

混合神經網路於太陽能電廠之光伏面板瑕疵診斷

劉宇森¹ 謝振中^{2*} 謝宗穎³

摘要

本文提出一結合深度50層殘差神經網路(Residual Neural Network 50, ResNet50)與長短期記憶模型(Long Short-Term Memory, LSTM)的混合神經網路，實現對太陽能電廠之太陽能模組的光伏面板的物理破壞、電損、鳥屎汙染與灰塵等的複數瑕疵自動化檢測，以提高太陽能模組的光伏面板瑕疵檢測的準確性。所提混合神經網路模型除透過實驗驗證之有效性與準確性外，並與傳統神經網路檢測模型進行對比。驗證結果顯示，所提之混合神經網路模型於太陽能板之瑕疵檢測的訓練時間及準確度與驗證時間及準確度，皆優於傳統神經網路模型。

關鍵詞：光伏面板，自動化檢測，瑕疵檢測，混合，神經網路

1. 前言

現代社會對於化石燃料的高度依賴，相應地造成環境和氣候災難的威脅。再生能源的使用，能夠降低碳排放同時減少對空氣和水資源的污染；因此，再生能源的發展和應用可在環保和氣候保護發揮關鍵性的作用外，並已成為環境和氣候問題之一不可或缺的解決方案。此外，太陽能因具豐富的取之不盡的特性及近代半導體技術之蓬勃發展，已成為取代傳統化石燃料能源的主要再生能源之一。

臺灣面臨2050淨零排放跨世代、跨領域、與跨國際之轉型工程，政府已建構科技研發及氣候法制等兩大面向之基礎環境，推動能源、產業、生活、社會等四大轉型策略，以逐步實現2050淨零排放之永續社會外，並提出「十二

項關鍵戰略」推動2050淨零轉型，並滾動式提出個別戰略計畫，以落實淨零轉型之長期願景目標(臺灣2050淨零排放路徑及策略總說明，2024)。

另一方面，太陽能光伏發電的效能提升，同時地有助於提高對生態永續的意識。太陽能模組通常由鋁製框架和玻璃層壓保護，以免受雨、風和雪等環境影響。然而，這些保護措施無法防止光電模組在樹枝掉落衝擊、冰雹或熱應力造成的機械損壞。此外，太陽模組在安裝過程中掉落、焊接錯誤或電線缺陷等製造錯誤也可能導致太陽能模組損壞。再者，機械應力、潮濕、高溫 and 長期紫外曝曬，亦也可能致使太陽能模組的保護材料降解。因此，有必要監測太陽能模組並及時更換或維修有缺陷的太陽能模組，以確保最大化太陽能發電廠的發電

¹逢甲大學，電機系碩士研究生

²逢甲大學，電機系教授

³國立中興大學，資訊管理學系學士學生

*通訊作者，電話：04-24517250 Ext. 3815，電郵：jjshieh@fcu.edu.tw

收到日期: 2024年05月27日

修正日期: 2024年08月13日

接受日期: 2024年08月16日

率。再者，雖然太陽能模組的設計壽命為25年或更長(Jordan and Kurtz, 2011)，但大多數太陽能模組都經歷壽命末期前耗損的情況。故障的太陽能模組失效的及時檢測與回復，極大地影響太陽能發電廠的回收年限。

傳統的太陽能板非破壞性檢測可概分為紅外線熱成像(Wang *et al.*, 2023)、電檢測(Luna-Romero *et al.*, 2024)及光檢測(Jia *et al.*, 2022)三大類別。紅外線熱成像檢測是透過紅外線熱成像相機觀察太陽能板表面溫度分佈，檢測異常溫區以指示電池或連接問題。其於溫度對比度低時，分辨效率差。電檢測則透過電流和電壓測量，檢查太陽能板的電氣特性，異常電流或電壓暗示著太陽能板電池或系統問題。電檢測容易受到電子設備或電磁場的干擾，可能導致測量的不穩定性和誤差外，電檢測系統的穩定性和準確性可能受到電源和電壓的變化影響。雖然光檢測利用光譜分析儀器以確保太陽能板能有效轉換光能為電能。然而，在對戶外太陽能板進行檢測時，容易受外部光環境的影響而降低檢測準確度。此外，由於傳統的太陽能板非破壞性檢測方法需依賴於人為操作，容易受到主觀因素的影響，對於大量數據的處理效率較低以及難以應對複雜場景外，需要經驗豐富的專業人員參與以提昇效率、準確性和普及性應用。

另一方面，人工智慧提可高工作效率、提供準確分析，處理大數據、自動化任務，並為個性化服務創造機會。其學習能力和解決複雜問題的特點使其在多個領域展現優勢。近年深度學習已大量地應用於太陽能電廠之太陽能板非破壞性檢測。由於太陽能發電廠之太陽能板於環境下之顏色會讓破裂及刮痕瑕疵變的不明顯，太陽能板非破壞性檢測可分為出廠前之產品檢測(Wang *et al.*, 2017；Yılmaz and Bayrak, 2019；Madeti and Singh, 2018；Akram *et al.*,

2019)與太陽能發電廠的現場檢測(Cavieres *et al.*, 2022；Wang *et al.*, 2021；Segovia Ramírez *et al.*, 2024)兩大類。2017年，Huaizhi Wang等人提出了基於小波轉換(Wavelet Transform, WT)和深度卷積神經網路(Deep Convolutional Neural Network, DCNN)以確定太陽能模組發電功率預測(Wang *et al.*, 2017)。採用小波轉換用於將原始訊號分解為多個頻率序列並利用DCNN 提取每個頻率中表現出的非線性特徵和不變結構外，並結合脊柱分位數回歸(Quantile Regression of Spinal Column, QR)的機率光伏發電預測模型，以統計評估太陽能模組發電數據中的機率資訊。2019年，Alper Yılmaz等人基於非抽取小波變換(Un-Decimated Wavelet Transform, UWT)即時檢測微電網中的電能品質擾動(Power Quality Disturbances, PQD)，以克服基於小波變換的方法在即時應用中的限制(Yılmaz and Bayrak, 2019)。2018年，Siva Ramakrishna Madeti等人基於k近鄰的系統(k-Nearest Neighbors, kNN)提出太陽能模組串聯故障檢測與診斷 (Madeti and Singh, 2018)。其可偵測並分類開路故障、線路故障(L-L)故障、有和沒有旁路二極體故障的部分遮蔽以及即時有反向旁路二極體故障的部分遮蔽外，故障分類的平均準確率高達98.70%。M. Waqar Akram等人提出使用卷積神經網路(Convolutional Neural Network, CNN)架構來識別電致發光(Electroluminescence, EL)太陽能影像缺陷(Akram *et al.*, 2019)，除可在普通CPU電腦上工作並同時保持即時速度外，預測一幅影像僅需8.07 ms且在EL影像的資料集93.02%的準確率。

再者，太陽能模組的光伏面板之性能除影響太陽能發電廠的發電率與供電可靠度外，並也同時關係著太陽能電廠運轉維護成本。實現對太陽能電廠之太陽能模組的光伏面板的遮蔽、刮痕與破裂等的複數瑕疵自動化檢測，可

以提升太陽能發電廠的發電率與供電可靠度外，並也同時可以降低太陽能電廠運轉維護成本。Youyang Wang等人基於絕對EL成像的自動太陽能電池缺陷檢測和分類的自適應方法，開發出一無監督演算法來根據EL影像中的缺陷特徵自動檢測缺陷(Wang *et al.*, 2021)。該方法根據電源對檢測到的缺陷進行統計分類，首次嘗試結合自動缺陷檢測與細粒度分類。多種類型太陽能電池的實驗結果顯示該方法平均不確定度最低為5.15%，與兩種傳統方法相比其優化率達98.9%外，為光伏產業的實際設計和可靠性診斷提供更多的指導性。Isaac Segovia Ramírez 等人基於影像分析的新方法，提出使用兩個連續的卷積神經網路檢測物聯網平臺中的熱點並減少誤報數量(Segovia Ramírez *et al.*, 2024)。該平臺的架構透過實施不同的捲積神經網路自動處理所接收到的資料。其中包括三個不同尺寸、面板形狀和較寬溫度範圍的光伏太陽能發電廠的熱分析圖。與支援向量機或不同的人工神經網路相比，面板檢測的準確度與熱點檢測的準確度分別高達99%與96%。Robinson Cavieres等人利用卷積神經網路對RGB (Red, Green, Blue)影像進行語義分割和分類的自動物理故障分類 (Cavieres *et al.*, 2022)。雖然其可識別為故障和無故障的2種輸出類別，並識別出無故障、裂縫、陰影和不易檢測到的灰塵等4種類別。然而，其對於2種類別與4種出類之平均準確度分別僅有75%與70%。前述等文獻皆可應用以實現對太陽能電廠之太陽能模組的光伏面板的瑕疵自動化檢測，然而其等皆僅能辨識光伏太陽能板的單一類型瑕疵。

近年來，混和神經網路於預測未來的工作狀態展現優異的性能。Zilong Tan等人提出一基於CNN-LSTM的混和網路故障預測模型，以預測網路未來的工作狀態(Tan and Pan, 2019)。故障預測技術可以讓工作人員提前做好故障修復

的準備，減少故障的修復時間，進而減少故障造成的損失。Ran Song等人結合變分模態分解 (Variational Mode Decomposition, VMD)、CNN和LSTM，融合全局和局部特徵，提高整個網路的穩定性和穩健性(Song and Jiang, 2021)。高精度模型實現故障特徵的自適應提取與擺脫了對先驗知識的依賴外，所提出的模型考慮時序特徵的影響，除可減少資訊損失及可提升學習有效特徵外，並大大地提高診斷的準確性。Yonghua Yu等人基於CNN-LSTM的視覺系統，提出基於卷積神經網路模型(Convolutional Neural Network, CNN)的檢測器來檢測視野中的有缺陷的柑橘並將其暫時分類為相應的類型。其除使用基於長短期記憶模型(Long Short-Term Memory, LSTM)的預測器根據圖像序列數據預測未來柑橘的位置外，並可與機器人夾具配合進行各種柑橘即時分類與複數型態的瑕疵診斷(Yu *et al.*, 2024)。

CNN通過多層卷積和殘差塊的設計，能夠高效地捕捉輸入資料的不同維度特徵。卷積神經網路模型之深度特徵提取的優勢確保我們的模型對於複雜、多樣的行為模式有更全面的理解和表達能力，且每一個卷積層都有助於提升特徵的抽象程度，相當適合作為深度學習的特徵提取器(He *et al.*, 2016)。ResNet神經網路模型是CNN的一種，而深度50層殘差神經網路(Residual Neural Network 50, ResNet50)模型為神經網路模型之一，主要特點是引入殘差塊(Residual Block)，這使得ResNet50模型能夠輕鬆地擴展到更深的深度而不會遭遇梯度消失的問題(Huang and Liu, 2017)。雖然ResNet50模型可有效解決梯度消失問題、支持極深網絡、並可透過殘差塊提升訓練效率與模型性能，因此相當適用於大規模圖像分類等任務(Szegedy *et al.*, 2017)。然而，由於ResNet50模型的深度，它的模型參數非常龐大。這導致需要更多的數

據來進行訓練，而且在一些較小的應用中可能容易出現過擬合(Overfitting)的問題(Xia *et al.*, 2019)。

遞迴神經網路模型(Recurrent Neural Network, RNN)是一種專為處理序列數據而設計之人工神經網絡，其獨特之處在於網絡中存在循環連接，允許信息在網絡中傳遞並保留先前時間步的狀態。這使得RNN適用於自然語言處理、語音識別和時間序列預測等任務。另，LSTM是RNN變種，由於其具有記憶單元，因此能夠有效捕捉資料中的長期相依性外，經過訓練可以根據輸入序列預測標籤序列，以較長的時間進行模型訓練分類，減少梯度消失及爆炸問題，相當適合作為處理時間序列長期相依性行為之資訊(Gers *et al.*, 2019)。由於LSTM擁有長期依賴性，對於漸進性的變化更為靈敏，因此可捕捉太陽能板行為的長時間依賴性(Bergstra and Bengio, 2012)。再者，LSTM其序列建模能力使其適用於處理時間序列數據，有助於準確捕捉太陽能板行為的模式和趨勢。此外，LSTM還能自適應學習序列數據中的特徵，動態調整內部狀態，減少對手工特徵工程的需求，從而可更好地適應太陽能板的變化。然而，LSTM有多個超參數需要調整，包括學習速率、遺忘率等，這可能需要進行一定的實驗和調整，使得模型的訓練變得較為複雜(Sheng *et al.*, 2023)。

因此本文提出一結合ResNet50和LSTM的混合神經網路實現對太陽能電廠之太陽能模組的光伏面板的遮蔽、刮痕與破裂等的複數瑕疵自動化檢測，以提高太陽能模組的光伏面板瑕疵檢測的準確性，除可以提升太陽能發電廠的發電率與供電可靠度外，並也同時可以降低太陽能電廠運轉維護成本。

2. ResNet50與LSTM神經網路

2.1 ResNet50神經網路訓練單元

ResNet50神經網路模型每個殘差塊包含跳躍連接(Skip Connection)，這允許模型直接將輸入添加到輸出，從而在前向傳播過程中更容易地保留和學習原始輸入的信息(Zhong *et al.*, 2017)。

圖1所示為ResNet50神經網路訓練單元流程圖，分為5個階段(stage)。其中：

Stage 1：可視其為對INPUT的預處理，其中224,224,3：指輸入INPUT的高(Height)、寬(Width)和通道數(Channel)，即(H,W,C)。

COV_7x7_64：COV是卷積(Convolution)的縮寫，7x7指卷積核大小，64指卷積核的數量。

BN,ReLU：BN是Batch Normalization的縮寫，即常說的BN層，ReLU指ReLU激活函數是使神經網絡引入非線性，解決梯度消失問題，提高計算效率。

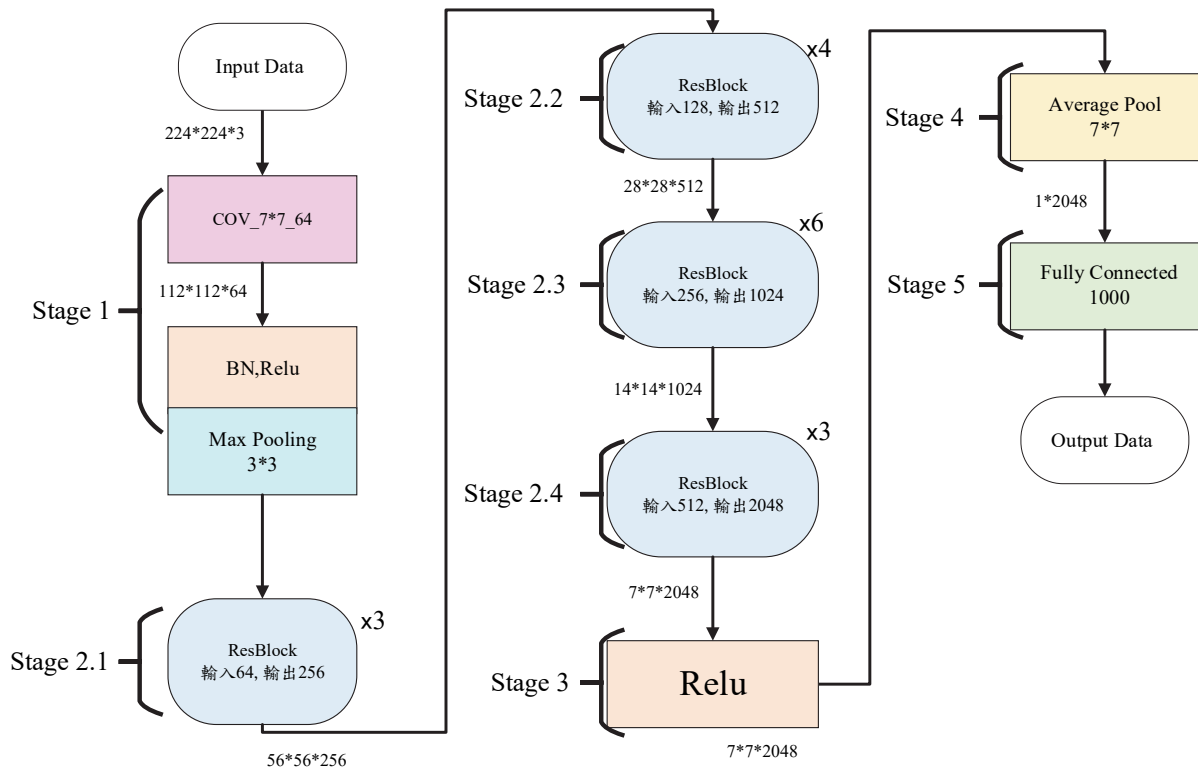
MAX Pooling：Max Pooling 3x3是一種池化操作，將輸入特徵圖分割成3x3的區域，然後對每個區域取最大值作為輸出。

由卷積層和最大池化層組成負責對輸入照片做特徵提取其輸入的大小為(64,56,56)，輸出的大小為(256,56,56)。

將尺寸為224x224x3的圖像轉換為尺寸為112x112x64的特徵圖通過卷積操作實現，使用適當大小的卷積核和適當的步幅進行卷積操作，將原始的3個通道的圖像轉換為64個通道的特徵圖，同時將圖像的高度和寬度尺寸減半，從224x224減少到112x112。

Stage 2.1：通過卷積層後將照片尺寸縮小112x112至56x56。

將尺寸為112x112x64的圖像轉換為尺寸為56x56x256將原始的64個通道的圖像轉換為256



資料來源：本研究繪製。

圖1 ResNet50神經網路訓練單元流程圖

個通道的特徵圖，同時將圖像的高度和寬度尺寸減半，從112x112減少到56x56。

Stage 2.2：通過卷積層後將照片尺寸縮小56x56至28x28。

將尺寸為56x56x256的圖像轉換為尺寸為28x28x512將原始的128個通道的圖像轉換為512個通道的特徵圖，同時將圖像的高度和寬度尺寸減半，從56x56減少到28x28。

Stage 2.3：通過卷積層後將照片尺寸縮小28x28至14x14。

將尺寸為28x28x512的圖像轉換為尺寸為14x14x1024將原始的512個通道的圖像轉換為1,024個通道的特徵圖，同時將圖像的高度和寬度尺寸減半，從28x28減少到14x14。

Stage 2.4：通過卷積層後將照片尺寸縮小14x14至7x7。

將尺寸為14x14x1024的圖像轉換為尺寸為7x7x2048將原始的1,024個通道的圖像轉換為

2,048個通道的特徵圖，同時將圖像的高度和寬度尺寸減半，從14x14減少到7x7。

Stage 3：ReLU激活函數。

ReLU激活函數指 輸入大於0時輸出等於輸入，小於等於0時輸出為0，有效減少梯度消失問題(Vanishing Gradient Problem, VGP)，從而加快神經網路的訓練速度。

Stage 4：Average Pool (平均池化層)取平均值作為輸出。

Average Pool：將輸入特徵圖分割成7x7的區域，然後對每個區域取平均值作為輸出。

Stage 5：Fully Connected (全連接層)將所有輸入節點與所有輸出節點完全連接，用於特徵組合和模式學習。

Fully Connected：用於整合高層特徵並生成最終的輸出，其中包含有1,000個神經元。

2.2 LSTM神經網路訓練單元

圖2為LSTM訓練單元流程圖，其中， C_t 為記憶細胞、 H_t 為輸出資料、 X_t 為輸入資料、 σ 為機活函數， C_t 表示為控制著資訊流過去的百分比(0 ~ 1)， \tanh 表示為資訊的數值(-1~1)，更新單元中的訊息。LSTM的核心是一個可以存儲和擷取信息的記憶單元。每個記憶單元都有一個狀態(Cell State)，可以在時間步之間傳遞信息。LSTM使用三個門控包括遺忘門(Forget Gate)、輸入門(Input Gate)和輸出門(Output Gate)。這些門控制著記憶單元中的信息流動，使得模型能夠更靈活地選擇信息保留和丟棄。其中，遺忘門決定在記憶單元中保留或刪除之前的記憶、輸入門更新記憶單元的內部狀態，根據當前的輸入、輸出門控制著記憶單元中的信息如何影響當前的輸出。

遺忘門(f_t)能決定資訊遺忘或保留。來自先前隱藏狀態 x_t 的資訊和當前輸入 h_{t-1} 的信息同時輸入到 σ 函數，輸出值處於0和1之間，越接近0意味著越應該忘記，越接近1意味著越應該保留。

$$f_t = \sigma[w_f(h_{t-1}, x_t) + b_f] \quad (1)$$

其中， σ 為Sigmoid激活函數， w_f 為權重矩陣， h_{t-1} 與 x_t 分別表示前一時間輸出數據與新經過處理的時間序列數據， b_f 為偏差量， \tilde{C}_t 為候選記憶細胞。

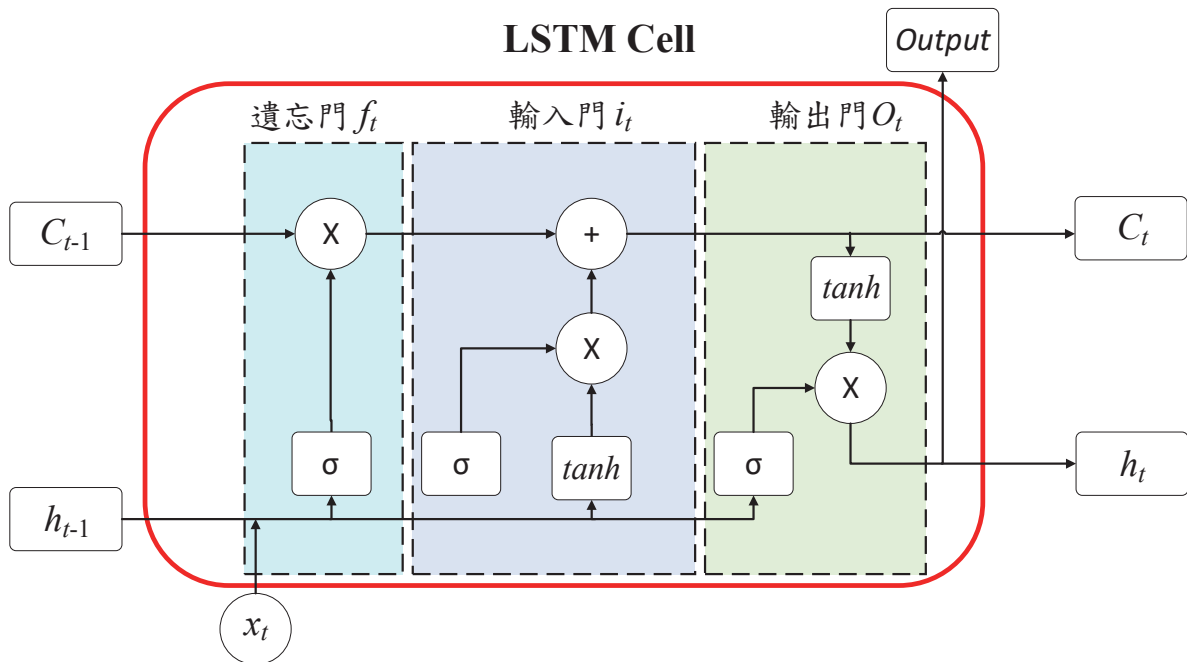
輸入門(i_t)為用來更新單元狀態。先將先前隱藏狀態的訊息和當前輸入的訊息輸入到 σ 函數，在0和1之間調整輸出值以決定更哪些是新信息，其中，0表示不重要，1表示重要。也可將隱藏狀態和當前輸入傳輸給 \tanh 函數，並在-1和1之間壓縮數值以調節網絡，然後把 \tanh 輸出和 σ 輸出相乘， σ 輸出將決定在 \tanh 輸出中之哪些信息是重要的且需要進行保留。

$$i_t = \sigma[w_i(h_{t-1}, x_t) + b_i] \quad (2)$$

$$\tilde{C}_t = \tanh[w_c(h_{t-1}, x_t) + b_c] \quad (3)$$

利用式(3)可更新記憶單元狀態。

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \quad (4)$$



資料來源：本研究繪製。

圖2 LSTM訓練單元流程圖

最後由輸出門(o_t)決定將單元狀態通過 \tanh 進行處理(得到一個在-1到1之間的值)並將它和 σ 門的輸出相乘，最終只會輸出確定輸出的那部分，如式(5)與式(6)。

$$o_t = \sigma[w_o(h_{t-1}, x_t) + b_o] \quad (5)$$

$$h_t = o_t \tanh(C_t) \quad (6)$$

2.3 召回率

召回率(Recall)，又稱為查全率或靈敏度，是評估分類模型性能的重要指標之一。召回率衡量模型能夠正確辨識所有實際正類樣本的能力。具體來說，召回率是指模型正確預測為正類的樣本數(真陽性，TP)與所有實際正類樣本數(真陽性，TP) + 假陰性，(FN)之比(Sokolova and Marina *et al.*, 2009)，即

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (7)$$

在應用中，召回率通常用於需要盡量找出所有正類的任務。高召回率表示模型能夠有效地捕捉到大部分的真實正類，從而降低了漏檢的風險。

2.4 F1分數

F1分數(F1 Score)是一種綜合用於評估分類模型性能的指標，通常用於衡量模型在非平衡數據集上的表現，特別適用於類別不平衡的情況。F1分數是精確率(Precision)和召回率(Recall)的調和平均數，權衡了模型的查準率(Precision Ratio)。精確率衡量的是模型預測為正類的樣本中有多少是真正的正類，而召回率則衡量的是實際正類樣本中有多少被正確預測為正類。F1分數可表示如(Powers, 2011)：

$$\text{F1} = 2 * \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (8)$$

F1分數的值範圍是0到1，值越接近1表示

模型的性能越好。當精確率和召回率的差異很大時，F1分數會降低，反映出模型在查全率和查準率之間存在不平衡。相比單獨的精確率或召回率，F1分數提供了一個更加全面的性能評估，因此廣泛地使用於機器學習應用。

2.5 t-SNE

t-分佈鄰域嵌入(t-Distributed Stochastic Neighbor Embedding, t-SNE)是一種強大的非線性降維技術，特別適用於高維數據的可視化。它由Geoffrey Hinton和Laurens van der Maaten於2008年提出(Hinton and Laurens, 2008)，其主要係將高維數據轉換為低維空間(通常是二維或三維)，以便於視覺化和探索數據的內在結構。t-SNE通過優化高維空間中數據點之間的相似性，在低維空間中保持這種相似性。具體來說，它使用概率分佈來描述數據點在高維空間中的相對距離，然後在低維空間中調整點的排列，以便這些分佈之間的差異最小化。這種方法可以有效地將相似的數據點聚集在一起，同時將不相似的數據點分開，因此特別適合用於處理非線性結構的數據。t-SNE廣泛應用在數據分析與機器學習模型解釋，尤其是應用在探索高維數據中的隱含模式和結構領域。

3. ResNet50-LSTM混合神經網路訓練模型

神經網路訓練是深度學習的核心過程，旨在通過大量數據使模型學到數據的特徵和模式，以達到預測或分類的目的。訓練開始時，模型權重被初始化，數據通過網絡進行前向傳播，產生預測結果。損失函數度量預測結果與實際標籤的差異，然後使用反向傳播算法計算梯度，根據梯度更新模型的權重，以最小化損失。這個過程透過優化器，如隨機梯度下降，

進行多次迭代(Epoch)，每次迭代被稱為一個Epoch。雖然通過不斷調整訓練權重，模型逐漸提高對數據的適應能力，提高準確性，然而其潛在過度擬合問題。為了解決這個問題，可以使用正則化技術，如隨機丟棄(Dropout)通過在訓練過程中隨機丟棄神經元來防止過擬合(Srivastava *et al.*, 2014)或通過在損失函數中添加權重的平方和懲罰項來約束模型權重(Ng, 2004)。最終還需通過在測試集上評估模型的性能，以確保其對新數據的泛化能力(Cao *et al.*, 2024)。整個訓練過程需要仔細選擇模型架構、損失函數和優化器，以及調整學習率等超參數，以獲得一個性能優越且泛化良好的神經網路模型。

雖然ResNet50擁有高準確度和深層網絡結構，能有效解決梯度消失問題；缺點是GPU運算效能需求低，訓練時間較長。相對地LSTM嵌入影像更新快速能有效捕捉長期依賴關係，訓練時間較短外並適合處理序列數據，然而其所需要高效能的GPU運算能力，對於電腦硬體成本較高。因此本文將ResNet50串級(Cascade) LSTM，利用ResNet50神經網路模型更好地提取深度特徵的輸出作為LSTM的輸入。由於LSTM的輸入將是影像的嵌入，LSTM的輸出將是影像的標籤。因此，ResNet50-LSTM混合神經網路結構特別適用於需要同時考慮空間和時間特徵的太陽能板分類刮痕、破裂、汙染等複數識別任務(Tang *et al.*, 2020)。

太陽能電廠之光伏面板瑕疵診斷可概分為五大類，1.完整無損：這類影像沒有任何瑕疵特徵，是基礎影像。ResNet50能夠有效地提取這些正常影像的特徵，作為模型的標準參考。2.鳥屎：鳥屎通常表現為不規則的斑塊，對於CNN來說，可以通過卷積層的紋理分析進行有效區分。LSTM層有助於捕捉這些斑塊的時間變化特徵。3.灰塵：灰塵影像中的特徵較為

分散且隨機。ResNet50的卷積層可以提取這些細微且隨機的特徵，LSTM層則有助於在多張影像中統合這些特徵，提高檢測精度。4.物理破壞：物理破壞包括裂紋、刮痕等明顯的形變特徵。這類瑕疵對於CNN的邊緣檢測能力提出了較高要求，而LSTM層能夠幫助整合形變前後的影像信息，提升模型對於形變特徵的鑑別能力。5.電損：電損通常表現為電流或電壓異常，這類影像特徵可能較為隱蔽且複雜。ResNet50可以通過多層卷積提取這些異常的特徵，而LSTM層則有助於捕捉這些異常特徵的時間變化，從而提高檢測的準確性。

由於所提之混合神經網路結合卷積神經網路(CNN)和長短期記憶網路(LSTM)的優勢，因此，能夠同時處理圖像空間特徵和時間序列特徵。如此一來，所提之混合神經網路結構有助於提高模型在複雜影像分類任務中的表現，特別是當瑕疵類別之間存在顯著差異更顯其檢測之優越性能。圖3為本文所提之混合神經網路訓練模型流程圖。其中，經過ResNet50的計算後，輸出 $1 \times 1 \times 1024$ 的特徵權重，最後由SoftMax進行分類。本研究利用LSTM對SoftMax進行替換，讓LSTM進行更準確的瑕疵分類。各步驟說明如下：

Step 1：設定擷取影像大小及檔案規格

設定影像擷取影像大小及檔案規格，將實驗初期使用的照片影像決定大小及檔案規格。

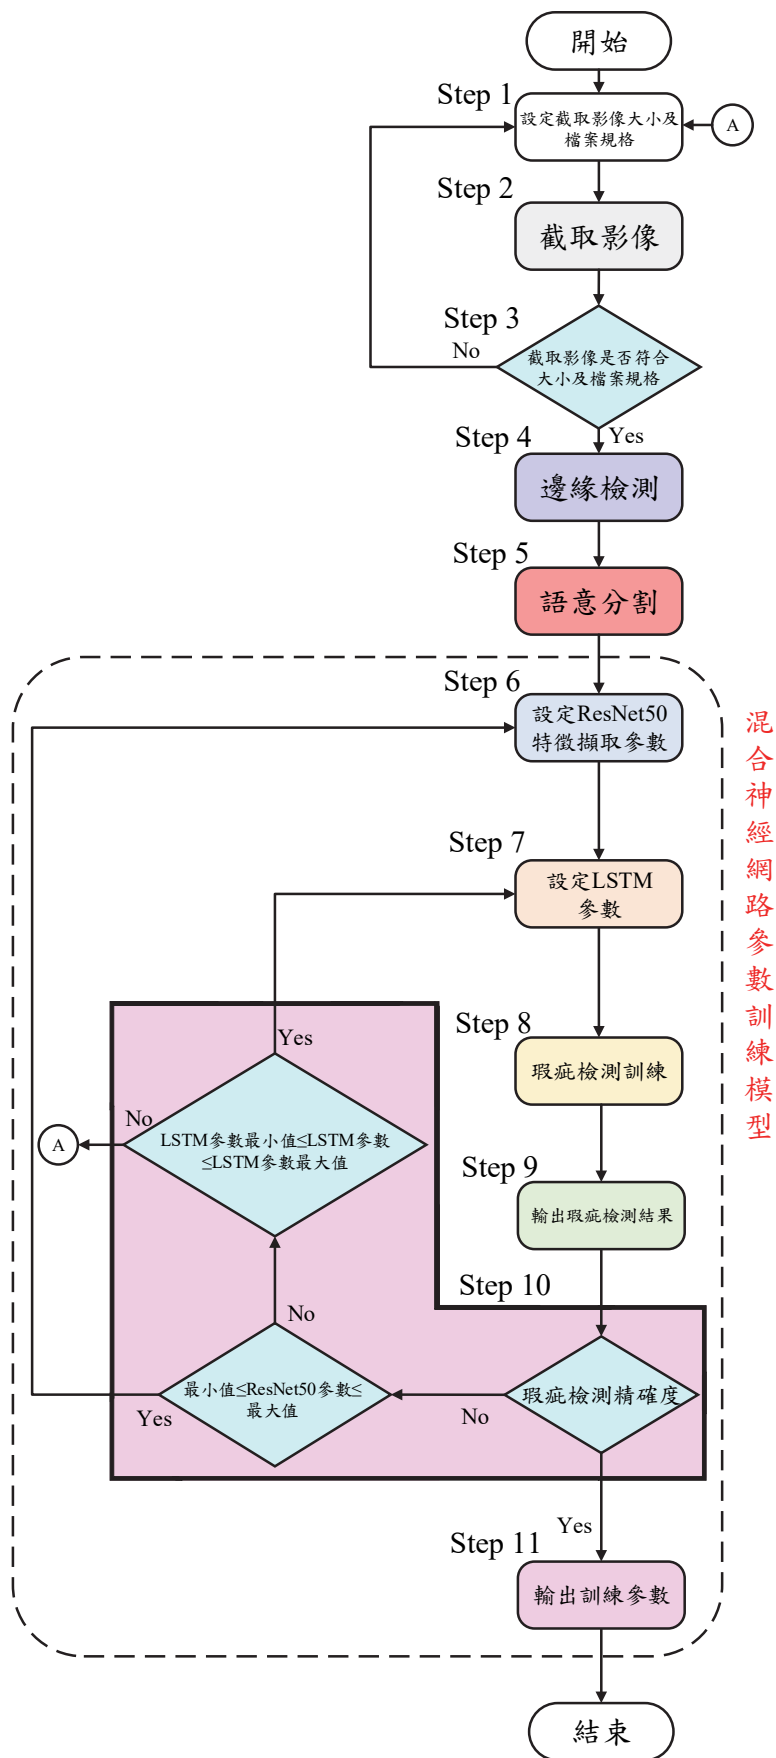
Step 2：擷取影像

根據Step 1之張數選定，擷取影像透過光學鏡頭捕捉影像，最終儲存為數位檔案。

Step 3：擷取影像是否符合大小及檔案規格

分析擷取影像大小及檔案規格是否符合設定之規格，若無法滿足，回到Step 1重新擷取影像及設定檔案規格。

Step 4：邊緣檢測(Edge Detection)



資料來源：本研究繪製。

圖3 ResNet50-LSTM神經網路訓練流程圖

利用Matlab程式根據影像中的邊界進行邊緣檢測，將目標與背景做出區分。

Step 5：語意分割(Semantic Segmentation)

根據Step 4影像邊界劃分後，清楚知道物體及背景的區分，接著對影像進行語意分割以顏色去區分所有瑕疵類型，淺藍色為完整無損(Clean)，紅色為鳥屎污染(Bird Drop)，粉紫色為電損(Electrical Damage)，咖啡色為灰塵污染(Dusty)，綠色為物理性破壞(Physical Damage)。

Step 6：設定ResNet50特徵擷取參數

設定ResNet50影像特徵擷取參數，優先調整優化器(Optimizer)使用，調整學習率(Learning Rate)，最大訓練週期數(Max Epochs)，最小批次大小(Min BatchSize)，驗證頻率(Validation Frequency)，最後調整輸出訓練信息頻率(Verbose Frequency)。

Step 7：設定LSTM參數

設定LSTM參數，優先調整優化器(Optimizer)使用，調整學習率(Learning Rate)，最大訓練週期數(Max Epochs)，最小批次大小(Min BatchSize)，訓練過程中隨機打亂訓練數順序為每一次迭代，最後調整梯度閾值(Gradient Threshold)。

Step 8：瑕疵檢測訓練

根據Step 6、7設定好的參數執行Step 8瑕疵檢測訓練。

Step 9：輸出瑕疵檢測結果

根據Step 8之瑕疵檢測訓練，輸出瑕疵檢測結果。

Step 10：瑕疵精準度

根據瑕疵訓練結果之精準度，判斷其模型瑕疵檢測之有效性，若無法滿足訓練精準度，則回到Step 6重新設定ResNet50之特徵擷取參數優化器；若仍再無法滿足訓練精準度則進入Step 7繼續設定LSTM之優化器參數；若瑕疵精

準度仍無法提高訓練精準度則回到Step 1 重新設定擷取影像大小及規格。

Step 11：輸出訓練參數

根據Step 10之設定神經網路參數，輸出訓練參數然後結束。

4. 實驗結果與討論

首先擷取1040張具各類瑕疵之太陽能板影像(solar panel, 2024)，其中所擷取到之太陽能板影像其瑕疵類別已經過如表1所示之前置處理。然後，對影像進行確定檔案統一規格。本文之影像大小使用224x224且檔案統一為jpg格式。完成此步驟後，再利用由Matlab所撰寫的程式進行影像邊緣檢測；利用邊緣檢測後的影像接著在Matlab App中的Image Labeler進行語意分割，作為視覺判別影像。將瑕疵類別進行顏色上的區分：藍色為完整無損(Clean)，紅色為鳥屎污染(Bird Drop)，粉紫色為電損(Electrical Damage)，咖啡色為灰塵污染(Dusty)，綠色為物理性破壞(Physical Damage)。本文所提之神經網路之瑕疵影像訓練集與測試集影像各為各520張且每一種瑕疵類別為32張，不同瑕疵類別的平均重疊率與平均覆蓋率，如表2所示。

接著，基於中前節進行神經網路參數訓練；神經網路模型參數訓練如表3所示。

單一瑕疵檢測與複數瑕疵檢測之神經網路模型測試結果如下。

A. 情境一：單一瑕疵檢測

1. ResNet50神經網路模型

圖4為ResNet50-LSTM利用太陽能光伏面板瑕疵影像進行訓練的結果，在單一瑕疵類別中圖4(a)中模型準確度為94.5%，此模型能夠精確辨識出單一的瑕疵。此外由圖4(b)可知ResNet50神經網路模型誤把鳥屎瑕疵和電損瑕

表1 瑕疵類別前置處理

瑕疵類別	影像特徵	產製方法
完整無損 (Clean)	<ul style="list-style-type: none"> • 無任何瑕疵，表面平整且均勻； • 作為基線，沒有其他類別的異常特徵。 	使用未受損的太陽能板。
鳥屎汙染 (Bird Drop)	<ul style="list-style-type: none"> • 不規則斑塊狀，通常較白或較暗，邊緣模糊；形狀和位置隨機，區別於灰塵和物理破壞。 	模擬或實際鳥糞污染板面。
電損 (Electrical Damage)	<ul style="list-style-type: none"> • 電流或電壓異常，可能顯示為熱點或顏色異常； • 難以肉眼檢測，需電測工具確認。 	通過電測設備模擬電損影像。
灰塵汙染 (Dusty)	<ul style="list-style-type: none"> • 細小顆粒狀，分佈不均，影像模糊； • 差異：細小且均勻分佈，區別於鳥屎和物理破壞。 	在板面上撒灰塵模擬。
物理性破壞 (Physical Damage)	<ul style="list-style-type: none"> • 明顯裂紋、刮痕或碎裂，形狀不規則； • 破壞明顯且影響板面結構，區別於其他瑕疵。 	使用工具在板面上施加物理破壞。

資料來源：本研究整理。

表2 不同瑕疵類別的平均重疊率與平均覆蓋率

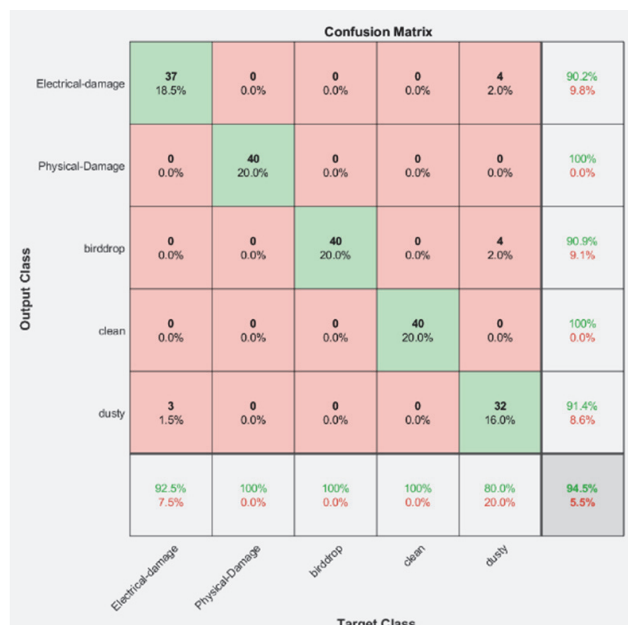
編號	瑕疵種類	平均重疊率(%)	平均覆蓋率(%)	瑕疵相互位置
1	Clean	0	100	---
2	Bird Drop	0	100	---
3	Dusty	0	100	---
4	Electrical Damage	0	100	---
5	Physical Damage	0	100	---
6	Bird Drop, Electrical Damage	86.74	85.62	隨機打亂
7	Bird Drop, Physical Damage	85.86	84.72	隨機打亂
8	Bird Drop, Dusty	95.41	98.00	隨機打亂
9	Dusty, Electrical Damage	97.65	97.92	隨機打亂
10	Dusty, Physical Damage	97.42	98.10	隨機打亂
11	Electrical Damage, Physical Damage	81.79	79.56	隨機打亂
12	Bird Drop, Electrical Damage, Physical Damage	82.56	81.92	隨機打亂
13	Dusty, Electrical Damage, Bird Drop	95.42	97.62	隨機打亂
14	Dusty, Electrical Damage, Physical Damage	95.33	98.00	隨機打亂
15	Dusty, Physical Damage, Bird Drop	95.41	97.53	隨機打亂
16	All Damage	89.22	89.55	隨機打亂

資料來源：本研究整理。


表3 神經網路模型參數訓練

神經網路模型	訓練參數	ResNet50	LSTM	ResNet50-LSTM
ResNet	優化器	adam	x	adam
	學習率調整	0.00001	x	0.00001
	最大迭代次數	15	x	15
	最小批次大小	4	x	4
	驗證頻率	60	x	60
	輸出訓練信息頻率	40	x	40
LSTM	優化器	x	adam	adam
	學習率調整	x	0.00001	0.00001
	最大迭代次數	x	20	20
	最小批次大小	x	4	4
	迭代訓練順序	x	每一次隨機打亂	每一次隨機打亂
	梯度閾值	x	2	2

資料來源：本研究整理。



(a) 影像訓練結果



(b) 瑕疵種類 t-SNE 分布圖

資料來源：本研究繪製。

圖4 ResNet50太陽能面板瑕疵


疵混淆，因此辨識準確率降低。

2. LSTM神經網路模型

圖5為LSTM利用太陽能光伏面板瑕疵影像進行訓練的結果，由圖5(a)可知在單一瑕疵

		Confusion Matrix					
Output Class	Electrical-damage	36 18.0%	0 0.0%	0 0.0%	0 0.0%	1 0.5%	97.3% 2.7%
	Physical-Damage	0 0.0%	40 20.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	birdrop	0 0.0%	0 0.0%	38 19.0%	0 0.0%	0 0.0%	100% 0.0%
	clean	0 0.0%	0 0.0%	0 0.0%	39 19.5%	0 0.0%	100% 0.0%
	dusty	4 2.0%	0 0.0%	2 1.0%	1 0.5%	39 19.5%	84.8% 15.2%
		90.0% 10.0%	100% 0.0%	95.0% 5.0%	97.5% 2.5%	97.5% 2.5%	96.0% 4.0%
		Electrical-Damage	Physical-Damage	birdrop	clean	dusty	
		Target Class					

(a) 影像訓練結果



(b) 瑕疵種類 t-SNE 分布圖

資料來源：本研究繪製。

圖5 LSTM太陽能面板瑕疵


類別模型準確度為96.0%，此模型能夠精確辨識出單一的瑕疵，其中灰塵瑕疵和完整無損的光伏面板有出現混淆，因此準確度降低，如圖5(b)。

3. ResNet50-LSTM混合神經網路模型

圖6為ResNet50-LSTM利用太陽能光伏面板瑕疵影像進行訓練的結果，由圖6(a)可知在單一瑕疵類別模型準確度為98.0%，此模型更能

		Confusion Matrix					
Output Class	Electrical-damage	40 20.0%	0 0.0%	0 0.0%	0 0.0%	1 0.5%	97.6% 2.4%
	Physical-Damage	0 0.0%	40 20.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	birddrop	0 0.0%	0 0.0%	39 19.5%	0 0.0%	2 1.0%	95.1% 4.9%
	clean	0 0.0%	0 0.0%	0 0.0%	40 20.0%	0 0.0%	100% 0.0%
	dusty	0 0.0%	0 0.0%	1 0.5%	0 0.0%	37 18.5%	97.4% 2.6%
	100% 0.0%	100% 0.0%	97.5% 2.5%	100% 0.0%	92.5% 7.5%	98.0% 2.0%	
		Electrical-damage	Physical-Damage	birddrop	clean	dusty	
		Target Class					

(a) 影像訓練結果



(b) 瑕疵種類 t-SNE 分布圖

資料來源：本研究繪製。

圖6 ResNet50-LSTM太陽能面板瑕疵

夠精確辨識出單一的瑕疵，如圖6(b)。

B. 情境二：複數瑕疵檢測

1. ResNet50神經網路模型

圖7所示為LSTM50利用太陽能板瑕疵影像進行訓練的結果，圖7(a)中模型準確度為85.4%，此模型在辨識鳥屎污染及物理破壞時能夠清楚的分類瑕疵，但在更進階的複數瑕疵中如:鳥屎加物理破壞、鳥屎加電損瑕疵，兩者會混淆在一起，其中瑕疵類別中鳥屎污染的複數瑕疵在分布圖中混淆在一起，如圖7(b)。

2. LSTM神經網路模型

圖8所示為LSTM利用太陽能板瑕疵影像進行訓練的結果，圖8(a)中模型準確度為81.3%，此模型能夠辨識出灰塵及鳥屎的瑕疵，其中辨識出複數瑕疵類別完整無損、灰塵物理破壞、鳥屎加物理破壞、鳥屎加電損破壞及灰塵加鳥屎瑕疵有出現混淆的部分，如圖8(b)。

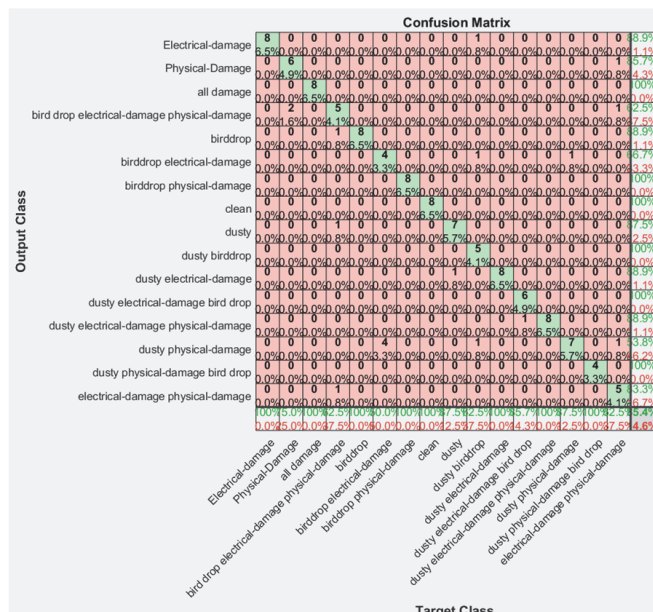
3. ResNet50-LSTM混合神經網路模型

圖9所示為ResNet50-LSTM利用太陽能板瑕


疵影像進行訓練的結果，圖9(a)中模型準確度為98.3%，此模型在辨識所有類別的瑕疵能夠清楚的分類，在圖9(b)中可以看到瑕疵種類分布非常清晰，沒有瑕疵混淆在一起。

由圖8可知鳥屎與灰塵污染兩者之辨識結果具有極高的混淆，此乃由於單一瑕疵之鳥屎與灰塵污染在某些光照條件下，兩者的反光特性顯得相似。不同瑕疵類別的訓練平均準確率如表4所示。由表4可知本文所提混合神經網路於太陽能電廠之光伏面板之瑕疵診斷之訓練在識別多種類型瑕疵的組合時，確實能夠更好地捕捉到瑕疵特徵的綜合表現。準確率於檢測複數瑕疵(編號15)時可高達99.41%外，於完整無損時(編號1)亦可達99.42%。

本論文太陽能板瑕疵分類共有16種，為了避免影響訓練結果分歧性，本論文均勻分配各類瑕疵，每類瑕疵之訓練影像張數為32張。表5所示為不同神經網路模型準確率及訓練比較之結果，其中，訓練準確率由訓練結果之召回率(式(7))與F1分數(式(8))求得。從表5可知於複



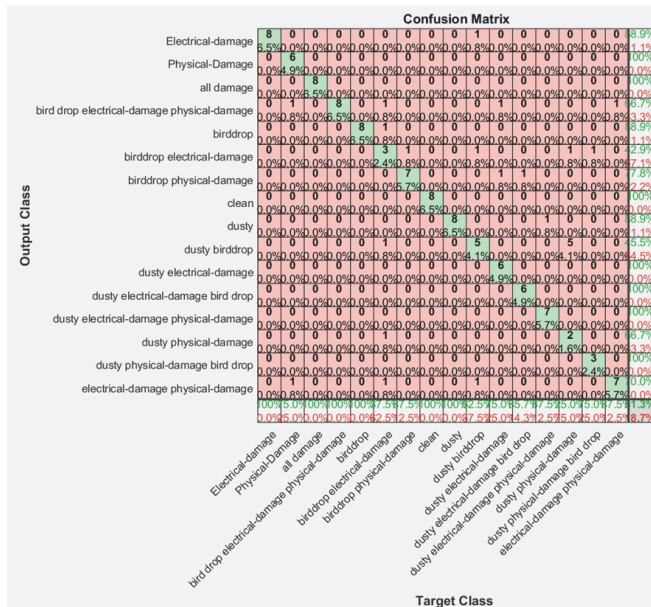
(a) 影像訓練結果




(b) 瑕疵種類 t-SNE 分布圖

資料來源：本研究繪製。

圖7 ResNet50太陽能光伏面板瑕疵



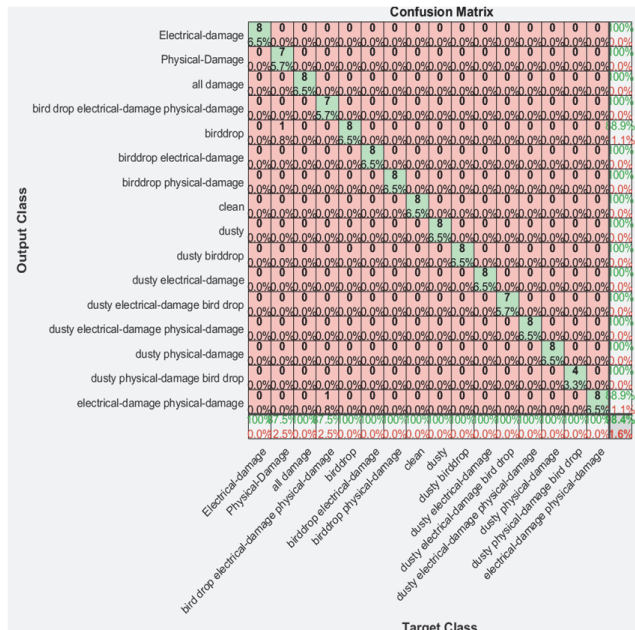
(a) 影像訓練結果




(b) 瑕疵種類 t-SNE分布圖

資料來源：本研究繪製。

圖8 LSTM太陽能光伏面板瑕疵



(a) 影像訓練結果



(b) 瑕疵種類 t-SNE分布圖

資料來源：本研究繪製。

圖9 ResNet50-LSTM太陽能光伏面板瑕疵

數瑕疵訓練，本文提出之ResNet50-LSTM混合神經網路訓練其準確率為89.3%最為出色。在單一瑕疵神經網路訓練，本文提出之ResNet50-LSTM混合神經網路訓練其準確率為96.5%，優

於ResNet50的 93.5%，LSTM的92.0%。在訓練時間方面，由於本文所提之ResNet50-LSTM混合神經網路訓練，利用ResNet50特徵擷取能力捕捉影像瑕疵特徵，解決影響圖像轉換時梯度

表4 不同瑕疵類別的鑑別準確率

編號	瑕疵種類	訓練平均準確率(%)
1	Clean	99.42
2	Bird Drop	98.18
3	Dusty	98.81
4	Electrical Damage	98.82
5	Physical Damage	97.22
6	Bird Drop, Electrical Damage	98.94
7	Bird Drop, Physical Damage	97.48
8	Bird Drop, Dusty	99.39
9	Dusty, Electrical Damage	98.26
10	Dusty, Physical Damage	97.49
11	Electrical Damage, Physical Damage	97.96
12	Bird Drop, Electrical Damage, Physical Damage	98.91
13	Dusty, Electrical Damage, Bird Drop	98.81
14	Dusty, Electrical Damage, Physical Damage	98.47
15	Dusty, Physical Damage, Bird Drop	99.41
16	All Damage	97.82

資料來源：本研究整理。

爆炸問題，同時利用LSTM提升影像嵌入更新速度，解決長期依賴性的問題。因此本文所提之混合神經網路相較ResNet50及LSTM訓練時間皆較快。複數瑕疵神經網路訓練時間為單一瑕疵神經網路訓練時間的2.5倍，且所提本文提出之混和神經網路訓練時間，不論於複數瑕疵或單一瑕疵亦皆為最短。因此，本文提出之混和神經網路模型於太陽能電廠之光伏面板之複數瑕疵診斷確實具可行性。

神經網路模型參數訓練後，進行神經網路模型準確度之實際驗證；驗證時隨機投入520張瑕疵光伏面板影像。表6所示為具複數瑕疵之光伏面板在本文所提出之混和神經網路於太陽能電廠之光伏面板之瑕疵診斷實測結果。由表5可知本文提出之ResNet50-LSTM混合神經網路

模型其在複數瑕疵驗證與單一瑕疵驗證準確率分別為89.3%與98.0%，與現有傳統神經網路模型相較皆最為出色。另，本文提出之ResNet50-LSTM混合神經網路模型在複數瑕疵診斷驗證為單一瑕疵的1.7倍外，與現有傳統神經網路模型相較，本文提出之ResNet50-LSTM神經網路驗證時間，不論於複數瑕疵驗證與單一瑕疵驗證亦皆為最短。因此，本文所提之混和神經網路模型於太陽能電廠之光伏面板之複數瑕疵診斷確實具可行性外並具有效性。

5. 結 論

本文提出一結合ResNet50與LSTM的混合神經網路實現對太陽能電廠之太陽能模組的光

表5 不同神經網路模型參數訓練

	神經網路模型	ResNet50-LSTM	ResNet50	LSTM	CNN (Acharya <i>et al.</i> , 2021)	YOLOv4 (Elidrissi <i>et al.</i> , 2022)
訓練準確率 (%) [訓練影像張數]	單一瑕疵	96.5[520] (5種瑕疵：Clean、Bird Drop、Dusty、Electrical Damage、Physical Damage)	93.5[520] (5種瑕疵：Clean、Bird Drop、Dusty、Electrical Damage、Physical Damage)	92.0[520] (5種瑕疵：Clean、Bird Drop、Dusty、Electrical Damage、Physical Damage)	74.8[515] (4種瑕疵：Normal、Microdefect、Large Defect、Low Resolution Defect)	83.0[---] (2種瑕疵：Normal、Defect)
	複數瑕疵	98.3[520]	85.4[520]	81.3[520]	---	---
訓練時間 (p.u.)	單一瑕疵	1.0	1.4	1.7	---	---
	複數瑕疵	2.6	3.2	3.5	---	---

資料來源：本研究整理。

表6 不同神經網路模型驗證比較

	神經網路模型	ResNet50-LSTM	ResNet50	LSTM	Mask RCNN (Cavieres <i>et al.</i> , 2022)	WNN (Li <i>et al.</i> , 2014)	YOLOv5l (Özer <i>et al.</i> , 2024)
驗證準確率 % [驗證影像張數]	單一瑕疵	95.0[520] (5種瑕疵：Clean、Bird Drop、Dusty、Electrical Damage、Physical Damage)	92.4[520] (5種瑕疵：Clean、Bird Drop、Dusty、Electrical Damage、Physical Damage)	90.0[520] (5種瑕疵：Clean、Bird Drop、Dusty、Electrical Damage、Physical Damage)	---	---	97.0[1100] (3種瑕疵：Normal、Damage、Dusty)
	複數瑕疵	97.3[520] (5種瑕疵：Clean、Bird Drop、Dusty、Electrical Damage、Physical Damage)	83.3[520] (5種瑕疵：Clean、Bird Drop、Dusty、Electrical Damage、Physical Damage)	80.3[520] (5種瑕疵：Clean、Bird Drop、Dusty、Electrical Damage、Physical Damage)	70[52] (2種瑕疵：Natural、Artificial Soiling)	83[100] (5種瑕疵：Normal、Short Circuit、Open Circuit、Abnormal Degradation、Partial Shading)	---
驗證時間 (p.u.)	單一瑕疵	1.0	2.2	2.3	---	---	---
	複數瑕疵	1.7	2.6	2.9	---	---	---

資料來源：本研究整理。

伏面板的遮蔽、刮痕與破裂等的複數瑕疵自動化檢測。結果顯示本文提出的ResNet50-LSTM混合神經網路在複數和單一瑕疵檢測訓練中均展現出色性能。在複數瑕疵訓練中，ResNet50-LSTM的準確率達到98.3%，明顯優於ResNet50的85.4%與LSTM的81.3%。在單一瑕疵訓練中，ResNet50-LSTM的準確率為96.5，超越ResNet50的93.5%與LSTM的92.0%。此外，本文所提出之ResNet50-LSTM在複數瑕疵診斷之訓練時間與單一瑕疵診斷時間，與現有神經網路模型相較皆為最短。再者，本文所提之ResNet50-LSTM神經網路在單一瑕疵驗證與複數瑕疵驗證準確率分別為95.0%與97.3%亦最為出色外，且驗證時間與現有神經網路模型相較亦皆為最短。本文所提的ResNet50-LSTM混合神經網路在訓練準確率和時間及驗證準確率和時間皆具相當的優越性，因此，除可以提升太陽能發電廠的發電率與供電可靠度外，並也同時可以降低太陽能電廠運轉維護成本。所提ResNet50與LSTM的混合神經網路在光伏面板顏色及瑕疵自動檢測任務中具相當有效性和實用價值。另，由於太陽能電廠光伏面板的複數瑕疵影像，如重疊率或覆蓋率、哪一類在上或在下、影像特徵與彼此間的差異等，目前尚未有制式標準，適當定義個別瑕疵在複數瑕疵的重疊或覆蓋情形與混合神經網路於太陽能電廠之光伏面板瑕疵診斷之泛用能力，未來可納入持續發展影像鑑別技術的研究課題。

參考文獻

- 臺灣 2050 淨零排放路徑及策略總說明, https://www.ndc.gov.tw/Content_List.aspx?n=DEE68AAD8B38BD76, May. 2024.
- Akram, M. W., G. Li and J. Yi, 2019. CNN Based Automatic Detection of Photovoltaic Cell Defects in Electroluminescence Images. *Energy*, vol. 189, pp. 1-15.
- Acharya, K. A., K. P. Sahu and R. S. Jena, 2021. Deep Neural Network based Approach for Detection of Defective Solar Cell. *Materials Today: Proceedings*, vol. 39, pp. 2009-2014.
- Bergstra, J and Y. Bengio, 2012. Random Search for Hyper-Parameter Optimization. *Machine Learning Research*, vol. 13, pp. 281-305.
- Cavieres, R., R. Barraza, D. Estay and J. Bilbao, 2022. Automatic Soiling and Partial Shading Assessment on PV Modules through RGB Images Analysis. *Applied Energy*, vol. 306, pp. 1-12.
- Cao, Y., D. Pang, Q. Zhao, Y. Yan and Y. Jiang, 2024. Improved YOLOv8-GD deep learning model for defect detection in electroluminescence images of solar photovoltaic modules. *Engineering Applications of Artificial Intelligence*, vol. 131, pp.121-132.
- Elidrissi, H., H. Achakir, Y. Zefri, I. Sebari, G. Aniba and H. Hajji, 2022. Automatic on Field Detection and Localization of Defective Solar Photovoltaic Modules from Orthorectified RGB UAV Imagery. *6th International Conference on Green Energy and Applications (ICGEA)*, Singapore, pp. 46-50.
- Gers, F.A., F. Cummins, and J. Schmidhuber, 1999. Learning to Forget: Continual Prediction with LSTM. *9th International Conference on Artificial Neural Networks: ICANN*, vol. 99, pp. 850-855.
- Hinton, G and V. D. M. Laurens, 2008. Visualizing Data using t-SNE. *Journal of Machine Learning Research*, vol. 9, pp. 2579-2605.

- He, K., X. Zhang, S. Ren and J. Sun, 2016. Deep Residual Learning for Image Recognition. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, pp. 770-778.
- Huang, G and Z. Liu, 2017. Densely Connected Convolutional Networks. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, USA, pp. 2261-2269.
- Jordan, D.C. and S.R. Kurtz, 2011. Photovoltaic Degradation rates-an Analytical Review. National Renewable Energy Laboratory, vol. 21, pp. 12-29.
- Jia, S., Y. Jia, Z. Bu, S. Li, L. Lv and S. Ji, 2022. Detection Technology of Partial Discharge in Transformer based on Optical Signal. Energy Reports, vol. 9, pp. 98-106.
- Li, X., P. Yang, J. Ni and J. Zhao, 2014. Fault Diagnostic Method for PV Array Based on Improved Wavelet Neural Network Algorithm. Proceeding of the 11th World Congress on Intelligent Control and Automation (WCICA), Shenyang, China, pp.1171-1175.
- Luna-Romero, S.F., X. Serrano-Guerrero, M. de Souza and G. Escrivá-Escrivà, 2024. Enhancing Anomaly Detection in Electrical Consumption Profiles through Computational Intelligence. Energy Reports, vol. 11, pp. 951-962.
- Madeti, S.R. and S.N. Singh, 2018. Modeling of PV System based on Experimental Data for Fault Detection Using KNN Method. Solar Energy, vol. 173, pp. 139-151.
- Ng, Andrew Y., 2004. Feature selection, L1 vs. L2 regularization, and rotational invariance. Machine Learning, pp.78-85.
- Özer, T. and Ö. Türkmen, 2024. An Approach based on Deep Learning Methods to Detect the Condition of Solar Panels in Solar Power Plants. Computers and Electrical Engineering, vol. 116, pp. 1-19.
- Powers and D. M. W, 2011. Evaluation: From Precision, Recall and F-measure to ROC, Informedness, Markedness and Correlation. Journal of Machine Learning Technologies, pp. 37-63.
- Srivastava, N., G. Hinton, A. Krizhevsky, I. Sutskever and R. Salakhutdinov, 2014. Dropout: A simple way to prevent neural networks from overfitting. Journal of Machine Learning Research, pp.1929-1958.
- Segovia Ramírez, I., F.P. García Márquez, and J. Parra Chaparro, 2024. Convolutional Neural Networks and Internet of Things for Fault Detection by Aerial Monitoring of Photovoltaic Solar Plants. Measurement, vol. 234, 114861, pp.1-23.
- Szegedy, C., S. Ioffe, V. Vanhoucke and A. Alemi, 2017. Inception-V4, Inception-Resnet and The Impact of Residual Connections on Learning. Proceedings of the AAAI Conference on Artificial Intelligence, vol. 31, no. 1, pp. 4278-4284.
- Sokolova, M. and G. Lapalme, 2009. A systematic analysis of performance measures for classification tasks. Information Processing & Management, vol. 45, pp. 427-437.
- Song, R. and Q. Jiang, 2021. Application of VMD Combined with CNN and LSTM in Motor Bearing Fault. IEEE 16th Conference on Industrial Electronics and Applications (ICIEA), Chengdu, China, pp. 1661-1666.

- solar panel, <https://www.kaggle.com/search?q=solar+panel+in%3Adatasets>, May. 2024.
- Sheng, Z., Z. An, H. Wang, G. Chen and K. Tian, 2023. Residual LSTM based Short-Term Load Forecasting. *Applied Soft Computing*, vol. 144, pp. 1-14.
- Tan, Z. and P. Pan, 2019. Network Fault Prediction based on CNN-LSTM Hybrid Neural Network. *International Conference on Communications, Information System and Computer Engineering (CISCE)*, Haikou, China, pp. 486-490.
- Tang, W., Q. Yang, K. Xiong and W. Yan, 2020. Deep Learning based Automatic Defect Identification of Photovoltaic Module Using Electroluminescence Images. *Solar Energy*, vol. 201, pp. 453-460.
- Wang, H., H. Yi, J. Peng, G. Wang, Y. Liu, H. Jiang and W. Liu, 2017. Deterministic and Probabilistic Forecasting of Photovoltaic Power based on Deep Convolutional Neural Network. *Energy Conversion and Management*, vol. 153, pp. 409-422.
- Wang, Y., L. Li, Y. Sun and J. Xu, 2021. Adaptive Automatic Solar Cell Defect Detection and Classification based on Absolute Electroluminescence Imaging. *Energy*, vol. 229, pp.1-14.
- Wang, F., J. Sheng, S. Sfarra and Y. Zhou, 2023. Multimode Infrared Thermal-Wave Imaging in non-Destructive Testing and Evaluation (NDT&E): Physical Principles, Modulated Waveform, and Excitation Heat Source. *Infrared Physics & Technology*, vol. 135, pp. 1-20.
- Xia, S., Y. Xia, H. Yu, Q. Liu, Y. Luo, G. Wang and Z. Chen, 2019. Transferring Ensemble Representations Using Deep Convolutional Neural Networks for Small-Scale Image Classification. *IEEE Access*, vol. 7, pp. 168175-168186.
- Yilmaz, A. and G. Bayrak, 2019. A real-time UWT-based Intelligent Fault Detection Method for PV-based Microgrids. *Electric Power Systems Research*, vol. 177, pp.1-13.
- Yu, Y., X. An, J. Lin and S. Li, 2024. A Vision System based on CNN-LSTM for Robotic Citrus Sorting. *Information Processing in Agriculture*, vol. 11, pp. 14-25.
- Zhong, Z., J. Li, L. Ma and H. Jiang, 2017. Deep Residual Networks for Hyperspectral Image Classification. *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Fort Worth, TX, USA, pp. 1824-1827.

Defects Diagnosis for Photovoltaic Panel Used in Solar Power Plant by Hybrid Neural Networks

Yu-Sen Liu¹ Jenn-Jong Shieh^{2*} Zong-Ying Shieh²

ABSTRACT

The article proposes a hybrid neural network that combines residual neural network (ResNet50) and long short-term memory (LSTM) to realize automated detection of complex defects such as physical damage, electrical loss, bird droppings contamination and dust on photovoltaic panels of solar modules in solar power plants, in order to improve the accuracy of photovoltaic performance of solar modules. In addition to verifying the effectiveness and accuracy of the proposed hybrid neural network model through experiments, it is also compared with the traditional neural network detection model. The verification results show that the proposed hybrid neural network model is superior to the traditional neural network model in terms of accuracy and verification time for defects diagnosis for photovoltaic panel used in solar power plant.

Keywords: photovoltaic panel, automated inspection, defect detection, hybrid, neural network.

¹Feng Chia University, Department of Electrical Engineering, postgraduate.

²Feng Chia University, Department of Electrical Engineering, professor.

³National Chung Hsing University, Department of Management Information Systems, undergraduate.

*Corresponding Author, Phone: +886-424517250 Ext.3815, E-mail: jjshieh@fcu.edu.tw

Received Date: May 27, 2024

Revised Date: August 13, 2024

Accepted Date: August 16, 2024