

應用統計方法與生成對抗網路於侵台颱風模擬之 比較與驗證研究

李冠緯¹ 林其穎^{2*}

¹ 國立陽明交通大學土木工程學系 碩士生

^{2*} 國立陽明交通大學土木工程學系 助理教授

摘要

在氣候變遷影響情況加劇下，建構可模擬未來侵台颱風行為的模型系統，對於風險評估與結構設計基準的訂定至關重要。本研究比較並建立兩種模擬侵台颱風的方法，第一種方法為基於傳統統計方法的模擬流程，透過負二項式分配模擬年生成頻率及統計迴歸方法進行颱風軌跡及強度模擬，搭配蒙地卡羅模擬技術重建侵台颱風的整體活動情形。第二種方法則為以條件式生成對抗網路（CGAN）為核心的深度學習模型，依序建構颱風生成位置、路徑與風場的模擬模型。CGAN 模型整合氣候條件輸入與歷史路徑圖像輸入。模型可模擬颱風在連續時間下的空間遷移行為，具備處理高維輸入與非線性分布的能力。模型驗證方面，統計模型在模擬颱風年生成數與長期頻率趨勢上與歷史資料相符，展現穩定具可解釋性之模擬能力。而 CGAN 模型則在模擬連續路徑變化、轉向角度與局部空間變化等細節表現優異，尤其在模擬圖像與實際觀測結果的相似度上展現更高精度。兩者在模擬範圍與模型適應性上具有互補性，前者適用於大量模擬與統計分析，後者則適用於反映氣候條件下的個別颱風行為與空間結構重建。本研究比較兩種方法的驗證結果與應用特性，針對颱風模擬系統建構提出具體比較與應用建議，作為未來風險規劃與耐風設計調整之參考。

關鍵字：氣候變遷、熱帶氣旋、西北太平洋地區、條件式生成對抗網路、統計模擬、蒙地卡羅抽樣

1. 前言

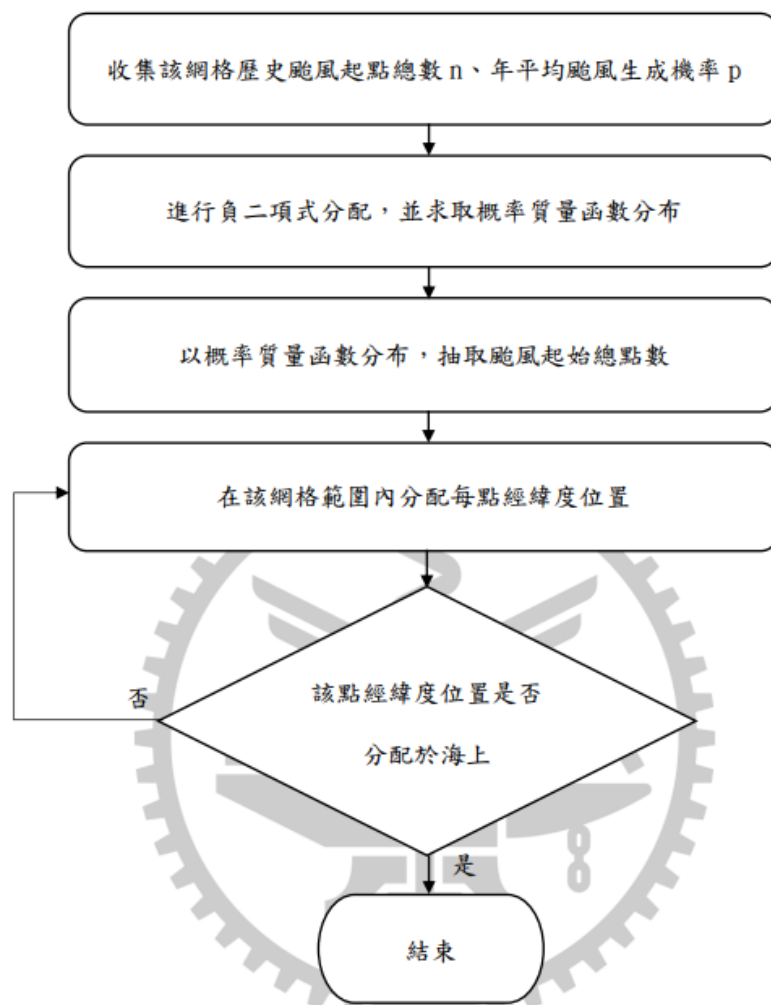
颱風模擬是颱風風險管理與工程設計中不可或缺的重要研究課題。傳統的颱風模擬方法多以統計模型為主，透過歷史資料建構數學分布，進行生成頻率、路徑及風場的估計，並以蒙地卡羅模擬大量樣本，以獲得長期的統計特性。此類方法計算效率高、理論基礎清楚，長期以來被廣泛應用於防災規劃與工程設計基準的推估。隨著計算能力提升與資料科學發展，機器學習與深度學習方法逐漸應用於颱風模擬。

其中，生成對抗網路（GAN）與條件式生成對抗網路（CGAN）展現了模擬颱風生成、路徑與風場細節的能力，能處理非線性關係與高維度輸入，突破傳統統計模型的限制。然而，兩種方法在模擬精度、可解釋性與應用場景上各具優缺點。本研究將統計模型與 CGAN 模型進行比較，釐清其模擬特徵，並探討其在颱風模擬研究與應用上的互補性。

2. 研究方法

2.1 統計模型方法

統計模型的建立包含生成點以及路徑軌跡模擬兩個部分，生成點的部分使用 Li 等人[1]提到的負二項式分佈進行生成起始點位及頻率的研究，簡要之訓練流程如下圖一起始位置頻率模型訓練流程所示。



圖一：起始位置頻率模型訓練流程

本研究之颱風軌跡模擬主要以歷史颱風資料和氣候環境因素為基礎，建立颱風軌跡模型，本模型主要生成每間隔 6 小時的颱風軌跡點，其中包含颱風中心經緯度、移動速度、轉向角度及中心壓力值。本研究使用 Vickery[2]所開發的 Empirical TC tracks model 來進行間隔 6 小時的颱風軌跡模擬，model 其中包含颱風移動速度、轉向角度與相對強度共三條方程式所組成，如下方三條方程式(1)(2)(3)所示，可以用來生成綜合性颱風路徑與中心壓力值。

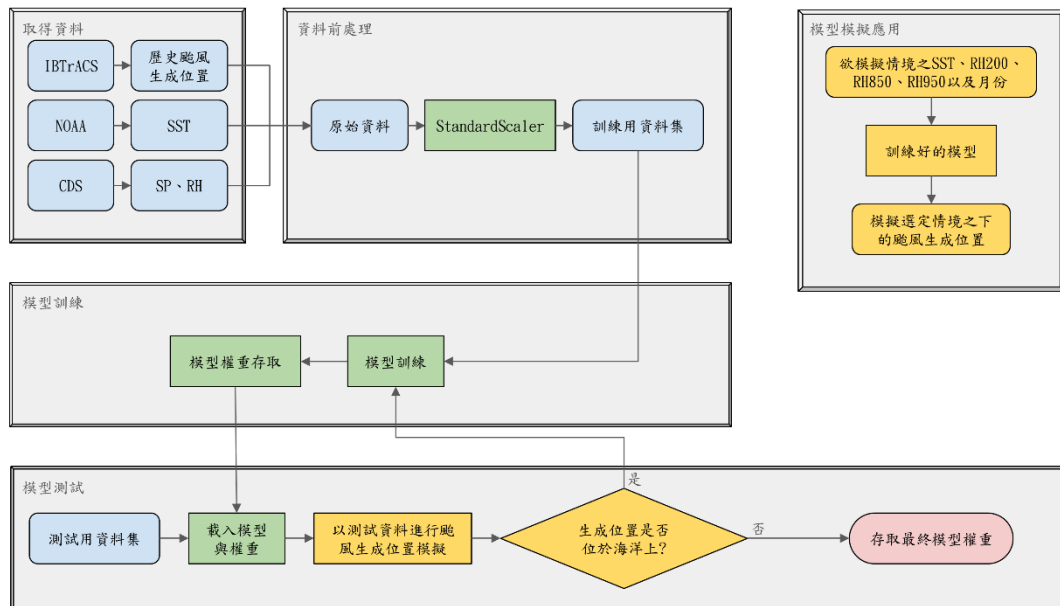
$$\Delta lnc = a_1 + a_2\Psi + a_3\lambda + a_4lnc_i + a_5\theta_i + \varepsilon_c \quad (1)$$

$$\Delta \theta = b_1 + b_2\Psi + b_3\lambda + b_4c_i + b_5\theta_i + b_6\theta_{i-1} + \varepsilon_\theta \quad (2)$$

$$\ln(I_{i+1}) = d_1 + d_2 \ln(I_i) + d_3T_{si} + d_4(T_{si+1} - T_{si}) + \varepsilon_I \quad (3)$$

其中平移速度 c 的變化定義為 $\Delta lnc = lnc_{i+1} - lnc_i$ ，風暴航向 θ 定義為 i 和 $i-1$ 時間實例之間的 $\Delta \theta = \theta_{i+1} - \theta_i$ ， a_1 、 a_2 、 a_3 、 a_4 、 a_5 、 b_1 、 b_2 、 b_3 、 b_4 、 b_5 、 b_6 、 d_1 、 d_2 、 d_3 、 d_4 分別表示地理相關模型參數，通過線性回歸分析估計， φ 為緯度、 λ 為經度、 c_i (單位:m/s) 為時間點 i 的風暴平移速度 θ_i (單位:°) 為時間步長 i 的風暴航向，由颱風前進方向與正北之間的角度確定，順時針方向為正。 ε_c 、 ε_θ 和 ε_I 為隨機誤差項 T_s (單位:K) 和 I_i 分別是該颱風中心點所在區域的海平面溫度(SST)和颱風的相對強度。

2.2 深度學習方法(CGAN)

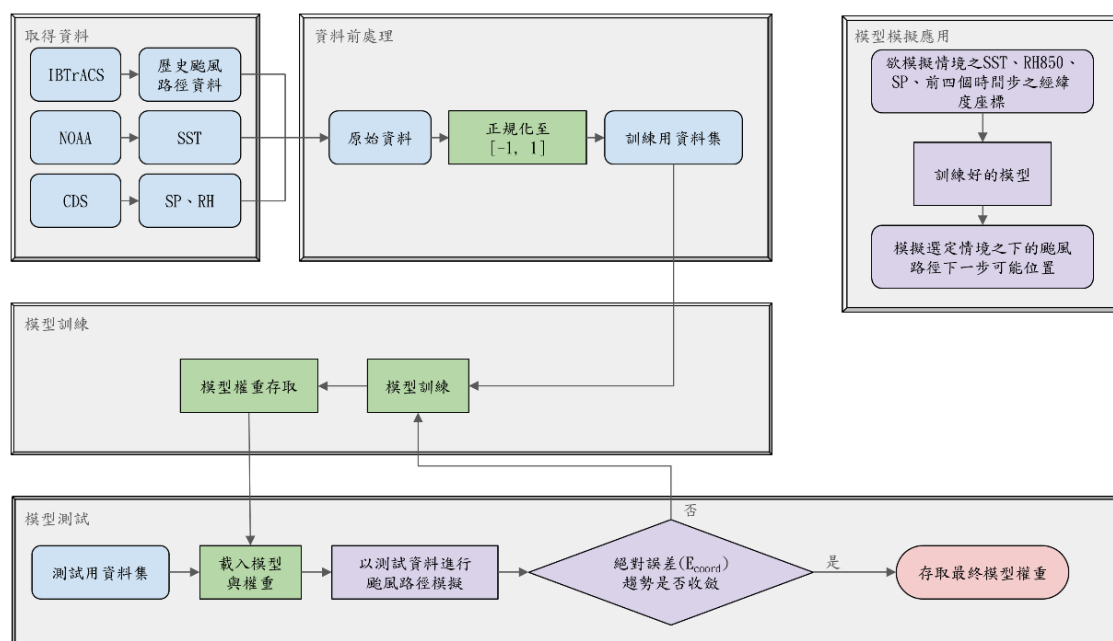


圖二：颱風生成位置模型整體流程圖

CGAN 模型透過生成器與判別器的對抗性學習，模擬颱風的生成與發展。在條件式生成對抗網路 (CGAN) 的架構中，颱風生成位置模型的主要功能在於模擬颱風於空間上的初始生成分布。該模型並非單純隨機決定颱風起始點，而是透過學習歷史颱風生成資料，結合環境條件

的輸入（如海平面溫度、相對濕度或大氣流場特徵），讓生成器在合理的範圍內產生可能的生成位置。本模型所使用的神經網路是基於 Goodfellow 等人⁰的架構以及 Rüttgers 等人⁰⁰⁰的颱風路徑模擬模型方法修改而來的簡易神經網路，模型的主要神經網路結構由一個生成器以及一個判別器所組成，生成器會將隨機噪聲與條件變數轉換為代表颱風起始經緯度的輸出，並藉由與判別器的對抗過程逐步修正，使產生的生成點能更接近真實的統計分布。判別器的角色在於檢驗生成點是否符合歷史資料的特徵，進而迫使生成器不斷優化自身輸出。這樣的架構使得模型能有效捕捉颱風生成區域的複雜分布，而不需依賴傳統統計方法所假設的固定機率函數。最終，生成位置模型為後續的路徑與風場模擬奠定基礎，確保颱風模擬能從合理的初始點展開，並更貼近實際觀測到的颱風生成行為。本模型的整體流程圖如圖二所示。

在颱風模擬系統中，路徑模擬模型的作用在於重現颱風自生成位置後的移動行為與軌跡演變。以條件式生成對抗網路（CGAN）為核心的方法中，模型會將歷史路徑資料與相關環境場（如大尺度氣流分布、海洋條件等）作為條件輸入，轉換為圖像化或高維度向量，使生成器能夠學習颱風在不同時間步的空間遷移特徵。本模型所使用的神經網路是基於 Isola 等人⁰的 Pix2Pix 模型架構以及 Rüttgers 等人⁰⁰⁰的颱風路徑模擬模型方法修改而來的條件式生成對抗網路(CGAN)模型，模型的主要神經網路結構由一個生成器以及一個判別器所組成。生成器在訓練過程中產生連續的路徑點，並透過與判別器的對抗過程逐步修正，使模擬路徑能更貼近真實觀測資料。相較於傳統統計方法以迴歸模型推估轉向角與移動速度的方式，CGAN 的路徑模擬能夠捕捉非線性關係與複雜的時空特徵，特別是在颱風轉向或不規則軌跡的情境下展現較佳表現。最終，路徑模擬模型使颱風的模擬結果不僅能反映平均性的統計分布，更能重現個別颱風在連續時間下的動態軌跡，提供細節更完整的模擬能力。本模型的整體流程圖如圖三所示。



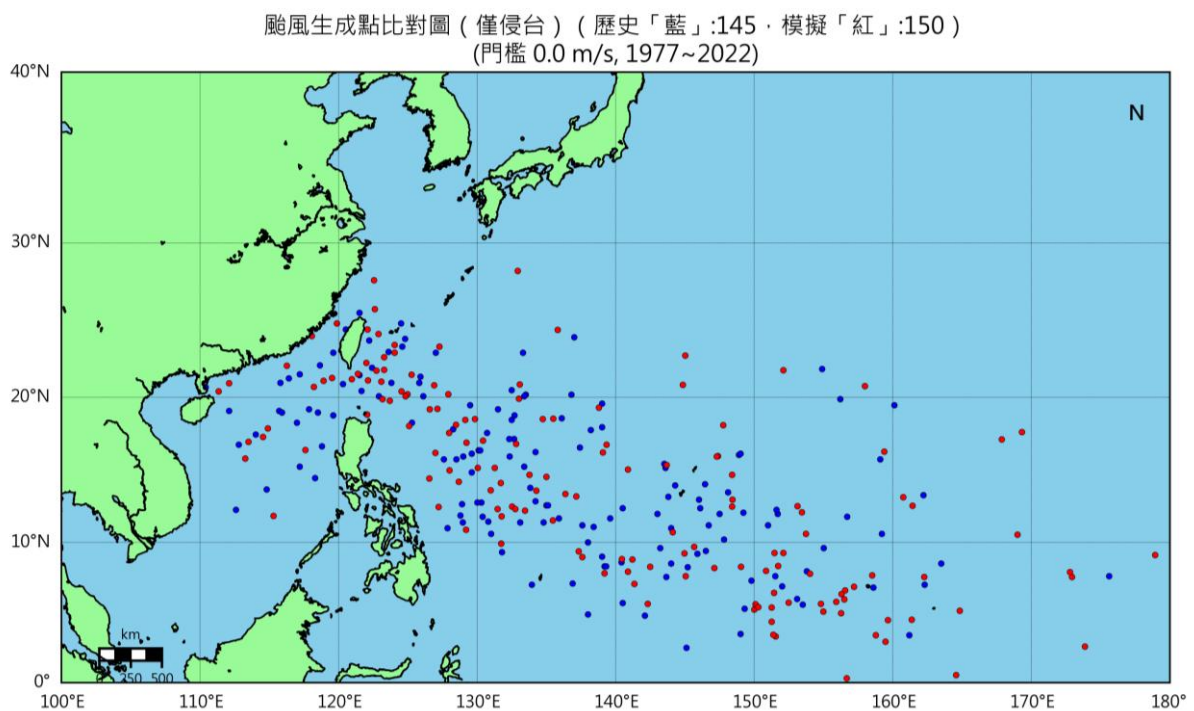
圖三:颱風路徑模擬模型(CGAN)整體流程圖

在技術實現上，本研究的 CGAN 路徑模型採用 U-Net 作為生成器架構，該架構的特色在於編碼器與解碼器之間的跳層連接(Skip Connection)機制。編碼器將 80×80 的輸入圖像透過四次下採樣操作，逐步提取高階特徵，而解碼器則通過轉置卷積恢復空間解析度。跳層連接將編碼過程中的淺層特徵直接傳遞至解碼器對應層，有效保留了颱風路徑的細節資訊。判別器則採用 PatchGAN 架構，不僅評估整體圖像真偽，更透過局部區域的判別提升模型對路徑細節的學習能力。此外，本研究採用「九宮格」標記法標註颱風位置，相較於單點標記，能更有效地捕捉颱風移動的空間特徵。

3. 研究結果

3.1 統計模型結果

統計模型在歷史資料中共有 145 點的侵台颱風，使用負二項式分配模擬一次，得到在研究範圍內共 150 點的侵台颱風，由下圖四可看出負二項式分配已完整模擬出颱風起始位置的數量及空間分布情況，從颱風起始點總數來看，兩者數量相當一致，由此可說明颱風起始位置頻率模型已成功模擬颱風起始點生成之分布情形。

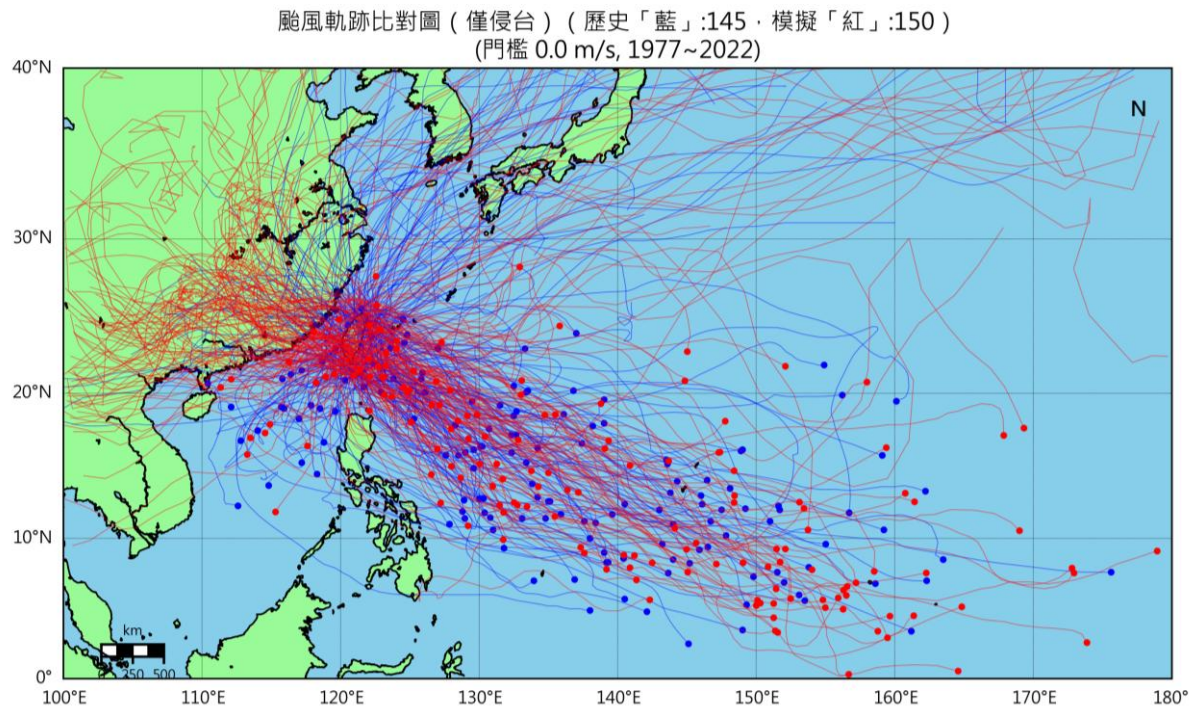


圖四：歷史與模擬侵台颱風起始位置分佈比較圖

而對於軌跡模擬的部分，圖五為歷史資料和模擬軌跡資料兩者重疊比較圖，由圖可觀察到兩者軌跡經緯度分布十分相似。

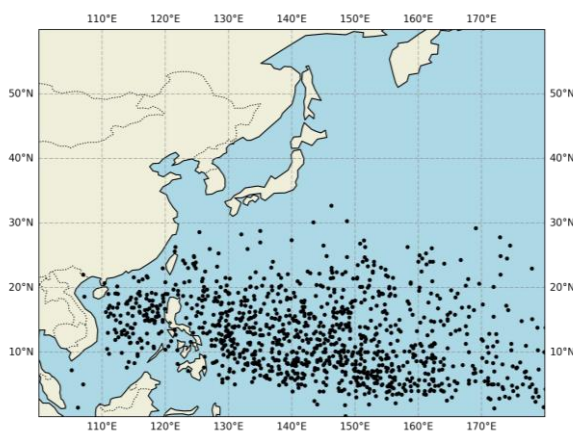
進一步分析統計模型的路徑模擬精度，本研究在台灣與中國東南沿海設置 15 個檢測站，收集半徑 200 公里內的颱風軌跡數據進行驗證。結果顯示，模擬的颱風轉向角度、移動速度與中

心氣壓的平均值與標準差都與歷史資料相當接近，其中颱風中心氣壓的模擬標準差雖略大於歷史資料，但考慮到颱風系統的自然變異性與極端事件的存在，此差異仍在合理範圍內。這些驗證結果證實了統計模型在捕捉颱風整體行為特徵上的有效性。

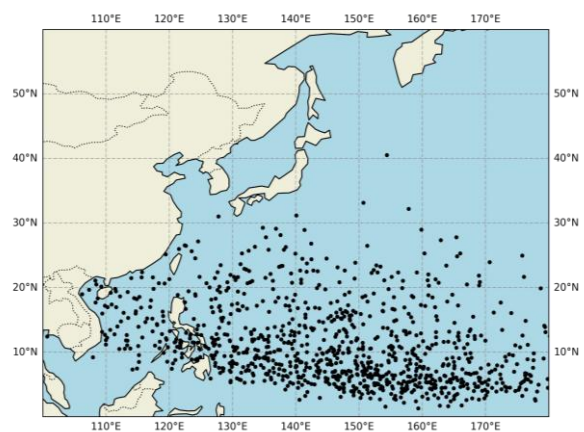


圖五:歷史與模擬侵台颱風軌跡比較圖

3.2 CGAN 模型結果



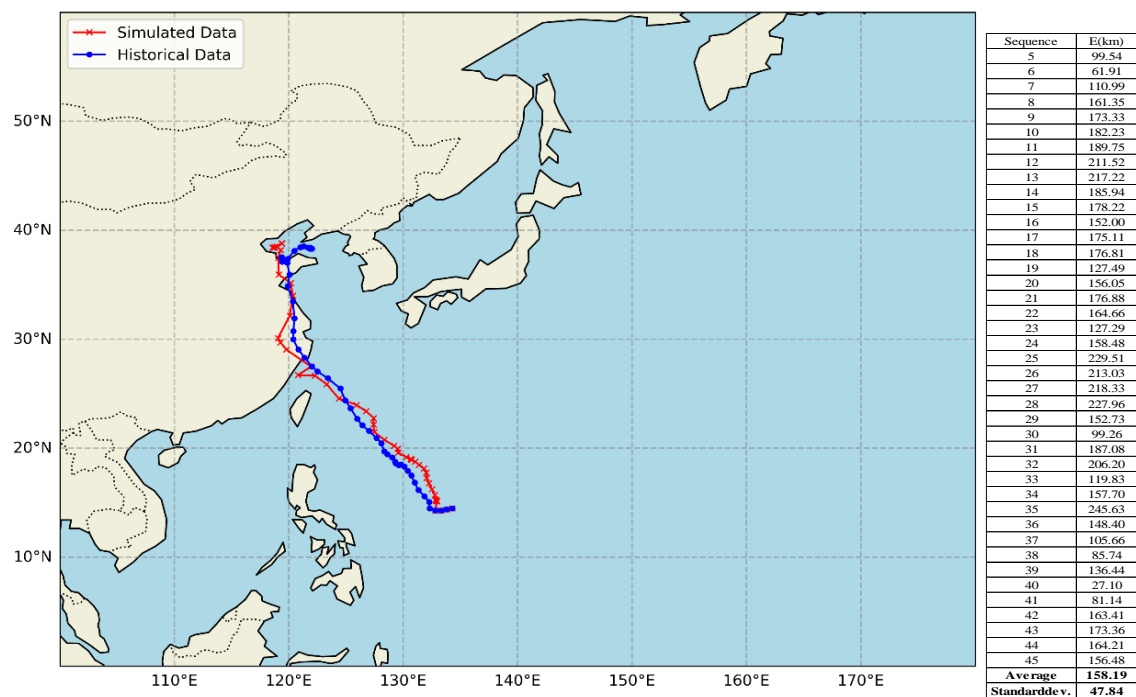
圖六:西元1977年至2021年颱風生成位置分布



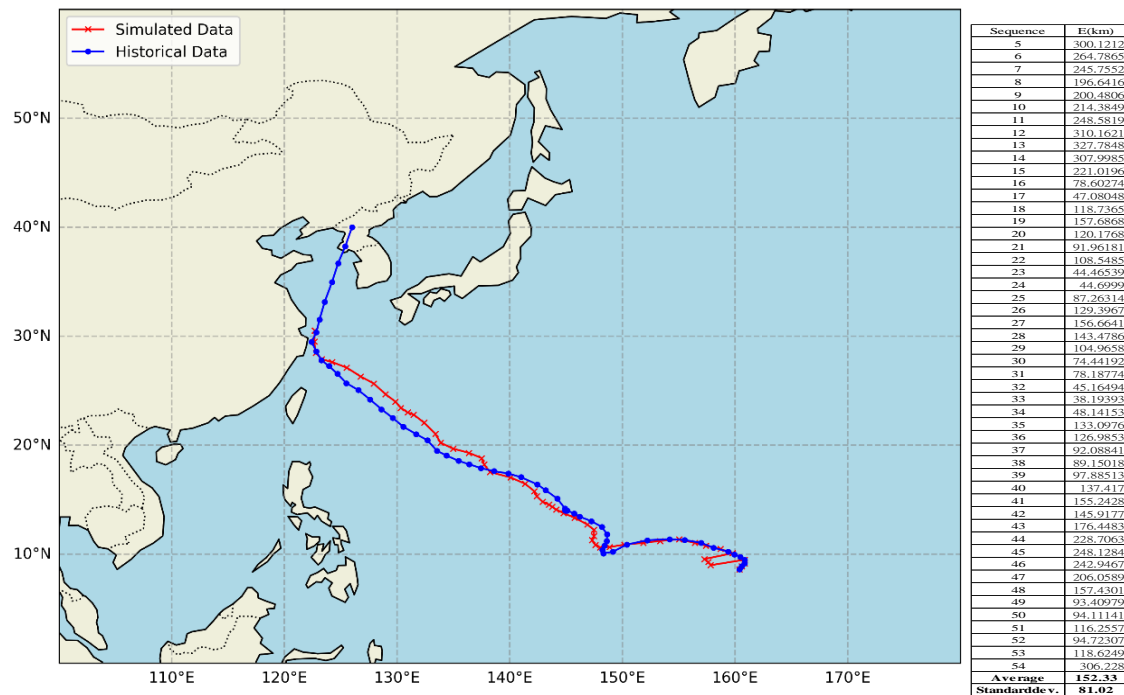
圖七:模擬1977年至2021年颱風生成位置結果

對於 CGAN 生成點模型的驗證，圖六展示了 45 年間研究範圍內共 1153 個颱風的生成位置的分布，而圖七則呈現了本模型模擬的結果。在每一個獨立的模擬之中，模型都會根據歷史資料中颱風每月的發生頻率，使用負二項式分配進行抽樣，從而決定每月生成的颱風數量，接著才通過 GAN 生成並模擬每個颱風的經緯度座標，在模擬過程中，本模型也設置了約束條件，確保生成的颱風位置位於海洋上，而非陸地，避免因生成位置在陸地上導致的模擬結果偏差。通過 1000 次的獨立模擬，在研究範圍內平均每次模擬共生成 1140.109 個颱風起始點位，模型的模擬結果與歷史數據之間的相對誤差僅 1.12%，表明本模型在生成數量上與歷史資料相當一致。

而軌跡模型驗證的部分，本節颱風路徑模型以西元 1977 年至 2021 年的氣候環境因素資料作為輸入機器學習模型所使用的數據。本研究之 CGAN 颱風路徑模擬模型成果如圖八和圖九所示，每張圖中分別以藍色標示歷史颱風路徑，以紅色標示本研究 CGAN 模型模擬之颱風路徑，並且在右方表格中標註颱風模擬路徑在各個時間步長 (timestep) 上與歷史資料之誤差(單位:km)，可以明顯的觀察到本研究之模擬結果不論是在颱風路徑整體發展趨勢上或是點對點 (Sequence to Sequence) 的個別誤差上，都與歷史資料十分吻合。



圖八: 2019 年 LEKIMA 颱風之歷史軌跡(藍色)與模擬軌跡(紅色)及其在每個 timestep 之誤差



圖九: 2015 年 CHAN-HOM 颱風之歷史軌跡(藍色)與模擬軌跡(紅色)及其在每個 timestep 之誤差

從模型驗證結果來看，統計模型在 15 個沿海檢測站的驗證中，其模擬的颱風轉向角度、移動速度與中心氣壓的平均值與標準差都與歷史資料相當接近。而 CGAN 模型在點對點路徑誤差方面表現優異，平均誤差為 148 公里，相較於參考文獻 Rüttgers 等人的 100 公里雖有差距，但本研究的兩種方法都具備處理未來氣候變遷情境的能力，這是參考方法所缺乏的重要特性。

4. 結論

綜合本研究結果，統計模型與生成對抗網路 (CGAN) 在颱風模擬上各具優勢與限制。統計模型以明確的數理結構與分布假設為基礎，能有效掌握颱風生成頻率與位置，其主要優點在於運算效率高、可重現性佳且理論架構清晰。然而，統計方法的限制在於假設條件過於理想化，難以處理複雜的非線性行為，導致在模擬颱風轉向、速度突變與局部風場強度變化時產生誤差。這些誤差多源於模型假設與真實大氣過程間的差異，如忽略區域尺度的氣流擾動或海氣耦合效應，進而造成模擬路徑的偏移與風速估算的誤差累積。

另一方面，CGAN 模型以深度神經網路為基礎，具備從大量資料中自動學習非線性關係的能力，能夠捕捉颱風生成與路徑變化的細節特徵。其在模擬轉向、環流擴散與風場分布方面表現優異，尤其能重現傳統模型難以捕捉的異常軌跡。然而，CGAN 模型的誤差主要來自資料依賴性與訓練穩定性問題。當歷史資料不足或資料品質不一致時，模型可能過度擬合特定樣本或產生非物理的輸出。此外，生成器與判別器在訓練過程中的平衡性對結果穩定性影響顯著，若訓練不當，可能導致路徑偏離或風場強度不連續的問題。

綜合而言，統計模型適合用於長期、多案例的整體趨勢模擬，而 CGAN 模型則在單一颱

風事件的細節重建與局部特徵捕捉上具有優勢。未來研究可考慮將兩者結合，利用統計模型提供全域分布與生成頻率的基礎，再以 CGAN 修正路徑與風場細節，形成兼具穩健性與高解析度的混合模擬系統。同時，針對誤差來源的分析亦可進一步納入模型不確定性量化與多資料交叉驗證，以提升颱風模擬之可靠度與實務應用價值。

本研究認為未來研究方向統計模型與 CGAN 的整合應用具有相當潛力。可考慮發展階層式的混合架構，先以統計模型快速產生大量的颱風事件樣本，掌握整體的頻率分布與季節特性，再針對關鍵的颱風事件使用 CGAN 進行路徑與風場的精細化模擬。此外，目前兩種模型都已具備處理氣候變遷情境的能力，未來可進一步比較在不同 SSP 情境下的模擬表現差異，並導入集成學習的概念，結合多個模型的預測結果以降低個別模型的系統性偏差。在實務應用上，如何將模型的不確定性量化並有效傳達給決策者，以及如何與即時觀測資料進行動態同化，都是值得深入探討的研究課題。

5. 參考文獻

- [1] Li, S. H., & Hong, H. P. (2016). Typhoon wind hazard estimation for China using an empirical track model. *Natural Hazards*, 82(2), 1009-1029
- [2] Vickery, P. J., Skerlj, P. F., & Twisdale, L. A. (2000). Simulation of hurricane risk in the US using empirical track model.
- [3] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Bengio, Y. (2014). Generative adversarial nets. *Advances in neural information processing systems*, 27.
- [4] Rüttgers, M., Lee, S., & You, D. (2018). Typhoon track prediction using satellite images in a generative adversarial network. *arXiv preprint arXiv:1808.05382*.
- [5] Rüttgers, M., Lee, S., Jeon, S., & You, D. (2019). Prediction of a typhoon track using a generative adversarial network and satellite images. *Scientific reports*, 9(1), 6057.
- [6] Rüttgers, M., Jeon, S., Lee, S., & You, D. (2022). Prediction of typhoon track and intensity using a generative adversarial network with observational and meteorological data. *IEEE Access*, 10, 48434-48446.
- [7] Isola, P., Zhu, J. Y., Zhou, T., & Efros, A. A. (2017). Image-to-image translation with conditional adversarial networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1125-1134).
- [8] 郭浩綸，以統計模型預測西北太平洋區域颱風侵襲台灣之變化，國立陽明交通大學碩士論文，2024 年。
- [9] 陳致霖，利用條件式生成對抗網路模擬西北太平洋侵台颱風，國立陽明交通大學碩士論文，2024 年。