

應用長短期記憶網路(LSTM)於海岸異常波浪 機率預警之研究

陳威成¹ 張芹瑜¹ 陳盈智¹ 林芳如² 朱啟豪² 董東璟¹ 蔡政翰³

¹國立成功大學 水利及海洋工程學系 ²交通部中央氣象署 海象氣候組

³國立臺灣海洋大學 海洋環境資訊系

前言與研究目的

海岸瘋狗浪(Coastal Freak Wave)

- 海岸瘋狗浪尚無明確定義，只要是在海岸邊激起的巨浪並足以將人沖倒，就可稱為海岸瘋狗浪
- 發生時機可分為兩種類型：
 1. 天氣不佳不斷有大浪襲擊岸邊或礁岩
 2. 在風平浪靜或僅有微風的天氣，突然激起大浪將人捲入海中
- 中央氣象署(2019)統計台灣2000至2019年共發生360件合計589人落海

海岸瘋狗浪的形成機制複雜，尚未有理論可完整解釋

➔難以預測何時何地會發生

人工智慧方法(artificial intelligent, AI)

近年來因電腦硬體與技術增強，**利用AI分析複雜的自然現象之研究層出不窮**



圖片來源：三立新聞網



圖片來源：TVBS NEWS



研究目的

海岸瘋狗浪發生機制複雜且難預警其發生時間，而近幾年已證實人工智慧技術能被成功運用

- 海岸瘋狗浪其發生的前兆與一定時間內的海氣象變化有關，**本研究將利用具有時序列處理能力的長短期記憶網路(Long Short-Term Memory, LSTM)建置海岸瘋狗浪預測模型，並與其他不具備時序列分析功能的方法進行比較(類神經網路、隨機森林與支撐向量機)**



研究區域與資料

研究區域

- 本研究的主要研究區域為**新北市貢寮區龍洞海岸之龍洞灣岬**

龍洞灣岬左側臨山，右側臨海，因長期海蝕作用，形成懸崖陡峭的地形

位於台灣東北海岸，易受**東北季風**的影響，經常會出現海岸瘋狗浪



- 中央氣象署(2019)**建立光學監視站長期拍攝龍洞灣岬**

以人工檢查是否有超過1.5倍人高的浪花，判斷是否有瘋狗浪發生

每小時發生一件或一件以上的海岸瘋狗浪，即視為一筆海岸瘋狗浪案例

彙整發生瘋狗浪之時間，結合鄰近龍洞浮標海氣象數據，建立海岸瘋狗浪資料



研究資料

使用2016-2019年期間的龍洞瘋狗浪案例

一共使用**2000筆資料**(有瘋狗浪與無瘋狗浪資料各占一半)，並將資料進行正規化(normalization)

處理後，作為模型學習的資料庫並劃分為訓練、驗證與測試資料。


*資料正規化(Normalization)

將原始數據縮放至特定範圍，使得各個海氣象因子數據的尺度一致

➤ 80% → 訓練與驗證資料。其中，驗證資料由K-fold交叉驗證產生


➤ 20% → 測試資料

訓練資料用於模型的學習，驗證資料用於模型調整訓練參數時比較依據，測試資料用於評估最終模型的性能。



資料時間步長

輸入給LSTM模型學習的資料為**時序列資料**，因此模型會**分析不同時間點的海氣象數據**




研究方法

類神經網路(Artificial Neural Network, ANN)

類神經網路是一種模仿人類大腦神經元結構的機器學習模型，由**多個神經元(Neurons)**組成龐大複雜網狀架構，神經元間透過**權重(Weight)**相連，形成數學函式。

模型在訓練過程會不斷地計算與更新權重，目標是減少模型輸出與實際值之間的誤差，最終得到擬合欲解決問題的函式



輸入層(Input layer)：接收外界給予的資訊

隱藏層(Hidden layer)：對輸入資訊進行計算和特徵提取

輸出層(Output layer)：輸出最終的預測結果

在ANN中，每個輸入資訊都是獨立處理的，且網路無法保留之前的資訊，無法理解前後數據的關聯，因此
ANN不擅長處理時序列數據。

長短期記憶神經網路(Long Short-Term Memory, LSTM)

LSTM為神經網路的一種，以多個LSTM神經元組成網路並以遞迴的方式來分析不同時間(t)的資訊

- LSTM有兩個主要資訊傳遞路徑:

記憶路徑(memory path)→負責儲存重要的長期資訊

隱藏狀態(hidden state)→負責處理每個時間的短期資訊

- 使用三種閥單元來控制資訊的傳遞

遺忘閥(forget gate):


控制是否減少資訊，避免儲存過多資訊，形成可靠的長期記憶

輸入閥(input gate):

控制每個時間(t)的資訊要輸入的多寡，包含傳入的短期資訊(t-1)與當下時間(t)輸入的資訊

輸出閥(output gate):

控制是否將神經元計算的結果(長期記憶+短期資訊)輸出給下一個時間(t+1)與下一層




損失函數、隱藏層層數與神經元數量

- 損失函數(loss function)用於計算模型預測與實際結果之間誤差的函數，選擇合適的損失函數能幫助模型有效下降誤差，本研究使用二元交叉熵(binary cross-entropy)：

$$L_{BCE} = -\frac{1}{N} \sum_{i=1}^N y_i \cdot \log(\hat{y}_i) + (1 - y_i) \cdot \log(1 - \hat{y}_i)$$

- 隱藏層層數越多或神經元數量越多，代表模型複雜度越高，能夠提升模型提取特徵的能力。
- 模型過於複雜，提取到不必要的雜訊
→可能導致過度學習(overfitting)

➤ 需透過實驗選擇合適的隱藏層層數與神經元數量




雙層長短期記憶網路

結果與討論

隱藏層層數與神經元數量率定結果


分別建立1~7層隱藏層的模型，每層皆為10個神經元

- 隨著層數的增加，模型的準確率並未提升，反而呈現下降趨勢，代表使用單層LSTM建立模型即能有良好的訓練效果



使用1到100個不同數量的神經元建立模型


- 當神經元數量達10個時，模型擁有最好的準確率，且持續增加神經元數量，準確率並沒有顯著的變化。代表選擇使用10個神經元建立模型能有良好的訓練效果



時間步長率定結果

建立時間步長為2小時~10小時的模型，觀察隨著資料量增加，模型準確率的變化

- 隨著資料量增加，選擇2小時的時間步長建立模型，表現出較好的增長趨勢，未來如持續增加數據，有較大的潛力能提升模型的預測能力。因此，使用瘋狗浪發生前2小時內的海氣象數據進行分析與預測



最終採用單層、10個神經元與2小時時間步長建置LSTM瘋狗浪預測模型



瘋狗浪預測模型建置結果

單層、10個神經元與2小時時間步長建置LSTM瘋狗浪預測模型，並產生驗證與測試結果

- 驗證與測試結果顯示各項評估指標均保持良好，可達近八成，代表**模型有能力預測瘋狗浪的發生**
- 反查率可達八成以上，代表**實際有瘋狗浪發生時，模型能夠準確預測其發生**

訓練結果	正確率	77.3%
測試結果	正確率	76.5%
	反查率	80.1%
	回應率	74.9%
	幾何平均評估指標	0.764

正確率：所有瘋狗浪或無瘋狗浪的資料中，模型預測正確的比率

回應率：模型預測為瘋狗浪會發生的結果中，有多少比例實際真的有發生

反查率：實際有瘋狗浪發生的資料中，模型有正確預測到瘋狗浪發生的比率

幾何平均評估指標：衡量模型在預測瘋狗浪發生和瘋狗浪未發生時的平衡表現



與其他AI方法比較

與其他三種AI方法建立的瘋狗浪模型進行比較，分別為類神經網路(ANN)、隨機森林(RF)以及支撐向量機(SVM)

- 結果顯示各模型表現均良好，表示**四種AI方法建立的模型皆有能力預測海岸瘋狗浪的發生，顯示此類AI技術應用於瘋狗浪預測的可行性**

		LSTM	ANN	RF	SVM
訓練結果	正確率	77.3%	78.1%	75.9%	77.8%
測試結果	正確率	76.5%	74.0%	78.0%	75.5%
	反查率	80.1%	80.1%	81.1%	79.6%
	回應率	74.9%	71.6%	76.5%	73.7%
	幾何平均評估指標	0.764	0.737	0.779	0.754


長浪期間情境分析

使用2020年的瘋狗浪資料

長浪期間，通常瘋狗浪發生的可能更高，然而長浪發生在風平浪靜的天氣下，可能讓民眾放鬆警戒，增加受害風險

案例選取：海岸瘋狗浪案例發生前2小時的示性波高>1.5m與平均週期>8s (根據中央氣象署規定之長浪標準)

案例編號	預測發生機率(%)			
	LSTM	ANN	RF	SVM
1	75.2%	74.9%	88.6%	80.7%
2	77.5%	72.3%	87.1%	79.1%
3	86.3%	86.3%	62.9%	77.0%
4	86.7%	86.3%	68.6%	78.3%
5	86.7%	83.7%	77.1%	78.1%
6	81.8%	77.2%	68.6%	65.2%
7	82.7%	73.2%	64.3%	77.4%
8	74.4%	77.0%	67.1%	77.5%
9	89.6%	85.2%	84.3%	49.2%
10	90.0%	87.0%	82.9%	56.4%
11	90.5%	85.7%	70.0%	70.4%



→ 四種機器學習方法都能成功預測到在長浪條件下發生的海岸瘋狗浪。

→ 與其他方法相比，在長浪期間，**LSTM模型輸出的瘋狗浪發生機率更高**。



颱風期間情境分析

使用2020年的瘋狗浪資料

- 颱風期間，通常瘋狗浪發生的可能更高，考慮到颱風海上警報發布前及解除後也有發生海岸瘋狗浪的可能性，且此種案例比較容易被輕忽，因此也將這段期間納入討論

→預測期間為各颱風發布海上警報前一天至海上警報解除後一天

- ✓ 在哈格比颱風中，LSTM模型的預測正確率為85.7%，比其他模型高出11%
- ✓ 在米克拉颱風中，LSTM模型的預測正確率為76.2%，相較於RF模型高出7%
- ✓ 在閃電颱風中，LSTM模型的預測準確率為79.3%，比其他模型高出10%

各模型在不同颱風期間之預測正確率 (Accuracy)

	LSTM	ANN	RF	SVM
HAGUPIT	85.7%	82.9%	74.3%	74.3%
MEKKHALA	76.2%	78.6%	69.0%	73.8%
ATSANI	79.3%	69.0%	72.4%	69.0%
平均準確率	80.4%	76.8%	71.9%	72.4%

綜合三起颱風期間的預測結果，**LSTM模型有最佳的預測準確率，平均準確率可達80.4%，可比其他機器學習方法之模型高出9%**



結論

結論

本研究利用光學攝影機記錄海岸瘋狗浪的出現時間，蒐集附近浮標的海氣象數據作為資料庫，並採用長短期記憶網路(LSTM)建置預測模型，以預測海岸瘋狗浪是否發生：

- 使用LSTM建置的預測模型在各評估指標上皆表現優良，可達八成，**顯示模型有能力預測海岸瘋狗浪的發生**
- 本研究的LSTM模型建置過程顯示，使用過多隱藏層或神經元的LSTM會導致性能下降，**使用單層且10個神經元建立LSTM已能有效學習數據特徵**
- 隨著資料量增加，以**2小時時間步長建置之模型**表現出較好的增長趨勢，表示**有較大的潛力能提升模型的預測能力**
- LSTM模型與其他AI方法建立的模型進行比較，**結果顯示在長浪與颱風期間，LSTM模型的預測表現優於其他模型**



Thanks for your attention



備註：為何只比較三個颱風

使用2020年的瘋狗浪資料

台灣於2020年有發布海上警報之颱風包括黃蜂(VONGFONG)、哈格比(HAGUPIT)、米克拉(MEKKHALA)、巴威(BAVI)及閃電(ATSANI)。

- 黃蜂颱風的海上警報期間，龍洞灣岬發生的海岸瘋狗浪案例過少，無法進行有效地討論。
- 巴威颱風的海上警報期間，龍洞灣岬每小時皆有發生海岸瘋狗浪，而LSTM、ANN、RF及SVM預測模型皆能成功預測海岸瘋狗浪發生，在預測表現上無差異性。

排除以上兩起颱風後，本研究最終選用了哈格比、米克拉和閃電颱風，共三起颱風進行進一步的情境分析。

預測期間為各颱風發布海上警報前一天至海上警報解除後一天。

考慮到颱風海上警報發布前及解除後也有發生海岸瘋狗浪的可能性，且此種案例比較容易被忽略，因此也將這段期間納入討論。

