

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BI-CNN進行婦女乳房鈣化點群聚偵測及良惡預測

執行計畫學生：魏嘉芯
學生計畫編號：MOST 109-2813-C-040-014-E
研究期間：109年07月01日至110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 110年03月25日

科技部補助
大專學生研究計畫研究成果報告

計 畫

： 基於 BI-CNN 進行婦女乳房鈣化點群聚偵測及良惡預測

名 稱

執行計畫學生： 魏嘉芯

學生計畫編號： 109-2813-C-040-014-E

研究期間： 109年07月01日至110年02月28日止，計8個月

指導教授： 秦群立

處理方式：立即公開查詢

涉及專利或其他智慧財產權，一年二年後可公開查詢

執行單位：中山醫學大學醫學資訊學系

中華民國 110 年 03 月 27 日

(一) 摘要

現今婦女的乳房狀況皆由醫師觀察乳房攝影影像後進行初步診斷，但乳房鈣化點十分微小，有時甚至醫師也無法一眼可見，往往需放大觀察才可進行判斷，若發現疑似惡性鈣化點群聚，會建議病患於有疑似惡性鈣化點群聚處進行穿刺切片檢測，進一步得知為良性或惡性群聚，但穿刺切片檢測為侵入性治療，除了會於病患身上留下傷口與疼痛感外，還會使病患因擔心而無法立刻接受檢查，導致乳癌患者無法立即確診而延遲治療時間。

為解決上述問題，本計畫建置出「基於 BI-CNN 進行婦女乳房鈣化點群聚偵測及良惡預測」系統，並與中山醫學大學醫學影像部醫師合作，透過乳房穿刺影像及醫囑得知群聚位置及其良惡狀況，作為訓練的目標資訊。利用 Gathering CNN 偵測乳房攝影影像中鈣化點群聚處，再將群聚鈣化點輸入 Mask R-CNN 分類群聚中鈣化點的良惡，最終於本計畫自建的使用者圖形介面中將乳房攝影影像上的良性鈣化點標記為綠色，惡性鈣化點標記為紅色。Gathering CNN 中的全卷積神經網路(FCN)透過滑動視窗產生接近於群聚鈣化點的候選框，並利用 ISODATA 分類法將候選框進行分類與融合，其中還加入損失函數及 IoU 檢測等方法，透過回傳數值以重新調整類神經網路權重值，提高系統準確率。本計畫希望藉由大量的資料集及完善的類神經網路架構，能夠提供醫師更多的診斷資訊，也希望透過精準的分析使病患不須穿刺切片檢測也能得知鈣化點良惡，減輕病患及醫療人員的負擔。

(二) 研究動機與研究問題

乳癌為我國婦女罹患率第一位之癌症，無論婦女或醫療單位皆十分重視且謹慎追蹤，而乳房攝影為目前主要的乳房篩檢方法，透過醫師觀察乳房影像中微小鈣化點的大小、分布及形狀來初步判斷為良性或惡性。依據醫師經驗指出，良性鈣化點在影像中的特性為大、分散且形狀為似圓狀，惡性鈣化點通常具有微小、聚集且不規則狀等特性，如圖 1 所示。當有惡性鈣化點的疑慮時，須配合侵入性的穿刺切片檢查，進一步確認是否為乳癌細胞或其分泌物壞死所導致的惡性鈣化點。為了更了解現況及需求，本計畫與中山醫學大學附設醫院醫學影像部合作，並實際訪問專業醫師，醫師表示惡性鈣化點於群聚鈣化點中的機率甚高，而當醫師透過乳房 X 光影像中找出疑似惡性乳房鈣化點群聚處，會立即告知病患進行進一步的檢測，現今檢測方法為穿刺切片取樣檢測，但經常發生以下問題：

1. 為侵入性檢測，會於患者乳房上留下傷口及疼痛感。
2. 病患得知需做切片治療的資訊後，往往會經過一段漫長的考慮時間、完善的心理準備，甚至於不同醫院照攝影像及診斷後，才會同意接受檢查，過程中可能延遲乳癌的確診與後續的治療。
3. 若為乳癌患者，無法於立即發覺進而治療。

為解決上述問題，本計畫開發出「基於 BI-CNN 進行婦女乳房鈣化點群聚偵測及良惡預測」系統，期望達到以下目標：

1. 透過自動分析乳房攝影影像來找出群聚中的惡性鈣化點。
2. 無須穿刺切片檢測便能找出病灶位置，降低病患心理負擔及省去侵入性治療造成的疼痛感。
3. 大量分析資料及強大的神經網路分析出可靠數據，提高患者認同感，加速患者考慮時間，盡早接受治療。
4. 快速分析及精準辨識，提供醫師參考資訊，使醫師更有把握進行診斷，且不易錯過微小鈣化點，有效輔助醫師診斷，並加速診療時間。

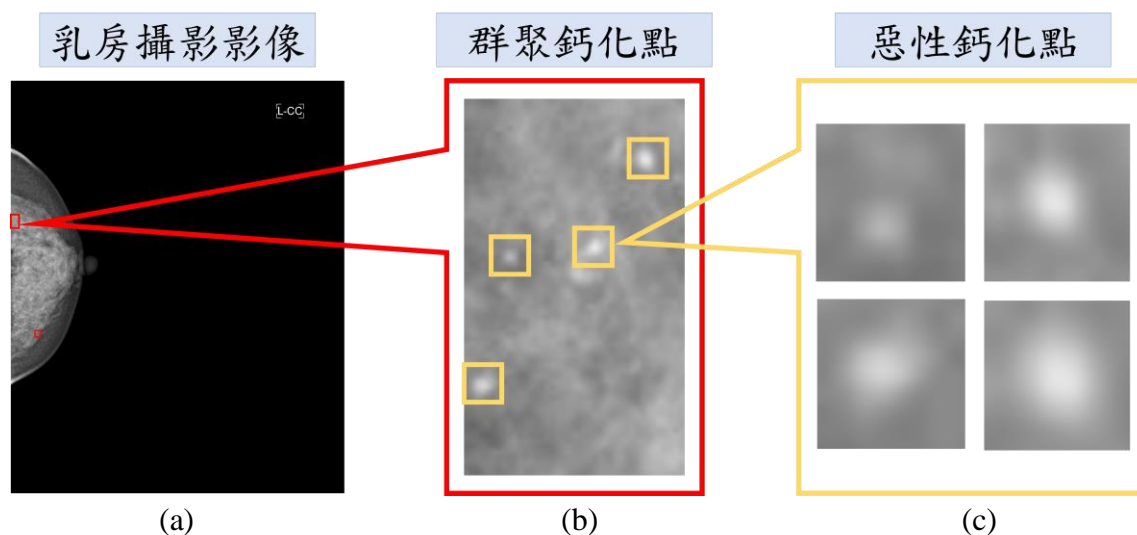


圖 1、(a)為乳房攝影影像，(b)為群聚鈣化點，(c)為惡性鈣化點

近年來人工智慧蓬勃發展，機器具有如人類一般的學習與判斷能力，可於接收大量資料後自行歸納，並針對輸入的數據進行分類或決策。本計畫希望利用深度學習開發出如醫生視覺判斷般的婦女乳房鈣化點群聚偵測及良惡預測系統，協助醫生於臨床上的診斷。

(三) 文獻回顧與探討

現今深度學習日漸被重視與應用，深度學習應用於醫學影像的論文紛紛被提出，非監督式學習的分類方法也大量應用於研究領域，本計畫希望參考許多文獻所提出的想法，加強其作法或改進其的不足，使方法更加完整且準確。本計畫將探討的文獻分為三大類，以下將逐一進行介紹。

1. 現今已用於乳房攝影影像上的相關研究

在 2014 年，Luis. A. Salazar-Licea 學者等人提出利用尺度不變特徵轉換 (Scale-invariant feature transform, SIFT) 及 K-means 分類法找出乳房攝影影像中的異常區域[1]，但 SIFT 於不同尺度可能找出過多的關鍵點且易受雜訊干擾，此篇論文作者也發現 X 光影像中的肌肉亮度影響了辨識結果，進而造成 K-means 分群時輸出錯誤結果，文末更是提到希望為來能利用深度學習方式改上以上狀況，使預測結果更為準確。

在 2015 年，JohnArealo 學者等人希望利用深度學習從乳房攝影影像中判斷出乳腺癌[2]，但資料集僅有 310 例含有惡性腫瘤，再加上 CNN 架構簡單，因此辨識結果不佳，本計畫希望改善以上問題，透過與醫院合作獲取大量資料，並加入更多卷積層來抽取乳房攝影影像上的微小特徵，提高辨識準確率。

在 2018 年，Mohammed Y. Kamil 學者等人比較 K-means 及 Fuzzy C-Means 在偵測乳房攝影影像中的腫瘤邊界[3]，結果證明 Fuzzy C-Means 的辨識準確率高於 K-Means，原因為 K-Means 為硬分群(hard clustering)，在分類時會將資料確切分類為某一類，而 Fuzzy C-Means 屬於軟分群(soft clustering)，其會將資料分類於不同類，並給予屬於不同類的程度，進而提高分類準確率。本計畫參考此論文研究結果，希望在分類群聚鈣化點時能夠依據不同輸入資料來調整，而非給予固定群數及相關參數。

2. FCN(Fully Convolutional Networks)應用於醫學影像上的相關研究

在 2018 年，Wentao Zhu 學者等人提出利用 FCN 提取乳房攝影影像中的特徵 [4]，以解決少量資料所造成分析結果不佳的問題。本計畫使用 FCN 來避免於少量資料集時所造成的過度擬合(Overfitting)，相較於大部分用於物件偵測的深度學習方法，FCN 不需大量參數與大量訓練影像，如 Faster R-CNN 及 SSD。

在 2018 年，Kelei He, Xiaohuan Cao 學者等人利用 FCN 分析骨盆 CT 影像 [5]，透過 FCN 學習影像中獨特的曲線，而此曲線為後續切割的依據。在 2019 年，Zhuoling Li 學者等人提出 CLU-CNNs 用於檢測青光眼 [6]，利用 FCN 找出眼底鏡影像中可能為視神經盤的區域，並利用 ANCF(Agglomerative Nesting Clustering Filtering)進行分群與融合相同區域的候選框，最終找到視神經盤以測量杯盤直徑比。由於本計畫目標為找出乳房攝影影像中的微小鈣化點，因此參考以上論文架構，透過 FCN 可提取出醫學影像中的微小特徵，再將 feature maps 作為輸入，找出可能為群聚鈣化點的候選框。

3. ISODATA(Iterative Self-Organizing Data Analysis Techniques Algorithm)應用於各領域的相關研究

近年來，非監督式機器學習的 ISODATA 分類法被應用於許多領域。在 2017 年，Amit Kumar Verma 學者等人利用 ISODATA 分類用於預測甘蔗產量的 LISS IV 資料 [7]，進而決定農業相關政策。同一年，N. Senthilkumaran 學者等人將 ISODATA 應用於分類 DNA 影像來鑑定是否有遺傳異常 [8]，並於未來希望透過分類結果切割 DNA 影像。Mingchao Li 學者等人也於同年提出利用 ISODATA 將家中總電量分類為不同用途的耗電量 [9]，文中也提到 ISODATA 改善 K-means 需先設定群數，且輸出的分類群數即為預設值，對於未知群數的狀況下十分不適合，此研究為本計畫使用 ISODATA 的重要參考依據。2020 年，Peng Zhang 學者等人將岩石的紋理分布統計資料進行分群 [10]。目前並未有將 ISODATA 應用於醫學影像上的相關研究，本計畫利用 ISODATA 將 FCN 產生的候選框分群，過程中將候選框融合或分裂，最終輸出框的數量即為群數，而每群皆為乳房攝影影像上的群聚鈣化點。

綜合上述文獻回顧，本計畫發現目前並未有利用深度學習偵測乳房攝影影像中鈣化點群聚處，並進而辨識其良性與惡性的研究，但有許多方法，如 ISODATA 分類法或 CNN 架構用於醫學影像上可達良好結果，本計畫希望建立於以上文獻所提出的想法，並加以改進及最佳化，搭配自行建置的使用者圖形介面，建置出「基於 BI-CNN 進行婦女乳房鈣化點群聚偵測及良惡預測」系統，有效輔助醫師診斷。

(四) 研究方法及步驟

此計畫利用 BI-CNN(Breast Imaging Convolutional Neural Network)建置出「基於 BI-CNN 進行婦女乳房鈣化點群聚偵測及良惡預測」系統，BI-CNN 分為 Gathering CNN 偵測群聚鈣化點及 Mask R-CNN 分類鈣化點良惡，計畫流程圖如圖 2 所示。

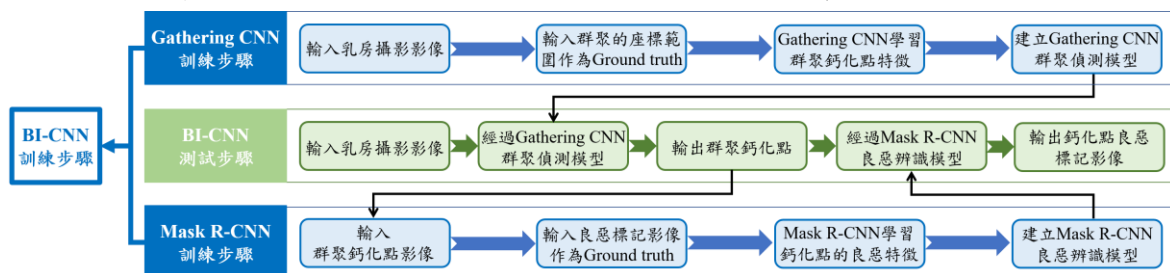


圖 2、系統流程圖

1. 輸入乳房攝影影像

本計畫與中山醫學大學附設醫院(Chung Shan Medical University Hospital)醫學影像部合作，並由醫師提供專業知識及乳房攝影影像，其中包含每位病患的乳房上下側照像(CC view)，如圖 3(a)所示，及左右側照像(MLO view)，如圖 3(b)所示。本計畫以此資料集進行訓練及測試，其中 80%的資料用於訓練，而 20%的資料用於測試。此外，若有疑似惡性鈣化點群聚而進行穿刺插針檢測的乳房穿刺影像，如圖 3(c)所示，本計畫會將其作為框選群聚鈣化點的依據，對應此病患的乳房攝影影像，框選出群聚鈣化點範圍，並透過演算法自動將框選的座標範圍及其檔名紀錄成 csv 檔，作為偵測群聚鈣化點的訓練資料。




圖 3、(a)為上下側照像，(b)為左右側照像，(c)為乳房穿刺影像

2. 使用 Gathering CNN 偵測群聚鈣化點

本計畫使用 Gathering CNN 偵測影像中鈣化點群聚處，其中使用滑動視窗(Sliding window)來找出鈣化點群聚的可能區域(Region Proposal)及預測可能的鈣化點群聚數量。Gathering CNN 分為兩部分，分別為全卷積神經網路(Fully Convolutional Neural Networks, FCN)及 ISODATA(Iterative Self-Organizing Data Analysis Techniques Algorithm)分類法。Gathering CNN 流程圖如圖 4 所示。

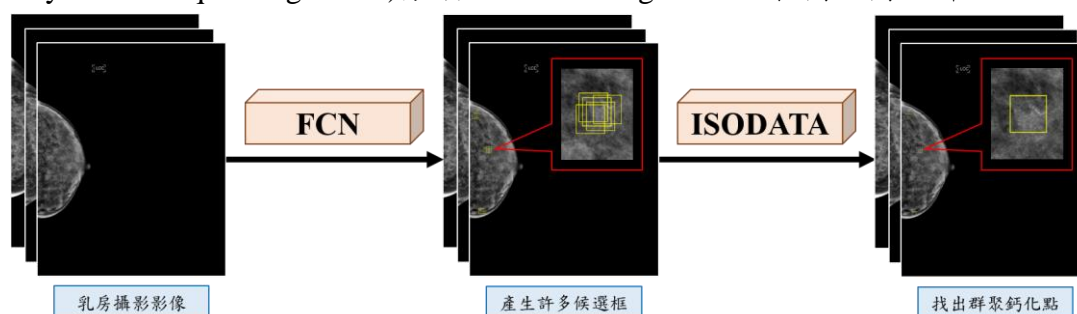


圖 4、Gathering CNN 流程圖

本計畫將乳房攝影影像輸入全卷積神經網路(FCN)，目標為自動框選出影像中的群聚鈣化點，因此訓練時會將影像及其群聚鈣化點座標範圍一併輸入，做為訓練時的 Ground truth，群聚鈣化點座標範圍是依據病患的切片檢測影像中進行穿刺之處對應在乳房攝影影像中相同區域進行框選，並透過演算法讀取框選的座標值後儲存成 csv 檔輸入。全卷積神經網路架構含有十二層皆為 3×3 的卷積層(Convolution layer)來抽取乳房攝影影像中的特徵及四層池化層(Pooling layer)來縮減特徵圖大小，其中前九層卷積層及前三層池化層產生的特徵圖(Feature maps)當作進行群聚鈣化點偵測前的輸入，與直接輸入整張乳房攝影影像相比，此作法利於找到人眼難以觀察的微小鈣化點。由於不同設備所拍攝的影像於亮度會有差異，為了減少影像間的差異性，本計畫於輸入卷積層前皆加入 BN(Batch Normalization)來進行影像正規化。另外，使用固定大小的滑動視窗來偵測影像中的鈣化點，滑動視窗所移動的距離為固定值，且每移動一次會產生一個 Bounding Box，每個 Bounding Box 經過 1×1 大小的卷積層將特徵由多維度降至一維後，最

後透過 Sigmoid 產生每個 Bounding Box 為可能為目標的機率值及其座標範圍，並篩選出機率值較高的 Bounding Box，成為候選框(Candidate Box)。此外，利用候選框於影像中的密集或分散程度預測可能的群數(K_0)，以利後續分群並尋找目標所在位置。

本計畫於架構中加入損失函數(Loss function)來計算 Ground truth 與候選框的座標及機率之差異，透過調整權重以降低損失函數的值，損失函數方程式如下：

$$L_{FCN}(p, c) = L_{pre}(p, p') + L_{cod}(c, c') \quad (1)$$

FCN 架構中的損失函數(L_{FCN})由 Predicted loss(L_{pre})及 Coordinate loss(L_{cod})所組成。 L_{pre} 計算 Bounding box 及 Ground truth 之間的誤差， p 為候選框被預測為目標的機率。 p' 為 Ground truth 的機率，其中目標處之機率為 1。 L_{cod} 用來計算候選框座標及目標座標的差異， c 為候選框的座標。 c' 為目標的座標。

為提高準確率，本計畫利用 IoU(Intersection over Union)再次篩選及檢測 FCN 產生的候選框。IoU 是透過候選框面積與 Ground truth 的目標面積進行運算，運算結果為 0 到 1 區間內的數值，越趨近於 1 代表候選框越接近於目標。IoU 低於 0.5 的候選框代表重疊性過低，與目標距離過遠，此時須將結果回傳至 FCN 架構，進而調整其權重值。透過 FCN 架構中的損失函數與 IoU 回傳結果不斷調整權重值來最佳化神經網路，使產生的候選框位置越來越接近目標。IoU 計算方式如下：

$$IoU = \frac{AO}{AU} = \frac{Area(Candidate\ Box) \cap Area(Ground\ Truth)}{Area(Candidate\ Box) \cup Area(Ground\ Truth)} \quad (2)$$

其中，Ground Truth 為群聚鈣化點，AO(Area of Overlap)為候選框與群聚鈣化點的交集面積，AU (Area of Union)為候選框與群聚鈣化點的聯集面積。

候選框產生後，會利用其分布於影像中的位置及密集程度預測影像中可能的目標數量及其位置，為了找出真正的群聚鈣化點數量及其在影像中的確切位置，本計畫使用 ISODATA(Iterative Self-Organizing Data Analysis Techniques Algorithm)分群法將候選框分群，並將相同群聚的候選框融合。ISODATA 為非監督式的聚類演算法，其建立於 K-means 分類法基礎上，改善需先設定固定群數的問題，ISODATA 擁有自動調整群數的能力，適合用於未知群數的乳房攝影影像，由於每張乳房攝影影像中的鈣化點群聚數量皆不相同，無法統一給定群數。ISODATA 的輸入參數包含預期的群數 K_0 、群內最少樣本數 Nmin、最大方差 Sigma 及群中心允許最小的距離 dmin 等。

3. 將群聚鈣化點輸入 Mask R-CNN 分類良惡

由於醫師在檢測乳房攝影影像時，會先找出鈣化點群聚處，並進行進一步穿刺切片檢測，本計畫希望能利用機器模擬醫師平時看診步驟，目標為偵測出群聚鈣化點後，將群聚內所有微小鈣化點皆標記其為良性或惡性，透過自動分析有效輔助醫師診斷，並取代穿刺切片檢測。因此 Gathering CNN 找出的群聚鈣化點後便進行切割，並對應此患者醫囑中的切片檢測結果標記群聚中的鈣化點，惡性鈣化點標記為紅色，良性鈣化點標記為綠色，且標記時依照鈣化點形狀進行標記。為了使影像大小一致及避免因調整大小導致影像中的鈣化點變形，本計畫將影像等比放大或縮小，使長邊為 100，並將大小放大至 100×100，作為 Mask R-CNN 訓練及測試的資料，如圖 5 所示。




圖 5、(a)為群聚鈣化點影像，(b)為調整大小後影像，(c)為良惡標記影像

(五) 實驗結果與探討

在實驗結果與探討中，首先介紹系統開發環境與使用工具，接下來介紹 Gathering CNN 偵測群聚鈣化點及 Mask R-CNN 分類良惡之測試階段混淆矩陣，接著介紹自建的圖形化使用者介面圖。為了驗證本系統確實有效輔助醫師，本計畫將醫師實際判斷鈣化點良惡之結果列於表格中，且計算出的各項評估指標進行分析，最後計算出醫師測驗結果並進一步與本研究分析結果進行比較。

1. 開發環境與工具

本計畫在訓練及測試階段皆使用相同開發環境與設備，軟硬體設備配置如表 1 所示。本計畫於 Ubuntu 18.04 作業系統中使用 Anaconda 3 並搭配 Keras 深度學習函式庫，使用 Python 程式語言開發，於 Spyder 撰寫程式。硬體設備使用 Intel core i9-9900X、NVIDIA RTX 5000 16GB GDDR6 和 16GB RAM 的電腦。

表 1、軟硬體設備

| | | |
|----|-----------|------------------------|
| 軟體 | 作業系統 | Linux Ubuntu 18.04 |
| | 深度學習開發環境 | Anaconda 3 |
| | 開發程式語言 | Python |
| | 深度學習函式庫 | Keras |
| | 開發 IDE 平台 | Spyder |
| 硬體 | CPU 處理器 | Intel Core i9-9900X |
| | GPU 顯卡 | NVIDIA Quadro RTX 5000 |
| | RAM 容量 | 64G |

2. 測試階段評估指標計算結果

本研究分別針對「Gathering CNN 偵測群聚鈣化點」及「Mask R-CNN 分類良惡」製作出測試階段混淆矩陣，如表 2 及表 3 所示。其中「Mask R-CNN 分類良惡」考慮所有鈣化點的標記狀況，包含鈣化點位置及輪廓，「Mask R-CNN 分類良惡之標記狀況」混淆矩陣如表 4 所示，若皆標記正確，如圖 6 (a)所示，則將此影像定義為 True Positive (TP)，若背景處被誤標記為鈣化點，如圖 6 (b)所示，則被定義為 False Positive (FP)，若鈣化點被誤判斷為背景而未被標記，如圖 6 (c)所示，則被定義為 False Negative (FN)。

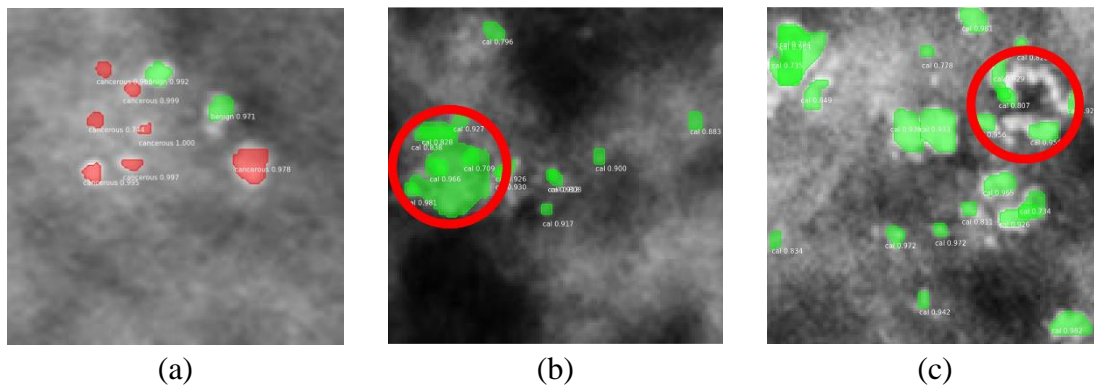


圖 6、Mask R-CNN 混淆矩陣中 TP、FP 及 FN 之定義，(a)為 Mask R-CNN 標記正確影像，即為 True Positive (TP)。(b)為 Mask R-CNN 將背景處被誤標記為鈣化點影像，即為 False Positive (FP)。(c)為 Mask R-CNN 將鈣化點被誤判斷為背景而未被標記影像，即為 False Negative (FN)。

表 2、Gathering CNN 偵測群聚鈣化點模型測試階段混淆矩陣

| | | 真實結果 | |
|------|-----|------|-----|
| | | 群聚 | 非群聚 |
| 預測結果 | 群聚 | 191 | 13 |
| | 非群聚 | 32 | 219 |

表 3、Mask R-CNN 分類良惡模型測試階段混淆矩陣

| | | 真實結果 | |
|------|----|------|-----|
| | | 惡性 | 良性 |
| 預測結果 | 惡性 | 152 | 19 |
| | 良性 | 7 | 239 |

表 4、Mask R-CNN 分類良惡之標記狀況測試階段混淆矩陣

| | | 真實結果 | |
|------|-----|------|----|
| | | 鈣化點 | 背景 |
| 預測結果 | 鈣化點 | 413 | 1 |
| | 背景 | 3 | - |

(1) Gathering CNN 偵測群聚鈣化點之結果分析

利用 Gathering CNN 在測試階段之混淆矩陣計算出準確度、精準度、敏感度及特異度分別為 90.11%、93.63%、85.65%及 94.40%，可見 Gathering CNN 對於分類乳房攝影影像上的群聚鈣化點及非群聚鈣化點有相當好的效果，但敏感度為 85.65%，仍有進步空間。

(2) Mask R-CNN 分類良惡模型之結果分析

Mask R-CNN 分類鈣化點良惡之準確度、精準度、敏感度及特異度分別為 93.76%、88.89%、95.60%及 92.64%，可知 Mask R-CNN 分類鈣化點效果良好。

(3) Mask R-CNN 分類良惡之標記狀況結果分析

Mask R-CNN 在切割群聚中的鈣化點的精準度及敏感度分別為 99.76%及 99.28%，由以上兩數據驗證了 Mask R-CNN 切割鈣化點的能力非常高，僅有鈣化點過於密集或輪廓模糊的影像會有標記錯誤的狀況發生。

3. 供醫師操作的圖形化使用者介面

本計畫建置簡潔易懂的使用者圖形介面供醫師使用，系統登入頁如圖 7 所示，為保障病患隱私，系統使用對象僅限醫事相關人員，使用前皆須輸入帳號密碼以核對身分。登入後系統首頁如 8 所示，醫師可點選「選擇影像」按鈕選擇欲分析影像，若要分析乳房攝影影像中的群聚處，可點選「群聚分析」按鈕，分析結果會在介面中顯示，如圖 9 所示。若醫師要進一步分析群聚中鈣化點的良好狀況，可點選「良惡分析」按鈕，系統會偵測出影像中的鈣化點並將鈣化點進行良惡標記，供醫師參考，如圖 10 所示。

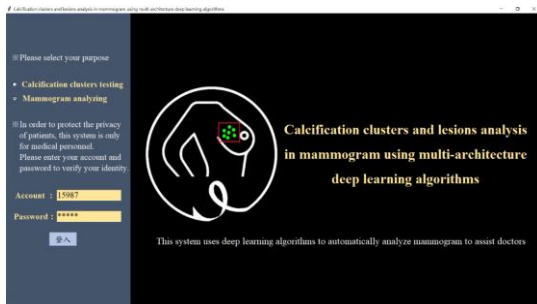


圖 7、系統登入頁

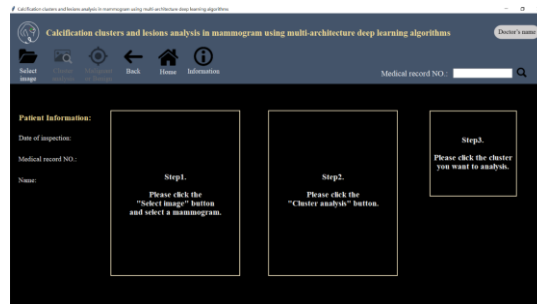


圖 8、系統首頁

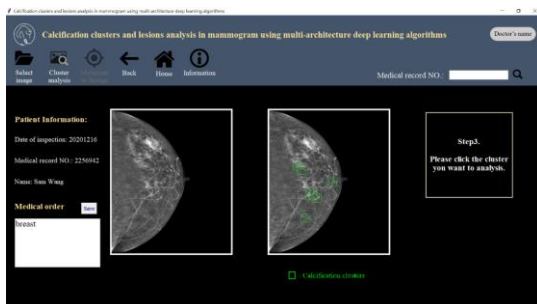


圖 9、群聚分析結果




圖 10、良惡分析結果

4. 醫師實際判斷群聚鈣化點結果

本計畫請醫師依照自身經驗判斷群聚中良性鈣化點或惡性鈣化點，共分為三階段，以避免醫師因疲勞而影像測驗結果，且每階段的測驗時間相隔兩周並對調影像順序，以避免醫師憑藉上一階段記憶選擇答案。第一階段測驗結果如表 5 所示，第二階段測驗結果如表 6 所示，第三階段測驗結果如表 7 所示。

表 5、第一階段測驗結果

| | | 真實結果 | |
|------|----|------|-----|
| | | 惡性 | 良性 |
| 預測結果 | 惡性 | 5 | 12 |
| | 良性 | 55 | 100 |

表 6、第二階段測驗結果

| | | 真實結果 | |
|------|----|------|----|
| | | 惡性 | 良性 |
| 預測結果 | 惡性 | 4 | 10 |
| | 良性 | 65 | 53 |

表 7、第三階段測驗結果

| | | 真實結果 | |
|------|----|------|----|
| | | 惡性 | 良性 |
| 預測結果 | 惡性 | 6 | 25 |
| | 良性 | 30 | 50 |

本計畫統整醫師三階段測驗結果，並得到醫師判斷鈣化點良惡的準確度、精準度、敏感度及特異度僅為 52.53%、24.19%、9.09% 及 18.80%，由以上實驗結果可知醫師在判斷鈣化點的良惡狀況能力有限，即使已看過無數位病患的病灶影像，判斷的結果仍不慎理想，因此現今醫師在找出群聚鈣化點處後會請病患進行侵入性的細針定位手術檢測來得知群聚中的鈣化點狀況。

(六) 結論

本研究參考諸多文獻方法並改善及優化流程，使用深度學習方法分析乳房攝影影像，深度學習演算法包含利用 Gathering CNN 偵測群聚鈣化點及利用 Mask R-CNN 偵測及分類群聚中鈣化點之良惡，訓練資料準備參考細針定位手術檢測影像及醫囑。本研究特別加入醫師觀點，透過實際訪問專業放射科醫師了解看診步驟及觀察乳房攝影影像的標準，仿照醫師看診步驟，首先辨識出鈣化點群聚，接續分類良惡。本研究的貢獻為精準分析病患乳房狀況來輔助醫師看診、易操作的圖形化使用者介面供醫師觀看、病患不需進行侵入性細針定位手術檢測便可偵測出乳房攝影影像中惡性鈣化點之處。未來期望能在檢測出惡性鈣化點後，進一步預測惡性的種類

(七) 參考文獻

- [1] Salazar-Licea, L. A., Mendoza, C. and Aceves, M. A. et al., "Automatic Segmentation of Mammograms Using a Scale-Invariant Feature Transform and K-Means Clustering algorithm", In: IEEE Electrical Engineering, Computing Science and Automatic Control (CCE), 2014 11th International Conference on, pp. 1-6, 2014.
- [2] Arevalo, J., González, F. A. and Ramos-Pollán, R. et al., "Representation learning for mammography mass lesion classification with convolutional neural networks", Comput. Methods Programs Biomed., vol. 127, pp. 248-257, 2016.
- [3] Kamil, M. Y. and Salih, "Mammography Images Segmentation via Fuzzy C-mean and K-mean", International Journal of Intelligent Engineering and Systems, vol.12, No.1, p. 22-29, 2019.
- [4] Zhu, W., Xiang, X. and Tran, T. D. et al., "Adversarial Deep Structured Nets for Mass Segmentation from Mammograms", In: IEEE ISBI, 2018.
- [5] He, K., Cao, X. and Shi, Y. et al., "Pelvic Organ Segmentation Using Distinctive Curve Guided Fully Convolutional Networks", IEEE Trans. Med. Imag., vol. 38, no. 2, pp. 585-595, 2019.
- [6] Li, Z., Dong, M. and Wen, S. et al., "CLU-CNNs: Object detection for medical images", Neurocomputing, vol. 350, pp. 53-59, 2019.
- [7] Verma, A. K., Garg, P. K., and Prasad, K. H., "Sugarcane crop identification from LISS IV data using ISODATA, MLC, and indices based decision tree approach", Arab. J. Geosci., pp. 16, 2017.
- [8] Li, M., Han, S., and Shi, J., "An enhanced ISODATA algorithm for recognizing multiple electric appliances from the aggregated power consumption dataset", Energy Build., vol. 140, pp. 305-316, 2017.
- [9] Senthilkumaran, N., and Sivapriya, M., "Riddler's Thresholding Algorithm for DNA Image Using ISODATA Modified Algorithm", Journal of Information Technology, vol.3, no.2, pp.41-48, 2017.

- [10] Zhang, P., Qian, X. and Guo, X. et al., “Automated demarcation of the homogeneous domains of trace distribution within a rock mass based on GLCM and ISODATA”, *International Journal of Rock Mechanics and Mining Sciences*, vol. 128, 2020.