

中華民國第 62 屆中小學科學展覽會  
作品說明書

---

國中組 生活與應用科學(一)科

第三名

032809

以新建構之卷積神經網路對腦部核磁共振影像  
執行多發性硬化症之判讀

學校名稱：新北市立永和國民中學

作者： 國二 呂顥天	指導老師： 鍾兆晉 陳敏華
---------------	---------------------

關鍵詞：卷積神經網路、腦部核磁共振影像、多發性  
硬化症

# 摘要

現階段台灣有關多發性硬化症病灶分割相關研究付之闕如，但電腦視覺輔助醫療已日漸成熟。本研究新建構卷積神經網路，提出一套以深度學習為基礎，可自動辨識腦部核磁共振影像中，分割多發性硬化症病灶之人工智慧病灶判讀方法。本研究使用約翰霍普金斯大學影像分析與通訊技術實驗室授權提供之 Longitudinal Multiple Sclerosis Lesion Imaging Archive 資料集為訓練與測試資料，共 151 筆核磁共振臨床資料、39583744 筆像素資料，並以 IoU 與 dice 係數為評估指標。經實證發現，本研究提出的方法，具有顯著 IoU 值，達 0.8523，另 dice 係數亦較其他方法高，其值為 0.9392，且在速度方面，禎數高達 13.79。本研究成果未來可連結醫院之核磁共振影像資料庫，自動分割出核磁共振影像中多發性硬化症病灶，以利於早期診斷與治療。

## 壹、前言

### 一、研究動機

現代影像學技術需要多重輸入，而電腦視覺為最主要的資料輸入，其用途有醫學影像學、即時路況偵測、運動追蹤等。Chen et al. (2021) 表示電腦視覺在物理成像研究領域，雖然已經在各種應用情境開發無數種演算法，然而，在醫學影像學中，如腫瘤偵測與定位、病灶數量與分析等相關用途，皆透過了解位置或範圍得取相關資料，不過在準確位置分析當中，需要非常多的資源與時間處理。而在醫學影像學，有許多延伸應用，亦代表有更多需要優化或進步的技術。

Süleyman Yıldırım and Dandil (2020) 的研究指出多發性硬化症為神經細胞周圍病變導致中樞神經系統出現功能異常，每年有數萬人因此過世，其中一大部分的死亡是因為未正確診斷，故及早、正確發現多發性硬化症顯得非常重要。現階段台灣有關多發性硬化症病灶辨識，通常可透過核磁共振、誘發電位等方式診斷多發性硬化症，因此本研究嘗試透過多發性硬化症核磁共振影像之病灶深度學習訓練與分析的研究目標與對象。

本研究計畫調查並開發可用於神經影像學之神經網路，並嘗試進行了解以下兩個問題：

(一)、影像分割模型若結構簡單，是否仍能應用於醫學影像領域？

(二)、承上，是否能夠保持其辨識品質並提高速度？

## 二、研究目的

(一)、運用 PyTorch 建構符合研究問題之分割卷積神經網路。

(二)、使用圖像處理器訓練本研究開發之卷積神經網路。

(三)、透過評估指標比較本研究之模型與其他模型應用於多發性硬化症病灶判讀之性能。

## 三、文獻探討

根據研究目的與問題，本研究對於以下醫學內容、技術內容、評估指標與分析及相關研究作文獻探討。

### (一) 醫學內容

#### 1. 多發性硬化症

多發性硬化症 (Multiple Sclerosis) 是一種中樞神經系統自身免疫性和神經退化性脫髓鞘疾病，是導致許多年輕人殘疾的主要原因(Khademi et al., 2021)。多發性硬化症為神經細胞周圍病變導致中樞神經系統出現故障，且及早發現多發性硬化症非常重要。通常可透過核磁共振、誘發電位等方式診斷多發性硬化症(Süleyman Yıldırım & Dandıl, 2020)。然而，多發性硬化症相關分割模型的表現有限。基於以上原因，本研究決定以多發性硬化症作為影像分割之疾病。

#### 2. 核磁共振 (MRI)

多發性硬化症可藉由核磁共振、誘發電位診斷，而其中以核磁共振影像準確度較高，故本研究以核磁共振作為多發性硬化症病灶判讀影像類型。

Mohamed et al. (2012) 指出核磁共振 (MRI) 是一種醫學成像技術，可實現身體掃描視圖的技術。核磁共振 (MRI) 是一種有效的工具，可提供有關腫瘤結構、多發性硬化症病灶的詳細資訊，從而實現對疾病的有效診斷、治療和監測，因此本研究使用核磁共振 (MRI) 影像來判斷多發性硬化症。而核磁共振影像又分為許多種類，依其運作模

式可分為 T1、T2、FLAIR、MPRAGE 與 DSE 等。

### 3. 大腦白質病變 (white matter lesion)

大腦白質病變與中風、去髓鞘疾病及周邊神經炎的病灶，而 FLAIR MRI 可提供凸顯大腦白質病變病灶的優勢，因為其顏色如其名，為白色(Khademi et al., 2021)。FLAIR MRI 可讓大腦白質病變與正常組織之亮度呈現差異，故本研究使用 FLAIR 影像。

## (二) 技術內容

### 1. 電腦視覺

電腦視覺是一個物理成像的研究領域，並且已經為各種應用情境開發了無數種演算法(Chen et al., 2021)。相較於電腦圖學，電腦視覺較注重在讓電腦「看見」，或分析與處理。然而，電腦視覺可結合人工智慧，以得到更準確的結果。

其中，人工智慧又分為機器學習與深度學習。

### 2. 深度學習

深度學習為人工智慧目前最多篇研究數的領域，因為其非常具有發展性(Bai et al., 2021)。深度學習之處理單位為神經元，其整理後的表示法如式 1-1。

$$\hat{y} = g \left( w_0 + \sum_{i=1}^m x_i w_i \right) \quad (1-1)$$

在式 1-1 中， $\hat{y}$  為輸出， $g$  為激活函數， $w_0$  為偏誤， $x_i$  為輸入， $w_i$  則為權重。一筆資料輸入後，先透過權重定義資料重要性，加總後調整偏誤，經過激活函數後便得到輸出。此為深度學習中神經元的定義。

本研究使用之模型為深度學習模型，因此需要圖像處理器 (GPU) 以訓練。

### 3. 圖像處理器 (GPU)

原先以超級電腦為主的圖像處理器加速處理已經漸漸轉到一般電腦上，因為各顯示卡製造商的發展與使用者的需求(Zhou et al., 2021)。對於圖像處理器，對本研究具有

加速的效益，但也成為本研究的研究需求與限制。本研究使用之雲端主機，包含 Nvidia Tesla T4，其基於 Nvidia 圖靈架構，許多深度學習專案與本研究皆會使用本圖像處理器。

而圖像處理器需要驅動的相關軟體，故 CUDA 在這個時候便非常重要。

## 4. CUDA

Bozorgmehr et al. (2021) 指出 CUDA 為一平行開發模型，亦可用於深度學習與數學運算之開發，及圖像處理器驅動。本研究使用之影像映像檔已安裝 CUDA 11.1 於雲端主機，故不須再額外費時安裝。

不過，有了圖像處理器的驅動，還要有能夠開發模型結構的程式語言套件。

## 5. PyTorch

Paszke et al. (2017) 指出 PyTorch 是一個基於 C++，常用的 Python 深度學習套件，彈性大、方便操作，在建立模型結構上較 TensorFlow 方便。本研究透過 PyTorch 建構與設計卷積神經網路。

## 6. 卷積神經網路

Aslani et al. (2019) 指出卷積神經網路在過去幾年，對醫學影像學領域帶來了極大的進步。卷積的定義如式 1-2。

$$(f * g)(x) = \int f(t)g(t - x) dt \quad (1-2)$$

其中  $f$  便為輸入資料與一函數， $g$  為卷積核 (kernel，類似於輸入向量之權重)。透過將兩者進行卷積，便可得到模型輸出。

然而，在卷積神經網路中，較常使用的是離散卷積，定義如式 1-3。

$$(f * g)(x) = \sum_t f(t)g(t - x) \quad (1-3)$$

由於兩輸入進行卷積時，相當於兩離散傅立葉轉換相乘，離散卷積除利用上述定義直接計算外，亦可透過快速傅立葉轉換（FFT）或分段卷積進行計算。分段卷積將  $f$  分為數段後，分別與  $g$  進行卷積後再相加。依時空複雜度由小到大排序，分別為分段卷積、快速傅立葉轉換及直接計算。

## 7. 激活函數

Xu et al. (2015) 表示在現今深度學習模型中，其中一個非常重要的元件是激活函數，而在卷積神經網路的訓練過程中較常使用非飽和激活函數，如 ReLU、Leaky ReLU 等。

在各種非飽和激活函數中，ReLU 及 Leaky ReLU 最為常見，本研究透過這三種激活函數進行元件調整。ReLU 與 LeakyReLU 之定義如式 1-4 與 1-5。

$$y_i = \begin{cases} x_i & \text{if } x_i \geq 0 \\ 0 & \text{if } x_i < 0 \end{cases} \quad (1-4)$$

$$y_i = \begin{cases} x_i & \text{if } x_i \geq 0 \\ \frac{x_i}{a_i} & \text{if } x_i < 0 \end{cases} \quad (1-5)$$

在式 1-3 中， $a_i$  為一介於 0 與  $+\infty$  之變數，設定為 100 以上會有較好的結果 (Maas, 2013)。

## （三）評估指標與分析

### 1. Intersect over Union (IoU)

Wang (2019) Intersect over Union (IoU) 為最重要的物件偵測及影像分割評估指標，其原理為計算輸出與原始資料的差異。由於評估指標為比較使用，相關研究大多不使用 IoU 作為評估指標，故本研究以 IoU 為次要評估指標。計算方式如式 1-6。

$$\text{IoU} = \frac{|A \cap B|}{|A \cup B|} \quad (1-6)$$

## 2. Sørensen-Dice coefficient (Dice Score)

Carass et al. (2020) 指出 Dice 係數為一醫學影像分割演算法常用評估指標，其提供標準化的分割準確度，並被證實具有實用性。本研究採用 Dice 係數為主要評估指標，以得到更完整的報告。計算方式如式 1-7。

$$\text{Dice Score} = \frac{2|A \cap B|}{|A| + |B|} \quad (1-7)$$

為與其他研究之方法進行比較，本研究採用 IoU 與 Dice Score 進行判斷的評估。

### (四) 相關研究

本研究蒐集多發性硬化症病灶辨識相關研究，共蒐集 6 篇與本研究較相關，如表 1-1。

表 1-1 相關研究之模型方法與訓練結果

本研究	模型方法	結果 (Dice Score)
Alshayji et al. (2018)	直方圖匹配與大津演算法	0.71 ± 0.18
Aslani et al. (2019)	多分支低取樣頻率神經網路	0.6655
Kamraoui et al. (2022)	3D UNet	0.677
Krüger et al. (2020)	全卷積 encoder-decoder 架構	0.45 ± 0.28
Schmidt et al. (2019)	析取邏輯	0.72
Süleyman Yıldırım and Dandıl (2020)	Mask R-CNN	0.8490

Alshayji et al. (2018) 提出之方法，為偏向分析與資料分布的實作方式，直方圖匹配為強調與提取特徵的方法，而大津演算法透過病灶位置分布進行判讀。此方法雖然速度較快，但準確度較機器學習與深度學習低。

Aslani et al. (2019) 亦為 encoder-decoder 之卷積神經網路，為多分支低取樣頻率神經網路。此方法先將資料分為高解析度與低解析度，使低解析度之資料經過卷積層後，將兩者合併，再經過數個卷積層進行訓練。此方法雖然已使用卷積神經網路，但因為程序複雜，所需執行時間較久，且準確度較純統計方法低。

Kamraoui et al. (2022) 之方法，為基於 UNet 的改良，使其能夠透過 3D 影像進行訓練，其保有 UNet 原先已具有速度之優勢。Krüger et al. (2020) 亦為基於相同方法。

Schmidt et al. (2019) 則使用比較方法，判斷兩影像間之差異，較接近於機器學習之方法。而 Süleyman Yıldırım and Dandil (2020) 則將 Mask R-CNN 應用於多發性硬化症之判讀。

本研究之所以使用影像分割技術，為多發性硬化症通常會有病灶擴大的情形，而病灶擴大則需進行病灶準確範圍的分離，方可準確比較前後差異。而影像分割之輸出為不規則形狀，貼合於病灶位置，故本研究採用影像分割技術。

## 貳、研究設備與器材

基於以上研究目的，本研究需圖像處理器訓練本研究開發之模型，故僅需雲端主機作為運算資源。本研究原先使用 Google Colab，其環境具有 CPU、GPU 與 TPU 三種選擇。然而，其具有防止使用者長時間使用服務，暫停其訓練的機制。因此本研究時常需要重新訓練。Kaggle 具有特殊資料結構，使用者必須使用其結構，才能使用其訓練服務。另外，仍有許多訓練服務，但較不穩定，因此本研究決定使用雲端服務，透過已安裝好相關套件及佈署好的映像檔，準備訓練環境。本研究經過比較與分析，選擇使用 AWS 的 EC2，為一虛擬主機，並使用 Nvidia 深度學習映像檔。詳細環境設置如下表。

表 2-1 本研究使用 AWS EC2 之 Nvidia 映像檔環境設置

主機類型	g4dn.xlarge
核心	4 vCPU
記憶體	16 GiB
儲存空間	125 GiB
顯示卡	Nvidia Tesla T4
CUDA 版本	11.2
PyTorch 版本	1.10.0



## 參、研究過程與方法

對於多發性硬化症病灶之核磁共振影像辨識研究，研究者已試提出三方法，第一方法為改良 Haar Cascade，其為 OpenCV 之常見物件辨識機器學習模型。研究者試修改其結構與學習方式，使其做到不規則影像分析的作用，曾多次修改 OpenCV 函式庫原始碼並重新編譯，但最終仍失敗。

第二方法為結合物件辨識模型 YOLOv5 與影像分割模型 Nested UNet，研究者使用本方法參與台灣國際科展。而第三方法即為本研究提出之新建構影像分割卷積神經網路，如圖 3-1。

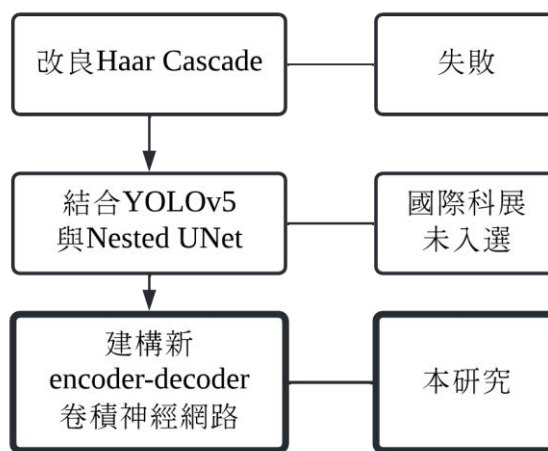


圖 3-1 研究者試提出之三方法。

### 一、資料收集

首先，需取得多發性硬化症之 FLAIR MRI 影像。FLAIR MRI 影像可凸顯白質病變之顏色差異，利於後續訓練。本研究聯繫約翰·霍普金斯大學影像分析與通訊實驗室，經同意授權取得 Longitudinal Multiple Sclerosis Lesion Imaging Archive 資料集，共 151 筆臨床 MRI NII 3D 影像檔案，包含 T1、T2、FLAIR、MPRAGE 與 DSE 種類影像。Carass et al. (2017) 表示本資料集有兩位醫學病灶標註者，標記資料集所有病灶，故病灶之標記已具備專家效力。

### 二、資料處理

由於約翰·霍普金斯大學提供本研究使用之資料集已有經過遮罩處理，不須再次手動製作遮罩，僅需將核磁共振立體影像轉換為平面影像。研究者透過 med2image 套件開發影像轉換之程式，再利用 torch.utils.data.Dataset 將資料以張量的形式輸入。由於影像分割是以像素為

資料與判斷單位，故本研究共有 77312 影像檔案，39583744 筆數據。

### 三、模型建構與設計

本研究之模型建構與設計，先透過參考 UNet 架構，將其調整為全卷積神經網路，完成一架構設計，後續再進行元件順序調製與卷積層數量調整、channel 數之調整等。

首先，本研究從一卷積層開始，並加入激活函數與批次標準化。之後再進行池化處理與 Softmax 函數，如圖 3-2。

以上所提到的激活函數、批次標準化、池化處理與 Softmax 函數皆為深度學習之元件，而以上元件皆為影像分割之常見元件。

在相關元件與卷積層調整方面，本研究分為五部分：激活函數的使用、批次標準化與激活函數的順序調整、Softmax 函數的加入與否、卷積層數量以及 channel 數的調整。

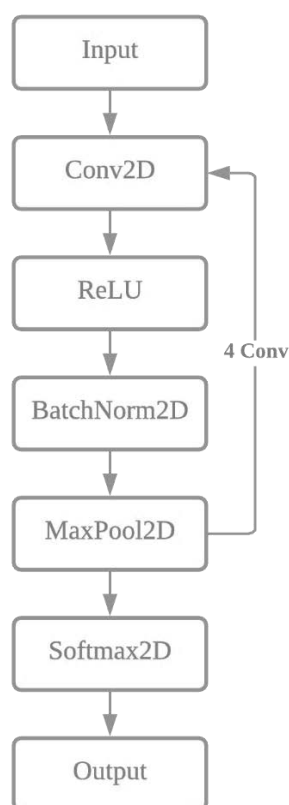


圖 3-2 本研究建構卷積神經網路初版架構。

## 四、模型訓練

本研究樣本資料須先轉換成平面影像。先將樣本資料分成兩類，分別為 train data 以及 validating data，筆數分配各為 80%及 20%。先以 train data 進行訓練，再以 validating data 測試，持續比較 train 與 validation 之 IoU、Dice score 及 loss，儲存最優化模型。本模型使用 SGD 作為優化器，並使用 BCEDiceLoss 作為損失函數，而動量為 0.9。經多輪測試後，將 validating data 送入最優化模型，測試其 IoU 及 Dice score，並評估模型之實際應用可行性。訓練流程如圖 3-3。

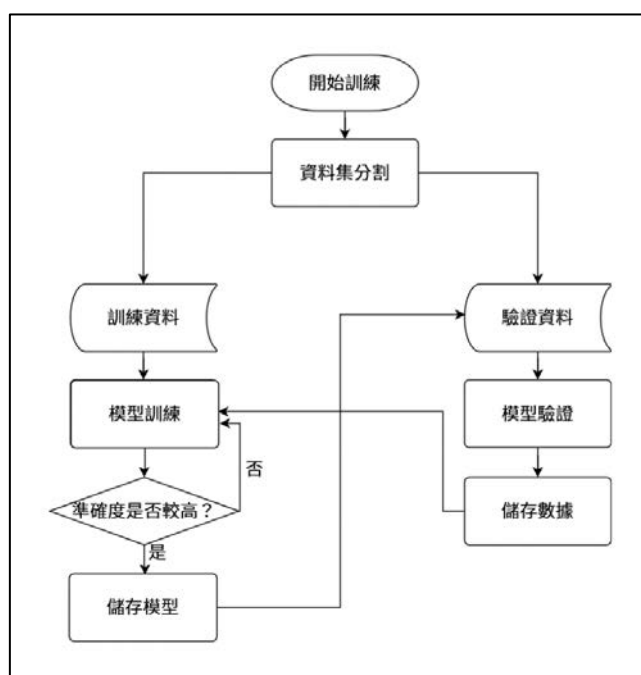


圖 3-3 本研究建構卷積神經網路訓練流程圖。

此外，Srikanth and Koley (2021) 指出訓練時的 epoch 數（epoch 為深度學習訓練單位，類似訓練週期），可在一個最優化的範圍內，也可以直接固定，而即使是測試，也至少需要 3 epoch。

## 五、評估與分析

由於本研究使用技術包含影像分割，將使用影像分割較常見之評估指標 IoU 與 Dice Score。此外，也將透過本模型與其他模型做比較，以利評估本模型之可行性。

Gurkan et al. (2019) 與 Xu et al. (2021) 之研究定義 IoU 值之門檻為 0.5。可得知 IoU 高於 0.5 皆為 True Positive。

## 肆、研究結果

### 一、建構影像分割卷積神經網路

#### (一) 激活函數

本神經網路之激活函數，共測試使用 ReLU、LeakyReLU、Sigmoid 與 TanH 四種，實驗數據如表 4-1，視覺化結果如表 4-2 至 4-5，訓練 3 epoch、每批輸入 16 張影像，學習率固定  $1e-4$ 。

表 4-1 激活函數調整數據

激活函數	ReLU	LeakyReLU	Sigmoid	TanH
最終 Dice Score	0.3858	0.4404	0.0000	0.0000
最終損失值	0.0059	0.0498	0.0116	0.0266
視覺化結果	遮罩面積偏少	遮罩面積正常	無遮罩	無遮罩

表 4-2 ReLU 激活函數遮罩視覺化結果

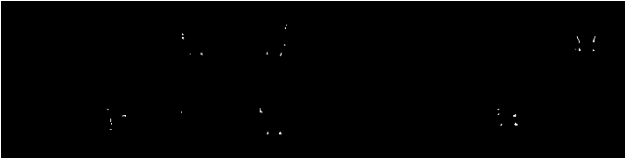


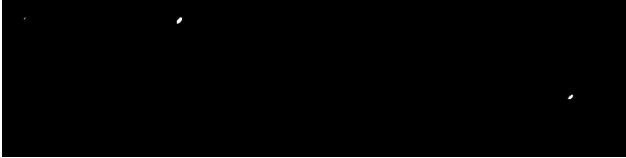
病灶位置	測試結果
	
	

表 4-3 LeakyReLU 激活函數遮罩視覺化結果

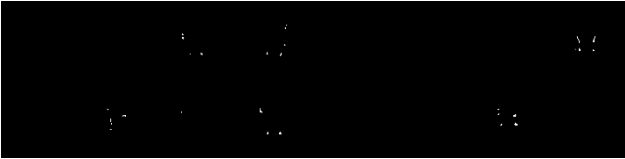



病灶位置	測試結果
	
	

表 4-4 Sigmoid 激活函數遮罩視覺化結果


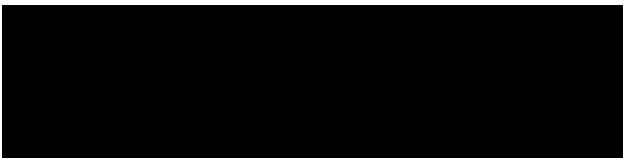
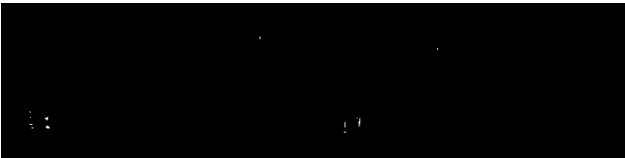
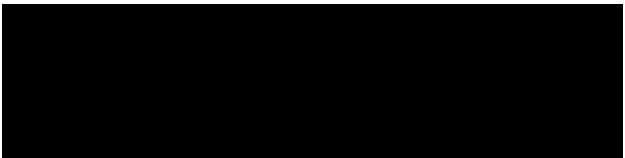
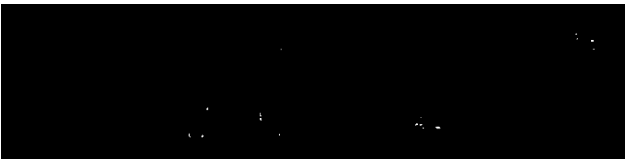
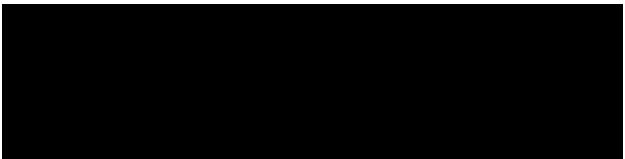
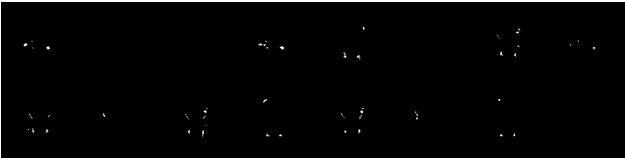
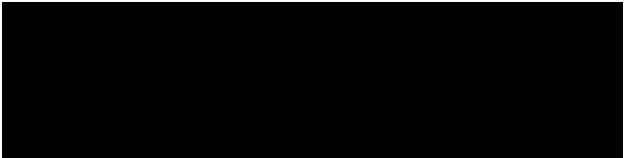
病灶位置	測試結果
	
	

表 4-5 TanH 激活函數遮罩視覺化結果

病灶位置	測試結果
	
	

由此可得知 LeakyReLU 之 Dice Score 較 ReLU 好，而 Sigmoid 與 TanH 幾乎無法使用，因此本研究使用 LeakyReLU 作為激活函數。

## (二) 批次標準化與激活函數的順序調整

本神經網路之兩元件：批次標準化與激活函數之順序前後調整，如表 4-6，訓練 3 epoch，每批輸入 16 張影像，學習率固定 1e-4，同激活函數訓練時之參數。

表 4-6 批次標準化與激活函數順序調整數據

順序	激活函數 → 批次標準化	批次標準化 → 激活函數
最終 Dice Score	0.5380	0.0344
最終損失值	0.4540	0.4420
視覺化結果	遮罩面積過大	遮罩面積正常

由於將激活函數放在批次標準化前，會使遮罩面積過大，故本神經網路將激活函數放置於批次標準化後。

## (三) Softmax 函數的加入與否

本神經網路之其中一元件：Softmax 函數能將輸入資料調整介於 0 與 1 之間，與 Sigmoid 函數極度相似。計算方式定義如式 4-1。

$$\sigma(\mathbf{z})_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (4-1)$$

其中  $\vec{z}$  為輸入值，因通常輸入資料為向量，以向量定義。 $e^{z_i}$  透過指數函數將其轉換為自然數，但仍無法限制於 1 之內，因此利用機率方法。式 4-1 中，分母將所有輸出值之總和定為 1，故 Softmax 函數之輸出值可介於 0 與 1 之間。

加入與否之訓練結果如表 4-7，相關訓練參數皆相同。

表 4-7 Softmax 函數加入與否之數據

是否加入 Softmax 函數	加入	不加入
最終 Dice Score	0.0000	0.4420
最終損失值	0.5190	0.0344
視覺化結果	無遮罩	遮罩面積正常

由於 Softmax 函數會使數據產生偏差，故本神經網路不加入 Softmax 函數。

## (四) 卷積層數量

本神經網路之原始碼結構為透過 torch.nn.Sequential 將重複出現的過程包裝，即可直接呼叫。至於在 torch.nn.Sequential 內的過程，即為卷積層、批次標準化與激活函數。而本神經網路探討 2 卷積層與 3 卷積層之訓練結果，如表 4-8。

表 4-8 卷積層數量之探討數據

卷積層數量	2 卷積層	3 卷積層	4 卷積層
最終 Dice Score	0.4420	0.0020	0.0053
最終損失值	0.0344	0.1610	1.1900
視覺化結果	遮罩面積正常	遮罩面積幾乎無重疊	遮罩面積幾乎無重疊

故本神經網路在 torch.nn.Sequential 中放置兩卷積層。

## (五) Channel 數調整

本神經網路執行方式為呼叫 torch.nn.Sequential 定義之函式 doubleConv，將 doubleConv 輸入 3 channel 之數據，再提高到 64，之後則持續將其 channel 提高至兩倍直到 512，再以  $512 + 256$ 、 $256 + 128$ 、 $128 + 64$  至輸出 1 channel。因此本實驗探討提高至 512 與提高至 1024，如表 4-9。

表 4-9 最高 channel 數調整數據

最高 channel 數	512	1024
最終 Dice Score	0.4420	0.6020
最終損失值	0.0344	0.0258
視覺化結果	遮罩面積正常	遮罩位置較 512 channels 準確

因此本神經網路將最高 channel 數提高至 1024。

基於以上 5 分段比較，建構出之神經網路結構如圖 4-1。其中 channel 數由於影像本身已為 3，故起始值為 3，而根據大多模型，提升至 64 為常見作法。

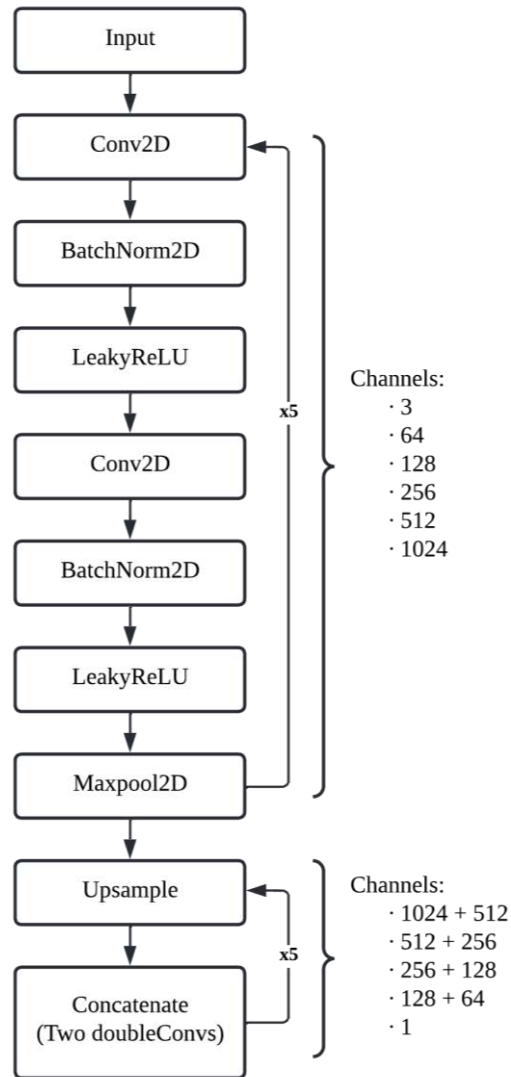


圖 4-1 完整建構與比較後卷積神經網路架構。

## 二、訓練本研究建構之卷積神經網路

### (一) 學習率調整

機器學習影像處理的品質需要仰賴學習率的調整與最佳化(Li et al., 2021)。因此，本研究亦須調整學習率。由於本神經網路結構與資料集需搭配之學習率較高，發現以  $1e-1$  至  $1e-3$  之 Dice Score 最高。因此本研究另外訓練 10 epoch 之兩模型，學習率分別為  $1e-1$  至  $1e-3$ ，其結果如圖 4-2。可得知  $1e-2$  之模型，最終 Dice Score 較好，故採用  $1e-2$  作為本神經網路之學習率。



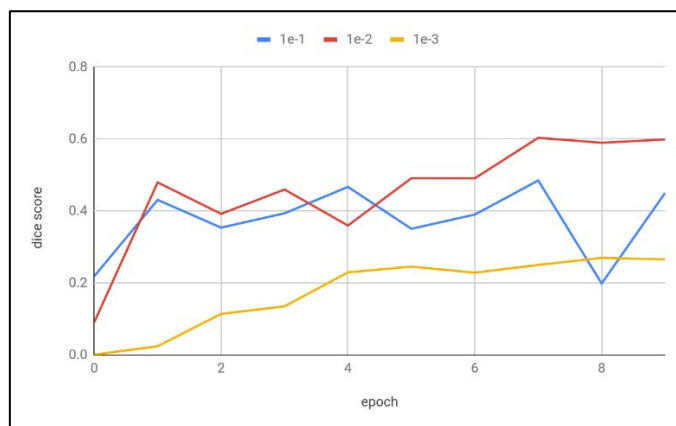


圖 4-2 學習率調整比較結果。

## (二) 訓練結果

本模型訓練時之最終訓練 IoU 為 0.6818，且訓練 IoU 較驗證 IoU 穩定，但驗證 IoU 較訓練 IoU 高，如圖 4-3。

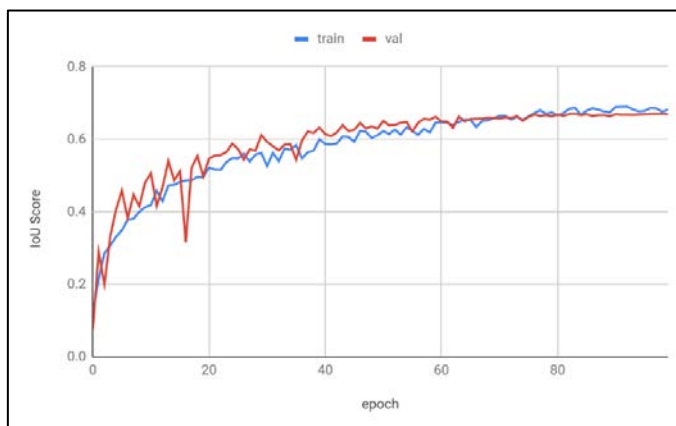


圖 4-3 模型訓練與驗證 IoU 值。

而本模型訓練時採用 BCEDiceLoss 函數作為損失函數，訓練結束時損失值約為 0.5403，如圖 6-4。

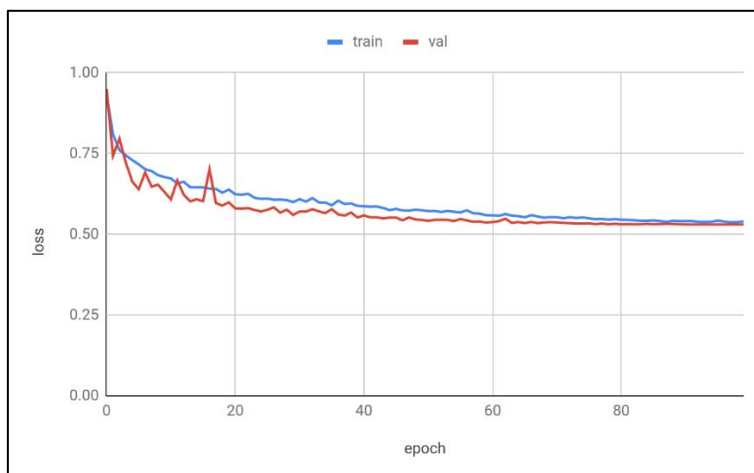


圖 4-4 模型訓練與驗證損失值。

然而，本神經網路之訓練結果仍須經過實際測試。表 4-10 為測試參數與結果。

表 4-10 測試參數與結果

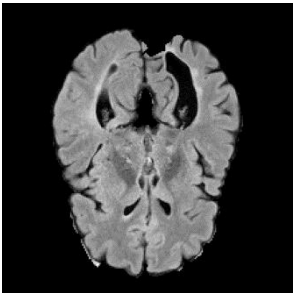


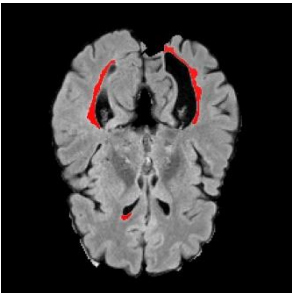
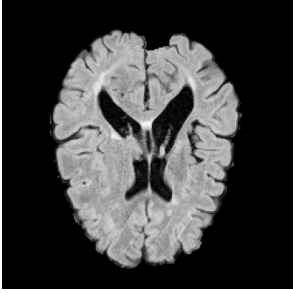
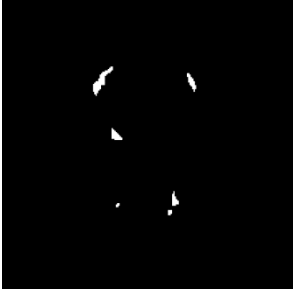
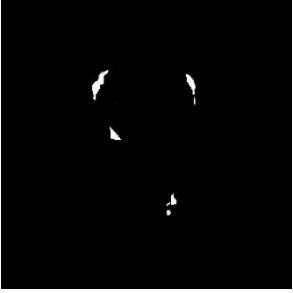
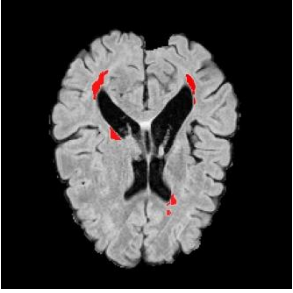
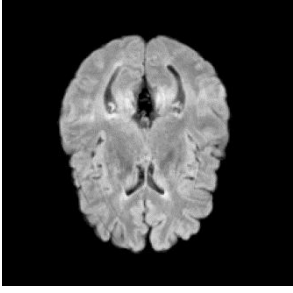


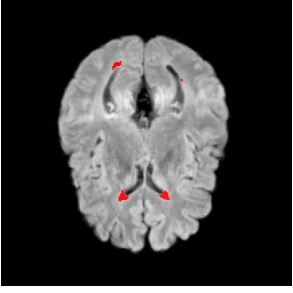
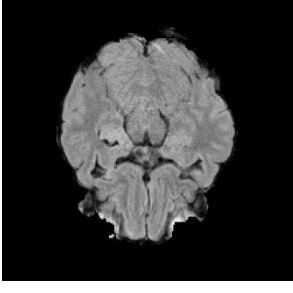

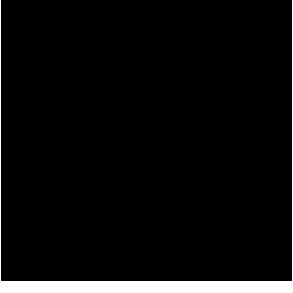
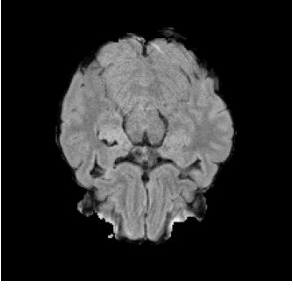
學習率	1e-2
動量	0.9
損失函數	BCEDiceLoss
<b>Dice Score</b>	<b>0.9392</b>
<b>IoU</b>	<b>0.8523</b>

表 4-10 中，動量為梯度下降法之參數，本訓練僅將其設定為 0.9，此為最優化後之結果。

雖然訓練時與驗證時 IoU 並不高，且 loss 仍約為 0.5403，但實際模型測試時可得知 IoU 約為 0.8523，且 Dice Score 約為 0.9392，故在測試資料上成效較好。

另外，本模型訓練之視覺化結果如表 4-11，可見與測試結果與原資料庫病灶位置無太大差異，且在無病灶之圖層中，測試結果病灶區域亦為空白。

表 4-11 視覺化測試結果

(a) 原 MRI 圖	(b) 病灶位置	(c) 測試結果	(a+c) 疊合結果
			
			
			
			

### 三、比較本研究之模型與其他模型

為驗證本神經網路之可行性，本研究使用 IoU 及 Dice Score 兩相似度評估指標與一般 UNet 及 Mask R-CNN 及相關研究文獻之模型做比較。UNet、Mask R-CNN 與本研究新建構之卷積神經網路為實際訓練結果，其餘為文獻中提供之數據，比較結果如表 4-12。

表 4-12 模型 dice score 比較結果

模型	Dice Score
Alshayeji et al. (2018) 提出之方法	0.71 ± 0.18
Aslani et al. (2019) 提出之方法	0.6655
Kamraoui et al. (2022) 提出之方法	0.677
Krüger et al. (2020) 提出之方法	0.45 ± 0.28
Schmidt et al. (2019) 提出之方法	0.72
Mask R-CNN	0.8490
本研究新建構之卷積神經網路	0.9392 ± 0.02

此外，於速度之比較，本研究採用禎數（Frames per second, FPS）比較，比較結果如表 4-13，可得知本研究新建構之卷積神經網路較其他模型之禎數高。

表 4-13 模型速度比較結果

模型	禎數
UNet	3.5
Mask R-CNN	5
本研究新建構之卷積神經網路	13.79

## 伍、討論

本研究為保持模型的裝置規格小型化，並未調整損失函數，因為若自行設計損失函數，將會比最基本的 BCEDiceLoss 需要更多的資源訓練與測試。

本研究開發之模型可直接結合核磁共振影像檔案伺服器使用，本研究完成串接程式，大幅縮減研究時程，並聚焦於數據分析。

若在辨識到病灶後，將其範圍放大並再訓練，將會使其品質變差，因為這會讓資料沒有腦部結構的參考依據，僅依其顏色變化，而非因放大導致解析度變差，而使模型準確度降低。故辨識出病灶後，將其範圍放大並再訓練並不可行。

有關激活函數方面，本研究測試使用 ReLU、Leaky ReLU、Sigmoid 與 TanH，其中 Sigmoid 與 TanH 在測試結果中，完全沒有遮罩。研究者推測此為不同種類激活函數所造成。ReLU 與 Leaky ReLU 等為非飽和激活函數，而 Sigmoid、TanH 等則為飽和激活函數。非飽和函數的定義如式 5-1。

$$\left( \lim_{z \rightarrow -\infty} f(z) \right) = +\infty \wedge \left( \lim_{z \rightarrow +\infty} f(z) \right) = +\infty \quad (5-1)$$

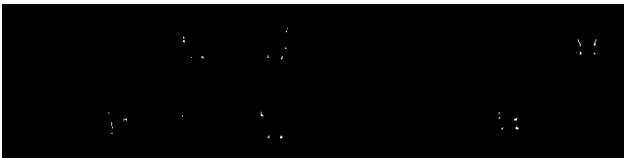

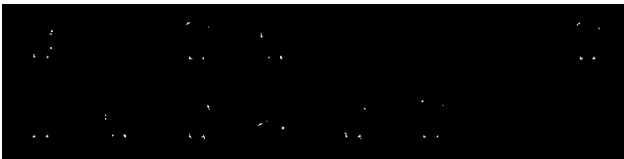

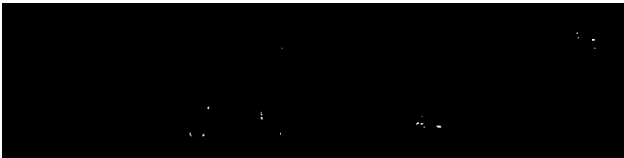

若一激活函數不符合以上條件，即為飽和激活函數。

有關學習率分析方面，學習率須依各資料集調整，因此本研究從  $1e-6$  測試到  $1e-1$ ，以多發性硬化症病灶為例， $1e-2$  之 IoU 最高，因此不論 epoch 數，學習率最優化後應為固定。

本研究提出之模型，與其他模型不同之處在於使用 Leaky ReLU 作為激活函數。些許模型使用 Leaky ReLU 能夠提高準確度，且資料最高 channel 數提高至 1024，提高模型學習速度，又不會造成如提高卷積層數量帶來的執行速度減慢。

本研究在調整學習率時，訓練 10 epoch 之原因為 10 epoch 已可觀察出學習率差異。但在正式訓練模型時，為得知本神經網路之整體表現，訓練 100 epoch。此外，研究者亦進行 2 epoch 的實驗，如表 5-1，可見 2 epoch 之訓練極度不完整，且遮罩面積過大，可視為遮罩面積過大之範例。

表 5-1 遮罩面積過大之訓練結果

病灶位置	測試結果
	
	
	

經實際訓練與測試，得知本研究新建構之卷積神經網路較其他模型之 IoU 及 Dice Score 高，故可得知本模型具有可行性。

## 陸、結論

### 一、核心成果

本研究發現確實能夠從零開發深度學習卷積神經網路，並透過核磁共振 FLAIR 影像之顏色差異，將其用於多發性硬化症病灶偵測，亦可透過完整影像是否具有病灶了解是否患有多發性硬化症，代表本研究開發與結合之模型可用於多發性硬化症的早期發現與診斷。目前已可輸入一核磁共振 nii 或 dcm 檔案後，經資料處理後直接辨識病灶。

### 二、推廣應用價值

由於本模型為影像分割卷積神經網路，亦可用於腦部腫瘤、肺炎等影像分割、辨識與分析，但須調整相關參數。

## 柒、未來展望

本研究成果未來可連結醫院之核磁共振影像資料庫，自動辨識影像是否具有多發性硬化症病灶，以利於早期診斷與治療。

除了多發性硬化症，本研究研提之卷積神經網路亦可透過調整參數與結構等，執行腦部或其他區域之病灶辨識。另外，本研究研提之卷積神經網路應亦可執行影像分割辨識，如車輛分割等，可顯現本研究之應用廣泛度。

本研究研提之卷積神經網路未來可執行於邊緣運算小型化裝置，如 Nvidia Jetson Nano，便可證明本卷積神經網路可執行於規格小型化的裝置上，不須使用高階圖像處理器便可執行，且具有一定的執行速度。

## 捌、参考文献

- Alshayegi, M. H., Al-Rousan, M. A., Ellethy, H., & Abed, S. e. (2018). An efficient multiple sclerosis segmentation and detection system using neural networks. *Computers & Electrical Engineering*, *71*, 191-205. <https://doi.org/10.1016/j.compeleceng.2018.07.020>
- Aslani, S., Dayan, M., Storelli, L., Filippi, M., Murino, V., Rocca, M. A., & Sona, D. (2019). Multi-branch convolutional neural network for multiple sclerosis lesion segmentation. *NeuroImage*, *196*, 1-15. <https://doi.org/https://doi.org/10.1016/j.neuroimage.2019.03.068>
- Bai, X., Wang, X., Liu, X., Liu, Q., Song, J., Sebe, N., & Kim, B. (2021). Explainable deep learning for efficient and robust pattern recognition: A survey of recent developments. *Pattern Recognition*, *120*, 108102. <https://doi.org/https://doi.org/10.1016/j.patcog.2021.108102>
- Bozorgmehr, B., Willemsen, P., Gibbs, J. A., Stoll, R., Kim, J.-J., & Pardyjak, E. R. (2021). Utilizing dynamic parallelism in CUDA to accelerate a 3D red-black successive over relaxation wind-field solver. *Environmental Modelling & Software*, *137*, 104958. <https://doi.org/https://doi.org/10.1016/j.envsoft.2021.104958>
- Carass, A., Roy, S., Gherman, A., Reinhold, J. C., Jesson, A., Arbel, T., Maier, O., Handels, H., Ghafoorian, M., Platel, B., Birenbaum, A., Greenspan, H., Pham, D. L., Crainiceanu, C. M., Calabresi, P. A., Prince, J. L., Roncal, W. R. G., Shinohara, R. T., & Oguz, I. (2020). Evaluating White Matter Lesion Segmentations with Refined Sørensen-Dice Analysis. *Scientific Reports*, *10*(1), 8242. <https://doi.org/10.1038/s41598-020-64803-w>
- Carass, A., Roy, S., Jog, A., Cuzzocreo, J. L., Magrath, E., Gherman, A., Button, J., Nguyen, J., Bazin, P.-L., Calabresi, P. A., Crainiceanu, C. M., Ellingsen, L. M., Reich, D. S., Prince, J. L., & Pham, D. L. (2017). Longitudinal multiple sclerosis lesion segmentation data resource. *Data in Brief*, *12*, 346-350. <https://doi.org/https://doi.org/10.1016/j.dib.2017.04.004>
- Chen, J., Balan, A., Masih Das, P., Thiruraman, J. P., & Drndić, M. (2021). Computer vision AC-STEM automated image analysis for 2D nanopore applications. *Ultramicroscopy*, 113249. <https://doi.org/https://doi.org/10.1016/j.ultramic.2021.113249>
- Gurkan, F., Gunsel, B., & Ozer, C. (2019). Robust object tracking via integration of particle filtering with deep detection. *Digital Signal Processing*, *87*, 112-124. <https://doi.org/https://doi.org/10.1016/j.dsp.2019.01.017>
- Kamraoui, R. A., Ta, V.-T., Tourdias, T., Mansencal, B., Manjon, J. V., & Coup, P. (2022). DeepLesionBrain: Towards a broader deep-learning generalization for multiple sclerosis lesion segmentation. *Medical Image Analysis*, *76*, 102312. <https://doi.org/https://doi.org/10.1016/j.media.2021.102312>
- Khademi, A., Gibicar, A., Arezza, G., DiGregorio, J., Tyrrell, P. N., & Moody, A. R. (2021). Segmentation of white matter lesions in multicentre FLAIR MRI. *Neuroimage: Reports*, *1*(4), 100044. <https://doi.org/https://doi.org/10.1016/j.vnirp.2021.100044>
- Krüger, J., Opfer, R., Gessert, N., Ostwaldt, A.-C., Manogaran, P., Kitzler, H. H., Schlaefer, A., & Schippling, S. (2020). Fully automated longitudinal segmentation of new or enlarged multiple

- sclerosis lesions using 3D convolutional neural networks. *NeuroImage: Clinical*, 28, 102445. <https://doi.org/https://doi.org/10.1016/j.nicl.2020.102445>
- Li, Y., Zhang, Q., & Yoon, S. W. (2021). Gaussian process regression-based learning rate optimization in convolutional neural networks for medical images classification. *Expert Systems with Applications*, 184, 115357. <https://doi.org/https://doi.org/10.1016/j.eswa.2021.115357>
- Maas, A. L. (2013). Rectifier Nonlinearities Improve Neural Network Acoustic Models.
- Mohamed, D., Ghoniemy, S., & Selim, G. (2012). Automated Brain Tumor Detection and Identification Using Image Processing and Probabilistic Neural Network Techniques. *International journal of image processing and visual communication*, 1, 1-8.
- Paszke, A., Gross, S., Chintala, S., Chanan, G., Yang, E., DeVito, Z., Lin, Z., Desmaison, A., Antiga, L., & Lerer, A. (2017). Automatic differentiation in PyTorch.
- Schmidt, P., Pongratz, V., Küster, P., Meier, D., Wuerfel, J., Lukas, C., Bellenberg, B., Zipp, F., Groppa, S., Sämann, P. G., Weber, F., Gaser, C., Franke, T., Bussas, M., Kirschke, J., Zimmer, C., Hemmer, B., & Mühlau, M. (2019). Automated segmentation of changes in FLAIR-hyperintense white matter lesions in multiple sclerosis on serial magnetic resonance imaging. *NeuroImage: Clinical*, 23, 101849. <https://doi.org/https://doi.org/10.1016/j.nicl.2019.101849>
- Srikanth, P., & Koley, C. (2021). A novel three-dimensional deep learning algorithm for classification of power system faults. *Computers & Electrical Engineering*, 91, 107100. <https://doi.org/https://doi.org/10.1016/j.compeleceng.2021.107100>
- Süleyman Yıldırım, M., & Dandıl, E. (2020). Automatic detection of multiple sclerosis lesions using Mask R-CNN on magnetic resonance scans. *IET Image Processing*, 14(16), 4277-4290. <https://doi.org/https://doi.org/10.1049/iet-ipr.2020.1128>
- Wang, Z. (2019). *SEG-YOLO: Real-Time Instance Segmentation Using YOLOv3 and Fully Convolutional Network* (Publication Number 2019:822) [Student thesis, DiVA. <http://urn.kb.se/resolve?urn=urn:nbn:se:kth:diva-271652>
- Xu, B., Wang, N., Chen, T., & Li, M. (2015). Empirical Evaluation of Rectified Activations in Convolutional Network. *ArXiv, abs/1505.00853*.
- Xu, R., Lin, H., Lu, K., Cao, L., & Liu, Y. (2021). A Forest Fire Detection System Based on Ensemble Learning. *Forests*, 12, 217. <https://doi.org/10.3390/f12020217>



## 【評語】 032809

1. 本作品利用 AI 影像辨識技術，判讀多發性硬化症之 MRI 影像，有效提高判讀準確率，探討最佳的模型參數，具有實用價值。
2. 報告中說“雖然訓練時與驗證時 IoU 並不高，實驗仍約為 0.5403，但實際模型測試時可得知 IoU 約為 0.8523，且 Dice Score 約為 0.9392，故在測試資料上成效較好。”這邊應該做 cross validation 來佐證及強化成果。
3. 本研究的目的清楚，使用工具教導辨識影像；許多工具使用及定義如卷積、激活、池化都需要深入學習。

## 作品簡報

# 以新建構之卷積神經網路對 腦部核磁共振影像執行多發性硬化症之判讀

Speaker: 中應 (一) 032809

## Pytorch Implementation of Nested UNet

license MIT

This repository contains

### Requirements

- PyTorch 1.x
- Albumentations 0
- Pandas 1.x.x

### Training on custom dataset

Make sure to put the files as the following structure

```
inputs
├── <dataset name>
│   ├── images
│   │   ├── 0a7e0
│   │   ├── 0aab0
│   │   ├── 0b176
│   │   └── ...
│   └── masks
│       └── 0
```

README.md

The file format doesn't

1. Train the model

```
python train.py --
```

```
usage: train.py [
```

## Pytorch Implementation of G

license MIT

```
nn.Conv2d(in_channels, out_c
nn.BatchNorm2d(out_channels)
nn.LeakyReLU(inplace=True),
nn.Conv2d(out_channels, out
nn.BatchNorm2d(out_channels)
nn.LeakyReLU(inplace=True)
```

This repository contains code for an image segmentation

### Requirements

README.md

- PyTorch 1.x
- Albumentations 0.1.12
- Pandas 1.x.x

### Installation

```
pip install -r requirements
```

### Training on custom dataset

Make sure to put the files as the following structure

```
inputs
├── <dataset name>
│   ├── images
```

# 建構多發性硬化症影像分割卷積神經網路

# Dice Score 高達 0.9392

# 速度提升到 13.79 FPS

多發性硬化症患者中有 50% 的患者持有 3 年的誤診紀錄

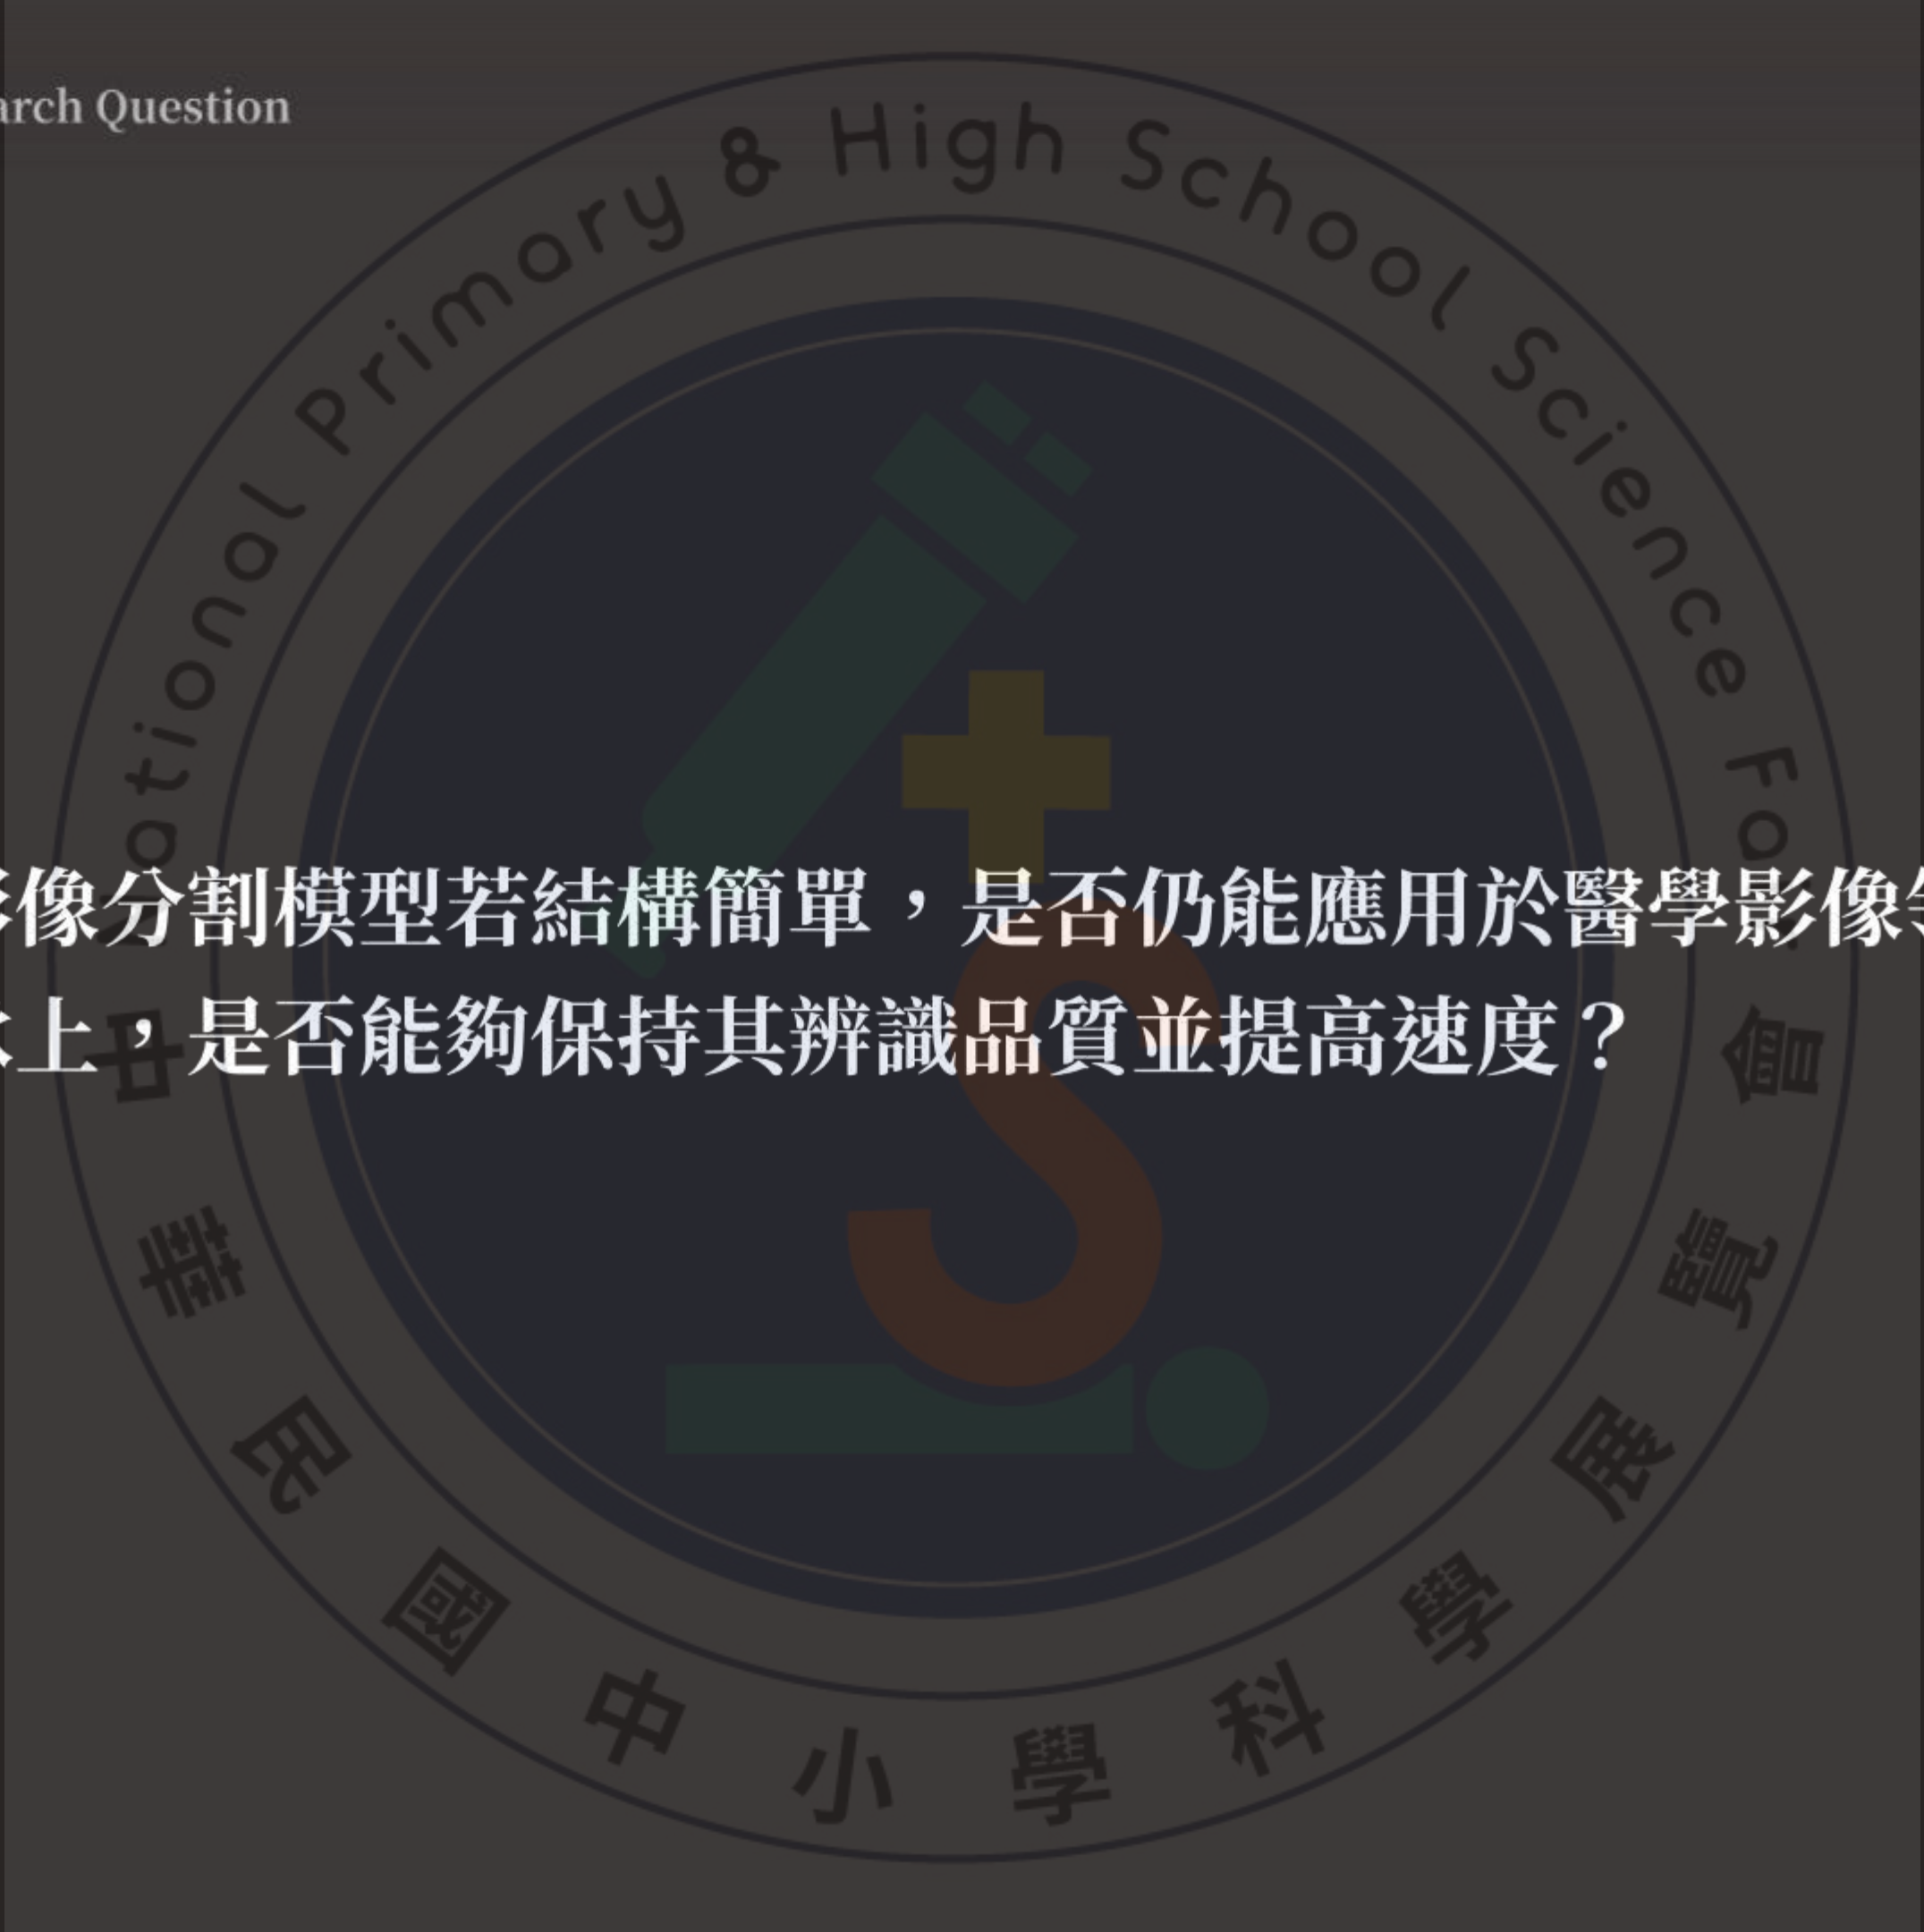
國內僅有 1 篇相關研究（且尚未公開全文）

醫學影像學研究僅限於常見疾病


#CNN

#Segmentation

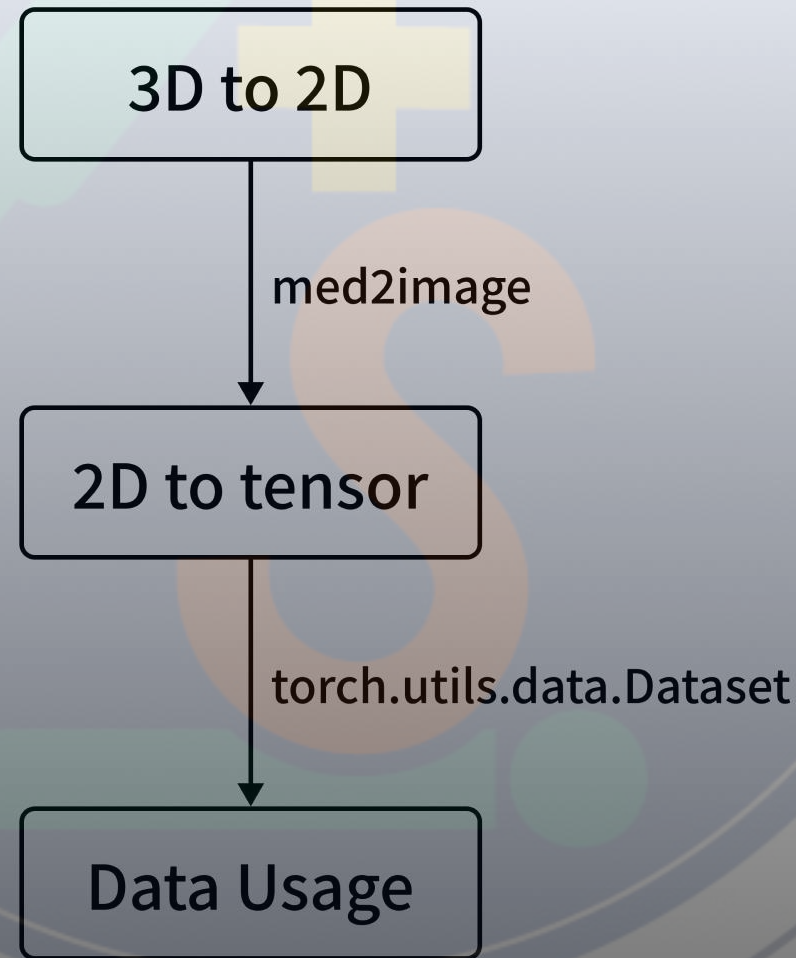
#Multiple Sclerosis

- 
- (一)、影像分割模型若結構簡單，是否仍能應用於醫學影像領域？
  - (二)、承上，是否能夠保持其辨識品質並提高速度？

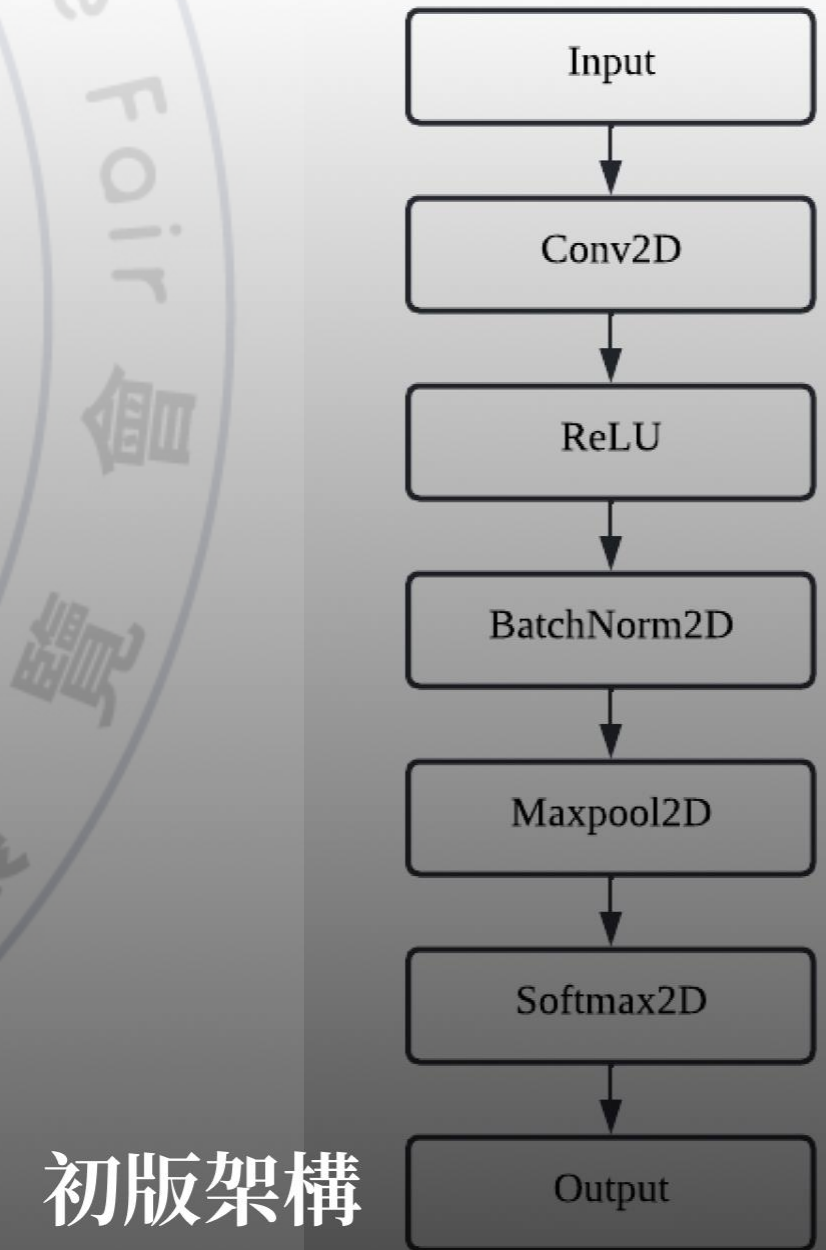
### 資料蒐集與模型建構



約翰霍普金斯大學 IACL 實驗室授權資料庫，病灶由兩位標註員進行標記



77312 平面影像檔  
39583744 筆數據



初版架構

## 調整模型

- 激活函數
- 批次標準化位置
- Softmax 函數
- 卷積層數量
- Channel 數調整


訓練、驗證與測試資料集 8:1:1

評估指標使用 Dice 係數、IoU 指標

## 建構卷積神經網路

- 激活函數：Leaky ReLU
- 批次標準化位於激活函數前
- 不加入 Softmax 函數
- 使用 2 卷積層
- 最高 channel：1024


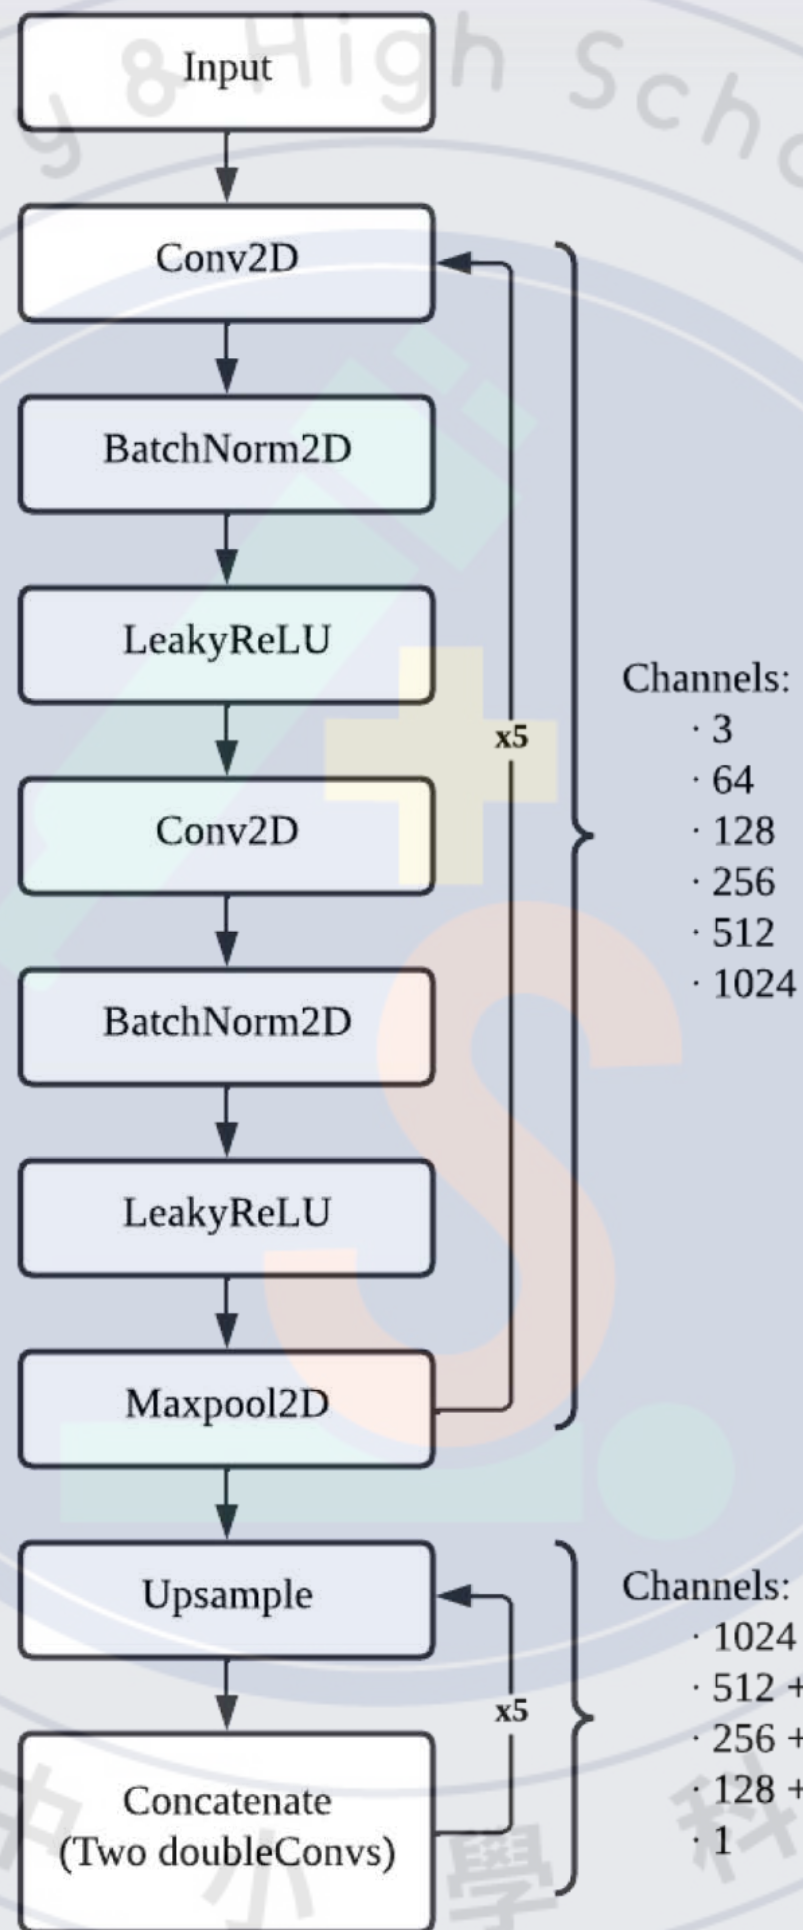
激活函數	ReLU	LeakyReLU	Sigmoid	TanH
最終 Dice 係數	0.3858	0.4404	0.0000	0.0000
最終損失值	0.0059	0.0498	0.0116	0.0266
視覺化結果	遮罩面積偏少	遮罩面積正常	無遮罩	無遮罩





# 訓練模型

- 調整學習率
- 損失函數採用 BCEDiceLoss
- 正式訓練使用
  - AWS EC2 g4dn.xlarge
  - 包含 Nvidia Tesla T4



## 訓練模型

(a) 原MRI圖 (b) 病灶位置 (c) 辨識結果 (a+c) 疊合結果



Method	Dice coefficient
Alshayeji et al. (2018)	$0.71 \pm 0.18$
Aslani et al. (2019)	0.6655
Kamraoui et al. (2022)	0.677
Krüger et al. (2020)	$0.45 \pm 0.28$
Schmidt et al. (2019)	0.72
Mask R-CNN	0.8490
<b>Proposed method</b>	<b><math>0.9392 \pm 0.02</math></b>

Method	FPS
UNet	3.5
Mask R-CNN	5
<b>Proposed Method</b>	<b>13.79</b>

## 研究結論

- 本模型主要貢獻於建構新模型
- 可應用於多發性硬化症影像分割
- 此模型 Dice 係數可達 94%
- 速度較 UNet 快 4 倍；較 Mask R-CNN 快 3 倍

## 未來展望

- 裝置小型化：於規格較低、體積較小之裝置執行
- 模型加速：利用模型加速套件減少更多執行時間
- 分級評估：透過體積或特徵判斷病理過程
- 其他醫療應用：腦瘤、血管造影、心臟外型等
- 臨床應用：實際以臨床試驗應用於醫療院所

- Alshayegi, M. H., Al-Rousan, M. A., Ellethy, H., & Abed, S. e. (2018). An efficient multiple sclerosis segmentation and detection system using neural networks. *Computers & Electrical Engineering*, 71, 191-205. <https://doi.org/10.1016/j.compeleceng.2018.07.020>
- Aslani, S., Dayan, M., Storelli, L., Filippi, M., Murino, V., Rocca, M. A., & Sona, D. (2019). Multi-branch convolutional neural network for multiple sclerosis lesion segmentation. *NeuroImage*, 196, 1-15. <https://doi.org/10.1016/j.neuroimage.2019.03.068>
- Bai, X., Wang, X., Liu, X., Liu, Q., Song, J., Sebe, N., & Kim, B. (2021). Explainable deep learning for efficient and robust pattern recognition: A survey of recent developments. *Pattern Recognition*, 120, 108102. <https://doi.org/10.1016/j.patcog.2021.108102>
- Bozorgmehr, B., Willemsen, P., Gibbs, J. A., Stoll, R., Kim, J.-J., & Pardyjak, E. R. (2021). Utilizing dynamic parallelism in CUDA to accelerate a 3D red-black successive over relaxation wind-field solver. *Environmental Modelling & Software*, 137, 104958. <https://doi.org/10.1016/j.envsoft.2021.104958>
- Carass, A., Roy, S., Gherman, A., Reinhold, J. C., Jesson, A., Arbel, T., Maier, O., Handels, H., Ghafoorian, M., Platel, B., Birenbaum, A., Greenspan, H., Pham, D. L., Crainiceanu, C. M., Calabresi, P. A., Prince, J. L., Roncal, W. R. G., Shinohara, R. T., & Oguz, I. (2020). Evaluating White Matter Lesion Segmentations with Refined Sørensen-Dice Analysis. *Scientific Reports*, 10(1), 8242. <https://doi.org/10.1038/s41598-020-64803-w>
- Carass, A., Roy, S., Jog, A., Cuzzocreo, J. L., Magrath, E., Gherman, A., Button, J., Nguyen, J., Bazin, P.-L., Calabresi, P. A., Crainiceanu, C. M., Ellingsen, L. M., Reich, D. S., Prince, J. L., & Pham, D. L. (2017). Longitudinal multiple sclerosis lesion segmentation data resource. *Data in Brief*, 12, 346-350. <https://doi.org/10.1016/j.dib.2017.04.004>
- Chen, J., Balan, A., Masih Das, P., Thiruraman, J. P., & Drndic, M. (2021). Computer vision AC-STEM automated image analysis for 2D nanopore applications. *Ultramicroscopy*, 113249. <https://doi.org/10.1016/j.ultramic.2021.113249>
- Gurkan, F., Günsel, B., & Ozer, C. (2019). Robust object tracking via integration of particle filtering with deep detection. *Digital Signal Processing*, 87, 112-124. <https://doi.org/10.1016/j.dsp.2019.01.017>
- Kamraoui, R. A., Ta, V.-T., Tourdias, T., Mansencal, B., Manjon, J. V., & Coup, P. (2022). DeepLesionBrain: Towards a broader deep-learning generalization for multiple sclerosis lesion segmentation. *Medical Image Analysis*, 76, 102312. <https://doi.org/10.1016/j.media.2021.102312>
- Khademi, A., Gibicar, A., Arezza, G., DiGregorio, J., Tyrrell, P. N., & Moody, A. R. (2021). Segmentation of white matter lesions in multicentre FLAIR MRI. *Neuroimage: Reports*, 1(4), 100044. <https://doi.org/10.1016/j.ynirp.2021.100044>
- Krüger, J., Opfer, R., Gessert, N., Ostwaldt, A.-C., Manogaran, P., Kitzler, H. H., Schlaefer, A., & Schippling, S. (2020). Fully automated longitudinal segmentation of new or enlarged multiple sclerosis lesions using 3D convolutional neural networks. *NeuroImage: Clinical*, 28, 102445. <https://doi.org/10.1016/j.nicl.2020.102445>
- Li, Y., Zhang, Q., & Yoon, S. W. (2021). Gaussian process regression-based learning rate optimization in convolutional neural networks for medical images classification. *Expert Systems with Applications*, 184, 115357. <https://doi.org/10.1016/j.eswa.2021.115357>
- Maas, A. L. (2013). Rectifier Nonlinearities Improve Neural Network Acoustic Models.
- Mohamed, D., Ghoniemy, S., & Selim, G. (2012). Automated Brain Tumor Detection and Identification Using Image Processing and Probabilistic Neural Network Techniques. *International journal of image processing and visual communication*, 1, 1-8.
- Paszke, A., Gross, S., Chintala, S., Chanan, G., Yang, E., DeVito, Z., Lin, Z., Desmaison, A., Antiga, L., & Lerer, A. (2017). Automatic differentiation in PyTorch.
- Schmidt, P., Pongratz, V., Küster, P., Meier, D., Wuerfel, J., Lukas, C., Bellenberg, B., Zipp, F., Groppa, S., Sämann, P. G., Weber, F., Gaser, C., Franke, T., Bussas, M., Kirschke, J., Zimmer, C., Hemmer, B., & Mühlau, M. (2019). Automated segmentation of changes in FLAIR-hyperintense white matter lesions in multiple sclerosis on serial magnetic resonance imaging. *NeuroImage: Clinical*, 23, 101849. <https://doi.org/10.1016/j.nicl.2019.101849>
- Srikanth, P., & Koley, C. (2021). A novel three-dimensional deep learning algorithm for classification of power system faults. *Computers & Electrical Engineering*, 91, 107100. <https://doi.org/10.1016/j.compeleceng.2021.107100>
- Süleyman Yıldırım, M., & Dandıl, E. (2020). Automatic detection of multiple sclerosis lesions using Mask R-CNN on magnetic resonance scans. *IET Image Processing*, 14(16), 4277-4290. <https://doi.org/10.1049/iet-ipr.2020.1128>
- Wang, Z. (2019). SEG-YOLO: Real-Time Instance Segmentation Using YOLOv3 and Fully Convolutional Network (Publication Number 2019:822) [Student thesis, DiVA. <http://urn.kb.se/resolve?urn=urn:nbn:se:kth:diva-271652>
- Xu, B., Wang, N., Chen, T., & Li, M. (2015). Empirical Evaluation of Rectified Activations in Convolutional Network. *ArXiv*, abs/1505.00853.
- Xu, R., Lin, H., Lu, K., Cao, L., & Liu, Y. (2021). A Forest Fire Detection System Based on Ensemble Learning. *Forests*, 12, 217. <https://doi.org/10.3390/f12020217>



**Thanks for listening!**

敬請各位教授給予指教！

032809：以新建構之卷積神經網路對腦部核磁共振影像執行多發性硬化症之判讀