

人工智慧模型應用於離岸風電 CPT 數據異常檢測

許景瀚 國立臺灣科技大學營建工程系/碩士生 李安叡 國立臺灣科技大學營建工程系/教授 陳立軒 萬鼎工程公司/工程師 江承家 萬鼎工程公司/大地技師

摘要

近年來,台灣積極推動離岸風電的開發,對於海底基礎設計之安全與效益有更嚴謹的要求。圓錐 貫入試驗(Cone Penetration Test, CPT)因具備高效率與連續量測優勢,被廣泛應用於海域土層調查。 然而,受到儀器狀態、海床環境變動及施工操作等因素常導致數據出現各種異常值(outliers),進而影響土層判釋與基礎設計。傳統依賴人工或簡單統計方法篩選異常,在面對數十口鑽孔與數萬筆記錄時,不僅耗時,更難以保證一致性。

本研究針對 CPT 量測資料,結合多尺度卷積神經網路與雙向長短期記憶網路(Long Short-Term Memory, LSTM),以建立自動化的異常偵測機制。首先對 CPT 原始數據進行前處理(包含標記整 合、缺失值補足及資料標準化),透過多尺度卷積層提取局部與全局特徵,再利用雙向 LSTM 捕捉時 間序列中的長期依賴性,最後經融合分類層進行二分類判斷。研究結果顯示,在辨識多種潛藏或非 典型異常方面表現良好,可作為離岸風電土層調查的輔助工具,提升地質參數的可信度及後續工程 設計的安全性。

此外,該技術為離岸風電基礎設計、荷載分析與數值模擬提供了更穩健的數據支援,並展現出與 即時監測、預警系統及多源數據融合整合的應用潛力。

一、前言

台灣近年來積極推動離岸風電發展,目前 已進入第三階段的大規模開發。然而,海域環 境的複雜性與不確定性,使得風力機組基礎設 計必須依賴詳細且可靠的地層資訊進行評估。 在離岸風電場場址調查中,圓錐貫入試驗 (Cone Penetration Test, CPT)因具備高效率、 連續量測能力與直接獲取地層參數的優勢,成 為國際間廣泛應用的地質勘測技術。但隨著鑽 探深度、海床條件與操作因素的多元化,CPT 數據在測試過程中常出現異常值(如數值偏 高、偏低或波動劇烈),若未能及時辨識並剔 除,將可能影響後續土層判釋與基礎設計,甚 至引發工程安全隱患。 傳統上,工程師多以人工判讀或利用簡單統計方法來識別潛在異常值。然而,離岸風電場常涉及數十口鑽孔及數萬筆 CPT 記錄,手動 判讀不僅耗時,更難以確保判斷的一致性與準 確性。此外,一些非典型異常(如局部硬層存 在或鑽桿加長過程中引起的高值飆升)可能未 超出傳統設定的「容許範圍」,進而難以察覺。 因此,如何有效且自動化地檢測與剔除 CPT 異 常數據,成為大地工程與風電產業亟待解決的 重要挑戰。

近年來,人工智慧(Artificial Intelligence, AI)與機器學習(Machine Learning)技術在地 質與大地工程領域逐步崛起。其中,長短期記憶 網路(Long Short-Term Memory, LSTM)因其在 處理時間序列資料與捕捉長期依賴關係上的優 勢,受到廣泛關注。LSTM模型能夠學習深度與 貫入阻力、摩擦阻力及孔隙水壓等測量值之間的 複雜關聯,自動識別出不易察覺的異常模式。若 能將LSTM模型成功導入CPT異常值檢測,不 僅可大幅降低人工審核的工作量,亦能提升數據 篩選的準確性與穩定性,進一步確保地層剖面資 料的可靠性。這對於離岸風電基礎設計、荷載分 析及數值模擬(如PLAXIS 3D模擬)等環節均 具備顯著助益。

二、CPT 數據與異常成因

2.1 背景

圓錐貫入試驗(Cone Penetration Test, CPT) 在離岸風電場環境中,通常同時量測錐尖阻抗 (Cone Resistance)、局部摩擦(Friction Resistance) 與孔隙水壓(Pore Water Pressure)這三項主要參 數(參見圖1)。

這些量測值可幫助工程師瞭解海床土層的 強度與滲透特性,並進一步評估風機基礎的設計 需求。然而,由於施工方式與海域環境等因素干 擾,CPT 數據時常出現各類異常值。 人工智慧模型應用於離岸風電 CPT 數據異常檢測



圖 1 三項量測參數的概念示意

2.2 常見異常類型

(1) 清孔效應

在 CPT 鑽探過程中,工程人員為進行儀器校正或保養,往往會暫停推進並重新開始量測, 導致錐尖阻力、局部摩擦與孔隙水壓在重新啟動時出現明顯跳躍或歸零現象(CPT-Guide-6th-Edition-2016)。若後處理時未剔除或調整,可能 誤判地層突然變硬或變軟。

(2) 鑽桿加長效應

在多階段鑽探中,鑽桿逐步加長會改變探 頭與地層之間的力學傳遞。將造成錐尖阻力、局 部摩擦或孔隙水壓的局部跳變或飆升,而若未在 後處理階段明確識別與修正,可能把加長效應誤 解成地層的真實突變。

(3) 硬質地層的影響

當 CPT 探頭遇到局部硬土層、礫石或岩塊 時,錐尖阻力(Cone Resistance)往往會呈現出 極端高值;相反,在鬆軟土層中,則可能顯示偏 低 Lunne *et al.* [2]。硬質地層引起的異常數據既 可能反映出地層的不均匀性,也可能是由探頭與 硬質物質碰撞後瞬間反饋造成的。

2.3 異常值對後續影響與風險

CPT 數據中的異常值,若未能及時剔除或 校正,將直接影響土層分層的精度及基礎參數的 估算,進而對工程設計產生重大影響。



異常數據可能導致對基礎承載力的評估出 現顯著偏差:

- 基礎承載力評估偏差:過高的阻力值可能使 工程師誤判土層具備更高承載力,而過低的 數據則會導致設計過於保守,進而影響風機 基樁設計。
- 工程風險與成本增加:過於保守的設計參數
 不僅會增加施工材料費用與工期,同時也提
 高了工程整體風險。精確識別並修正異常數
 據是降低工程風險與成本的重要前提。

綜合上述可見現有方法在識別 CPT 數據異常 方面仍存在不足,尤其是在大規模離岸風電場環 境下,傳統人工及簡單統計方法難以保證數據處 理的一致性與準確性。這使得利用人工智慧技術 來進行自動化異常檢測成為解決該問題的潛在方 向,亦為本研究後續工作奠定了堅實的理論基礎。

三、訓練資料前處理

在進行深度學習模型之訓練前,必須先對原 始圓錐貫入試驗(Cone Penetration Test, CPT)量 測資料進行整理與清洗。本研究之離岸風電 CPT 量測作業中,探頭每推進2公分即自動記錄一次 量測結果,包括錐尖阻力(Cone Resistance)、局 部摩擦(Local Friction)與孔隙水壓(Pore Pressure)等三項參數。圖2為資料的範例,每 一列對應一個量測深度。經過初步蒐集後,所有 量測數據會依序進行前處理(包含人工標記異常 值整合、缺失值處理、以及資料庫分割),以確 保後續模型訓練與評估更具精準度與穩定性。

	А	В	С	D				
1	Test length[1]	Cone resistance[2]	Local friction[3]	Pore pressure u2[6]				
2	0.02	0.2110057	0.000679028	0.001040422				
3	0.04	0.2336001	0.000752194	0.000240535				
4	0.06	0.2802345	0.000972212	-0.001458868				
5	0.08	0.3253186	0.00107046	-0.000556505				
6	0.1	0.3764363	0.002070483	-0.001743525				
7	0.12	0.3664641	0.001977563	0.001172788				
8	0.14	0.3999211	0.002435143	-0.002080844				
9	0.16	0.4100189	0.002489076	6.40479E-05				
10	0.18	0.4123757	0.002145858	-0.000293197				
11	0.2	0.3977	0.002019799	0.00711216				

圖 2 CPT 數據示意圖

3.1 人工標記異常值處理

在離岸風電 CPT 量測作業後,工程師透 過 '*' 符號將疑似異常的測點或深度位置記錄 下來,如圖3所示。此類異常通常由各種非穩 定因素造成,例如:

- 施工暫停與清孔:重新開鑽時可能導致錐尖
 阻力或孔隙壓力瞬時跳躍;
- 鑽桿加長或接頭鬆脫:機械操作造成間歇性
 的數據偏離;
- 硬層或礫石含量突變:引發極端高值,明顯 高於鄰近土層分布。

將上述標記整合用於後續的模型訓練,研 究採用以下步驟:

1. 人工標記去除與轉換

若該筆資料含有人工標記,則於數據中賦 予1(表示異常),否則為0(表示正常)。

2. 異常標籤

數據隨後成為監督式學習的真實標籤,使 得後續模型能夠學習「人為判定」的異常模式, 對潛在不穩定測值進行自動化判讀,如**圖3**。



圖 3 CPT 數據的結構和異常點的分布

3.2 缺失值處理

由於海域環境複雜及儀器操作可能暫停, CPT 紀錄中偶爾會產生缺失值。若未處理,模型 可能在讀取序列時產生錯誤或引入不合理的中 斷。本研究採用以下策略:

1. 線性插值(Linear Interpolation)

線性插值是一種常見的數值方法,用於填 補相鄰測點之間的缺失數據,確保土層性質隨 深度變化的連續性。在地質與土壤力學分析 中,維持測試數據的平滑性有助於提高模型計 算的準確度。

2. 前後值填補

當數據序列的開頭或末端存在缺失值時, 線性插值無法補足這些數據。因此,使用前向填 補與後向填補方法,以最近的有效值延伸填充缺 失數據,確保深度數據完整且不影響模型計算。

3. 缺失數據標記

為使模型能夠識別人工填補的數據,本研 究在填補後增加異常標記(Missing Flag)。凡經 過線性插值或前後填補的數據,均標記為1,原 始測值則標記為0。這樣,模型在學習時能區分 填補數據與實測數據,並避免將填補值誤認為真 實測量結果。

標記方式為原始測值標記為 0,插值/填補 值標記為 1 讀取成異常值。

經此處理,不但保留了測試深度的實際分 布,也減少空值影響模型訓練的可用樣本量。

3.3 資料集分割

為了評估模型在不同階段的學習及泛化能力,本研究依照常見做法,將收集到的CPT 資料 集依 7:1:2 的比例拆分為「訓練集(Train)」、「驗 證集(Validation)」與「測試集(Test)」三部分。

- 1. Train (70%):提供模型主要的學習樣本;模型於此資料上反覆更新參數以降低預測誤差。
- Validation (10%): 用於調整超參數 (hyperparameters)並監控是否發生過度擬合 (overfitting),亦可輔助早期停頓(early stopping)策略的判斷。
- 3. Test (20%):最終評估模型在未見資料上的 泛化能力,確保研究結果的客觀性與可信度。

人工智慧模型應用於離岸風電 CPT 數據異常檢測

如此分割方式符合大多數深度學習應用的 最佳實務,亦能維持訓練效率與評估嚴謹度間的 平衡。

四、LSTM 理論與應用

4.1 LSTM 理論基礎

4.1.1 RNN 面臨的挑戰

傳統全連接神經網路(Feedforward Neural Network)在處理時間序列數據時,無法捕捉各時間步之間的依賴關係,導致模型難以反映數據的動態變化。為解決此問題,循環神經網路(RNN)引入隱藏狀態,使得前一時刻的資訊可以傳遞到後續時間步。然而,Bengio et al. 指出[3],當序列過長或包含複雜長期依賴時,RNN由於梯度消失或梯度爆炸問題而難以學習有效特徵,這使其在實際工程應用中表現不佳。

4.1.2 LSTM 的創新與閘門機制

針對 RNN 的不足, Hochreiter 與 Schmidhuber 於 1997 年提出了 LSTM 模型 [4]。LSTM 引入了 細胞狀態與多重閘門(遺忘閘、輸入閘、輸出 閘),以靈活控制資訊的保留與更新,從而有效 防止長距離傳遞過程中關鍵資訊的丟失。尤其 是遺忘閘,使模型能根據當前輸入與過往記憶 自動調整資訊保留比例,從而使得模型在面對 長序列數據時仍能保持穩定擬合效果。此外, 為進一步提升模型對序列上下文的捕捉能力, 本研究採用雙向 LSTM,從正向與反向同時學習 數據特徵,以彌補單向結構在提取隱藏依賴性 時可能的不足。

4.1.3 LSTM 與 CPT 異常偵測關係

離岸風電 CPT 測試數據在深度方向上連續 記錄錐尖阻力、局部摩擦與孔隙水壓,但由於環 境變化、儀器不穩與地層不均的影響,數據中常 混雜雜訊與異常值。傳統統計方法或基本機器學 習技術往往無法有效捕捉這些非典型異常,而 LSTM 擁有強大的時序學習與長期依賴捕捉能

大地夜狮 第30期 35



力,可結合前後趨勢進行更精確的異常判斷。當 某一測點出現異常時,雙向 LSTM 可利用正反 向信息更全面地反映內在關聯性,從而顯著提高 檢測準確率 [5]。

4.2 模型架構設計與參數設定

混合模型由三大模組構成:多尺度 CNN 層、雙向 LSTM 層以及融合分類層,各部分設 計均基於 CPT 數據的實際特點與工程需求,如 圖 4。

4.2.1 多尺度卷積層

為捕捉 CPT 數據中不同尺度的局部特徵, 本研究採用多組卷積層,卷積核尺寸分別為3、 5與7個連續點的範圍。

- 卷積核尺寸:尺寸3 對局部細微變化敏感, 而尺寸7有助於抽取較大範圍的結構性趨 勢。多尺度設計使得模型在局部與全局特徵 提取間達到平衡,但若卷積核過大則可能引 入噪聲與計算負擔[6]。
- 濾波器數量:每層濾波器數量設定在 64 個, 既能充分反映數據豐富性,又避免過多參數導 致過擬合與資源浪費。這一設計經過反覆實驗 調整,以確保模型的表達能力與運算效率。

4.2.2 雙向 LSTM 層

經過多尺度卷積層後,特徵經由雙向 LSTM 層進行時序依賴學習。

- LSTM 單元數量:本研究選擇中等規模的單 元數量(128 單元),既能捕捉數據中隱含的 長期依賴,又避免因過多單元而增加模型複 雜度與運算成本。
- 激活與正則化:採用 ReLU 激活函數與 L2 正 則化,以確保學習過程穩定並防止數值波 動,同時維持模型的良好性能。

4.2.3 融合與分類層

在 LSTM 層之後,全連接層進行特徵融合 與分類決策。

- 全連接層與 Dropout: 全連接層將高維時序特 徵進一步整合,並引入適中比例的 Dropout 以防止過擬合。若 Dropout 過高則可能損失 有用資訊;過低則無法抑制過擬合。
- 輸出層與損失函數:輸出層採用 Sigmoid 激 活函數,輸出異常檢測概率。為解決 CPT 資 料中類別不平衡問題,使用自定義 Focal Loss,其參數 γ 與 α 需在提高難分類樣本識 別與兼顧正常樣本資訊間取得平衡。

4.3 模型設計總結與應用

本模型結合多尺度卷積神經網路(CNN) 與雙向長短期記憶網路(BiLSTM),以提高離 岸風電 CPT 數據的異常檢測能力。多尺度 CNN 透過不同大小的卷積核提取局部與全局特 徵, 強化模型對異常模式的識別能力。 BiLSTM 則利用雙向結構捕捉時間序列的長期



依賴,提升對數據變化趨勢的理解。最終,融 合層將 CNN 和 BiLSTM 的特徵綜合,確保模 型在高噪音與非典型異常條件下仍能保持穩定 性與準確性。

模型設計基於離岸風電 CPT 數據的特性, 並參考 Hochreiter & Schmidhuber、Malhotra et al.、Goodfellow et al. 等人的研究成果進行優化 [4.5.7]。結果顯示,該方法能有效識別異常數 據,提升檢測準確率與穩健性,為離岸風電地基 工程提供可靠的數據分析支援。

5.1 模型概要與訓練配置

本研究所提出之 CMC LSTM 模型結合了多 尺度卷積層(與雙向LSTM(Bidirectional LSTM), 並在後端透過全連接層(Dense Laver)輸出二分 類結果。表1統整了模型的主要結構與參數量, 顯示總參數量約 350.017。該模型良好平衡。為 解決異常樣本相對稀少的問題,本研究結合了類 別權重調整與 Focal Loss 策略,以提升模型對於 難分類樣本的學習效果。

表1 CMC_LSTM 模型結構與參數

層級	組件	設定	
總參數量		350,017	
類別權重調整		{0: 0.5659, 1: 12.8772}	
輸入層	Input	維度: (None, 20, 4)	
多口府举建网	Conv1D(三組)	Filters = 64 · Kernel Sizes = [3,5,7] · Activation = ReLU	
多八度仓惧層	批次正規化	加速訓練並提高模型穩定性	
	最大池化	用於降維並提取關鍵特徵	
雙向 LSTM 層	BiLSTM	Units = 128,雙向合併後輸出維度 = 256	
全連接層	Dense Dropout	神經元數=64、防止過擬合	

5.2 訓練過程與收斂情形

本研究透過早期停頓(EarlyStopping, patience = 5) 與模型檢查點機制,於驗證集損失 表現自動儲存最佳模型權重,從而有效避免過長 訓練後的過擬合與性能退化。圖5展示了模型在 30 個 Epoch 中的訓練損失與驗證損失變化情 形,主要觀察點包括:



人工智慧模型應用於離岸風電 CPT 數據異常檢測



圖 5 CMC LSTM 的訓練與驗證損失

- 1. 初期損失快速下降:在前5個 epoch 中,模 型對基礎特徵有初步掌握,驗證損失由 0.0875 逐漸下降至約 0.0694。
- 2. 中後期持續優化: 隨著 epoch 增加, 模型逐 步修正權重,最終在第 30 個 epoch 達到最小 驗證損失約 0.0419, 顯示整體收斂良好。
- 3. 訓練與驗證損失趨勢一致: 在全程訓練過程 中並未出現嚴重的過擬合或震盪現象,說明 採用 Focal Loss 與適度的 Dropout/L2 正則化 能維持模型穩定性。

5.3 閾值動態搜尋

為了兼顧精確率與召回率的平衡,本研究 在驗證集上針對不同閾值進行 F1-Score 的動態 搜尋,最終選擇閾值約0.58 作為判斷異常的標 準。此閾值可在防止誤報與避免漏報之間取得相 對穩定的折衷。

5.4 指標評估(Metrics)

為全面評估模型在異常偵測任務中的性 能,研究同時採用了以下指標:

- 正確率: 衡量模型整體預測正確率。
- 精確率:重視模型判定為異常時的準確性, 對工程中避免誤報至關重要。
- 召回率: 反映模型檢出所有真實異常的能 力,特別適用於安全監控場景。

大地板师 第30期 37



- F1 分數:綜合 Precision 與 Recall 的調和平均,能較全面反映模型性能。
- AUC:衡量模型在不同閾值下區分異常與正 常樣本的能力,AUC 越接近1表示區分效果 越好。

5.5 測試集評估結果

在測試集階段,CMC_LSTM 模型於閾值= 0.58下獲得以下主要指標,如表2。

混淆矩陣顯示模型對正常與異常樣本皆有 不錯的判別能力,其中對異常類別的召回率達到 七成以上,仍有進一步優化空間。然而整體曲線 下面積(AUC)高達 0.93以上,意味著在不同 判斷閾值下仍能維持良好的區分度。此結果也反 映出多尺度卷積架構與雙向LSTM協同學習, 能有效提取CPT數據中的深層特徵與序列依賴 性,大幅提升了異常偵測的精準度,圖6為測試 集中人工標記異常(左)與模型預測異常(右) 的比較示意圖。

表 2 CMC_LSTM 模型評估指標

正確率	精確率	召回率	F1 分數	AUC
0.9391	0.7647	0.7297	0.7468	0.9368

5.6 結果討論

- 高 AUC 表現:模型在不同閾值下均具備良好的異常/正常區分能力,對於工程應用可根據需求調整閾值。若更重視安全性,可提高 Recall(即降低閾值),但需容忍較高的誤報率。
- 2. **召回率與精確率平衡**:F1-Score 為 0.7468, 顯示本研究透過 Focal Loss 與權重調整在平 衡 Precision 與 Recall 上取得不錯的效果;但 若未來應用於極端安全場景,仍可再行優化 以提高 Recall。
- 3. 多尺度 CNN 與雙向 LSTM 結合:實驗結 果佐證了多尺度卷積對局部特徵的敏銳捕 捉,以及雙向 LSTM 在跨深度依賴學習上 的優勢,兩者結合在離岸風電 CPT 資料的 高雜訊情境下,能降低模型對異常樣本的 漏判。
- 後續改進方向:若需要進一步提升異常檢出率,可考慮擴充資料量、調整序列長度、加入更多特徵(如施工暫停或儀器加長的記錄)或採用多層 LSTM 結構;同時也需兼顧模型複雜度與計算資源的限制。



六、結論與建議

6.1 結論

本研究針對離岸風電場中 CPT 數據所面臨 的異常問題,提出一套結合多尺度卷積神經網路 與雙向 LSTM 的自動異常偵測方法。整個流程 從數據前處理、缺失值補全到人工標記異常點, 再到模型架構設計與參數調校,都力圖降低人為 誤差,並提高工程應用時的數據可信度。經過實 驗評估,模型在高雜訊環境下仍能精準辨識由施 工操作、鑽桿加長效應及地層變異等因素引發的 異常數據,主要指標如 AUC 超過 0.93、F1-Score 約 0.75,均顯示出不錯的辨識效果。與傳 統人工判讀及單純統計方法相比,此方法不僅大 幅減少了現場人力成本,亦能在關鍵時刻提供可 靠的數據參考,為離岸風電基礎設計提升效率的 技術基礎。

6.2 建議

為進一步推動本研究成果在實際工程中的 應用,並提升異常偵測技術的整體效能,未來可 以從以下幾個方向進行:

1. 即時監測與預警系統整合

考慮到本模型具備自動化與即時預測的潛 力,建議將其與現場監測系統無縫整合。一旦偵 測到異常數據,系統可立即發出警示,使工程師 得以及時介入檢核,有效降低因數據異常而導致 的施工風險與後續維修成本。

2. 多源數據融合

除了 CPT 數據外,離岸風電場同時還涉及 地震波探勘、聲納掃描、風浪流量測等多種監測 數據。未來可考慮將本方法擴展到多源數據的融 合應用,或引入更多外部環境特徵(如水深、海 床地貌等),以進一步提升異常偵測的準確度及 模型對環境變化的適應性。

3. 與基礎設計軟體的結合

在離岸風電基礎設計階段,常依賴數值分

人工智慧模型應用於離岸風電 CPT 數據異常檢測

析軟體(如 PLAXIS 3D)進行地盤與結構互動 模擬。建議未來將自動化異常檢測所得的 CPT 結果與這些設計軟體整合,使工程師能在設計初 期就針對可能出現的異常狀況採取對策,從而提 高設計參數的可靠性與工程安全性。

此外,還能進一步擴充數據庫,進行跨區 域與不同施工條件下的模型驗證,並探索加入其 他輔助參數(如設備運作狀況、現場環境監控資 料)優化模型結構與演算法。透過跨領域合作, 不僅能更深入理解 CPT 數據中異常產生的機 制,也有助於構建一套更完整、穩健的離岸風電 數據監控與預警系統。

參考文獻

- Robertson, P. K. (2016). Guide to Cone Penetration Testing for Geotechnical Engineering (6th ed.). Gregg Drilling & Testing, Inc.
- Lunne, T., Robertson, P. K., and Powell, J. J. M. (1997). Cone Penetration Testing in Geotechnical Practice. John Wiley & Sons.
- Bengio, Y., Simard, P., and Frasconi, P. (1994). Learning long-term dependencies with gradient descent is difficult. IEEE Transactions on Neural Networks.
- Hochreiter, S., and Schmidhuber, J. (1997). Long short-term memory. Neural Computation.
- Malhotra, P., Vig, L., Shroff, G., and Agarwal, P. (2015). Long Short Term Memory Networks for Anomaly Detection in Time Series. In Proceedings of the 23rd European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning (ESANN).
- Lu, Y.-X., Jin, X.-B., Liu, D.-J., Zhang, X.-C., and Geng, G.-G. (2023). Anomaly detection using multiscale C-LSTM for univariate time-series. Security and Communication Networks, 2023.
- Goodfellow, I., Bengio, Y., and Courville, A.
 (2016). Deep Learning. MIT Press.

大地板师第30期 39