

使用DCGAN進行 Augmentation

對腦腫瘤圖像進行癌症
分類與辨識

指導教授：邱銘傳 組別：Group1

學生：白哲睿 110034532

目錄 CONTENTS



01

研究背景介紹

02

研究方法介紹

03

個案研究

04

結論與未來展望

1

PART


研究背景介紹

ONE

背景說明-腦腫瘤分類與辨識

研究背景

- ◆ 腦腫瘤生存率低：5年生存率-男性(34%)、女性(36%)
- ◆ 類型複雜難以辨識：腦腫瘤的大小與位置差異很大
- ◆ 從MRI生成報告具有挑戰性和耗時：MRI分析需要專業神經外科醫生，否則可能因經驗不足而導致錯誤的診斷



研究目的

由於本研究使用的腦腫瘤MRI資料集數據並不平衡，故我們會在資料預處理的階段使用DCGAN來擴增相對較少的數據類別，最後使用卷積神經網絡(CNN)，建立一個專門對腦部腫瘤 MRI 影像進行檢測的自動化分類器，減輕醫師的診斷負擔，並期望能提升診斷的效率。

問題描述(5W1H)

What


透過分析MRI影像對腦腫瘤進行檢測與分類

Where

醫院、放射科、或是其他任何需要進行診斷的區域

When

進行腦腫瘤的檢測與分類時



Who

病患、病患家屬、放射科醫生、腦腫瘤研究人員

Why

腦腫瘤MRI資料量不平衡且腦腫瘤的檢測耗時費力、需依賴醫生經驗

How

透過DCGAN進行數據增強、使用卷積神經網絡(CNN)進行分類

2

PART

研究方法介紹

TWO

DenseNet

特色

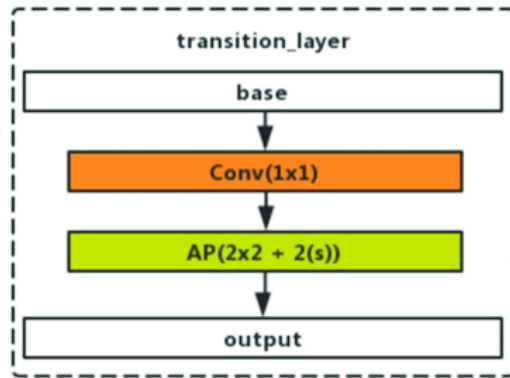
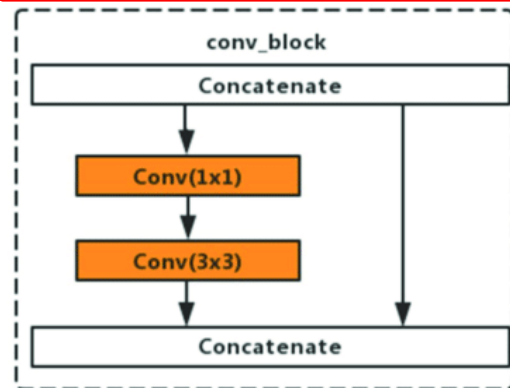


- 建立前面層與後面層的**密集連接**
- 通過特徵在 channel 上的連接來實現

特徵重複使用

優勢：參數量需求更低，計算效率提升

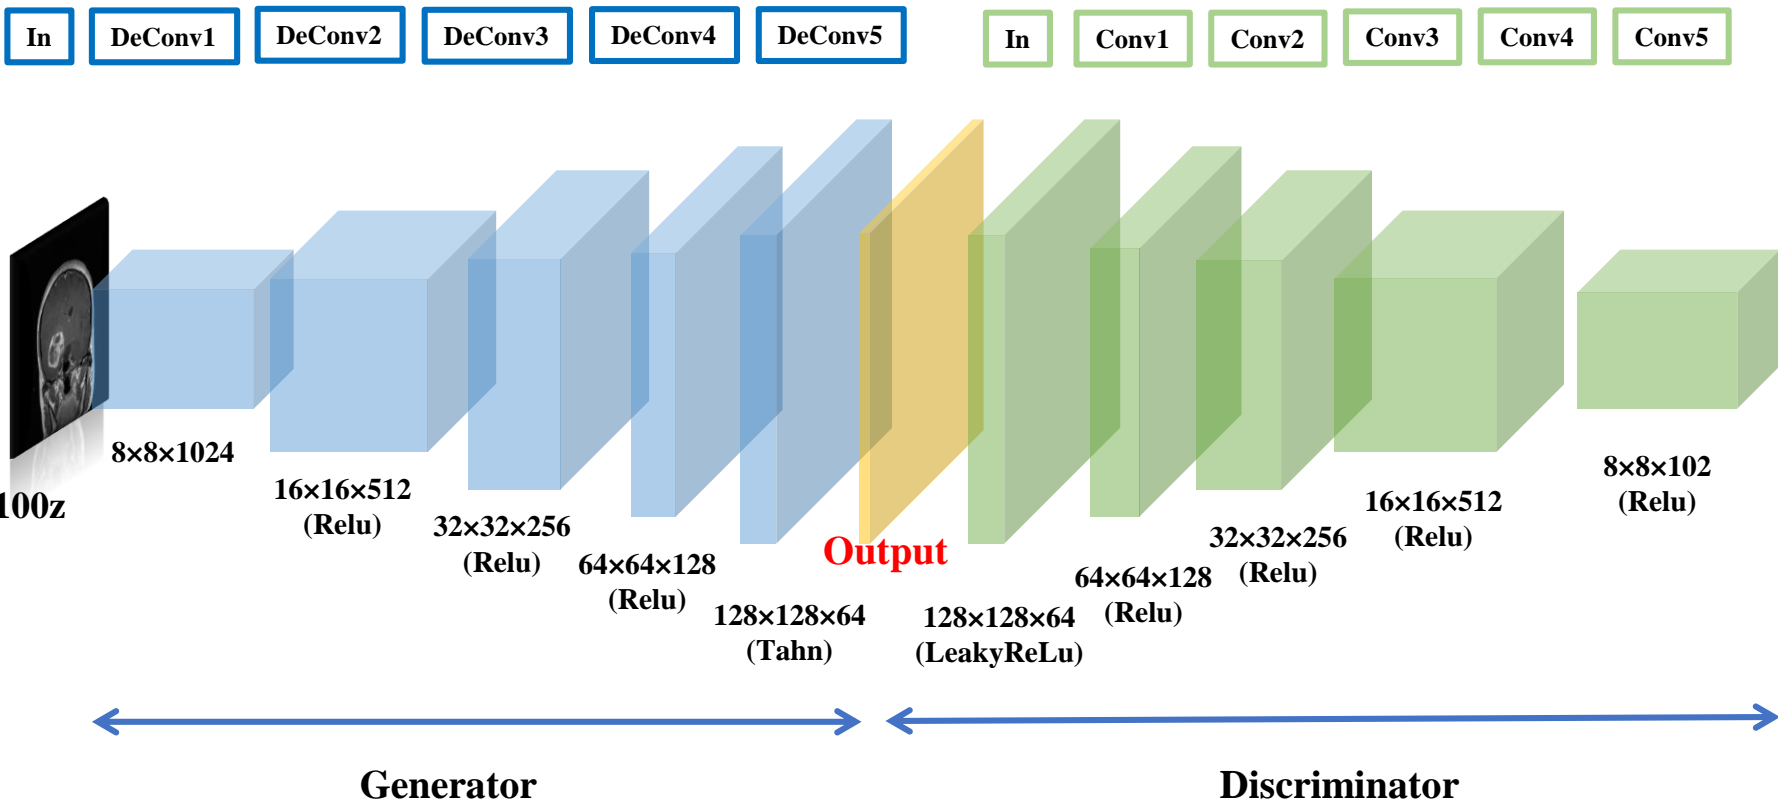
減輕梯度彌散，使模型不易過擬合

增強特徵在各層之間流動

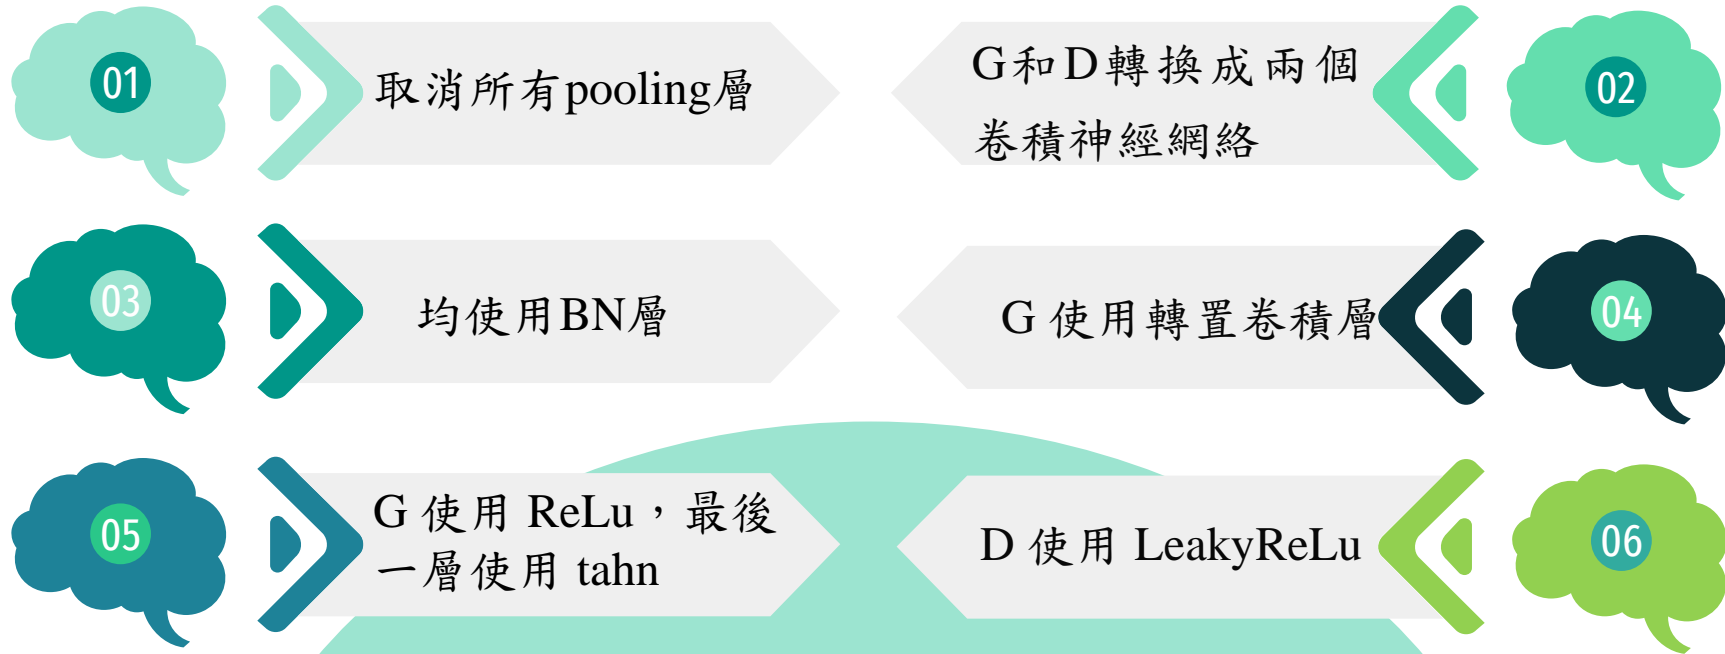


DCGAN(1/2)


DCGAN Model




DCGAN(2/2)



Original



DCGAN



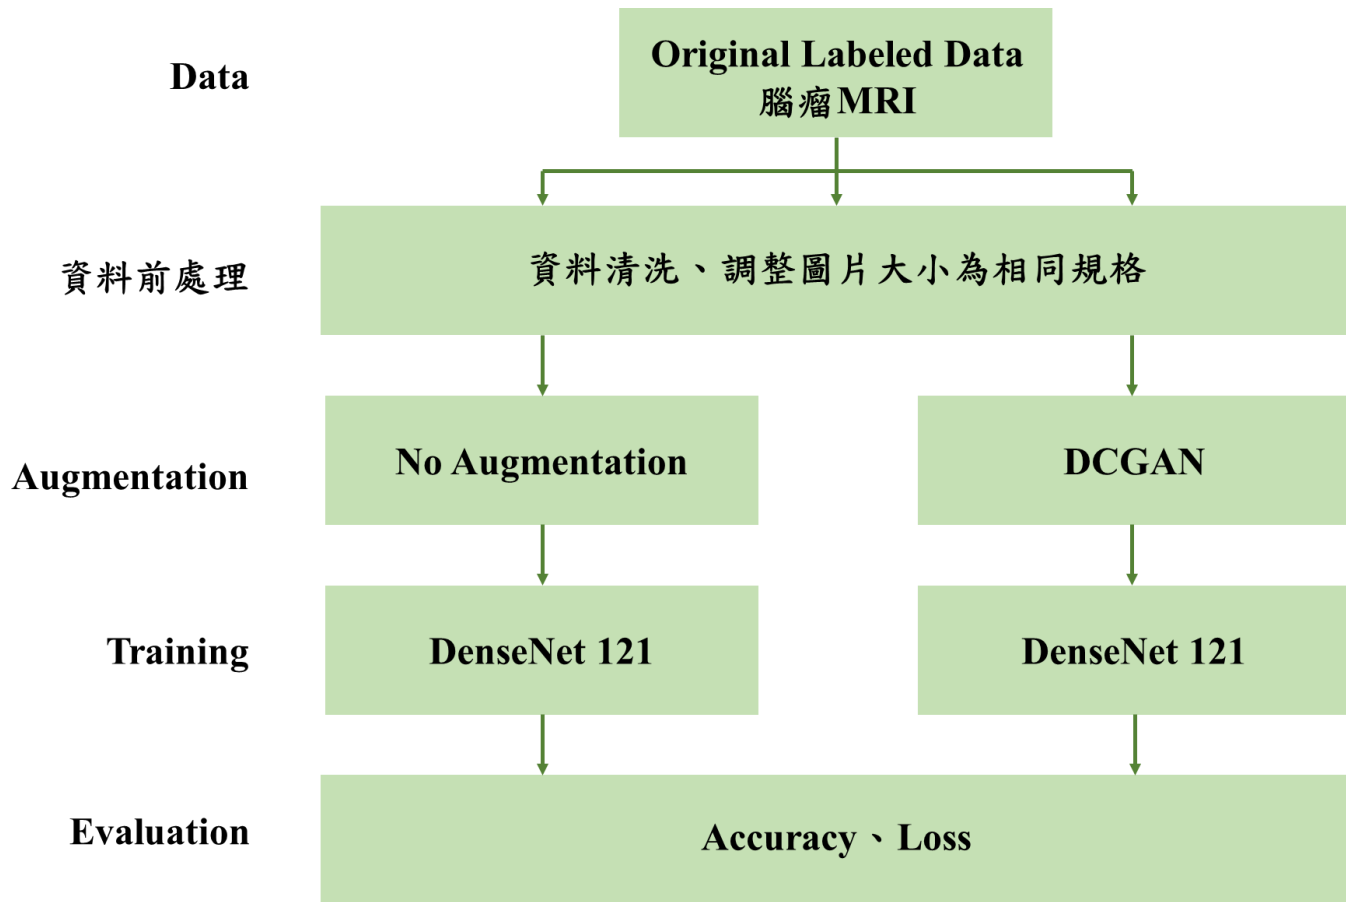
3

PART

個案研究

TRREE

研究流程



資料集介紹


資料來源

- Kaggle
- 腦腫瘤(MRI)類別資料集
- 共有四種類別

資料集


- 2870 張訓練集圖片
- 394 張測試集圖片
- 共有3264筆 MRI 圖像

pituitary tumor




垂體瘤

no tumor




沒有腫瘤

meningioma tumor



腦膜瘤

glioma tumor



膠質瘤

腦腫瘤類別	訓練集圖片數量	測試集圖片數量
glioma tumor(膠質瘤)	826 張	100 張
meningioma tumor(腦膜瘤)	822 張	115 張
no tumor(無腫瘤)	395 張	105 張
pituitary tumor(垂體瘤)	827 張	74 張

資料前處理(1/2)





資料清洗(Data Cleansing)

透過人工的方式將空白或模糊的腦腫瘤圖片剔除



調整圖片大小為相同規格

原本的圖片大小不一，故我們將圖片resize為 224*224



資料前處理(2/2)





Step 3

數據集平衡

避免 No tumor 資料量過少的情況，本研究透過DCGAN進行數據擴增

```
1 # Training
2 print("Start!")
3 input_images = np.asarray([np.asarray(Image.open(file).convert("RGB").resize((IMAGE_SIZE, IMAGE_SIZE))) for file in glob(INPUT_DATA_DIR + '*')])
4 print ("Input: " + str(input_images.shape))
5
6 np.random.shuffle(input_images)
7
8 sample_images = random.sample(list(input_images), SAMPLES_TO_SHOW)
9 show_samples(sample_images, OUTPUT_DIR + "inputs", 0)
10
11 with tf.Graph().as_default():
12     train(get_batches(input_images), input_images.shape)
13     #saver = tf.train.Saver()
```

腦腫瘤類別	訓練集圖片數量	測試集圖片數量
glioma tumor	826 張	100 張
meningioma tumor	822 張	115 張
no tumor	790 張	105 張
pituitary tumor	827 張	74 張



參數優化(1/2)

希望可以透過調整參數達到CNN模型效能的提升

因子	說明	Level 1	Level 2	Level 3
A	Dropout	0.4	0.5	0.6
B	Optimizer	Adam	AdaDelta	SGD
C	Activate function	Tahn	ELU	ReLu
D	Learning rate	0.01	0.005	0.001

- 依據田口方法設計一組四因子三水準的實驗，找出最佳水準組合
- 實驗中統一使用30 epochs 進行訓練
- 分別對數據增強前後的資料集進行訓練
- 為了減少實驗次數而使用L9直交表

參數優化(2/2)


- 通過田口方法設計出一組包含四個因子三水準的參數組合

實驗	Dropout	Optimizer	Activate function	Learning rate
1	0.4	Adam	Tahn	0.005
2	0.4	AdaDelta	Tahn	0.01
3	0.4	SGD	ELU	0.001
4	0.5	Adam	SGD	0.01
5	0.5	AdaDelta	SGD	0.005
6	0.5	SGD	ELU	0.01
7	0.6	Adam	ELU	0.001
8	0.6	AdaDelta	Tahn	0.005
9	0.6	SGD	SGD	0.001

L9直交表

實驗設計：DenseNet121

DenseNet121之數據增強前後的結果，分別的最佳組合為第四次實驗與第七次實驗
經過數據增強後的分類準確度明顯上升



DCGAN 數據增強前

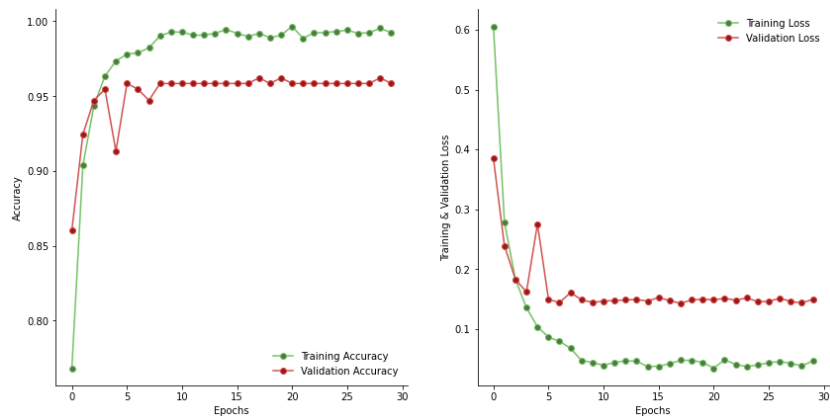
實驗	Dropout	Optimizer	Activate function	Learning rate	Accuracy
1	0.4	Adam	Tahn	0.005	0.8651
2	0.4	AdaDelta	Tahn	0.01	0.8943
3	0.4	Adagrad	ELU	0.01	0.8815
4	0.5	Adam	SGD	0.001	0.9132
5	0.5	AdaDelta	SGD	0.005	0.9013
6	0.5	Adagrad	ELU	0.01	0.912
7	0.6	Adam	ELU	0.001	0.8753
8	0.6	AdaDelta	Tahn	0.005	0.8864
9	0.6	Adagrad	SGD	0.001	0.8946

DCGAN 數據增強後


實驗	Dropout	Optimizer	Activate function	Learning rate	Accuracy
1	0.4	Adam	Tahn	0.005	0.8955
2	0.4	AdaDelta	Tahn	0.01	0.9232
3	0.4	Adagrad	ELU	0.01	0.9153
4	0.5	Adam	SGD	0.001	0.8966
5	0.5	AdaDelta	SGD	0.005	0.9472
6	0.5	Adagrad	ELU	0.01	0.9561
7	0.6	Adam	ELU	0.001	0.9864
8	0.6	AdaDelta	Tahn	0.005	0.9247
9	0.6	Adagrad	SGD	0.001	0.9311

實驗設計：結果

Epochs vs. Training and Validation Accuracy/Loss



Epochs vs. Training and Validation Accuracy/Loss



Data Augmentation	Dropout	Optimizer	Activate function	Learning rate	Accuracy
No	0.5	Adam	SGD	0.001	0.9132
Yes	0.6	Adam	ELU	0.001	0.9864



4

PART
結論與未來展望

FOUR

結論

- ◆ 利用DCGAN進行數據增強平衡資料量
- ◆ 透過實驗設計的田口方法找出最佳的參數水準組合

貢獻

- ◆ DCGAN 參數調整困難且時間不足
- ◆ 並未評估 DCGAN 生成的 MRI 圖像
- ◆ 並未應用不同的 CNN 架構

侷限性

- ◆ 實驗結果優異有機會應用在臨床試驗
- ◆ 可作為專家診斷的依據，以減少人力與時間的花費

適用性

- ◆ 對 DCGAN 進行參數優化
- ◆ 嘗試其他最新的生成圖像模型來比較此研究的生成結果

未來改善

