

軌道振動量測數據結合長短期記憶模型(LSTM)預估幾何不整處之探討—以臺灣鐵路公司臺中工務段為例

黃宇謙¹ 賴俊呈² 賴瑞應³ 洪士林⁴ 陳保先⁵ 王鴻民⁶

¹交通部運輸研究所運輸技術研究中心副研究員

²交通部運輸研究所運輸技術研究中心助理研究員

³交通部運輸研究所運輸技術研究中心研究員兼科長

⁴國立陽明交通大學土木工程學系教授

⁵國營臺灣鐵路股份有限公司工務養護總隊隊長

⁶國營臺灣鐵路股份有限公司臺中工務段技術員

摘要

國營臺灣鐵路股份有限公司(簡稱臺鐵公司)規定轄下各工務段每月至少辦理 1 次營運列車行駛時之振動量測，並透過訂立標準值推估軌道幾何線形異常處，本研究蒐集臺鐵公司臺中工務段過往量測資料，分析列車行為模式對振動量測可能造成的影響，並經資料篩選和處理後，擇定單一月份振動量測資料做為深度學習長短期記憶模型(Long Short-Term Memory, LSTM)之訓練、測試資料集，再利用完成學習之模型預測後續月份之振動量測值，並藉由比較預測值和真實振動量測值之差值，利用現場查修資料瞭解差異原因，以推估振動量測和軌道幾何線形不整之關聯性，結果顯示，各月份振動量測在相同的車種、固定路線範圍且穩定速度行駛下有相近的振動模式，故藉由振動量測能反映軌道狀況，而 LSTM 亦可準確預測軌道振動量測值。

一、前言

軌道巡查是捍衛鐵路營運安全的重要任務，目前臺鐵公司軌道巡查工作主要是由道班人員於夜間營運列車停駛後，以徒步或使用工程維修車，透過人工目視方式進行軌道巡查作業，然而，此作業方式除了費時、費力外，亦伴隨著危險，而目前國外已有導入人工智慧(Artificial Intelligence, AI)於軌道巡檢工作之相關案例，透過圖像、影片、聲音及振動等資料進行各項軌道巡查之應用研究，並投入實地場域完成試驗後上線使用。另外，臺鐵公司規定每月須至少辦理 1 次營運列車行駛時之振動量測，並透過訂立標準值推估軌道幾何線形異常處，爰此，本研究利用量測資料結合深度學習技術，探討軌道幾何不整與振動量測之關聯性，期能提供更有效的檢測方法，藉以減輕道班人員現場工作頻率、降低作業安全意外發生機率，有效改善目視巡查盲點。本研究範圍為臺鐵公司臺中工務段所轄鐵道，將檢查人員針對其轄區軌道所進行之每月例行振動量測數據以及軌道查修紀錄為研究資料，並進行分析、篩選適用之資料範圍，再經資料處理後做為深度學習之訓練、驗證及測試資料集，接著交付 LSTM 預測振動值，藉由比較

預測值和真實量測值之差異處後，再利用查修資料去瞭解軌道真實幾何情形，以評估振動量測和軌道幾何不整之間的關聯性。

二、文獻回顧

Hiroataka Mori(2013)在列車車頭駕駛室內放置監測設備以蒐集振動加速度訊號，其透過加速度隨時間變化之均方根(Root Mean Square, RMS)值的大小來評估軌道幾何的不規則性，RMS 值較高處代表軌道狀況較差，並說明人為道碴補充或軌道維修後之 RMS 值有所下降。T.Real(2014)則以磁吸方式將加速度計安裝在列車車底轉向架上，利用蒐集之橫向振動加速度值估計軌道水平方向不平整，再運用其開發的軌道監測推車獲取之軌道幾何資料進行驗證，經比對後顯示有良好的一致性。Mai Odashima(2017)使用列車縱向加速度值估計軌道垂直向不規則性，利用其建立 6 個自由度列車車輛的數位模型，模擬現實車輛在不同速度的運動下的加速度，接著透過卡爾曼濾波器(Kalman Filter)估計軌道幾何，再與放置營運車廂之加速度儀實際測量值進行比較，結果顯示有良好的一致性。Hitoshi Tsunashima(2019)開發包含加速度儀及麥克風傳感設備之監測系統，並將加速度儀放置於列車車廂內，其定義時速 60 公里的列車行駛在長 1,000 公尺且幾何線型皆在正常值內的鐵軌所量測之車廂振動情形為基準，並將短時間內不同方向之加速度值進行均方根計算，再利用機器學習中的支持向量機(Support Vector Machine, SVM)進行訓練，用以判別軌道幾何是否有不平整的樣態。Shuai Ma(2019)提出結合卷積神經網路(Convolutional Neural Network, CNN)和 LSTM 的深度學習模型，預測高速鐵路列車車身的垂直和水平加速度值。Julia Niebling(2020)將聚類演算法(Clustering Algorithms)和深度學習的卷積自編碼器(Convolutional Auto-Encoder, CAE)結合，分析蒐集之列車加速度原始訊號進行訊號特徵擷取的成效。

三、名詞定義及研究方法

3.1 軌道幾何

交通部綜合規劃司(原技監室)發布之「1067mm 軌距軌道養護檢查規範(110 年 6 月 2 日修訂)」定義軌道幾何常見名詞如下：

1. 動態標準值：係以軌道檢查車檢測之軌道動態容許不整值。
2. 靜態標準值：係以人力檢測軌道在不受力狀態下之靜態容許不整值。
3. 軌距不整：軌距之基本尺寸為 1067mm，在曲線段須加寬，軌距不整量較基本尺寸大者為(+)，小者為(-)。
4. 水平不整：指左右鋼軌之高度差，以左側軌為基準，右側軌較高的場合為(+)，較低為(-)。
5. 高低不整：指鋼軌頂面縱方向之凹凸，以 10 公尺為範圍，鋼軌高凸狀態為(+)，低凹時為(-)。

6. 方向不整：指鋼軌側面沿軌距線縱方向之彎曲，以 10 公尺為範圍，向軌距外側之彎曲為 (+)，向軌距內側之彎曲為 (-)。
7. 平面性不整：表示軌道之平面歪扭狀態，係以近似固定軸距(4.6 公尺)以每 5 公尺間之水平不整代數差求之。相關示意如圖 1。




圖 1 軌道幾何不整示意圖

3.2 振動量測

臺鐵公司依「交通部臺灣鐵路管理局路線巡查安全作業程序(98 年 12 月 14 日修訂)」，規定各工務段每月至少辦理 1 次振動量測，以利用動態方式檢測轄區軌道幾何線形。振動量測方法是由工務段相關人員攜帶振動檢查儀乘坐營運中列車，並將其置於機車頭地板靠中心處(如圖 2)，振動檢查儀內含 GPS 接收器，可即時記錄哩程位置，以便確認振動異常發生位置後交由道班人員前往查看，如經過隧道段等無法接收 GPS 訊號的地點時，則改由檢查人員手動記錄哩程，振動檢查儀內建加速度規，可記錄列車行駛狀態之三軸向(X 軸、Y 軸、Z 軸)加速度值(如圖 3)，其單位為 gal (cm/sec^2)，X 軸代表前後(平行列車行駛方向)，Y 軸代表左右(垂直列車行駛方向)，Z 軸代表上下(垂直軌道)，此外，該檢查儀可一併記錄時間、列車速度、經緯度等資訊。

臺鐵公司振動量測規定係以某紀錄點之加速度值取平方並相加後開根號(此稱 RMS 值)，然而臺鐵公司認為 X 軸向加速度為平行列車車行方向，受加速及突然剎車影響甚大，較無法反映軌道幾何變化所反饋之振動，故 RMS 值僅納入 Y 軸向加速度值及 Z 軸向加速度值，如式(1)：

$$RMS = \sqrt{Y^2 + Z^2} \dots (1)$$

臺鐵公司認為 RMS 值 ≥ 70 gal 則可能有軌道幾何不平整的缺失發生，故檢查人員會將振動量測 RMS 值 ≥ 70 gal 的紀錄點位所在哩程數輸出，再交付軌道查修人員擇日至現場先進行靜態標準值之量測，若量測結果符合容許標準之範圍內則不予處置，反之，則依檢查結果進行處置作為(例如：吊起軌道並補充道碴)，最終完成列車振動檢查流程。



圖 2 振動檢查儀及振動量測過程




圖 3 振動檢查儀顯示介面及各軸向加速度值代表意義

3.3 LSTM

Sepp Hochreiter 和 Jürgen Schmidhuber(1997)提出一種遞迴神經網路(Recurrent Neural Networks, RNN)稱為 LSTM，常用於處理和時間有相關性之任務(即是現在的結果可能受過去因素所影響)，例如：自然語言處理(Natural Language Processing, NLP)、價格和數據預測等任務，而許多有關 LSTM 的變體亦隨之被提出，例如：Felix Gers 和 Jürgen Schmidhuber(2000)提出添加窺孔連接(Peephole Connections)的 LSTM、Cho (2014)發明門控循環單元(Gated Recurrent Unit, GRU)等等。

LSTM 模型中設有隱藏態(Hidden State)以及單元態(Cell State)，目的為儲存當前資料特徵，使未來的輸入可以共享該特徵後預測輸出，而隱藏態主要負責儲存短期的記憶，單元態則主要負責長期的記憶，此外，LSTM 中還加入了輸入閥(Input Gate)，遺忘閥(Forget Gate)和輸出閥(Output Gate)，輸入閥、遺忘閥作用在於決定原始輸入值需不需要被儲存及需要儲存多少，輸出閥作用在於決定何為需輸入給隱藏態的值。

LSTM 模型的一層主要會分成 4 個路徑，每條路徑皆乘載一完整向量，並且彼此間透過各種計算相互作用，首先，在遺忘閥的路徑會連同上一層隱藏態的輸出和輸入值一同被考量，在經過激發函數後輸出，如式(2)：

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \dots (2)$$

σ ：激發函數，使用 Sigmoid；

W_f ：代表與輸入值有關的權重矩陣(Weight Matrix)；

b_f ：代表與輸入值有關的偏誤(Bias)。

f_t 此時為 0~1 之間的數值，若 $f_t=0$ 代表不會記憶任何資訊； $f_t=1$ 則代表全部記憶，相同地，在輸入閥路徑上一層隱藏態的輸出 h_{t-1} 和輸入值 x_t 亦一同被考量，如式(3)：

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \dots (3)$$

輸入閥路徑的輸出會併同新值的路徑(激發函數使用 Tanh)輸出，如式(4)，與遺忘閥路徑的輸出共同決定是否需更新單元態，如式(5)，最後，在輸出層路徑會基於前述單元態之狀態決定輸出何者至下一層隱藏態，如式(6)和(7)。

$$N_t = \tanh(W_t \cdot [h_{t-1}, x_t] + b_t) \dots (4)$$

$$C_t = f_t * C_{t-1} + i_t * N_t \dots (5)$$

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \dots (6)$$

$$h_t = O_t * \tanh(C_t) \dots (7)$$

四、資料分析與處理

臺鐵公司臺中工務段考量其未來主力營運車種需求，從 2022 年 9 月開始使用 EMU3000 為每月放置 GPS 振動檢查儀進行振動量測之車種，此外，該工務段每月乘坐 EMU3000 進行振動量測之車行時間、路線(山線下行)皆固定，本研究認為該振動資料能對應該段路線的軌道幾何狀況並有利找出固定之行為模式。

爰此，本研究蒐集 EMU3000 從 2022 年 9 月至 2023 年 1 月山線下行共 6 次振動檢查儀所記錄之振動量測數據(9 月有進行兩次振動量測)，並將 Y 軸向加速度值及 Z 軸向加速度值分別輸出，以便能清楚分析列車上下以及左右方向之振動樣態，輸出資料為 csv 檔，其記錄的內容包含：(1)時間、(2)哩程數、(3)車行速度、(4)振動加速度絕對值、(5)振動相對於平均振幅之值、(6)經緯度座標(如圖 4)。

振動值大小排名	時間	里程	車行速度	加速度絕對值	相對平均振幅之值	經緯度座標	
Rank	Time	Km	kph	Abs mg	Rel to ave	Latitude	Longitude
128	11:43:02	117.461	101	35	2.1	N24 44.41'	E120 53.89'
559	11:43:03	118.682	103	19	1.2	N24 44.12'	E120 53.24'
877	11:43:04	117.517	102	14	0.9	N24 44.40'	E120 53.86'
51	11:43:05	118.739	102	42	2.5	N24 44.10'	E120 53.21'
478	11:43:06	117.574	102	21	1.3	N24 44.38'	E120 53.83'
291	11:43:08	117.631	102	27	1.6	N24 44.37'	E120 53.81'

圖 4 EMU3000 之振動量測原始輸出資料內容

首先比對 EMU3000 之停靠站資訊，臺中工務段振動量測路線內共有 6 個停靠站，由北至南分別為新竹、竹南、苗栗、豐原、臺中、彰化及員林，由量測人員攜帶 GPS 振動檢查儀自新竹站上車，並將其置於列車車頭地板靠中心位置，待列車速度始達穩定時啟動檢查儀，一直至經過員林站後關閉儀器並結束每月的振動量測，其站與站間概估之車行時間及大致距離如圖 5。




圖 5 EMU3000 山線下行振動測量路線範圍

然而，因為每月的振動量測為人員手動啟動及關閉檢查儀，導致開始和結束時間與哩程皆不固定，為了準確對應站與站間之路線範圍，以做更細部分析，本研究將每月振動量測原始資料與停靠站哩程、停等時間及列車速度等進行交叉比對，並藉以找出列車運行是否有固定之行為模式(例如：減速進站、長時間停靠、經過隧道段或彎道限速段.....等等)，基此，本研究設定篩選振動量測原始資料條件包含：

1. 停等時間過長處，用以切分站與站間的路段、號誌站(等待列車調度)。
2. 兩點哩程數在短時間內卻突然有巨大變化處，對應現地隧道段或中性區間(交流變電站供電區間，擔心突波發生而切掉儀器電源)。
3. 列車速度有變化處，用以判別進出站、彎道限速段、突發事件導致剎車等等。

經由上述條件篩選後，可發現列車部分狀況皆反映在固定哩程，並可從每個月振動量測數據中找出規律，首先，各車站的哩程皆為固定，由此可依站與站之間做每月份的振動量測值對應，列車進站前約 1 至 2 公里會開始放緩車速準備進站，到站後會有超過 30 秒以上的停等接載客，出站後則開始加速至時速 110 到 120 公里後穩定行駛，在苗栗站和豐原站範圍間(140.6K~179.1K)哩程約 143.6K~171.4K 有經過多座隧道，使哩程數因 GPS 斷訊導致長時間無變化或有哩程突然遽變的情形，此外，在哩程 175.2K 左右會進入中性區間，此時檢查人員會暫時關閉振動檢查儀避免突波造成儀器損害，直至通過 177K 左右再度開啟，臺中站到彰化站範圍間(193.3K~210.9K)，會行經曲線段，哩程約 203.6K~205.4K，此時因曲線限速車速將會放緩通過，在 206.2K 會抵達號誌站，此時可能會因應調度緣由降速或停等。本研究整理各月振動量測資料之哩程和行為模式對應如表 1。

表 1 EMU3000 車行路線哩程數和行為模式對應表

哩程 (K)	106.4	123.2 124.0	125.4	125.4 126.0	133.4	139.0 139.8	140.6	140.6 142.0
行為 模式	新竹站	減速準備 進站	竹南站	加速段	隧道段 (哩程長時間 無變化)	減速準備 進站	苗栗站	加速段
哩程 (K)	143.6	147.8	161.9	170.9 171.3	171.4	175.2 176.9	176.9 177.7	179.1
行為 模式	隧道段 (哩程長時間 無變化)	隧道段 (哩程長時間 無變化)	隧道段 (哩程長時間 無變化)	車速放緩 過站 (不停車)	隧道段 (哩程長時間 無變化)	中性區間 (關閉儀器 電源)	減速準備 進站	豐原站
哩程 (K)	191.4 191.8	193.3	193.3 195.2	203.5 205.4	206.2	208.2 209.0	210.9	-
行為 模式	減速準備 進站	臺中站	加速段	曲線段 限速 (車速低於 80km/h)	號誌站 (降速或停 等調度)	減速準備 進站	彰化站	-

另外，經檢視資料發現，若以列車行駛時速約 100km/hr 左右，大約每 2 秒記錄振動量測點一次，該點代表取樣瞬間該哩程對應的振動狀態，而列車速度減緩會導致 GPS 振動檢查儀的取樣點之間的時間被拉長，導致有長時間的振動值無變化產生，造成取樣過寬的狀況，故應考量行駛車速較為穩定之哩程範圍內的振動量測值，較能確保後續深度學習訓練的品質。

綜上分析，本研究選擇從車行範圍中再選擇取樣率較穩定的 4 個路段範圍，並將 Y 軸向加速度值及 Z 軸向加速度值分開探討，該路段範圍的哩程區間分別為：121.9~125.4K、126K~140.6K、143.6~161.5K、198~205.4K，並發現 4 個路段範圍中，不同月份的同一段區間，無論是 Y 軸向加速度或是 Z 軸向加速度隨時間之變化，其振動量測輸出之波形皆相近似。以 143.6~161.5K 範圍中 2022 年 9 月第 1 次振動量測波形(藍色)與其他月份振動量測波形(各顏色)比較之 Y 軸向加速度值與時間圖為例(如圖 6)，即可得知同樣車行路線下有相似之振動態樣。




圖 6 各月份間振動量測 Y 軸向加速度-時間波形圖比較

五、深度學習訓練與預測成果探討

5.1 學習資料集建立

依前章節取得 EMU3000 的振動量測資料並予以分析後，發現各月份間之振動型態相近，故應可利用 2022 年 9 月第 1 次振動量測 Y 軸向加速度資料，交付 LSTM 訓練後，用以預測後續月份的振動量測 Y 軸向加速度值，同樣，亦可利用 2022 年 9 月第 1 次振動量測 Z 軸向加速度資料，經 LSTM 訓練後預測後續月份的振動量測 Z 軸向加速度值(如圖 7)，並推斷其預測值應該會多數接近實際量測加速度值，而發生預測偏誤較大之處，可探究是否有發生軌道維修或其他可能改變軌道幾何線型的事件，進而導致模型預測失準。



圖 7 資料訓練、測試及預測流程示意圖

5.2 模型建構與預測成果

本研究利用 Python 的 Pandas 套件匯入 2022 年 9 月第 1 次振動量測資料 4 個路段範圍之加速度值，並將其轉為 Dataframes，再以 sklearn 套件中的 MinMaxScaler 模組，對資料進行正規化(將範圍限縮至 0~1)，接著將 80%Dataframes 內的資料當做訓練集(其中的 20%用作驗證)、剩下則為測試集，深度學習框架則使用 Python 之 Tensorflow 模組，整體架構主要以上面層兩個大小 128 和 64 及下面層兩個大小 64 和 128 總共四層之 LSTM 層組成，類似沙漏形狀的組合，並皆使用 ReLU 為激發函數，中間插入 RepeatVector，用於針對上層 LSTM 輸出的一維向量，並通過重複該輸入使其轉換成二維向量，以符合下層 LSTM 之輸入形狀，再利用 TimeDistributed 和 Dropout 減少參數量後輸入 Dense 層，另外，LSTM 模型之關鍵在於時間步長(Time Steps)的決定，即是告知模型要用第 N 筆資料來預測第 N+1 筆資料，經測試後發現時間步長訂為 7 能有較好的結果，並設定訓練 epochs 為 100，批次(Batch)大小為 64，損失函數(Loss Function)為平均絕對值誤差(Mean absolute error, MAE)，如公式(8)。

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \cdots (8)$$

為找出最低之 loss 值，本研究亦使用 EarlyStopping 模組功能，並設定在連續 15 個 epoch 內，驗證集的 loss 值未有下降趨勢時，則觸發模型停止訓練，監控指標模式設定為最小化，而

在獲得停止訓練當下之驗證集 loss 值後，會將其和歷史驗證集 loss 值進行比較，如果當前驗證集 loss 值較歷史 loss 值為大，則改使用過去所記錄之最小驗證集 loss 值，以下各別說明 Y 軸向及 Z 軸向加速度值訓練、測試及後續預測成果。

1. Y 軸向加速度

利用 2022 年 9 月 EMU3000 第 1 次振動量測之 Y 軸向加速度資料，並交付前揭建立好之 LSTM 訓練後，發現其在 epochs 為 91 時模型停止訓練，此時的訓練集 loss 值為 0.0167、驗證集 loss 值為 0.0163，再比較過去所記錄之最小驗證集 loss 值為 0.0148，結果顯示有良好的收斂且無過擬合現象(如圖 8)。




圖 8 Y 軸向加速度訓練集 loss 值和驗證集 loss 值比較圖

若將訓練資料進行預測(如圖 9 的橘色線段)和以測試資料進行預測(如圖 9 的綠色線段)，與原實際振動量測值(如圖 9 的藍色線段)進行繪圖比較，可發現多數點都能良好的擬合，惟在振動量測值較大的部分預測效果略顯不佳，本研究將測試集的預測值和實際值差異達 20% 的部分以上輸出，發現共有 12 個點預測值較實際值差異超過 20%，最高誤差來到 58%。

本研究利用該學習完的模型預測後續月份(2022 年 9 月第 2 次、10 月、11 月、12 月以及 2023 年 1 月)振動量測 Y 軸向加速度資料，並利用預測值和實際量測值進行對比，而發生預測偏誤較大之處(此處定義為預測結果和實際測量結果誤差大於 20%)，即是需要探究有發生何事件導致預測失準之哩程數所在。運用完成訓練之模型預測後續月份之振動量測 Y 軸加速度值的情況，彙整如表 2。




圖 9 利用訓練和測試資料預測 2022 年 9 月第 1 次振動量測 Y 軸向加速度值結果

表 2 LSTM 預測後續月份振動量測 Y 軸向加速度值的情況

振動量測月份	原始資料筆數	預測結果和實際測量結果誤差大於 20%筆數	比率
2022 年 9 月(第 2 次)	2795 筆	79 筆	2.82%
2022 年 10 月	2735 筆	65 筆	2.38%
2022 年 11 月	2665 筆	62 筆	2.32%
2022 年 12 月	2635 筆	42 筆	1.59%
2023 年 1 月	2710 筆	62 筆	2.29%

2. Z 軸向加速度

利用 2022 年 9 月 EMU3000 第一次振動量測 Z 軸向加速度資料，並交付前揭建立好之 LSTM 訓練後，發現其在 epochs 為 84 時模型停止訓練，此時訓練集 loss 值為 0.0245、驗證集 loss 值為 0.0194，再比較過去所記錄之最小驗證集 loss 值為 0.019，結果顯示有良好的收斂且無過擬合現象(如圖 10)。

若將訓練資料進行預測(如圖 11 的橘色線段)和以測試資料進行預測(如圖 11 的綠色線段)，與原實際振動量測值(如圖 11 的藍色線段)進行繪圖比較，可發現多數點都能良好的擬合，然而和 Y 軸向加速度一樣在振動量測值較大的部分預測效果略顯不佳，一樣將測試集的預測值和實際值差異達 20%的部分以上輸出，發現共有 6 個點預測值較實際值差異超過 20%，最高誤差來到 38%。




圖 10 Z 軸向加速度訓練集 loss 值和驗證集 loss 值比較圖




圖 11 利用訓練和測試資料預測 2022 年 9 月第 1 次振動量測 Z 軸向加速度值結果

同樣地，利用該學習完的模型預測後續月份(2022 年 9 月第 2 次、10 月、11 月、12 月以及 2023 年 1 月)振動量測 Z 軸向加速度資料，並利用預測值和實際量測值進行對比。利用訓練好的模型預測後續月份之振動量測 Z 軸向加速度值的情況，整理如表 3。

表 3 LSTM 預測後續月份振動量測 Z 軸向加速度值的情況

振動量測月份	原始資料筆數	預測結果和實際測量結果誤差大於 20%筆數	比率
2022 年 9 月(第 2 次)	2935 筆	64 筆	2.18%
2022 年 10 月	2885 筆	61 筆	2.11%
2022 年 11 月	2860 筆	58 筆	2.02%
2022 年 12 月	2810 筆	52 筆	1.85%
2023 年 1 月	2820 筆	63 筆	2.23%

經由上述預測結果和實際測量結果誤差大於 20%筆數，發現不管 Y 軸向或 Z 軸向加速度，經 LSTM 預測後表現最好的皆為 2022 年 12 月(Y 軸向 1.59%、Z 軸向 1.85%)。因本研究想探討振動量測預測值和實際值誤差較大的哩程，再經由人員相關維修處置後，對於後續月份是否產生變化，故找出相鄰月份間，振動量測相近哩程(設定範圍在 10 公尺內)有無出現前述預測結果和實際測量結果誤差大於 20%資料點位，經篩選出相近哩程數之 Y 軸向加速度點位資料如表 4，Z 軸向加速度哩程數資料如表 5。

表 4 Y 軸向加速度相鄰月份振動量測預測和實際結果誤差大於 20%所在哩程數

日期	2022/9 (2nd)	2022/10	2022/11	2022/12	2023/1
哩程數(K)				122.304	122.301
	126.032	126.030	126.029		
	126.130	126.122			
		127.311	127.308		
		129.802	129.781		
		130.317	130.312		
	131.359	131.354		131.350	131.348
		132.433	132.435		
	134.371	134.375			
		136.672	136.678		
	137.326	137.322			
	137.360	137.356			
	153.510	153.505			
	153.544	153.539			
			160.393	160.406	
			160.933	160.937	
				202.012	202.012
			202.372	202.380	
		202.432	202.436		
			202.467	202.472	
	203.474	203.481			
				205.167	205.168

表 5 Z 軸向加速度相鄰月份振動量測預測和實際結果誤差大於 20% 所在哩程數

日期	2022/9 (2nd)	2022/10	2022/11	2022/12	2023/1
哩程數(K)			124.984	124.984	
	126.592	126.595			
		130.317	130.312		
		130.500	130.500		
	132.075	132.073			
	132.108	132.105			
		136.397	136.392		
	137.225	137.220			
	137.292	137.288			
			147.554	147.564	
	147.633	147.633			
	147.899	147.901			
			148.823	148.820	
			148.857	148.854	148.857
		151.614	151.613		
	152.300	152.299	152.299		
			200.797	200.801	
			200.825	200.829	200.833
			201.858	201.866	
		201.912	201.918		

本研究利用取得軌道路線範圍內之相關維修資料，並使用它與預測結果和實際測量結果誤差大於 20% 的哩程數進行相互比較及間接驗證，發現共有以下 3 處哩程經維修後，後續月份同哩程處的振動量測值，其預測結果和實際測量結果收斂至 20% 以內。

1. Y 軸向加速度在軌道哩程 131.35K 左右，於 2022 年 9 月第 2 次振動量測和 10 月振動量測發現，預測結果和實際測量結果誤差大於 20%，然而在經 10 月中旬的砸道整修後，後續月份即無發現同哩程附近有預測結果和實際測量結果誤差大於 20% 的情形。
2. Y 軸向加速度在軌道哩程 203.48K 左右，於 2022 年 11 月振動量測和 12 月振動量測發現，預測結果和實際測量結果誤差大於 20%，然而在經 12 月中旬砸道整修後，後續月份即無發現同哩程附近有預測結果和實際測量結果誤差大於 20% 的情形。
3. Z 軸向加速度在軌道哩程 151.61K 左右，於 2022 年 10 月振動量測和 11 月振動量測發現，預測結果和實際測量結果誤差大於 20%，然而在經 11 月中旬人工起道、砸道後，後續月份即無發現同哩程附近有預測結果和實際測量結果誤差大於 20% 的情形。

六、結論與建議

本研究蒐集臺鐵公司臺中工務段的振動量測資料，經資料篩選和處理後，選擇 EMU3000 振動量測資料為深度學習 LSTM 之訓練、測試資料集，再使用完成學習之模型預測後續月份之振動量測值，並藉由比較預測值和真實量測值之差值，利用現場查修資料瞭解差異原因，以推估振動量測和軌道幾何不整之間的關聯性，並獲得以下結論與建議：

6.1 結論

1. 各月份振動量測比較結果顯示，一段列車以穩定速度行駛且相同的路線範圍內出現的振動模式相近似，故振動量測能反映軌道狀況。
2. 本研究利用深度學習之 LSTM 進行固定區間軌道振動量測的加速度值預測，結果顯示多數可準確的進行預測，惟在加速度振幅值較劇烈處，容易預測失準。

6.2 建議

1. 本研究採固定車種(EMU3000)並以固定的路線區段所得之振動量測資料進行分析，然而該振動值尚受許多因素影響，建議後續可針對各種可能對振動量測造成影響的因素進行研究並提出方法予以屏除，以真實反映軌道幾何線型不平整所反饋之振動，應可得到較好的結果。
2. 臺鐵公司訂定列車振動量測之標準值($RMS \geq 70gal$)，然而，因軌道屬封閉場域，本研究無法就 LSTM 預測失準處一一至現場複查並和原標準值比較是否有因此降低誤報率，僅能利用後續維修資料進行間接驗證。建議後續若有現場巡軌的機會，可考慮利用本方法或其他科學化、數據化方式，針對不同車種訂出適用之振動量測標準值。
3. 本研究使用 EMU3000 自 2022 年 9 月至 2023 年 1 月共 6 次振動量測數據為主要分析資料，惟資料數量可能略嫌不足。建議後續可針對資料持續蒐集，以強化模型學習、降低誤差。
4. 經資料解析後發現，若是以列車速度 100km/hr 左右穩定行駛時，GPS 振動檢查儀約 1 至 2 秒取樣一點，故每一個振動值約是軌道 25 至 50 公尺範圍內的瞬間狀態，然而在列車車速慢下來時，可能會長達 5 至 10 秒才取樣一點，若以精準度而言，取樣尺度似乎過寬，不利於從該資料中獲取細緻振動情形，亦導致要對應軌道幾何不整缺失發生之哩程點有困難。建議後續若要利用振動做更詳細的研究時，可考量額外安裝精度較高、取樣範圍較準的儀器進行分析較有助益。

參考文獻

1. Mori, H., Sato, Y., Ohno, H., Tsunashima, H., & Saito, Y. (2013). Development of Compact Size Onboard Device for Condition Monitoring of Railway Tracks. *Journal of Mechanical Systems for Transportation and Logistics*, 6(2), 142–149.
2. T. Real, J. Montrós, Montalbán-domingo, L., Zamorano, C., & J.I. Real. (2014). Design and Validation of a Railway Inspection System to Detect Lateral Track Geometry Defects Based on Axle-Box Accelerations Registered from in-Service Trains. *Journal of Vibroengineering*, 16(1), 210–224.
3. Odashima, M., Azami, S., Naganuma, Y., Mori, H., & Tsunashima, H. (2017). Track Geometry Estimation of a Conventional Railway from Car-Body Acceleration Measurement. *Mechanical Engineering Journal*, 4(1), 1–12.
4. Tsunashima, H. (2019). Condition Monitoring of Railway Tracks from Car-Body Vibration Using a Machine Learning Technique. *Applied Sciences*, 9(13), 1–13.
5. Ma, Shuai, Gao, Liang, Liu, Xiubo, & Lin, Jing. (2019). Deep Learning for Track Quality Evaluation of High-Speed Railway Based on Vehicle-Body Vibration Prediction. *IEEE Access*, 7, 185099–185107.
6. Niebling, J., Baasch, B., & Kruspe, A. (2020). Analysis of Railway Track Irregularities with Convolutional Autoencoders and Clustering Algorithms. *Communications in Computer and Information Science*, 1279, 78–89.
7. 交通部技監室，「1067 公厘軌距軌道橋隧檢查養護規範」(110 年 6 月 2 日修訂)。
8. 交通部臺灣鐵路管理局，「交通部臺灣鐵路管理局路線巡查安全作業程序」(98 年 12 月 14 日修訂)。
9. McCulloch, W. S., & Pitts, W. (1943). A Logical Calculus of the Ideas Immanent in Nervous Activity. *The Bulletin of Mathematical Biophysics*, 5, 115–133.
10. Rosenblatt, F. (1958). The Perceptron a Probabilistic Model for Information Storage and Organization in the Brain. *Psychological Review*, 65(6), 386–408.
11. Werbos, P. (1974). Beyond Regression New Tools for Prediction and Analysis in the Behavioral Science. Thesis(Ph. D.)--Harvard University.
12. Y. Lecun, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard, & L. D. Jackel. (1989). Backpropagation Applied to Handwritten Zip Code Recognition. *Neural Computation*, 1(4), 541–551.
13. Hochreiter, S., & Schmidhuber, J. (1997). LONG SHORT-TERM MEMORY. *Neural Computation*, 9(8), 1735–1780.
14. Gers, F., & Schmidhuber, J. (2000). Recurrent Nets That Time and Count. *IEEE-INNS-ENNS International Joint Conference*, 3.
15. Cho, K., Merriënboer, Bart Van, Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Yoshua. (2014). Learning Phrase Representations Using RNN Encoder-Decoder for Statistical Machine Translation. *Empirical Methods in Natural Language Processing (EMNLP)*, 1724–1734.