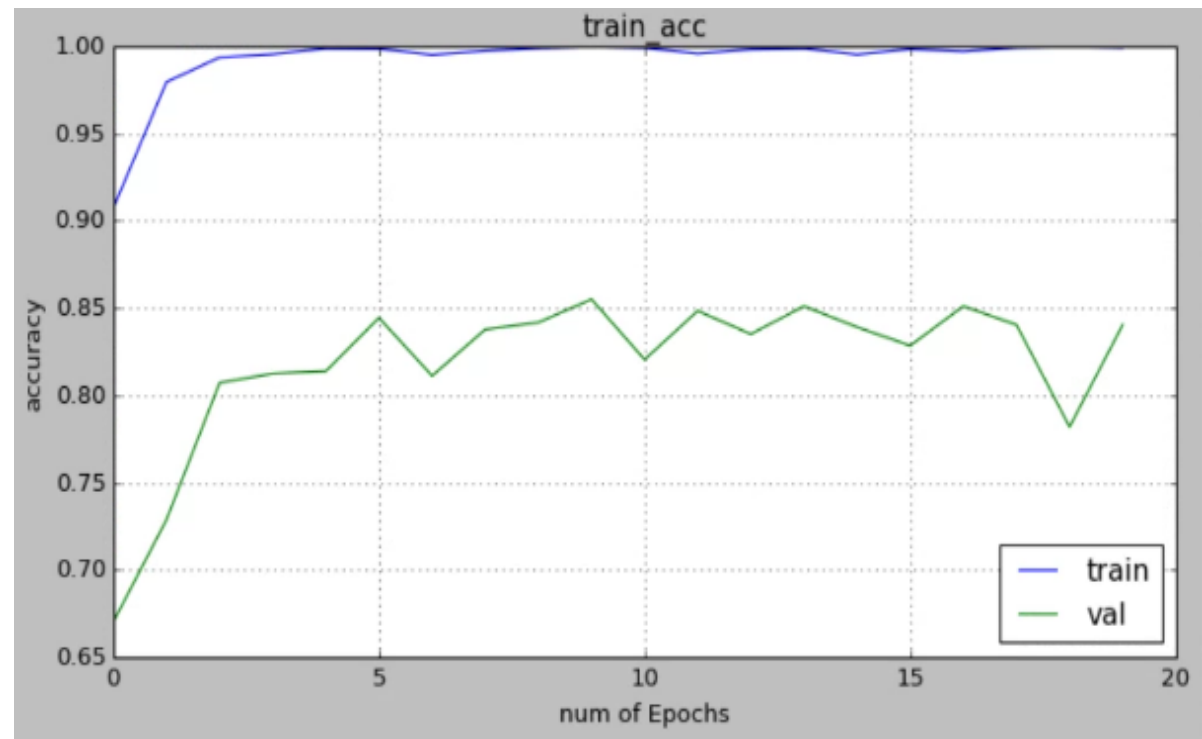
    return model

model = get_model()
model.summary()
```

- Optimizer: Adam
- Loss : binary\_crossentropy
- Dropout : 0.3
- Learning rate : 0.001



# 初始實驗結果



# 參數優化(1/3)



	optimizer	Learning rate	dropout	Activation function
水準一	Adam	0.001	0.3	relu
水準二	SGD	0.0001	0.4	tanh
水準三	Adagrad	0.005	0.5	sigmoid

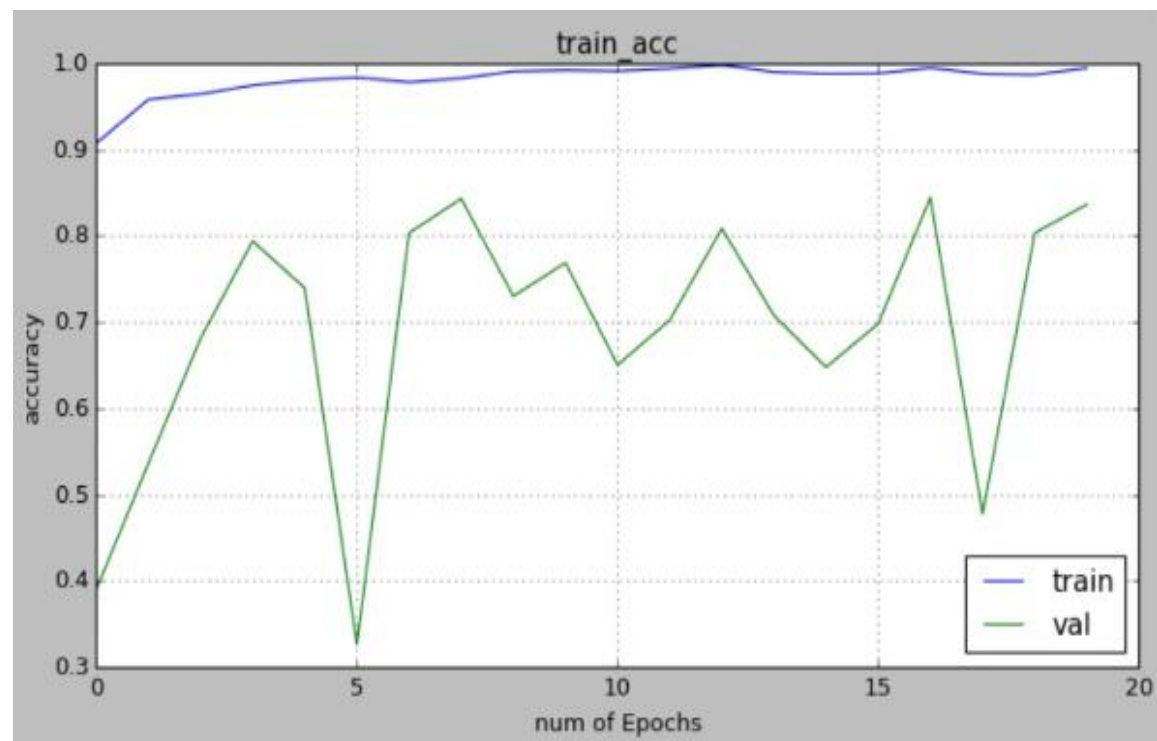
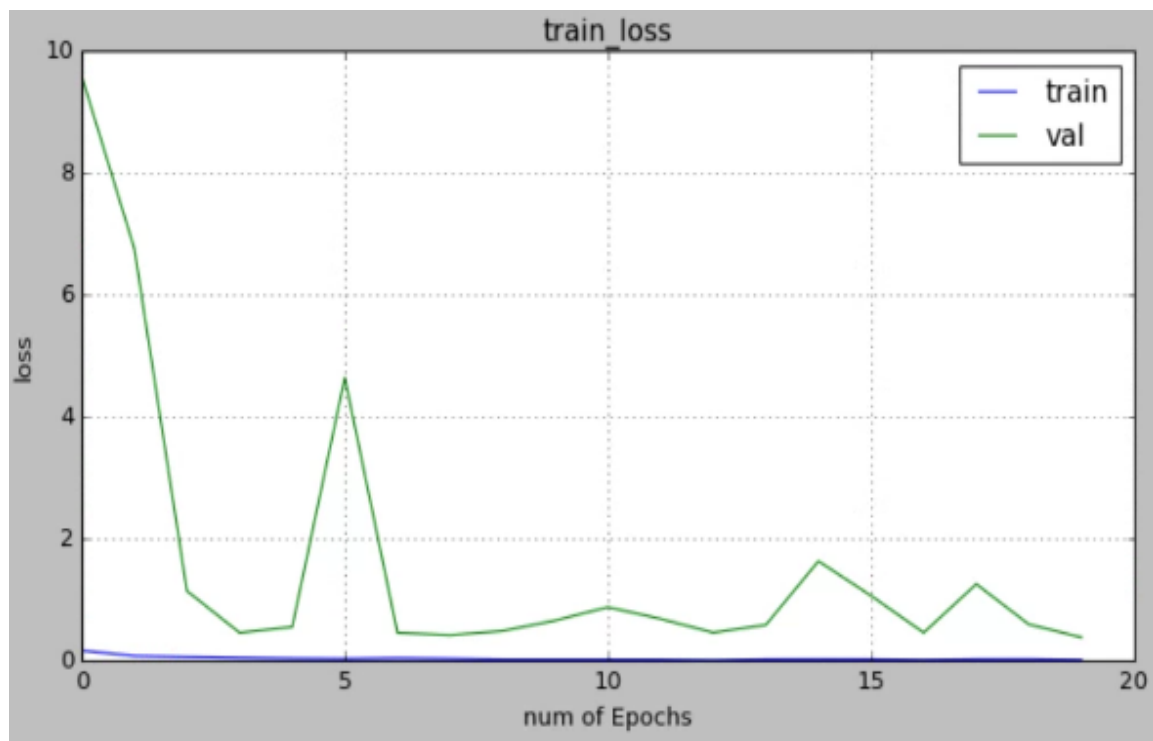
# 參數優化(2/3)



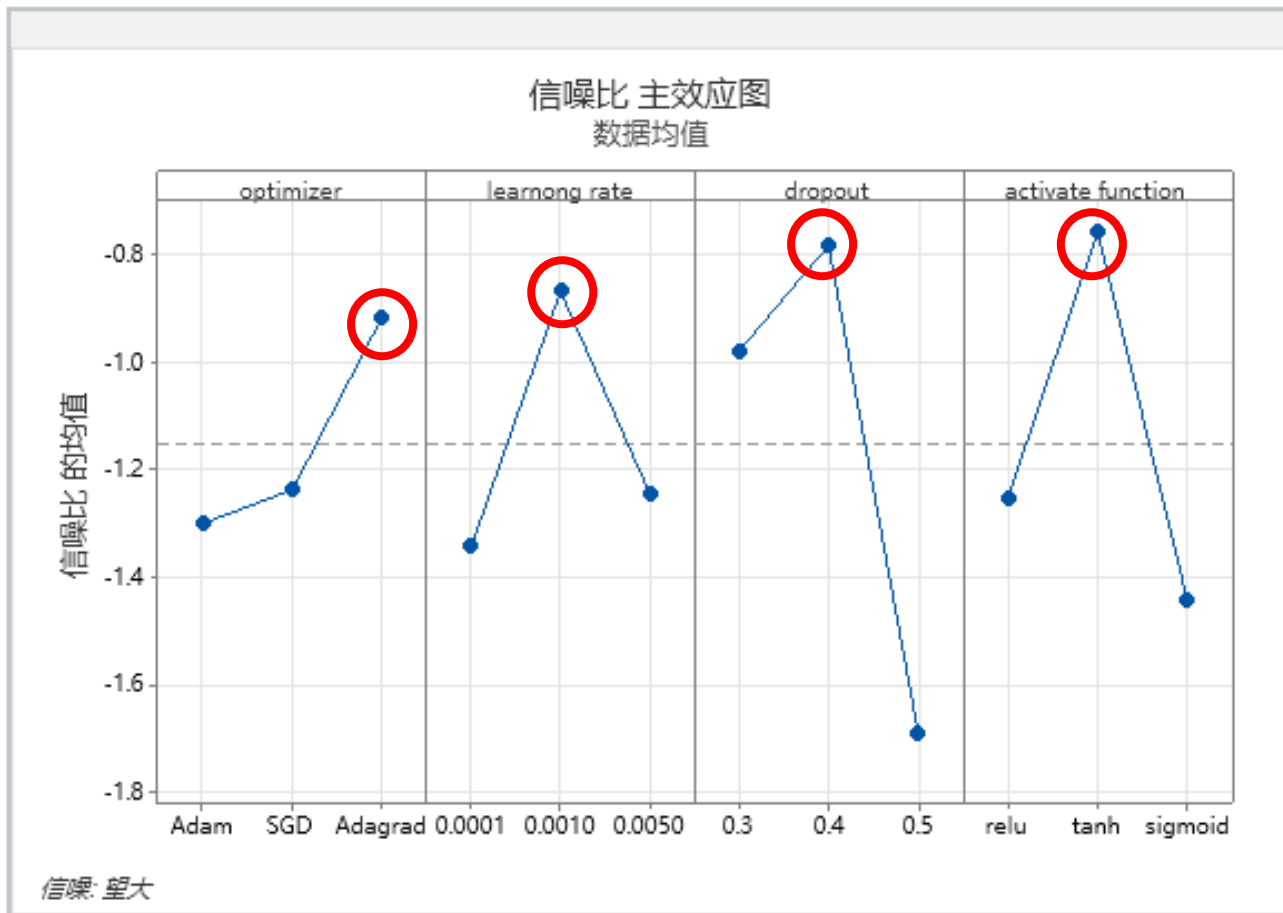
L9直交表

	optimizer	Learning rate	dropout	Activate function	Train acc	Test acc
1	Adam	0.001	0.3	relu	0.9943	0.8231
2	Adam	0.0001	0.4	tanh	0.9992	0.8564
3	Adam	0.005	0.5	sigmoid	0.9764	0.6609
4	SGD	0.001	0.4	sigmoid	0.9757	0.8457
5	SGD	0.0001	0.5	relu	0.7970	0.7793
6	SGD	0.005	0.3	tanh	0.9980	0.8511
7	Adagrad	0.001	0.5	tanh	0.9940	0.8511
8	Adagrad	0.0001	0.3	sigmoid	0.9214	0.8231
9	Adagrad	0.005	0.4	relu	0.9995	0.8540

# 實驗2



# 參數優化(3/3)



Optimizer: Adagrad  
Learning rate: 0.001

Dropout: 0.4

Activate function: tanh

Train\_acc : 0.9940

Test\_acc : 0.8497

4

# 結論



# 研究貢獻



- 本研究透過建立CNN模型來協助醫生快速判讀患者的疾病，特別是對新手醫師來說，可能會因為經驗不足而導致對某些變化視而不見，此模型可以降低醫師的出錯率。
- 另外為了讓大型醫院能專注治療病情嚴重的個案，會將篩檢量能分配到第二、三線的醫院，透過人工智慧的方法能提供醫院具有良好效率的工具，減輕醫院的人力負擔。

# 未來展望



- 可以嘗試增加可辨識疾病的數量，或建立一系統除了辨識疾病之外，還能標記出異常位置，或是有疑點的部位，降低對個人經驗值的依賴，協助醫生進行後續相關醫療處理。





**Thanks for Listening**

