



監測訊號異常的自動化處理與分類 以橋梁加速度監測為例

黃謝恭* / 國立中興大學土木工程研究所結構工程組 副教授

林天邠 / 荷語魯汶大學機械工程研究所機電動力系統組 博士班研究生

橋梁的結構健康監測 (Structural Health Monitoring, SHM) 與結構完整性管理 (Structural Integrity Management, SIM) 技術，是隨著科技進展下，人們憑藉實現永續建設與維護的方法，進而獲得廣泛應用。然而隨之而來的便是大量的數據，並且伴隨著許多異常數據，若是使用人工檢測與分類異常訊號，既費力又乏味，而且效率相當低下，因此，本次監測使用一座大跨徑斜張橋為示範案例，導入一種機器學習技術，稱為模式識別網路 (pattern recognition network)，用來取代人工檢測與分類的過程，並且使用統計資料來避免龐大且較無效率的機械學習模型。另外，針對訓練資料集中出現標記錯誤的問題，本次示範案例中改善傳統的迭代修剪損失最小化 (Iterative Trimmed Loss Minimization, ITLM)，利用人機協同 (Human-In-The-Loop, HITL) 的機械學習技術來施行人工輔助校正，結果顯示在使用不平衡資料集的情況下，人機協同的迭代修剪損失最小化能夠提升整體效能，更適合用於異常訊號的檢測與分類。

前言

橋梁的結構健康監測 (Structural Health Monitoring, SHM) 與結構完整性管理 (Structural Integrity Management, SIM) 是智慧城市發展中最重要的一項技術，也是利用科技實現永續建設與維護的創新範例，因此一直以來備受關注，目前兩項技術已經廣泛應用於持續且長期的監控結構健康狀況，並且及時偵測基礎建設的早期劣化，尤其是大型結構，例如建築物、水壩和隧道 [1-3]。

上述兩項技術在持續且長期的監測過程中會產生大量的數據，而惡劣的環境、損壞的元件、校正錯誤或是感測器故障都會損壞量測資料，影響資料品質 [4]，異常數據可能在後續處理過程中扭曲資訊、在系統識別過程中擷取不正確的特性、在損傷偵測過程中產生錯誤結論，並且最終在橋梁的結構健康監測或結構完整性管理

中導致對橋梁狀況的錯誤判斷。一般而言，及時檢測異常訊號並將其分類可為監測系統的維護工作提供指引；然而，這些工作通常都是由人工執行，既費力又乏味，而且效率相當低下，無法達到自動有效的檢測與分類。

近年來基於人工智慧 (Artificial Intelligence, AI) 與機械學習 (Machine Learning, ML) 所開發的檢測與分類被證實是準確高效且容易自動化的，尤其是在結構健康監測的技術上，例如使用卷積神經網路 (Convolutional Neural Network, CNN) 來直接偵測量測資料的異常 [5-7]。雖然基於人工智慧與機械學習之策略可以達到自動有效的檢測與分類，但仍面臨許多挑戰，例如高度仰賴計算力、需要大量且標記正確的訓練資料集 … 等等 [8]，尤其是在實際應用中完全標記正確的訓練資料集往往是不可得的，尤其是在大量資料的前提下，亦即標記錯誤是不可避免的，因此模型效能通常會受到限制 [9]，為此有數種技術被提出來改善機械學習模型的效能，例如 Ren

* 通訊作者，skhuang@nchu.edu.tw

等人嘗試使用不同的權重，在一組有標記錯誤的訓練資料集上常識訓練與學習^[10]。

在本次監測示範案例中，針對橋梁二個月的監測資料來基於機械學習發展準確且自動有效的檢測與分類技術，該類神經網路（Artificial Neural Network, ANN）是衍伸過去發展之機械學習模型^[8]，為一種透過統計資料對於現地所量測到的資料進行特徵提取（feature extraction），讓基於機械學習的模型能夠自動且有效的學習各類別的資料特徵，進而達到異常數據與訊號的檢測與分類，最後將所訓練出來的模型在不同月份下的性能，以及修正的結果施行觀察與討論，進而得到整體的結論。

監測示範案例簡介

本次監測示範案例為一座大跨徑斜張橋，量測資料均來自於全球結構健康監測的國際競賽，1st International Project Competition for Structural Health Monitoring (IPC-SHM)^[11]，本座斜張橋主跨長 1,088 公尺，兩邊副跨長 300 公尺，兩座橋塔高達 306 公尺。斜張橋一共安裝 16 顆雙軸向加速度計和 2 顆三軸向加速度計，其中雙軸向加速度計 14 顆分別安裝在大橋的橋面板上（頻道編號 1 至 28 號），2 顆分別安裝在兩座橋塔的塔頂（頻道編號 29 至 32 號），而在兩座橋塔的底部各有安裝 1 顆三軸向加速度計（頻道編號 33 至 38 號），如圖 1 所示。

該橋之監測系統以 20 Hz 為取樣頻率，本次監測示範案例總共使用兩個月共計 1,440 小時 54,720 筆的資料，每一筆資料為一小時，收集到的所有資料還有進一步的前處理，以便給予監督式學習的標籤。在兩

個月的量測資料內，分為 6 種不同標籤，包含一種正常訊號（normal data），與五種異常訊號，包含遺失訊號（missing）、微弱訊號（minor）、離群值訊號（outlier）、方波訊號（square）與飄移訊號（dnft），可以看到無論是那個資料集，在各個標籤分布上是非常不平衡的，兩個月中各標籤所佔數據與比例如圖 2 所示，兩個月的資料整體來看正常訊號分別佔了 48% 與 49%，五種異常訊號分別佔了 2% 至 20% 不等，這種典型的不平衡資料集是讓機械學習要達到準確且自動有效的檢測與分類中需要克服的一大難關。

監測資料一筆為一小時，共 72,000 點，若是直接使用時域（time-domain）的加速度數據進行學習、檢測與分類，會讓機械學習模型龐大且較無效率，而本次監測示範案例所使用資料包含 54,720 筆，巨大的資料量無法達到快速的訓練以及學習，因此建議使用統計資料作為輸入來讓模型學習^[12]。案例使用一個典型的模式識別網路（pattern recognition network）來對統計資料進行監督式學習，模式識別網路是一個多層前饋（Multi-Layer Feedforward, MLF）的類神經網路，可以透過預先給定的目標標籤進行訓練用以區分輸入資料的特定模式。訓練時，每筆監測資料的統計數值將被當作模式識別網路的輸入資料，其中包含：機率分佈（probability distribution）、資料範圍（range）、算術平均數（arithmetic mean）、標準差（standard deviations）、四分位數（quartile）與標準分數（standard score，又稱 z-score、z 分數或標準化值）… 等共十一個統計數值作為訓練輸入。




圖 1 本次監測示範案例與加速度計安裝位置示意圖




圖 2 整體資料在不同類別中所佔數據與比例

初步檢測與分類結果

模式識別網路是典型的淺層（shallow）類神經網路，相較於近期流行的深層（deep）模型，可以享有小巧、效率高與可移植的優點，案例中各個網路層的連接均是使用全連接層（Fully Connected Layer, FCL），其中在輸入層與四層隱藏層中間使用雙曲正切（hyperbolic tangent）作為激活函數（activation function），在輸出層則是使用 softmax 當作激活函數。同時，使用交叉熵誤差（cross-entropy error）作為損失函數（loss function），使類神經網路能夠對於不好的預測產生較大損失，給予類神經網路較多的修正，最後通過激活函數轉化為各個標籤機率，此為分類中最常使用的損失函數之一，也適合應用於本示範案例之多標籤分類（multi-label classification）的問題。

這裡學習停止的標準採用檢查訓練是否達到最小梯度（gradient）或是達到取大期數（epoch），為了適當避免過擬合（overfitting，又稱過度學習）問題，例如學習結果雖然在損失函數的最終表現良好，但卻無法分類不是在訓練資料內的其他資料，也就是缺乏泛化性（generalization），案例採用驗證（validation）資料集^[13]的方式，預先將部分資料隔離，當隨著學習的進行，訓練資料集的損失函數減小但驗證資料集的損失函數卻逐漸變大時，檢查相似情形是否連續經過一

定期數時，此時會提早結束訓練並使用過去最佳的網路模型。透過分成訓練及驗證資料集的方式，能夠維持模式識別網路模型的泛化能力，進而使類神經網路模型可以較廣泛的被使用在同樣的領域中，換句話說就是能夠維持模型對不同資料的適應性。

在監督式學習的類神經網路中，混淆矩陣（confusion matrix）是常用來衡量模型分類的評估標準^[14]，能夠確實瞭解模型預測結果和真實標籤之間的對應關係，如表 1 所示。混淆矩陣主要分為真陽性（True Positive, TP）真陰性（True Negative, TN）假陽性（False Positive, FP）與假陰性（False Negative, FN）四類，進而可以衍生出在機器學習領域中常用的 3 種評估指標，例如：

- 準確率（accuracy）表示分類完全正確的比例，是指模型分類到正確標籤的樣本數除以總樣本數，以比例表示。

$$\text{accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

- 精確率（precision）表示分類為該標籤的樣本中，真正是該標籤樣本的機率。

$$\text{precision} = \frac{TP}{TP + FP} \quad (2)$$

- 召回率（recall）表示在真實該標籤的樣本中，被分類為該標籤的機率。

表 1 混淆矩陣各項評估標準之定義

Confusion Matrix Actual Condition Positive		Actual Condition	
		Actual Condition Negative	
Predicted Condition	Predicted Condition Positive	True Positive (TP)	False Positive (FP)
	Predicted Condition Negative	False Negative (FN)	True Negative (TN)

$$\text{recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}$$

(3)

其中精確率與召回率可能在不同的情況中被個別看重，例如召回率也可說是在真實的事件中有多少被成功找出來，精確率也可說是在所有被分類為真實的事件中有多少可信。

圖 3 為本次示範案例初步之混淆矩陣，其中最下行（第七行）為召回率而最右列（第七列）為精確率，行列交點（第七行第七列）為準確率。由第一個月與第二個月的準確率可以瞭解使用模式識別網路進行學習、檢測與分類，能夠正確的區分正常訊號與各種異常訊號，個別準確率達到 98.9% 與 99.4%，然而若往進階評估標準來看，兩個月的離群值訊號均未被妥善檢測與分類，例如第一個月的召回率與精確率分別為 75.5% 與 83.1%，第二個月的召回率為 78.5%，僅有第二個月的精確率稍微超過 90%（92.5），然而相較於其他異常訊號，精確率仍不算高。因此，從示範案例兩個月的初步結果可以總結如下：利用模式識別網路進行學習、檢測與分類大跨徑斜張橋的加速度數據基本可行，正常訊號與各種異常訊號能夠使用淺層類神經

網路高效區分，唯獨離群值訊號的分辨上使用初步結果較為不好，在精確率與召回率上略有疑義。

分類不正確結果之檢討

在監測示範案例中，模式識別網路能夠高效區分正常訊號與各種異常訊號，僅在單一異常訊號的分辨結果較為不好，為了更深入瞭解淺層類神經網路在離群值訊號的精確率與召回率較為低迷之具體原因，逐步檢視各個時域的加速度數據，得到一些較為特別的觀察。

圖 4 為本次示範案例中分類不正確之錯誤標籤，橫軸為時間單位為分鐘，例如圖 4(a)、圖 4(b) 和圖 4(c) 顯示了三個不同的加速度數據，這些資料的標籤分別應為微弱訊號、微弱訊號和離群值訊號，但是最終都被標記為正常訊號；圖 4(d) 標記為離群值訊號，而圖 4(e) 則標記為微弱訊號，但是這兩個加速度數據在經過檢查後都應該歸類為正常訊號；圖 4(f) 顯示一個可以被標記為微弱訊號亦可以標記為離群值訊號的範例，但是這個加速度數據最終都標記為微弱訊號。除此之外，遺失訊號、方波訊號和飄移訊號也有少數標記錯誤，例如圖 4(g) 所示的方波訊被標記錯誤為正





圖 3 本次監測示範案例兩個月初步之混淆矩陣

常訊號，儘管資料在 45 分後遺失，因為每一筆資料為一小時，在整段時域的加速度數據含有兩種標籤的例子比比皆是，這些資料應被歸類為多重標籤，類似例子如圖 4(h) 和圖 4(i) 中的加速度數據在其記錄的開始和結束時展示出不同的標籤，但是最終僅被標記為正常訊號，圖 4(j) 和圖 4(k) 顯示兩個正常訊號在一小時

內變化成遺失訊號，但是最終僅被標記為遺失訊號。最後一個範例如圖 4(l) 所示，最終標記為遺失訊號，但是時域數據應先標記為遺失訊號，然後在最後幾分鐘內改為方波訊號，上述所有標籤錯誤都會直接影響建議模式識別網路在區分正常訊號與各種異常訊號時的正確性。




圖 4 分類不正確之錯誤標籤的展示與檢討

基於機械學習所開發的分類器（classifier）對於訓練資料集的品質非常敏感，也就是說，如果訓練資料集是一團糟或是充滿標記錯誤，區分正常訊號與各種異常訊號的結果將會很差，反過來說若有足夠數量的訓練資料集，且資料集中標記錯誤的標籤比例不高，機械學習本身泛化性就能很好地處理標記錯誤問題。然而，安排高品質的訓練資料集來進行學習是困難且昂貴的，例如本次監測示範案例的初始標籤是由多人同時協助標記完成，雖然事前有著充分的溝通與一致的共識，但是在實際操作時仍會因為種種原因標記錯誤，因此應用一些修正技術來確保學習過程的有效性，並產生訓練良好的類神經網路模型是極其必要的。

人機協同（Human-in-the-Loop, HITL） 機械學習與改善後之結果

在訓練資料集中，每一小時加速度數據的標籤都是由人工所標記完成，因此，難免出現由於人工標記所產生的失誤，或是標記過程中標準有所差異的情形發生，另外時域數據含有多種標籤的例子可以在許多資料中觀察得到，使得人工標記時容易產生混淆的情形。現今有許多基於機械學習的技術可以提升模型對於正確標籤模式（pattern，亦即特徵）的學習，而迭代修剪損失最小化（Iterative Trimmed Loss Minimization, ITLM）就是一個非常好的例子^[15,16]。

迭代修剪損失最小化的技術是基於機械學習的一個現象，即類神經網路模型在訓練時傾向嘗試學習較

為明確且清楚的模式，尤其是在訓練初期的時候，這些明確且清楚的模式通常存在於標記正確的乾淨資料集中，因此迭代修剪損失最小化的技術不再最小化整個訓練資料集的損失，而是嘗試最小化修剪損失（trimmed loss），而修剪損失就是從具有清楚明確模式的有限資料而來，至於不具備清楚明確模式的其他資料，在訓練時就不將被採用。迭代修剪損失最小化的技術憑藉在訓練的初期階段，擁有標記正確的資料，其學習曲線通常比標記錯誤的資料更好，只需要估計標記正確的資料所占之數量或百分比，並只需要專注於這些損失較小的資料即可，具體來說迭代修剪損失最小化的技術保留原始訓練流程，但在初期階段就提早終止，之後選擇損失相對較小的資料來計算修剪損失，並使用這些資料重新訓練模型，以將注意力放在較乾淨的資料集上，最終透過多次重複執行修剪損失，即可篩選出錯誤標籤，進而提升分類器的效能，如圖 5(a) 所示。

傳統的迭代修剪損失最小化專注於標記正確的資料，並且在相關的研究中被證明是有效的，僅僅經過幾次迭代就能提供高效的分類器^[17]。然而傳統的迭代修剪損失最小化對於不具備清楚明確模式的其他資料，在訓練時摒棄不再採用，無法根本解決標記錯誤的問題，因此本次監測示範案例導入人機協同的迭代修剪損失，人工介入損失較大的訓練資料，施行輔助校正，確認標記正確與否或修正標記錯誤的資料（如圖 5(a) 所示），確認與修正標記著重在損失較大的訓練資料，並且人機




圖 5 傳統的與人機協同的迭代修剪損失之流程比較

協同的迭代修剪損失仍然最小化整個訓練資料集的損失，以求同時保證訓練效果與乾淨資料集。

圖 6 顯示在迭代修剪損失施行人工輔助校正的詳細流程，假設本次監測示範案例標記正確的資料占比約為 95%，因此每次迭代中都會以人工介入確認與修正最後 5% 的資料，首先檢查個別資料是否

具有任何未定義的標籤（本示範案例並未發現其他標籤），其次檢查個別資料是否有多重標籤（例如圖 4(f) 至圖 4(l) 均屬於此），由於統計資訊將會捨棄時間資訊，因此在記錄的開始和結束時展示不同標籤的資料可以分為兩組獨立的資料，不過為了簡單起見，本次監測示範案例保持每一筆資料為一小時並且直接排除這些資料，最後檢查資料是否有標記錯誤，例如圖 4(a) 至圖 4(e) 所示，這些資料經過調整後，會再次納入訓練資料集，以改善訓練以及學習過程，另一方面，將標記正確的資料重新納入訓練資料集，以促使類神經網路模型重新學習模式。

本次監測示範案例最終總共進行了四次人工輔助校正，以第一個月的資料來看，在四次迭代後預測錯誤的標籤數目從最初的 402 個逐步下降為 243、207、127 與 108 個，準確率從最初的 98.5% 逐步上升為 99.1%、99.3%、99.6% 與 99.6%，可以判斷預測錯誤的標籤數目與準確率都達到收斂，此學習過程終止，整體來說人工介入總共調整了 979 個預測錯誤的資料，只佔總資料的 3%，此外最終只有 50 個具有多重標籤的資料被排除在訓練資料集之外，只佔總資料的 0.18%，顯示所提出的類神經網路模型能夠成功地從總資料的 99.82% 中學習到各個標籤之模式。若往進階評估標準來看，各個標籤也都有明顯提升，例如離群值訊號精確率與召回率從較為低迷的結果分別提高 16.12% 與 8.6%，最終，所提出的分類器在所有進階評估標準和標籤上的表現都高於 92%，其中大部分都達到 99% 以上，如圖 7 所示。最重要的是，人機協同的迭代修剪損失不僅提供了一個高效的類神經網路模型，還透過加入人工輔助校正功能提




圖 6 在迭代修剪損失施行人工輔助校正的詳細流程

供一個高品質的資料集，以上其實是一個主動學習的迴圈；迭代修剪損失的技術提供擷取功能來尋找標記錯誤的資料，而人工輔助校正則充當人類專家來註解所選的範例，因此基於機械學習的技術可以從較乾淨的訓練資料集中學習到最正確的模式。

		Confusion Matrix						
Predicted Labels	normal	13541 48.0%	0 0.0%	16 0.1%	29 0.1%	2 0.0%	0 0.0%	99.7% 0.3%
	missing	0 0.0%	2939 10.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	minor	10 0.0%	0 0.0%	1823 6.5%	1 0.0%	0 0.0%	0 0.0%	99.4% 0.6%
	outlier	26 0.1%	0 0.0%	8 0.0%	377 1.3%	0 0.0%	0 0.0%	91.7% 8.3%
	square	3 0.0%	0 0.0%	0 0.0%	0 0.0%	2993 10.6%	0 0.0%	99.9% 0.1%
	drift	0 0.0%	0 0.0%	1 0.0%	0 0.0%	0 0.0%	6453 22.9%	100.0% 0.0%
	Rec.	99.7% 0.3%	100% 0.0%	98.6% 1.4%	92.6% 7.4%	99.9% 0.1%	100% 0.0%	99.7% 0.3%
			normal	missing	minor	outlier	square	drift
Actual Labels								

(a) 第一個月

		Confusion Matrix							
Predicted Labels	normal	12926 49.0%	0 0.0%	6 0.0%	2 0.0%	0 0.0%	0 0.0%	99.9% 0.1%	
	missing	0 0.0%	2963 11.2%	0 0.0%	1 0.0%	0 0.0%	0 0.0%	100.0% 0.0%	
	minor	3 0.0%	0 0.0%	1609 6.1%	4 0.0%	0 0.0%	0 0.0%	99.6% 0.4%	
	outlier	4 0.0%	0 0.0%	2 0.0%	243 0.9%	0 0.0%	0 0.0%	97.6% 2.4%	
	square	0 0.0%	0 0.0%	0 0.0%	0 0.0%	3211 12.2%	0 0.0%	100% 0.0%	
	drift	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	5399 20.5%	100% 0.0%	
	Rec.	99.9% 0.1%	100% 0.0%	99.5% 0.5%	97.2% 2.8%	100% 0.0%	100% 0.0%	99.9% 0.1%	
			normal	missing	minor	outlier	square	drift	Pre.
			Actual Labels						

(b) 第二個月

圖 7 本次監測示範案例兩個月改善之混淆矩陣

結語

在持續且長期的監測過程中會產生大量的數據，其中不乏許多異常數據，本次監測使用一座大跨徑斜張橋為示範案例，導入模式識別網路來取代人工檢測與分類的過程，監測資料一筆為一小時，若是直接使用時域的加速度數據進行學習、檢測與分類，會讓機械學習模型龐大且較無效率，因此案例使用統計資料作為類神經網路的輸入資料。初步檢測與分類結果顯示模式識別網路能夠高效區分正常訊號與各種異常訊號，僅在單一異常訊號的分辨結果較為不好，經過逐步檢視各個時域的加速度數據，揭示標記錯誤的影響。接著，示範案例導入人機協同的迭代修剪損失來人工介入損失較大的訓練資料，施行輔助校正，確認

標記正確與否或修正標記錯誤的資料，最終改善機械學習模型的效能，並且同時確保標記正確的訓練資料集，因此分類器可以從較乾淨的資料集中學習到最正確的模式。

參考資料

1. Brownjohn, J.M. (2007). Structural health monitoring of civil infrastructure. Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences, 365 (1851), 589-622.
2. Karbhari, V.M. and Ansari, F. (Eds.). (2009). Structural health monitoring of civil infrastructure systems. Elsevier.
3. Toh, G. and Park, J. (2020). Review of vibration-based structural health monitoring using deep learning. Applied Sciences, 10(5), 1680.
4. Yi, T.H., Huang, H.B., and Li, H.N. (2017). Development of sensor validation methodologies for structural health monitoring: A comprehensive review. Measurement, 109, 200-214.
5. 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.
6. Tang, Z., Chen, Z., Bao, Y., and Li, H. (2019). Convolutional neural network based data anomaly detection method using multiple information for structural health monitoring. Structural Control and Health Monitoring, 26(1), e2296.
7. Nong, X., Luo, X., Lin, S., Ruan, Y., and Ye, X. (2023). Multimodal Deep Neural Network-Based Sensor Data Anomaly Diagnosis Method for Structural Health Monitoring. Buildings, 13(8), 1976.
8. Chou, J.Y., Fu, Y., Huang, S.K., and Chang, C.M. (2022). SHM data anomaly classification using machine learning strategies: A comparative study. Smart Structure System, 29, 77-91.
9. Jiang, X., Liu, J., Wang, J., Nie, Q., Wu, K., Liu, Y., and Zheng, F. (2022). Softpatch: Unsupervised anomaly detection with noisy data. Advances in Neural Information Processing Systems, 35, 15433-15445.
10. Ren, M., Zeng, W., Yang, B., and Urtasun, R. (2018, July). Learning to reweight examples for robust deep learning. In International conference on machine learning (pp. 4334-4343). PMLR.
11. Bao, Y., Li, J., Nagayama, T., Xu, Y., Spencer Jr, B.F., and Li, H. (2021). The 1st international project competition for structural health monitoring (IPC-SHM, 2020): A summary and benchmark problem. Structural Health Monitoring, 20(4), 2229-2239.
12. 林天邨、黃謝恭、周肇昱 (2022)，使用機器學習和統計資訊進行異常訊號檢測和分類，結構工程期刊，第三十七卷，第四期，第 41-63 頁。
13. Tetko, I.V., Livingstone, D.J., and Luik, A.I. (1995). Neural network studies. 1. Comparison of overfitting and overtraining. Journal of chemical information and computer sciences, 35(5), 826-833.
14. Stehman, S.V. (1997). Selecting and interpreting measures of thematic classification accuracy. Remote sensing of Environment, 62(1), 77-89.
15. Shen, Y. and Sanghavi, S. (2019a). Learning with bad training data via iterative trimmed loss minimization. In International Conference on Machine Learning (pp. 5739-5748). PMLR.
16. Shen, Y. and Sanghavi, S. (2019b). Iterative least trimmed squares for mixed linear regression. Advances in Neural Information Processing Systems, 32.
17. Huang, S.K. and Lin, T.X. (2025). Development of data anomaly classification for structural health monitoring based on iterative trimmed loss minimization and human-in-the-loop learning. Structural Health Monitoring, 24(1), 548-565.



交廣工程顧問有限公司

誠信 | 創新 | 品質 | 服務 | 永續發展

【專業技術整合，橫跨多元領域】

交廣工程顧問秉持「誠信、創新、品質、永續發展」理念，整合結構、土木、排水、橋梁與耐震補強等專業技術服務，深度參與國內重要公共工程，累積豐富實績。

【投入公共參與，重視社會連結】

長期投入公會事務、災後勘災與社會公益，展現對社會的責任與參與。我們致力打造前瞻、安全、永續的工程環境，與夥伴攜手共創價值。

【前瞻創新應用，引入AI與數位工具】

因應數位轉型，公司積極導入AI模型檢核與智慧作業平台，提供AI輔助的室內空間資訊優化服務，實現結構智慧安全。

服務
項目

- | | |
|----------------|---------------|
| 01. 公共工程規劃設計 | 05. 水土保持工程 |
| 02. 工程專案管理監造 | 06. 自來水及下水道工程 |
| 03. 私有建物耐震弱層補強 | 07. 大地及隧道工程 |
| 04. 房屋安檢鑑定 | |

台北總公司

☎ 02-2709-0716

🌐 www.jgce.com.tw

📍 台北市大安區忠孝東路三段52號2樓

桃園分公司

☎ 03-357-2323

🌐 www.jgce.com.tw

📍 桃園市桃園區莊二街24號7樓