

出國報告(出國類別:進修)

赴美國匹茲堡大學進修電機工程碩士 心得報告

服務機關：國防部軍備局第二〇二廠

姓名職稱：連毅軒上尉

派赴國家：美國

出國日期：108年8月9日至110年8月13日

報告日期：110年9月16日

摘要

本次進修係奉 108 年 7 月 10 日國人管理字第 1080010979 號令核定赴美國匹茲堡大學(University of Pittsburgh)進修電機與電腦工程碩士學位，進修期間自 108 年 8 月 9 日起至 110 年 8 月 13 日止。完成學業修業後於 8 月 13 日抵達臺，因應全球嚴重特殊傳染性肺炎(COVID-19)，返臺後即配合衛生福利部規定實施居家檢疫 14 日及自主健康管理乙週，並於 110 年 9 月 6 日返回原建制單位軍備局第二〇二廠報到。

本案報告內容主要為赴美國進修 2 年期間之學習過程及研究心得，綱要有目的、進修過程、心得與建議及參考資料來源等項，碩士期間研究機器學習相關主題，取得可與全球使用相同資料集相比的成果，並勝過使用相同基礎架構的模型，研究亦顯示使用移轉學習可有效降低模型訓練所需時間，當擁有足夠樣本數時，資料擴增技巧可避免模型過擬合，另生成對抗網路在樣本數有限下，仍可產出與真實樣本極近似的影像資料。進修期間所習得的機器學習與訊號處理相關知識與應用經驗，未來可用於目標影像識別、控制系統及數據分析等方面，此外，與來自不同文化與領域人士接觸交流後，獲得不同觀點並砥礪自己應持續精進學能。

目錄

壹、目的	3
貳、進修過程	3
參、心得與建議	15
肆、參考資料	17

壹、目的

本次係奉國防部 108 年 7 月 10 日國人管理字第 1080010979 號令，赴美國匹茲堡大學(University of Pittsburgh)進修電機與電腦工程碩士學位 2 年，研究項目係探討機器學習相關模型之應用，進修期間自 108 年 8 月 9 日起至 110 年 8 月 13 日止(含交通往返路程 5 日)，並於 110 年 8 月份達成碩士學位要求後取得碩士學位，於核定期間內返廠辦理報到手續。

本報告係依「行政院及所屬各機關出國報告綜合處理要點」相關規定撰擬，旨在提供進修經驗及論文研究心得予相關人員參考運用。

貳、進修過程

一、學校簡介

匹茲堡大學為美國賓夕法尼亞州匹茲堡的公立研究型大學，成立於 1787 年，為美國大學協會(Association of American Universities)成員之一，並在卡內基高等教育機構分類(Carnegie Classification of Institutions of Higher Education) 中被評為最高級別之 R1 學校，研究活動的質量非常高¹，並為美國國家衛生院研究經費之主要接收者，2018 年投入約 10 億美金在研究與相關發展，為該年度全美第 14 高之學校²。學校主校區位於匹茲堡奧克蘭地區，下轄文學院、商學院、工學院、公衛學院及護理學院等 16 個學院³，最具代表性建築為學習大教堂(Cathedral of Learning)，為 42 樓層高之哥德復興式建築，世界第二高的哥德式建築，亦為西半球最高之教學大樓⁴；另設有 4 個分校，分位於布拉福、格林斯堡、詹斯鎮及泰特斯維地區。

學校提供豐富軟硬體資源，學校網站可免費取得作業系統、文書處理及專業用途等工具軟體，學習大教堂內設有 31 個各具不同國家文化風格的教室，例如：英格蘭、德國、日本及土耳其等，除進行教學活動外，假日亦開放供名眾參觀，

為匹茲堡著名景點之一。

因應新冠肺炎疫情，校方自 109 年 3 月 20 日起僅允許必要人員得申請進入，其餘人員(含學生)限制進入各教學大樓及體育館等學校設施；3 月 23 日起所有課程改遠端方式，透過雲端視訊平台線上授課，9 月份起採現地與遠端方式並行的混合授課模式。

二、課程介紹

學業要求部分，電機與電腦工程研究所要求碩士生須在 5 個學年度內取得至少 30 個學分，進修期間共習得 38 學分；另分為修課與研究等兩個方向，畢業學分須自系上開設或指定之系外課程中獲得，否則不列入畢業學分計算；每門課的評分方式概分為等第制及合格制，等第制區分 A+, A, A-, B+, B, B-, C+, C, C-, D+, D, D-, F 計 13 個級別，其中 A+及 A 可轉換為點數 4.0，A- 為 3.75，其餘依序遞減至 0，合格制僅有通過與不通過 2 種評分，通過後即獲得全部學分，但無法轉換為點數計算。當獲得 12 學分以上且累計成績(QPA，為各門課成績點數的加權平均，滿分為 4.0)達 3.0，始得修論文研究課程，選擇研究方向者須撰寫論文並完成口試，口試合格後始授予學位，進修期間修習課程摘述如后：

(一) 學術寫作(3 學分)

課程主要協助非英語母語者在學術方面獲得研究所等級之語言能力，多數學生入學前雖已通過相關語言檢定門檻，該課程著重於培養學術方面的技巧，以利學生寫出結構完整、用詞清楚且簡潔的英文報告或文獻。課程透過文章分析、每週寫作作業及小組寫作等涉及個人、小組與全班間之活動，逐步提升寫作能力；此外，學術倫理亦為課程教學要項之一，學校對作弊或抄襲等違反學術倫理之行為採零容忍態度，課程教導學生應如何正確引用參考資料，另學校教學系統會自動檢查上傳之作業電子檔是否存有抄襲嫌疑。此課程對學術寫作的架構與規範很有幫助。

(二) 生物訊號模型與分析(3 學分)

主要學習如何使用數學模型識別一維與二維等各種生物訊號，並著重觀

念的理解及實作，於課程中操作 t 檢驗、排列檢定、廣義線性回歸模型、聲頻訊號時域與頻域轉換及計算相關值，以了解樣本間關係與模型之信心值；計算心電圖之 QRS 複合波、聲頻訊號之功率頻密度，及以短時傅立葉轉換與小波轉換分析聲頻訊號，學習訊號處理方法；進行聲頻訊號之功率譜密度計算與短時距傅立葉變換、以小波方法分析腦電波圖，及學習計算擴散磁振造影之非等向性指標；探討不同樣本間擴散磁振造影之關聯性，並以視覺化方式呈現連接矩陣；期末報告為利用不同個體的多張網路圖，擷取特徵以進行分群作業。透過該門課，能將理論與實際應用方式進行連接，瞭解不同生物訊號適用之處理方式。

(三) 機器學習(3 學分)

為學習機器學習相關方法、數學與演算法之研究所等級基礎課程，瞭解如何在電腦視覺、自然語言處理與資料探勘等科學應用情境中，採用適合的機器學習技巧，課程中實作單純貝氏分類器進行文字分類，學習線性判別；透過主成分分析法與線性判別分析降低資料維度，再分別以最近鄰居法及交叉驗證進行影像分類，俾了解與應用；實作線性及多項式核支援向量機，進行多類別人臉辨識，並實施交叉驗證，確保模型非過擬合；期末報告為實作 3 層式人工類神經網路(ANN)，進行英文字母與數字分類，模型若採用迷你批次方式及可調適學習率，可加快訓練與模型收斂過程。於此課程獲得全面性的機器學習相關知識，在不使用既有函示庫下，編寫各機器學習方法，更能加深記憶。

(四) 數位訊號處理(3 學分)

學習廣泛應用於各領域中之連續時間數位訊號處理，範圍涵蓋離散時間訊號數學分析、快速傅立葉轉換原理，且包含相關應用練習及專題報告，例如：離散時間訊號基本序列、離散時間系統分類、以頻域或傅立葉轉換表示法及取樣方式；Z 變換及線性非時變系統之變換分析，俾了解線性非時變系統之特性，及輸入與輸出訊號間之關係；離散傅立葉轉換及其特性，以處理

有限長週期性訊號，並實作逆梳形濾波器，模擬聲波反射現象；無限脈衝響應濾波器及有限脈衝響應濾波器之設計，以應用於線性時間不變量系統，並透過雙線性轉換實作離散濾波器。在課程中深入學習傅立葉轉換，對時域與頻域的訊號處理有進一步的認知。

(五) 進階神經成像訊號模型化與分析(3 學分)

課程著重於神經訊號相關之統計理論與實作，主題橫跨傳統方法與現代方法，並包含統計推論、假設與信心限制等基礎介紹，課內介紹的方法摘述如后：學習多峰資料分析方式，以降低僅透過單峰資料造成之分析偏差，並提升模型性能；學習潛在類別分析，利用分類變數或連續變數建立模型，並描述無法直接觀察量化之資料分布情形；使用因素分析預測連續性潛在變數，其與潛在類別分析均用於描述無法直接觀測的複雜模式，惟因素分析屬降低資料維度方法；透過主成分分析及堆疊回歸法建立模型，預測神經成像特徵與特定主體變數間的關係。於課程中瞭解神經成像訊號不同的處理方式，以及各分析方法適合的使用時機。

(六) 進階機器學習(3 學分)

為機器學習之進階課程，著重於相關數學演算法，例如：隨機梯度下降等最佳化方法，以降低深度類神經網路的計算成本，並減少模型擬合所需訓練時間；以統計角度研析機器學習，透過機率思辨方式觀察模型、學習定律及演算法，並學習圖形類神經網路，俾有效處理具關連性的圖資料；藉由類神經網路隱藏層之批次正規化，降低因輸入資料數值分佈不同所致的共變量偏移，俾提升訓練模型準確度及減少模型擬合所需訓練時間；平行運算隨機梯度下降演算法，透過使處理器存取共享記憶體並允許複寫其他成員之運算結果，以避免發生鎖定情形，同時提升運算效能。該課程介紹許多近 5 年的著名研究文獻，例如批次正規化，對論文研究非常有助益。

(七) 計算機組織(3 學分)

課程中介紹處理器效能指標、消耗功率、性能評估、及指令平行處理和

其可能問題與改善方式；透過換名暫存器、重序緩衝器及分支預測等方式，提升指令處理效能；學習快取及記憶體運作方式，以解決資料局部性衍生之存取延遲問題。課程目標為使學生瞭解處理器設計之理論背景，如何透過資料處理、控制邏輯、記憶體與平行系統，組織數十億個半導體以實作指令集架構。在課程中實際編寫托馬蘇洛算法，瞭解指令排程優化方式。

(八) 資訊安全(3 學分)

主要涵蓋電腦系統、網路與人因層級之資訊安全技術與理論，例如：觀察 Cookie 相關實作，及實作非對稱式與對稱式加密方法，以瞭解網路廣告紀錄和追蹤方式，並獲得演算法相關操作經驗；防火牆運作方式與阻斷服務攻擊，藉由實作封包過濾器及 TCP/IP 協定相關攻擊，瞭解基本漏洞特徵；說明緩衝器溢位與格式字串弱點等攻擊原理。透過此課程，進行多樣資訊安全相關實作，瞭解漏洞特徵與預防措施。

(九) 模式識別(3 學分)

主要介紹統計學習與模式識別之理論，課程透過深入的理論講解，使學生理解相關機率模型與其應用，例如：如何選擇適合資料之分類器，並分析產出結果是否具相關價值及其信心區間；學習邏輯式迴歸，並實作梯度下降、紐頓梯度下降及隨機梯度下降等演化法，以瞭解最大可能性預測之相關處理方式。於課程中瞭解到以統計為基礎情況下，衍生出的模式識別方法與其推導方式。

三、論文研究

(一) 摘要

隨著科技發展，近年電腦輔助系統的進步，可自動從重點區域擷取特徵並進行預測，降低侵入式程序可能衍生的風險⁵⁻¹⁰，現已提出多種使用影像特徵進行自動化評估的深度學習方法。研究目的為建立卷積神經網路模型，模型包含影像前處理及使用有限數量之標記樣本的轉移學習，並透過公開資料集，檢視資料增強的有效性，模型評估結果的平均誤差約 5.8 個月，90%

以上評估的誤差小於 1 年；另進一步研究當樣本數不足時，生成對抗式網路能否有效防範模型過擬合。

(二) 背景介紹

1、 影像處理

多數電腦系統均透過去背程序，減少噪點及目標區外的部位，因這些區域不存有切合的資訊，且可能對影像分析系統造成負面影響，進而降低效能¹¹⁻¹²。

定限法為將大於或小於設定值的影像密度，取代為特定數值，因其有效且簡單而被廣泛使用，常見類型為全域定限及區域定限¹⁵。全域定限主要基於影像數值有雙峰直方圖的假設，影像中的目標可透過與一定值的背景像素值進行比較，當大於目標閾值則將該像素數值設為 1，若小於則設為 0，其結果為二次元成像¹⁶。區域定限法將影像劃分為數個子區域，每個子區域均會選出一個目標閾值並與同區域像素進行比較¹⁶，此方法可解決影像亮度不平均分布的情況¹⁵，然而子區域的範圍大小是全域固定，很難找到最佳的設定值。區域適應定限則透過滑動窗口來計算目標閾值，Sauvola's 法為常見技巧之一，其藉由計算像素周圍窗口的均值及標準差來設定定限¹⁵。

直方圖等化法為調整影像密度分布以進行影像增強的方式，目標是將原密度分布變換至平均分布型態。CLAHE 為一種適應直方圖等化法的方法，此法主要基於將影像劃分為數個不重疊且大小幾乎一致的區域，限制區域的對比增益，以減少雜訊並達到直方圖正規化¹⁷。

2、 機器學習

人工類神經網路起發自人類大腦運作機制，主要由神經元與神經結組成，神經元為可平行運作的處理單元，各神經元間的資訊透過神經結來連結傳遞，在 1960 年代此網路稱為感知器網路，感知器模型會將與神經元連結的所有神經元所帶的值，乘上神經結的權重，加總結果即該神經元的

值，此外，同一階層的神經元可組成神經層，它們接收前一層的數值作為輸入，輸出則是下一層神經元的輸入，此種模型則稱為多層感知器¹⁸。

卷積神經網路為多層網路的一種演變，其各層間的單元未與網路的輸入單元完全連結，而是與輸入的小子集合連結，主要概念是將輸入空間的特徵以更顯著的區段方式進行結合，直到某一層可看到整個輸入，同時特徵數量會越來越少且更抽象¹⁸。

U-Net 是常用於影像分割的卷積神經網路，模型架構為對稱式且主要由編碼器與解碼器組成，兩者基本結構與一般卷積神經網路相似(如附圖 1)，但在編碼器中，特徵通道數在每一個降低取樣步驟中會增加為兩倍，在解碼器中，特徵通道數則在每一個增加取樣步驟中會減少至一半，另外編碼器的特徵圖繪會與解碼器增加取樣步驟的輸出結合，使內容資訊可傳遞至解碼器的後續階層¹⁹。

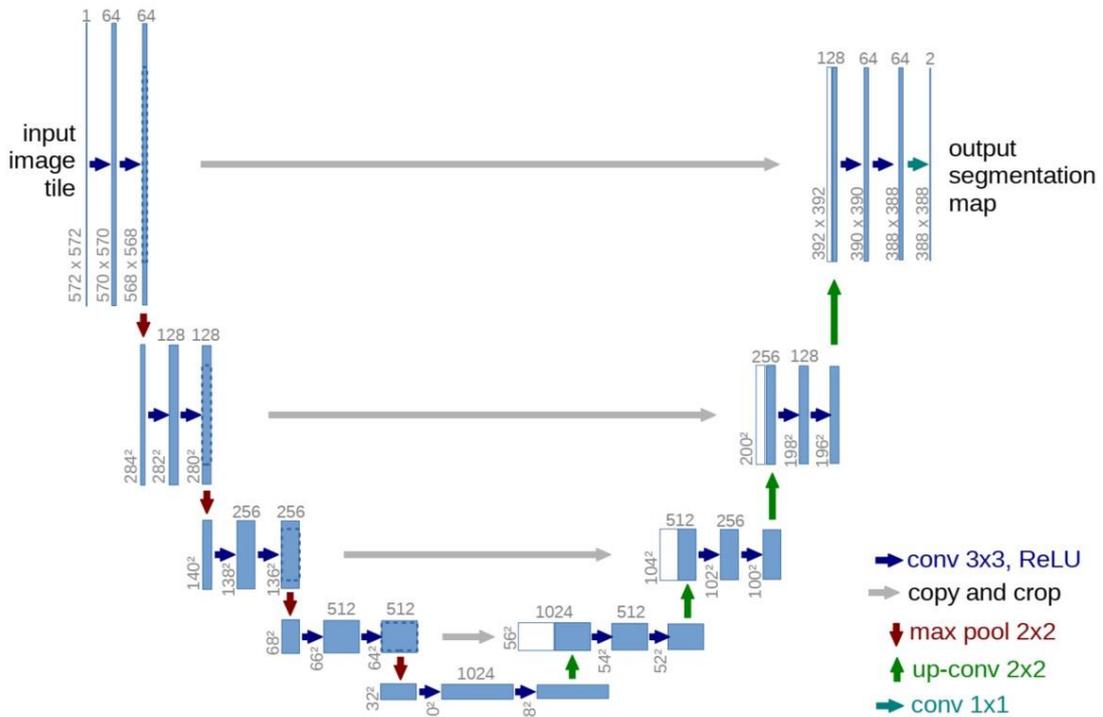


圖 1、U-Net 網路架構圖¹⁹

DenseNet 為另一種卷積神經網路，一般 N 層的卷積神經網路會有 N 個連結，但 DenseNet 區塊內的階層以前饋方式連結，前導層與接連層以元素方面連結而非相加(如附圖 2)，因此僅有 $\frac{N(N+1)}{2}$ 個連結，提升資訊流動並減少網路參數數量，可有效處理深度類神經網路梯度消失的問題²⁰。

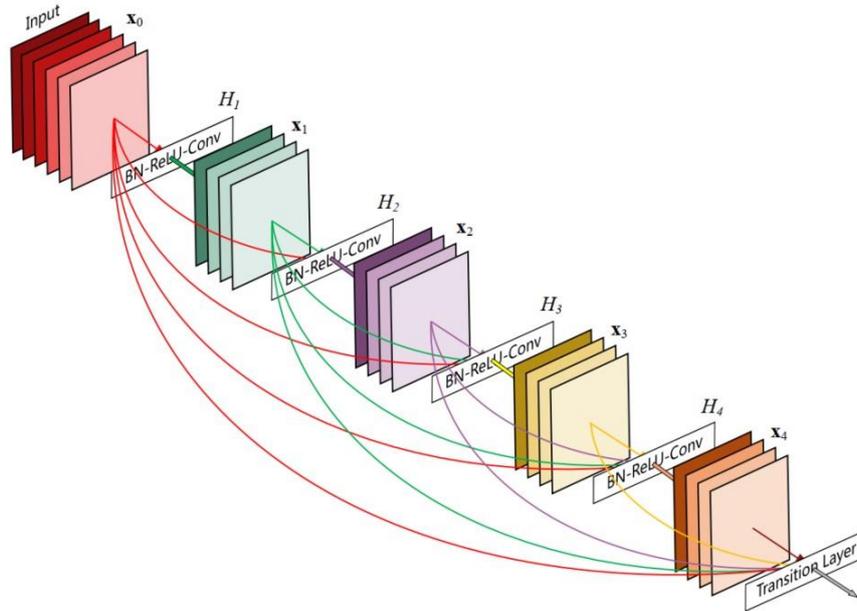


圖 2、DenseNet 結構圖²⁰

生成對抗式網路主要由一個生成模型及一個區別模型構成，生成模型的目標是學習資料的分布狀態並製造偽資料，區別模型則是評估輸入資料是來自真實集合或是生成器產出的偽資料，兩個模型以零和賽局的方式互相對抗²¹。

過擬合為模型記住訓練資料集並學習到樣本內不相關資訊的情形，模型在處理未曾看過資料時，效能會顯著下降，因此使用越少資料訓練模型，越容易導致過擬合，資料擴增為解決過擬合的方式之一，其可增加樣本的多樣性，但在訓練生成對抗式網路的過程中加入雜訊，恐影響模型學習資料分布，並破壞生成器與區別器間細緻的平衡，適應性區別器擴增法為解

決方式之一，對所有真實影像與生成影像進行資料擴增，這些影像都會用於訓練生成器及區別器，訓練生成器時，使用標準可微分基元於微分擴增，區別器的輸出則由過擬合試探法進行量測，並藉此調整資料擴增的幅度²²。可微分擴增法為另一種採用類似策略的解決方式，訓練生成器與區別器時，均對真實與生成資料實施資料擴增，擴增方式仍為可微分，因此擴增資料的梯度可向遞給生成器²³。

3、效能指標

準確度(ACC)為表示正確預測樣本在所有樣本間的比例，常用於評估二元分類器的辨識效能，計算公式如下：

$$\text{準確度} = \frac{\text{真陽性} + \text{真陰性}}{\text{真陽性} + \text{真陰性} + \text{偽陽性} + \text{偽陰性}}$$

Fréchet Inception 距離(FID)為比較生成影像與真實影像間的方式，其計算兩個多變數常態分布間 Wasserstein 指標的平方，數值越小表示真實與生成影像間的激發分布越近，計算公式(μ_r, μ_g 為真實影像與生成影像的平均值， Σ_r, Σ_g 為真實影像與生成影像的方差)：

$$\text{FID} = |\mu_r - \mu_g|^2 + \text{tr} \left(\Sigma_r + \Sigma_g - 2\sqrt{\Sigma_r \Sigma_g} \right)$$

(三) 研究方法

1、研究資料

使用的公開資料集來自北美放射協會 2017 年機器學習競賽，內有 1 萬 2,611 張訓練影像、1,425 張驗證影像及 200 張測試影像，以及每張影像的基準真相與真實資訊，基準真相為 6 位檢閱者的評估結果，並進行校正後的數值²⁴。

2、資料前置處理

首先使用 U-Net 分割網路進行背景去除作業，使用越多標記資料，越容易取得較好的分割結果，但需要耗費大量標記成本，因此自訓練集內隨機挑選 500 張影像進行標記，並將 U-Net 網路的編碼器更換為事先用 ImageNet 資料集訓練過的 RegNetX 骨幹，以提升訓練效率，接著保留 U-Net 網路產出中有最多連接單元的遮罩，再套用至資料集去除背景。

接著對分割後的影像進行直方圖等化以提升影像對比，等化過程中使用雙線性差值法去除邊緣的瑕疵，接著使用邊緣演算法計算手部輪廓，並定位出特定位置，藉由其他定位出的參照標的及一固定定位點，計算將距離特定位置最遠的定位標誌，旋轉自影像最上方所需的角度的角度，再裁切旋轉後影像的邊緣，縮放為 256x256 像素。

3、預測網路

評估網路主要基於 DenseNet 網路架構及輔助分類器生成對抗網路 (ACGAN)，所有瓶頸區塊與傳遞區塊皆配有批次正規化及非線性整流，輸入模型影像資料為固定大小(256x256 像素)，標籤嵌入至 1x1 大小的矩陣，並與平均集化層的輸出連接後，作為第一個線性層的輸入，此網路最終有兩個輸出，一個用於判斷輸入影像是真實或生成，另一個用於預測數值(如附表 1)，模型網路的總參數量約為 1,760 萬。

表 1、預測網路結構表

Layers	Kernel	Strides	Padding	Output size	Activation
Convolution	7×7	2×2	1×1	[batch, 64, 126, 126]	-
MaxPooling	3×3	2×2	0	[batch, 64, 62, 62]	-
Bottleneck Block (1)	$\begin{bmatrix} 1 \times 1 \\ 3 \times 3 \end{bmatrix}$	$\begin{bmatrix} 1 \times 1 \\ 1 \times 1 \end{bmatrix}$	$\begin{bmatrix} 0 \\ 1 \times 1 \end{bmatrix}$	[batch, 448, 62, 62]	ReLU
Transition Block (1)	1×1	1×1	0	[batch, 448, 31, 31]	ReLU
Bottleneck Block (2)	$\begin{bmatrix} 1 \times 1 \\ 3 \times 3 \end{bmatrix}$	$\begin{bmatrix} 1 \times 1 \\ 1 \times 1 \end{bmatrix}$	$\begin{bmatrix} 0 \\ 1 \times 1 \end{bmatrix}$	[batch, 832, 31, 31]	ReLU
Transition Block (2)	1×1	1×1	0	[batch, 832, 15, 15]	ReLU
Bottleneck Block (3)	$\begin{bmatrix} 1 \times 1 \\ 3 \times 3 \end{bmatrix}$	$\begin{bmatrix} 1 \times 1 \\ 1 \times 1 \end{bmatrix}$	$\begin{bmatrix} 0 \\ 1 \times 1 \end{bmatrix}$	[batch, 1216, 15, 15]	ReLU
Transition Block (3)	1×1	1×1	0	[batch, 1216, 7, 7]	ReLU
Bottleneck Block (4)	$\begin{bmatrix} 1 \times 1 \\ 3 \times 3 \end{bmatrix}$	$\begin{bmatrix} 1 \times 1 \\ 1 \times 1 \end{bmatrix}$	$\begin{bmatrix} 0 \\ 1 \times 1 \end{bmatrix}$	[batch, 1600, 7, 7]	ReLU
Transition Block (4)	1×1	1×1	0	[batch, 1600, 3, 3]	ReLU
Bottleneck Block (5)	$\begin{bmatrix} 1 \times 1 \\ 3 \times 3 \end{bmatrix}$	$\begin{bmatrix} 1 \times 1 \\ 1 \times 1 \end{bmatrix}$	$\begin{bmatrix} 0 \\ 1 \times 1 \end{bmatrix}$	[batch, 1984, 3, 3]	ReLU
Average Pooling	3×3	3×3	0	[batch, 1984, 1, 1]	ReLU
Linear (1)	-	-	-	[batch, 1]	Tanh
Linear (2-1)	-	-	-	[batch, 1000]	LeakyReLU
Linear (2-2)	-	-	-	[batch, 500]	LeakyReLU
Linear (2-3)	-	-	-	[batch, 229]	-

4、實驗設定

實驗中使用 Adam 最佳化器(學習率為 0.0002，第一與第二慣量預測子分為 0.5 與 0.999)訓練模型，迷你批次量為 32，影像通道數為 1，類別數為 229，生成批次的中央處理器執行序數為 8，並使用所有的訓練、驗證及測試資料集，程式運行於 Pytorch 框架和一張 NVIDIA Tesla P100 顯示卡。

此外，為了模擬訓練資料集不足的情境，將資料數值四捨五入至整數位後，分層選取百分之十的訓練資料集，由於各資料群的樣本數不同，採樣數量上限訂為 50，最後自 1,262 張影像中擷取出 917 張做為 StyleGAN2 的訓練資料。

(四) 實驗結果

當使用所有的訓練資料集，有使用變換的模型取得最佳結果(平均誤差為 5.8 個月、均方根誤差為 7.3 個月、誤差一年內準確率超過 90%)，當僅使用百分之十的訓練資料集，未使用變換的基本模型結果比另外兩種佳(平均誤差為 9.5 個月、均方根誤差為 12.5 個月、誤差一年內準確率為 72%)，此外，使用生成對抗式網路的模型效能表現，優於使用變換的模型(如附表 2)。

與其他使用相同測試資料集的評估模型比較，研究取得可與之相比的成果，並勝過同樣使用 DenseNet 為基礎的模型(如附表 3)。

表 2、各實驗設定結果表

Model	MAE		RMSE		ACC		ACC	
	(months)		(months)		(Within 1 year)		(Within 2 years)	
	(100%)	(10%)	(100%)	(10%)	(100%)	(10%)	(100%)	(10%)
Base (baseline)	7.425	9.48	9.459	12.5	82.5%	72%	99%	96%
+Transform	5.805	14.62	7.296	18.81	92%	50.5%	99.5%	80.5%
+GAN	-	12.5	-	15.79	-	55.5%	-	89%

MAE=Mean Absolute Error; RMSE=Root Mean Square Error; ACC=Accuracy

表 3、與其他模型結果比較表

Item	Method	MAE
1. Alexander et al. [21]	Inception V3	4.2 months
2. Igloukov et al. [10]	VGG	5 months
3. Proposed	DenseNet+Transformation	5.8 months
4. Zhao et al. [12]	DenseNet	male: 6 months female: 6.3 months
5. Pan et al. [11]	CNN	7.4 months

參、心得與建議

一、修課學習

進修期間，學校課程不完全以作業考試的結果來決定該門課的成績，課堂出席狀況或課程參與度，幾乎在每門課中都佔有一定比例，藉此鼓勵同學積極參與課程討論，並有效提供相關回饋，另外有的課會在每堂開始前進行點名，除加深印象外，亦透過基本問候增進授課教授與同學間互動。惟 109 年起受新冠肺炎影響，改以遠端視訊方式授課，人與人間的互動性因而降低，有教授採取主動點人回答問題方式，每個人通常每堂課都會被點到一次，其積極主動的教學態度可供效法。

除了作業與考試外，不少課程還有小組報告等需要同學間相互合作的專題，並有同儕互評的機制，教授會提供評鑑項目與指標供同學參考，藉此有效呈現成員的貢獻度，降低齊頭式給分可能衍生的勞役不均現象。

二、學術研究

研究過程充滿困難與挑戰，一個現象背後成因可能涉及多個領域與不同面向，

例如：論文研究使用醫學影像進行年齡評估，對於工程領域的人而言，首要目標是建立準確的評估模型，誤差越小表示模型越佳，不會深入探究模型處理的過程，取得的結果才是最重要的部分，但對於醫學領域，評估模型的準確度固然重要，但模型使用哪些特徵進行評估作業，反而會是更加關注的要項，其可藉由醫學領域相關知識，判斷使用該特徵是否合理。因此不同領域研究人員分析問題的觀點與使用的方法也不盡相同，各領域有其著重的項目或廣泛接受的指標，與不同領域人員接觸交流後，原先認知的正確標準，在對方觀點中可能並不合理，因此需要不斷學習與溝通，始能相互理解，藉此不斷精進自身能力。

三、生活文化

美國同樣有醫療保險可用於支付昂貴的醫療費用，但在自由經濟模式下，一般成年人需自行選擇保險公司以及方案，保險給付內容依方案調整，此外保險公司與醫院的合作結盟關係亦影響給付比例，以進修期間參保學校的一般學生醫療險為例，每月保費約為 225 美金，在有結盟與為結盟的醫院分須先負擔 250 美金及 500 美金，若該筆醫療費用高於前述自付額，則需再分負擔超額部分的 10%及 30%，若有加保牙醫及眼科保險，每月保費計約 250 美金，此外，學校亦提供研究生醫療險，在有結盟的醫院雖無自付額，除掛號費外，其餘費用均由保險公司承擔，但每月須繳交約 380 美金的保費，相比我國全民健康保險體制，在美國能獲得的醫療資源與個人經濟狀況有強烈關聯，費用較高且無法廣泛照顧全體國民，但擁有更多資源可投入先進技術研究。

民間保險公司也有提供相關醫療保險，每月保費較低，但自付額度與比例均較高，經濟情況許可下，仍建議未來進修人員優先考慮學校醫療保險，始能獲得較全面性的保障。

四、未來應用

隨著科技進步，可收集與儲存的數位訊號之種類及數據量越來越多，不斷有創新或更有效率的資料處理方法與技術被提出，同時處理設備的硬體效能也有顯著提升，過去處理過程需耗費數天或數小時，現在甚至可縮減至數分鐘，進修期

間所學機器學習與訊號處理相關知識與應用經驗，未來可用於目標影像識別、控制系統及數據分析等，例如在工廠生產方面，先進影像處理技術可協助辨識產品外觀是否存有人類眼睛無法察覺或是無法直接識別的疵病，另藉由相關技術，生成對抗式網路能在有限訓練資料下，取得與透過豐富資料集訓練之模型相比的效能，且能無限生成資料供模型訓練用；此外，自動化生產設備將提供更多的數據，透過統計分析、模式識別與機器學習方法，相關模型可將難以解讀的龐大原始數據，轉換為可應用的資訊，除供決策者作為後續規劃參考外，亦可快速適應多變的需求做出預測，並即時檢視原物料庫存等資訊後，提供有關建議，以提升生產作業效能。

肆、參考資料

1. Classifications: University of Pittsburgh-Main Campus.
<http://www.carnegiefoundation.org/classifications/sub.asp?key=748&subkey=16063&start=782>.
2. Table 20. Higher education R&D expenditures, ranked by FY 2018 R&D expenditures: FYs 2009 – 18.
<https://ncesdata.nsf.gov/herd/2018/html/herd18-dt-tab020.html>.
3. University of Pittsburgh: Home. <https://www.pitt.edu/>.
4. University of Pittsburgh - Wikipedia.
https://en.wikipedia.org/wiki/University_of_Pittsburgh.
5. Cao F, Huang HK, Pietka E, Gilsanz V. Digital hand atlas and web-based bone age assessment: System design and implementation. *Comput Med Imaging Graph.* 2000;24(5):297-307.
doi:10.1016/S0895-6111(00)00026-4
6. Zhang A, Gertych A, Liu BJ. Automatic bone age assessment for young children from newborn to 7-year-old using carpal bones. *Comput Med Imaging Graph.* 2007;31(4-5):299-310.
doi:10.1016/j.compmedimag.2007.02.008
7. Shobha Rani N, Yadhu CR, Karthik U. Chronological age assessment based on wrist radiograph processing - Some novel approaches. *J Intell Fuzzy Syst.* 2021;40(5):8651-8663. doi:10.3233/JIFS-190779
8. Sotoca JM, Iñesta JM, Belmonte MA. Hand bone segmentation in radioabsorptiometry images for computerised bone mass assessment.

- Comput Med Imaging Graph.* 2003;27(6):459-467.
doi:10.1016/S0895-6111(03)00053-3
9. Liu J, Qi J, Liu Z, Ning Q, Luo X. Automatic bone age assessment based on intelligent algorithms and comparison with TW3 method. *Comput Med Imaging Graph.* 2008;32(8):678-684.
doi:10.1016/j.compmedimag.2008.08.005
 10. Pietka E, Gertych A, Pospiech S, Cao F, Huang HK, Gilsanz V. Computer-assisted bone age assessment: Image preprocessing and epiphyseal/metaphyseal ROI extraction. *IEEE Trans Med Imaging.* 2001;20(8):715-729. doi:10.1109/42.938240
 11. Rubin DL, Greenspan H, Brinkley JF. Biomedical imaging informatics. *Biomed Informatics Comput Appl Heal Care Biomed Fourth Ed.* 2014:285-327. doi:10.1007/978-1-4471-4474-8_9
 12. Yan CH. *Segmentation of Hand Bone for Bone Age Assessment.*; 2013. doi:10.1007/978-981-4451-66-6
 13. Bayer LM. RADIOGRAPHIC ATLAS OF SKELETAL DEVELOPMENT OF THE HAND AND WRIST: Second Edition. *Calif Med.* 1959;91(1):53.
<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC1577858/>.
 14. Forfar JO. Reviewed Work(s): Assessment Of Skeletal Maturity And Prediction Of Adult Height by J. M. Tanner, R. H. Whitehouse, W. A. Marshall, M. J. R. Healy and H. Goldstein. *Br Med J.* 1976;1(6018):1153. doi:10.1136/bmj.1.1203.118
 15. Shafait F, Keysers D, Breuel T. *Efficient Implementation of Local Adaptive Thresholding Techniques Using Integral Images.* Vol 6815.; 2008. doi:10.1117/12.767755
 16. Lee SU, Yoon Chung S, Park RH. A comparative performance study of several global thresholding techniques for segmentation. *Comput Vision, Graph Image Process.* 1990;52(2):171-190.
doi:10.1016/0734-189X(90)90053-X
 17. Pizer SM, Amburn EP, Austin JD, et al. Adaptive Histogram Equalization and Its Variations. *Comput vision, Graph image Process.* 1987;39(3):355-368. doi:10.1016/S0734-189X(87)80186-X
 18. Alpaydin E. *Machine Learning: The New AI.* Cambridge: MIT Press; 2016.
 19. Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation. *Lect Notes Comput Sci (including Subser Lect Notes Artif Intell Lect Notes Bioinformatics).* 2015;9351:234-241. doi:10.1007/978-3-319-24574-4_28
 20. Huang G, Liu Z, Van DerMaaten L, Weinberger KQ. Densely connected

- convolutional networks. *Proc - 30th IEEE Conf Comput Vis Pattern Recognition, CVPR 2017*. 2017;2017-Janua:2261-2269.
doi:10.1109/CVPR.2017.243
21. Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks. *Commun ACM*. 2020;63(11):139-144. doi:10.1145/3422622
 22. Karras T, Aittala M, Hellsten J, Laine S, Lehtinen J, Aila T. Training Generative Adversarial Networks with Limited Data. *NeurIPS*. 2020;(NeurIPS). <http://arxiv.org/abs/2006.06676>.
 23. Zhao S, Liu Z, Lin J, Zhu J-Y, Han S. Differentiable Augmentation for Data-Efficient GAN Training. 2020;(NeurIPS).
<http://arxiv.org/abs/2006.10738>.
 24. Halabi SS, Prevedello LM, Kalpathy-Cramer J, et al. The RSNA pediatric bone age machine learning challenge. *Radiology*. 2019;290(3):498-503.
doi:10.1148/radiol.2018180736