



利用深度學習進行訊號異常識別 之方法比較及在線識別

周肇昱／國立臺灣大學土木工程研究所結構工程組 博士班研究生

黃謝恭／國立中興大學土木工程研究所結構工程組 助理教授

張家銘／國立臺灣大學土木工程學系 副教授

於各種民生基礎建設中，為確保結構的可靠性與安全性，常安裝有各式監測系統，以獲得相關之當前狀態。在長期的監測過程中，這些監測系統會生成大量的數據，其中亦包含許多異常訊號，最終會對結構健康監測（Structural Health Monitoring, SHM）與其應用（例如系統識別和損傷檢測）造成挑戰。因此，了解與探索結構健康監測系統之異常訊號至關重要，需研發仰賴高效自動檢測並分類異常訊號之技術。本研究嘗試、探索且比較了幾種常見的機械學習（Machine Learning）技術，結合數種不同的資料類型為輸入，訓練各式淺層和深層神經網絡，包括使用統計資訊的模式識別（Pattern Recognition，或稱圖形識別）網路、基於時間歷時的圖像式卷積神經網絡（Convolutional Neural Network, CNN）與基於圖像式時頻混合卷積神經網絡。為測試上述自動檢測與分類技術，使用中國一座大跨度斜張橋之一個月中所量測真實加速度訊號，透過不同模型訓練參數進行模型效能的相互比對。測試結果顯示，三種深度學習模型皆可以成功地檢測和分類六種不同的訊號異常。在這些方法中，經過重新訓練的 GoogleNet 能在準確性方面優於其他模型，並且可進行在線的自動化訊號異常識別，作為施行結構健康監測前檢查訊號品質不可或缺的工具。

簡介

在長期結構健康監測的應用中，監測系統通常需要感測器與監測網能自主運作的，並由量測民生基礎建設的反應有效地評估結構的損傷或狀態；然而，因監測元件老化、惡劣環境或校準錯誤等問題，訊號異常很可能經常會發生並影響結果^[1,2]。這些訊號異常通常在依據訊號繪製的圖表中，可被人工檢查出來；由於該工作高度人力仰賴，若能採用機械學習技術分析，則可直接對感測反應進行特徵繪製，並直接、自動檢討訊號之正確性。具體來說，感測器訊號異常通常分為：遺失資料（Missing）、微弱資料（Minor）、反常資料（Outlier，亦或稱突波資料，Spike）、方波資料（Square）、偏移資料（Trend）、漂移資料（Drift）、高雜訊資料（Excessive Noise）、非線性資料（Non-linearity）等。在進行結構健康監測前，必須先確保其量測數據品質並盡可能排除訊號異常的可能，以獲得較準確的結構健康結果。

訊號異常的出現可直接影響結構健康監測的結果。研究人員發現，由於感測器異常而量測得到的數據會使訊號處理（Signal Processing）失真，例如，功率譜密度（Power Spectral Density, PSD）的計算錯誤、系統識別性能下降（尤其是用於模態形狀的估計）及結構損傷檢測的指示失真^[3]。因此，開發高效的前置技術來自動檢測與分類不同類型的異常訊號，發展可靠的結構健康監測應用為當務之急。

異常訊號的處理與判別在過去已有學者進行了廣泛的研究^[4]。Chang 等人^[5]利用自迴歸（Autoregressive, AR）建模技術開發了一組 Kalman 估測器來預測感測器的輸出，計算預測與量測的反應之殘差，並應用於檢測三種類型的感測器異常，包括加性、乘性和緩慢漂移之訊號異常。另外，機械學習技術已被應用來直接對感測器故障進行分類^[6-9]，最近，Bao 等人^[10]開發了一種基於深度學習的策略，利用生物視覺和邏輯思維，將原始量測數據通過數據可視化（Data

Visualization) 進行轉換，然後憑藉深度神經網絡進一步分類，並透過一座大跨度橋樑所量測的真實數據進行驗證。Fu 等人^[3] 在無線監測系統中，探討監測訊號之異常，其中反常資料、漂移資料和偏差資料 (Bias) 是三種主要的異常類型，該研究開發了一種三階段策略，進行分佈式相似性測試 (Distributed Similarity Test) 檢測異常，並使用人工神經網絡對異常進行分類，最終應用校正函數 (Correction Function) 或使用估計值替換異常訊號來解決問題。Mao 等人^[11] 開發了生成對抗網絡 (Generative Adversarial Network)，結合無監督方法 (如自動編碼器, Autoencoder) 檢測感測器異常，減少傳統的監督式學習中標記階段所需的大量人力成本，將原始量測數據轉換為格拉姆角場 (Gramian Angular Field) 圖像，使用來自全尺寸橋樑的兩組數據集來驗證所提出的方法。這些方法都證實了機器學習於訊號異常識別的可行性以及其可有效將低使用的人力成本。然而，鮮少研究針對不同模型交互比對，且透過模型進行在線的訊號異常識別。

在本研究中，將使用三種方法來檢測和分類異常訊號，包括基於統計資訊的模式識別 (Pattern Recognition, 或稱圖形識別) 網路、基於時間歷時轉換圖的卷積神經網絡 (Convolutional Neural Network, CNN) 和圖像式時頻混合的深度神經網絡，本研究中使用一組由位於中國的一座大跨度斜張橋於一個月中所量測的加速度資料來驗證上述三種方法，透過比較不同訓練參數如：輸入資料維度、訓練速率和 epoch，試圖找尋最適合訊號異常識別之模型以及探討其參數對於模型的影響。並透過準確性最高之模型進行在線識別的可行性分析。從結果得知，每種方法皆能有相

當令人滿意的識別結果，並且利用圖像式時頻混合資料進行 GoogLeNet 模型訓練有著最高的識別精度。該模型也展現其高精度的在線自動化識別能力。爾後可直接應用於實際工程案例，在進行結構健康監測前針對量測資訊進行快速的故障篩選。

訊號異常介紹

結構健康監測系統為了確保高準確性的判別結果，對於感測器量測訊號的品質有相當高的要求。在現地量測中，常常會發生異物撞擊、感測器老化、抑或訊號線損壞，導致量測訊號異常。因此，在實施結構健康監測前，進行訊號異常識別為維持高效能之監測系統首要工作。此外，訊號異常分類有助於工程師更好地了解感測器的使用狀況，並提升維修的效率。本研究中，將集合探討三種深度學習模型針對檢測與分類訊號異常之應用，模型包含：(1) 模式識別 (Pattern Recognition, 或稱圖形識別) 網路；(2) 基於時間歷時的圖像式 CNN；(3) 基於圖像式時頻混合 CNN。在以下介紹中，將簡要闡述本研究所使用的量測資料，包括訊號的種類、分佈以及如何進行資料擴增；接著，針對各模型的特徵、資料結構、輸入資料型態、訓練精度和識別結果進行進一步的討論及介紹。

本研究使用的量測資料由 IPC-SHM (International Project Competition for Structural Health Monitoring) 協會提供，針對中國一座大跨度斜張橋長期監測之加速度數據，包括 38 顆加速規之反應，其中採樣頻率為 20 Hz^[12]。圖 1 為本研究所考慮的七種訊號種類，包括正常資料、遺失資料、微弱資料、反常資料、方波資料、偏移資料及漂移資料。在該資料中，統計各類異常訊號的數

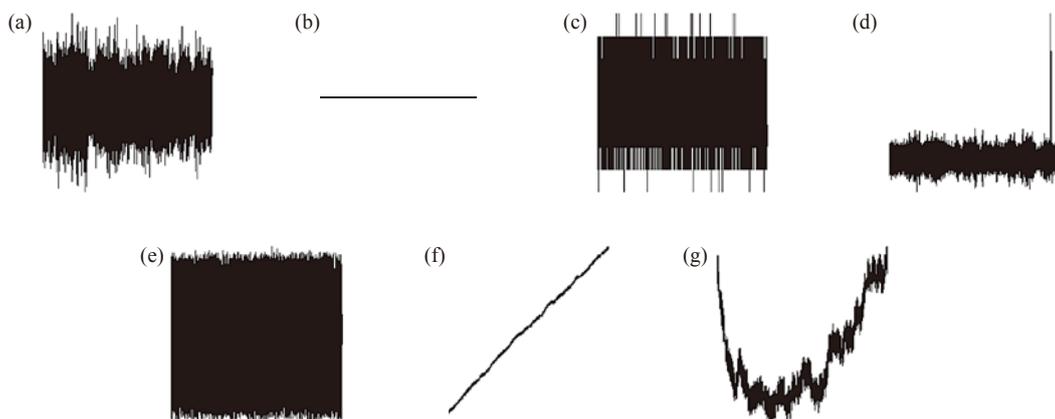


圖 1 訊號種類：(a) 正常資料，(b) 遺失資料，(c) 微弱資料，(d) 反常資料，(e) 方波資料，(f) 偏移資料，(g) 漂移資料

量得知，感測器故障的種類分佈並不平衡，如圖 2 所示，其中數量最多的大約有 12000 組（正常資料），最少則到 523 組（異常資料）。為了強調該資料庫在分佈上的不平衡性，可以以圓餅圖的形式表示，其中包含與完整資料庫相比的百分比，如圖 2(b) 所示。為了調整資料庫的不平衡以降低可能影響訓練成果的比重（例如，正常訊號的學習遠多於異常訊號的偏差學習），訓練資料庫的數量均以反常資料的總數作為基準。在訓練過程中，一些標記不明確的訊號已人工刪除，確保模型不考慮可能誤導的特徵。為了提高訓練模型的精度，且確保訊號異常標記不會因訊號翻轉而改變，因此，本研究嘗試將每小時的歷時資料進行調整，使得資料庫數量擴展為兩倍，如表 1 顯示，透過擴展後所使用訓練和驗證資料庫的數量，使得資料量能被模型有效訓練。

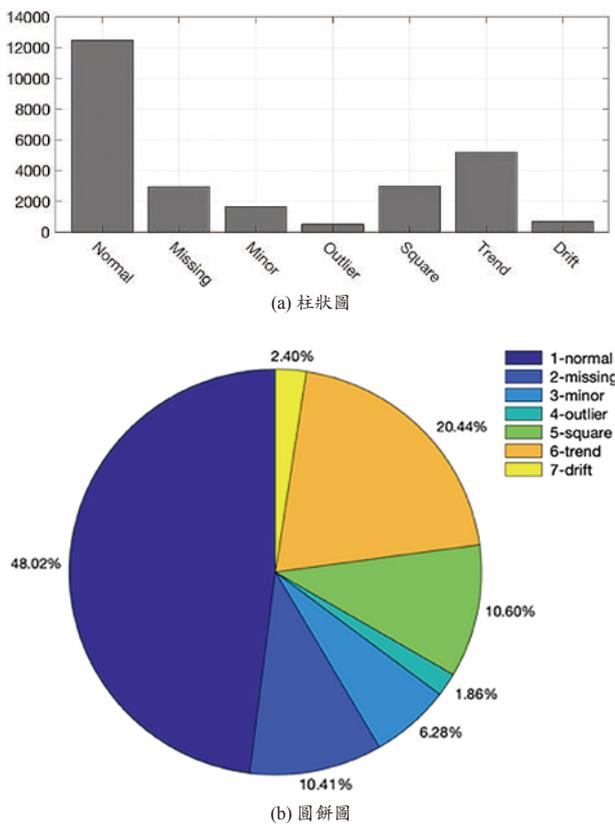


圖 2 訊號異常資料庫種類數量統計

表 1 所使用之訓練和驗證資料庫各異常種類數量

/種類	正常	遺失	微弱	反常	方波	偏移	漂移
訓練資料庫	800						
驗證資料庫	24136	5076	2512	224	5168	9506	554
總和	24936	5876	3312	1024	5968	10306	1354

深度學習模型介紹

模式識別網路

類神經網路架構

模式識別網路可用來分辨六種訊號異常，其是由多層前饋（Multi-Layer Feedforward, MLF）類神經網路進行資料訓練，根據目標標籤來對輸入資料的分類進行學習。在本研究中，透過運算而得的 64 個參數作為輸入，包含機率分佈、算術平均值、數值範圍與標準偏差。神經網路由四層組成：輸入層、輸出層以及兩層隱藏層，如圖 3 所示。四層網路的神經元皆互相連接，並以雙曲切線（Hyperbolic Tangent）作為激勵函數，透過平方誤差（Mean Squared Error, MSE）計算模型的損失。

訓練模型之初，透過 Nguyen-Widrow 初始化演算法計算各神經元的初始權重和偏差值，接著，MLF 會根據誤差與反向傳播法更新各神經元的權重和偏差值。最佳化時透過 Levenberg-Marquardt 演算法，也稱為阻尼最小平方（Damped Least-squares, DLS）演算法，來提升模型精度，並在達到最小梯度或最大自適應值時終止訓練，以期達到最佳化模型。為了避免過度擬合（Overfitting）現象，使用獨立的參考資料庫來驗證訓練結果，確保原始資料庫精度增加時亦提升參考資料庫的精度。換句話說，如果訓練模型的準確性增加，但驗證資料庫的精度反而保持不變或下降，則模型會提前終止（代表過度擬合）來保持泛用性。這種方法與曲線擬合（Curve Fitting）有著類似且皆不可避免的問題，即近似函數的自由度越高，靈活性越

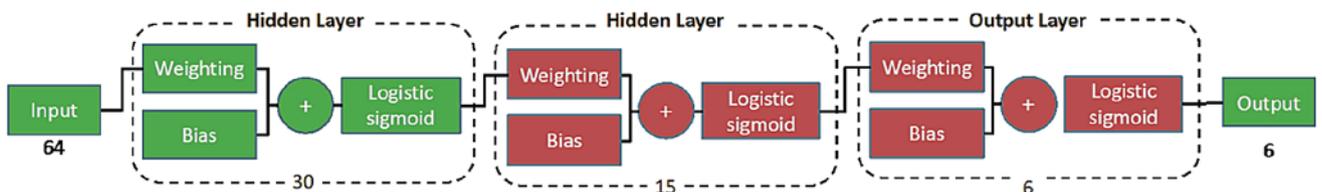


圖 3 模式識別網路架構

大，輸入數據的擬合性越強；然而，考慮到真實訊號可能受到雜訊的影響，使用較泛用的模型是有助於表現實際情況的。

輸入層

若要直接以加速度數據做為輸入，則以單一加速規採樣頻率 20 Hz 計算，一小時資料量為 72,000 筆，而本研究所使用資料包含 744 小時以及 38 顆加速規，巨大資料量無法達到快速的識別以及訓練。因此，若直接使用加速規數據，不如改採用一些統計上的參數作為輸入來降低資料維度，為了有效區分七個不同的訊號種類，本研究採用的統計參數包含機率分佈、算術平均值、數值範圍和標準偏差，如圖 4 所示。

如前所述，除了上述三個統計參數外，還採用機率分佈來區分不同的訊號異常種類，機率分佈是一種函數用來描述不同數值在整個訊號中出現的次數，在本次研究中，負兩個標準偏差與正兩個標準偏差之間的機率分佈被用來訓練模型，並總共分配了 61 個部份來描述訊號，換句話說，每個部份的範圍為：

$$r_s = \frac{\sigma_x}{30} \quad (1)$$

其中 r_s 是每個部份的範圍， σ_x 是訊號的標準偏差。如圖 4 所示，不同的訊號種類表現出非常不同的機率分

佈，例如，標記為正常資料應具有常態分布，如圖 4(a) 所示，標記為偏移資料應具有類似均勻分佈，如圖 4(c) 所示，並且標記為微弱資料應具有很多呈現零的分佈（資料僅重複數個特定數字），如圖 4(b) 所示。根據上述統計參數，可以輕鬆地分類訊號種類，因此，這些統計參數用作後續神經網路的輸入。

然而，由於部分訊號異常具有獨特的特性，因此可以在模式識別網路之前就進行分類。在資料庫中，只有兩種訊號被標記為遺失資料，一個是充滿 NAN (Not A Number) 的資料，這種資料不能生成任何統計參數，但可以在訊號輸入訓練模型之前就輕易識別。另一個是具有固定值的資料，此類資料具有單調的統計參數，最重要的是，數據範圍始終為零，因此在準備輸入時也能夠輕易識別。通過佈置一些檢查邏輯，在將輸入到模式識別網路之前，可以方便地標記遺失資料，因此，由模型分類的訊號種類從七個減少到六個。

基於時間歷時的圖像式卷積神經網路

CNN 是最常見的物件分類技術之一，主要包括卷積層 (Convolution Layer)、池化層 (Pooling Layer) 和子採樣層 (Subsampling Layer)，然後是完全連接的層。這些分層旨在從圖像中提取微小特徵，並在選定的標籤中對圖像進行評分，最終對象根據所有標籤中的最佳分數進行分類。

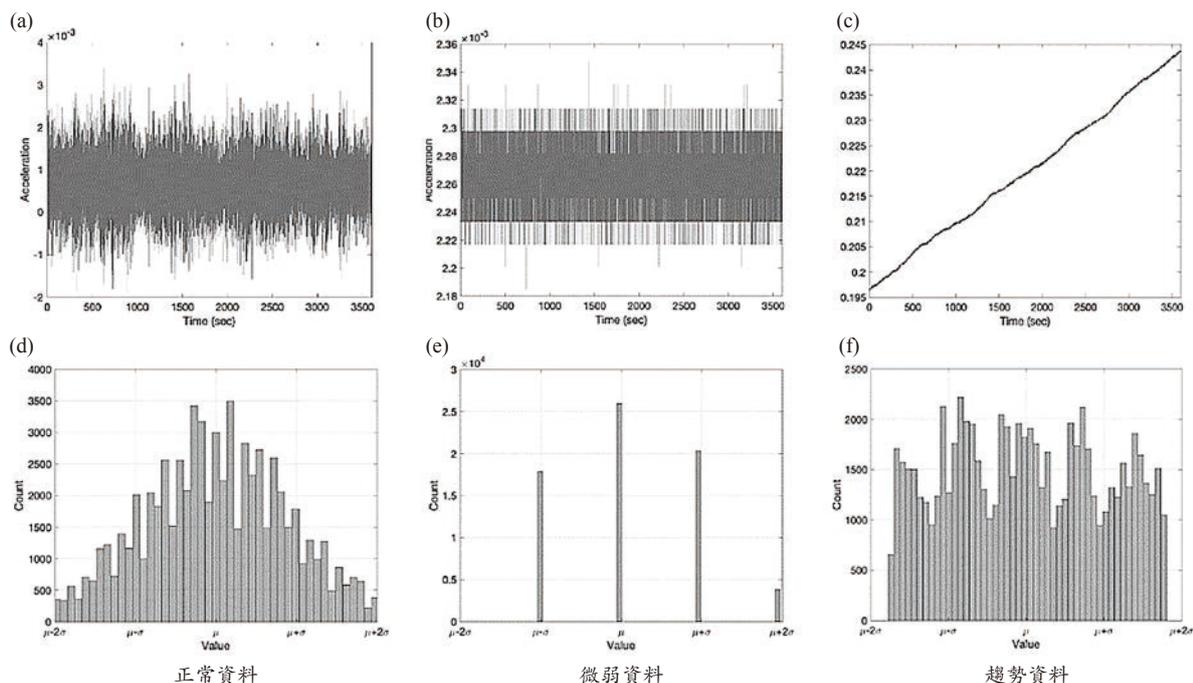


圖 4 訊號以及統計參數之比較

類神經網路架構

本研究中使用一個簡單的卷積神經網路，用於分類由異常訊號直接轉換成之圖像，以下簡稱為 CNN-1。在此模型中，圖像解析度首先被縮小為 28×28 ，以加快訓練過程，值得一提的是，圖像解析度對應之電腦運算量是相對的，解析度越高則運算時間也會增加。本模型共使用三個組合層，如圖 5 所示，每層包含一卷積層和一正規層（用以批次正規化與池化），此外，每個神經元的激勵函數採用修正線性單位（Rectified Linear Unit, ReLU）函數，在萃取圖像特徵後，模型末端包含全連接層（Fully Connected Layer）、softmax 層和分類層，以便對七種不同標籤分數進行排名。訓練過程中，每次輸入 128 張圖像做訓練，當其誤差降低至閾值，則表示模型收斂。而分數最高的標籤即為訊號異常識別的種類。

輸入層

訊號異常可透過人眼輕易識別，表示每種類型的異常在視覺上皆有獨特之處，因此，一個最簡單的想法是直接將訊號轉換為圖像，如圖 1 所示。七種類型的訊號異常首先由

$$y_{\text{normalize}} = \frac{y - y_{\min}}{y_{\max} - y_{\min}} \quad (2)$$

其中是正規後的訊號、是輸入歷時、和是輸入歷時中最大和最小值，在模型訓練中，正規化訊號可以消除數值大小對於模型的影響，並只捕捉訊號特徵。在正規化訊號至區間 $[-1, 1]$ 後，將轉換為圖檔作為資料庫，由於圖像的解析度對於模型訓練甚為重要，過低之解析度會造成圖像部分特徵遺失，如反常的峰值會消失。因此，在本研究中採解析度為 256×256 像素的圖像。經測試，該解析度為人工可識別訊號異常之最小解析度，並且不會造成嚴重的資料特徵遺失。

基於圖像式時頻混合卷積神經網路

為了進一步提高模型精度，本研究使用混合資訊作為輸入並建立更複雜的機器學習模型架構 [13]，嘗試利用 GoogLeNet 的模型架構進行資料的重新訓練。GoogLeNet 對於物件分類有很好的訓練成果，在 2014 年 ILSVRC (ImageNet Large Scale Visual Recognition Challenge) 比賽中，它針對 1000 種類型的物件進行分類獲得第一名 [14]，與 ZFnet 和 AlexNet 相比，其效能有了顯著的提升，此外，與 VGGNet 相比，它的錯誤率更低。因此，本研究利用 GoogLeNet 進行模型訓練，並通過快速的傅立業轉換，將時間歷時和頻譜進行影像的疊合。

類神經網路架構

在本研究中，首先將圖像解析度縮放為 224×224 像素，以減少電腦運算量。GoogLeNet 的架構由 22 層網路組成，包括卷積層、最大池化層、inception 層、平均池化層、線性層、softmax 層和全連接層，更詳細的模型架構建立說明可參考 [14]。為了使模型吻合資料庫，本研究將最後一個分類層和全連接層的維度替換成 1×7 ，以便單獨識別七種訊號種類，每次訓練的數量為 10 張圖片，並且初始學習速率為 0.001。為了讓訓練的資料皆使用資料庫資料，本研究未使用遷移學習 (Transfer Learning)，而是重新訓練 GoogLeNet 模型。

輸入層

為了提取更多的訊號特徵，而不僅僅是考慮訊號本身的時間歷時，本研究先是使用上一小節由式 (2) 求得的時間歷時，並將之與頻率資訊重合。其頻率反應可由 [15]

$$Spec_k = \left| \sum_{s=1}^t e^{iks} x_s \right|^2 \quad (3)$$

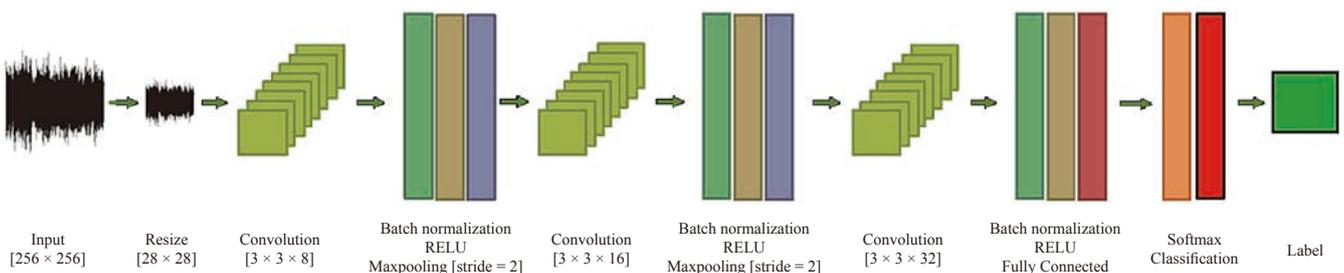


圖 5 簡單卷積神經網路模型架構

其中表示於頻率點的頻率反應，是於時間的訊號 x 。透過頻率反應轉換成熱圖 (Heat Map)，並與時間歷時的圖疊合，完成混合輸入資訊，影像解析度為 512×512 像素的圖像。值得一提的是，由於熱圖對於解析度極其敏感，因此降低解析度可能會造成圖片過於模糊而無法得到精度高的模型。圖 6 為基於七種不同訊號異常所繪製出的混合資訊輸入影像，如圖所示，可以同時在時間域及頻率域觀察到這些訊號異常的特性。

訓練模型結果與比較

為了確保資料庫中不同標籤之間的平衡性，每種標籤使用的數量為 554 筆，其中訓練的資料庫佔總資料庫的 70%，驗證資料庫佔總資料庫的 30%，圖 7(a)

顯示經過多次試訓後 MSE 的最佳結果。很明顯，在權重持續更新後，訓練資料庫和驗證資料庫的 MSE 同時減少；然而，驗證資料庫的 MSE 在 53 次迭代後開始略有增加，這意味著模型趨勢與訓練資料庫不再吻合，在經過驗證資料庫的 MSE 連續 6 次增加後停止迭代，並選擇了第 53 個迭代的結果作為訓練完成的模型。圖 7(b) 為利用該訓練完成模型計算的誤差矩陣 (Confusion Matrix)。總體而言，準確性良好，各式標籤的最低精度高達 90%，從該矩陣得知，微弱資料和反常資料相互誤判的機率較高，這是由於該兩種訊號異常的機率分佈非常相似，且透過算術平均值和標準偏差區分兩者也相對困難。

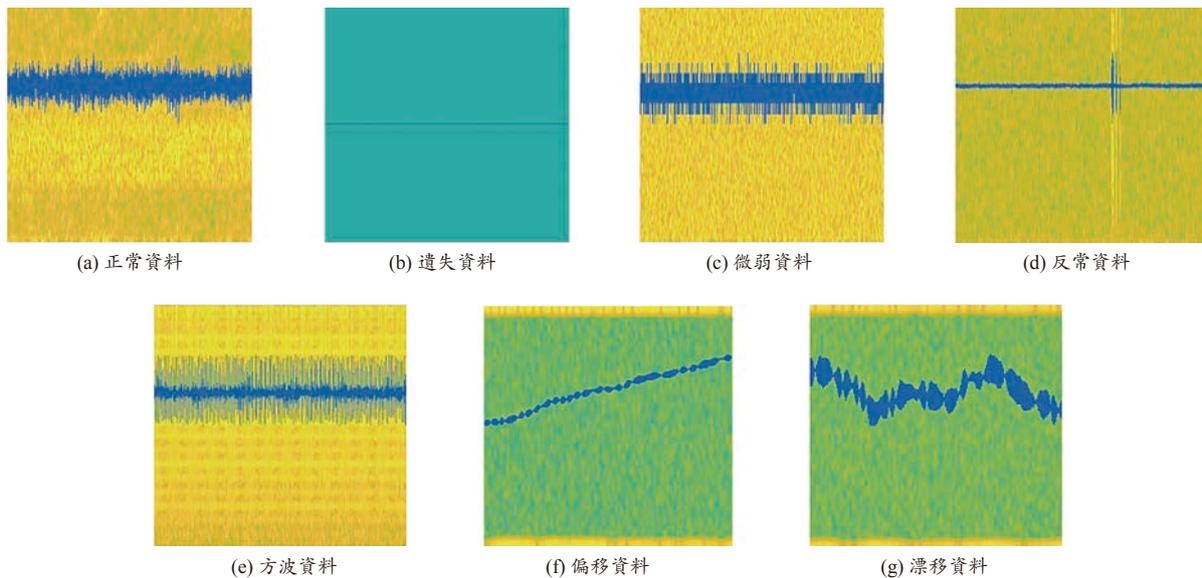
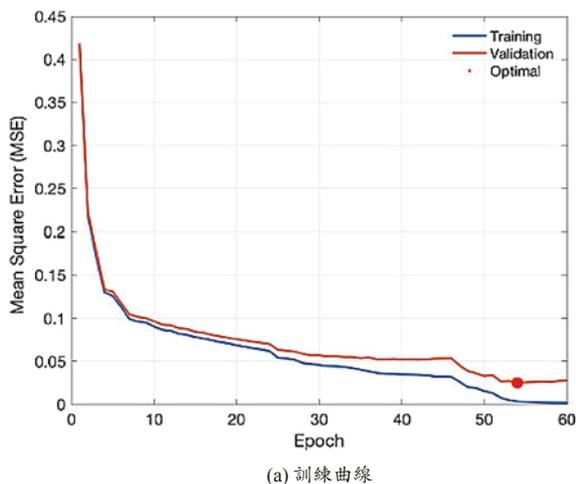


圖 6 混合資料輸入影像



(a) 訓練曲線

	Normal	Missing	Minor	Outlier	Square	Trend	Drift
Normal	97.7%	0.0%	0.8%	1.1%	0.0%	0.0%	0.0%
Missing	0.0%	100%	0.0%	0.0%	0.0%	0.0%	0.0%
Minor	2.3%	0.0%	92.4%	7.6%	0.0%	0.0%	0.0%
Outlier	0.0%	0.0%	5.8%	90.7%	0.2%	0.0%	0.0%
Square	0.0%	0.0%	0.2%	0.2%	99.8%	0.0%	0.0%
Trend	0.0%	0.0%	0.8%	0.0%	0.0%	100%	0.0%
Drift	0.0%	0.0%	0.0%	0.3%	0.0%	0.0%	100%

(b) 誤差矩陣 (confusion matrix)

圖 7 透過模式識別模型的訓練及驗證成果

圖 8 表示基於 CNN-1 模型和 GoogLeNet 模型的學習曲線，分別如圖 8(a) 及圖 8(b) 所示，藍線表示透過訓練資料庫進行訓練的的誤差和準確性，而紅線表示驗證資料庫的誤差和準確性，對於兩種模型，都可以觀察到誤差收斂於極低點，表示成功的找到最佳

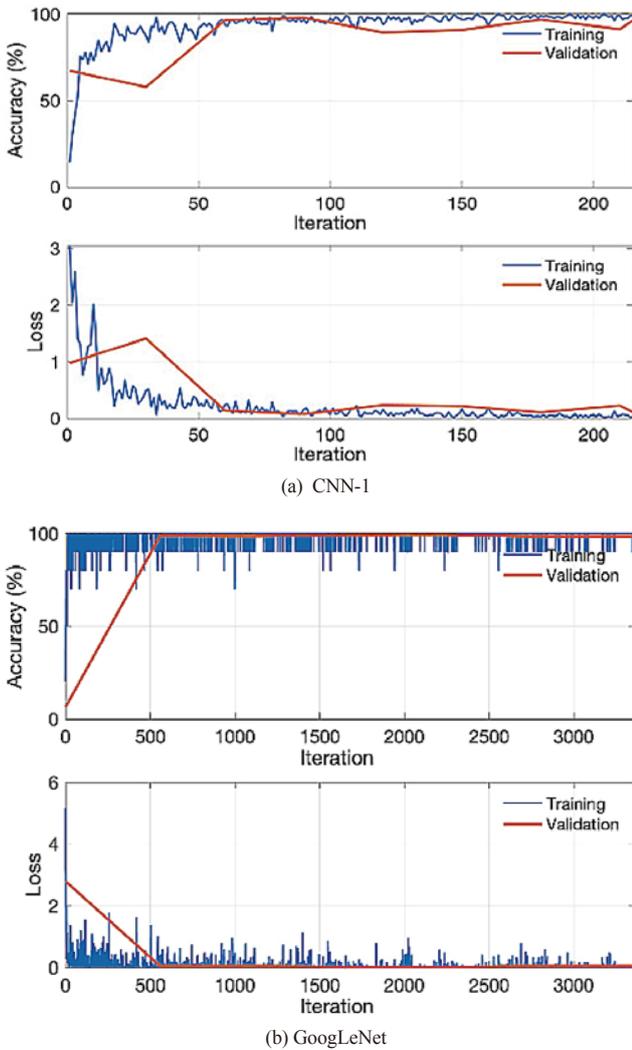


圖 8 模型的訓練曲線

訓練模型。此外，兩模型準確度也表示模型有著非常高的識別率。

接著，調整了不同的參數（例如輸入影像解析度、epoch 和訓練速率），以獲得最佳訓練模型，表 2 為利用一小時訊號作為輸入資料對應不同參數的精準度比較，儘管每個模型的訓練時使用訓練資料庫數量不盡相同，但其使用的驗證資料庫一致。如本表所示，增加解析度對模型的準確性有良好的影響，此外，通過增加 epoch 和降低訓練速率也可以增加精度；然而，當訓練速率降低時有可能會造成模型找到局部最佳解，而無法獲得全域最佳解，此外，通過 GoogLeNet 等結構較為複雜的模型，可以更有效地捕捉每個訊號異常種類，從而產生更好的精準性。比較不同類型的訓練模型，本研究得到透過 GoogLeNet 模型進行混合資訊輸入的訓練，可獲得最佳的識別結果，其最佳的參數配置如表中紅色螢光所示。

由於一小時進行一次識別，對於即時監測系統而言無法靈活運用，因此本研究也透過輸入的一小時資料轉換為十分鐘資料，並基於該資料訓練一個可用於在線（On-line）偵測的系統的模型。基於以上述研究結論得出 GoogLeNet 模型為精度最高之模型，在線偵測系統中也採用該模型。圖 9 為該在線偵測系統所進行的識別結果，從圖中所示，每十分鐘的資料將轉換成圖片，並透過已訓練好之模型進行即時識別，不同顏色來標示其訊號異常的種類。以本圖為例，綠色表示該訊號為微弱資料，而藍色則表示為反常資料。表 3 為圖 9 識別訊號異常結果所對應的偵測時間，該識別結果充分展現了該訓練模型的準確性，以及可運用於在線系統之中，達到高精度自動化的訊號異常識別。

表 2 基於不同參數設定之模型精度

參數						訊號異常種類精度 (%)						
#	原始解析度	變更解析度	模型名稱	Epoch	訓練速率	1	2	3	4	5	6	7
1	256256	28	CNN-1	4	1e-2	97.2	99.8	77.0	89.0	99.4	84.8	99.8
2	256256	64	CNN-1	4	1e-2	95.3	99.9	91.9	86.8	99.2	94.3	93.7
3	256256	64	CNN-1	5	1e-2	97.9	99.8	93.3	93.6	99.8	98.6	99.1
4	256256	224	GoogLeNet	4	1e-3	99.6	99.7	99.6	87.7	99.9	99.5	98.0
5	256256	224	GoogLeNet	6	1e-3	98.5	99.7	99.1	97.0	99.9	97.1	100
6	256256	224	GoogLeNet	6	1e-5	97.8	100	98.9	94.9	99.4	98.1	99.6
7	651	-	模式識別	60	1e-3	99.7	100	98.1	75.0	99.5	99.0	88.2

(註:1. 正常、2. 遺失、3. 微小、4. 反常、5. 方波、6. 偏移、7. 飄移)

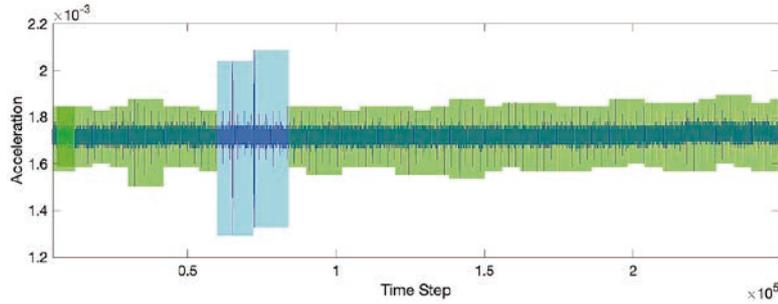


圖 9 利用資料庫進行之訊號異常識別結果

表 3 基於即時偵測系統所判別出訊號異常時間及種類

#	偵測異常時間	訊號異常種類
1	2020-01-01-00:05:00 – 2012-01-01-00:45:00	微弱資料
2	2012-01-01-00:50:00 – 2012-01-01-01:05:00	反常資料
3	2012-01-01-01:10:00 – 2012-01-01-03:20:00	微弱資料

結論

在本研究中探索並比較了幾種常見的深度學習技術，並用其來檢測與分類不同類型的異常訊號，使用位於中國的一座大跨度斜張橋之一個月中所量測的真實加速度資料，進行訓練和測試這幾種深度學習模型，包含使用訊號統計資訊的模式識別網路、基於時間歷時的圖像式卷積神經網路和基於圖像式時頻混合卷積神經網路。測試結果顯示，三種模型皆可以成功檢測和分類六種不同的訊號異常（包含遺失資料、微弱資料、反常資料、方波資料、偏移資料和漂移資料）。此外，本研究比較了三種不同類型的神經網路模型，包含模型複雜度、輸入資料類型以及模型訓練參數。由本研究顯示，透過時頻混合資料進行 GoogLeNet 模型訓練最能有效的將訊號異常分類。此外，在提高訓練圖片的解析度及訓練的 epoch 下，模型能夠有更高的識別精度。雖然降低學習速率在大部分情況能改善模型精度，但過低的學習速率會增加其找到局部解的可能，反而造成模型識別精度的衰減。同時，在大多數情況下，感測器的訊號異常種類有很大機率會再次出現在同一個感測器上，倘若能夠將該特性加入訓練，勢必能夠獲得更精確的模型。最終，本研究透過 GoogLeNet 模型針對時頻混合資料成功進行十分鐘的訊號異常識別。該識別可由加速度資料中自動地將訊號異常捕捉，並提供可視化以及異常時間資訊。從結果而知，本研究所提出之 GoogLeNet 模型能夠精準的判別訊號異常種類，並且可進行在線的自動化訊號異常識別，確保有效的結構健康監測使用數據。

參考資料

- Sharma, A.B., Golubchik, L., and Govindan, R (2010). Sensor faults: Detection methods and prevalence in real-world datasets. *ACM Transactions on Sensor Networks (TOSN)*, 6(3), 23.
- Mahapatro, A., and Khilar, P.M (2013). Fault diagnosis in wireless sensor networks: A survey, *IEEE Communications Surveys & Tutorials*, 15(4), 2000-2026.
- Fu, Y., Peng, C., Gomez, F., Narazaki, Y., and Spencer Jr. B.F (2019). Sensor Fault Management Techniques for Wireless Smart Sensor Networks in Structural Health Monitoring, *Structural Control and Health Monitoring*, e2362.
- Bao, Y., Chen Z., Wei, S., Xu, Y., Tang, Z., and Li, H. (2019). The state of the art of data science and engineering in structural health monitoring, *Engineering*, 5, 234-242.
- Chang, C.M., Chou, J.Y., Tan, P., and Wang, L (2017). A sensor fault detection strategy for structural health monitoring systems, *Smart Structures and Systems*, 20(1), 43-52.
- Zhao, C., Sun, X., Sun, S, and Jiang, T (2011). Fault diagnosis of sensor by chaos particle swarm optimization algorithm and support vector machine, *Expert Systems with Applications* 38, 8: 9908-9912.
- Yu, C.B., Hu, J.J., Li, R., Deng, S.H., and Yang, R.M (2014). Node fault diagnosis in WSN based on RS and SVM, In 2014 International Conference on Wireless Communication and Sensor Network (pp. 153-156). IEEE.
- Dragos, K. and Smarsly, K (2016). Distributed adaptive diagnosis of sensor faults using structural response data, *Smart Materials and Structures*, 25(10), 105019.
- Smarsly, K. and Law, K.H (2014). Decentralized fault detection and isolation in wireless structural health monitoring systems using analytical redundancy, *Advances in Engineering Software*, 73, 1-10.
- Bao, Y., Tang, Z., Li, H., and Zhang, Y (2019). Computer vision and deep learning-based data anomaly detection method for structural health monitoring, *Structural Health Monitoring*, 18(2), 401-421.
- Mao, J., Wang, H., and Spencer Jr, B.F (2020). Toward data anomaly detection for automated structural health monitoring: Exploiting generative adversarial nets and autoencoders. *Structural Health Monitoring*, 1475921720924601.
- Tang, Z., Chen, Z., Bao, Y., and Li, H (2018). Convolutional neural network-based data anomaly detection method using multiple information for structural health monitoring. *Structural Control and Health Monitoring*, e2296.
- Singla, A., Yuan, L., and Ebrahimi, T (2016). Food/Non-food image classification and food categorization using pre-trained GoogLeNet Model. *MADiMa 16: Proceedings of the 2nd International Workshop on Multimedia Assisted Dietary Management*, October 2016 Pages 3-11
- Christian, S., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., and Rabinovich, A (2015). Going deeper with convolutions, In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1-9.
- Grchenig, K (2013). *Foundations of Time-Frequency Analysis*. Springer Science + Business Media, LLC.