

# 結合影像生成技術與深度學習於 資訊不足時提高疾病快篩檢測結 果判讀之研究

## Enhancing Rapid Disease Screening Interpretation with Image Generation and Deep Learning Under Limited Data

盧建銘、陳建甫

Jian-Ming Lu, Chien-Fu Chen

人工智慧驅動的疾病診斷通常依賴大規模資料集，然而資料匱乏仍然是傳染病檢測的一大障礙。為了緩解這個問題，吾人採用 Wasserstein 生成對抗網路 (Wasserstein generative adversarial network, WGAN) 來提升低資料量情境下的診斷效能。透過引入基於 Wasserstein 距離的最佳化方法，該方法增強了訓練穩定性並提高了合成影像的品質。我們將此方法與使用分類神經網路的傳統資料增強方法進行了對比評估以實現快速、便攜且經濟高效的診斷。在僅使用一半原始資料 ( $n = 150$ ) 的情況下，模型仍保持了 95% 左右的準確率，凸顯了其在資源有限環境下的潛力。

AI-driven disease diagnosis typically relies on large-scale datasets, yet data scarcity remains a major barrier for infectious disease detection. To alleviate this issue, we adopt the Wasserstein generative adversarial network (WGAN) to improve diagnostic performance in low-data scenarios. By incorporating Wasserstein distance-based optimization, the proposed approach enhances training stability and synthetic image quality. We evaluate the method against conventional data augmentation using classification neural networks for rapid, portable, and cost-effective diagnostics. With half of the original data ( $n = 150$ ), the model maintained 95% accuracy, highlighting its potential in resource-limited settings.

### 一、前言

在資源匱乏的環境中，缺乏高品質且可負擔的診斷工具，長期以來被視為造成全球健康負擔的重要因素之一。為回應此一問題，世界衛生組織熱帶疾病研究與培訓計畫 (World

Health Organization Special Programme for Research and Training in Tropical Diseases, WHO/TDR) 提出 ASSURED (Affordable、Sensitive、Specific、User-friendly、Rapid、Equipment-free、Delivered) 診斷準則，作為適用於開發中國家公共衛生與醫療體系之理想檢測標準，並已被廣泛應用於定點照護 (point of care, POC) 相關系統中<sup>(1)</sup>。

相較於高度精密且需仰賴複雜儀器與專業技術人員的實驗室檢測模式，應用於社區與初級醫療層級的診斷工具，必須同時具備快速、低成本與易於操作等特性，方能在傳染病爆發時於醫療資源不足的環境中進行大規模篩檢，並有效降低醫療體系負擔<sup>(2-4)</sup>。側層流免疫分析 (lateral flow immunoassay, LFIA) 為目前最常見的快速診斷測試之一，其具備操作簡單、反應快速、價格低廉與攜帶方便等優勢，已廣泛應用於臨床診斷、藥物濫用檢測、食品安全與環境分析等領域，並在全球公共衛生中扮演關鍵角色<sup>(5-6)</sup>。然而，傳統 LFIA 仍存在若干限制。相關研究指出，測試結果的判讀常受到操作人員經驗影響，容易產生主觀誤判，其判斷準確率僅約為 80% 至 97%<sup>(7)</sup>。此外，LFIA 多僅提供定性結果，若欲進一步推估分析物濃度，往往仍須仰賴專業儀器或其他分析方法輔助，進而增加系統複雜度與整體成本，限制其於大規模公共衛生應用中的實用性。

近年來，深度學習於影像辨識、自然語言處理與生醫分析等領域均展現卓越成果，其優勢在於可自動從大量資料中學習高維度且具判別力之特徵。然而，深度學習模型的效能高度依賴大規模且具標註之資料集，而在臨床與生醫應用中，資料蒐集與標註往往昂貴、耗時，並受限於倫理與實務條件。即便已有部分公開醫療資料集，其規模多仍有限，且多侷限於特定疾病或任務<sup>(8)</sup>。因此，如何在小型資料集與有限標註條件下，仍能有效訓練深度學習模型，已成為當前人工智慧於醫療應用中最具挑戰性的課題之一。

為因應資料不足問題，影像辨識領域中常見作法為利用資料增強 (data augmentation) 技術，透過旋轉、平移、縮放與映射等幾何或影像變換方式擴充資料量，以提升模型魯棒性。然而，當資料集規模本身過小時，僅透過傳統幾何變換所產生的影像多樣性仍然有限，其對模型效能提升之效果亦相對受限<sup>(9-10)</sup>。因此，近年研究逐漸轉向透過人工合成影像的方式，藉由生成模型擬合真實資料分布，以實現更具代表性的資料增強。

本研究整合生成式對抗神經網路 (generative adversarial networks, GAN)，用於真實 LFIA 影像資料之生成與擴增。透過混合真實影像與深度學習生成影像，本方法有效提升資料集規模與多樣性，加速後續分類神經網路之開發與系統設計，並改善小樣本條件下模型訓練效率與準確性。此外，所提出之簡化自注意力機制在提升特徵表徵能力的同時，亦兼顧計算效率，使其更具實務應用潛力。為驗證本研究方法之可行性，本研究選擇金黃色葡萄球菌之特徵蛋白 A 作為目標生物標誌物。金黃色葡萄球菌為重要的人類病原菌之一，亦為植入式醫療裝置相關感染之主要成因，至今仍屬臨床治療上的重大挑戰。本文分別以真實資料集與混合生成資料之資料集訓練分類神經網路，並透過混淆矩陣、t-SNE 等方式系統性評估模型效能。

實驗結果顯示，透過 WGAN 進行資料生成可有效提升低資料量情境下之分類效能，並對後續診斷任務帶來實質助益。本研究所提出之方法為快速診斷測試提供一具潛力的解決方案，能降低對大量標註資料之依賴，同時兼顧模型效能與訓練成本，對於資源匱乏環境中的醫療應用具有重要意義。未來研究可進一步拓展至其他生醫感測與疾病檢測領域，深入探討生成模型於智慧診斷系統中的應用潛力。

## 二、實驗方法

### 1. 側層流免疫分析試片

側向流體免疫分析試片主要由樣品墊 (sample pad)、結合墊 (conjugate pad)、檢測墊 (test pad) 以及吸收墊 (absorbent pad) 所組成 (如圖 1 所示)，並利用毛細作用將待檢測之檢體依序與上述區域進行反應。首先，樣品墊為最先與檢體接觸的區域，材料為玻璃纖維或纖維素，其作用為初步樣品的過濾，避免基質效應並穩定檢體的狀態。再者，若檢體中含有欲檢測之抗體，將會與原本乾燥於結合墊之酵素或是有修飾抗體之奈米材料結合，以便後續之反應。而檢測墊是由硝化纖維膜所組成，其表面含有具含有高度蛋白親和力之聚酯薄膜並預先畫有兩道線，測試線以及控制線，測試線含有能捕捉目標物之特定抗體，而控制線能抓住有奈米材料標記之抗體，進而達到訊號顯色的效果。最終，多出來的液體會透過毛細力流向吸收墊進行吸收，以達到穩定流場的效果。而完整的側向流體免疫層析法測試流程為十五分鐘。




圖 1. 側向流體免疫分析試片組成圖。

本實驗所使用的樣品墊與結合墊皆預先分別乾燥 5% BSA in PBST 和 AuNPs @ Rabbit-Anti-Protein A，而測試墊的部分則是分別畫上 Rabbit Anti-Protein 與 Goat-Anti-Rabbit IgG 做為測試線以及控制線。以上的乾燥模式皆以 37 °C 之溫度放置於墊熱板上乾燥兩個小時。待各個試片元件完全乾燥完成方可進行組裝，依序將樣品墊、結合墊、檢測墊以及吸收墊黏貼至專用背板，完成試片組裝步驟。

表 1. 側向流體免疫層析試片組成、材質以及使用試劑。

Structure	Material	Reagent
Sample pad	Glass fiber	5% BSA in PBST
Conjugate pad	Polyester	AuNPs @ Rabbit-Anti-Protein A
Test pad	NC membrane	TL : Rabbit Anti-Protein CL : Goat-Anti-Rabbit IgG
Absorbent pad	Cellulose	N/A

## 2. 側層流免疫分析試片數據庫建立

根據標準測試步驟 (如圖 2 所示), 根據流入之樣品濃度不同, 將側層流免疫分析試片分成 blank、低濃度以及高濃度三種類別, 最終共得到 300 張原始的真實側層流免疫分析試片資料 (每一類別 100 張)。

為降低環境因素對試片反應結果之影響, 所有試片之製備、反應時間與影像擷取皆於受控之實驗室環境中進行, 包含穩定之室溫 (約 25 °C) 以及固定十五分鐘之反應時間來進行影像擷取。此設計可有效減少環境變因對試片顯色與訊號強度之干擾, 使資料庫主要反映不同濃度條件下之影像特徵差異。

在資料前處理的部分, 先根據原始資料的邊緣進行裁切, 並將其解析度標準化至 660×50, 於圖像兩側進行零填充至 660×660, 針對測試線與控制線位置進行裁切, 最終將圖片標準化至 128×128。資料增強的部分, 由於本研究目的在於檢測不同濃度之側層流免疫分析試片, 因此吾人選擇以幾何形式 (旋轉) 來進行資料增強, 最終得到 30,000 張資料 (每一類別 10,000 張)。



圖 2. 資料蒐集流程圖。

## 3. Wasserstein Generative Adversarial Network (WGAN)

傳統的生成式對抗神經網路是透過生成器與判別器的相互對抗, 不斷改進模型來達到最終目的地。然而, 原始的生成式對抗神經網路訓練過程是非常不穩定的, 主要原因為其獨特的訓練模式, 在生成器與判別器相互博弈的過程常常會有梯度爆炸、梯度消失與模型崩潰等狀況發生。為了解決上述問題, Arjovsky 等人提出 Wasserstein Generative Adversarial Network, 針對損失函式進行優化, 改用 Wasserstein distance 來優化神經網路, 其定義如下:

$$W(P_r, P_g) = \inf_{r \sim \Pi(P_r, P_g)} E(x, y) \sim y [\|x - y\|] \quad (1)$$

其中  $\Pi(P_r, P_g)$  代表在  $P_r$  以及  $P_g$  的邊界中, 所有聯合分佈  $r(x, y)$  的集合, 而 Wasserstein distance 則是在計算分布中  $x$  與  $y$  距離期望值之最小估計值, 可以穩定的進行模型訓練。

由於生醫影像資料往往具備樣本數少、結構高度一致且類內差異有限等特性, 傳統 GAN 容易因資料分布稀疏而產生模式崩潰或過度擬合之問題。相較之下, WGAN 能夠在小樣本條件下穩定學習資料分布特性, 並維持生成樣本之多樣性與結構合理性, 因此特別適用於生醫影像與側層流免疫分析影像等應用場景。WGAN 透過引入 Wasserstein distance 作為

優化目標，使生成模型在理論基礎與實務訓練表現上皆顯著優於傳統 GAN，不僅有效改善訓練不穩定問題，亦為後續影像資料生成與資料增強任務提供更可靠之技術基礎。

#### 4. 神經網路訓練結果評估指標

本研究探討了四個性能指標，包括敏感度、特異度、陽性預測值 (positive predictive value, PPV) 和陰性預測值 (negative predictive value, NPV)。對於每張圖片，分類器生成的結果可以歸類為真陽性 (true positive, TP)、真陰性 (true negative, TN)、假陽性 (false positive, FP) 或假陰性 (false negative, FN) 四個類別之一。結果的真偽取決於與所選的黃金標準進行比較。

靈敏度是衡量分類器正確檢測陽性結果能力的指標，其計算方法為：

$$Sensitivity = \frac{TP}{TP + FN} \quad (2)$$

特異度則衡量分類器正確檢測陰性結果的能力，其計算方法為：

$$Specificity = \frac{TN}{TN + FP} \quad (3)$$

這些指標表示診斷測試中確定的陽性和陰性結果中，真陽性和真陰性的比例。

在本研究中，我們使用了混淆矩陣、t-SNE 等指標來評估分類神經網路的性能。這些評估方法提供研究人員對模型在不同方面的表現和效能的全面了解。混淆矩陣是一個有助於評估分類器在各個類別上的表現情況的工具。它包含了真陽性、真陰性、偽陽性和偽陰性等數據。透過混淆矩陣，我們可以瞭解分類器在不同類別上的預測準確度、誤分類情況等。進一步的數據分析和結果顯示，我們的分類神經網路在不同類別上均取得了良好的表現，具有較高的真陽性和真陰性數量，並且偽陽性和偽陰性的數量相對較低，這證明了我們的模型對於分類任務的可靠性。而 t-SNE 是一種降維和可視化技術，利用二維的分布圖來呈現高維度資料間的相互關係。我們利用 t-SNE 將分類神經網路提取的特徵表示轉換為低維空間，以觀察不同類別之間的分離程度和聚集模式。經過 t-SNE 降維和可視化後，我們觀察到不同類別的樣本在低維空間中有明顯的分離和聚集模式，這表明分類神經網路能夠有效地學習並區分不同類別的特徵表示。利用混淆矩陣、t-SNE 的評估結果，我們能夠更全面地了解分類器在側層流免疫分析試片檢測中的性能表現。這些評估結果有助於確定分類器的適用性和可靠性，並輔助我們在實際應用中的決策和選擇。

### 三、實驗結果

#### 1. 分類神經網路性能比較與選擇

本研究之最終目標是將生成之資料混合真實資料應用於手機架構之圖像辨識系統，因此吾人選用適合壓縮至手機作業環境之分類神經網路模型，包括 ResNet50、MobileNetV2、EfficientNet lite0 三種分類神經網路架構<sup>(11-13)</sup>。針對不同濃度之真實側層流免疫分析圖像來進行分類訓練，為了瞭解不同分類神經網路之優劣，吾人統一將批次大小 (batch size) 設定為 32、最佳化器設定為 Adam、損失函式 (loss function) 設定為 Cross Entropy Loss、將訓練

次數設定為 100 代 (Epochs)。並檢視在相同的訓練條件下，何者之收斂程度與準確率最佳。

根據訓練結果 (圖 3 與表 2 所示)，可以明顯觀察出 ResNet50、MobileNetV2、EfficientNet lite0 針對真實數據集進行分類訓練，無論是損失函式抑或是準確率的計算皆有收斂之趨勢。此外，利用測試集來檢視分類神經網路分辨未知數據的準確率，其中 EfficientNet lite0 的準確率最高 (97.80%)，其次為 MobileNet V2 (95.23%)，最後是 ResNet 50 (92.83%)。因此本研究選用 EfficientNet lite0 來做為主要分類神經網路架構。

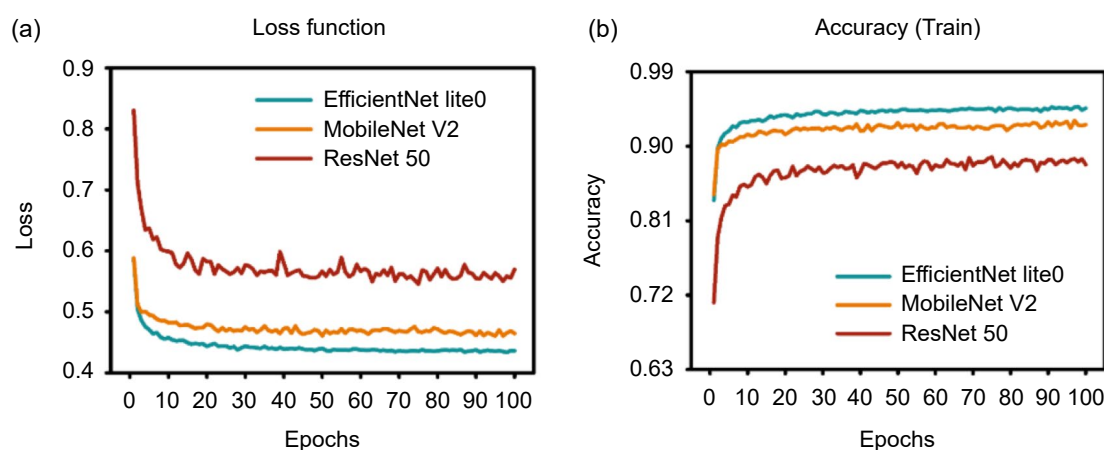


圖 3. 利用真實資料針對不同分類神經網路進行 100 代訓練之結果與比較。(a) 不同分類神經網路之損失函數圖。(b) 不同分類神經網路之準確率圖。

表 2. 不同分類神經網路模型於測試集資料之準確率。

Model	Accuracy (%)
ResNet50	92.83
MobileNetV2	95.23
EfficientNet lite0	97.80

## 2. WGAN 訓練結果

吾人利用 Wasserstein 生成式對抗神經網路 (wasserstein generative adversarial network, WGAN) 針對側層流免疫分析試片影像資料進行大量資料生成，以克服原始資料量不足對深度學習模型訓練所造成之限制。本研究所採用之 WGAN 在理論與實務層面上，皆具備適合應用於低資料量生醫影像分析之特性。相較於傳統生成式對抗神經網路，WGAN 透過在判別器中引入 Lipschitz 連續性限制，使模型能以 Wasserstein 距離作為生成資料分布與真實資料分布差異之衡量指標，進而提供更具意義且平滑的距離度量。此一特性可有效改善傳統 GAN 訓練過程中常見之梯度消失與模式崩潰 (mode collapse) 問題，使生成模型於訓練過程中具備更佳的穩定性與可收斂性，特別適用於小型且結構高度一致之生醫影像資料生成任務。

在模型架構設計上，本研究之 WGAN 採用卷積式生成器與鑑別器結構，生成器以隨機潛在向量為輸入，透過多層轉置卷積 (transposed convolution) 逐步還原空間解析度，以生成與真實 LFIA 影像尺寸一致之合成影像；鑑別器則由多層卷積神經網路所構成，負責評估輸入影像屬於真實資料或生成資料之機率分布，並回饋其 Wasserstein 距離以引導生成器更

新，以確保模型訓練過程之穩定性與理論合理性。此外，Lipschitz 連續性所帶來的平滑性亦有助於提升生成結果之可解釋性，具體而言，潛在空間中的微小擾動會對應至生成影像中連續且結構化的變化，而非產生突兀或不具生物意義的影像雜訊。此特性對於生醫影像生成尤為重要，因其能在保留影像結構與診斷相關特徵的前提下，擴增資料多樣性，並避免生成不合理之影像。

為確保生成影像之品質與多樣性，並避免生成資料出現與原始資料高度重複之情形，本研究進一步引入 Hamming Distance<sup>(14)</sup> 與 Structural Similarity Index Measure (SSIM)<sup>(15)</sup> 作為量化評估指標。Hamming Distance 可用以檢測生成影像與真實影像在像素或特徵層級上的差異程度，以確認生成資料並非簡單複製原始樣本；SSIM 則從亮度、對比度與結構相似性等面向評估生成影像與真實影像之結構一致性，藉此確保生成影像在維持生醫影像關鍵結構特徵的同時，仍具備足夠變異性。

如圖 4 所示，WGAN 在訓練過程中其損失函式值呈現穩定收斂趨勢，顯示模型已逐漸學習到真實 LFIA 影像資料之分布特性，且未出現明顯震盪或發散現象。由生成影像視覺化結果亦可觀察到，其在試線位置、背景紋理與整體亮度分布等關鍵視覺特徵上，皆與真實影像相符，顯示 WGAN 所生成之影像不僅具備良好視覺品質，亦保有足夠生醫判讀意義。本研究所建構之 WGAN 架構能有效擷取側層流免疫分析影像之關鍵結構特徵，並穩定產生具代表性與多樣性的合成影像，適用於後續分類神經網路之資料增強任務，亦為解決生醫影像資料不足問題提供一可行且具實務價值之技術途徑。

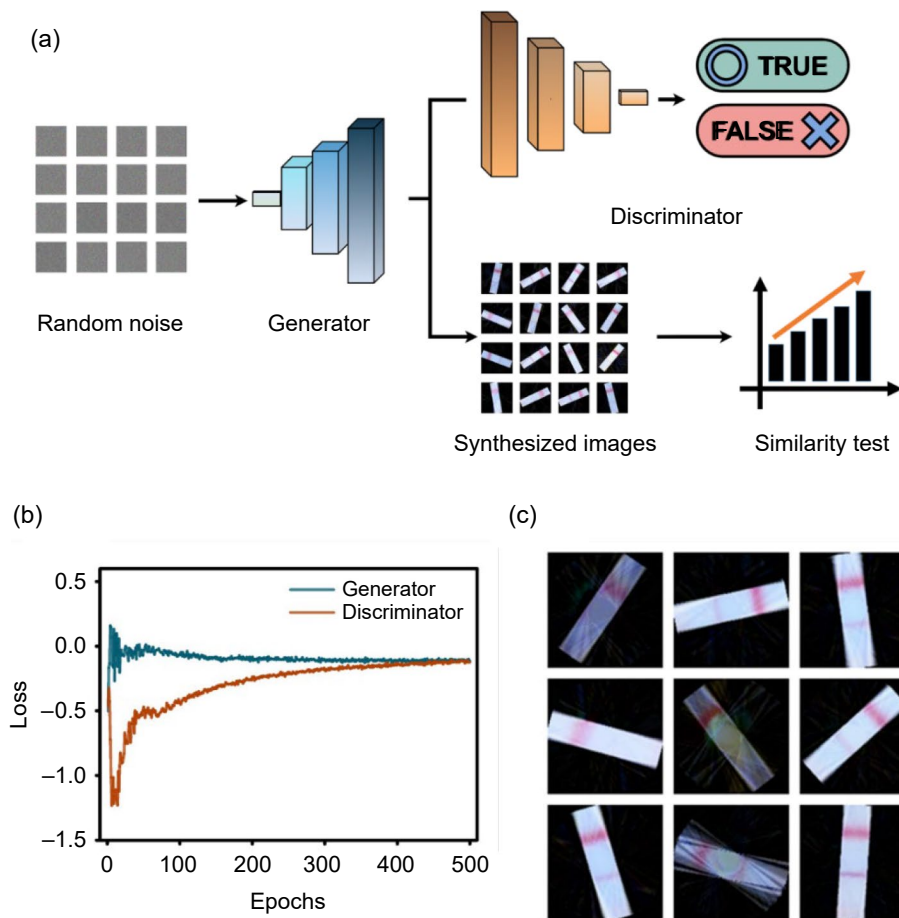


圖 4. (a) WGAN 之神經網路架構。(b) WGAN 之損失函數圖。(c) 最終生成之模擬圖像。

### 3. 神經網路穩定性驗證 (K-fold Cross Validation)

K-fold Cross Validation 為一常用於評估神經網路模型與輸入資料穩定性之方法<sup>(16-17)</sup>。本研究採用三折交叉驗證 (3-fold cross validation) 進行實驗設計，將資料集劃分為三個子集，每一折約包含 10,000 筆資料，並進行三次循環訓練，使各子集皆能輪流作為驗證資料使用。最終依據 K-fold Cross Validation 之計算方式，將各次訓練所獲得之損失函式值與分類準確率取平均，以作為評估模型穩定性與泛化能力之依據。

在分類模型設定方面，本研究統一採用 EfficientNet-Lite0 作為分類神經網路架構，批次大小 (batch size) 設定為 32，最佳化器採用 Adam，損失函式設定為 Cross Entropy Loss，並將每一循環訓練之訓練代數 (Epochs) 設定為 100，以確保模型於充分訓練條件下進行效能驗證。

本研究透過 K-fold Cross Validation 針對由真實資料與 WGAN 生成資料所構成之混合資料集進行分類模型訓練與評估。如圖 5 與表 3 所示，無論從損失函式或分類準確率之收斂趨勢觀察，模型在訓練中皆呈現穩定且一致之學習行為，顯示所建構之混合資料集具備良好之代表性與一致性，有助於分類神經網路有效學習影像特徵。最終結果顯示，利用 WGAN 生成影像所擴增之混合資料集進行訓練時，分類神經網路於測試集上可達到 95.67% 之分類準確率，驗證本研究所提出之資料生成與訓練流程於小樣本條件下，具備良好之穩定性與實務應用可行性。

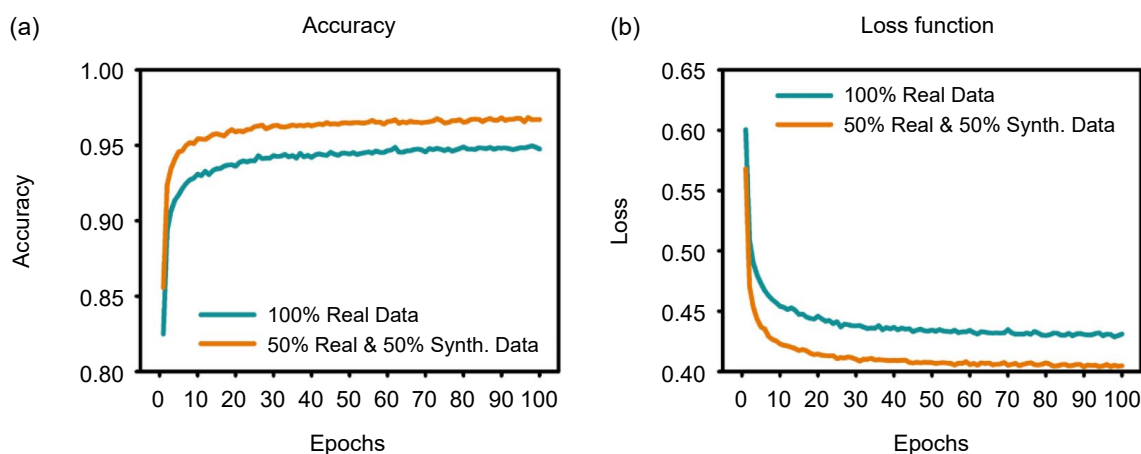


圖 5. 神經網路穩定性驗證與比較。(a) 不同資料組成之準確率圖。(b) 不同資料組成之損失函數圖。

表 3. 利用真實數據集與不同生成模式之混合數據集所訓練之 EfficientNet lite0，進行 K-fold Cross Validation 並應用於測試集資料之準確率。

Datasets	Accuracy (%)
Real data	95.54
Real data with WGAN	95.67

### 4. 訓練結果

為評估所提出之資料生成策略對分類模型效能之影響，本研究採用真實影像與 WGAN

生成影像所組成之混合資料集，訓練 EfficientNet-Lite0 作為分類神經網路，並於獨立測試集上進行效能驗證。其整體分類結果如表 4 與圖 6 所示。

由表 4 可知，該模型於測試集上達到整體準確率 (accuracy) 為 0.9563，顯示透過混合資料訓練後，分類模型能夠在三類別任務中維持穩定且高水準之辨識能力。進一步分析各類別之分類表現，blank 類別之敏感度與特異度分別為 0.9690 與 0.9600，顯示模型對於背景樣本具有良好的辨識與排除能力；high Concentration 類別之敏感度與特異度則分別達 0.9800 與 0.9900，為三類別中表現最佳者，顯示模型對高濃度樣本具備高度穩定且可靠的判別能力；low Concentration 類別雖因訊號較弱而具較高判別難度，其敏感度仍達 0.9200，特異度為 0.9845，顯示即使在低訊號條件下，模型仍可有效區分其與其他類別之差異。

由圖 6(a) 之混淆矩陣可觀察到，大多數樣本均能被正確分類，僅少部分樣本於 Blank 與 Low Concentration 之間出現誤判，推測其主因為低濃度影像在視覺特徵上與背景影像存在部分重疊，進而提高分類困難度。然而整體錯誤比例仍屬可接受範圍，顯示 WGAN 生成資料有助於提升模型對邊界樣本之辨識能力。此外，圖 6(b) 所示之 t-SNE 視覺化結果進一步驗證模型於特徵空間中的分類能力。由圖可明顯觀察到三類別樣本於低維特徵空間中呈現良好分群趨勢，各類別之間具有明確分界，且類內樣本分布集中，顯示 EfficientNet-Lite0 在混合資料訓練後，已能有效學習具判別力之深層特徵表示。透過 WGAN 所生成之影像與真實資料混合訓練，不僅有效擴增資料量與多樣性，亦顯著提升分類模型於小型資料集情境下之穩定性與泛化能力，證實本研究提出之資料生成與分類架構於側層流免疫分析影像判讀任務中具有高度可行性與實務應用潛力。

表 4. 利用真實數據集與 WGAN 生成圖像結合之混合數據集所訓練之 EfficientNet lite0，於測試集資料之準確率、敏感度與特異度。

Accuracy	Blank		High conc.		Low conc.	
	Sensitivity	Specificity	Sensitivity	Specificity	Sensitivity	Specificity
0.9563	0.9690	0.9600	0.9800	0.9900	0.9200	0.9845

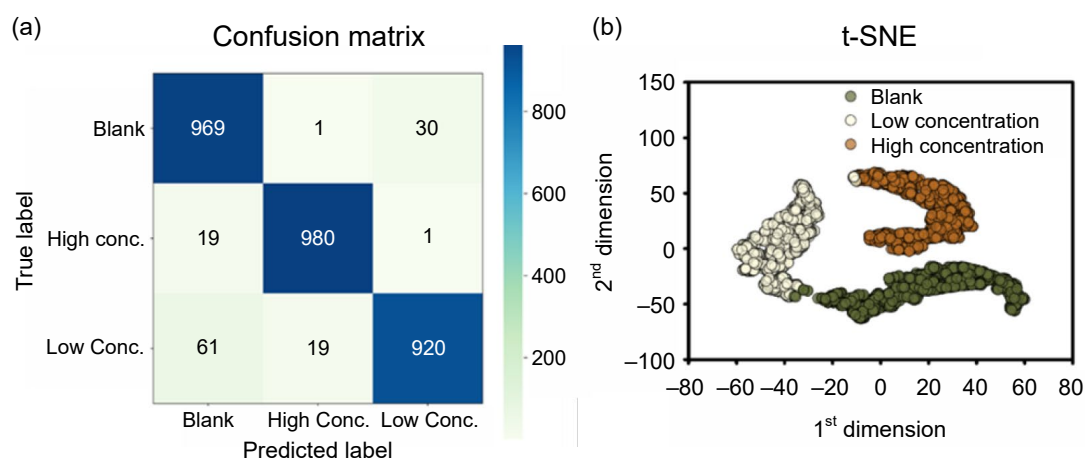


圖 6. 混合數據集訓練結果可視化。(a) 混淆矩陣。(b) t-SNE 圖。

## 四、結論

深度學習成功的關鍵在於大型且可靠的數據之建立與前處理，若是面對小型的資料庫，則時常產生過擬合或是欠擬合的狀況，因此如何用少量的數據訓練出高準確率的神經網路模型，一直是研究人員不斷追求的目標。本研究證明在訓練小型數據集之分類神經網路訓練時，利用生成式對抗神經網路針對資料進行資料生成，用以增加整體資料量，對於後續分類任務之表現有莫大的幫助。為了驗證相關模型的可行性，吾人選擇側層流免疫分析為檢測方法，記錄不同濃度下側層流免疫分析之影像，建立原始的小型數據集，再透過生成式對抗神經網路增加數據量，最終透過訓練分類神經網路分析其濃度狀態，並做為檢視側層流免疫分析結果之工具。

值得注意的是，儘管 LFIA 影像在像素空間中呈現高維度特性，但它們具有強烈的空間規律性，且 *intra-class variability* 相對較低。因此，其內在 *intrinsic data manifold* 的維度預計會遠低於原始的 *ambient space*。在這種條件下，本研究提出的 WGAN 架構能夠有效學習具備意義的數據分佈，且不會違背其底層假設。然而，若將此方法擴展至更複雜或非結構化的高維數據時，可能需要額外的架構約束或正規化 (*regularization*) 策略，這將在未來的研究中進一步探討。

未來可將本研究所提出之資料生成與分類架構推廣至其他生醫感測平台與快速診斷技術，例如電化學感測、生物晶片或螢光檢測系統，以驗證其於不同感測形式下的通用性與穩定性。其次，未來可進一步導入半監督式或自監督式學習架構，結合未標註資料與生成資料，以降低對人工標註的依賴並提升模型實務可行性。然而，在實際之現場檢測應用情境中，環境條件仍可能造成額外變異，未來研究可透過資料增強或域適應等方法加以建模與補償，以進一步提升模型於真實應用場域中的穩健性。生成模型本身亦可進一步優化，例如透過更精細的條件式生成策略或跨域生成方法，使合成影像在生物特徵與結構上更貼近真實樣本。最後，未來亦可朝向即時診斷與臨床決策支援系統整合之方向發展，使所提出之方法不僅止於影像分類層級，更能實際參與臨床診斷流程，進一步提升快速診斷技術於資源有限環境中的實用價值。

## 參考文獻

1. K.J. Land, D.I. Boeras, X.S. Chen, A.R. Ramsay, and R.W. Peeling, *Nature microbiology*, **4**, 46 (2019).
2. D. Mabey, R. W. Peeling, A. Ustianowski, and M. D. Perkins, *Nature Reviews Microbiology*, **2**, 231 (2004).
3. A. C. Ghani, D. H. Burgess, A. Reynolds, and C. Rousseau, *Nature*, **528**, 50 (2015).
4. M. Zhang, X. Cui, and N. Li, *Materials Today Bio*, 100254 (2022).
5. J. Hu et al., *Sensors and Actuators B: Chemical*, **243**, 484 (2017).
6. K. Misawa, T. Yamamoto, Y. Hiruta, H. Yamazaki, and D. Citterio, *ACS sensors*, **5**, 2076 (2020).
7. K. M. Learmonth, D. A. McPhee, D. K. Jardine, S. K. Walker, T.-T. Aye, and E. M. Dax, *Journal of Clinical Microbiology*, **46**, 1692 (2008).
8. L. Yi and M.-W. Mak, *IEEE transactions on neural networks and learning systems*, **33**, 172 (2020).
9. S. Suh, H. Lee, P. Lukowicz, and Y. O. Lee, *Neural Networks*, **133**, 69 (2021).
10. S. Shao, P. Wang, and R. Yan, *Computers in Industry*, **106**, 85 (2019).
11. M. Tan and Q. Le, "Efficientnet: Rethinking model scaling for convolutional neural networks," *International conference on machine learning*, May 24 (2019).
12. Z. Wu, C. Shen, and A. Van Den Hengel, *Pattern Recognition*, **90**, 119 (2019).
13. P. Nagrath, R. Jain, A. Madan, R. Arora, P. Kataria, and J. Hemanth, *Sustainable cities and society*, **66**, 102692 (2021).

14. V. Vinolin and M. Sucharitha, *International Journal of Intelligent Systems*, **36**, 6503 (2021).
15. R. Bhatt, N. Naik, and V. K. Subramanian, *IEEE transactions on image processing*, **30**, 2611 (2021).
16. J. D. Rodriguez, A. Perez, and J. A. Lozano, *IEEE transactions on pattern analysis and machine intelligence*, **32**, 569 (2009).
17. T.-T. Wong and P.-Y. Yeh, *IEEE Transactions on Knowledge and Data Engineering*, **32**, 1586 (2019).

## 作者簡介

陳建甫先生為國立臺灣大學應用力學博士，現為國立臺灣大學應用力學研究所特聘教授，並合聘於臺大重點科技研究學院，同時擔任臺大半導體製程及系統研究中心與奈米機電系統研究中心主任。

Chien-Fu Chen received his Ph.D. from the Institute of Applied Mechanics, National Taiwan University. He is currently a Distinguished Professor at the Institute of Applied Mechanics, National Taiwan University (NTU). He also holds joint appointments with the Graduate School of Advanced Technology and the Global Undergraduate Program in Semiconductors and serves as Director of the Center for Semiconductor Processing and Systems Research, NTU.

盧建銘先生為國立臺灣大學應用力學研究所博士班研究生。

Jian-Ming Lu is currently a Ph.D. student at the Institute of Applied Mechanics, National Taiwan University.