

影像類別與分類模型之適配度與效率分析

陳鈺儒、高韓英*

中文摘要

本論文旨在探討各種神經網路模型應用於辨識不同圖像類別的適切程度。本論文收集了2018-2023已發表的影像處理相關論文，其中包括400筆以上之影像判別資料，根據使用的神經網路模型和分類結果進行了詳細分析和比較，並使用資料包絡分析(Data Envelopment Analysis, DEA)評估不同神經網路識別模型與圖像類別與之間的效率。本研究發現混合卷積神經網路(Hybrid CNN)應用於動物類別圖像，而使用深度卷積神經網路(Deep CNN)於植物圖像有較高的分類準確度與分類效率分數。研究結果對於理解圖像與模型之間的關聯性具有重要意義，也有助於選擇最適合的神經網路模型來處理不同類型的圖像數據，從而提高影像處理的準確度和效率。

關鍵詞：影像處理，類神經網路模型，資料包絡分析，效率評估

陳鈺儒，國立東華大學資訊工程系

高韓英(通訊作者)，國立東華大學資訊工程系教授，E-mail: teresak@gms.ndhu.edu.tw

Compatibility and Efficiency Analysis Between Image Categories and Classification Models

Yu-Ru Chen, Han-Ying Kao*

Abstract

This study aims to verify the compatibility between different image categories and neural network models. This work compiles papers published between 2018 and 2023 with experiments related to image processing, and conducts a detailed analysis and comparison of their classification results and model parameters. We also use Data Envelopment Analysis (DEA) to evaluate the efficiency for classifying various image category types by applying neural network models. This study finds that classifying animal images with hybrid convolutional neural networks (hybrid CNN) and classifying plant images with deep convolutional neural networks (deep CNN) gain higher classification accuracy as well as efficiency scores. The research findings are significant for understanding the relationship between image types and classification models, and beneficial in selecting the most suitable models for handling different types of image data. This can improve the accuracy and efficiency of image processing as suggested by the findings to of this paper.

Keywords: Image Processing, Neural Network Models, Data Envelopment Analysis, Efficiency Evaluation.

Yu-Ru Chen, Department of Computer Science and Information Engineering, National Dong Hwa University.
Han-Ying Kao (Corresponding Author), Professor, Department of Computer Science and Information Engineering, National Dong Hwa University, E-mail: teresak@gms.ndhu.edu.tw

壹、緒論

近年來，深度學習在影像處理[1]領域取得了顯著的突破，神經網路可以自動學習圖像中的特徵，並具有良好的分類性能。然而，神經網路的訓練過程需要大量的數據資料且耗時長，資料取得不易。另外，相同的神經網路模型在處理不同圖像類別的分類任務時，可能會受到樣本大小、參數設定、神經網路層數等因素的影響而產生差異。對於不同的神經網路模型，這種影響更加複雜，而這種不一致性可能對結果的準確性和穩定性造成重要影響。

因此，本研究的動機在於比較不同神經網路模型應用於不同圖像類型分類的結果，評估其分類性能和穩定性，進一步發現不同圖像類型與神經網路模型的適配程度，以提供更有效和準確的影像分類解決方案。

本研究將探討各種不同的神經網路模型，如人工神經網絡[2](Artificial Neural Network, ANN)卷積神經網路[3](Convolutional Neural Network, CNN)、Visual Geometry Group (VGG)[4]等，將使用上述模型來分類不同類型的圖像數據集，以比較它們在分類結果方面的表現，包含準確率(Accuracy)、精確率(Precision)、召回率(Recall)等[5]。為了評估分類性能和穩定性，本論文另使用資料包絡分析法(Data Envelopment Analysis, DEA)[6]作為效率衡量指標。透過這項研究將期望發現不同圖像類型之最佳的神經網路分類模型，為影像分類領域提供更深入的理解。

本研究之內容架構如圖 1 所示，本節緒論包含研究背景與內容，第二節文獻探討主要是說明本研究中所提到的相關評估指標、理論及方法，其中包含各類神經網路模型以及資料包絡分析法，第三節研究方法將說明資料收如何收集與缺失值處理與效率分析的數學模型與參數，第四節說明實證結果與分析，最末第五節敘述結論與未來研究方向。



圖 1. 研究內容架構圖

貳、文獻探討

一、影像處理應用

影像處理[1]是指對圖像進行分析、修改、加工、增強或理解的技術。它可以應用於各種領域，包括醫學影像、安全監控、人臉識別、自動駕駛、圖像檢索等。以下是一些影像處理的應用：

(一) 圖像增強和修復：

即通過降噪、去模糊、銳化、對比度增強等方法，改善圖像的品質和細節。

Liu [7] 提出了(Probabilistic Diverse GAN, PD-GAN), 一種用於圖像修補的概率多樣性生成對抗網絡。PD-GAN 可以生成多個修補結果, 並且這些修補結果在帶有不同孔洞區域的圖像修復上較完整逼真。

(二) 特徵檢測和提取:

識別圖像中的特定對象、形狀、邊緣或紋理, 例如人臉檢測、物體識別、角點檢測等。Chai[8]提出了一種用於 3D 物體檢測的方法, 可以在 2D 透視範圍影像中學習 3D 表示。並通過融合攝像頭影像來提高效率。在 Waymo Open 數據集上, 他們的方法在行人檢測方面表現優秀, 模型較小效率較高。

(三) 圖像分割:

將圖像分成不同的區域或對象, 例如醫學影像中的器官分割、物體分割等。Lu[9]提出計算機視覺越來越擅長於在圖像和視頻中分割物體, 但通常忽略了與物體相關的場景效果, 如陰影、反射和煙霧等。為了解決這個問題, 使用自動識別物體及其效果並使用自監督方式, 只用普通視頻進行訓練, 無需手動標籤, 並且能自動生成各種物體和效果的全景遮罩。展示了現實世界視頻中不同主題(汽車、動物、人)之間的交互作用和複雜效果的結果。

(四) 物體追蹤和檢測:

追蹤和檢測圖像中的物體, 例如運動目標跟踪、行人檢測等。Stadler [10]提出了一種新的遮擋處理策略, 優於基於特徵的方法, 不需要單獨的重新識別網絡。改進了基於回歸的方法的軌跡管理, 處理缺失的檢測和處理離開圖像邊界的軌跡。進一步提高了性能並超越了最先進的方法。

(五) 圖像分類和識別:

根據圖像的內容將其歸類到不同的類別中, 例如手寫數字識別、圖像分類等。Yan [11]提出一個名為「Primitive Representation Learning Network (PREN)」的網絡, 用於將視覺文字表示應用於並行解碼。將視覺文字表示與帶有 2D 注意機制的編碼器-解碼器模型結合, 提出了名為「PREN2D」的框架, 以解決注意力方法中的對齊問題。在英文和中文場景文字識別任務上的實驗結果表明, PREN 在準確性和效率之間取得了平衡, 而 PREN2D 有更好的表現。

二、神經網路模型

影像處理常見的模型有人工神經網路(Artificial Neural Networks, ANN)與卷積神經網路, ANN 模仿生物神經網路的結構。而卷積神經網路 (Convolutional Neural Networks, CNN), 是用於圖像處理的最常見模型之一, 在影像處理中佔有非常重要的地位, 在影像辨識上的精確度可以達到超過人類的水準。可有效地從圖像中提取特徵, 並在分類、檢測等任務中取得優秀的成果。以下將介紹重要的 CNN 模型:

(一) LeNet

LeNet 由 LeCun 等人[3]所提出, 該論文將 LeNet 應用於光學字元辨識(Optical character recognition, OCR)和文件中的字體識別(character recognition)。這篇論文的出現代表神經網路(Artificial Neural Networks, ANN)從傳統的對圖像進行直接操作, 演變成了現代的卷積神經網路 (Convolutional Neural Networks, CNN), 這種結構能夠從圖像中提取特徵, 為影像處理領域帶來了重大的進展。由圖 2

LeNet 模型架構圖中可以看到 LeNet 的網路架構共有七層：卷積層(Convolution)、池化層(Subsampling)、卷積層、池化層、全連接卷積層(Fully Connected)、全連接層、連接層(Gaussian Connection)。




圖 2. LeNet 模型架構圖[3]

(二) AlexNet

為 Krizhevsky [12]提出的卷積神經網路並在同年的 ImageNet LSVRC 競賽中奪得了冠軍。圖 3 為 AlexNet 模型架構圖中可以看到 AlexNet 的架構有八層，共使用五個卷積層、三個全連接層。新增的卷積層可以處理更複雜的圖像與更多的特徵。卷積操作後的特徵圖會通過 (Rectified Linear Unit, ReLU) 激活函數進行轉換將所有負值的輸出都設置為零從而引入了非線性。這有助於網絡更好地學習複雜的特徵和模式並減少不必要的資料。AlexNet 在深度學習和影像處理領域引起了重大的變革，使其不再只是學術研究的領域，而是實際應用的解決方案。這導致了神經網路在各種行業中的廣泛應用，包括金融[13]、醫療[14]、農業[15]等。




圖 3. AlexNet 模型架構圖[12]

(三) VGG

由 Simonyan & Zisserman [4]提出的卷積神經網路，並在 ImageNet LSVRC 的分類競賽中獲得了第二名。VGGNet 有許多不同的結構，例如 VGG11, VGG13, VGG16, VGG19，其差異在於網路的層數。與 AlexNet 相比 VGG 使用了更小的卷積核、更多的卷積層，這樣的設計增加了網路的深度，從而提升特徵提取的能力。VGG 的深度和簡單的架構啟發了許多後續的模型設計。它強調了增加網路深度的重要性，並通過使用多個小卷積核的方法來提取特徵。這個思想對於後來的深度模型設計，如 ResNet [16]和 Inception [17]等，產生了重大影響。

三、資料包絡分析法

由於神經網路在影像分類領域已經能夠獲得良好的分類結果，然而，對於不同圖像類別和不同神經網路模型，無法直接找到最好的分類結果而需要多種網路一起比較。因此，本研究使用資料包絡分析法(Data Envelopment Analysis, DEA)[6]作為評估效率的指標，以評估不同神經網路訓練參數對分類結果的相關程度。

資料包絡分析法是一種非參數的效率評估方法，用於評估相對效率和效能評估，本節將會介紹 DEA 在影像處理的應用與 DEA 中的 CCR 模型 Charnes, Cooper & Rhodes [18]與 BCC 模型 Banker, Charnes & Cooper [19]。

假設有 n 個決策單位需要被評估，每一決策單位均有 m 個投入 ($i=1, \dots, m$)、 s 個產出因子 ($r=1, \dots, s$)，分別以 $X_{1j}, X_{2j}, \dots, X_{mj}$ 和 $Y_{1j}, Y_{2j}, \dots, Y_{sj}$ ($j=1, \dots, n$) 表示投入與產出項目，則第 k 個決策單位的效率值 E_k 計算方式如式(1)所示，其中 v_i 和 u_r 所對應的投入與產出的加權權重， ε 為一個非負數的極小值，其主要的作用是確保所有的加權權重均為正數。效率值為 E_k 並介於 0 與 1 之間。

(一) CCR 線性模型

CCR 模型 [18]是由 Charnes、Cooper 和 Rhodes 於 1978 年提出的，它是 DEA 的最早發展的模型之一，也是 DEA 的基礎。CCR 模型主要用於評估多個相同或類似單元的相對效率。CCR 模型主要用於評估單元的相對效率也是本研究所使用的效率評估模型，CCR 模型通過建立線性規劃問題，計算每個單元的效率得分。在這個問題中，每個單元的輸入和產出數量作為變數，並且要滿足資源限制和生產平衡的條件。通過解決這個線性規劃問題，可以獲得每個單元的效率得分。

$$\begin{aligned} \text{Max } E_k &= \frac{\sum_{r=1}^s u_r Y_{rk}}{\sum_{i=1}^m v_i X_{ik}} \\ \text{s.t. } &\frac{\sum_{r=1}^s u_r Y_{rj}}{\sum_{i=1}^m v_i X_{ij}} \leq 1, \quad j=1, 2, \dots, n \\ &u_r, v_i \geq \varepsilon \quad r=1, 2, \dots, s, \quad i=1, 2, \dots, m \end{aligned} \quad (1)$$

$$\sum_{i=1}^m v_i X_{ik} = 1 \quad (2)$$

(二) BCC 線性模型

BCC 模型[19]在 CCR 模型的基礎上進一步發展而來，BCC 模型引入了一個額外的變數 u_0 來考慮生產過程的變動規模報酬情況。這個額外的變數使得 BCC 模型可更全面地評估決策單位的效率，包含衡量技術效率(Technical Efficiency, TE)與規模效率(Scale Efficiency, SE)，使其在效率評估上更為全面和有深度。在 BCC 模式中，上述 CCR 之數學模式(1)擴充為下列式(3)，原限制式(2)則不變。

$$\begin{aligned}
 \text{Max } E_k &= \frac{\sum_{r=1}^s u_r Y_{rk} - u_0}{\sum_{i=1}^m v_i X_{ik}} \\
 \text{s.t. } &\frac{\sum_{r=1}^s u_r Y_{rj} - u_0}{\sum_{i=1}^m v_i X_{ij}} \leq 1, \quad j = 1, 2, \dots, n \\
 &u_r, v_i \geq \varepsilon \quad r = 1, 2, \dots, s, \quad i = 1, 2, \dots, m \\
 &u_0 \quad \text{unrestricted in sign}
 \end{aligned} \tag{3}$$

(三) DEA 在影像處理的相關應用

DEA 在影像處理領域的應用相對較少，因為它主要用於評估效率、效能、生產效率、技術效率和經濟效率的方法，可以應用於各種組織和行業，例如企業、醫院、學校等。而在影像處理中更常見的是使用基於比較的定性評估、定量評估指標（如 PSNR、SSIM 等）以及人工智能模型的性能評估（如精度、召回率等）然而，DEA 作為一種效率評估方法，可以提供一種不同的視角，用於評估和比較影像處理的效率和效能。有關 DEA 在影像處理相關應用：Xie [20]提出了一種改善遙感影像融合的方法，該方法針對影像處理中的問題進行了改進。通過引入梯度約束項，該方法有效地將全色影像的空間訊息轉移到融合結果中。同時，利用核函數保留了多光譜影像的光譜信息。為了選擇最佳參數，研究採用資料包絡分析方法，並整合了當前最先進的影像質量指標。通過視覺知覺度量 and 融合指標的評估，實驗結果表明該方法優於其他常用的影像融合技術。Bozorgmanesh [21]這篇論文提出了一種結合資料包絡分析和影像處理的方法來改善影像分割的效果。該方法利用 DEA 作為評估性能的工具，用於比較不同的影像分割方法並選擇適當的參數值。通過將不同類別影像（如動物、建築等）的計算時間和準確性的平均值作為輸入和輸出，該方法處理了大量的輸入和輸出數據。實驗結果表明，所提出的方法在影像分割方面具有優越性能。

參、研究方法

本節說明研究流程架構、資料蒐集與處理、資料說明與投入產出項之選擇、及研究限制。

一、研究方法架構

本研究之研究方法根據圖 1 研究內容架構圖中的研究方法展開說明：

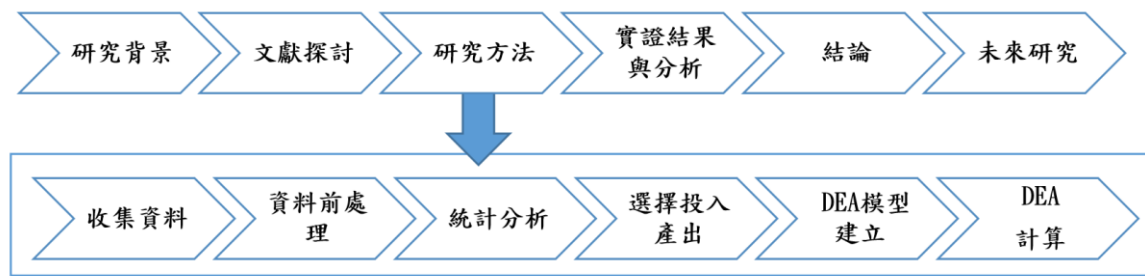


圖 4. 研究方法圖

- (一) 資料蒐集：收集來自 IEEE Xplore 的相關論文資料，包含 37 篇影像分類相關論文，並取得 400 筆不同影像類別、模型、參數的資料。
- (二) 資料前處理：對收集的資料進行整理與處理，包括新增欄位以及遺失值處理。
- (三) 統計資料分析：對已收集資料進行統計分析
- (四) 投入產出選擇：DEA 投入與產出變數選擇。
- (五) DEA 模型建立：建立 DEA 模型以計算各分類網路模式之效率。
- (六) DEA 效率計算。

二、資料蒐集與處理

本研究所蒐集的資料來自 IEEE Xplore Digital Library[22]，時間跨度為 2018 年至 2023 年。共收集了 37 篇與影像分類相關的論文，其中包括 28 篇會議論文和 9 篇期刊論文，共計 400 筆實驗資料。這些論文涵蓋了不同的影像類別、模型和參數。

本章節分為兩部分第一部分為所收集論文的影像分類，第二部分為所收集論文的模型分類。首先，本文將 37 篇影像分類論文分成 7 種影像類別分別是：動物(Animals)、身體部位(Body parts)、符號(character)、食物與飲料(Food and drink)、害蟲(Pest)、植物(Plant)、科技(Technology)。

- (一) 動物(Animals)包含：魚類與鳥類。[23-24]
- (二) 身體部位(Body parts)包含：牙齒、皮膚、細胞、腦。[25-35]
- (三) 符號(Character)包含：手寫文字與符號。[36-42]
- (四) 食物與飲料(Food and drink)包含：食物、水果、飲料。[43-46]
- (五) 害蟲(Pest)包含：蟲與果蠅。[47-49]
- (六) 植物(Plant)包含：花、樹、木頭、種子。[50-57]
- (七) 科技(Technology)包含：太陽能板與晶圓。[58-59]

其次，在模型分組部分，本研究考慮 AlexNet[12]、ANN[2]、CNN[3]、DenseNet[60]、EfficientNet[61]、GoogLeNet[62]、Inception[17]、KNN[56]、LeNet[3]、MobileNet[64]、ResNet[16]、SVM[56]、VGG[4]、Xception[65]、ShuffleNet[66]、SqueezeNet[67]、GhostNet[68] 和 random forest[48]等模型。將前述模型依照其特性和結構進行分類，以分析不同影像類別和不同神經網路模型的適切性，並為後續的效率分析提供基礎。

- (一) 人工神經網路(ANN)

ANN [37,41,48,57]人工神經網路是一種基於生物神經元結構的計算模型，它模仿人腦的神經元之間的連接和信息傳遞。人工神經網路可用於解決多種問題，包括影像處理、自然語言處理等。不同於卷積神經網路，ANN 通常是全連接的，每個神經元與上一層的每個神經元都有連接，因此在大型問題上可能需要更多的參數和計算資源。

(二) 傳統卷積神經網路(Traditional CNN)：

傳統卷積神經網路是最早的卷積神經網路模型，包含 AlexNet、CNN、LeNet [23,28,29,33,37-41,45,48,50-52,56]，其與 ANN 的差異是新增了卷積層和池化層組成。這些層次的組合有助於提取圖像中的特徵，從而將複雜的圖像模式轉換為更高層次的表示。傳統 CNN 在影像分類、目標檢測等任務上取得了很好的成果，但在處理更深和複雜的模型時，可能會遇到梯度消失等問題。

(三) 深度卷積神經網路(Deep CNN)：

深度卷積神經網路是傳統 CNN 的延伸，包含 DenseNet、ResNet、VGG、Xception、Inception、GoogLeNet [23,24,27,28,30-32,36-40,43-48,50-56,58,59]，通常具有更深的網路結構，可以更有效地處理複雜的特徵。這種類型的模型通常包含更多的層次，如殘差塊(Residual Blocks)、密集塊(Dense Blocks)等，這些結構有助於解決梯度消失問題，並進一步提升性能。

(四) 輕量級卷積神經網路(Lightweight CNN)：

輕量級卷積神經網路是專為移動設備等資源受限的環境而設計的模型，包含 EfficientNet、MobileNet、ShuffleNet、SqueezeNet 和 GhostNet [25,32,36,40,43,46,47,52,56,58]，相較於傳統 CNN 或者深度 CNN，輕量級卷積神經網路使用可分離卷積等輕量級結構，以減少參數和計算量，但同時保持優秀的性能。

(五) 混合卷積神經網路(Hybrid CNN)：

包含 Semantic components and ResNet、CNN and SVM、Inception and ResNet [23-26,33-35,37,38,42,53,59]，其將多個不同結構或配置的 CNN 模型組合在一起，以提高整體性能。每個 CNN 可能具有不同的結構或是在不同的數據子集上訓練的，然後將它們組合起來形成一個更強大的模型。這種方法旨在充分利用多個 CNN 的優點，以提高模型的性能。

(六) 其他 Other：

常指的是基於傳統機器學習的模型，如支持向量機(SVM)和最近鄰居(KNN)等。這些方法在早期被廣泛應用於影像處理和分類任務。優勢在於解釋性強和易於實現，但在處理複雜的特徵和大數據時可能受限於性能。本類模式包含：SVM、KNN、HOG[46]、random forest 等[29,41,46,49,48,57]。

三、資料說明與投入產出項之選擇

(一) 資料欄位概述：

將介紹資料庫欄位，其中包含了論文本身原本存在的欄位，以及在整理資料後新增的欄位。經整理後資料可以讓資料更具有可解釋性和可用性，以便於進一

步的研究分析和結果呈現。

1. image type：圖像類別分類。
2. samples：資料庫圖片樣本大小。
3. training %：資料庫訓練圖片樣本百分比。
4. Validation %：資料庫驗證圖片樣本百分比。
5. Model：模型類別。
6. epoch：訓練的回合數。
7. batch：訓練的批次大小。
8. learning rate：學習率。
9. Training Accuracy：模型在訓練集上的準確率，如下式(4)所示：
 - True positive (TP): 預測為正例，實際為正例
 - True Negative (TN): 預測為正例，實際為負例
 - False Positive (FP): 預測為負例，實際為負例
 - False Negative (FN): 預測為負例，實際為正例

$$Accuracy = \frac{TN+TP}{TP+TN+FP+FN} \quad (4)$$

10. Val Accuracy：模型在驗證集上的準確率。
11. Testing Accuracy：模型在測試集上的準確率。是最終用來評估模型性能的指標。模型在測試數據上的表現反映其在實際應用中的能力。
12. Merge ACC：新增欄位，Merge ACC 是一個用於合併不同準確率結果的欄位。由於每篇論文的實驗設計可能不同，導致準確率結果表達存在差異性，有時可能會缺少 Training Accuracy、Val Accuracy 或 Testing Accuracy 數據。在本論文中，首先以 Testing Accuracy 代表準確度若無此資料依次以此類推，利用 Val Accuracy 和 Training Accuracy 代表準確度。本研究之 Merge ACC 選取邏輯如下：

```

if (testing_accuracy != "NA")
{
    merge_acc = testing_accuracy;
}
else if (val_accuracy != "NA")
{
    merge_acc = val_accuracy;
}
else if (training_accuracy != "NA")
{
    merge_acc = training_accuracy;
}
else
{
    merge_acc = "NA";
}
    
```

13. Recall：原本欄位，模型的召回率。召回率是指在所有真實正例中，模型成功找到並預測出的正例數量的比例，其計算公式如(5)所示：

$$Recall = \frac{TP}{TP+FN} \quad (5)$$

14. Precision：原本欄位，模型的精確率。精確率是指在所有被模型預測為正例的樣本中，實際為正例的數量的比例，其計算公式如(6)所示：

$$Precision = \frac{TP}{TP+FP} \quad (6)$$

15. F1-Score：原本欄位，模型的 F1 分數。F1 分數是召回率和精確率的調和平均值，它綜合考慮了兩者的影響，用於評估模型的整體性能。F1-Score 計算公式如(7) 所示：

$$F1-Score = \frac{2*(R*p)}{R+P} \quad (7)$$

(二) 使用欄位說明：經上述說明，本研究將使用以下欄位進行分析和評估：

1. image type：用於進行圖像類別分析。
2. samples：資料庫圖片樣本大小，是影像訓練模型的重要指標。
3. training %：訓練比例，表示資料庫中訓練圖片樣本所占的百分比。
4. Model：將所有訓練模型分為 6 類並以此欄位進行後續圖像類別分析。
5. epoch：訓練的回合數。是影像訓練模型的重要指標。
6. Merge ACC：評估模型在圖像分類結果的重要指標。
7. Recall：評估模型在圖像分類結果的重要指標。
8. Precision：評估模型在圖像分類結果的重要指標。

(三) DEA 模型參數描述

本研究根據資料包絡分析 CCR 模型乘法模型[69]設計，考慮 n 個決策單位（即本研究中之各實驗樣本），變數 X_{k1} 、 X_{k2} 、 X_{k3} 為決策單位 k 的三項投入變數，(samples、training %、epoch)， Y_{k1} 、 Y_{k2} 、 Y_{k3} 為各實驗樣本之三項產出變數 (Merge ACC、Recall、Precision)。 E_k 為效率分數，由於三項投入變數對於效率的影響為乘法性關係，所以在效率分式中採用相乘的方式計算 $X_{k1} * X_{k2} * X_{k3}$ ；三項產出變數相互獨立故在效率分式中採用加法型計算之。本研究之參數與變數如表 1 所示，變數之選擇說明如下所示。

投入變數選擇：將實驗的重要參數作為投入變數。在資料表中，收集了樣本數(samples)、訓練比率(training %)、測試比例(testing %)、驗證比例(validation %)、時期(epoch)、批次(batch)、學習率(learning rate)等。本研究認為樣本數與訓練比率、時期等參數較為重要且資料較完整，因此將這些參數視為投入變數，由於以上變數相互影響故使用相乘的方式評估模型的效率。

產出變數之選擇：本研究認為準確度(Accuracy)是重要的評估指標，然而由於每篇論文的實驗結果呈現方式各不相同，導致資料表中可能缺乏準確度指標。為解決此問題，本研究新增了 Merge ACC 欄位，用於合成模型效能的準確度指標。另外，部分論文可能未提供準確度，而使用精確率(Precision)、召回率(Recall)和 F1-Score 等指標來評估模型。因此，選擇合成準確度(Merge ACC, 請參考第三章第三節說明)、精確率(Precision)和召回率(Recall)作為產出變數，以全面衡量模型效能。

<<表 1. DEA 模式之參數與變數列表>>

四、研究限制

本研究在探討影像分類相關論文時，僅限於收集了 2018 年至 2023 年期間在 IEEE Xplore 數據庫上發表的論文資料，並採用文獻回顧方法進行資料收集和分析。然而，由於蒐集範圍、報告差異和資料庫限制，本研究存在以下限制：

資料偏向性：某些特定的圖像類別、模型或參數的數據可能較為集中，而其他可能重要的領域未被完全納入，這可能導致對於整個領域的全面性理解不足。

資料差異：不同作者間可能使用不同的資料庫、模型、評估指標等，這可能對分析和結果產生影響，且難以進行直接比較。

分類器差異：許多論文中未明確交代 CNN 模型中特徵擷取和分類器的部分，本研究只採用模型與最後的分類準確度進行分析，未涵蓋所有分類器可能導致結果差異。

實驗驗證限制：本研究僅依賴文獻報告的結果，未進行實際實驗或執行模型等相關驗證，可能存在著實驗結果的限制和不確定性。

肆、實證結果與分析

一、統計分析

準確度為影像處理中的重要指標因此本節將對資料進行圖像分類與模型分類的統計分析，其中以合成準確度 Merge ACC 為主要分析對象。表 2 與圖 5 為 7 種圖像類別對神經網路模型 Merge ACC 的統計分析，共 328 筆實驗樣本資料(全部 400 筆扣除資料不全之 72 筆資料)，NA 代表資料過少無法計算，說明如下：

動物(Animals)：共有 3 種神經網路模型 Deep CNN、Hybrid CNN、Traditional CNN 其中表現最好的是 Hybrid CNN，平均 Merge ACC 為 0.9382，代表 Hybrid CNN 對動物的圖像具有非常出色的分類結果。

身體部位(Body parts)：共有 5 種神經網路模型 Deep CNN、Hybrid CNN、Lightweight CNN、Other、Traditional CNN 其中表現最好的是 Traditional CNN，Merge ACC 平均 0.9293 代表 Traditional CNN 對身體部位的圖像具有非常出色的分類結果。

符號(Character)：共有 6 種神經網路模型 ANN、Deep CNN、Hybrid CNN、Lightweight CNN、Other、Traditional CNN 其中表現最好的是 Hybrid CNN，平均 Merge ACC 平均 0.9651，代表 Hybrid CNN 對符號的圖像具有非常出色的分類結果。較差的是 Traditional CNN Merge ACC 平均 0.5254，造成 Traditional CNN 較低的原因可能為資料包含手寫文字與符號，且每種文字之間存在外觀差異，這使得模型在處理這些外觀差異時可能遇到困難。

食物與飲料(Food and drink)：共有 6 種神經網路模型 Deep CNN、Lightweight CNN、Other、Traditional CNN 其中表現最好的是 Traditional CNN，平均 Merge ACC 為 0.9836，代表 Traditional CNN 對食物與飲料的圖像具有非常出色的分類結果。較差的是 Deep CNN 在 Merge ACC 中最大最小值相差較大造成平均值較低，可能原因為食物和飲料類別包含了各種不同種類食物、水果和飲料，其外觀特徵和組成成分存在較大的多樣性導致分類結果差異較大。

害蟲(Pest)：共有 5 種神經網路模型 ANN、Deep CNN、Lightweight CNN、Other、Traditional CNN 其中表現最好的是 Other Merge ACC 平均 0.9612，代表 Other 對害蟲的圖像具有非常出色的分類結果。

植物(Plant)：共有 6 種神經網路模型 ANN、Deep CNN、Hybrid CNN、Lightweight CNN、Other、Traditional CNN 其中表現最好的是 Deep CNN 平均 Merge ACC 0.9339，代表 Deep CNN 對植物的圖像具有非常出色的分類結果。

科技(Technology)：共有 3 種神經網路模型 Deep CNN、Hybrid CNN、Lightweight CNN 其中表現最好的是 Lightweight CNN，平均 Merge ACC 0.9928 代表 Lightweight CNN 對科技的圖像具有非常出色的分類結果。

<<表 2. 圖像類別之 Merge ACC >>

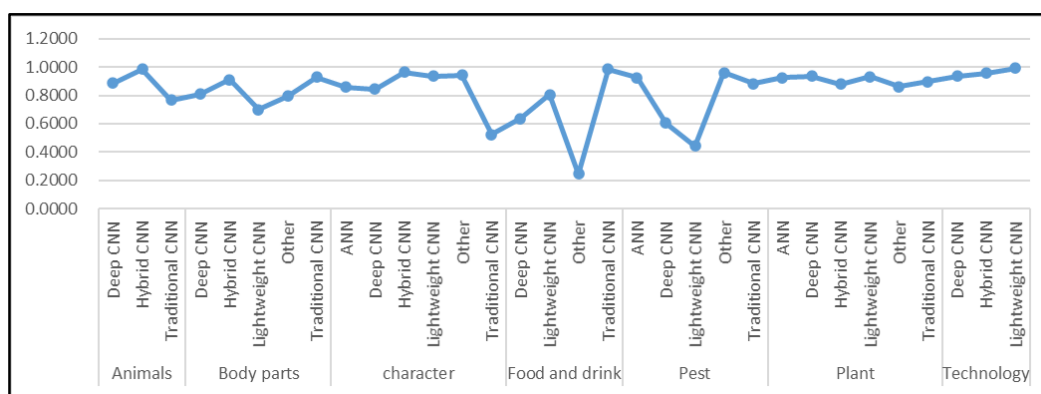


圖 5. 圖像類別之 Merge ACC 平均圖

表 3 與圖 6 為 6 種圖神經網路模型對圖像類別 Merge ACC 的統計分析，共 328 筆資料(全部 400 筆扣除資料缺值之 72 筆資料)，NA 代表資料過少無法計算，資說明如下：

(一) 人工神經網路(ANN)：

分析 3 種圖像類別 character、Pest、Plant，整體看來雖然資料量較少但是使用 ANN 的所有圖像類別都具有較好分類性能。

(二) 深度卷積神經網路(Deep CNN)：

分析 6 種圖像類別 Animals、Body parts、character、Food and drink、Pest、Plant，其中 Food and drink 與 Pest 類別表現較差，可能原因為食物和飲料類別包含了各種不同種類食物、水果和飲料，其外觀特徵的不同可能導致分類結果差異較大。害蟲類別的特徵相對較複雜，包括它們的外形、顏色、紋理等方面的變化。這些特徵可能在不同害蟲之間存在較大的差異，使得模型再提取和區分這些特徵時面臨一定問題，導致分類結果差異較大。

(三) 混合卷積神經網路(Hybrid CNN)：

分析 6 種圖像類別 Animals、Body parts、character、Plant，整體來看所有使

用 Hybrid CNN 的圖像類別都可以取得較好的分類成果。其中平均 Merge ACC 最高的為 Animals Merge ACC 平均 0.9999 代表 Hybrid CNN 對 Animals 圖像具有非常出色的分類結果。

(四) 輕量級卷積神經網路(Lightweight CNN)：

分析 6 種圖像類別 Body parts、character、Food and drink、Pest、Plant、Technology 其中除了 Pest 類別以外都有較高的分類結果，可能由於害蟲因為種類不同與特徵複雜造成使用 Lightweight CNN 分類無法取得較好的結果。

(五) 傳統卷積神經網路(Traditional CNN)：

分析 6 種圖像類別 Animals、Body parts、character、Food and drink、Pest、Plant，其中除了 character 類別以外都有較高的分類結果。這可能是因為 character 類別包含手寫文字，手寫文字受到寫字習慣、大小、工整程度等影響特徵可能較複雜，這使得模型在處理這些外觀差異時可能遇到困難，導致效率評估結果較低。

(六) 其他 Other：

分析 5 種圖像類別 Body parts、character、Food and drink、Pest、Plant，其中 Merge ACC 平均最低的為 Food and drink 為 0.2475，只有一筆資料可能由於資料較少而造成資料分類結果較差。Merge ACC 平均最高的為 Pest 為 0.9612，代表使用 Other 模型可能在 Pest 圖像分類上取得較好的結果。

整體而言 7 種圖像類別與神經網路模型都可以找到較好的分類結果即為較高的準確度，但每種模型所需要的訓練參數與結果都不同。因此本研究將以 DEA 分析模型的訓練參數與分類結果來衡量投入參數與產出分類結果之間的關係。

二、DEA 結果分析

本研究使用資料包絡分析法(DEA)對投入變數(samples、training %、epoch)，產出變數(Merge ACC、Recall、Precision) 進行效率分析並以 SCORE 代表效率分數，並將結果與 Merge ACC 一起進行分析。這有助於深入瞭解模型的效能和適用性。

<<表 3.模型類別之 Merge ACC >>




圖 6. 模型類別之 Merge ACC 平均圖

此外，由於 DEA 需要完整的投入與產出資料所以本研究在處理資料中的遺失值時提出了 3 種效率評估模型，以確保資料的完整性和分析的準確性：

模型 Model-A：模型 Model-A 為完整的數據，將刪除包含缺失值的資料項目，並直接對剩餘的完整資料進行分析，不需進行額外的處理步驟。5 種圖像類別與 5 種神經網路模型總共 47 筆資料。

模型 Model-B：模型 Model-B 為完整的投入與產出遺失值估計，對於投入資料存在缺失的資料項目刪除缺失的資料，並對於產出資料存在缺失的項目，將使用該指標的最小值來進行替代(Merge ACC 0.0351, Recall 0.2521, Precision 0.2460)。6 種圖像類別與 6 種神經網路模型總共 216 筆資料。

模型 Model-C：模型 Model-C 為投入與產出遺失值估計，對於投入資料存在缺失的資料項目使用該指標的平均值來進行替代(Samples 78631, training % 0.6604, epoch 71)；對於產出資料存在缺失的項目，使用該指標的最小值來進行替代(Merge ACC 0.0351, Recall 0.2521, Precision 0.2460)。7 種圖像類別與 6 種神經網路模型總共 400 筆資料。

上述模型確保資料在後續分析中的完整性與可靠性，同時克服了遺失值可能引發的分析偏差，進一步說明如下：

(一) 模型 Model-A

下表 4 為模型 Model-A 的圖像分類 DEA 效率分析，下圖 7 為模型 Model-A 的圖像分類 DEA 效率折線圖，SCORE 表示 DEA 模式計算之效率分數。

1. 身體部位(Body parts)：共有 3 種神經網路模型 Deep CNN、Hybrid CNN、Lightweight CNN，DEA SCORE 平均最高的為 Lightweight CNN SCORE 平均 0.1363 最低的為 Deep CNN SCORE 平均 0.3431，整體看來呈現 DEA SCORE 較低可能原因為在效率評估中無法充分利用資源或優化輸入輸出比導致身體部位 DEA 效率分數較低。
2. 符號(Character)：共有 3 種神經網路模型 Deep CNN、Hybrid CNN、Lightweight CNN，DEA SCORE 平均最高的為 Lightweight CNN SCORE 平均 0.2842 最低的為 Hybrid CNN SCORE 平均 0.1793，整體看來呈現 DEA SCORE 較低可能原因為在效率評估中無法充分利用資源或優化輸入輸出比導致符號 DEA 效率分數較低。
3. 食物與飲料(Food and drink)：共有 3 種神經網路模型 Deep CNN、Lightweight CNN、Other，DEA SCORE 平均最高的為 Lightweight CNN SCORE 平均 0.2842 最低的為 Other SCORE 平均 0.0457，其中 Other 模型 DEA SCORE 較其他模型低因此本研究認為 Other 與食物與飲料類別適配程度較低。
4. 害蟲(Pest)：共有 2 種神經網路模型 Deep CNN、Traditional CNN，DEA SCORE 平均最高的為 Traditional CNN SCORE 平均 0.2632 最低的為 Deep CNN SCORE 平均 0.2451，整體看來呈現 DEA SCORE 較低可能原因為在效率評估中無法充分利用資源或優化輸入輸出比導致害蟲 DEA 效率分數較低。
5. 植物(Plant)：共有 3 種神經網路模型 Deep CNN、Lightweight CNN、

Traditional CNN，DEA SCORE 平均最高的為 Deep CNN SCORE 平均 0.7155 最低的為 Lightweight CNN SCORE 平均 0.1614，其中 Deep CNN 模型 DEA SCORE 較其他模型高因此本研究認為 Deep CNN 與植物類別適配程度較高。

下表 5 為模型 Model-A 的模型分類 DEA 效率分析，下圖 8 為模型 Model-A 的模型分類 DEA 效率折線圖，進一步說明如下：

<<表 4.模型 Model-A 的圖像分類 DEA 效率分析>>




圖 7. 模型 Model-A 的圖像分類 DEA 效率折線圖

<<表 5.模型 Model-A 的模型分類 DEA 效率分析>>




圖 8. 模型 Model-A 的模型分類 DEA 效率折線圖

1. 深度卷積神經網路(Deep CNN): 共有 5 圖像類別 Body parts、character、Food and drink、Pest、Plant，DEA SCORE 平均最高的為 Plant SCORE 平均 0.7155 最低的為 Food and drink SCORE 平均 0.1155，其結果表明 Deep CNN 對 Plant 類別適配性較高與對 Food and drink 適配性較低。
2. 混合卷積神經網絡(Hybrid CNN): 共有 2 圖像類別 Body parts、character，DEA SCORE 平均最高的為 Body parts SCORE 平均 0.3439 SCORE 最低的為 character SCORE 平均 0.1793，整體看來呈現 DEA SCORE 較低可能原因為在效率評估中無法充分利用資源或優化輸入輸出比導致 Hybrid

CNN DEA 效率分數較低。

3. 輕量級卷積神經網路(Lightweight CNN): 共有 4 圖像類別 Body parts、character、Food and drink、Plant, DEA SCORE 平均 最高的為 Body parts SCORE 平均 0.3475 最低的為 Food and drink SCORE 平均 0.1323, 整體看來呈現 DEA SCORE 較低可能原因為在效率評估中無法充分利用資源或優化輸入輸出比導致 Lightweight CNN DEA 效率分數較低。
4. 其他 Other: 只有 Food and drink 類別 DEA SCORE 平均為 0.0457, 結果表明 Other 與 Food and drink 的適配度較低。
5. 傳統卷積神經網路(Traditional CNN)共有 2 圖像類別 Pest、Plant, DEA SCORE 平均 最高的為 Plant SCORE 平均 0.4390 最低的為 Pest SCORE 平均 0.2632, 整體看來呈現 DEA SCORE 較低可能原因為在效率評估中無法充分利用資源或優化輸入輸出比導致 Traditional CNN 效率分數較低。

(二) 模型 Model-B

下表 6 為模型 Model-B 的圖像分類 DEA 效率分析, 下圖 9 為模型 Model-B 的圖像分類 DEA 效率折線圖, 進一步說明如下:

1. 身體部位(Body parts): 共有 4 種神經網路模型 Deep CNN、Hybrid CNN、Lightweight CNN、Traditional CNN, DEA SCORE 平均最高的為 Hybrid CNN 0.3685 SCORE 最低的為 Hybrid CNN 0.3014, 整體看來呈現 DEA SCORE 較低可能原因為在效率評估中無法充分利用資源或優化輸入輸出比導致身體部位 DEA 效率分數較低。
2. 符號(Character): 共有 5 種神經網路模型 ANN、Deep CNN、Hybrid CNN、Lightweight CNN、Traditional CNN, DEA SCORE 平均 最高的為 Lightweight CNN 0.1361 SCORE 最低的為 Traditional CNN 0.0933, 其中 Traditional CNN 模型 DEA SCORE 較其他模型低因此本研究認為 Traditional CNN 與符號類別適配程度較低。
3. 食物與飲料(Food and drink): 共有 3 種神經網路模型 Deep CNN、Lightweight CNN、Other, DEA SCORE 平均最高的為 Hybrid CNN 0.3685 SCORE 最低的為 Other 0.0456, 其中 Other 模型 與模型 Model-A 相比其 DEA SCORE 依然較其他模型低因此本研究認為 Other 與食物與飲料類別適配程度較低。
4. 害蟲(Pest): 共有 5 種神經網路模型 Deep CNN、Hybrid CNN、Lightweight CNN、Other、Traditional CNN, DEA SCORE 平均最高的為 Other 0.4170 SCORE 最低的為 Lightweight CNN 0.0459, 其中 Lightweight 模型 DEA SCORE 較其他模型低因此本研究認為 Lightweight 與害蟲類別適配程度較低。
5. 植物(Plant): 共有 4 種神經網路模型 Deep CNN、Hybrid CNN、Lightweight CNN、Traditional CNN, DEA SCORE 平均最高的為 Deep CNN 0.5835 SCORE 最低的為 Lightweight CNN 0.2351, 其中 Deep CNN 模型與模型 Model-A 相比其 DEA SCORE 依然較其他模型高因此本研究認為 Deep

CNN 與植物類別適配程度較高。

6. 科技(Technology)：共有 2 種神經網路模型 Deep CNN、Lightweight CNN，DEA SCORE 平均最高的為 Deep CNN 0.3955 SCORE 最低的為 Lightweight CNN 0.3920，整體看來呈現 DEA SCORE 較低可能原因為在效率評估中無法充分利用資源或優化輸入輸出比導致身體部位 DEA 效率分數較低。

<<表 6.模型 Model-B 的圖像分類 DEA 效率分析>>




圖 9. 模型 Model-B 的圖像分類 DEA 效率折線圖

表 7 為模型 Model-A 的模型分類 DEA 效率分析，下圖 10 為模型 Model-A 的模型分類 DEA 效率折線圖。此外，根據不同分類模式分析如下：

<<表 7.模型 Model-B 的模型分類 DEA 效率分析>>




圖 10. 類別 B 的模型分類 DEA 效率折線圖

1. 人工神經網路(ANN)：共有 2 圖像類別 character、Pest，為模型 Model-B 新增的神經網路模型，DEA SCORE 平均最高的為 character 0.3317 SCORE 最低的為 Pest 0.2748，整體看來呈現 DEA SCORE 較低可能原因為在效率

評估中無法充分利用資源或優化輸入輸出比導致 ANN DEA 效率分數較低。

2. 深度卷積神經網路(Deep CNN)：共有 5 圖像類別 Body parts、character、Food and drink、Pest、Plant，DEA SCORE 平均最高的為 Plant 0.5835 SCORE 最低的為 Food and drink 0.0989 其結果依然表明 Deep CNN 對 Plant 類別適配性較高與對 Food and drink 適配性較低。
3. 混合卷積神經網路(Hybrid CNN)：共有 3 圖像類別 Body parts、character、Plant，DEA SCORE 平均最高的為 Body parts 0.3685 SCORE 最低的為 character 0.2353，整體看來呈現 DEA SCORE 較低可能原因為在效率評估中無法充分利用資源或優化輸入輸出比導致 Hybrid CNN DEA 效率分數較低。
4. 輕量級卷積神經網路(Lightweight CNN)：共有 6 圖像類別 Body parts、character、Food and drink、Plant、Pest、Technology，DEA SCORE 平均最高的為 Technology 0.3685 SCORE 最低的為 character 0.2353，整體看來呈現 DEA SCORE 較低可能原因為在效率評估中無法充分利用資源或優化輸入輸出比導致 Hybrid CNN DEA 效率分數較低。
5. 其他 Other：共有 2 圖像類別 Food and drink、Pest，Pest 為模型 Model-B 新增的圖像類別，DEA SCORE 平均最高的為 Pest 0.4170 SCORE 最低的為 Food and drink 0.0456 結果表明 Other 對 Pest 圖像類別適配性較高對 Food and drink 適配性較低。
6. 傳統卷積神經網路(Traditional CNN)共有 4 圖像類別 Body parts、character、Pest、Plant 其中 Body parts、character 為模型 Model-B 新增的圖像類別，DEA SCORE 平均最高的為 Body parts 0.3617 SCORE 最低的為 character 0.0933，結果表明 Traditional CNN 對 character 適配性較低。

(三) 模型 Model-C

下表 8 為模型 Model-C 的圖像分類 DEA 效率分析，下圖 11 為模型 Model-C 的圖像分類 DEA 效率折線圖。

<<表 8.模型 Model-C 的圖像分類 DEA 效率分析>>

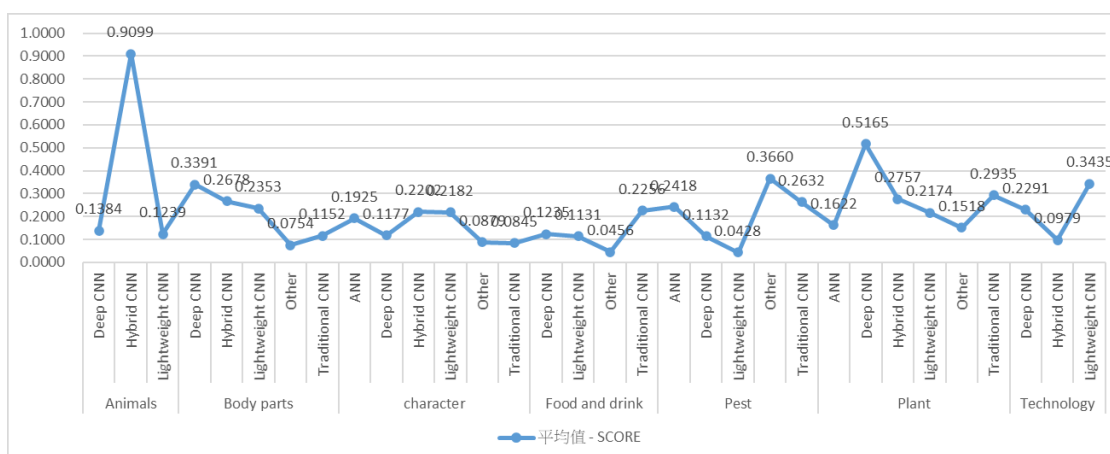


圖 11. 模型 Model-C 的圖像分類 DEA 效率折線圖

1. 動物(Animals)：共有 3 種神經網路模型 Deep CNN、Hybrid CNN、

Lightweight CNN，DEA SCORE 平均最高的為 Hybrid CNN SCORE 平均 0.9099 最低的為 Lightweight CNN SCORE 平均 0.1239，這表示相對於其他模型，Hybrid CNN 在動物圖像分類上具有較高的效率，這也代表動物類別對於 Hybrid CNN 的適配程度較高。

2. 身體部位(Body parts)：共有 4 種神經網路模型 Deep CNN、Hybrid CNN、Lightweight CNN、Other、Traditional CNN，DEA SCORE 平均最高的為 Deep CNN SCORE 平均 0.3391 最低的為 Other SCORE 平均 0.0754，結果表示 Other 在身體部位圖像分類適配程度較低。
3. 符號(Character)：共有 6 種神經網路模型 ANN、Deep CNN、Hybrid CNN、Lightweight CNN、Other、Traditional CNN，DEA SCORE 平均最高的為 Hybrid CNN SCORE 平均 0.2202 最低的為 Traditional CNN SCORE 平均 0.0845，整體看來與模型 Model-A、Model-B 相似依然呈現 DEA 效率較低的情況，也依然認為 Other 與食物與飲料類別適配程度較低。
4. 食物與飲料(Food and drink)：共有 3 種神經網路模型 Deep CNN、Lightweight CNN、Other、Traditional CNN，DEA SCORE 平均最高的為 Traditional CNN SCORE 平均 0.2256 最低的為 Other SCORE 平均 0.0456，整體看來依然呈現 DEA 效率較低的情況。
5. 害蟲(Pest)：共有 6 種神經網路模型 ANN、Deep CNN、Hybrid CNN、Lightweight CNN、Traditional CNN，DEA SCORE 平均最高的為 Lightweight CNN SCORE 平均 0.3660 最低的為 Other SCORE 平均 0.0428，整體看來依然呈現 DEA 效率較低的情況。
6. 植物(Plant)：共有 4 種神經網路模型 ANN、Deep CNN、Hybrid CNN、Lightweight CNN、Other、Traditional CNN，DEA SCORE 平均最高的為 Deep CNN 0.35165 SCORE 平均 最低的為 Other SCORE 平均 0.1518，整體平均 SCORE 有些微下降但 Deep CNN SCORE 平均 0.5165 依然是相對較高的效率分數，依然可以認為植物圖像與 Deep CNN 較適配。
7. 科技(Technology)：共有 2 種神經網路模型 Deep CNN、Hybrid CNN、Lightweight CNN，DEA SCORE 平均最高的為 Lightweight CNN SCORE 平均 0.3435 S 最低的為 Hybrid CNN SCORE 平均 0.0979，整體看來依然呈現 DEA 效率較低的情況。

下表 9 為模型 Model-C 的模型分類 DEA 效率分析，下圖 12 為模型 Model-C 的模型分類 DEA 效率折線圖。此外，根據不同分類模式分析如下：

<<表 9.模型 Model-C 的模型分類 DEA 效率分析>>

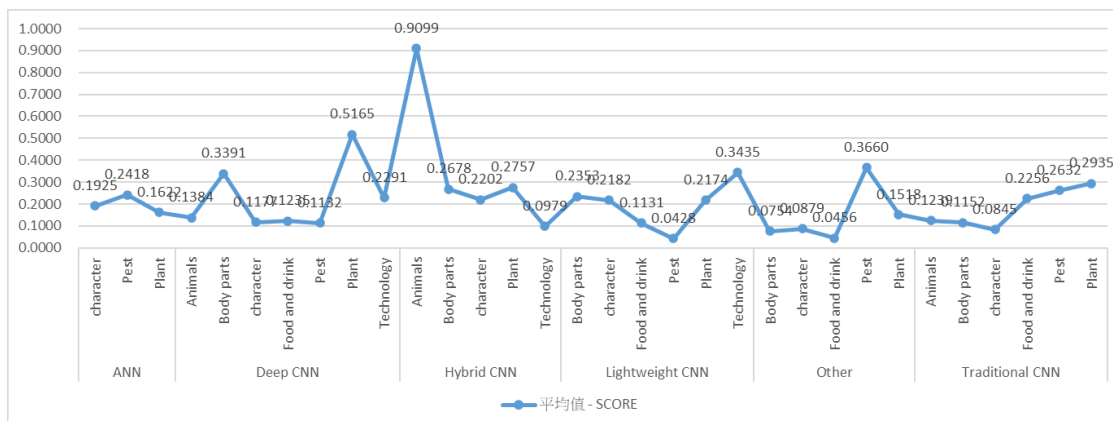


圖 12. 模型 Model-C 的模型分類 DEA 效率折線圖

1. 人工神經網路(ANN): 共有 3 圖像類別 character、Pest、Plant，DEA SCORE 平均最高的為 Pest SCORE 平均 0.2418 最低的為 Plant SCORE 平均 0.1622，整體看來依然呈現 DEA 效率較低的情況。
2. 深度卷積神經網路(Deep CNN): 共有 7 圖像類別 Animals、Body parts、character、Food and drink、Pest、Plant、Technology，DEA SCORE 平均最高的為 Plant 0.5165 SCORE 平均最低的為 Pest SCORE 平均 0.1132，整體看來 Plant 類別相較於其他類別效率較高，代表 Deep CNN 對 Plant 類別適配性較高。
3. 混合卷積神經網路(Hybrid CNN): 共有 5 圖像類別 Animals、Body parts、character、Plant、Technology，DEA SCORE 平均最高的為 Animals SCORE 平均 0.9099 最低的為 Technology SCORE 平均 0.0979，結果表明 Hybrid CNN 對 Animals 類別適配性較高。
4. 輕量級卷積神經網路(Lightweight CNN): 共有 6 圖像類別 Body parts、character、Food and drink、Pest、Plant、Technology，DEA SCORE 平均最高的為 Technology SCORE 平均 0.3435 最低的為 Pest SCORE 平均 0.0428，結果依然代表 Lightweight CNN 對 Pest 類別適配性較低。
5. 其他 Other: 共有 5 圖像類別 Animals、Body parts、character、Food and drink、Pest、Plant，DEA SCORE 平均最高的為 Pest SCORE 平均 0.3660 最低的為 Food and drink SCORE 平均 0.0456，結果依然代表 Other 對 Food and drink 適配性較低。
6. 傳統卷積神經網路(Traditional CNN)共有 6 圖像類別 Animals、Body parts、character、Food and drink、Pest、Plant，DEA SCORE 平均最高的為 Plant 平均 0.2935 最低的為 character SCORE 平均 0.0845 其中 character 結果依然代表 Traditional CNN 對 character 類別適配性較低。

下表 10 為模型 Model-ABC 的圖像分類 DEA 效率比較表，下圖 13 為模型 Model-ABC 的圖像分類 DEA 效率比較折線圖。

1. 動物(Animals): 共有 3 種神經網路模型 Deep CNN、Hybrid CNN、Lightweight CNN，此為模型 Model-C 新增的圖像類別，以模型 Model-C 結果來看，Hybrid CNN 對動物圖像分類上具有較高的效率，這也表示動物類別對於 Hybrid CNN 的適配程度較高。

2. 身體部位(Body parts)：共有 4 種神經網路模型 Deep CNN、Hybrid CNN、Lightweight CNN、Other、Traditional CNN，在模型 Model-ABC 所有 DEA SCORE 平均中最低的為模型 Model-C 新增的 Other SCORE 平均 0.0754，結果表示 Other 在身體部位圖像分類適配程度較低，
3. 符號(Character)：共有 6 種神經網路模型 ANN、Deep CNN、Hybrid CNN、Lightweight CNN、Other、Traditional CNN，整體看來與模型 Model-A、Model-B 相似依然呈現 DEA 效率較低的情況，結果顯示 Other 與食物與飲料類別適配程度較低。
4. 食物與飲料(Food and drink)：共有 3 種神經網路模型 Deep CNN、Lightweight CNN、Other、Traditional CNN，整體看來與模型 Model-A、Model-B 相似依然呈現 DEA 效率較低的情況。
5. 害蟲(Pest)：共有 6 種神經網路模型 ANN、Deep CNN、Hybrid CNN、Lightweight CNN、Traditional CNN，DEA SCORE 最高的為 Lightweight CNN 整體看來與模型 Model-A、Model-B 相似依然呈現 DEA 效率較低的情況。
6. 植物(Plant)：共有 4 種神經網路模型 ANN、Deep CNN、Hybrid CNN、Lightweight CNN、Other、Traditional CNN，在模型 Model-ABC 所有 DEA SCORE 平均中 Deep CNN SCORE 平均 0.5165 依然是相對較高的效率分數，依然可以認為植物圖像與 Deep CNN 較適配。
7. 科技(Technology)：共有 2 種神經網路模型 Deep CNN、Hybrid CNN、Lightweight CNN，整體看來與模型 Model-A、Model-B 相似依然呈現 DEA 效率較低的情況。

<<表 10.模型 Model-ABC 的圖像分類 DEA 效率比較表>>

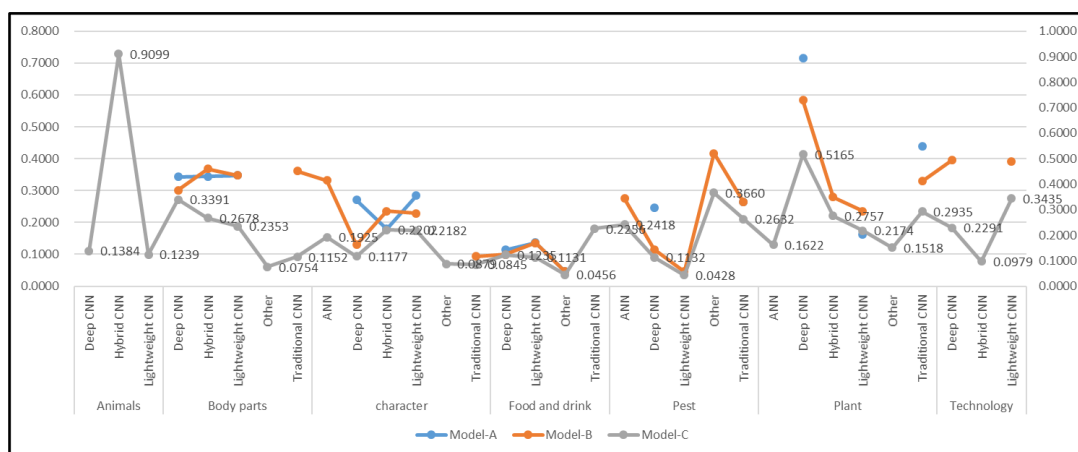


圖 13. 模型 Model-ABC 的圖像分類 DEA 效率折線圖

下表 11 為模型 Model-ABC 的模型分類 DEA 效率比較表，下圖 14 為模型 Model-ABC 的模型分類 DEA 效率比較折線圖。此外，就分類模式分析：

1. 人工神經網路(ANN)：共有 3 圖像類別 character、Pest、Plant，整體看來與模型 Model-A、B 相似依然呈現 DEA 效率較低的情況。
2. 深度卷積神經網路(Deep CNN)：共有 7 圖像類別 Animals、Body parts、

character、Food and drink、Pest、Plant、Technology，在模型 ABC 所有 DEA SCORE 平均中 Plant 類別相較於其他類別效率較高，代表 Deep CNN 對 Plant 類別適配性較高。

3. 混合卷積神經網絡(Hybrid CNN)：共有 5 圖像類別 Animals、Body parts、character、Plant、Technology，在模型 Model-ABC 所有 DEA SCORE 平均中 Animals SCORE 平均 0.9099 效率結果表明 Hybrid CNN 對 Animals 類別適配性較高。
4. 輕量級卷積神經網路(Lightweight CNN)：共有 6 圖像類別 Body parts、character、Food and drink、Pest、Plant、Technology，其中 Pest 依然與模型 B 相似代表 Lightweight CNN 對 Pest 類別適配性較低。
5. 其他 Other：共有 5 圖像類別 Animals、Body parts、character、Food and drink、Pest、Plant，其中 Food and drink 與模型 Model-A、B 相似依然代表 Other 對 Food and drink 適配性較低。Body parts、character DEA 效率分數較低可能原因為模型 Model-C 對於投入資料存在缺失的資料使用該指標的平均值替代；對於產出資料存在缺失資料使用最小值來進行替代。而造成效率分數下降。
6. 傳統卷積神經網路(Traditional CNN)：共有 6 圖像類別 Animals、Body parts、character、Food and drink、Pest、Plant，character 依然與模型 Model-B 相似代表 Traditional CNN 對 character 類別適配性較低。

<<表 11. 模型 Model-ABC 的模型分類 DEA 效率比較表>>

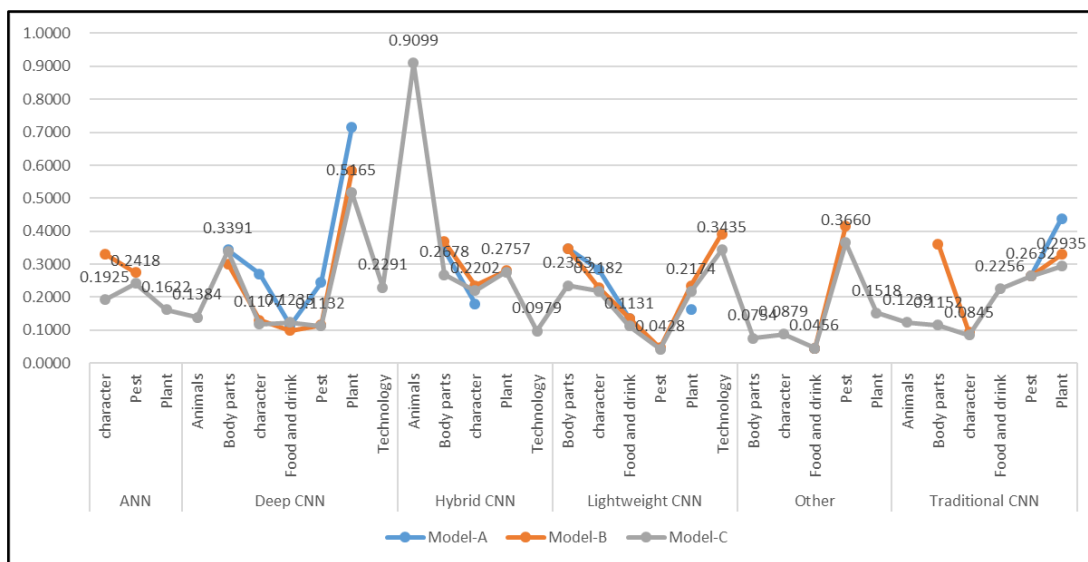


圖 14. 模型 Model-ABC 的模型分類 DEA 效率比較折線圖。

本研究發現 DEA 效率分析中動物類別與 Hybrid CNN 適配性較高，植物類別與 Deep CNN 適配性較高。其他影像類別與神經網路模型 DEA 效率分數較低的可能原因為以下兩點 1.每種圖像類型包含較多圖像例如符號類別包含手寫文字與符號，這種特徵不同造成模型在前處理與訓練上有許多差異。2.產出缺值資料使用最小值填補，造成效率分數較低。

伍、結論與未來研究方向

本研究根據包括七種影像類別及六種神經網路模型的 400 筆資料，進行分析與分類效率評估。探討了不同圖像類型與神經網路模型之間的適配程度，以減少在不同神經網路模型參數測試方面所需的時間，同時也追求更優異的準確度。

透過 DEA 計算圖像類別與神經網路模型的分類效率，本研究歸納適配的圖像類別與神經網路模型：Hybrid CNN 用於判讀動物圖像、與 Deep CNN 用於判別植物圖像，分別得到最高準確度，這顯出不同圖像類別下模型選擇的重要性。

本研究不僅為不同圖像類別的分類任務提供了神經網路模型選擇的建議，同時也揭示了模型在不同類別中性能的差異。這些發現對於進一步改進和優化影像處理模型具有參考價值，也為未來相關研究提供了有價值的啟示。

本研究有以下幾點可在未來檢討與改進：

一、增加影像分類論文數量

增加論文數量有助於深入瞭解不同影像類別和模型之間的效能差異，並提供更全面的效能評估結果。

二、對結果進行實驗或執行模型

對結果進行實驗與分析以驗證本研究提出的結論和發現，可以通過使用相同的影像類別和模型，以及相似的評估方法和指標來進行實驗。這將有助於驗證結果的可靠性。

三、對不同投入與產出進行分析

進一步分析和探討不同投入與產出之間的關係，以及使用更全面的效能評估方法，將有助於深入瞭解模型的效能和改進的方向。這將提高研究的可靠性和實用性，並為相關領域的應用提供更具價值的結果和建議。

參考文獻

- Gupta, D., Bhurchandi, K., & Murala, S. (2022). Computer Vision and Image Processing: 7th International Conference, Nagpur, India, November 4-6, 2022, Revised Selected Papers, Part I.
- Frank Rosenblatt (1957). The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. *Psychological Review*, 65(6), 386-408.
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-Based Learning Applied to Document Recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- Simonyan, K., & Zisserman, A. (2015). Very Deep Convolutional Networks for Large-Scale Image Recognition. *Proceedings of the International Conference on Learning Representations (ICLR)*.
- T.Saranyaa, S.Sridevi, C.Deisyc, Tran Duc Chungd, M.K.A.Ahamed Khane. (2019). Performance Analysis of Machine Learning Algorithms in Intrusion Detection System: A Review. In *Proceedings of the Third International Conference on Computing and Network Communications (CoCoNet'19)*
- Farrell, M.J. (1957). The Measurement of Productive Efficiency. *Journal of the Royal Statistical Society*, 120, 253-290.
- Liu, H. (2021). PD-GAN: Probabilistic Diverse GAN for Image Inpainting. *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 20-25 June 2021. DOI: 10.1109/CVPR46437.2021.00925
- Chai, Y. (2021). To the Point: Efficient 3D Object Detection in the Range Image with Graph Convolution Kernels. *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 20-25 June 2021. DOI:10.1109/CVPR46437.2021.01574
- Lu, E. (2021). Omnimatte: Associating Objects and Their Effects in Video. *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 20-25 June 2021. DOI: 10.1109/CVPR46437.2021.00448
- Stadler, D. (2021). Improving Multiple Pedestrian Tracking by Track Management and Occlusion Handling. *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 20-25 June 2021. DOI: 10.1109/CVPR46437.2021.01081
- Yan, R. (2021). Primitive Representation Learning for Scene Text Recognition. *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 20-25 June 2021. DOI: 10.1109/CVPR46437.2021.00035
- Krizhevsky, A. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90
- Barra, S. (2020). Deep learning and time series-to-image encoding for financial forecasting. *IEEE/CAA Journal of Automatica Sinica*, 7(3), 683-692. DOI: 10.1109/JAS.2020.1003132
- Tian, Z. (2022). Retinal Medical Image Classification Based on Deep Convolutional Neural Network AlexNet. *The 4th International Conference on Industrial Artificial Intelligence (IAI)*, 24-27 August 2022. DOI: 10.1109/IAI55780.2022.9976745
- Dong, C. (2021). Classification of strawberry diseases and pests by improved AlexNet deep learning networks. In *Proceedings of the 13th International Conference on Advanced*

- Computational Intelligence (ICACI), May 14-16, 2021, pp. 1-6. DOI: 10.1109/ICACI52617.2021.9435893
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 770-778.
- Szegedy, C. (2016). Rethinking the Inception Architecture for Computer Vision. In Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016. DOI: 10.1109/CVPR.2016.308
- Charnes, A., & Cooper, W. W., & Rhodes, E., Measuring the efficiency of decision making units. European Journal of Operational Research, 1978(2), 429-444.
- Banker, R.D., & Charnes, A., & Cooper, W.W., Some models for estimating technical and scale inefficiencies in data envelopment analysis. Management Science, 1984. 30, 1078-1092.
- Xie, Q. (2019). Image Fusion Based on Kernel Estimation and Data Envelopment Analysis. International Journal of Information Technology & Decision Making, 18(02), 487-515.
- Bozorgmanesh, H. (2022). Comparing image segmentation methods using data envelopment analysis. Computational Mathematics and Computer Modeling with Applications (CMCMA), 1(1), 48-55. DOI: 10.52547/CMCMA.1.1.48
- IEEE Xplore Digital Library. (2023). [<https://ieeexplore.ieee.org/Xplore/home.jsp>].
- Li, Y. (2022). The Fine-Grained Recognition of Bird Images Based on Joint Semantic Components and ResNet. In Proceedings of the 5th International Conference on Artificial Intelligence and Big Data (ICAIBD), May 27-30, 2022. DOI: 10.1109/ICAIBD55127.2022.9820403
- Agarwal, A. K. (2021). Transfer Learning Inspired Fish Species Classification. In Proceedings of the 8th International Conference on Signal Processing and Integrated Networks (SPIN), August 26-27, 2021.
- Shah, H. A. (2022). A Robust Approach for Brain Tumor Detection in Magnetic Resonance Images Using Finetuned EfficientNet. IEEE Access, 10, 65426-65438. DOI: 10.1109/ACCESS.2022.3184113
- Vo-Le, C. (2021). Breast Cancer Detection from Histopathological Biopsy Images Using Transfer Learning. In Proceedings of the 2020 IEEE Eighth International Conference on Communications and Electronics (ICCE), January 13-15, 2021. DOI: 10.1109/ICCE48956.2021.9352069
- Jibhakate, P. (2022). Early Glaucoma Detection Using Machine Learning Algorithms of VGG-16 and Resnet-50. In Proceedings of the 2022 IEEE Region 10 Symposium (TENSYMP), July 01-03, 2022. DOI: 10.1109/TENSYMP54529.2022.9864471
- Zhang, J. (2021). Image Detection of Dental Diseases Based on Deep Transfer Learning. In Proceedings of the 2nd International Conference on Artificial Intelligence and Computer Engineering (ICAICE), November 05-07, 2021. DOI: 10.1109/ICAICE54393.2021.00151
- Meng, N. (2019). Large-Scale Multi-Class Image-Based Cell Classification With Deep Learning. IEEE Journal of Biomedical and Health Informatics, 23(5), 2091-2098. DOI: 10.1109/JBHI.2018.2878878

- Huq, A. (2020). Robust Deep Neural Network Model for Identification of Malaria Parasites in Cell Images. In Proceedings of the 2020 IEEE Region 10 Symposium (TENSYMP), June 05-07, 2020. DOI: 10.1109/TENSYMP50017.2020.9230832
- Gurses, A. (2020). Tooth Restoration and Dental Work Detection on Panoramic Dental Images via CNN. In Proceedings of the 2020 Medical Technologies Congress, November 19-20, 2020. DOI: 10.1109/TIPTEKNO50054.2020.9299272
- Liu, J. (2022). VGG, MobileNet and AlexNet on Recognizing Skin Cancer Symptoms. In Proceedings of the 2022 3rd International Conference on Electronic Communication and Artificial Intelligence (IWECAI), January 14-16, 2022. DOI: 10.1109/IWECAI55315.2022.00107
- Duvvuri, K. (2022). Detection of Brain Tumor Using CNN and CNN-SVM. The 3rd International Conference for Emerging Technology (INCET), 27-29 May 2022. IEEE. DOI: 10.1109/INCET54531.2022.9824725.
- Mhasawade, A. (2023). Comparative study of SVM, KNN and Decision Tree for Diabetic Retinopathy Detection. The 2023 International Conference on Computational Intelligence and Sustainable Engineering Solutions, 1-6, . DOI: 10.1109/CISES58720.2023.10183456.
- Zhou, C. (2021). COVID-19 Detection Based on Image Regrouping and Resnet-SVM Using Chest X-Ray Images. IEEE Access, 9, 81902-81912. DOI: 10.1109/ACCESS.2021.3086229.
- Goel, P. (2022). A Pre-Trained CNN based framework for Handwritten Gujarati Digit Classification using Transfer Learning Approach. Proceedings of the 4th International Conference on Smart Systems and Inventive Technology (ICSSIT), January 20-22, 2022. DOI: 10.1109/ICSSIT53264.2022.9716483
- Miloud, K. (2021). Arabic Handwriting Recognition System Based on Genetic Algorithm and Deep CNN Architectures. Proceedings of the 2021 International Conference on Decision Aid Sciences and Application (DASA), December 07-08, 2021. DOI: 10.1109/DASA53625.2021.9682380
- Sun, J. (2022). Handwritten Ancient Chinese Character Recognition Algorithm Based on Improved Inception-ResNet and Attention Mechanism. Proceedings of the 2022 IEEE 2nd International Conference on Software Engineering and Artificial Intelligence (SEAI), June 10-12, 2022. DOI: 10.1109/SEAI55746.2022.9832356
- Zhao, Z. (2022). Research on single-character image classification of Tibetan ancient books based on deep learning. Proceedings of the 2022 3rd International Conference on Computer Vision, Image and Deep Learning & International Conference on Computer Engineering and Applications (CVIDL & ICCEA), May 20-22, 2022. DOI: 10.1109/CVIDLICCEA56201.2022.9824018
- Li, X. (2022). SwordNet: Chinese Character Font Style Recognition Network. IEEE Access, 10, 8388-8398. DOI: 10.1109/ACCESS.2022.3143795
- Liu, W. (2020). Comparisons on KNN, SVM, BP and the CNN for Handwritten Digit Recognition. The 2020 IEEE International Conference on Advances in Electrical Engineering and Computer Applications (AEECA) 1-5, DOI: 10.1109/AEECA49918.2020.9213482.
- Jindal, V. (2023). Multiclassification Hybrid Model Using CNN and SVM for National Emblems. The 2023 World Conference on Communication & Computing (WCONF)

- Yadav, S. (2021). Automated Food image Classification using Deep Learning approach. Proceedings of the 7th International Conference on Advanced Computing and Communication Systems (ICACCS), March 19-20, 2021. DOI: 10.1109/ICACCS51430.2021.9441889
- Mishra, R. (2022). Banana ripeness classification using transfer learning techniques. Proceedings of the 2022 International Conference on Computing, Communication, Security and Intelligent Systems (IC3SIS), June 23-25, 2022. DOI: 10.1109/IC3SIS54991.2022.9885244
- Abhijit, M. (2021). Detecting faulty bottle caps using CNN model. Proceedings of the 2nd International Conference on Smart Electronics and Communication (ICOSEC), October 07-09, 2021. DOI: 10.1109/ICOSEC51865.2021.9591780
- Nguyen, T. T. (2021). VinaFood21: A Novel Dataset for Evaluating Vietnamese Food Recognition. Proceedings of the 2021 RIVF International Conference on Computing and Communication Technologies (RIVF), August 19-21, 2021. DOI: 10.1109/RIVF51545.2021.9642151
- Zhou, S. (2020). Efficient Convolutional Neural Network for Pest Recognition - ExquisiteNet. Proceedings of the 2020 IEEE Eurasia Conference on IOT, Communication and Engineering (ECICE), October 23-25, 2020. DOI: 10.1109/ECICE50847.2020.9301938
- Peng, Y. (2019). FB-CNN: Feature Fusion-Based Bilinear CNN for Classification of Fruit Fly Image. IEEE Access, 8, 3987-3995. DOI: 10.1109/ACCESS.2019.2961767
- Tao, D. (2019). A Novel Model for Sex Discrimination of Silkworm Pupae From Different Species. IEEE Access, 7, 165328-165335. DOI: 10.1109/ACCESS.2019.2953040
- Singh, A. (2020). CNN Based Detection of Healthy and Unhealthy Wheat Crop. Proceedings of the 2020 International Conference on Smart Electronics and Communication (ICOSEC), September 10-12, 2020. DOI: 10.1109/ICOSEC49089.2020.9215340
- Satoto, B. D. (2021). Corn Seed Classification Using Deep Learning as an Effort to Increase Corn Productivity. Proceedings of the 2021 5th International Conference on Informatics and Computational Sciences (ICICoS), November 24-25, 2021. DOI: 10.1109/ICICoS53627.2021.9651846
- Narvekar, C. (2020). Flower classification using CNN and transfer learning in CNN - Agriculture Perspective. Proceedings of the 3rd International Conference on Intelligent Sustainable Systems (ICISS), December 03-05, 2020. DOI: 10.1109/ICISS49785.2020.9316030
- He, M. (2021). Flower Image Classification Based on Multi-scale Dense Residual Network. Proceedings of the 2021 6th International Conference on Image, Vision and Computing (ICIVC), July 23-25, 2021. DOI: 10.1109/ICIVC52351.2021.9526970
- Praba, R. D. (2021). Foliar Disease Classification in Apple Trees. Proceedings of the 2021 International Conference on Advancements in Electrical, Electronics, Communication, Computing and Automation (ICAECA), October 08-09, 2021. DOI: 10.1109/ICAECA52838.2021.9675529
- Hashim, N. M. Z. (2022). Grey Oyster Mushroom Classification toward a Smart Mushroom Grading System for Agricultural Factory. Proceedings of the 2nd International Conference on Intelligent Technologies (CONIT), June 24-26, 2022. DOI: 10.1109/CONIT55038.2022.9847864

- Liu, S. (2020). Real-time Classification of Rubber Wood Boards Using an SSR-based CNN. *IEEE Transactions on Instrumentation and Measurement*, 69(11), 8725 - 8734. DOI: 10.1109/TIM.2020.3001370
- Huixian, J. (2020). The Analysis of Plants Image Recognition Based on Deep Learning and Artificial Neural Network. *IEEE Access*, 8, 68828-68841.
- Chen, X. (2020). A Light-Weighted CNN Model for Wafer Structural Defect Detection. *IEEE Access*, 8, 24006-24018. DOI: 10.1109/ACCESS.2020.2970461
- Rahman, M. R. (2021). CNN-based Deep Learning Approach for Micro-crack Detection of Solar Panels. *Proceedings of the 3rd International Conference on Sustainable Technologies for Industry 4.0 (STI)*, December 18-19, 2021. DOI: 10.1109/STI53101.2021.9732592
- Huang, G. (2017). Densely Connected Convolutional Networks. In *Proceedings of the Conference on Computer Vision and Pattern Recognition (CVPR)*, arXiv:1608.06993
- Tan, M. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *Proceedings of the International Conference on Machine Learning (ICML)*, 2019. arXiv:1905.11946
- Szegedy, C. (2015). Going Deeper with Convolutions. *Proceedings of the Conference on Computer Vision and Pattern Recognition (CVPR)*, 2015. arXiv:1409.4842
- Nugrahaeni, R. A. (2016). Comparative analysis of machine learning KNN, SVM, and random forests algorithm for facial expression classification. *Proceedings of the 2016 International Seminar on Application for Technology of Information and Communication (ISEMANTIC)*, August 05-06, 2016. DOI: 10.1109/ISEMANTIC.2016.7873831
- Andrew G. (2017). MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. *Proceedings of the Computer Vision and Pattern Recognition (CVPR)*, arXiv:1704.04861
- Chollet, F. (2017). Xception: Deep Learning with Depthwise Separable Convolutions. *Proceedings of the Computer Vision and Pattern Recognition (CVPR)*, arXiv:1610.02357
- F. N. Iandola, M. W. Moskewicz, K. Ashraf, S. Han, W. J. Dally, and K. Keutzer, "Squeezenet: Alexnet-level accuracy with 50x fewer parameters and <1mb model size," arXiv:1602.07360, 2016.
- X. Zhang, X. Zhou, M. Lin, and J. Sun: "An extremely efficient convolutional neural network for mobile devices," arXiv:1707.01083, 2017.
- K. Han, Y. Wang, Q. Tian, J. Guo, C. Xu and C. Xu, "GhostNet: More Features from Cheap Operations," arXiv:1911.11907, 2020,.
- 吳, 何. (2008). 組織效率與生產力評估：資料包絡分析法. 前程文化事業股份有限公司.

表 11. DEA 模式之參數與變數列表

n	DEA 模式決策單位 (實驗樣本) 個數
s	DEA 模式產出個數, 本研究共有 3 項產出, (準確度、精確率、召回率)
m	DEA 模式投入個數, 本研究共有有 3 項投入, (樣本數、訓練比率、時期)
X_{k1}	代表決策單位 k 的 Samples 變數
X_{k2}	代表決策單位 k 的 training % 變數
X_{k3}	代表決策單位 k 的 epoch 變數
Y_{k1}	代表決策單位 k 的 Merge ACC 變數
Y_{k2}	代表決策單位 k 的 Recall 變數
Y_{k3}	代表決策單位 k 的 Precision 變數
E_k	決策單位 k 的效率值。

表 12. 圖像類別之 Merge ACC

image type	Model	平均值 - Merge ACC	標準差 - Merge ACC	最大值 - Merge ACC	最小值 - Merge ACC	計數 - Merge ACC
Animals	Deep CNN	0.8856	0.0458	0.9400	0.7700	10
	Hybrid CNN	0.9832	0.0259	0.9999	0.9318	11
	Traditional CNN	0.7667	NA	0.7667	0.7667	1
Body parts	Deep CNN	0.8104	0.2256	0.9860	0.3202	31
	Hybrid CNN	0.9108	0.0542	0.9830	0.7400	32
	Lightweight CNN	0.6999	0.4131	0.9920	0.4078	2
	Other	0.7938	0.2070	0.9990	0.2450	30
	Traditional CNN	0.9293	0.0698	0.9950	0.7050	33
character	ANN	0.8596	0.1505	0.9660	0.7531	2
	Deep CNN	0.8425	0.0963	1.0000	0.3522	74
	Hybrid CNN	0.9651	0.0111	0.9886	0.9417	11
	Lightweight CNN	0.9361	0.0409	0.9650	0.9071	2
	Other	0.9435	0.0035	0.9460	0.9410	2
	Traditional CNN	0.5254	0.3393	0.9903	0.0351	20
Food and drink	Deep CNN	0.6376	0.2496	0.9402	0.1266	32
	Lightweight CNN	0.8054	0.1065	0.9283	0.7399	3
	Other	0.2475	NA	0.2475	0.2475	1
	Traditional CNN	0.9836	NA	0.9836	0.9836	1
Pest	ANN	0.9250	NA	0.9250	0.9250	1
	Deep CNN	0.6033	0.1701	0.8500	0.4679	6
	Lightweight CNN	0.4433	0.0515	0.5232	0.3826	6
	Other	0.9612	0.0288	0.9946	0.9050	14
	Traditional CNN	0.8833	0.0491	0.9500	0.8333	4
Plant	ANN	0.9247	NA	0.9247	0.9247	1
	Deep CNN	0.9339	0.0492	0.9967	0.8352	24
	Hybrid CNN	0.8791	NA	0.8791	0.8791	6
	Lightweight CNN	0.9317	0.0143	0.9471	0.9188	3
	Other	0.8620	0.0036	0.8645	0.8594	2
	Traditional CNN	0.8973	0.0775	0.9672	0.7090	11
Technology	Deep CNN	0.9360	0.0527	1.0000	0.8530	14
	Hybrid CNN	0.9550	0.0198	0.9690	0.9410	2
	Lightweight CNN	0.9928	0.0188	1.0000	0.9463	8

表 13. 模型類別之 Merge ACC

Model	image type	平均值 - Merge ACC	標準差 - Merge ACC	最大值 - Merge ACC	最小值 - Merge ACC	計數 - Merge ACC
ANN	character	0.8596	0.1505	0.9660	0.7531	2
	Pest	0.9250	NA	0.9250	0.9250	1
	Plant	0.9247	NA	0.9247	0.9247	1
Deep CNN	Animals	0.8856	0.0458	0.9400	0.7700	10
	Body parts	0.8104	0.2256	0.9860	0.3202	31
	character	0.8425	0.0963	1.0000	0.3522	74
	Food and drink	0.6376	0.2496	0.9402	0.1266	32
	Pest	0.6033	0.1701	0.8500	0.4679	6
	Plant	0.9339	0.0492	0.9967	0.8352	24
	Technology	0.9360	0.0527	1.0000	0.8530	14
Hybrid CNN	Animals	0.9832	0.0259	0.9999	0.9318	11
	Body parts	0.9108	0.0542	0.9830	0.7400	32
	character	0.9651	0.0111	0.9886	0.9417	11
	Plant	0.8791	NA	0.8791	0.8791	6
	Technology	0.9550	0.0198	0.9690	0.9410	2
Lightweight CNN	Body parts	0.6999	0.4131	0.9920	0.4078	2
	character	0.9361	0.0409	0.9650	0.9071	2
	Food and drink	0.8054	0.1065	0.9283	0.7399	3
	Pest	0.4433	0.0515	0.5232	0.3826	6
	Plant	0.9317	0.0143	0.9471	0.9188	3
	Technology	0.9928	0.0188	1.0000	0.9463	8
Other	Body parts	0.7938	0.2070	0.9990	0.2450	30
	character	0.9435	0.0035	0.9460	0.9410	2
	Food and drink	0.2475	NA	0.2475	0.2475	1
	Pest	0.9612	0.0288	0.9946	0.9050	14
	Plant	0.8620	0.0036	0.8645	0.8594	2
Traditional CNN	Animals	0.7667	NA	0.7667	0.7667	1
	Body parts	0.9293	0.0698	0.9950	0.7050	33
	character	0.5254	0.3393	0.9903	0.0351	20
	Food and drink	0.9836	NA	0.9836	0.9836	1
	Pest	0.8833	0.0491	0.9500	0.8333	4
	Plant	0.8973	0.0775	0.9672	0.7090	11

表 14. 模型 Model-A 的圖像分類 DEA 效率分析

image type	Model	平均值 - SCORE	標準差 - SCORE	最大 - SCORE	最小 - SCORE	計數 - SCORE
Body parts	Deep CNN	0.3431	0.0019	0.3457	0.3411	4
	Hybrid CNN	0.3439	NA	0.3439	0.3439	1
	Lightweight CNN	0.3475	NA	0.3475	0.3475	1
character	Deep CNN	0.2703	0.0070	0.2774	0.2601	5
	Hybrid CNN	0.1793	0.0004	0.1799	0.1787	8
	Lightweight CNN	0.2842	NA	0.2842	0.2842	1
Food and drink	Deep CNN	0.1145	0.0274	0.1321	0.0674	5
	Lightweight CNN	0.1363	NA	0.1363	0.1363	1
	Other	0.0457	NA	0.0457	0.0457	1
Pest	Deep CNN	0.2451	0.0165	0.2567	0.2334	2
	Traditional CNN	0.2632	0.0146	0.2831	0.2483	4
Plant	Deep CNN	0.7155	0.4165	1.0000	0.1588	9
	Lightweight CNN	0.1614	0.0022	0.1629	0.1598	2
	Traditional CNN	0.4390	0.4859	1.0000	0.1538	3

表 15. 模型 Model-A 的模型分類 DEA 效率分析

Model	image type	平均值 - SCORE	標準差 - SCORE	最大 - SCORE	最小 - SCORE	計數 - SCORE
Deep CNN	Body parts	0.3431	0.0019	0.3457	0.3411	4
	character	0.2703	0.0070	0.2774	0.2601	5
	Food and drink	0.1145	0.0274	0.1321	0.0674	5
	Pest	0.2451	0.0165	0.2567	0.2334	2
	Plant	0.7155	0.4165	1.0000	0.1588	9
Hybrid CNN	Body parts	0.3439	NA	0.3439	0.3439	1
	character	0.1793	0.0004	0.1799	0.1787	8
Lightweight CNN	Body parts	0.3475	NA	0.3475	0.3475	1
	character	0.2842	NA	0.2842	0.2842	1
	Food and drink	0.1363	NA	0.1363	0.1363	1
	Plant	0.1614	0.0022	0.1629	0.1598	2
Other	Food and drink	0.0457	NA	0.0457	0.0457	1
Traditional CNN	Pest	0.2632	0.0146	0.2831	0.2483	4
	Plant	0.4390	0.4859	1.0000	0.1538	3

表 16. 模型 Model-B 的圖像分類 DEA 效率分析

image type	Model	平均值 - SCORE	標準差 - SCORE	最大 - SCORE	最小 - SCORE	計數 - SCORE
Body parts	Deep CNN	0.3014	0.0927	0.3455	0.1356	5
	Hybrid CNN	0.3685	0.0227	0.3889	0.3439	5
	Lightweight CNN	0.3474	NA	0.3474	0.3474	1
	Traditional CNN	0.3617	NA	0.3617	0.3617	1
character	ANN	0.3317	NA	0.3317	0.3317	1
	Deep CNN	0.1304	0.0781	0.4404	0.0569	74
	Hybrid CNN	0.2353	0.1010	0.4354	0.1787	11
	Lightweight CNN	0.2289	0.0783	0.2842	0.1735	2
	Traditional CNN	0.0933	0.0975	0.4230	0.0182	19
Food and drink	Deep CNN	0.0989	0.0343	0.1317	0.0390	11
	Lightweight CNN	0.1361	0.0001	0.1361	0.1360	2
	Other	0.0456	NA	0.0456	0.0456	1
Pest	Deep CNN	0.2748	NA	0.2748	0.2748	1
	Hybrid CNN	0.1158	0.1000	0.2557	0.0485	6
	Lightweight CNN	0.0459	0.0053	0.0542	0.0397	6
	Traditional CNN	0.4170	0.0623	0.4646	0.2688	14
Plant	Deep CNN	0.2632	0.0146	0.2831	0.2483	4
	Hybrid CNN	0.5835	0.3590	1.0000	0.1588	21
	Lightweight CNN	0.2801	0.0313	0.3139	0.2270	6
	Traditional CNN	0.2351	0.1277	0.3826	0.1598	3
	total	0.3300	0.2404	0.9846	0.1538	10
Technology	Deep CNN	0.3955	0.0914	0.5194	0.3031	4
	Lightweight CNN	0.3920	0.0793	0.5194	0.3020	8

表 17.模型 Model-B 的模型分類 DEA 效率分析

Model	image type	平均值 - SCORE	標準差 - SCORE	最大 - SCORE	最小 - SCORE	計數 - SCORE
ANN	character	0.3317	NA	0.3317	0.3317	1
	Pest	0.2748	NA	0.2748	0.2748	1
Deep CNN	Body parts	0.3014	0.0927	0.3455	0.1356	5
	character	0.1304	0.0781	0.4404	0.0569	74
	Food and drink	0.0989	0.0343	0.1317	0.0390	11
	Pest	0.1158	0.1000	0.2557	0.0485	6
	Plant	0.5835	0.3590	1.0000	0.1588	21
	Technology	0.3955	0.0914	0.5194	0.3031	4
Hybrid CNN	Body parts	0.3685	0.0227	0.3889	0.3439	5
	character	0.2353	0.1010	0.4354	0.1787	11
	Plant	0.2801	0.0313	0.3139	0.2270	6
Lightweight CNN	Body parts	0.3474	NA	0.3474	0.3474	1
	character	0.2289	0.0783	0.2842	0.1735	2
	Food and drink	0.1361	0.0001	0.1361	0.1360	2
	Pest	0.0459	0.0053	0.0542	0.0397	6
	Plant	0.2351	0.1277	0.3826	0.1598	3
	Technology	0.3920	0.0793	0.5194	0.3020	8
Other	Food and drink	0.0456	NA	0.0456	0.0456	1
	Pest	0.4170	0.0623	0.4646	0.2688	14
Traditional CNN	Body parts	0.3617	NA	0.3617	0.3617	1
	character	0.0933	0.0975	0.4230	0.0182	19
	Pest	0.2632	0.0146	0.2831	0.2483	4
	Plant	0.3300	0.2404	0.9846	0.1538	10

表 18. 模型 Model-C 的圖像分類 DEA 效率分析

image type	Model	平均值 - SCORE	標準差 - SCORE	最大 - SCORE	最小 - SCORE	計數 - SCORE
Animals	Deep CNN	0.1384	0.0115	0.1462	0.1082	10
	Hybrid CNN	0.9099	0.2592	1.0000	0.1312	11
	Lightweight CNN	0.1239	NA	0.1239	0.1239	1
Body parts	Deep CNN	0.3391	0.0942	0.4367	0.0996	31
	Hybrid CNN	0.2678	0.0567	0.4279	0.2149	32
	Lightweight CNN	0.2353	0.1586	0.3474	0.1231	2
	Other	0.0754	0.0576	0.2943	0.0314	30
	Traditional CNN	0.1152	0.1064	0.3673	0.0382	33
character	ANN	0.1925	0.1452	0.2951	0.0898	2
	Deep CNN	0.1177	0.0726	0.3857	0.0543	74
	Hybrid CNN	0.2202	0.0802	0.3815	0.1748	11
	Lightweight CNN	0.2182	0.0921	0.2833	0.1531	2
	Other	0.0879	0.0004	0.0881	0.0876	2
Food and drink	Traditional CNN	0.0845	0.0827	0.3713	0.0183	20
	Deep CNN	0.1235	0.0422	0.2149	0.0391	32
	Lightweight CNN	0.1131	0.0280	0.1361	0.0819	3
	Other	0.0456	NA	0.0456	0.0456	1
Pest	Traditional CNN	0.2256	NA	0.2256	0.2256	1
	ANN	0.2418	NA	0.2418	0.2418	1
	Deep CNN	0.1132	0.1021	0.2558	0.0449	6
	Lightweight CNN	0.0428	0.0044	0.0497	0.0376	6
	Other	0.3660	0.0543	0.4070	0.2369	14
Plant	Traditional CNN	0.2632	0.0146	0.2831	0.2483	4
	ANN	0.1622	NA	0.1622	0.1622	1
	Deep CNN	0.5165	0.3697	1.0000	0.1554	24
	Hybrid CNN	0.2757	0.0408	0.3139	0.2004	6
	Lightweight CNN	0.2174	0.1033	0.3366	0.1563	3
	Other	0.1518	0.0006	0.1522	0.1514	2
Technology	Traditional CNN	0.2935	0.2360	0.9847	0.1506	11
	Deep CNN	0.2291	0.2449	0.9664	0.0857	14
	Hybrid CNN	0.0979	0.0005	0.0982	0.0975	2
	Lightweight CNN	0.3435	0.0695	0.4548	0.2647	8

表 19. 模型 Model-C 的模型分類 DEA 效率分析

Model	image type	平均值 - SCORE	標準差 - SCORE	最大 - SCORE	最小 - SCORE	計數 - SCORE
ANN	character	0.1925	0.1452	0.2951	0.0898	2
	Pest	0.2418	NA	0.2418	0.2418	1
	Plant	0.1622	NA	0.1622	0.1622	1
Deep CNN	Animals	0.1384	0.0115	0.1462	0.1082	10
	Body parts	0.3391	0.0942	0.4367	0.0996	31
	character	0.1177	0.0726	0.3857	0.0543	74
	Food and drink	0.1235	0.0422	0.2149	0.0391	32
	Pest	0.1132	0.1021	0.2558	0.0449	6
	Plant	0.5165	0.3697	1.0000	0.1554	24
	Technology	0.2291	0.2449	0.9664	0.0857	14
Hybrid CNN	Animals	0.9099	0.2592	1.0000	0.1312	11
	Body parts	0.2678	0.0567	0.4279	0.2149	32
	character	0.2202	0.0802	0.3815	0.1748	11
	Plant	0.2757	0.0408	0.3139	0.2004	6
	Technology	0.0979	0.0005	0.0982	0.0975	2
Lightweight CNN	Body parts	0.2353	0.1586	0.3474	0.1231	2
	character	0.2182	0.0921	0.2833	0.1531	2
	Food and drink	0.1131	0.0280	0.1361	0.0819	3
	Pest	0.0428	0.0044	0.0497	0.0376	6
	Plant	0.2174	0.1033	0.3366	0.1563	3
	Technology	0.3435	0.0695	0.4548	0.2647	8
Other	Body parts	0.0754	0.0576	0.2943	0.0314	30
	character	0.0879	0.0004	0.0881	0.0876	2
	Food and drink	0.0456	NA	0.0456	0.0456	1
	Pest	0.3660	0.0543	0.4070	0.2369	14
	Plant	0.1518	0.0006	0.1522	0.1514	2
Traditional CNN	Animals	0.1239	NA	0.1239	0.1239	1
	Body parts	0.1152	0.1064	0.3673	0.0382	33
	character	0.0845	0.0827	0.3713	0.0183	20
	Food and drink	0.2256	NA	0.2256	0.2256	1
	Pest	0.2632	0.0146	0.2831	0.2483	4
	Plant	0.2935	0.2360	0.9847	0.1506	11

表 20. 模型 Model-ABC 的圖像分類 DEA 效率比較表

Model	image type	平均值 - SCORE		
		Model-A	Model-B	Model-C
Animals	Deep CNN	NA	NA	0.1384
	Hybrid CNN	NA	NA	0.9099
	Lightweight CNN	NA	NA	0.1239
Body parts	Deep CNN	0.3431	0.3014	0.3391
	Hybrid CNN	0.3439	0.3685	0.2678
	Lightweight CNN	0.3475	0.3474	0.2353
	Other	NA	NA	0.0754
	Traditional CNN	NA	0.3617	0.1152
character	ANN	NA	0.3317	0.1925
	Deep CNN	0.2703	0.1304	0.1177
	Hybrid CNN	0.1793	0.2353	0.2202
	Lightweight CNN	0.2842	0.2289	0.2182
	Other	NA	NA	0.0879
	Traditional CNN	NA	0.0933	0.0845
Food and drink	Deep CNN	0.1145	0.0989	0.1235
	Lightweight CNN	0.1363	0.1361	0.1131
	Other	0.0457	0.0456	0.0456
	Traditional CNN	NA	NA	0.2256
Pest	ANN	NA	0.2748	0.2418
	Deep CNN	0.2451	0.1158	0.1132
	Lightweight CNN	NA	0.0459	0.0428
	Other	NA	0.4170	0.3660
	Traditional CNN	0.2632	0.2632	0.2632
Plant	ANN	NA	NA	0.1622
	Deep CNN	0.7155	0.5835	0.5165
	Hybrid CNN	NA	0.2801	0.2757
	Lightweight CNN	0.1614	0.2351	0.2174
	Other	NA	NA	0.1518
	Traditional CNN	0.4390	0.3300	0.2935
Technology	Deep CNN	NA	0.3955	0.2291
	Hybrid CNN	NA	NA	0.0979
	Lightweight CNN	NA	0.3920	0.3435