

科技部補助
大專學生研究計畫研究成果報告

計畫名稱：基於DICOM RT Structure和GAN深度學習演算法之頭頸部CT影像器官圈選

執行計畫學生：謝雅如
學生計畫編號：MOST 108-2813-C-040-004-E
研究期間：108年07月01日至109年02月28日止，計8個月
指導教授：秦群立

處理方式：本計畫可公開查詢

執行單位：中山醫學大學醫學資訊學系

中華民國 109年03月27日

(一)摘要

癌症的發生是細胞不正常增生所產生的惡性腫瘤，且這些增生的細胞會侵犯身體的其他部分，例如：局部侵入正常組織、經由體內循環系統或淋巴系統轉移到身體其他部位。因此，醫院的放射腫瘤科主要對這些腫瘤進行化學治療、放射線治療或標靶治療。在實行這些治療動作前，醫師須透過各項檢查及自身經驗才能與患者確認治療方案，其中一項重要的檢查則是電腦斷層影像(CT)掃描。每位患者在 CT 影像掃描後，影像會先交由醫學影像放射師將重要的器官與需要進行治療的標靶體積框選出來，形成一張 DICOM RT 影像給醫生做診斷判斷及劑量評估。然而，放射師很容易因為經過長時間的圈選器官造成眼睛疲憊或者器官與治療靶體積不一樣的失誤情況發生。

為了解決上述問題，本計畫開發 Radiation Therapy Generator Adversarial Network (RTGAN)，是一套基於生成對抗網路(GAN)的深度學習演算法來進行頭頸部 CT 影像器官的圈選及切割。在影像前處理部分結合 CT 影像與 RT Structure (RS)檔案資訊產生 Bitmap (BMP)檔案，再將 BMP 檔放入生成網路中。生成的影像會透過鑑別網路與原始影像進行比對，以此做為學習的模型。經過不斷的訓練，搭配多重損失函數的計算與參數調整，最終生成相似於放射師所圈選的原始 RT 影像。最後，系統還會將生成的影像儲存回 RT 格式供醫院中的醫師們使用。本計畫也將提出的方法實際運用在放射腫瘤科中，經過測試與評估，其結果與人工圈選器官或治療靶的區域幾乎是一樣的。此外，也有與其他方法及市售的醫用軟體進行比較，並使用 SSIM 及 PSNR 兩指標計算影像品質，分別得到分數為 0.984 和 31.26。不僅可以有效降低誤判率，也能輔助醫師在最短時間內做出更準確的診斷。

(二)研究動機與研究問題

醫院的放射腫瘤科主要是對腫瘤進行放射線的治療單位，其中，放射師需要先將 CT 影像中重要器官與需要進行放射線治療的標靶體積框選出來形成一張 Digital Imaging and Communications in Medicine (DICOM) radiotherapy (RT)影像，透過此資訊來輔助醫師診斷與決策放射線或治療用化學藥物的使用量。圖 1(a)為患者接受電腦斷層掃描後的一張原始 CT 影像，圖 1(b)為放射師在原始 CT 影像上圈選器官及治療標靶體積後之 RT 影像。然而，長時間重複圈選器官或治療標靶體積很容易造成放射師的眼睛或精神疲憊，導致圈選的器官或治療靶的體積不一樣的情況發生，且現有的相關資訊軟體所獲得的結果也不符合醫師的要求。




圖 1、(a)原始 CT 影像，(b)放射師圈選器官後的 RT 影像

近年來，因為人工智慧的蓬勃發展，機器可以自動學習、從巨量資料中找到規則並進一步對學習的資料預測結果。許多各界學者開始思考如何將現代科技應用在醫學影像診斷及判讀上。有鑑於生成對抗網路(Generative Adversarial Network, GAN)深度學習演算法在影像處理取地的良好成果，有學者提出使用此演算法，透過少量的資料進行學習、進行影像的比對與修正並取得不錯的成效。

目前尚無學者將 GAN 運用在醫學影像的切割上，本計畫開發一套基於 GAN 深度學習演算法—Radiation Therapy GAN (RTGAN)，並將之應用於頭頸部 CT 影像的器官圈選上，透過兩個相互競爭的類神經網路：生成和鑑別網路來進行影像的對比與切割。在生成網路中，系統會試著產生像原始影像的生成 RT 影像，而鑑別網路會將生成的 RT 影像與放射師所圈選的 RT 影像進行真偽判斷[10-11]，並使用多重損失函數進行生成影像與標準影像的誤差計算。期望本計畫所提出的器官圈選系統能輔助放射腫瘤科醫師在 CT 影像的判讀及診斷上，幫助醫生和一般民眾在臨床上快速得到醫病的治療方針。

(三)文獻回顧與探討

當患者針對腫瘤接受各種治療之前，醫生必須先替患者做 CT 掃描，進一步在 CT 影像上進行器官、腫瘤及治療標靶體圈選及分割。其中，完成器官圈選則是放射師每日的工作。然而，每日重複的動作容易讓放射師的眼睛及精神感到疲憊，造成圈選的器官或治療靶體積不一樣情況發生。若能輔助放射師更準確且快速的在醫學影像上進行器官圈選，並提供醫生跟患者盡早討論治療方針，必能降低疾病帶來的疼痛及心理壓力。此外，雖然至今已有許多影像切割的論文被提出，但針對器官圈選的部分仍佔少數。若能參考多篇文獻做為基礎，並發展出自動器官圈選於醫學影像切割上的方法，將更具意義。

在 2009 年，Maria Y. Y. Law 等學者發表了一篇基於 DICOM-RT 的電子病歷系統的論文[1]，其帶來的好處有三個方面：作為執行有效臨床服務的基礎、建立一個共同平台與統一數據並給予醫師和專家進行交流。DICOM 標準影像的概念從放射理論學延伸到放射治療上，不僅有助於整合來自不同廠商的放射治療設備和病患資訊，也可以雙向性操作及查看影像及治療等資訊，在放射治療中使用 DICOM 診斷各種影像。由此可知 DICOM-RT 已被整合成一套綜合放射治療電子病歷，且在醫學影像相關研究與創新開發的同時提供重要資料，成為改進放射治療的資料庫。

在 2014 年，Jon Pipitone 等學者提出一篇醫學影像切割應用在人類大腦中的海馬體的論文[2]。透過自動生成的模板，針對海馬體周圍的多圖譜切割任務提出了 MAGeT-Brain 方法。通過非線性影像的轉換，將切割過的影像與每個目標影像配對並標記融合的部分，再進行兩個單獨的蒙特卡羅交叉實驗去驗證和比較使用不同圖譜、模板庫及融合方法的 MAGeT-Brain 和基本的海馬體影像分割的差異。此研究提出的方法有效的改善海馬體的切割不便性，但是沒有對整個大腦器官或身體其他器官的切割方法進行深入研究。

在 2017 年，Ibragimov B 等學者提出準確分割風險器官(Organs-at-risks, OARs)是有效規劃頭頸部的癌症治療的放射治療的關鍵步驟[3]。運用卷積神經網絡(Convolutional Neural Network, CNN)對 CT 影像中的風險器官進行分割並輸入風險區域附近的正常與異常部分進行學習，藉此找出風險區域。使用 50 個 CT 影像驗證了 CNN 在脊髓、下頷骨、腮腺、喉、咽、眼球和細胞分割方面表現出相似或更好的表現，但是在視神經、下頷下腺和視交叉分割的表現較差。獲得的分割結果從 37.4%的交叉骰子係數(Dice coefficient, DSC)到 89.5%的下頷骨 DSC。此研究提出的方法有效的運用在頭頸部的器官分割上，但是若應用在其他影像上，例如：MR 影像，則器官的輪廓會不明顯。

在 2017 年，Fausto Milletari 等學者發表了一篇透過 CNN 的抽象能力來執行影像分割的論文[4]。他們利用霍夫(Hough)投票結合 CNN 進行醫學影像的全自動定位與分割，並證明這種分割方法容易適應不同的模組。為了展示 CNN 應用在醫學影像分析上的表現，嘗試在不同情況下根據六種不同網絡架構的性能進行研究。透過評估不同數量的訓練數據和在不同維度下(2D, 2.5D 和 3D)對最終結果的影響，結果顯示在 MRI 的影像上分別描繪了基底神經和中腦的 26 個區域。本計畫參考了這篇使用深度

學習(Deep Learning)演算法進行影像切割的論文，以此為構思探討是否使用相關網路架構來進行自動器官圈選的方法。

在 2018 年，越來越多學者透過深度學習演算法的訓練協助醫學影像的切割與診斷[5-6]，且 GAN 在影像處理取地的良好成果，有學者提出使用 GAN 演算法並透過少量的資料進行學習、比對與修正並取得不錯的成效 [7-9][11]。Qiang Z 等學者通過集成支持向量機和圖形切割(Integrating support vector machine and graph cuts)進行醫學影像的切割[10]。使用不同類別的醫學影像，如：MR 腦影像、超音波手臂影像等，並發現針對影像局部訓練比整張訓練效果好。K. Seeliger 等學者提出一篇從大腦活動中重建視覺刺激的論文[12]。透過訓練一個深度卷積類生成對抗網絡，能夠透過磁共振成像實驗中刺激大腦，並指出經過不斷的訓練產生越來越相似的樣本，可以建造出最佳的預測模型。

綜合以上的文獻回顧，本計畫發現大部分的文獻僅探討傳統 CNN 在醫學影像的分類或分割，極少數提及使用 GAN 在器官圈選的切割。因此本計畫將利用由中山醫學大學附設醫院放射腫瘤科所提供的 CT 影像並結合深度學習演算法進行分析，將影像輸入至 GAN 進行醫學影像的器官圈選。再利用多重損失函數進行誤差的計算與評估，並透過回傳誤差來調整參數以得到更好的結果。最後，將生成的影像與原始影像進行比對，並將器官的位置資訊等寫入 RT Structure (RS)檔案供醫師診斷使用。

(四)研究方法及步驟

本計畫採用一種基於 GAN [13]之 RTGAN 深度學習演算法進行頭頸部 CT 影像器官的自動圈選，其流程圖如圖 2 所示。



圖 2、系統流程圖

本系統主要分為「輸入大量 CT 影像」、「影像前處理」、「使用 GAN 深度學習演算法之器官圈選」及「建立全新 RS 檔案」四個部份，以下將針對各步驟詳細說明。

1. 輸入大量 CT 影像

本計畫的影像來源為中山醫學大學附設醫院(Chung Shan Medical University Hospital)放射腫瘤科醫師和放射師所提供的 CT 影像。影像資料集為 150 位病患共 11593 張頭頸部 DICOM RT 影像，並將資料集分 80%給訓練資料，20%給測試資料。在訓練網路的過程中也會持續增加影像資料，提高資料集多樣和豐富性。

2. 影像前處理

影像前處理的流程圖如圖 3 所示，在影像前處理時，會將檔案進行格式轉換、去除訊及統一器官顏色，最後生成的 RT 影像會做為訓練樣本輸入至深度學習演算法。

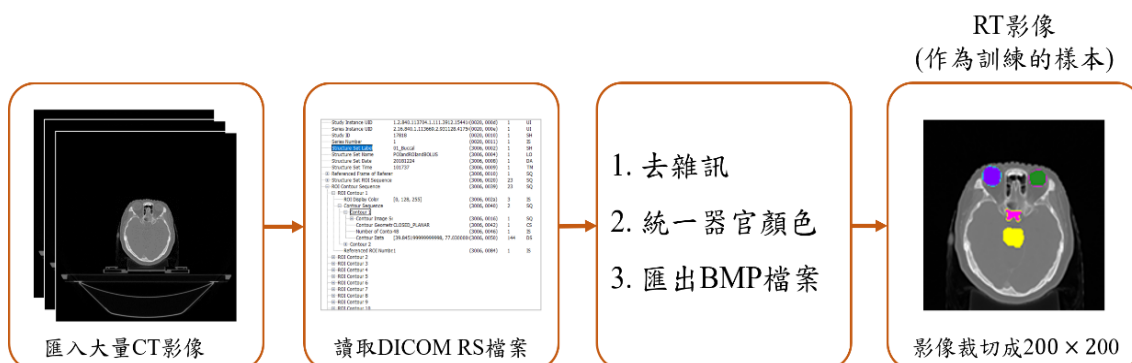


圖 3、影像前處理流程圖

(1) CT 影像格式轉換

每位病人在接受 CT 斷層掃描後會得到約有 90 張頭頸部的 DICOM 影像，我們會先將 DICOM 影像轉換成 BMP 檔，並透過 Z 軸進行排序，將影像由頭至肩頸部依序排列。每一張 CT 影像會結合對應的 RS 檔中的重要器官資訊，例如：器官圈選輪廓的 x 軸、y 軸和 z 軸座標與器官顏色等，再與 CT 影像資訊進行合併後匯出 BMP 檔，生成一張新的大小為 200×200 的 RT 影像。

(2) 去除雜訊

放射師可能因為疲勞或突發狀況，不小心在器官圈選的過程中誤觸或圈選到非器官區域，在影像上會呈現類似一個點的形狀，我們會歸類這些點為雜點。即使肉眼看不到，如圖 4(a)所示，但是 RS 檔中也會記錄該筆數據。這些人為圈選錯誤造成的雜訊，在 RS 記錄檔中其輪廓的 x 軸、y 軸與 z 軸只會有一個數值，如圖 4(b)所示。

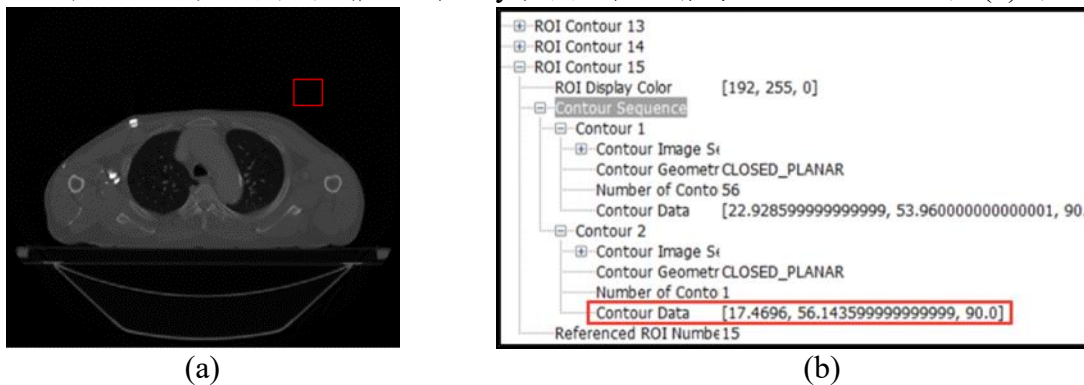


圖 4、(a)有雜訊的 CT 影像，(b)DICOM RS 檔中雜訊的位置

雜點會先進行去雜訊化，利用程式抓取 RS 檔案中這些特別的三軸數值並遮蔽及刪除。避免這些雜點在影像進行訓練時會被深度學習網路誤認成一個器官，影響到訓練及測試的結果及準確度。

(3) 統一器官顏色

在生成的 RT 影像中，本計畫會將放射師所圈選的器官先進行顏色統一。因為每一位醫學影像放射師可能習慣在圈選器官、腫瘤及治療標靶體時使用的顏色都不相同。例如：A 放射師在圈選腦幹時，習慣用橘色，但是 B 放射師習慣用藍色。這些圈選結果直接給醫師進行診斷查看時不會有太大問題，但是若將這些影像匯入深度學習網路進行訓練及學習，最後的訓練結果會與原始放射師所圈選的器官影像相差甚遠。因此，本計畫會在影像前處理的程式中給予每個器官一個標準顏色。再從每一個病人的 RS 檔中，針對該對應到的器官抓取其 x 軸及 y 軸等區域座標資訊，將座標資訊結合後繪製於 CT 影像。其輪廓所涵蓋的區域利用標準顏色進行填滿，最後形成一張顏色標準化過後的影像供訓練網路使用。

3. 使用 GAN 深度學習演算法之器官圈選

本計畫會將形成的 RT 影像輸入至開發的 RTGAN 演算法中，生成一張圈選過的 RT 影像，其流程圖如圖 5 所示。本計畫使用的 RTGAN 深度學習演算法分為兩大部分：生成網路與鑑別網路，其架構圖如圖 6 所示。在生成網路中包含 12 層卷積層，而每一層卷積層都會有 batch 進行標準化。除了在最後一層中使用 tanh 雙曲線激發函數，其餘的每一層都使用 ReLU 激發函數。系統最後會生成一張 RT 影像，並輸入鑑別網路中。在鑑別網路中，我們搭配 Leaky ReLU 激發函數、5 層卷積層、4 層 batch 和 1 層全連接層，並與原始放射師所圈選的 RT 影像樣本進行 SSIM 和 PSNR 比對。在多次比對後，經過生成網路所產生的 RT 影像會十分接近原始放射師在 CT 影像中所圈選的器官面積及位置。

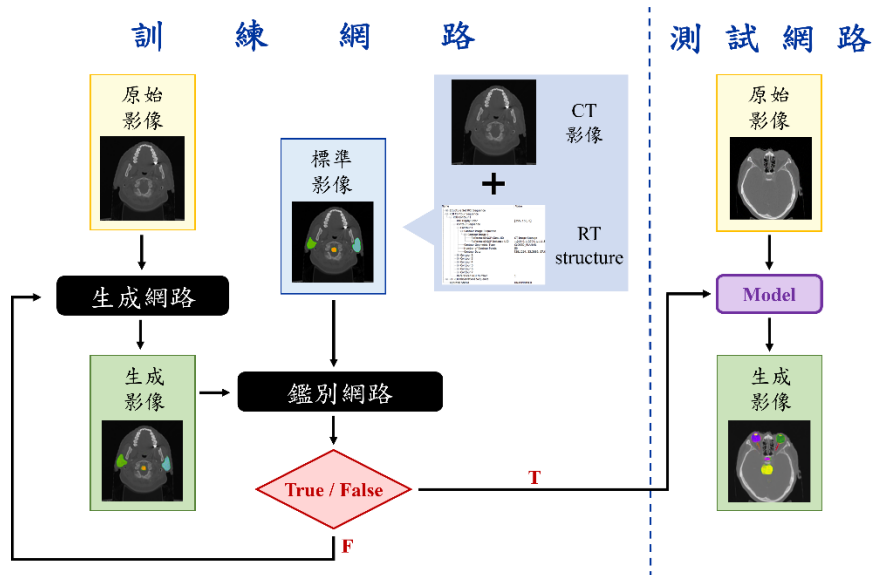


圖 5、影像輸入至 RTGAN 深度學習演算法進行訓練的流程圖

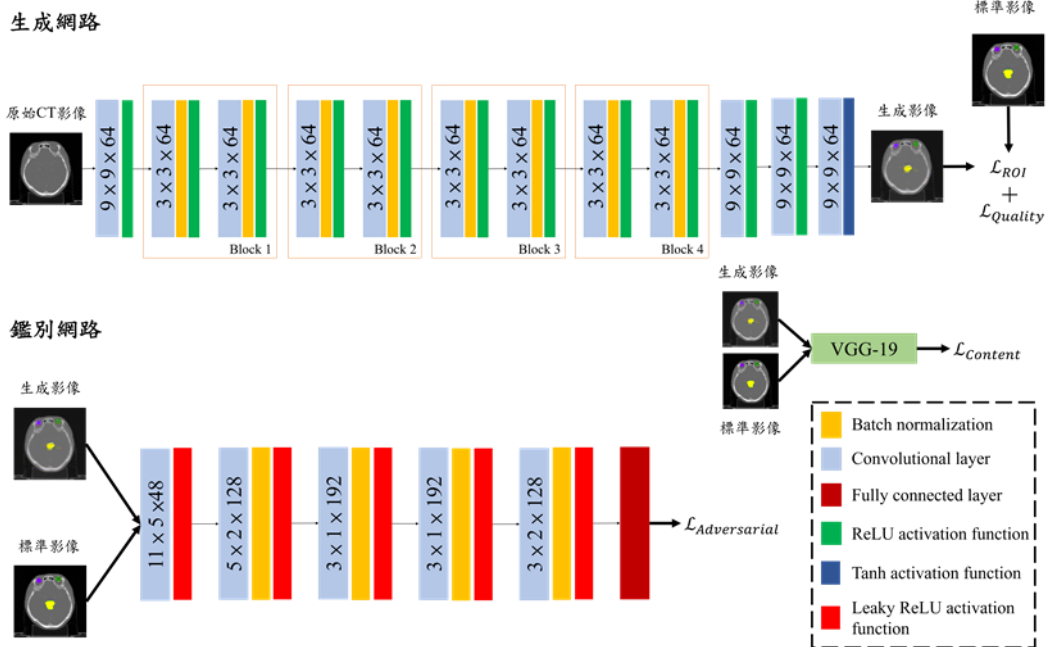


圖 6、RTGAN 深度學習網路架構圖

為達到更好的器官圈選目的，本計畫在 GAN 的生成網路設置了四種損失函數並給予不同權重值，最後將它們整合成一個總損失函數。根據輸入的影像與放射師原始圈選的影像進行比對並將誤差回傳，以下將分別作介紹。

A. 感興趣區域損失函數

為了測量增強影像和目標影像之間的區域(Region of Interest, ROI)和顏色飽和差異，我們提出使用高斯拉普拉斯運算子($LoG(\cdot)$)進行影像邊緣銳利化，並用 $\| \cdot \|$ 表示歐幾里德距離，計算原始影像中獲得的特徵與標準影像之間的誤差。本計畫使用的感興趣區域損失函數(L_{ROI})為方程式(1)，其中 $G_{\theta}(X_i)$ 和 Y_i 分別表示邊緣銳利化後的 X 和 Y 影像，如方程式(2)所示。 LoG 運算方式如方程式(3)所示，我們定義 $\sigma = 1.4$ 。

$$L_{ROI} = \sum_i \| \mathcal{R}(G_{\theta}(X_i)) - \mathcal{R}(Y_i) \| \quad (1)$$

$$\mathcal{R}(G_{\theta}(X(i, j))) = \sum_{m, n} X(i + m, j + n) \times LoG(m, n) \quad (2)$$

$$LoG(m, n) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{m^2 + n^2}{2\sigma^2}\right) \quad (3)$$

B. 鑑別損失函數

在生成網路中，鑑別損失函數($\mathcal{L}_{Adversarial}$)會特別針對影像紋理部分進行偵測。透過最大似然估計(Maximum Likelihood Estimation, MLE)在生成網路與鑑別網路之間進行紋理的機率分布比較。將生成網路生成的影像放入鑑別網路中，經由鑑別網路產生的相似程度為 0 至 1，再將數值取 \log 進行誤差計算。本計畫使用的紋理損失函數為方程式(4)：

$$\mathcal{L}_{Adversarial} = - \sum_i \log \mathcal{D}_\gamma((G_\theta(X_i)), Y_i) \quad (4)$$

其中 G_θ 和 \mathcal{D}_γ 表示生成器與鑑別器，而 $G_\theta(X_i)$ 代表生成網路輸出的器官圈選影像。

C. 內容損失函數

內容損失函數($\mathcal{L}_{Content}$)主要是考慮圈選後的影像 $G_\theta(X)$ 和標準影像 Y 中每一個像素值的差異，使它們有類似的特徵表現。本計畫分別將生成網路生成的影像與標準影像輸入 VGG-19 中，並由 ReLU 激發函數所產生的激發圖上抽取影像中的特徵，最後比較每個特徵圖中的內容誤差。本計畫使用的內容損失函數為方程式(5)：

$$\mathcal{L}_{Content} = \sum_i \sum_{m,n} \frac{1}{C_i H_i W_i} \left\| \phi_{Y_s}^{\lambda_s}(G_\theta(X_{m,n})) - \phi_{Y_s}^{\lambda_s}(Y_{m,n}) \right\| \quad (5)$$

其中 m 和 n 是 x 和 y 維度的像素值； C_i 代表批量處理大小， H_i 和 W_i 代表影像的高度和寬度經過 VGG19 第 i 層卷積層後得到的特徵圖，而 $\phi_{Y_s}^{\lambda_s}$ 是 VGG-19 網絡中 λ_s th 層的 γ_s th 區塊輸出的特徵圖。

D. 品質損失函數

在品質損失函數($\mathcal{L}_{Quality}$)中，我們透過峰值信噪比(Peak Signal to Noise Ratio, PSNR)和結構相似度(Structural Similarity Index, SSIM)來計算生成的標記影像和真實情況之間的相似程度，結合 PSNR 和 SSIM 並給予不同的網路權重，為方程式(6)：

$$\mathcal{L}_{Quality} = 1 \cdot \mathcal{L}_{PSNR} + 1.5 \cdot \mathcal{L}_{SSIM} \quad (6)$$

\mathcal{L}_{PSNR} 由均方誤差(Mean Square Error, MSE)定義，並計算生成的標記影像和真實情況之間的相似程度，如方程式(7)所示。 MAX_I 表示影像中可能的最大像素值，而均方根誤差定義如方程式(8)所示，其中影像 i 的大小為 $a \times b$ ，雜訊(noise)近似值為 K 。

$$\mathcal{L}_{PSNR} = - \sum_i 20 \cdot \log\left(\frac{MAX_I}{\sqrt{MSE(G_\theta(X_i), Y_i)}}\right) \quad (7)$$

$$MSE(G_\theta(X_i), Y_i) = \frac{1}{ab} \sum_{i=0}^{a-1} \sum_{j=0}^{b-1} [G_\theta(X_i)(i, j) - Y_i(i, j)]^2 \quad (8)$$

\mathcal{L}_{SSIM} 分別計算 x 和 y 兩張影像之間的整體相似性，如方程式(9)和(10)所示。我們定義 $L = 255$ ， $K_1 = 0.01$ 和 $K_2 = 0.03$ ； u_x 和 u_y 是 x 和 y 的平均值； σ_x 和 σ_y 是 x 和 y 的方差； σ_{xy} 是 x 和 y 的協方差。

$$\mathcal{L}_{SSIM} = - \sum_i \frac{(2u_{G_\theta(X_i)}u_{Y_i} + c_1)(2\sigma_{G_\theta(X_i)Y_i} + c_2)}{(u_{G_\theta(X_i)}^2 + u_{Y_i}^2 + c_1)(\sigma_{G_\theta(X_i)}^2 + \sigma_{Y_i}^2 + c_2)} \quad (9)$$

$$C_1 = (K_1 * L)^2, C_2 = (K_2 * L)^2 \quad (10)$$

E. 總損失函數

最後，本計畫針對 \mathcal{L}_{ROI} 、 $\mathcal{L}_{Adversarial}$ 、 $\mathcal{L}_{Content}$ 和 $\mathcal{L}_{Quality}$ 四種損失函數的誤差回傳進行權重加總，成為總損失函數(\mathcal{L}_{Total})結果，如公式(11)所示。

$$\mathcal{L}_{Total} = 5 \cdot \mathcal{L}_{ROI} + 1 \cdot \mathcal{L}_{Adversarial} + 10 \cdot \mathcal{L}_{Content} + 1 \cdot \mathcal{L}_{Quality} \quad (11)$$

這些權重的參數設置是根據訓練數據的初步實驗來選擇，程式也會在每一次迭代訓練後將各個損失函數分別乘上各自的權重後計算。透過上述的迭代訓練調整，

我們發現訓練完成的生成網路具有辨識影像中的器官面積、位置及以各種顏色區別的能力。我們也使用 ADAM[14]來優化生成網路和鑑別網路中的參數，並結合 Momentum 和 RMSprop 的特點後優化本研究的訓練網路。在生成網路中，ADAM 用於最小化總損耗值。而鑑別損失函數可通過 ADAM 調整鑑別網路中的對抗機率參數。

4. 建立全新 RS 檔案

當一張 CT 影像經過上述步驟後會產生一張完成器官圈選的 RT 影像，系統會將器官著色部分，也就是器官的面積及位置座標化並匯入一個 RS 檔中，形成一個全新的 RS 檔，其流程圖如圖 7 所示。



圖7、將RT影像的資訊寫入新的RS檔之流程圖

綜合以上研究方法，使用 RTGAN 深度學習演算法能將 CT 影像中的器官利用顏色圈選出來，不管是大面積的器官或是細微的神經都能精準描繪出來。本計畫所提出的方法不僅能減少醫院放射師及醫師在器官圈選上的疲勞和負擔，醫生也能準確的診斷並擬定合適的治療方針，有效提升放腫科的各案治療，降低錯誤診斷的風險。

(五) 實驗結果與探討

本計畫的實驗結果分為以下幾個部份進行討論。首先，介紹系統開發環境與使用工具，再來比較在不同參數下網路訓練結果。接著，我們針對實驗結果進行分析，包含訓練及測試的成功率及計算特異度和敏感度等。最後會介紹系統實作介面，並針對本計畫提出的方法與其他市面上的產品或方法進行比較。

1. 開發環境與使用工具

每一次的實驗都在相同的硬體配置環境下進行訓練及測試，其軟硬體配置規格如表 1 所示。本實驗使用 ADAM 優化器，並將 Batch 設為 15、激發函數設為 $5e-4$ 。

表 1、本計畫採用之軟硬體設備

軟硬體設備	
作業系統	Linux Ubuntu 18.04
CUDA 版本	10.0
Deep Learning framework	Tensorflow
CPU	Intel ® i9-9900X
RAM	64GB
GPU	Nvidia GeForce RTX 2080 Ti

2. 結果討論

在多次訓練的結果下，我們觀察到總損失函數值大約都在 50000 次迭代訓練下會收斂，因此本計畫將訓練設在 50,000 次迭代訓練時自動停止網路訓練，如圖 8 所示。根據圖 9，我們發現在 20000 次迭代訓練之前，其測試成功率從 0.85 急劇增加到 0.91，並在 26500 次迭代訓練後，其數值變化趨於平緩。

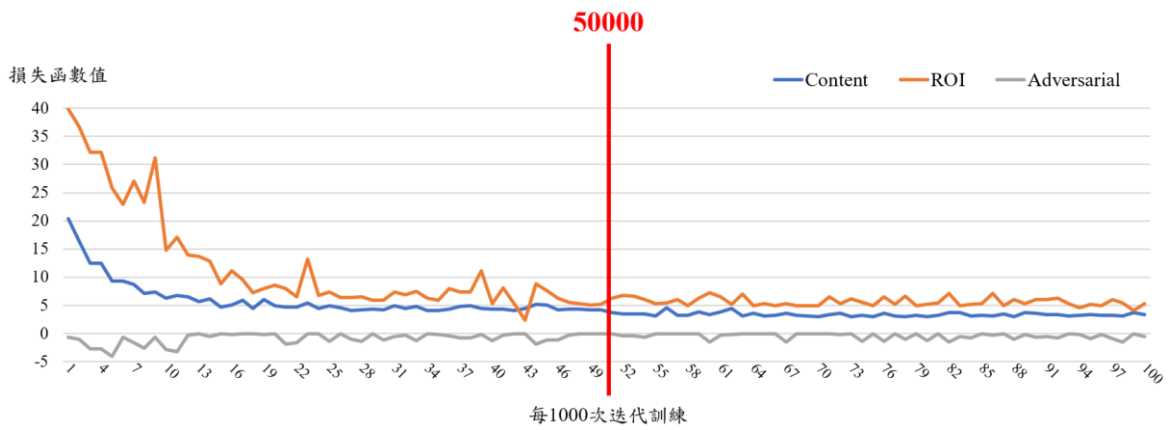


圖 8、折線圖：不同迭代訓練次數下損失函數之數值




圖 9、折線圖：不同迭代訓練次數下的訓練及測試成功率

在醫學影像上，通常會使用混淆矩陣之二分法將影像進行分類，分為四個數值：真陽性(TP)、假陽性(FP)、假陰性(FN)及真陰性(TN)，透過數值計算以得知敏感度及特異度。在本計畫中，將敏感度定義為正確將器官圈選出來、而特異度則定義為非器官位置卻以顏色或形狀進行圈選。以此定義為前提下，我們提出一個混淆矩陣來判定器官圈選的結果對與錯，如表 2 所示。

表 2、本計畫提出的混淆矩陣—以腦幹為例

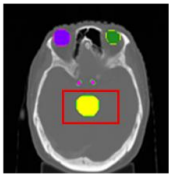
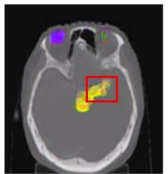
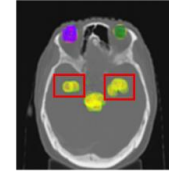
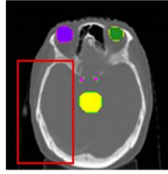
		Actual	
		Positive	Negative
Predicted	Positive	<p>TP</p>  <p>器官在正確位置上被圈選出來</p>	<p>FP</p>  <p>在不該有器官的位置上，卻有器官被圈選出來</p>
	Negative	<p>TN</p>  <p>器官在正確位置上被圈選出來，但是圈選結果是錯的</p>	<p>FN</p>  <p>在不該有器官的位置上，沒有器官被圈選出來</p>

表 3 列出在不同的迭代訓練次數下的訓練成功率、測試成功率、敏感度及特異度，我們得知在 50000 次迭代訓練下，本計畫的敏感度為 91.2%，這代表器官都有在正確的位置上被圈選出來。而特異度為 92.6%，這代表仍是有有一些不該被圈選出器官的位置還是有系統認為是器官而將之圈選出來。

表 3、訓練成功率、測試成功率、敏感度及特異度比較表

訓練迭代次數	訓練成功率(%)	測試成功率(%)	敏感度(%)	特意度(%)
10000	81.2	78.5	77.7	79.8
20000	84.9	81	80.5	83.7
30000	91.2	85.7	84.1	85.9
40000	93.6	87.4	89.3	91.4
50000	95.8	93	91.2	92.6

最後，我們從表 3 中得知測試成功率從 78.5% 提升至 93%，代表本計畫所提出的方法可以和放射師一樣在頭頸部 CT 影像中準確的進行器官圈選。我們也使用 SSIM 及 PSNR 兩個影像品質評估指標，計算生成影像與標準影像之相似度，分別得到分數為 0.984 和 31.26，如表 4 所示。

表 4、影像品質評估指標(SSIM 及 PSNR)比較表

訓練迭代次數	SSIM	PSNR
10000	0.953	28.37
20000	0.972	29.32
30000	0.98	29.78
40000	0.982	30.62
50000	0.984	31.26

3. 系統實作與介面展示

本系統的介面是使用 Python 內建的 Tkinter 函式庫實作，如圖 10 至 13 所示，且已於中山醫學大學附設醫院放射腫瘤科部門進行測試使用。

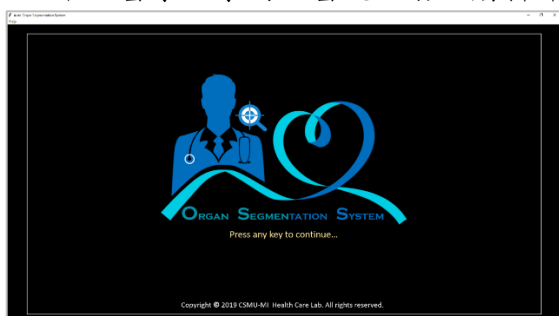


圖 10、系統首頁



圖 11、功能主頁面首頁

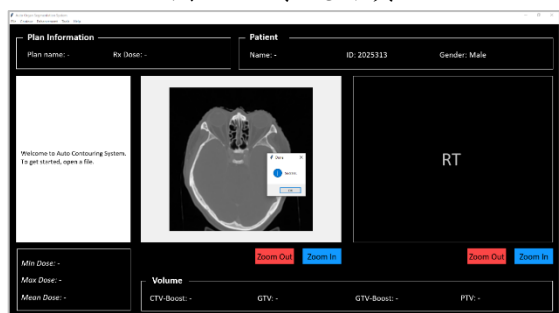


圖 12、跳出訊息框之介面圖



圖 13、完成器官圈選之介面圖

4. 比較與結果展示

為了驗證本計畫所提出的方法，我們將實驗結果與放射師手動圈選、Pinnacle3 醫用套裝軟體、U-net、CGAN 與 Cycle-GAN 等方法進行比較，如表 5 所示。經過綜合評比，以放射師手動圈選為滿分進行比較，發現本文提出的方法其敏感度及特異度為最高，平均每張影像所花費的測試時間也是六者之中偏少的，僅需 3 秒就能完成圈選一張頭頸部 CT 影像。因此，證明此方法不但可以有效減少醫學物理學師花費在圈選器官或治療標靶體的時間，也能提供醫師準確的圈選結果進行後續的診斷決策。

表 5、本計畫提出之 RTGAN 與其他方法之比較

方法	敏感度(%)	特意度(%)	圈選時間(秒/張)
手動圈選	100	100	45
Pinnacle 3	93.8	81.8	9
U-Net	86.5	90.6	4.3
CGAN	90.4	87.5	2.8
CycleGAN	63.7	61.6	1.5
RTGAN	91.2	92.6	0.058

最後，我們也將測試影像結果與其中三種方法的影像比較，如圖 14 所示，並可從圖中得知本計畫所提出的方法，其圈選結果是最近似於手動圈選的標準影像。

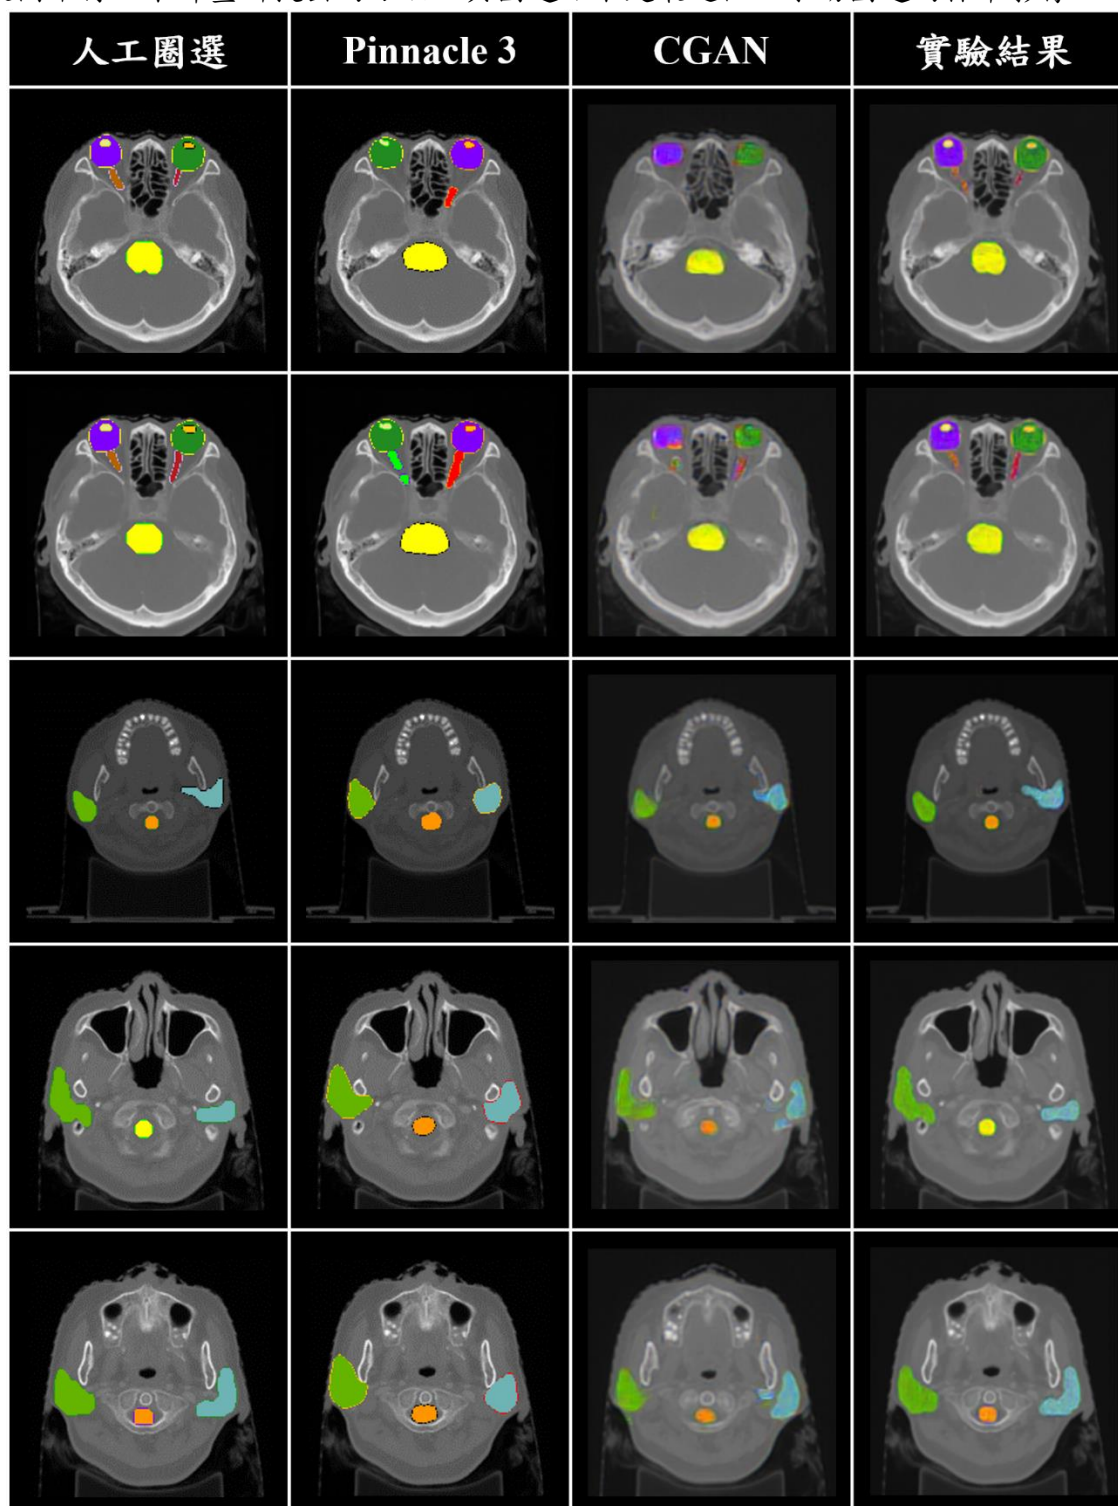


圖 14、不同方法之測試影像比較結果圖。

(六)結論

在 CT 影像中進行器官圈選及診斷十分仰賴有經驗的放射腫瘤科醫師和放射師的專業知識，而目前醫師的診斷方法為依據放射師所圈選的器官和腫瘤大小、形狀及體積來判斷化學治療藥物的劑量。但是長時間的圈選動作會造成醫師及放射師的負擔，若感到疲倦則容易發生誤判的狀況。為了解決以上的問題，本計畫開發 RTGAN，一個基於 GAN 的深度學習演算法，並應用在醫學影像的自動圈選器官上。使用了四個不同的損失函數和 ADAM 優化器來計算總損失函數值，透過迭代訓練最小化該數值。並在訓練過程中比較圈選的影像和標準影像以增加準確度，提升測試網路輸出的影像結果圖品質。希望未來能改良，進一步分辨器官是否有病變，並針對各個案例進行治療劑量的估算或協助其他種類的醫學影像診斷，大幅提升醫病存活率。

(七)參考文獻

- [1] MYY Law, B Liu, LW Chan (2009) Informatics in radiology: DICOM-RT-based Electronic Patient Record Information System for Radiation Therapy. *RadioGraphics* 29:912-922.
- [2] J Pipitone, MTM Park, J Winterburn et al (2014) Multi-atlas segmentation of the whole hippocampus and subfields using multiple automatically generated templates. *NeuroImage* 101:494-512.
- [3] B Ibragimov, L Xing (2017) Segmentation of organs-at-risks in head and neck CT images using convolutional neural networks. *Medical Physics* 44:547-557.
- [4] F Milletari, SA Ahmadi, C Kroll et al (2017) Hough-CNN: Deep learning for segmentation of deep brain regions in MRI and ultrasound. *Computer Vision and Image Understanding* 164:92-102.
- [5] L Bi, J Kim, E Ahn et al (2018) Step-wise integration of deep class specific learning for dermoscopic image segmentation. *Pattern Recognition* 85:78-89.
- [6] HR Roth, H Oda, X Zhou et al (2018) An application of cascaded 3D fully convolutional networks for medical image segmentation. *Computerized Medical Imaging and Graphics* 66:90-99.
- [7] L Jiao, H Wu, H Wang et al (2018) Multi-Scale Semantic Image Inpainting with Residual Learning and GAN. *Neurocomputing* 331:199-212.
- [8] D Mahapatra, B Bozorgtabar, R Garnavi (2019) Image super resolution using progressive generative adversarial networks for medical image analysis. *Computerized Medical Imaging and Graphics* 71:30-39.
- [9] S Banerjee, S Das (2018) LR-GAN for degraded Face Recognition. *Pattern Recognition Letters* 116:246-253.
- [10] Q Zheng, H Li, B Fan et al (2018) Integrating support vector machine and graph cuts for medical image segmentation. *Journal of Visual Communication and Image Representation* 55:157-169.
- [11] M Frid-Adar, I Diamant, E Klang et al (2018) GAN-based synthetic medical image augmentation for increased CNN performance in liver lesion classification. *Neurocomputing* 321:321-331.
- [12] K Seeliger, U Güçlü, L Ambrogioni et al (2018) Generative adversarial networks for reconstructing natural images from brain activity. *NeuroImage* 181:775-785.
- [13] IJ Goodfellow, J Pouget-Abadie, M Mirza (2014) Generative Adversarial Networks. *arXiv preprint arXiv:1406.2661*.
- [14] DP Kingma, JL Ba (2015) ADAM: A Method for Stochastic Optimization *arXiv preprint arXiv:1412.6980v9*.