

國立臺灣大學工學院工程科學及海洋工程學系



碩士論文

Department of Engineering Science and Ocean Engineering

College of Engineering

National Taiwan University

Master Thesis

基於深度學習之老鼠腦部磁振影像

中風區域分割研究

Stroke Lesion Segmentation in Rat Brain MR Images

Based on Deep Learning

何世馨

Shih-Hsin Ho

指導教授：張恆華 博士

Advisor: Heng-Hua Chang, Ph.D.

中華民國 109 年 7 月


July 2020

## 致謝

感謝張恆華教授，感謝我的電腦，感謝大家。



## 中文摘要



腦中風長期是造成人類死亡的主要原因之一，依型態可以分為腦缺血及腦出血兩大類，而磁共振成像 (Magnetic Resonance Imaging, MRI) 之影像可以作為初步之腦中風判讀依據。在相關實驗中，齧齒動物老鼠時常選擇為實驗動物，以其中風腦部影像作為研究基礎。而在研究上，腦中風影像之中風區域選取及判讀需要腦神經專家處置，這是一件繁鎖且耗時的任務，並有標準一致性上的問題。本研究以深度學習為基礎，針對磁共振成像中 T2 加權成像及擴散加權成像 (Diffusion Weighted Imaging, DWI) 之影像，開發腦中風影像自動分割中風區域之模型。透過全卷積神經網路為基礎架構，當中加入本研究所提出之混合殘差塊，並使用 3528 張 T2 和 3024 張 DWI 增強後之影像分別進行訓練。檢視實驗結果，以本架構針對兩種影像各別訓練之模型，能在訓練資料以外之測試資料有優異的分割結果。在分割 T2 影像中風區域中達到 86.84% 的準確度，並在 DWI 影像中達到了 87.36% 的準確度。

關鍵字：深度學習、卷積神經網路、磁共振成像、缺血型腦中風、影像分割

## Abstract


Stroke has been one of the main causes of human deaths for a long time. Stroke can be divided into two types: ischemic and hemorrhagic. Magnetic Resonance Imaging (MRI) can be used as a preliminary interpretation basis for stroke. In related experiments, mice are often selected as experimental animals, and their brain images are used for research. Usually, the determination and segmentation of stroke areas in rat brain stroke images requires manual processing by neurological experts. This process is complicated and time-consuming, and may have different standards. This thesis develops a model based on deep learning for automatically segmenting stroke regions in T2 Weighted and Diffusion Weighted image (DWI) images. Into the fully convolutional network as the basic structure, the mix block proposed by this thesis is incorporated. The network is trained using 3528 T2 and 3024 DWI augmented images. The experimental results show that the two models trained separately for the two types of rat images with this architecture have excellent stroke segmentation results in the test data. The T2 image segmentation result has 86.84% accuracy, and the DWI image achieved 87.36% accuracy.

Keywords: deep learning, convolutional neural network (CNN), magnetic resonance imaging (MRI), ischemic stroke, image segmentation

# 目錄




致謝.....	i
中文摘要.....	ii
Abstract.....	iii
目錄.....	iv
圖目錄.....	vii
表目錄.....	x
<b>第 1 章 緒論.....</b>	<b>1</b>
1.1 研究背景.....	1
1.2 研究動機.....	2
1.3 研究目的.....	2
1.4 論文架構.....	2
<b>第 2 章 文獻探討.....</b>	<b>3</b>
2.1 卷積神經網路.....	3
2.1.1 神經元.....	3
2.1.2 卷積層.....	5
2.1.3 池化層.....	6
2.2 神經網路訓練.....	6
2.2.1 前饋.....	7
2.2.2 反傳遞演算法.....	7
2.2.3 自適應矩估計優化器.....	8
2.3 全卷積網路.....	9
2.3.1 編碼-解碼模型.....	9



2.3.2	U 型網路.....	11
2.4	殘差學習.....	12
2.5	批量標準化.....	13
2.6	不同網路架構核心.....	14
2.6.1	Dense block.....	14
2.6.2	Inception module.....	14
2.6.3	倒置殘差塊.....	15
2.6.4	Squeeze-and-Excitation block.....	16
2.6.5	ResNeXt block.....	17
<b>第 3 章</b>	<b>研究設計與方法.....</b>	<b>18</b>
3.1	研究流程.....	18
3.2	資料前處理.....	19
3.3	資料增強.....	19
3.4	卷積神經網路架構.....	21
3.4.1	殘差塊.....	21
3.4.2	混合殘差塊.....	22
3.4.3	卷積層架構.....	24
3.4.4	卷積核初始化.....	24
3.4.5	其他網路架構.....	24
<b>第 4 章</b>	<b>實驗結果.....</b>	<b>25</b>
4.1	老鼠腦部 MR 影像資料集.....	25
4.2	神經網路訓練模型.....	26
4.2.1	實驗環境.....	26
4.2.2	神經網路訓練參數.....	26
4.3	實驗結果評估標準.....	27

4.3.1	一致度.....	28
4.3.2	敏感度.....	29
4.3.3	識別度.....	29
4.3.4	戴斯係數.....	29
4.3.5	雅卡爾指數.....	29
4.4	T2 影像實驗結果.....	30
4.4.1	神經網路模型預測結果.....	30
4.4.2	其他方法比較.....	41
4.5	DWI 影像實驗結果.....	49
4.5.1	神經網路模型預測結果.....	49
4.5.2	其他方法比較.....	60
<b>第 5 章</b>	<b>結論及未來展望.....</b>	<b>68</b>
5.1	結論.....	68
5.2	未來展望.....	69
<b>附錄</b> .....		<b>70</b>
<b>參考文獻</b> .....		<b>72</b>



# 圖目錄



圖 1-1 圖為擴散加權成像 .....	1
圖 1-2 圖為 T2 加權成像 .....	1
圖 2-1 神經元 .....	3
圖 2-2 線性整流函數 .....	4
圖 2-3 圖為 Sigmoid 函數 .....	4
圖 2-4 圖為 tanh 函數 .....	5
圖 2-5 輸入經過卷積運算得到輸出 .....	5
圖 2-6 最大值池化 .....	6
圖 2-7 多層神經網路 .....	7
圖 2-8 全卷積網路[16] .....	10
圖 2-9 上採樣 - 填滿 .....	10
圖 2-10 上採樣 - 位置 .....	10
圖 2-11 圖為 U 型網路結構[18] .....	11
圖 2-12 淺層與深層網路[20] .....	12
圖 2-13 殘差塊[20] .....	12
圖 2-14 批量標準化[21] .....	13
圖 2-15 圖為 Dense block [22] .....	14
圖 2-16 圖為 Inception module [23] .....	15
圖 2-17 圖 a 為傳統殘差塊， b 為 Separable 卷積塊[25] .....	16
圖 2-18 圖 a 為傳統殘差塊， b 為倒置殘差塊[25] .....	16
圖 2-19 圖為 Squeeze-and-Excitation block [27] .....	16
圖 2-20 圖為 ResNeXt block [29] .....	17
圖 3-1 研究流程 .....	18
圖 3-2 過擬合示意圖 .....	19



圖 3-3 資料集影像擴充 .....	20
圖 3-4 不同結構之殘差塊[32].....	22
圖 3-5 混和殘差塊 .....	22
圖 3-6 本研究之 Rat-Unet 網路架構.....	23
圖 3-7 卷積層架構 .....	24
圖 4-1 結果評估示意圖 .....	28
圖 4-2 測試之 T2 影像分割結果柱狀圖 .....	31
圖 4-3 測試之 T2 影像分割結果誤差比例柱狀圖 .....	32
圖 4-4 測試之 T2 資料集編號 141 之中風區域預測區域.....	33
圖 4-5 測試之 T2 資料集編號 141 之中風區域正確區域.....	34
圖 4-6 測試之 T2 資料集編號 141 之中風區域正確與預測區域.....	35
圖 4-7 測試之 T2 資料集編號 141 之中風區域三維正確與預測區域.....	36
圖 4-8 測試之 T2 資料集編號 142 之中風區域預測區域.....	37
圖 4-9 測試之 T2 資料集編號 142 之中風區域正確區域.....	38
圖 4-10 測試之 T2 資料集編號 142 之中風區域正確與預測區域.....	39
圖 4-11 測試之 T2 資料集編號 142 之中風區域三維正確與預測區域.....	40
圖 4-12 測試之 T2 資料集中風區域預測誤差較大圖例.....	41
圖 4-13 測試之 T2 資料集編號 118 之中風區域其他方法預測.....	42
圖 4-14 測試之 T2 資料集編號 118 之切片 10 中風區域其他方法預測.....	43
圖 4-15 測試之 T2 資料集編號 141 之中風區域其他方法預測.....	44
圖 4-16 測試之 T2 資料集編號 141 之切片 14 中風區域其他方法預測.....	45
圖 4-17 測試之 T2 資料集編號 142 之中風區域其他方法預測.....	46
圖 4-18 測試之 T2 資料集編號 142 之切片 12 中風區域其他方法預測.....	47
圖 4-19 測試之 DWI 影像分割結果柱狀圖 .....	50
圖 4-20 測試之 DWI 影像分割結果誤差比例柱狀圖 .....	51
圖 4-21 測試之 DWI 資料集編號 141 之中風區域預測區域.....	52

圖 4-22 測試之 DWI 資料集編號 141 之中風區域正確區域 .....	53
圖 4-23 測試之 DWI 資料集編號 141 之中風區域正確與預測區域 .....	54
圖 4-24 測試之 DWI 資料集編號 141 之中風區域三維正確與預測區域 .....	55
圖 4-25 測試之 DWI 資料集編號 142 之中風區域預測區域 .....	56
圖 4-26 測試之 DWI 資料集編號 142 之中風區域正確區域 .....	57
圖 4-27 測試之 DWI 資料集編號 142 之中風區域正確與預測區域 .....	58
圖 4-28 測試之 DWI 資料集編號 142 之中風區域三維正確與預測區域 .....	59
圖 4-29 測試之 DWI 資料集中風區域預測誤差較大圖例 .....	60
圖 4-30 測試之 DWI 資料集編號 141 之中風區域其他方法預測 .....	61
圖 4-31 測試之 DWI 資料集編號 141 之切片 12 中風區域其他方法預測 ...	62
圖 4-32 測試之 DWI 資料集編號 142 之中風區域其他方法預測 .....	63
圖 4-33 測試之 DWI 資料集編號 142 之切片 6 中風區域其他方法預測 .....	64
圖 4-34 測試之 DWI 資料集編號 146 之中風區域其他方法預測 .....	65
圖 4-35 測試之 DWI 資料集編號 146 之切片 10 中風區域其他方法預測 ...	66

## 表目錄



表 4-1 資料集 .....	25
表 4-2 電腦環境 .....	26
表 4-3 訓練參數 .....	27
表 4-4 學習率調整 ReduceLROnPlateau 參數.....	27
表 4-5 自適應矩估計優化器參數 .....	27
表 4-6 區域分類 .....	28
表 4-7 測試之 T2 影像分割結果.....	31
表 4-8 測試之 T2 影像分割結果分析 .....	32
表 4-9 測試之 T2 影像分割結果與其他方法比較.....	48
表 4-10 測試之 T2 影像模型訓練時間與其他方法比較.....	48
表 4-11 測試之 DWI 影像分割結果.....	50
表 4-12 測試之 DWI 影像分割結果分析 .....	51
表 4-13 測試之 DWI 影像分割結果與其他方法比較 .....	67
表 4-14 測試之 DWI 影像模型訓練時間與其他方法比較 .....	67

# 第 1 章 緒論



## 1.1 研究背景

腦中風長期是造成人類死亡的主要原因之一[1]。腦中風依型態可以分為缺血型及出血型兩大類，而其中大部分是由於腦血管阻塞所造成之缺血型腦中風。在判讀腦中風或是腦中風之程度，磁共振成像（Magnetic Resonance Imaging, MRI）之影像可以作為初步之依據[2]。其中磁共振成像有不同類別，包括 T1 加權成像、T2 加權成像及擴散加權成像（Diffusion Weighted Imaging, DWI）等成像方式。本研究所使用之資料集影像成像為 T2 加權成像及擴散加權成像（DWI）。在實驗上，齧齒動物老鼠時常選擇為實驗動物，其與人類同為哺乳動物，並與人類有 90% 的基因序列相似度[3]，且容易飼養也相對穩定。老鼠也可以運用在腦中風實驗上，透過磁共振成像檢視老鼠腦中風的情況，如圖 1-1 及圖 1-2，未來便能以此為基礎延伸至人類研究[4]。




圖 1-1 圖為擴散加權成像

圖左為原影像，圖右藍色區域為腦中風區域




圖 1-2 圖為 T2 加權成像

圖左為原影像，圖右藍色區域為腦中風區域



## 1.2 研究動機

老鼠缺血型腦中風在磁共振成像之腦部影像中，對中風區域分割並對結果進行分析，需要腦神經專家對各張影像進行手動分割。在不同權重之成像上，同隻老鼠可能會有些許不同之結果，這樣的工作流程是較為繁鎖及費時。故本研究提出對 T2 加權成像及擴散加權成像 (DWI) 之腦部影像進行自動化分割腦中風區域之深度學習模型，在維持一定分割結果精準度上簡化此流程。

## 1.3 研究目的

本研究目的為，分割老鼠缺血型腦中風在磁共振成像上 T2 加權成像及擴散加權成像 (DWI) 之腦部影像上之中風區域。透過卷積神經網路對現有資料集進行訓練並學習出適當之模型，並應用於訓練資料集外之測試資料且分析結果，以便進一步運用於大量之鼠腦影像，協助醫師及專家進行研究及判讀。

## 1.4 論文架構

本論文包含五個章節。

第一章，緒論，闡述研究之背景及動機，並說明研究之目的。

第二章，文獻探討，說明卷積神經網路之架構，並探討以此為延伸之相關研究及應用。

第三章，研究設計與方法，展示本研究之研究流程及所提出之神經網路架構，並就各流程進行說明。

第四章，實驗結果，針對實驗結果進行分析，其中包含實驗環境及結果分析之指標說明。

第五章，結論及未來展望，對於本論文之總結，並提出未來期許及可能之研究方向。

## 第 2 章 文獻探討



### 2.1 卷積神經網路

神經網路之研究近期在電腦科學領域蓬勃發展，而其中卷積神經網路 (Convolutional Neural Networks, CNN) 為其大宗[5]，目前被廣泛應用於電腦視覺領域，並且在某些領域之應用上擁有超越人類判斷的精準度[6]。卷積神經網路中透過卷積層，以卷積運算對輸入資料進行特徵提取，並加入池化層減少資料量及保留特徵，最後將結果輸出[7]。以下將對神經網路及卷積神經網路架構進行說明。

#### 2.1.1 神經元

神經網路之單元可以稱作神經元 (Neuron)，如圖 2-1，發想來自生物中神經元構造[8]，深度神經網路包含了數個神經元。




圖 2-1 神經元

其計算公式可以表示如下：

$$y_k = \varphi\left(\sum_{i=1}^n x_i w_{ki} + \theta_k\right) \quad (1)$$

其中  $i$  表示神經元的第  $i$  個元素， $k$  表示第  $k$  個神經元。 $x$  為神經元的多個輸入，與權重  $w$  相乘並與偏差值  $\theta$  相加後作為訊號。最後訊號透過激勵函數  $\varphi$  可以得到輸出  $y$ 。

當中激勵函數特性為非線性函數，可視為對神經元中之刺激訊號。透過非線性轉換，使得神經網路能解決非線性問題。目前神經網路架構中，大多使用線性整流函數 (Rectified Linear Unit, ReLU) [9] 作為激勵函數，公式如下：

$$f(x) = \max(0, x) \quad (2)$$

將輸入小於 0 的值設為 0 並保留大於 0 的值，停止傳遞不必要的特徵，減緩過擬合的發生，再作為下一層之輸入，如圖 2-2，過擬合現象會在第 3 章中說明。




圖 2-2 線性整流函數

而其他常見之激勵函數，Sigmoid 式(3) 及 tanh 函數 式(4) [10]，其函式可繪製為圖 2-3 及圖 2-4。

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3)$$




圖 2-3 圖為 Sigmoid 函數

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4)$$




圖 2-4 圖為 tanh 函數

由圖 2-3 和圖 2-4，可以發現在左右兩側之飽和區導數接近 0，會使得反傳遞中訊息消失，無法順利更新參數，而整流線性單位函數之導數在輸入大於 0 的情況下為 1 反之為 0，避免了上述的現象。

### 2.1.2 卷積層

卷積神經網路能處理電腦視覺問題，當中卷積層（Convolution layer）為重要因素。卷積層將輸入透過卷積運算產生輸出，如圖 2-5，將輸入經由步伐（Stride）與權重矩陣求得哈達瑪積（Hadamard product），圖中。運算子表示對兩個矩陣各元素相乘得到哈達馬乘積，一個卷積層中會依需求給定多個權重矩陣。




圖 2-5 輸入經過卷積運算得到輸出





權重矩陣可以稱為過濾器 (Filter) 或是卷積核 (Kernel)，透過卷積運算，多個過濾器能將輸入之不同特徵提取，過濾出符合如此特徵之區塊，並保留空間上的訊息。而輸出則稱為特徵地圖 (Feature Map)。

### 2.1.3 池化層

卷積神經網路中加入池化層 (Pooling layer)，可以降低資料維度以減少資料量並進行特徵地圖的提取保留，而此操作稱為對資料進行編碼。常見池化有最大值池化 (Max pooling)，或是平均池化 (Average pooling)。最大值池化保留範圍內最大值，並根據範圍及步伐進行運算，如圖 2-6，公式如下：

$$y = \max_{i,j=1}^{h,w} X_{i,j} \quad (5)$$

公式中  $h$  及  $w$  表示為最大池化的範圍， $X$  為欲進行運算之矩陣。而平均池化則是取範圍內數值之平均值。



圖 2-6 最大值池化

## 2.2 神經網路訓練

多個層透過連結便組合成網路，輸入及輸出層是將資料輸入及產生結果，當中透過隱藏層進行運算，如圖 2-7。而其中各層的權重便是透過神經網路反覆進行前饋及反傳遞演算法所調整，稱為學習[11]，並期望達到最佳準確度。




圖 2-7 多層神經網路

### 2.2.1 前饋

在前饋中，將輸入資料透過各層的連接及運算，最終輸出結果，結果可視為以多權重所組成之函式。而以圖 2-7 為例之含兩層隱藏層之神經網路公式如下：

$$y = \varphi \left( \sum_y \sum_z w_{3,y,z} \varphi \left( \sum_x \sum_y w_{2,x,y} \varphi \left( \sum_i \sum_x x_i w_{1,i,x} \right) \right) \right) \quad (6)$$

組合與式(1)相似之算式。 $x$  為神經網路的輸入， $i$  為第  $i$  個輸入，與權重  $w$  相乘作為訊號，權重  $w$  下標之 3 個參數分別為層、第幾個輸入及第幾個輸出，將輸出之各訊號加總後透過激勵函數  $\varphi$  作為下一層之輸入，最後輸出為  $y$ 。

### 2.2.2 反傳遞演算法

神經網路透過反傳遞演算法 (Backpropagation) 來更新權重，以最小化輸出之誤差。誤差可以透過所選用之損失函數 (Loss function) 來計算。而透過更新權重來降低誤差，需知道該權重對於誤差之影響，而這個影響力可以透過偏微分及鍊鎖率 (Chain Rule) 來計算，公式如下：

$$\frac{\partial \text{loss}}{\partial w_{ki}} = \frac{\partial \text{loss}}{\partial \text{out}} * \frac{\partial \text{out}}{\partial z_k} * \frac{\partial z_k}{\partial w_{ki}} \quad (7)$$



公式表示權重  $w_{ki}$  對於誤差之影響，當中  $k$  和  $i$  代表在  $k$  層的第  $i$  個權重，而當中  $z$  表示經過激勵函數之輸出。如此得到了誤差在該權重上的梯度，再根據此數值去更新權重，優化目前的模型。

### 2.2.3 自適應矩估計優化器

在得到誤差在該權重上的梯度後，模型需要根據此梯度去更新權重，優化整個模型。而自適應矩估計優化器 (Adaptive Moment Estimation, Adam) [12] 是目前被大量使用的優化演算法[13]，該演算法結合了其他優化器 Momentum 演算法[14]及 RMSprop (Root Mean Square prop) 演算法[15]。此演算法會先計算出與前一次梯度更新方向相關之參數  $m_t$  與  $v_t$ ，公式如下：

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (8)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (9)$$

$\beta_1$  與  $\beta_2$  為指數衰退率， $g_t$  為此次梯度。

$m_t$  類似 Momentum 演算法， $m_{t-1}$  為之前的梯度所計算出的方向，在與當前梯度相加，如此可以考慮到整個梯度的運動方向。類似慣性的概念，若前一次梯度與此次是同方向，就加強這方向的移動，反之則減緩。而  $v_t$  類似 RMSprop 演算法當中之參數，計算之前梯度的平方和，但是會與指數衰退率相乘，可以調整欲參考之梯度的重要程度。

由於在初始時參數會設定為 0，導致前期計算時與期望之參數的偏差過小，因此計算出參數後，會通過偏差校正來校正參數，公式如下：

$$\widehat{m}_t = \frac{m_t}{(1 - \beta_1^t)} \quad (10)$$

$$\widehat{v}_t = \frac{v_t}{(1 - \beta_2^t)} \quad (11)$$



最後便可以對權重進行更新，公式如下：

$$\theta_{t+1} = \theta_{t+1} - \frac{\eta}{\sqrt{\widehat{v}_t} + \epsilon} \widehat{m}_t \quad (12)$$

其中  $\theta$  為權重， $\epsilon$  為常數以防止除 0， $\eta$  為學習率，學習率越大，則權重的更新也較大，但有可能會導致錯過最佳解，而過小則可能更新過慢，或是無法找到最佳解之方向，故學習率參數需視神經網路模型之學習過程手動調整。

## 2.3 全卷積網路

全卷積網路 (Fully Convolutional Networks, FCN) [16] 可以用來處理語意分割 (Semantic segmentation) 問題，語意分割是對輸入資料的各數值或是圖片中像素點進行分類，以圖片為概念便是能將圖片中的目標物體位置分割出來。以下對全卷積網路進行說明。

### 2.3.1 編碼-解碼模型

卷積神經網路中池化層可以視為進行編碼，而傳統卷積神經網路在解決分類問題時會在最後加上全連接層來處理分類[17]。全卷積網路中則沒有全連接層，而是在編碼後，加入上採樣層 (Upsampling layer) 如圖 2-8 或反卷積層進行卷積運算，以解碼還原至原大小。並解碼時可加入先前網路中對應之池化層訊息，以處理像素點分類問題，稱之為編碼-解碼模型 (Encoder-Decoder Model)。

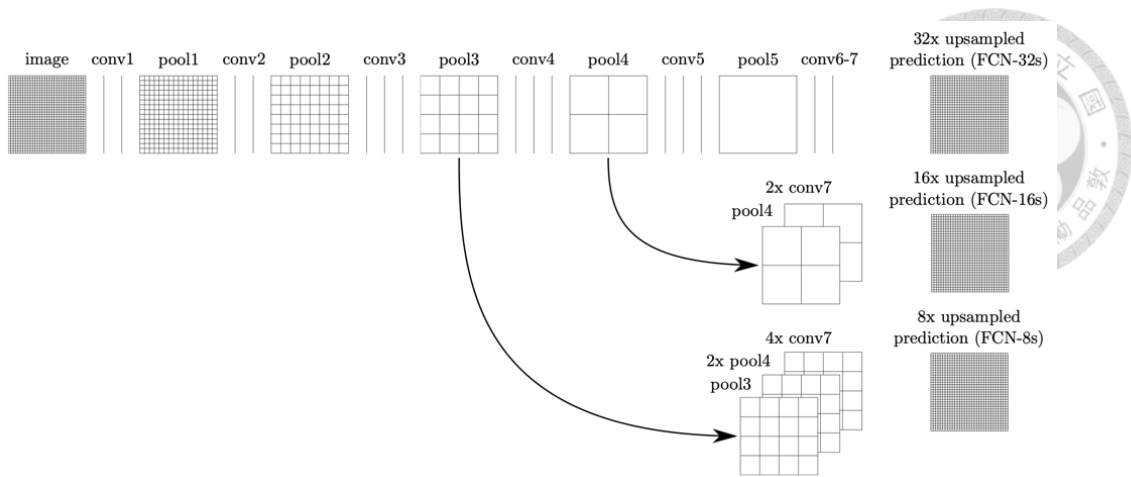


圖 2-8 全卷積網路[16]

上採樣層將特徵地圖還原至原大小，同時達成解碼。上採樣有不同還原方式，常見是將放大後區塊填滿，如圖 2-9，或是放置於進行編碼池化前資料所在位置等等，如圖 2-10。

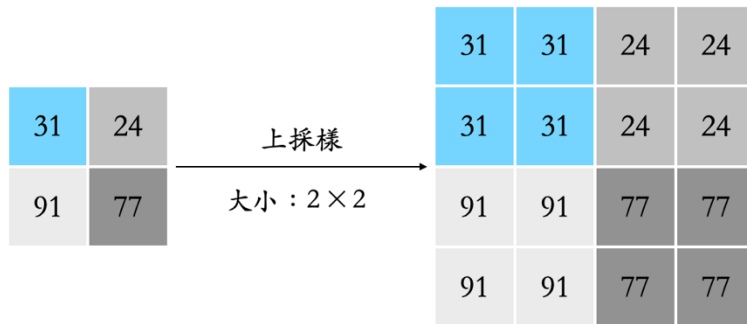


圖 2-9 上採樣 - 填滿




圖 2-10 上採樣 - 位置



## 2.4 殘差學習

許多研究顯示[19]，網路深度對於訓練結果有重要影響。但是當神經網路到達一定的深度時，卻可以發現較深層的網路比淺層的網路有更低的準確度，準確度在淺層網路達到了飽和，如圖 2-12 所示。何愷明的研究[20]指出，這並非由過擬合及網路無法收斂而產生，並將這樣的現象稱為退化（Degradation），同時提出了解決辦法，殘差學習（Residual Learning），使神經網路能輕易地加深，克服了深層網路難以訓練的問題。

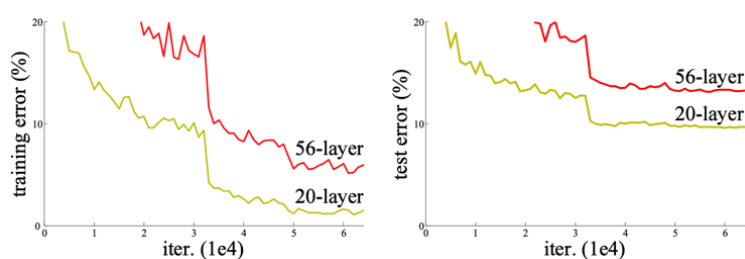


圖 2-12 淺層與深層網路[20]

殘差學習中的殘差塊，如圖 2-13，加入了捷徑（Shortcuts），在輸出時將輸入與之相加。




圖 2-13 殘差塊[20]

輸入  $x$  經過卷積後得到輸出  $F(x)$ ，而目標輸出可表示為  $H(x)$ ，因此  $F(x)$  可稱為殘差（Residual），代表兩者差距，公式如下：

$$F(x) = H(x) - x \quad (13)$$

目標輸出為殘差與輸入之加總，公式如下：

$$H(x) = F(x) + x \quad (14)$$



殘差學習中神經網路所需學習的為殘差  $F(x)$ ，而不需要學習整個目標  $H(x)$ 。在如此情況下加深網路深度，當學習過程中網路深度已經達到飽和時，殘差變小，輸入會趨近於輸出，如此網路比較不會出現退化的情形，使得深層網路容易訓練。

## 2.5 批量標準化

批量標準化 (Batch Normalization) [21]，神經網路將資料分批進行訓練，並將此批資料在訓練過程中進行標準化，使得輸出平均值為 0 標準差為 1，並會再給予調整的參數，用以改變或減低標準化的影響，而調整參數是藉由網路學習自行調整，公式如圖 2-14。批量標準化使得下一層之輸入變的穩定，透過標準化降低了前一層權重改變時的輸出敏感度，緩解權重的更新對於整體網路模型的影響，並使得網路能更加快速的收斂。

**Input:** Values of  $x$  over a mini-batch:  $\mathcal{B} = \{x_{1\dots m}\}$ ;

Parameters to be learned:  $\gamma, \beta$

**Output:**  $\{y_i = \text{BN}_{\gamma, \beta}(x_i)\}$

$$\mu_{\mathcal{B}} \leftarrow \frac{1}{m} \sum_{i=1}^m x_i \quad // \text{ mini-batch mean}$$

$$\sigma_{\mathcal{B}}^2 \leftarrow \frac{1}{m} \sum_{i=1}^m (x_i - \mu_{\mathcal{B}})^2 \quad // \text{ mini-batch variance}$$

$$\hat{x}_i \leftarrow \frac{x_i - \mu_{\mathcal{B}}}{\sqrt{\sigma_{\mathcal{B}}^2 + \epsilon}} \quad // \text{ normalize}$$

$$y_i \leftarrow \gamma \hat{x}_i + \beta \equiv \text{BN}_{\gamma, \beta}(x_i) \quad // \text{ scale and shift}$$

圖 2-14 批量標準化[21]





## 2.6 不同網路架構核心

本節介紹其他研究所提出之網路架構其核心，透過核心之組合，可以進一步建構所需之卷積神經網路亦或是全卷積網路，本論文之實驗結果也將與本節介紹之方法進行比較。

### 2.6.1 Dense block

Dense block 於 2016 年所提出[22]，如圖 2-15，其研究中將使用 Dense block 組成之網路架構稱為 DenseNet。殘差塊只於最終輸出時與輸入相加，而 Dense block 中各層之輸入為前面各層輸出之合併，透過密集之連接，使得各層能使用前面層之特徵，運用重複使用之特徵以學習出其神經網路所需之權重。




圖 2-15 圖為 Dense block [22]

### 2.6.2 Inception module

Inception module 為 Google 於 2014 年所提出[19]，其所組成之網路架構可稱為 InceptionNet，Inception module 之組合將網路拓寬，透過不同尺度之特徵來進行特徵提取，包含池化層及不同大小之卷積層等，並將輸出再進行合併，

Inception module 於 2015 有經過改良[23]，如圖 2-16，並且其中可以加入殘差捷徑，以其為核心所架構之網路，可稱為 InceptionResNet [24]。




圖 2-16 圖為 Inception module [23]

### 2.6.3 倒置殘差塊

倒置殘差塊 ( Inverted residual block ) 為 2018 年所提出[25]，其為 MobileNetV2 之核心，其中運用了 MobileNets [26]中將傳統卷積層以 Depthwise 卷積及 Pointwise 卷積兩個步驟取代，稱為 Separable 卷積塊，如圖 2-17。Separable 卷積塊對輸入之各特徵地圖先進行卷積運算，再將其組合後，透過  $1 \times 1$  之卷積核及所設定之數量進行卷積運算。透過 Separable 卷積塊，能夠減少傳統卷積之計算量。而倒置殘差塊中除了運用 Separable 卷積塊，不同於傳統殘差塊將輸入降低維度，其卷積層會將輸入之維度提升，因此稱之為倒置 ( Inverted )，如圖 2-18，並於輸出時降低維度且不加入 ReLu 激勵函數，因研究認為在低維度時使用 ReLu 激勵函數會有特徵上的損失。

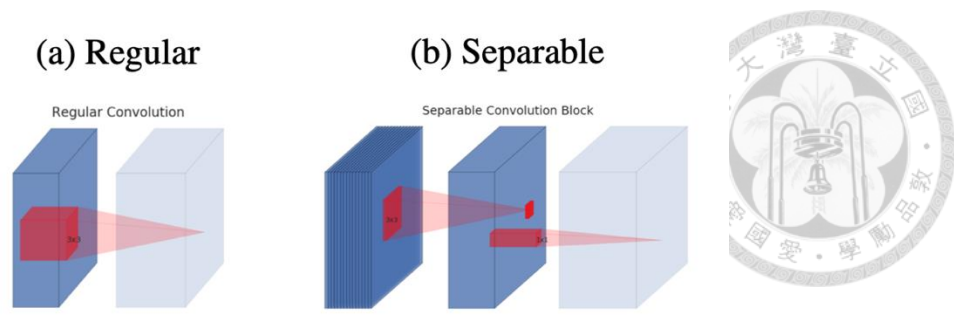


圖 2-17 圖 a 為傳統殘差塊， b 為 Separable 卷積塊[25]

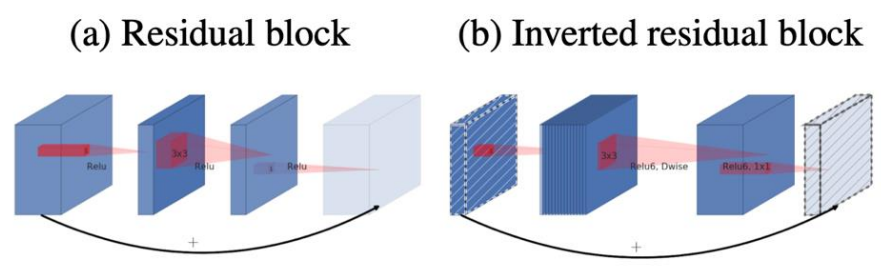


圖 2-18 圖 a 為傳統殘差塊， b 為倒置殘差塊[25]

### 2.6.4 Squeeze-and-Excitation block

Squeeze-and-Excitation block 於 2017 年所提出[27]，簡稱 SE block ，此核心透過 Global pooling 達到該研究中所稱之 Squeeze 操作，再透過兩層全連接層進行 Excitation ，如圖 2-19，其所得出之結果會再乘上輸入，使重要特徵增強並減低不重要之特徵，而 SE block 能夠與其他不同網路架構核心組合，於 2019 年所提出之 EfficientNet [28]，其核心便是倒置殘差塊並加入 SE block 。

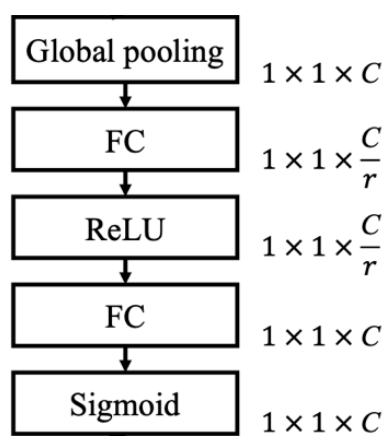


圖 2-19 圖為 Squeeze-and-Excitation block [27]



## 2.6.5 ResNeXt block

ResNeXt block 為 2017 年所提出[29]，其為不同版本之殘差塊，類似 Inception module 的概念，將輸入分為不同之通道，於最後做相加，如圖 2-20，可以取得不同之特徵，再透過學習調整不同通道之權重。




圖 2-20 圖為 ResNeXt block [29]

# 第 3 章 研究設計與方法



本章詳細介紹本論文之研究設計與方法。首先介紹研究流程，接下來詳細說明流程中之步驟，以展示研究方法，包含資料集處理及所提出之卷積神經網路架構，並將此神經網路架構命名為 Rat-Unet。

## 3.1 研究流程

本研究可分為兩大部分，卷積神經網路模型訓練及老鼠腦部 MR 影像中缺血型中風區域分割。如圖 3-1，以下對流程進行更詳細之說明。

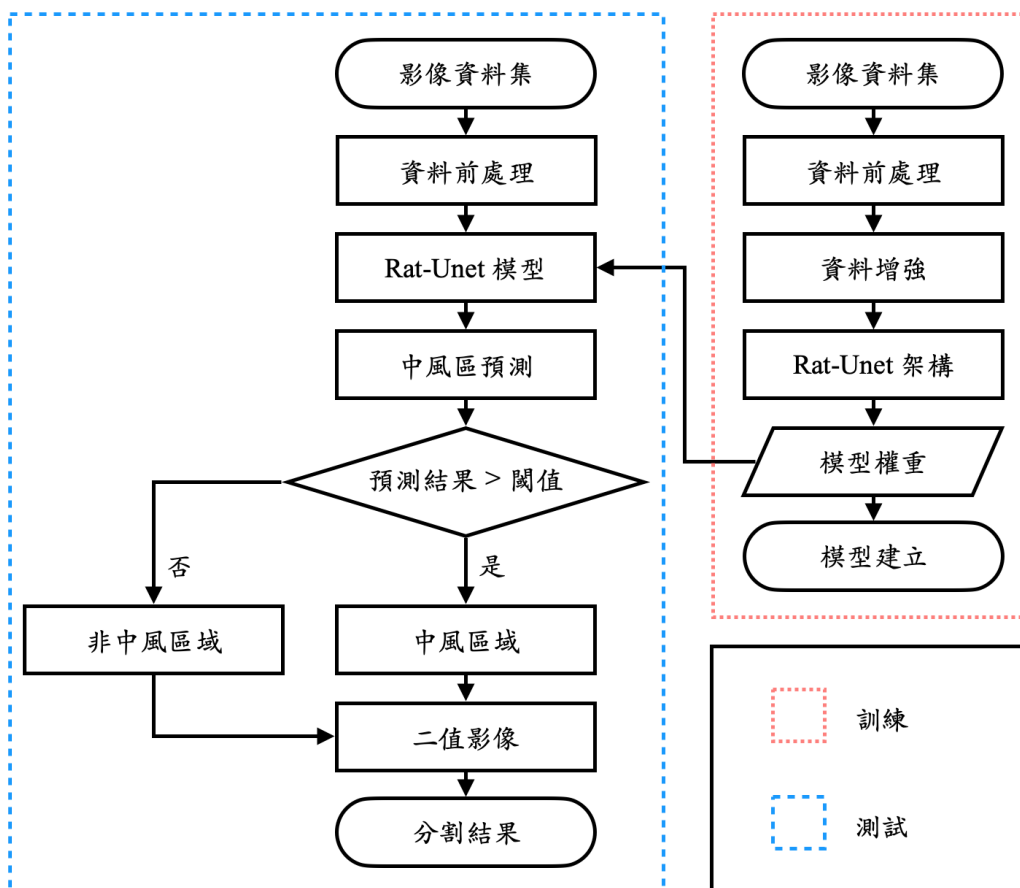


圖 3-1 研究流程



### 3.2 資料前處理

在資料前處理，會對資料集使用標準分數正規化 ( Standard Score Normalization ) [30]的運算以使資料集符合標準常態分佈。儘量避免神經網路受到範圍較大卻不重要的特徵影響，以較快並且貼近最佳解的方向進行權重調整。

進行標準分數正規化，先計算所有欲輸入模型之影像資料集中所有像素值的平均值  $X_{mean}$  與標準差  $X_{std}$  後，再對所有像素值分別減去  $X_{mean}$  後再除  $X_{std}$  。經過標準分數正規化的資料集，平均數為 0 ，並且標準差為 1 ，公式如下：

$$z = \frac{x - X_{mean}}{X_{std}} \quad (15)$$

### 3.3 資料增強

本研究用於訓練之資料集影像數量，T2 有 588 張及 DWI 有 504 張，在第 4 章會進一步說明資料集。而這樣的資料數量對於深度學習之模型訓練來說是相對少的。若單純以這些資料給予神經網路進行訓練，訓練出來的權重，可能會對於訓練資料集有非常優異表現，但對於訓練資料集外的資料集會發生失準，這種過度擬和於訓練資料集的情況稱做過擬合 ( Overfitting ) 。而我們所期望的權重，應該要符合資料集整體的走向，如圖 3-2。




圖 3-2 過擬合示意圖

圖左為期望函式，圖右為過擬合

在面對資料規模較小的情況，研究及實驗指出[7, 17, 18]，適當地以原資料透過轉換以擴充資料集，能有效地提升深度學習之模型在未知資料的判斷準確度，減低過度擬和的現象。

本研究將資料集影像數量擴充至 6 倍。並對資料進行以下四種轉換。

1. 影像旋轉：隨機旋轉整影像  $\pm 30$  度。
2. 水平翻轉：隨機沿著水平方向翻轉影像。
3. 推移變換：隨機推移比例 0.3 。
4. 縮放變換：隨機調整影像大小至原圖之 80% 至 120% 。

樣本增強結果顯示如圖 3-3。




圖 3-3 資料集影像擴充



### 3.4 卷積神經網路架構

本研究之卷積神經網路架構 Rat-Unet，為編碼-解碼模型 (Encoder-Decoder Model) 之全卷積網路 (FCN)，於解碼步驟時結合相對應之編碼層，以得到影像分割之預測結果。

Rat-Unet，是以 U 型網路為基礎。包含 5 個最大值池化層與 5 個上採樣層。以最大值池化層進行編碼，再以上採樣層解碼還原至原大小，並將輸出與對應之編碼層進行合併。

本研究中於編碼步驟，以殘差塊 (Residual block) [20]加深網路深度，於第一及第二最大值池化層之前，各加入兩個卷積層。而於第三至第五最大值池化層之前，加入本研究所提出之混合殘差塊，通過兩個不同結構之殘差塊取得不同尺度之特徵地圖，並進行合併。最後，使用 Sigmoid 函數將特徵地圖輸出值壓縮至 0 至 1 中，作為像素分類問題中為分割目標的機率，架構如圖 3-6。

#### 3.4.1 殘差塊

在殘差學習中，除了基本的殘差塊 (Basic block)，研究中[20]提出了殘差瓶頸塊 (Bottleneck block) 減少了計算量，並在 2016 年將兩種殘差塊加以改良 [31]，本研究使用改良後之殘差瓶頸塊及 2019 年提出之 Res2Net 單元 (Res2Net block) [32]做為神經網路之部分，上述殘差塊如圖 3-4。

Res2Net 單元，是取材殘差瓶頸塊，將第二層  $3 \times 3$  的卷積層以卷積組 (Group convolution) 取代，可以讓神經網路觀察不同尺度的訊息，使神經網路能在多個尺度中進行學習。



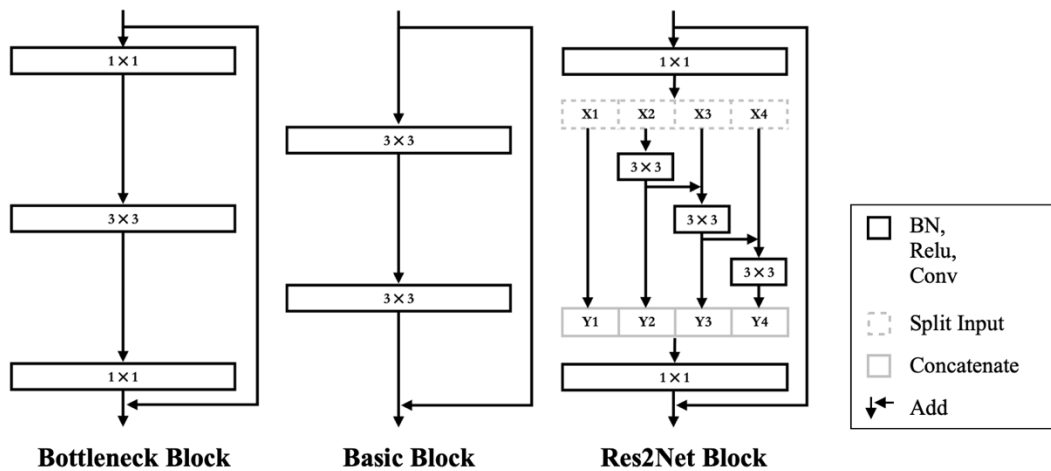


圖 3-4 不同結構之殘差塊[32]

圖中 BN 為 Batch Normalization

### 3.4.2 混合殘差塊

本研究提出混和殘差塊 (Mix Block)，結合 Res2Net 單元與殘差瓶頸塊，並將輸出合併後加入卷積層及殘差捷徑，結構如圖 3-5。

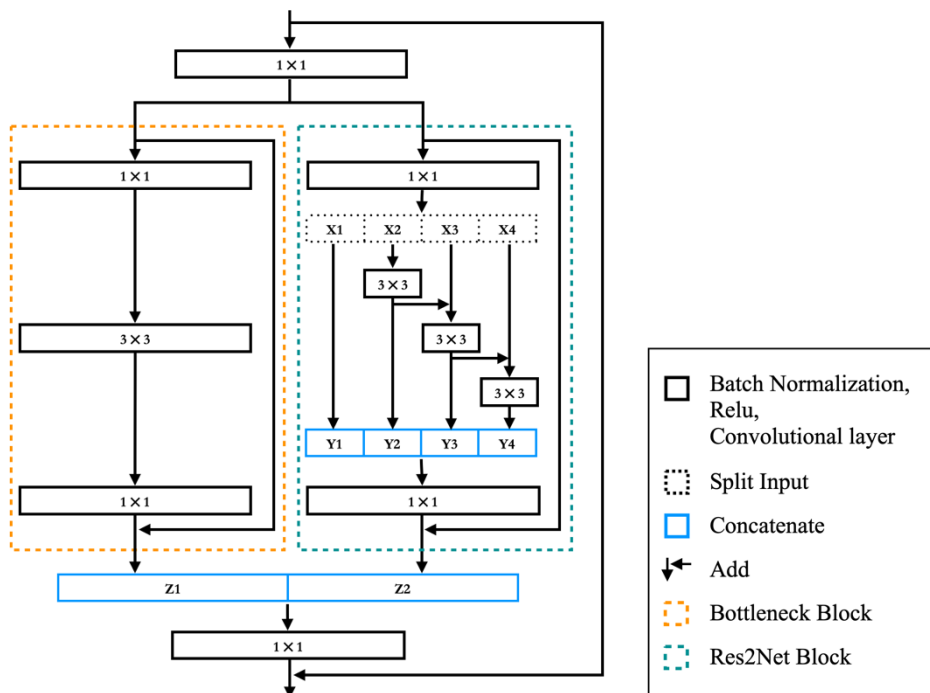


圖 3-5 混和殘差塊

以 Res2Net 單元結合殘差瓶頸塊，能保留 Res2Net 單元所取得之多尺度信息，並同時加入殘差瓶頸塊以單層卷積層處理所獲取信息，再透過網路學習並使用感興趣之特徵，使神經網路能在保有原視野下再從不同尺度之特徵中進行選擇。

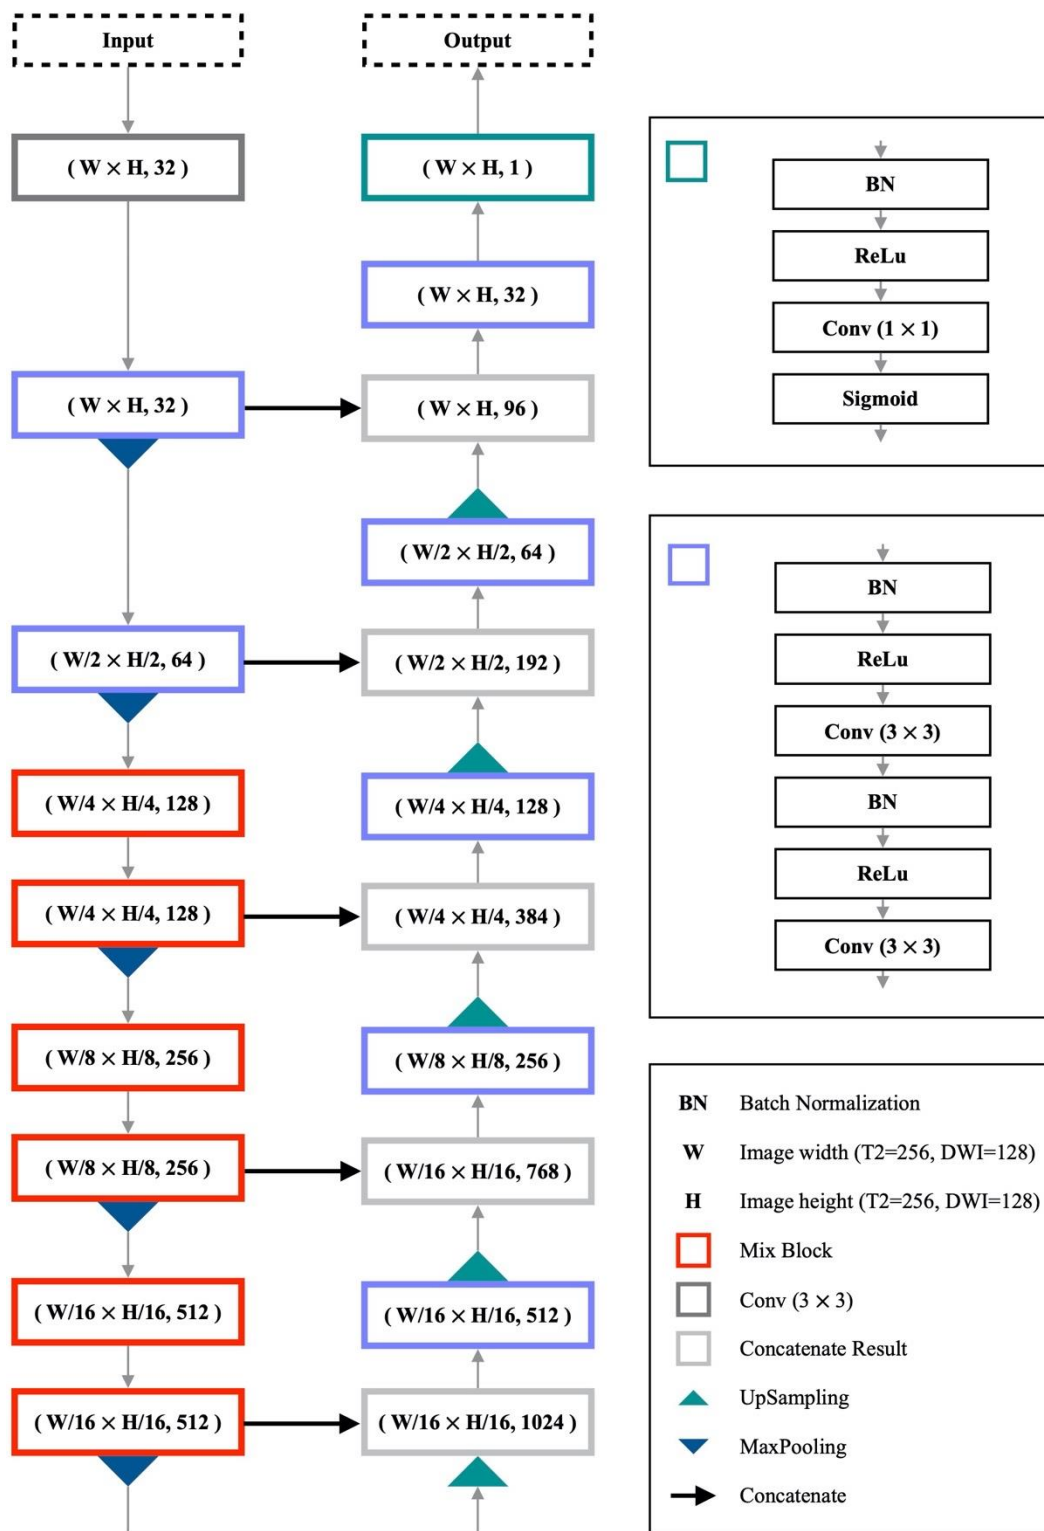


圖 3-6 本研究之 Rat-UNet 網路架構



### 3.4.3 卷積層架構

在 Rat-Unet 中大部分卷積層前，會加入批量標準化後再使用整流線性單位函數，最後才為卷積層。如此順序是經由實驗後發現如此搭配在訓練上能有比較好的表現，如圖 3-7。




圖 3-7 卷積層架構

### 3.4.4 卷積核初始化

神經網路透過權重進行運算，再透過學習來更新權重，而在開始時需要給定權重之初始化值。給定方式目前常見為 Xavier 初始化[33]，此初始化方式使輸入與輸出之標準差保持相似，適合在使用 Sigmoid 及 tanh 函數為激勵函數時保持梯度穩定。而本研究使用整流線性單位函數，在輸入小於 0 時會設置為 0，因此約有一半值消失，並不適合使用 Xavier 初始化，而研究指出[34]，簡單的改良 Xavier 初始化，將其變異數調整為 Xavier 初始化之變異數約兩倍，並於截斷常態分布中取值，此初始化後之權重，於使用整流線性單位函數之網路中也能保持梯度穩定。因此本研究使用上述 Xavier 初始化改良後之版本。

### 3.4.5 其他網路架構

實驗中也有建構 Rat-Unet 以外之神經網路架構，但其結果不如 Rat-Unet。於第四章實驗結果比較中，稱之為 Proposed 2，詳如附錄。

## 第 4 章 實驗結果



本章節說明研究中所使用之資料集及實驗環境，並說明 Rat-Unet 網路架構所訓練之模型設定，及其對於老鼠腦部 MR 影像缺血型中風區域之分割結果。

### 4.1 老鼠腦部 MR 影像資料集

提供本論文使用之老鼠腦部 MR 影像資料集，來自臺大醫院神經科葉馨喬醫師所提供之 T2 及 DWI 鼠腦影像，並使用葉醫師所分割之真實腦部影像進行分析。本研究將 T2 及 DWI 資料集分別分為訓練資料及測試資料。訓練資料用於訓練卷積神經網路模型，而測試資料用於檢視與評估模型結果。資料及詳細情形如表 4-1。

表 4-1 資料集

	T2	DWI
老鼠數量	65	57
腦部影像切片	15	15
影像總數	975	855
影像大小	256 × 256	128 × 128
訓練資料老鼠數量	49	42
訓練資料影像總數	588×6	504×6
驗證資料影像總數	147	126
測試資料老鼠數量	16	15
測試資料影像總數	240	225
訓練-驗證-測試資料比例	3528:147:240	3024:126:225



## 4.2 神經網路訓練模型

以下說明本研究之神經網路模型訓練之參數設置及實驗環境。

### 4.2.1 實驗環境

本研究之實驗電腦環境如表 4-2。並使用 Python3.5.7 [35]作為開發之程式語言，套件使用 Keras 2.2.4 [36]並搭配 tensorflow-gpu 1.15.2 [37]。

表 4-2 電腦環境

CPU	Intel(R) Xeon(R) CPU E5-2620 v3 @ 2.40GHz × 4
GPU	NVIDIA Tesla K40c
RAM	Samsung DDR4 ECC REG 2133 8G × 2, 4G × 2
作業系統	Ubuntu 18.04.3 LTS

### 4.2.2 神經網路訓練參數

在 T2 及 DWI 分割任務的模型訓練中，皆設置了 200 次的訓練週期 (Epoch) 與 8 的批次大小 (Batch size)，以戴斯係數 (Dice coefficient) [38]與 1 之差距作為損失函數。並將訓練資料集中 20 % 作為為驗證資料 (Validation data)，如表 4-1，訓練過程中只將在驗證資料上準確度最高的模型儲存，並在驗證資料上的準確度連續 15 個週期沒有提升的情況下停止訓練，如表 4-3。學習率調整上，在前面週期設置較大學習率，加速神經網路的學習，後期使用較小學習率，使網路學習較為平穩並接近最佳結果，使用 Keras 之 ReduceLROnPlateau 函式做調整，如表 4-4。而自適應矩估計優化器[12]的參數設置則如表 4-5。於測試資料分割時，以預測結果大於固定閾值時判斷為中風區域，實驗時過程中以 0.002 至 0.6 之閾值範圍進行測試，並以 0.5 為基準。

表 4-3 訓練參數

<b>Epoch</b>	200
<b>Batch size</b>	8
<b>Validation split</b>	20%
<b>Early stop patience</b>	15



表 4-4 學習率調整 ReduceLRonPlateau 參數

<b>Init learning rate</b>	1e-03
<b>monitor</b>	val_loss
<b>factor</b>	0.5
<b>patience</b>	10
<b>Min learning rate</b>	1e-04

表 4-5 自適應矩估計優化器參數

<b><math>\beta_1</math></b>	0.9
<b><math>\beta_2</math></b>	0.999
<b><math>\epsilon</math></b>	1e-07

### 4.3 實驗結果評估標準

將模型訓練後，便可將模型運用於影像中缺血型中風區域之分割，而在評估分割的結果與醫生所提供之正確區域的差距，本研究以五種指標作為評斷標準，分別為一致度 ( Conformity,  $\kappa_c$  )、 敏感度 ( Sensitivity,  $\kappa_{st}$  )、 識別度 ( Sensibility,  $\kappa_{sb}$  ) [39]、 戴斯係數 ( Dice coefficient,  $\kappa_D$  ) [38]，及雅卡爾指數 ( Jaccard similarity coefficient,  $\kappa_J$  ) [40]，接下來將說明以上指標。




圖 4-1 結果評估示意圖

如圖 4-1，X 圓區域視為本研究之模型所分割出來之預測區域，Y 圓區域則視為醫師所提供之正確區域。以此示意圖，可以將兩者所估區域進行分類，如表 4-6。

表 4-6 區域分類

符號	TP	FP	FN
意義	$X \cap Y$	$X \cap \sim Y$	$\sim X \cap Y$
區域	B	A	C

TP 代表預測區域與正確區域相同之區域，FP 代表所預測之區域不在正確區域中，而 FN 代表正確區域中沒有被預測之區域。將結果分類為上述區域，便可進行評斷標準之五項指標計算。

### 4.3.1 一致度

一致度 (Conformity,  $\kappa_c$ ) 可以評估預測正確中預測錯誤的比例關係，可以了解預測結果與正確結果之差異性，公式如下：

$$\kappa_c = 1 - \frac{FP + FN}{TP} \times 100\% \quad (16)$$



### 4.3.2 敏感度

敏感度 (Sensitivity,  $\kappa_{st}$ ) 評估正確結果中預測正確的比例，能夠了解預測正確的情形，公式如下：

$$\kappa_{st} = \frac{TP}{TP + FN} \times 100\% \quad (17)$$

### 4.3.3 識別度

識別度 (Sensibility,  $\kappa_{sb}$ ) 則是評估正確結果中將錯誤預測為正確的比例，能夠了解預測中誤判的情形，公式如下：

$$\kappa_{sb} = 1 - \frac{FP}{TP + FN} \times 100\% \quad (18)$$

### 4.3.4 戴斯係數

戴斯係數 (Dice,  $\kappa_D$ ) 是廣泛使用的評估指標，能夠評估預測正確的比例，並給予預測正確較高權重，可以了解當中與正確結果的誤差，也是本研究中所重視的指標，公式如下：

$$\kappa_D = \frac{2 \times TP}{2 \times TP + FN + FP} \times 100\% \quad (19)$$

### 4.3.5 雅卡爾指數

雅卡爾指數 (Jaccard,  $\kappa_J$ ) 與戴斯係數 (Dice) 類似，不同之處在於預測正確部分並未給予權重，公式如下：

$$\kappa_J = \frac{TP}{TP + FN + FP} \times 100\% \quad (20)$$



## 4.4 T2 影像實驗結果


本節展示 Rat-Unet 模型在 T2 影像中對於測試資料之分割結果，並與其他方法進行比較及分析。



### 4.4.1 神經網路模型預測結果

表 4-7 及表 4-8 為測試之 T2 資料集中，各老鼠的中風區域分割預測結果與正確結果比較。並附上編號 141 及 142 之結果圖，結果圖包括預測結果、正確結果及合併結果，同時附上在三維空間之分割結果，三維空間結果展示預測結果與正確結果在三維空間中正面、側面及背面之不同視角圖像以供檢視與比較，如圖 4-4 至圖 4-11。檢視上述結果圖，可以發現在這兩組資料集中，本研究之模型多數能判斷正確之位置及輪廓，可以觀察預測之結果與正確結果是接近的。

表 4-7 測試之 T2 影像分割結果



編號	$\kappa_c(\%)$	$\kappa_{st}(\%)$	$\kappa_{sb}(\%)$	$\kappa_D(\%)$	$\kappa_J(\%)$
118	74.53	82.79	96.12	88.70	79.70
141	74.81	82.34	96.91	88.81	79.88
142	74.76	83.10	95.92	88.79	79.85
146	85.01	92.89	93.18	93.03	86.96
149	67.16	77.41	97.17	85.89	75.28
154	67.96	82.45	91.13	86.19	75.73
159	74.61	86.02	92.14	88.74	79.75
267	80.01	86.84	95.80	90.91	83.34
268	74.95	82.92	96.31	88.87	79.97
275	63.74	77.38	94.57	84.65	73.39
280	58.77	76.29	92.26	82.91	70.81
284	67.18	83.65	88.90	85.90	75.29
286	33.03	61.99	96.50	74.91	59.89
295	64.51	82.90	87.68	84.93	73.81
304	83.15	86.48	98.95	92.23	85.58
307	61.78	76.00	94.95	83.96	72.35




圖 4-2 測試之 T2 影像分割結果柱狀圖

表 4-8 測試之 T2 影像分割結果分析

表中誤差比例計算為誤差除以正確像素



編號	預測像素	正確像素	誤差	誤差比例 (%)
118	46400	40218	6182	13.32
141	45443	38823	6620	14.57
142	57197	49863	7334	12.82
146	34164	34065	99	0.29
149	56852	45616	11236	19.76
154	32371	29559	2812	8.69
159	40721	38230	2491	6.12
267	32293	29400	2893	8.96
268	25825	22365	3460	13.40
275	35104	29068	6036	17.19
280	26769	22495	4274	15.97
284	16254	15402	852	5.24
286	3512	2300	1212	34.51
295	17780	16929	851	4.79
304	40054	35060	4994	12.47
307	2871	2327	544	18.95
平均				12.94±7.94




圖 4-3 測試之 T2 影像分割結果誤差比例柱狀圖





圖 4-4 測試之 T2 資料集編號 141 之中風區域預測區域

圖中數字為切片編號








圖 4-5 測試之 T2 資料集編號 141 之中風區域正確區域


圖中數字為切片編號




1 ( $K_D=N/A\%$ )




2 ( $K_D=76.19\%$ )




3 ( $K_D=88.38\%$ )




4 ( $K_D=92.14\%$ )




5 ( $K_D=94.19\%$ )




6 ( $K_D=84.68\%$ )




7 ( $K_D=89.55\%$ )




8 ( $K_D=87.24\%$ )




9 ( $K_D=94.94\%$ )




10 ( $K_D=88.52\%$ )




11 ( $K_D=91.73\%$ )




12 ( $K_D=86.20\%$ )



13 ( $K_D=75.94\%$ )



14 ( $K_D=92.36\%$ )



15 ( $K_D=91.32\%$ )

圖 4-6 測試之 T2 資料集編號 141 之中風區域正確與預測區域  
圖中數字為切片編號，藍色區域為預測區域，紅色區域為正確區域

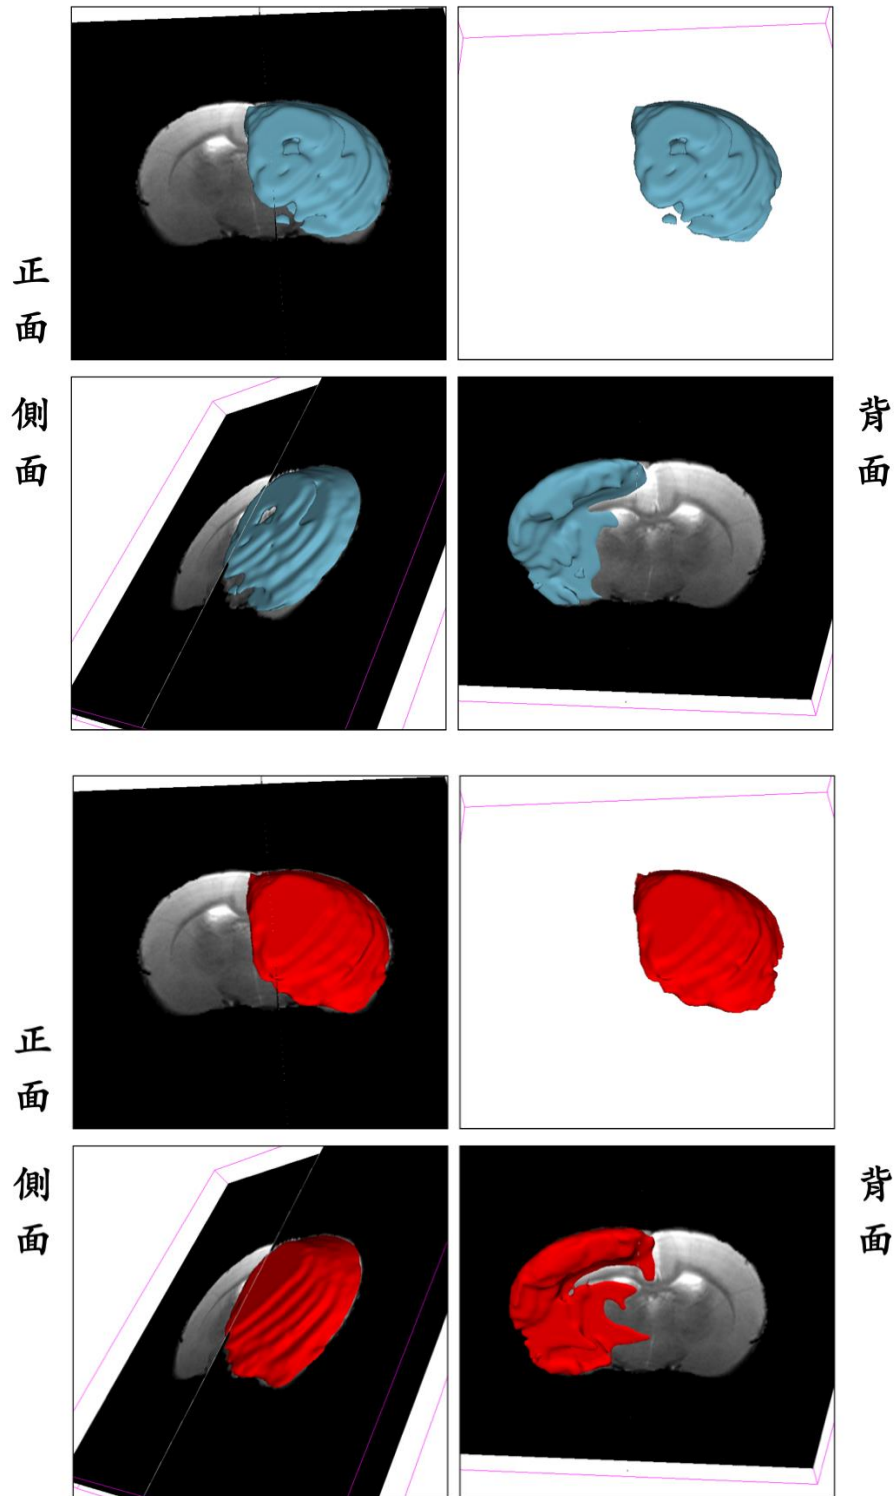


圖 4-7 測試之 T2 資料集編號 141 之中風區域三維正確與預測區域

上方藍色區域為預測區域，下方紅色區域為正確區域

(圖中三維空間結果為原結果加厚兩倍以利檢視)




圖 4-8 測試之 T2 資料集編號 142 之中風區域預測區域

圖中數字為切片編號







圖 4-9 測試之 T2 資料集編號 142 之中風區域正確區域

圖中數字為切片編號





圖 4-10 測試之 T2 資料集編號 142 之中風區域正確與預測區域  
圖中數字為切片編號，藍色區域為預測區域，紅色區域為正確區域




圖 4-11 測試之 T2 資料集編號 142 之中風區域三維正確與預測區域

上方藍色區域為預測區域，下方紅色區域為正確區域

(圖中三維空間結果為原結果加厚兩倍以利檢視)

除了上述編號 141 及 142 之外，有一些資料在預測上有失準的情形，如圖 4-12，在預測上有判斷出大略位置，但是在輪廓上與正確結果有較大的落差。由圖中可以觀察到某些區域是看似比較不明顯的。

在中風區域之正確分割上，是會參考前後之中風情形，而本模型是以二維資料為輸入，會將資料視為各別之輸入，並不會考慮前後張之關係。




圖 4-12 測試之 T2 資料集中風區域預測誤差較大圖例

圖中數字為資料編號及切片編號，藍色區域為預測區域，紅色區域為正確區域

#### 4.4.2 其他方法比較

實驗以測試資料集作為比較標準，並以戴斯係數 (Dice) 及雅卡爾指數 (Jaccard) 為主要觀察指標。並附上其他方法於編號 118、141 及 142 之預測結果之三維空間圖及其中切片之比較圖，如圖 4-13 至圖 4-18。結果顯示本研究提出之 Rat-UNet 在其他方法中有優異的表現，如表 4-9，在其他指標中也有穩定及良好的預測結果。

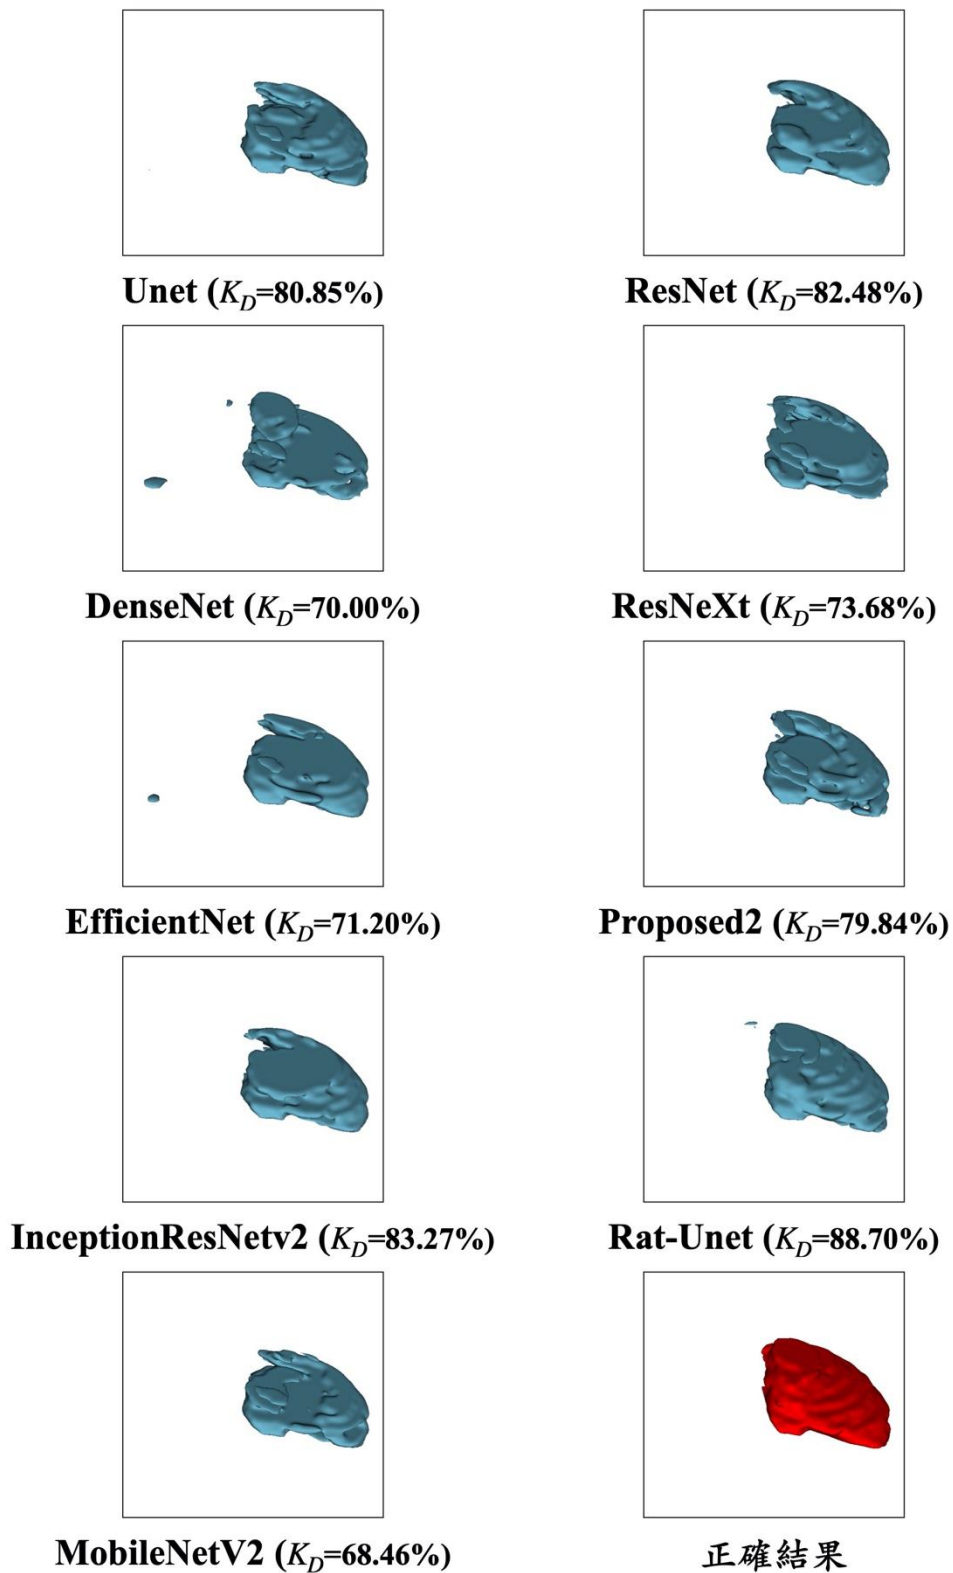


圖 4-13 測試之 T2 資料集編號 118 之中風區域其他方法預測

(圖中三維空間結果為原結果加厚兩倍以利檢視)




圖 4-14 測試之 T2 資料集編號 118 之切片 10 中風區域其他方法預測

圖中藍色區域為預測區域，紅色區域為正確區域

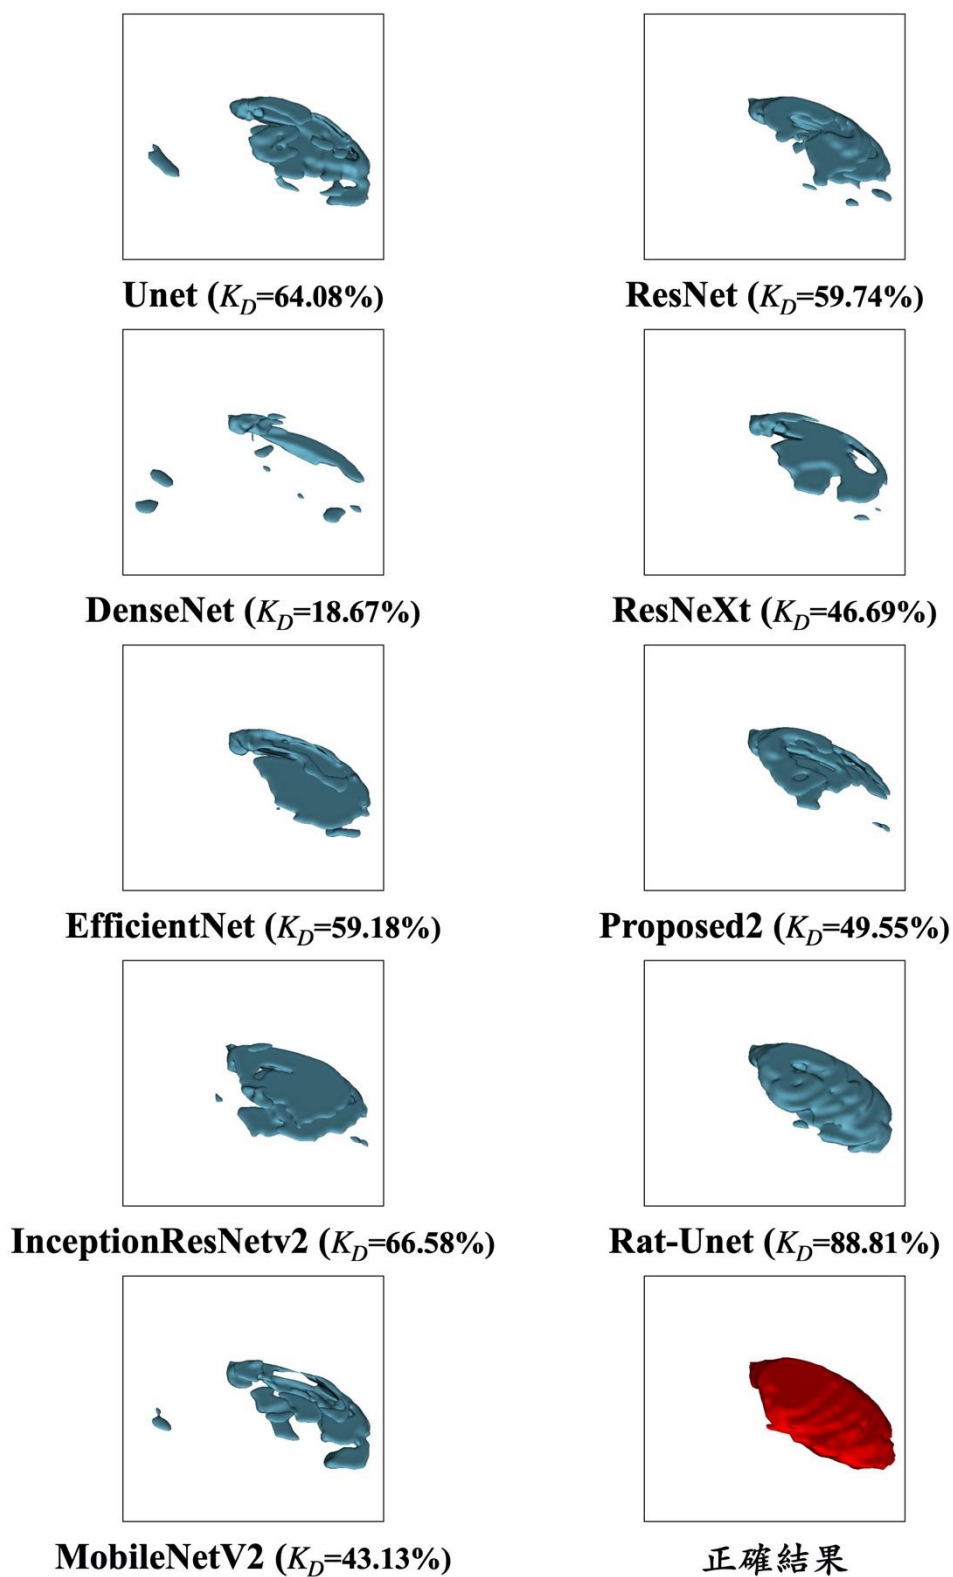


圖 4-15 測試之 T2 資料集編號 141 之中風區域其他方法預測

(圖中三維空間結果為原結果加厚兩倍以利檢視)

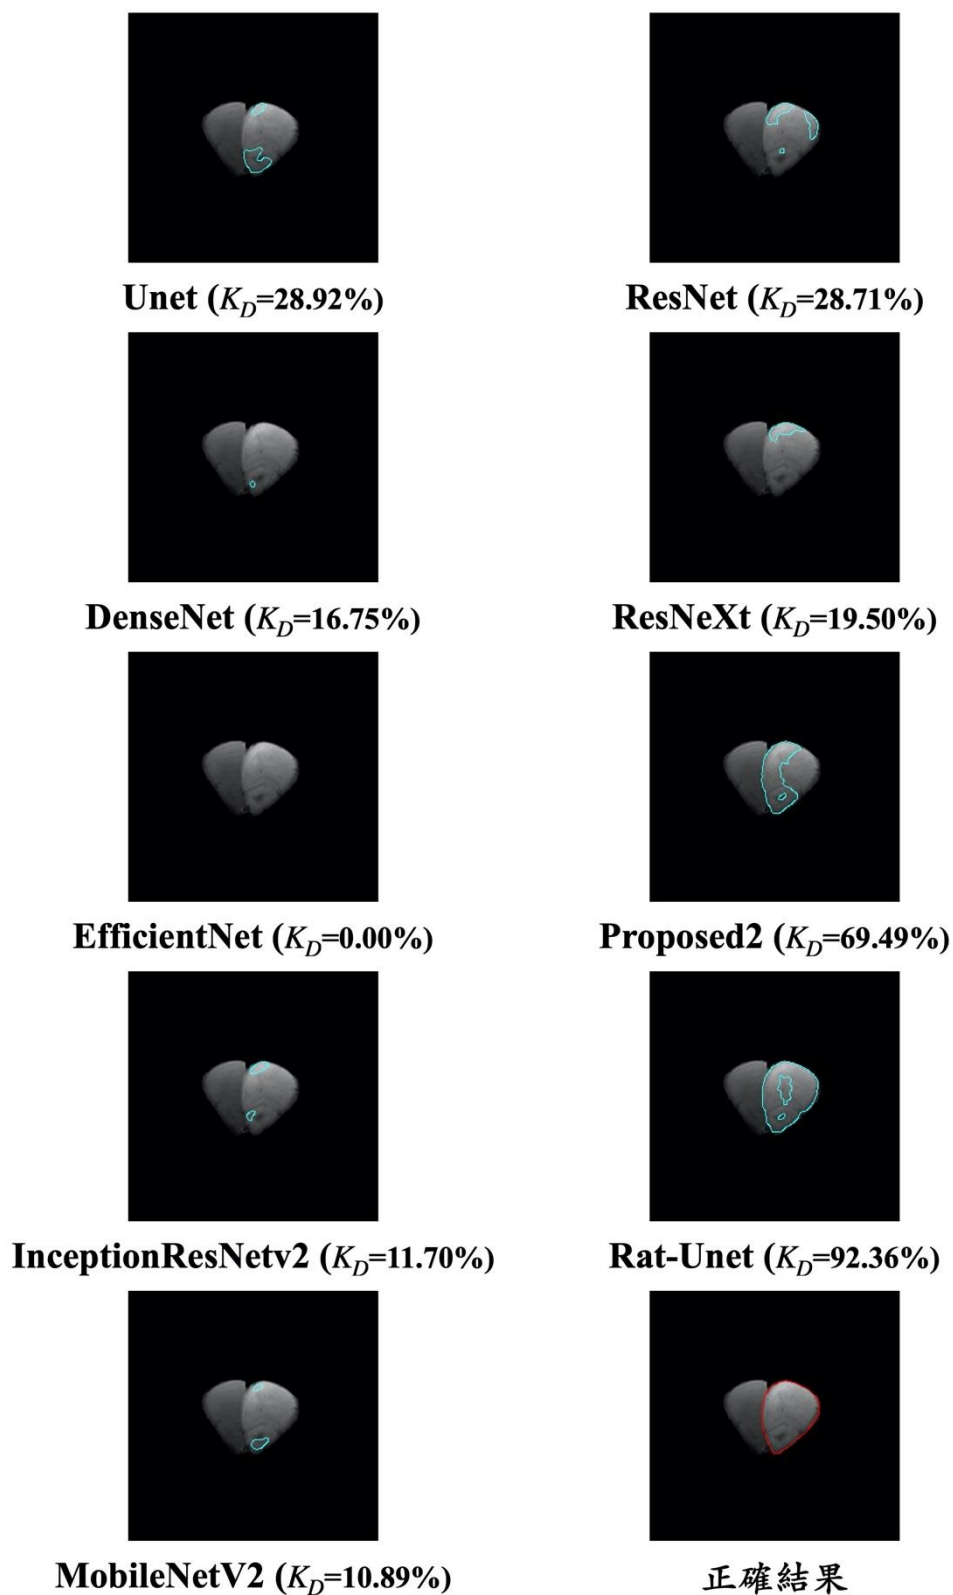


圖 4-16 測試之 T2 資料集編號 141 之切片 14 中風區域其他方法預測

圖中藍色區域為預測區域，紅色區域為正確區域



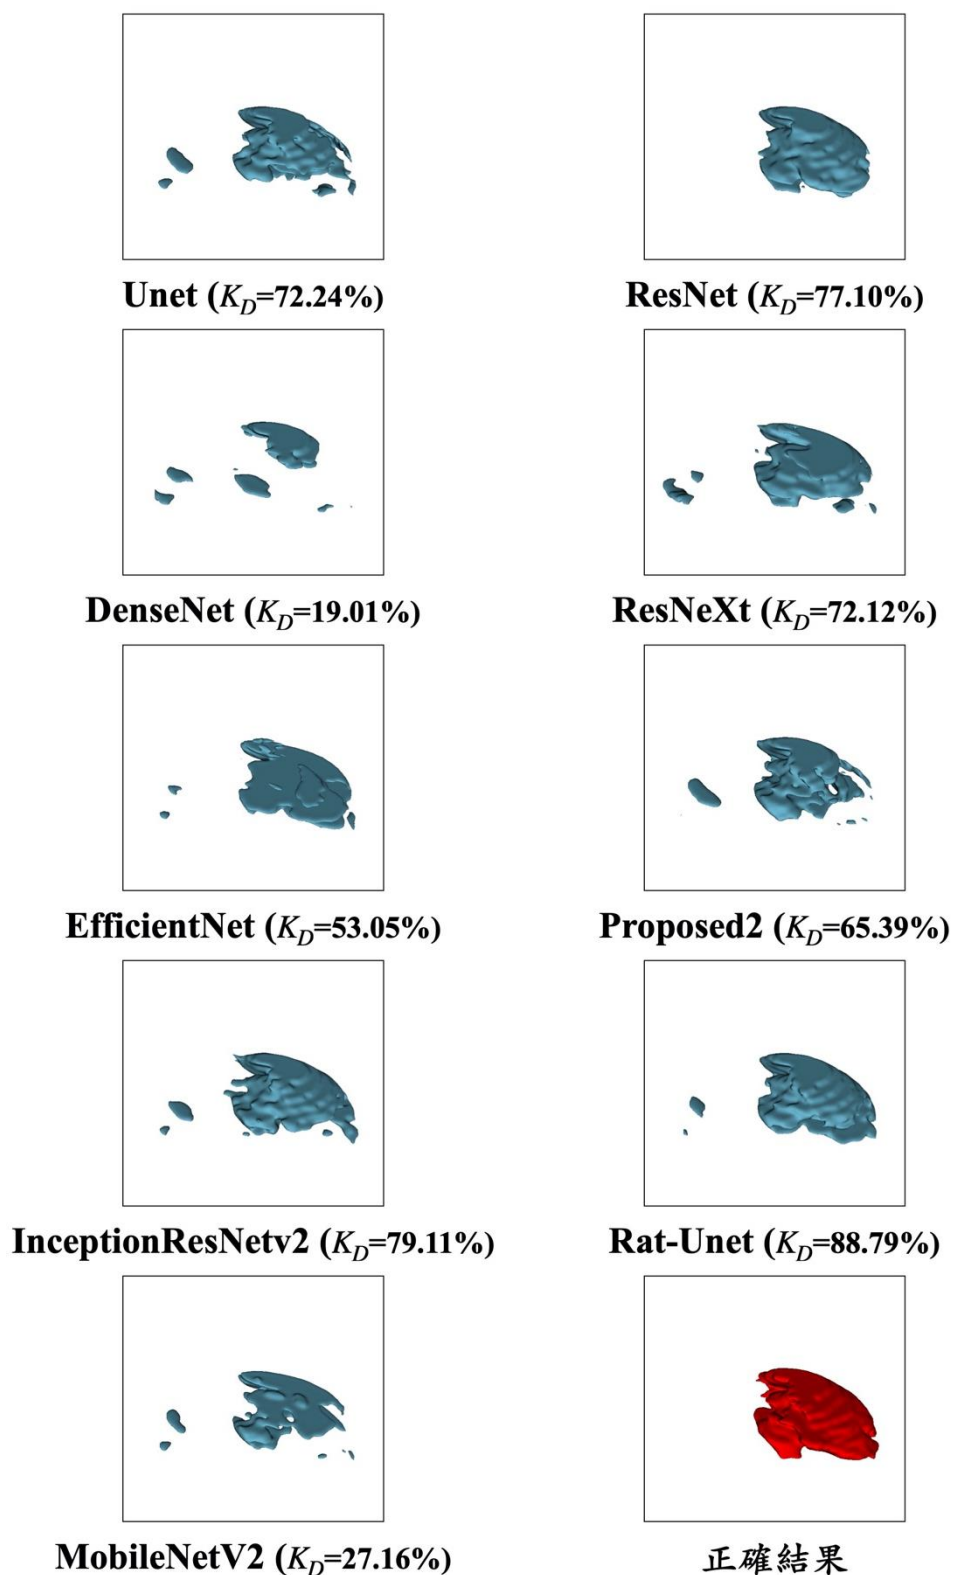


圖 4-17 測試之 T2 資料集編號 142 之中風區域其他方法預測

(圖中三維空間結果為原結果加厚兩倍以利檢視)

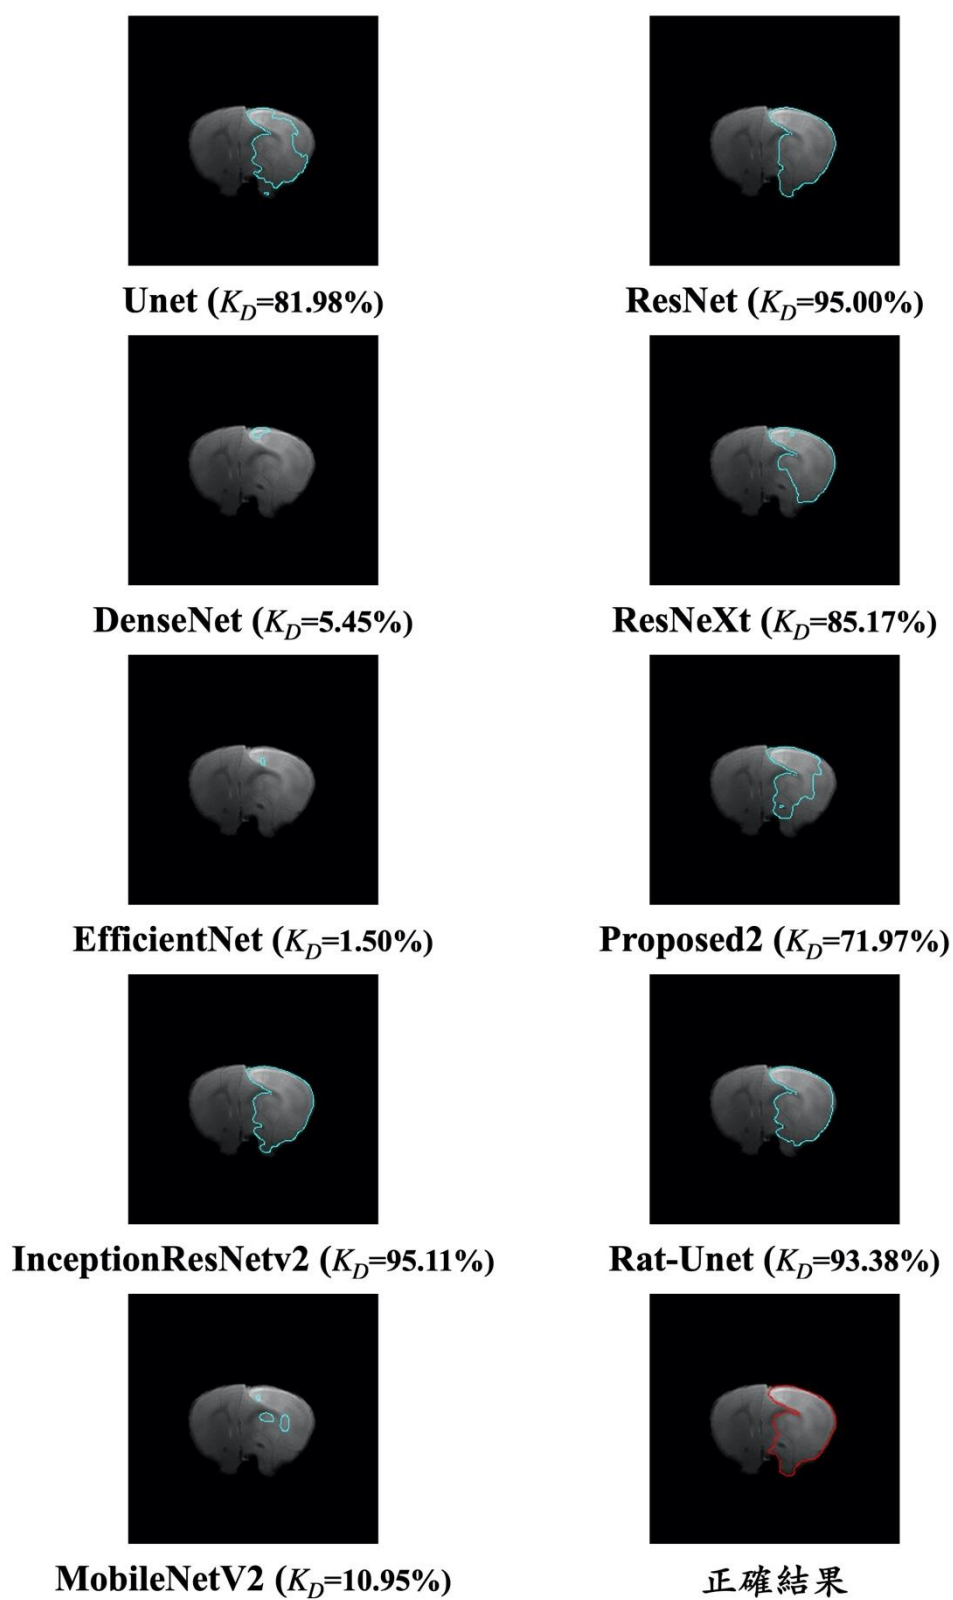


圖 4-18 測試之 T2 資料集編號 142 之切片 12 中風區域其他方法預測

圖中藍色區域為預測區域，紅色區域為正確區域

表 4-9 測試之 T2 影像分割結果與其他方法比較

	$K_C(\%)$	$K_{st}(\%)$	$K_{sb}(\%)$	$K_D(\%)$	$K_J(\%)$
<b>Unet</b>	56.95±26.23	76.82±11.51	92.67±8.44	83.09±8.02	71.79±11.17
<b>DenseNet</b>	-66.63±288.11	66.32±27.73	93.17±4.23	72.47±25.24	61.51±25.36
<b>EfficientNet</b>	43.73±49.53	72.13±17.09	95.08±3.46	80.26±12.32	68.52±15.44
<b>InceptionResNetV2</b>	60.35±20.40	77.96±10.22	92.96±4.97	83.97±6.48	72.85±9.26
<b>MobileNetV2</b>	8.10±133.18	68.22±21.94	93.61±4.70	75.83±18.00	63.73±19.68
<b>ResNet</b>	54.84±28.85	76.39±12.56	92.33±5.56	82.47±8.13	70.87±10.90
<b>ResNeXt</b>	44.31±49.55	71.85±14.35	94.43±3.51	80.13±10.76	67.95±13.22
<b>Proposed2</b>	51.92±47.02	75.89±15.60	94.19±2.67	82.57±11.18	71.58±14.19
<b>Rat-Unet</b>	69.12±12.24	81.34±6.78	94.28±3.13	86.84±4.32	76.97±6.51

表 4-10 測試之 T2 影像模型訓練時間與其他方法比較

一訓練週期訓練時間 (秒)	
<b>Unet</b>	2227
<b>DenseNet</b>	598
<b>EfficientNet</b>	477
<b>InceptionResNetV2</b>	1107
<b>MobileNetV2</b>	381
<b>ResNet</b>	371
<b>ResNeXt</b>	1016
<b>Proposed2</b>	1400
<b>Rat-Unet</b>	1033

## 4.5 DWI 影像實驗結果


本節展示 Rat-Unet 模型在 DWI 影像中對於測試資料之分割結果，並與其他方法進行比較及分析。



### 4.5.1 神經網路模型預測結果

表 4-11 及表 4-12 為測試之 DWI 資料集中，各老鼠的中風區域分割預測結果與正確結果比較。並同樣附上編號 141 及 142 之結果圖，結果圖包括預測結果、正確結果及合併結果，亦附上在三維空間之分割結果，展示在三維空間中正面、側面及背面之不同視角圖像，如圖 4-21 至圖 4-28。由上述結果圖中可以發現本模型之預測亦與正確區域接近。

表 4-11 測試之 DWI 影像分割結果



編號	$\kappa_c(\%)$	$\kappa_{st}(\%)$	$\kappa_{sb}(\%)$	$\kappa_D(\%)$	$\kappa_J(\%)$
141	78.47	85.47	96.14	90.28	82.29
142	80.35	87.79	94.97	91.06	83.58
146	72.67	86.89	89.36	87.98	78.54
149	83.14	92.53	91.87	92.22	85.57
154	68.03	81.81	92.03	86.22	75.77
159	75.09	85.98	92.60	88.93	80.06
226	73.62	84.66	93.00	88.35	79.12
267	63.02	75.70	96.32	84.40	73.01
268	75.11	92.97	83.90	88.93	80.07
274	39.73	82.16	68.32	76.84	62.39
275	76.12	87.71	91.34	89.33	80.72
280	65.81	80.79	91.59	85.40	74.52
281	73.60	89.86	86.42	88.34	79.12
294	78.55	89.56	91.23	90.31	82.34
310	55.35	79.76	84.62	81.75	69.13




圖 4-19 測試之 DWI 影像分割結果柱狀圖

表 4-12 測試之 DWI 影像分割結果分析

表中誤差比例計算為誤差除以正確像素



編號	預測像素	正確像素	誤差	誤差比例 (%)
141	9866	8813	1053	10.67
142	11765	10920	845	7.18
146	7310	7130	180	2.46
149	11274	11349	75	0.67
154	8296	7448	848	10.22
159	10795	10081	714	6.61
226	8125	7448	677	8.33
267	10204	8100	2104	20.62
268	7322	7986	664	9.07
274	7007	7977	970	13.84
275	9027	8700	327	3.62
280	9155	8166	989	10.80
281	8162	8442	280	3.43
294	10344	10171	173	1.67
310	8544	8129	415	4.86
平均				7.60±5.27




圖 4-20 測試之 DWI 影像分割結果誤差比例柱狀圖





圖 4-21 測試之 DWI 資料集編號 141 之中風區域預測區域

圖中數字為切片編號





圖 4-22 測試之 DWI 資料集編號 141 之中風區域正確區域

圖中數字為切片編號



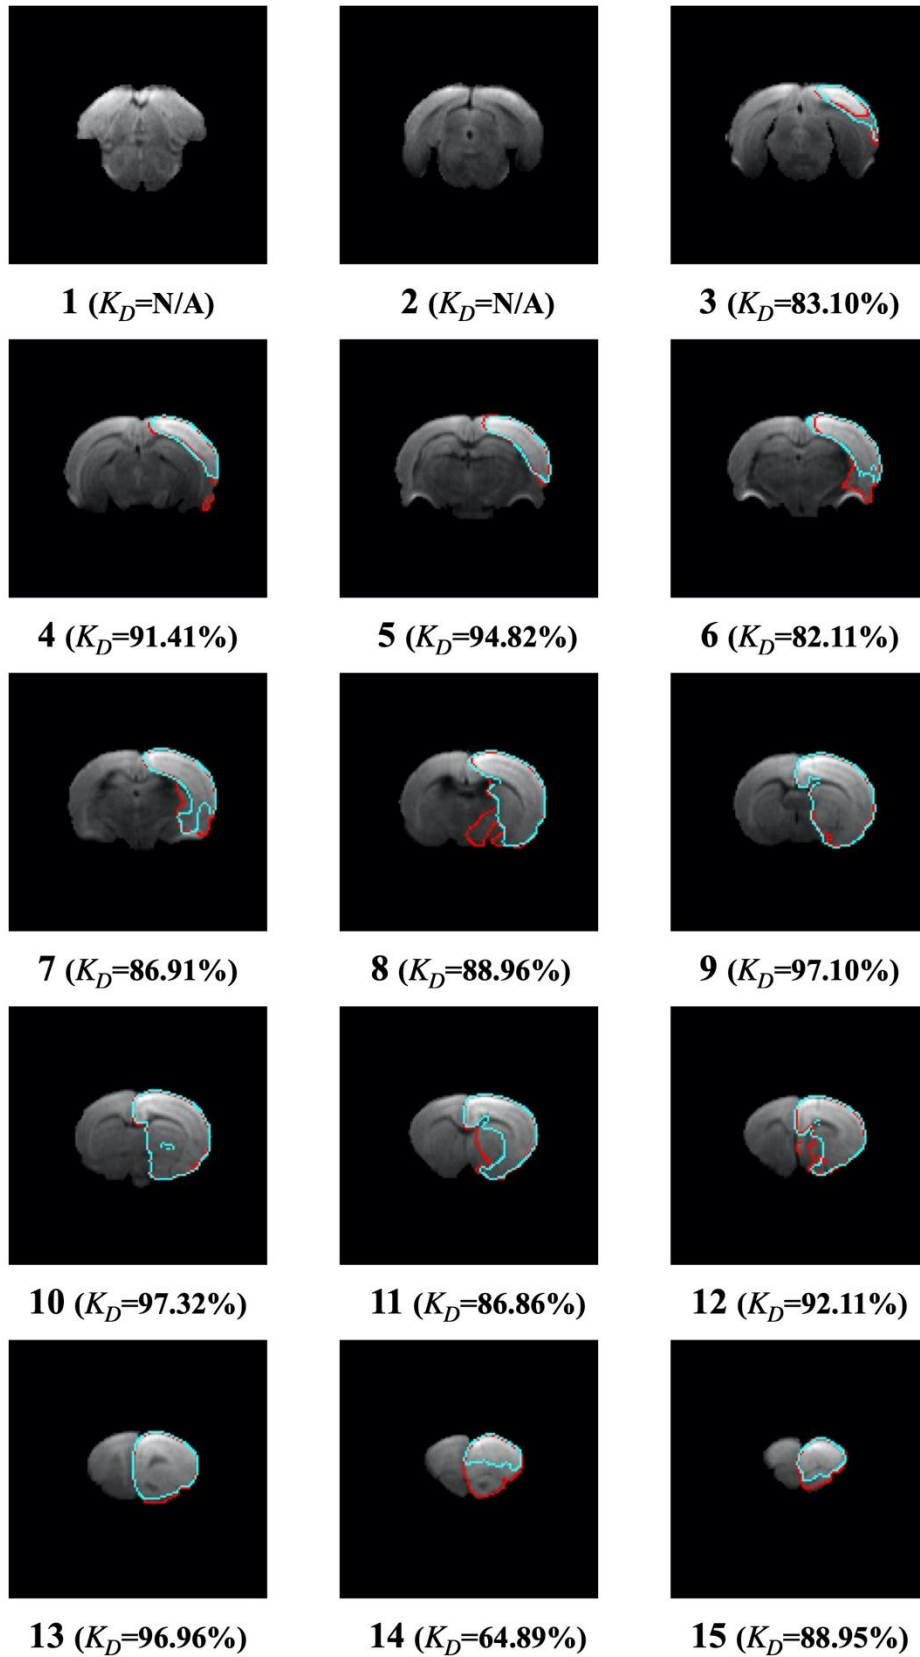



圖 4-23 測試之 DWI 資料集編號 141 之中風區域正確與預測區域  
圖中數字為切片編號，藍色區域為預測區域，紅色區域為正確區域

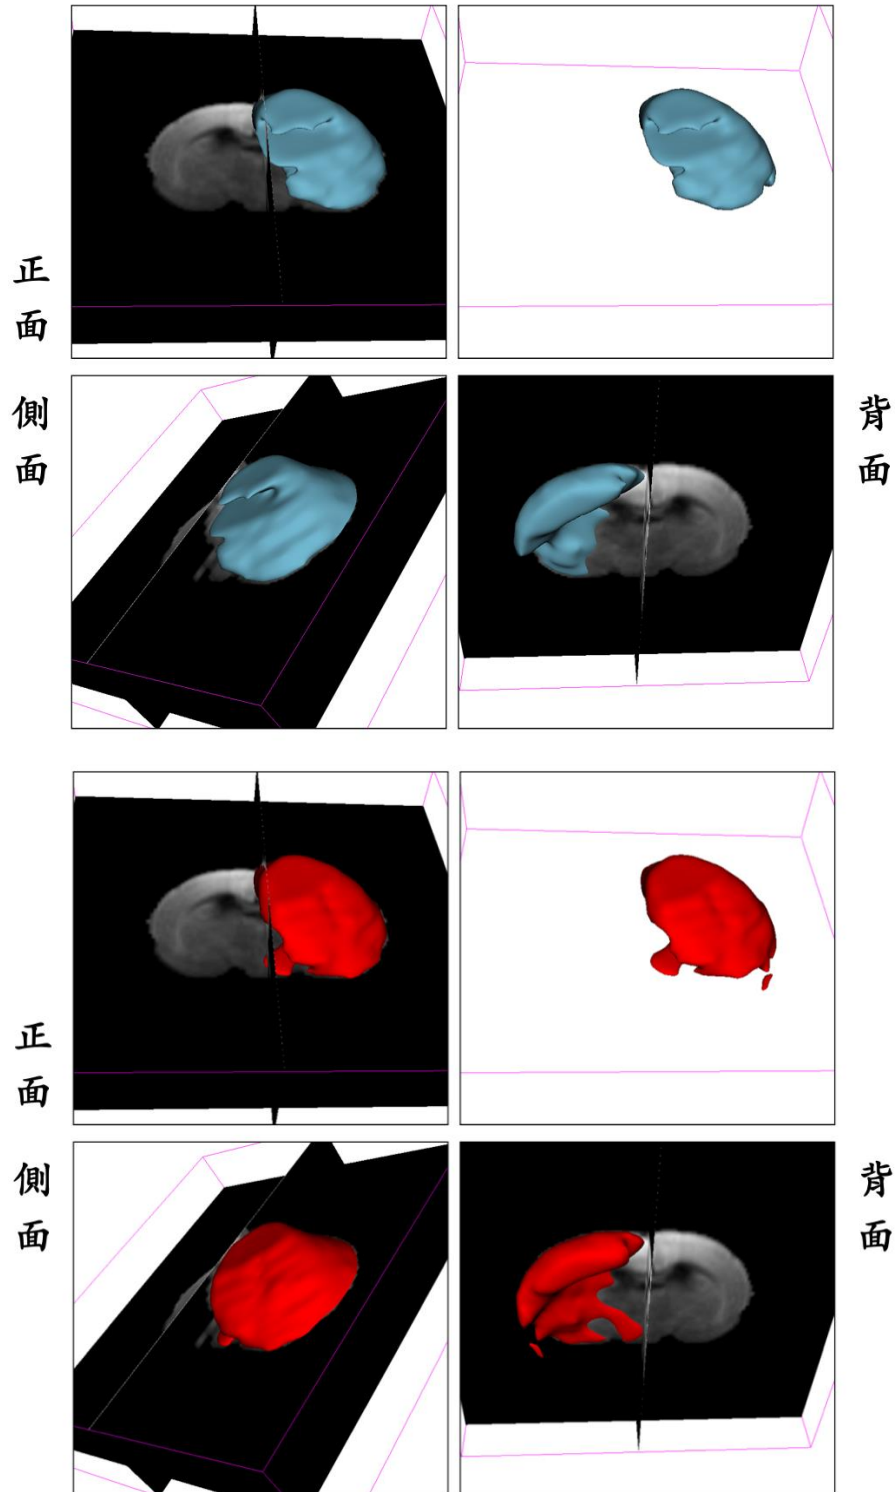


圖 4-24 測試之 DWI 資料集編號 141 之中風區域三維正確與預測區域

上方藍色區域為預測區域，下方紅色區域為正確區域

(圖中三維空間結果為原結果加厚兩倍以利檢視)





圖 4-25 測試之 DWI 資料集編號 142 之中風區域預測區域

圖中數字為切片編號





圖 4-26 測試之 DWI 資料集編號 142 之中風區域正確區域

圖中數字為切片編號





圖 4-27 測試之 DWI 資料集編號 142 之中風區域正確與預測區域  
圖中數字為切片編號，藍色區域為預測區域，紅色區域為正確區域

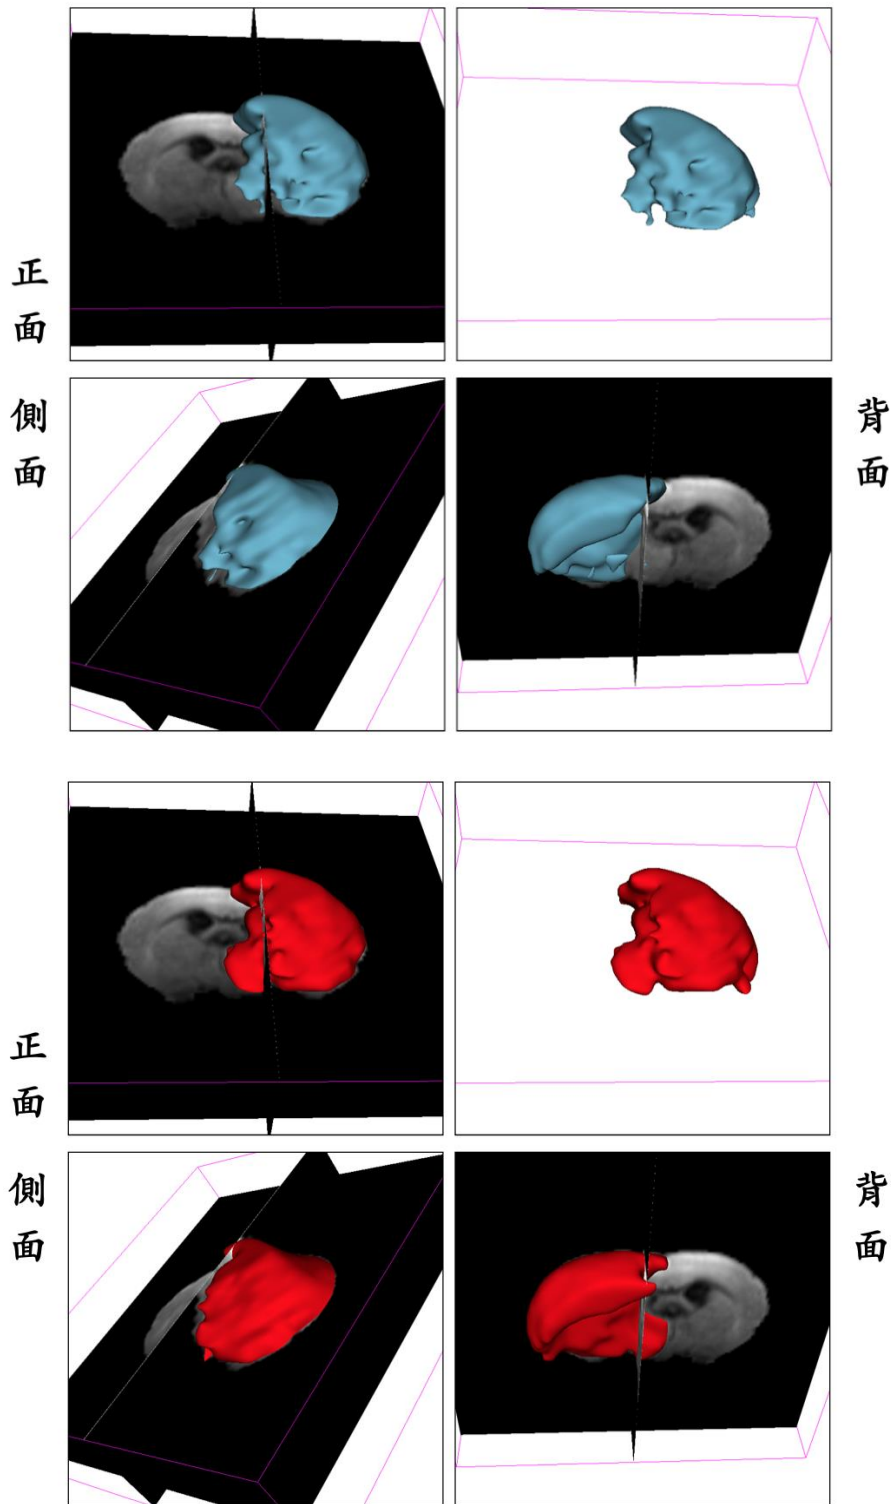


圖 4-28 測試之 DWI 資料集編號 142 之中風區域三維正確與預測區域

上方藍色區域為預測區域，下方紅色區域為正確區域

(圖中三維空間結果為原結果加厚兩倍以利檢視)

在 DWI 的預測中，與 T2 資料中相同，在某些資料上也有失誤的情形，如圖 4-29，在位置判斷上大略有判斷正確，但是在區域之範圍上是與正確區域有些差距，於圖中觀察，可以發現本模型之預測區域大致上是可以理解，但還是與專家所分割之正確區域有所不同。




圖 4-29 測試之 DWI 資料集中風區域預測誤差較大圖例

圖中數字為資料編號及切片編號，藍色區域為預測區域，紅色區域為正確區域

#### 4.5.2 其他方法比較

附上其他方法於編號 141、142 及 146 之預測結果之三維空間圖及其中切片之比較圖，如圖 4-30 至圖 4-35。結果顯示，本研究所提出之 Rat-Unet 模型在 DWI 影像分割，在其他方法之模型中表現出色並在各項指標上相對穩定，如表 4-13，且其他方法對於 T2 及 DWI 兩種影像表現上有落差，而 Rat-Unet 所學習之模型是相對穩定的。

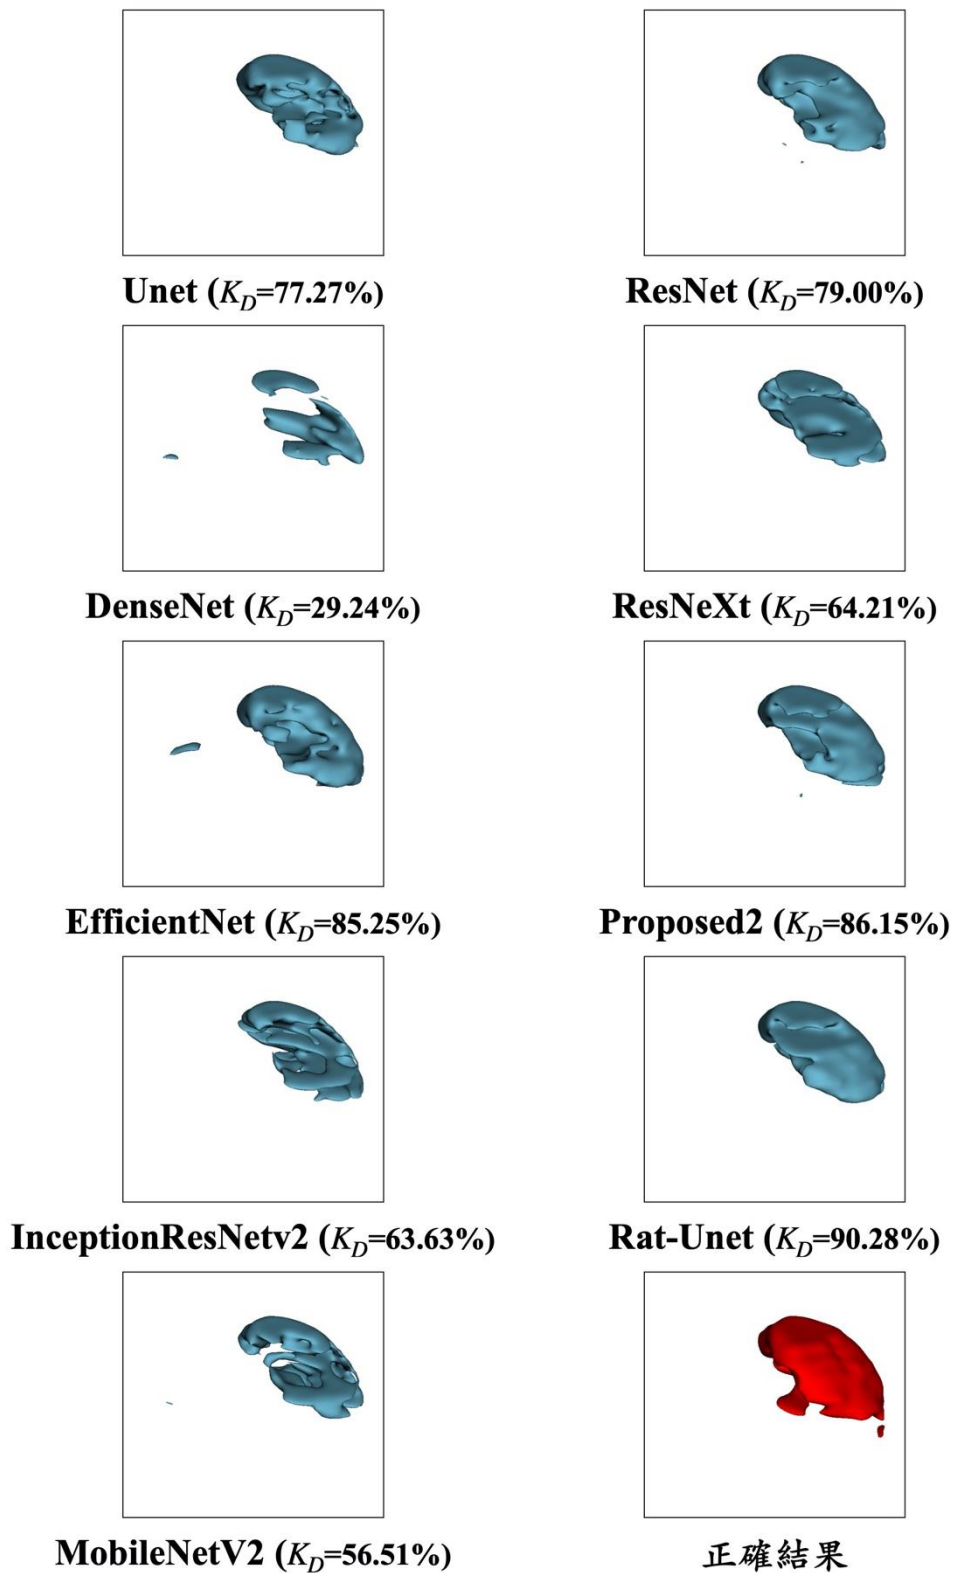


圖 4-30 測試之 DWI 資料集編號 141 之中風區域其他方法預測

(圖中三維空間結果為原結果加厚兩倍以利檢視)



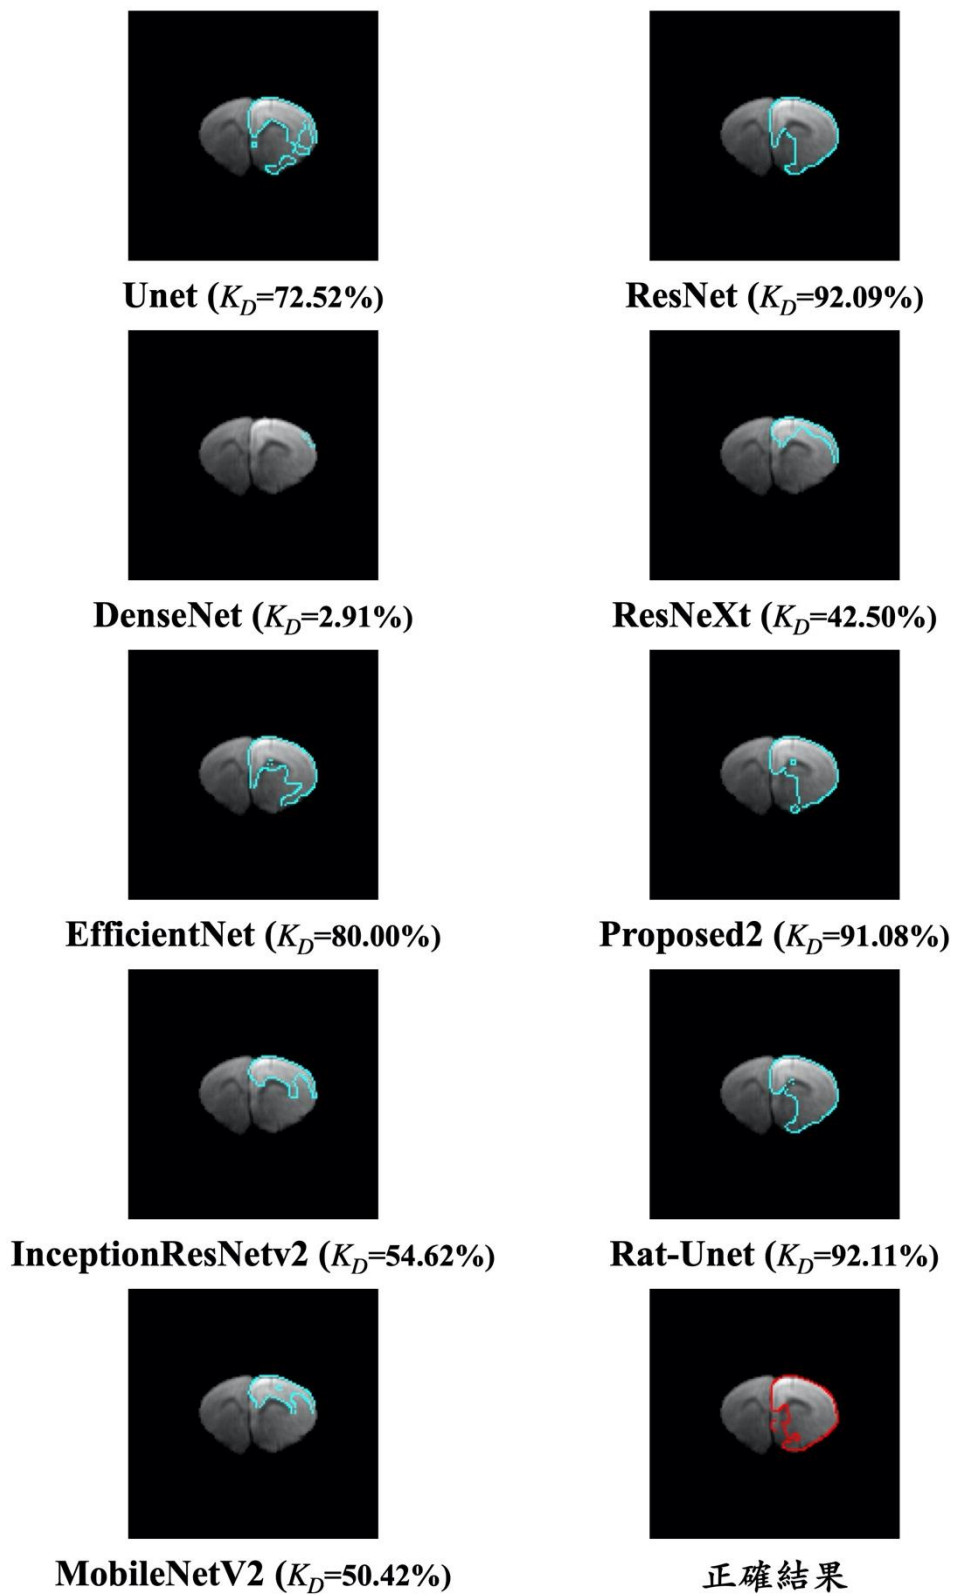


圖 4-31 測試之 DWI 資料集編號 141 之切片 12 中風區域其他方法預測

圖中藍色區域為預測區域，紅色區域為正確區域

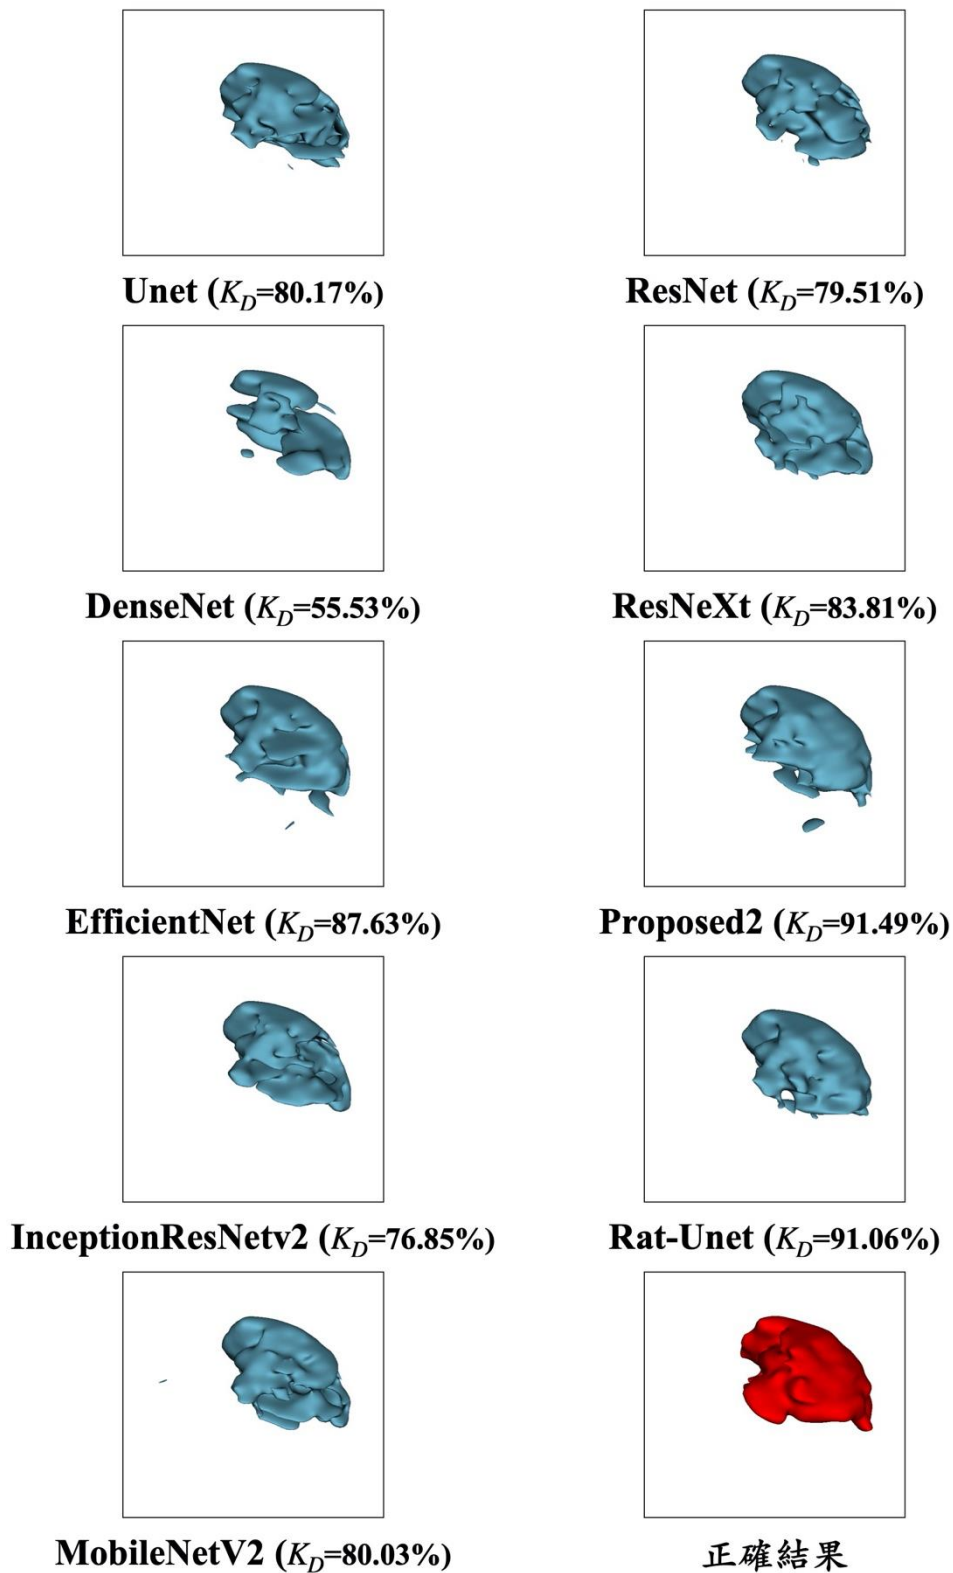


圖 4-32 測試之 DWI 資料集編號 142 之中風區域其他方法預測

(圖中三維空間結果為原結果加厚兩倍以利檢視)

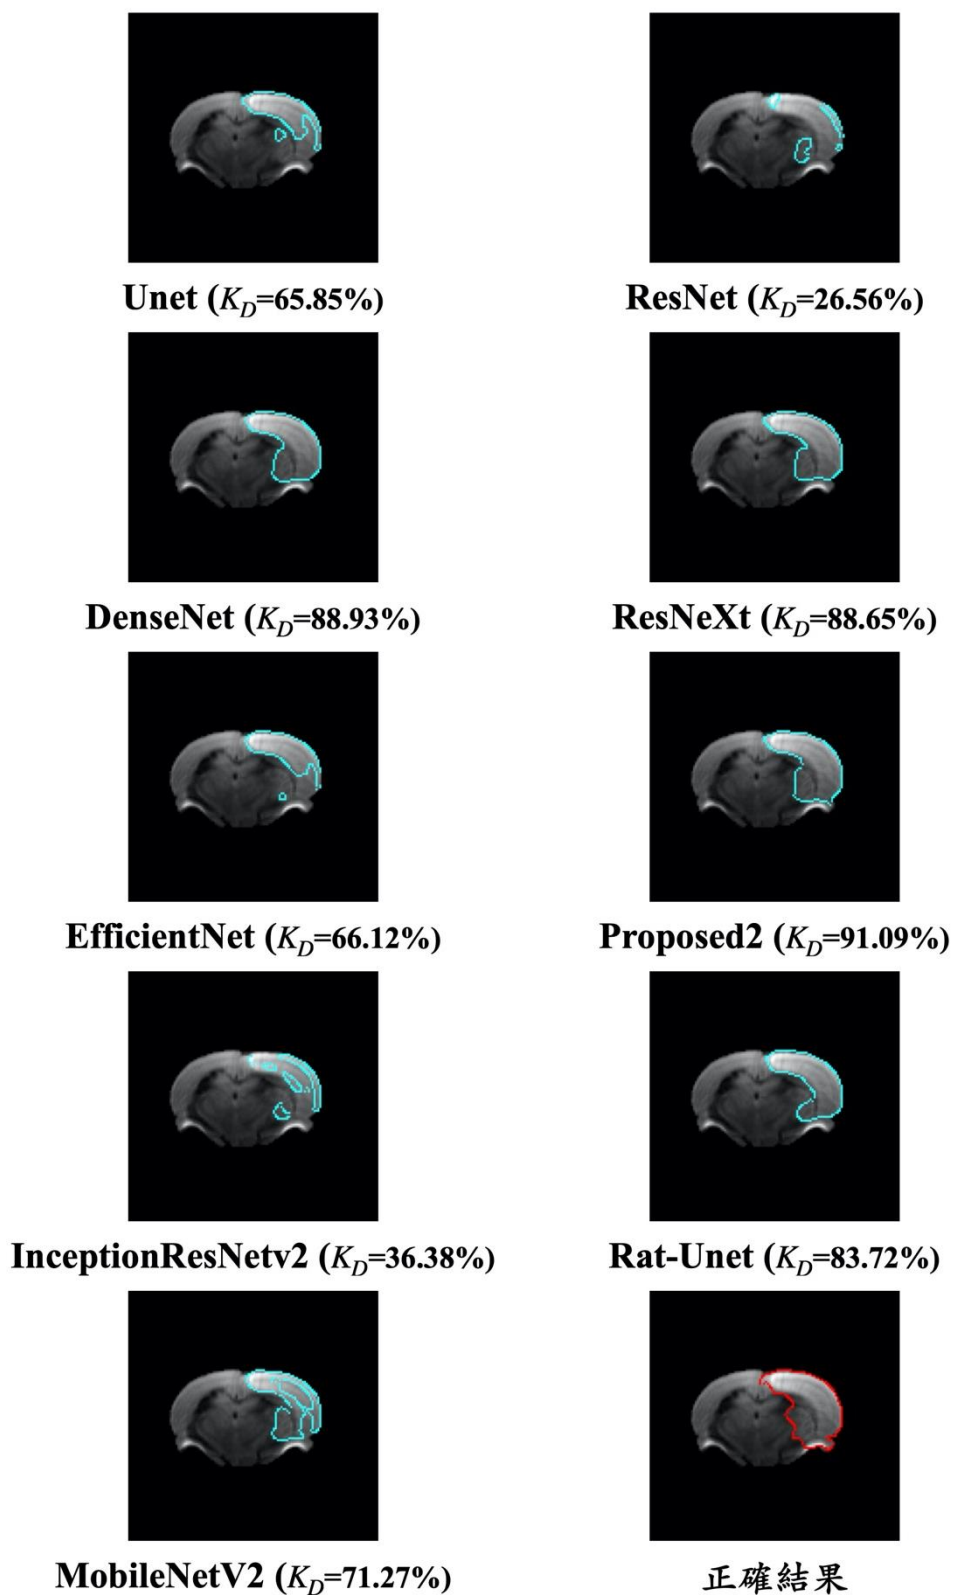


圖 4-33 測試之 DWI 資料集編號 142 之切片 6 中風區域其他方法預測

圖中藍色區域為預測區域，紅色區域為正確區域

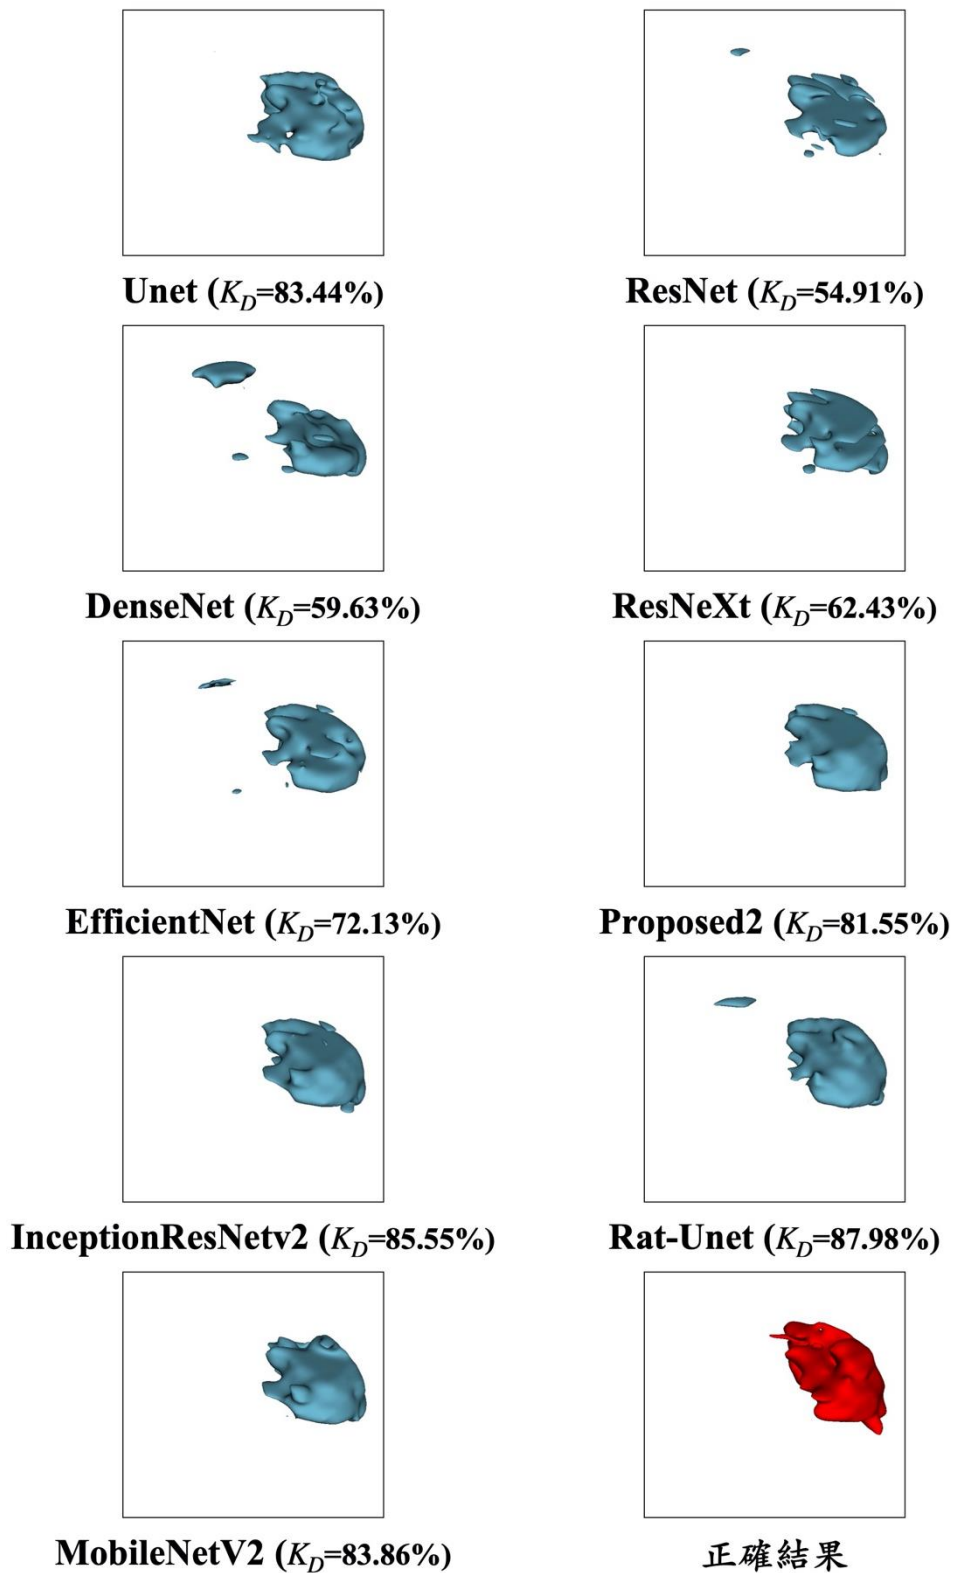


圖 4-34 測試之 DWI 資料集編號 146 之中風區域其他方法預測

(圖中三維空間結果為原結果加厚兩倍以利檢視)

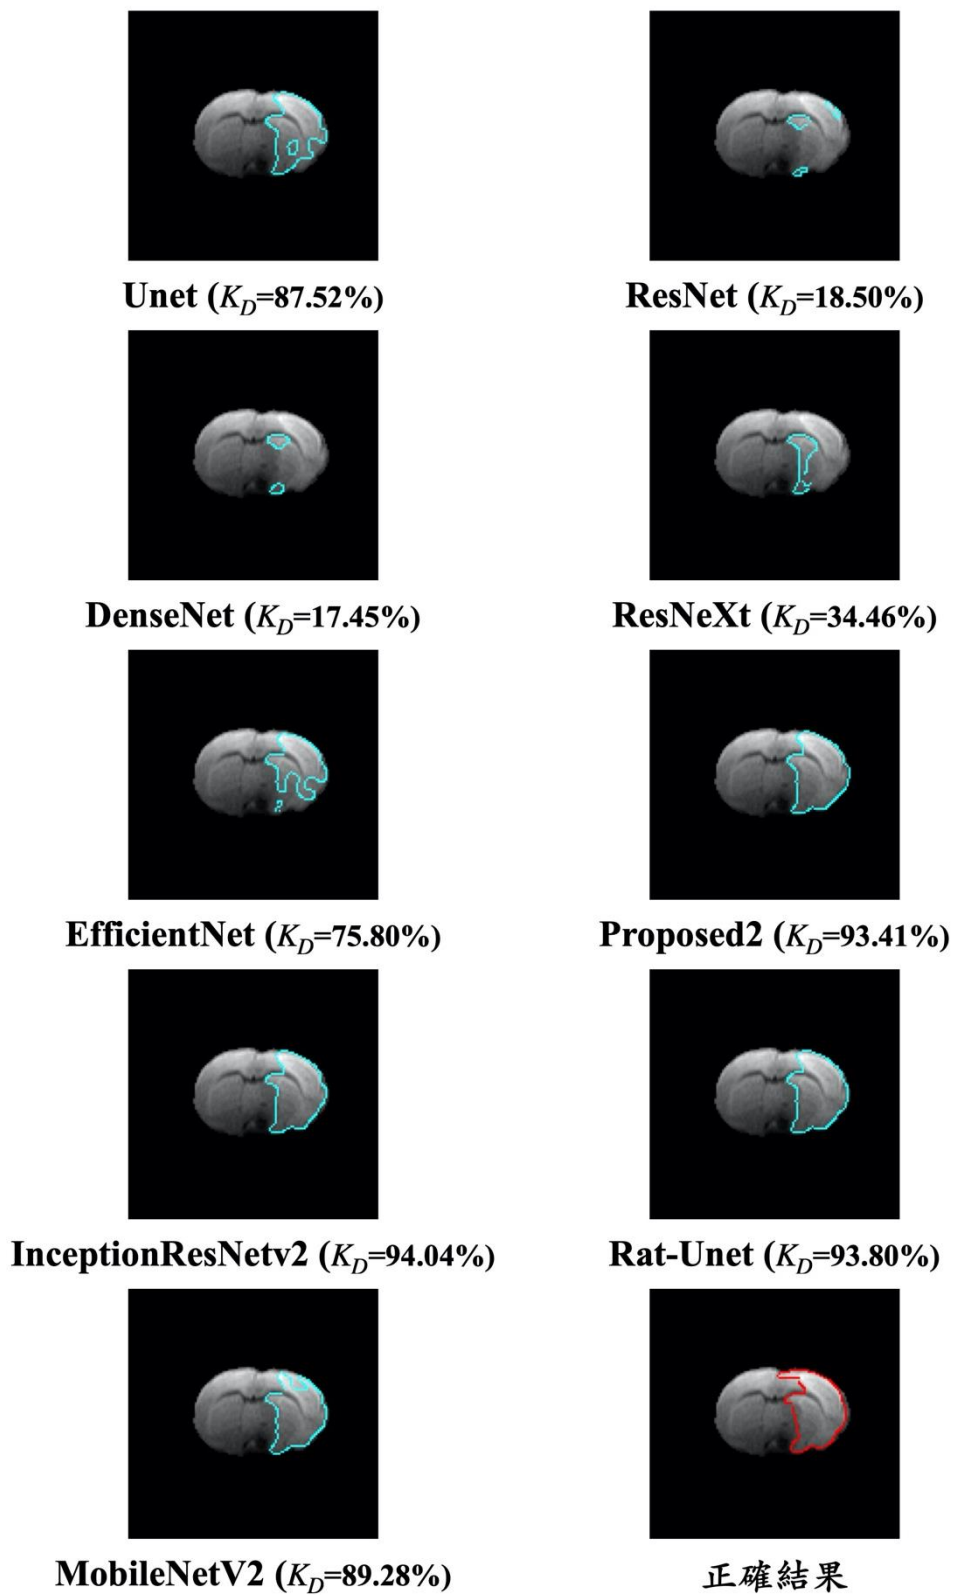


圖 4-35 測試之 DWI 資料集編號 146 之切片 10 中風區域其他方法預測

圖中藍色區域為預測區域，紅色區域為正確區域

表 4-13 測試之 DWI 影像分割結果與其他方法比較

	$K_c(\%)$	$K_{st}(\%)$	$K_{sb}(\%)$	$K_D(\%)$	$K_J(\%)$
<b>Unet</b>	63.93±12.95	80.73±7.42	90.89±6.05	84.95±4.49	74.08±6.65
<b>DenseNet</b>	21.59±119.54	72.57±20.96	91.88±6.18	78.37±17.08	66.90±18.94
<b>EfficientNet</b>	59.57±17.67	78.02±7.00	91.42±6.98	83.57±5.66	72.14±7.97
<b>InceptionResNetV2</b>	59.61±23.42	77.58±10.27	93.22±5.13	83.82±6.88	72.66±9.38
<b>MobileNetV2</b>	56.89±32.77	77.56±12.46	92.61±5.33	83.33±8.54	72.18±11.15
<b>ResNet</b>	54.95±34.83	78.54±13.04	89.89±8.19	82.75±8.63	71.32±10.89
<b>ResNeXt</b>	57.34±31.40	81.63±14.15	87.38±9.54	83.49±8.91	72.51±11.86
<b>Proposed2</b>	65.87±14.26	84.79±7.24	86.93±8.58	85.70±4.89	75.26±7.22
<b>Rat-Unet</b>	70.58±11.16	85.58±4.85	89.58±6.96	87.36±3.98	77.75±6.02

表 4-14 測試之 DWI 影像模型訓練時間與其他方法比較

一訓練週期訓練時間 (秒)	
<b>Unet</b>	565
<b>DenseNet</b>	190
<b>EfficientNet</b>	144
<b>InceptionResNetV2</b>	415
<b>MobileNetV2</b>	123
<b>ResNet</b>	118
<b>ResNeXt</b>	343
<b>Proposed2</b>	358
<b>Rat-Unet</b>	279

## 第 5 章 結論及未來展望



### 5.1 結論

造成人類死亡的主要原因中，腦中風長期榜上有名，因此若是能在腦中風領域能有突破性進展，勢必能提升人類之生活品質。而以齧齒動物老鼠做為腦中風實驗對象時，磁共振成像之影像可以作為腦中風區域及程度之初步判讀依據，但在影像上中風區域選取及判讀需要腦神經專家處置，以進一步探討及分析，這是一項繁瑣的工作，並且不同專家分割上有標準一致性上之問題。因此本研究提出腦中風影像自動分割中風區域之模型，以簡化及協助上述之研究流程。

在此分割任務上，本研究透過全卷積神經網路為架構，加入提出之混合殘差塊，組成 Rat-Unet 網路架構。當中混合殘差塊以不同尺度之特徵給予神經網路做抉擇，再以殘差學習避免網路在加深時退化之情形。並在訓練模型時對現有資料集透過不同程度之旋轉、推移及縮放，進行資料增強以提升網路在測試資料上之表現。

在實驗中，Rat-Unet 網路架構各以少量的 T2 中 588 張及 DWI 中 504 張原始訓練影像，增強後分別增加為 3528 及 3024 張，並以此進行模型訓練。其所學習出之模型，分別在 T2 加權成像及擴散加權成像 (DWI) 之腦部影像中風區域分割上，對於測試資料集都有優異的精準度。在分割 T2 影像中風區域中達到 86.84% 的準確度，並在 DWI 影像中達到了 87.36% 的準確度。

以此模型為基礎，進一步運用於未來之資料集，分別能在 T2 及 DWI 影像中產生腦中風區域之初步分割結果，輔助專家在研究時之目標區域選取及判讀，簡化研究之流程。

## 5.2 未來展望

本研究所使用之資料集數量，對於深度學習來說是顯得相對少量的，若是以本研究之網路架構為基礎，再加入新的資料集進行訓練，對於準確度的提升會是有幫助的。

本研究之模型能在分割上有一定的精準度，但此模型是以二維影像為訓練資料，故每張影像會視為單一個體，而實際情況下，這些影像是一個三維立體的腦部成像，以此概念再對神經網路架構進行調整，也許是一個可以嘗試之方向。

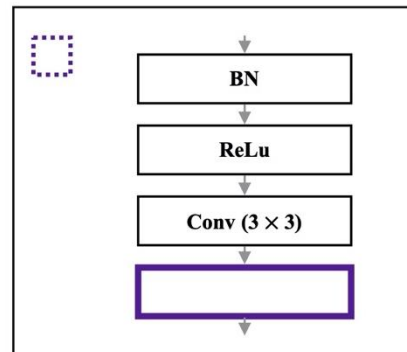

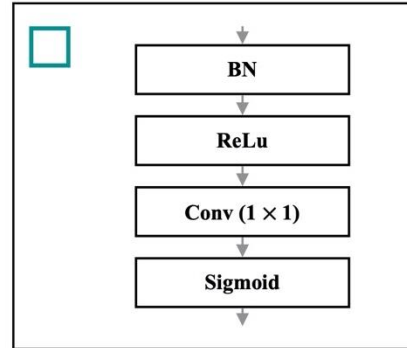
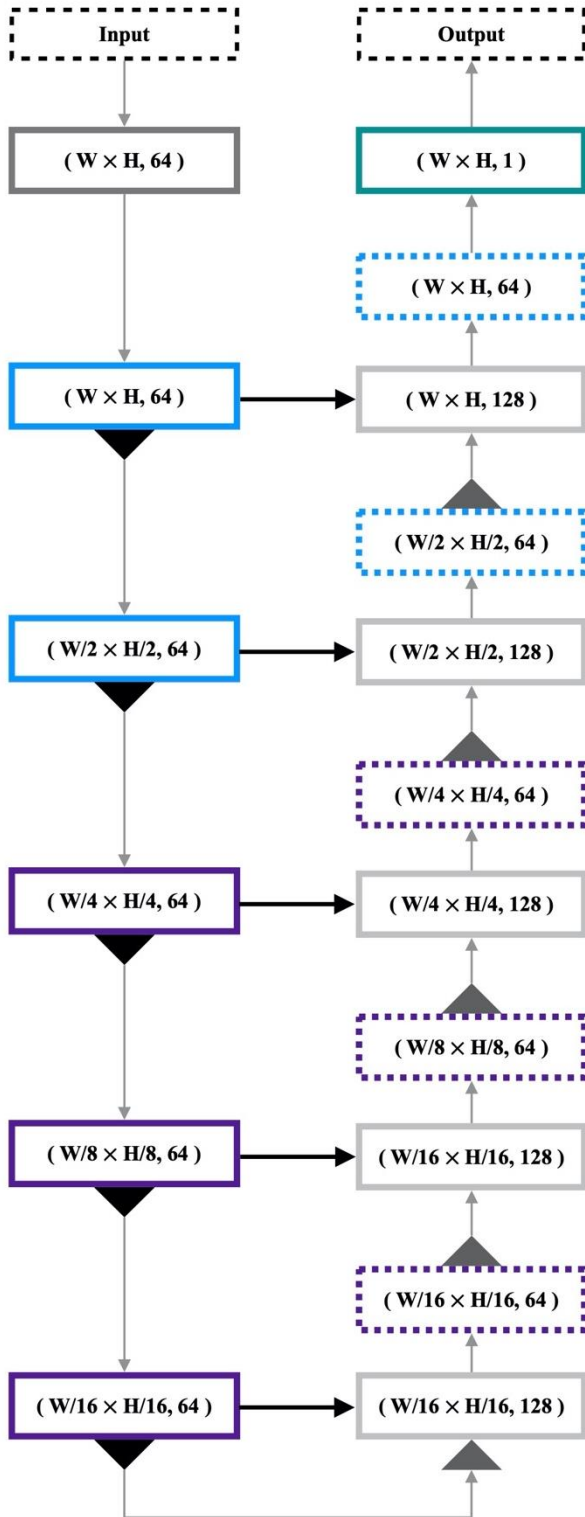




# 附錄

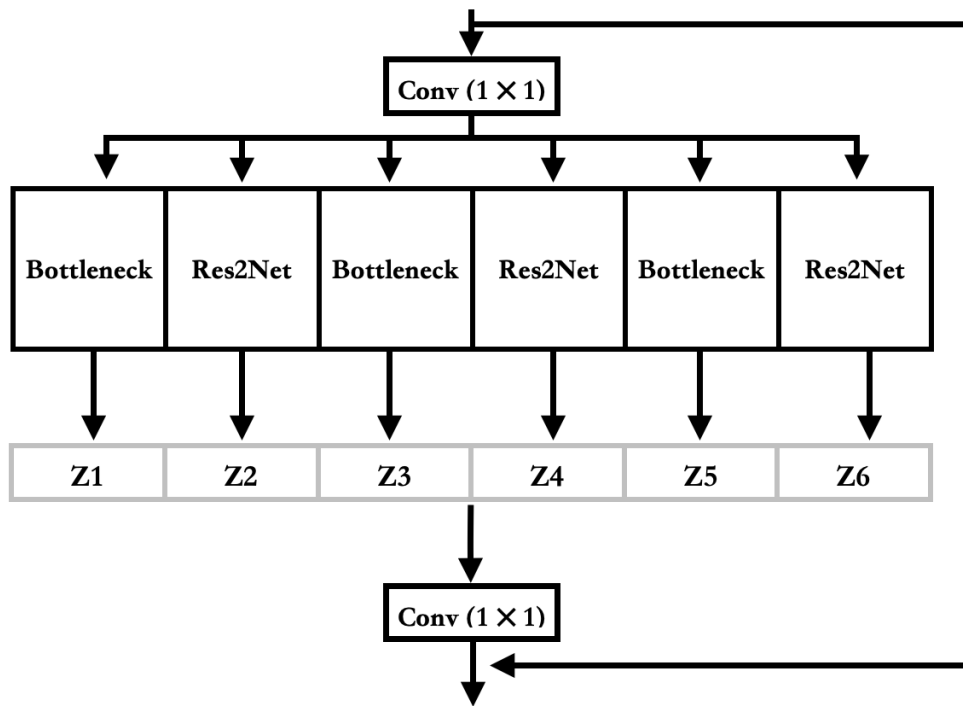


(1) Proposed 2 網路架構




- BN** Batch Normalization
- W** Image width (T2=256, DWI=128)
- H** Image height (T2=256, DWI=128)
- Basic Block
- Separate Block
- Conv (3 x 3)
- Concatenate Result
- MaxUnpooling with index
- MaxPooling
- Concatenate

(2) Separate Block



## 參考文獻



- [1] W. H. Organization. "Top 10 causes of death." [https://www.who.int/gho/mortality\\_burden\\_disease/causes\\_death/top\\_10/en/](https://www.who.int/gho/mortality_burden_disease/causes_death/top_10/en/) (accessed.
- [2] J. A. Chalela *et al.*, "Magnetic resonance imaging and computed tomography in emergency assessment of patients with suspected acute stroke: a prospective comparison," *The Lancet*, vol. 369, no. 9558, pp. 293-298 0140-6736, 2007.
- [3] R. J. Mural *et al.*, "A comparison of whole-genome shotgun-derived mouse chromosome 16 and the human genome," *Science*, vol. 296, no. 5573, pp. 1661-1671 0036-8075, 2002.
- [4] T. M. Woodruff, J. Thundyil, S.-C. Tang, C. G. Sobey, S. M. Taylor, and T. V. Arumugam, "Pathophysiology, treatment, and animal and cellular models of human ischemic stroke," *Molecular neurodegeneration*, vol. 6, no. 1, pp. 11 1750-1326, 2011.
- [5] A. Khan, A. Sohail, U. Zahoora, and A. S. Qureshi, "A survey of the recent architectures of deep convolutional neural networks," *arXiv preprint arXiv:1901.06032*, 2019.
- [6] S. Dodge and L. Karam, "A study and comparison of human and deep learning recognition performance under visual distortions," 2017: IEEE, pp. 1-7 1509029915.
- [7] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278-2324 0018-9219, 1998.
- [8] F. Rosenblatt, "The perceptron: a probabilistic model for information storage and organization in the brain," *Psychological review*, vol. 65, no. 6, pp. 386 1939-1471, 1958.
- [9] X. Glorot, A. Bordes, and Y. Bengio, "Deep sparse rectifier neural networks," 2011, pp. 315-323.
- [10] C. Nwankpa, W. Ijomah, A. Gachagan, and S. Marshall, "Activation functions: Comparison of trends in practice and research for deep learning," *arXiv preprint arXiv:1811.03378*, 2018.
- [11] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning representations by back-propagating errors," *nature*, vol. 323, no. 6088, pp. 533-536 1476-4687, 1986.
- [12] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," *arXiv preprint arXiv:1412.6980*, 2014.
- [13] S. Ruder, "An overview of gradient descent optimization algorithms," *arXiv*

*preprint arXiv:1609.04747*, 2016.

- [14] N. Qian, "On the momentum term in gradient descent learning algorithms," *Neural networks*, vol. 12, no. 1, pp. 145-151 0893-6080, 1999.
- [15] G. Hinton, N. Srivastava, and K. Swersky. "Neural Networks for Machine Learning: Lecture 6a: Overview of mini-batch gradient descent." [http://www.cs.toronto.edu/~tijmen/csc321/slides/lecture\\_slides\\_lec6.pdf](http://www.cs.toronto.edu/~tijmen/csc321/slides/lecture_slides_lec6.pdf) (accessed.
- [16] J. Long, E. Shelhamer, and T. Darrell, "Fully convolutional networks for semantic segmentation," 2015, pp. 3431-3440.
- [17] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," 2012, pp. 1097-1105.
- [18] O. Ronneberger, P. Fischer, and T. Brox, "U-net: Convolutional networks for biomedical image segmentation," 2015: Springer, pp. 234-241.
- [19] C. Szegedy *et al.*, "Going deeper with convolutions," 2015, pp. 1-9.
- [20] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," 2016, pp. 770-778.
- [21] S. Ioffe and C. Szegedy, "Batch normalization: Accelerating deep network training by reducing internal covariate shift," *arXiv preprint arXiv:1502.03167*, 2015.
- [22] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, "Densely connected convolutional networks," 2017, pp. 4700-4708.
- [23] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, "Rethinking the inception architecture for computer vision," 2016, pp. 2818-2826.
- [24] C. Szegedy, S. Ioffe, V. Vanhoucke, and A. A. Alemi, "Inception-v4, inception-resnet and the impact of residual connections on learning," 2017.
- [25] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "Mobilenetv2: Inverted residuals and linear bottlenecks," 2018, pp. 4510-4520.
- [26] A. G. Howard *et al.*, "Mobilenets: Efficient convolutional neural networks for mobile vision applications," *arXiv preprint arXiv:1704.04861*, 2017.
- [27] J. Hu, L. Shen, and G. Sun, "Squeeze-and-excitation networks," 2018, pp. 7132-7141.
- [28] M. Tan and Q. V. Le, "Efficientnet: Rethinking model scaling for convolutional neural networks," *arXiv preprint arXiv:1905.11946*, 2019.
- [29] S. Xie, R. Girshick, P. Dollár, Z. Tu, and K. He, "Aggregated residual transformations for deep neural networks," 2017, pp. 1492-1500.
- [30] E. Kreyszig, "Advanced Engineering Mathematics, 10th Eddition," ed: Wiley, 2009.
- [31] K. He, X. Zhang, S. Ren, and J. Sun, "Identity mappings in deep residual

- networks," 2016: Springer, pp. 630-645.
- [32] S. Gao, M.-M. Cheng, K. Zhao, X.-Y. Zhang, M.-H. Yang, and P. H. S. Torr, "Res2net: A new multi-scale backbone architecture," *IEEE transactions on pattern analysis and machine intelligence* 0162-8828, 2019.
- [33] X. Glorot and Y. Bengio, "Understanding the difficulty of training deep feedforward neural networks," 2010, pp. 249-256.
- [34] K. He, X. Zhang, S. Ren, and J. Sun, "Delving deep into rectifiers: Surpassing human-level performance on imagenet classification," 2015, pp. 1026-1034.
- [35] P. S. Foundation. "Python 3.5.7." <https://www.python.org/downloads/release/python-357/> (accessed.
- [36] keras-team. "Keras 2.2.4." <https://github.com/keras-team/keras> (accessed.
- [37] Google. "tensorflow-gpu 1.15.2." <https://github.com/tensorflow/tensorflow> (accessed.
- [38] L. R. Dice, "Measures of the amount of ecologic association between species," *Ecology*, vol. 26, no. 3, pp. 297-302 1939-9170, 1945.
- [39] H.-H. Chang, A. H. Zhuang, D. J. Valentino, and W.-C. Chu, "Performance measure characterization for evaluating neuroimage segmentation algorithms," *Neuroimage*, vol. 47, no. 1, pp. 122-135 1053-8119, 2009.
- [40] P. Jaccard, "The distribution of the flora in the alpine zone. 1," *New phytologist*, vol. 11, no. 2, pp. 37-50 0028-646X, 1912.