

多尺度卷積長短期記憶神經網路應用於溫度誤差預測研究

李浩君¹ 陳怡儒² 林冠成¹
國立中興大學資訊管理學系¹ 中央氣象局²

摘要

溫度預報與人類生活及財產息息相關，準確的溫度預報可以幫助緊急管理並減少經濟損失，同時創造大量的商業價值，並將資源調度最大化，提高商業價值及人類生活品質。中央氣象局使用遞延平均法(Decaying Average)進行溫度預報誤差修正，Decaying Average 方法使用固定權重計算當前時間點與前一時刻溫度預測誤差之遞延關係，取得不錯的成效，但與實際觀測值仍有差距。

台灣地形極為複雜，同時具有盆地、高原、平原、丘陵、山地五大地形，讓天氣的時空特性變得更為複雜。因此，本論文提出一個基於 GoogLeNet Inception 多尺度卷積核的改良版 ConvLSTM 演算法模型-IConvLSTM，透過捕捉不同地形之特徵來提升模型的預測能力，並以北台灣做為驗證。模型訓練使用 2017 至 2019 年資料扣除測試集，測試集為三年每月 15 日至 19 日資料。實驗結果顯示，在北台灣第 1 日預報場，以平均絕對誤差(Mean Absolute Error, MAE)做比較。原始預報場、DecayingAverage、ConvLSTM 模型和本研究提出模型的 MAE 分別為 1.9855、1.6422、0.9201 和 0.7347。相較於原始預報場，DecayingAverage、ConvLSTM 模型和本研究提出模型的修正幅度分別為 17.29%、53.66%和 62%。上述結果說明深度時空模型能夠有效校正數值天氣系統的預報誤差，其中又以本研究所提出的修正模型表現最佳，驗證所提出模型已經具有實際作業的預報能力。

關鍵字：遞延平均法、卷積長短期記憶神經網路、時空序列、深度學習、預報誤差修正、數值天氣預報

一、前言

近代數值天氣溫度預報系統逐漸完善，準確度不斷提高，但數值天氣溫度預報系統預報結果與真實觀測值仍存在誤差，且會隨著預報時間拉長，誤差逐漸增大(張蘭慧, 2011)。目前中央氣象局溫度誤差修正方法為 Decaying Average，Decaying Average 優點維只需要儲存前一時間點的誤差以及當下資料便可計算當下系統偏差，有效節省資料儲存空間，約 60 天即可涵蓋 90%上的誤差資訊，並透過簡單的數學式修正溫度誤差，計算負荷量少，當權種係數 0.04 時，有最佳的修正效果，(陳怡儒等, 2017)然而目前統計類型修正方法，相比溫度時空複雜特性，方程式過於簡單且無法同時考慮範圍內所有網格點間的時空特性，因此修正預報誤差方法仍有很大的進步空間。

由於氣象資料同時具有時間與空間的複雜交互作用特性，難以用一組數學方程進行預測，而深度學習是透過多層神經網路的非線性運算組合，能夠自動學習複雜的資料特徵並尋找最佳方程式(LeCun, et

al., 2015)，因此近年來有許多學者使用深度學習技術於氣象預測領域，其中 Karevan 等人使用長短期記憶神經網路(Long Short-Term Memory, LSTM)捕捉天氣時間序列特徵，預測比利時、荷蘭的五座城市之最高、最低溫度，預測效果與 Weather Underground 預測平台預報能力相當(Karevan, et al., 2020)；Sayeed 等人使用卷積神經網路(Convolutional Neural Network, CNN)，捕捉 WRF(Weather Research and Forecasting)系統天氣空間特徵，預測韓國風速、風向、溫度、降水量、濕度等天氣數值，對於 WRF 數值天氣預報有明顯修正效果(Sayeed, et al., 2020)；Lin 等人使用卷積長短期記憶神經網路(Convolutional LSTM, ConvLSTM)使用歐洲中期天氣預報中心(ECMWF)溫度與降雨數據進行溫度誤差預測，預測效果優於歐洲中期預報中心集成預報技術(Objective Consensus Forecast, OCF)(Lin, et al., 2019)；Shi 等人提出一個融合卷積核與 LSTM 的 ConvLSTM 時空模型，在降雨預測實驗中效果優於 LSTM 以及傳統光流預測技術，證明 ConvLSTM 於氣象領域有良好的時空特徵捕捉能力(Shi, et al., 2015)。

由此可見深度學習技術於氣象預測領域皆有優異

的表現，因此本論文使用深度學習時空模型於溫度誤差修正，驗證深度學習技術於台灣溫度時空特性的預測能力。

二、深度學習於時空預測技術

(一) 深度學習於溫度預報應用

Sayed 等人使用 2014 至 2017 年韓國 WRF 模式資料，設計了一個 CNN 卷積網路捕捉偏差特性，作為 WRF 模式後處理修正方案，改善了韓國地區地表風速、風向、降水、相對濕度、表面壓力、表面溫度等預報 (Sayed, et al., 2020)；其研究模型架構包含五層 32 個 filters 的一維卷積網路，並透過線性單元整流激發，提取每小時氣象參數，在 93 個觀測站中改善了約 20% 的風速預測效果，降雨準確度提高了 7%，而溫度 IOA (Index of Agreement) 準確度也提升至 0.98-0.99，證明卷積網路能夠有效捕捉地表氣象特徵；Karevan 等人使用五層的 LSTM 模型預測布魯塞爾、安特衛普、列日市、阿姆斯特丹、愛因荷芬等五座歐洲城市每日最高以及最低溫度，實驗比較了輸入時間長度對於模型預測效果，其中模型輸入 20 天溫度資料，最高溫預測結果 MAE 為 1.48 略優於輸入 10 天的預測結果 (MAE 為 1.88)；而最低溫預測結果 MAE 分別為 1.76 與 1.54 (Karevan, et al., 2020)。

Lin 等人使用 ConvLSTM 模型預測溫度偏差，並比較了使用 NWP 溫度系統預測偏差數據及融合降雨數據，其中單純使用 NWP 溫度偏差數據作為模型訓練提高了 3% 預測準確度；而使用融合數據集則準確度提高了 4% (Lin, et al., 2019)；Kreuzer 等人等使用 ConvLSTM 模型預測德國布萊梅港、埃森、卡塞爾、烏爾姆、肯普田五座觀測站溫度，其中包含內陸、背山、多風靠海、山地等地形，用以驗證模型對於不同空間特性的預測能力。實驗結果 ConvLSTM 於大部分情況皆優於季節自回歸平均法 (Seasonal Autoregressive Integrated Moving Average, SARIMA)、LSTM (Kreuzer, et al., 2020)。

由以上文獻可知，CNN 演算法較著重於提煉資料空間特徵，LSTM 用以捕捉資料時間特徵資訊，ConvLSTM 演算法具有同時學習時間與空間特徵的能力，而氣象預報為一個融合時間與空間線性與非線性函數最佳化問題 (Tekin, et al., 2021)，因此後續將會針對已應用於其他領域之時空模型進行討論，並作為本論文模型發想方向。

(二) 深度學習於時空序列應用

Zhu (Zhu, et al., 2017) 等人使用多模分別輸入單色手勢動圖以及 RGB 手勢動圖，增加模型資訊量輸入。每個輸入端都使用 3DCNN 卷積網路用於提取手部

姿勢短期時空特徵，再接上 ConvLSTM 捕捉長時空特徵。用於 IsoGD 與 SKIG 資料集，取得良好的預測結果。Lotter 等人提出 PredNet 網路，分別由卷積輸入層、ConvLSTM 遞迴層、卷積預測層、誤差層，四層網路組成。遞迴層學習影片時空序列特徵，並產出隱含向量作為卷積預測層的輸入；誤差層用來計算預測層與下一時段的輸入層 (等同預測時段) 偏差，以修正遞迴層的權重。此模型於影片預測上雖然有模糊問題，但在影片特徵提取上有良好的表現 (Lotter, et al., 2016)。

Christian Szegedy (Szegedy, et al., 2015) 於 2015 年提出 Inception 概念，作者認為增加卷積層深度以及神經元數量，更容易造成過擬和問題以及模型參數量暴增造成運算資源浪費，因此設計同時考慮多種尺度特徵並有效率的 CNN 模型架構解決這些問題，此研究中使用了 1x1、3x3、5x5 尺寸卷積核並聯，所提出的模型架構相較同性能傳統 CNN 模型節省 3 到 4 倍時間。

Agethen (Agethen, et al., 2019) 使用了多種卷積核於 ConvLSTM 輸入如圖 1，並透過一層 1x1 卷積核 CNN 輸出輸入門、遺忘門、細胞狀態、輸出與門原始 ConvLSTM 相同數量參數，其中文獻提到於 1x1 卷積層前透過 Tanh 非線性函數進行激發效果會更佳。

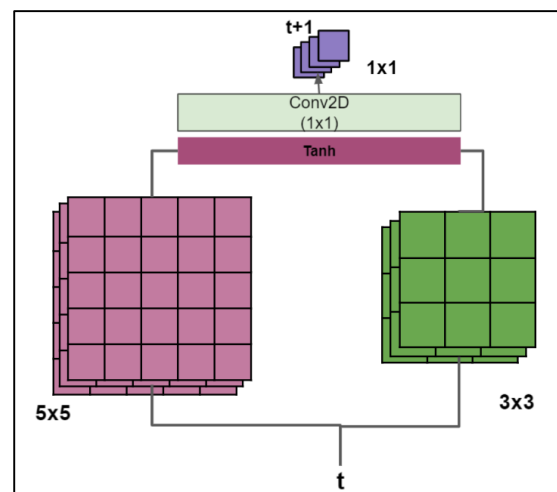


圖 1 multiple kernels ConvLSTM 圖

(Agethen, et al., 2019)

溫度預測屬於時空預測問題，不同時空預測應用上方法通用，本論文參考 Zhu 使用 CNN (Zhu, et al., 2017) 以及 Lotter 使用 ConvLSTM (Lotter, et al., 2016) 提取時空特徵之方法，並參考 Christian Szegedy 與 Agethen 所提出之多尺度卷積核概念改良

傳統的 ConvLSTM 演算法組合一個能夠同時預測北台灣不同尺度溫度時空特徵的模型進行溫度誤差修正。

(三) 溫度誤差預測模型建力

本論文所設計之北台灣溫度預測模型 IConvLSTM 架構如圖 2，模型由編碼器(Encoder)、解碼器(Decoder)組成；模型透過編碼器架構提取北台灣溫度誤差時空特徵並透過解碼器以編碼器萃取之時空特徵進行預測，最後透過全連結層輸出第一日預報場(第 1 小時至第 24 小時預報)個別誤差，以下根據模型各部分進行說明

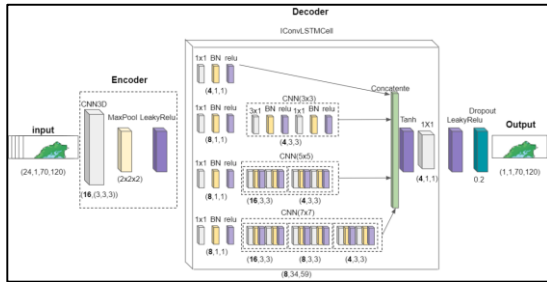


圖 2 北台灣溫度預測模型

1. 編碼器

編碼器以 3DCNN 組成，此架構參考 Zhu 學者於輸入端使用 3DCNN 卷積網路提取手部姿勢短期時空特徵，再接上 ConvLSTM 捕捉長時空特徵。用於 IsoGD 與 SKIG 資料集，取得良好的預測結果(Zhu, et al. , 2017)；IConvLSTM 模型編碼器使用 3x3x3 卷積核之 3DCNN 提取北台灣溫度誤差時空特徵如圖 3.10，其中 70 與 120 分別為北台灣空間長寬範圍，24 作為時間深度組成 3 維時空資料，並透過 3DCNN 進行時空特徵提取，使用 2x2x2 最大池化層降低資料維度，最後透過 Leaky_relu 非線性函數整流輸出；其中 Leaky_relu 函數為 relu 函數負數部份乘以一個負斜率保留部份負值激發效果。




圖 3 3D CNN 特徵提取圖

2. 解碼器

由 IConvLSTM 神經元組成，解碼編碼器所萃取的北台灣溫度誤差時空特徵，透過 Leaky_relu 非線性函數整流輸出，並使用 Dropout 層於每次訓練迭代跳過 20%神經元預防 Overfitting 發生；IConvLstm

神經元構造如圖 3.11，IConvLstm 神經元為本論文為了捕捉不同尺度地形時空特徵，提出一種混和 Inception 多尺度機制的 ConvLSTM 神經元架構。

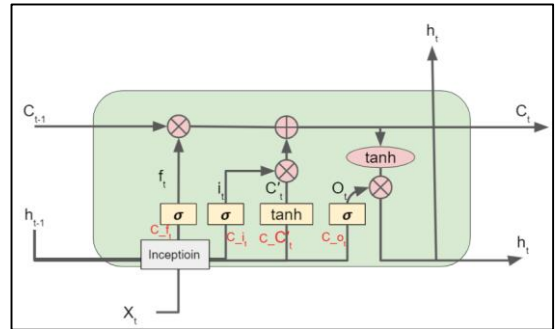


圖 4 IconvLSTM cell 圖

圖 3.12 為本研究提出之多尺度網路 Inception 模塊，使用了 1x1 以及 3x3、5x5、7x7 卷積核，並使用 padding 補充，使不同尺度卷積核輸出相同尺寸之特徵圖以供後續融合，並於 3x3、5x5、7x7 卷積層前堆疊一層 1x1 卷積層配合 relu 非線性激發函數整流捕捉非線性特徵，同時增加歸一化層(BatchNorm)幫助模型收斂，再輸出至各尺度卷積網路層；其中 3x3、5x5、7x7 卷積使用 3x3 卷積層疊而成減少參數，此技巧源自 Karen Simonyan 於 VGG 網路提出堆疊 3x3 卷積層達到大尺度卷積核視野效果，兩層 3x3 卷積層等同 5x5 卷積層視野，3 層 3x3 卷積層等同 7x7 視野，於每層使用非線性整流函數使網路組合函數更豐富複雜，堆疊卷積層組成更複雜隱含函數同時減少參數量，以 7x7 尺度卷積層網路為例，堆疊 3 層 3x3 卷積網路節省 81%以上參數量(Simonyan, et al. , 2014)。

每層 3x3 卷積網路使用可分離卷積(Depthwise separable convolution)組成組成，可分離卷積網路為 Andrew G. Howard 於 MobileNet 網路中提出的核心技術，將標準卷積網路分解成深度卷積網路以及一個 1x1 的點卷積網路，先使用深度卷積網路對輸入每個通道進行卷積，再使用點卷積網路融合輸出，其優點為大幅度減少參數量，以 RGB 三通道圖片為例，通過以 3X3 卷積核數量為 4 的卷積層運算，標準卷積層參數量為 108，可分離卷積參數量為 39，大幅減少參數量(Howard, et al. , 2017)，並且於每個卷積層後方加入歸一化層及 relu 非線性激發函數堆疊達到減少參數並增加非線性整流能力。融合多尺度空間特徵後再透過 1x1 卷積層以及 tanh 整流輸出細胞狀態、輸入門、輸出門、遺忘門狀態，此一想法源自 Agethen(Agethen, et al. , 2019)使用了多種卷積核於 ConvLSTM 輸入如圖 3.13，並透過一層 1x1 卷積核 CNN 輸出輸入門、遺忘門、細胞狀態、輸出與門原始 ConvLSTM 相同數量參數，其中文獻提到於 1x1 卷積層前先透過 Tanh 非線性函數進行激發效果會更佳。




圖 5 IConvLSTM 神經元卷積構造圖

本論文提出之 IConvLSTM 神經元計算公式如 (1) ~ (6)，輸入門、遺忘門、輸出門、細胞狀態皆考慮了 1x1、3x3、5x5、7x7 尺度權重，使此神經架構達到同時考慮多尺度時空之能力。

$$i_t = \sigma \left(\begin{bmatrix} W_{i1x1} * [h_{t-1}, x_t] & W_{i5x5} * [h_{t-1}, x_t] \\ W_{i3x3} * [h_{t-1}, x_t] & W_{i7x7} * [h_{t-1}, x_t] \end{bmatrix} + W_i \right) \circ C_{t-1} \quad (1)$$

$$f_t = \sigma \left(\begin{bmatrix} W_{f1x1} * [h_{t-1}, x_t] & W_{f5x5} * [h_{t-1}, x_t] \\ W_{f3x3} * [h_{t-1}, x_t] & W_{f7x7} * [h_{t-1}, x_t] \end{bmatrix} + W_f \circ C_{t-1} \right) \quad (2)$$

$$C'_t = \tanh \left(\begin{bmatrix} W_{c1x1} * [h_{t-1}, x_t] & W_{c5x5} * [h_{t-1}, x_t] \\ W_{c3x3} * [h_{t-1}, x_t] & W_{c7x7} * [h_{t-1}, x_t] \end{bmatrix} \right) \quad (3)$$

$$C_t = f_t \circ C_{t-1} + i_t \circ C'_t \quad (4)$$

$$o_t = \sigma \left(\begin{bmatrix} W_{o1x1} * [h_{t-1}, x_t] & W_{o5x5} * [h_{t-1}, x_t] \\ W_{o3x3} * [h_{t-1}, x_t] & W_{o7x7} * [h_{t-1}, x_t] \end{bmatrix} + W_o \circ C_t \right) \quad (5)$$

$$h_t = o_t \circ \tanh(C_t)$$

本論文提出之 IConvLSTM 模型解碼器部分使用 8 顆神經元，而編碼器使用倒金字塔參數設計，使用 3x3x3 數量為 16 個卷積核；解碼器中 IConvLSTM 神經元超參數如表 3.4，各尺度堆疊卷積層卷積核數量皆採用倒金字塔設計以 8 顆為初始層卷積核數量，為了合併多尺度計算結果，加入 padding 保證輸出形狀相同，最終為了輸出輸入層、隱藏層、神經元狀態、遺忘門四個計算參數，卷積層輸出通道數等同卷積核數量，因此最後一層卷積核數量為 4。

(四) 模型評估方法

由於 MSE 和 RMSE 會受到離群值的影響(outliers)，對溫度數據集中極值誤差給予較大的權重，因而影響模型參數修正方向，降低模型準確度，因此本論文使用平均絕對誤差(MAE)做為本論文模型以及 Decaying Average 與原始預報場的評估指標。

Mean Absolute Error (MAE) 平均絕對誤差

平均絕對誤差也稱作 L1 損失函數，不考慮誤差

正負方向，只計算預測值與目標值的絕對誤差，其中計算方式(17)為預測值 (f_i) 和實際值 (y_i) 之差的絕對值之和除以樣本個數 (n)，MAE 小表示模型預測誤差小，模型的預測表現佳。

$$MAE = \frac{1}{n} \sum_{i=1}^n |f_i - y_i| \quad (7)$$

三、實驗結果與討論

2017 年至 2019 年測試集預測結果如圖 4.1，可以發現本實驗之 IConvLSTM 與原始預報場、DecayingAverage 於第一天預報場(第 1 小時至第 24 小時)有相似走勢，而 IConvLSTM 預測效果明顯最好，其 24 小時平均 MAE 為 0.7447，原始預報場為 1.9856，DecayingAverage 修正方法為 1.6427，相較原始預報場平均誤差改善程度約為 62%。




圖 6 北台灣溫度預報誤差圖

預測案例視覺化

本論文以 4 個預測案例 ME 誤差視覺圖作為預測效果說明，分別使用 2018 年 8 月 16 日(零點, UTC+0) 第 4 個預報場(中午十二點, UTC+8)及第 14 個預報場(晚上十點, UTC+8); 2018 年 12 月 18 日(零點, UTC+0) 第 5 個預報場(下午一點, UTC+8)及第 18 個預報場(早上兩點, UTC+8)，驗證不同時段模型於夏天(8 月)、冬天(12 月)以及早上、晚上不同時間北台灣網格溫度預測效果，並討論 IConvLSTM 與 DecayingAverage 修正的結果。

表 1 為 2018 年 8 月 16 日(零點, UTC+0) 第 4 個預報場(中午十二點, UTC+8)，使用不同預報技術預測結果，原始預報場整體 MAE 為 1.8140，海洋部分為 1.5204，陸地為 2.1129，DecayingAverage 修正技術整體 MAE 為 1.7670，海洋陸地為 1.7640、1.7684，於陸地地區有 18% 的修正幅度；IConvLSTM

無論海洋或是陸地皆優於原始預報場以及 DecayingAverage 修正技術，整體修正幅度為 20%。

ME 誤差圖中紅色部分為溫度高報地區，藍色為低報地區，白色為誤差正負 0.5 範圍內區域，原始預報場於雪山山脈與宜蘭外海有嚴重高報問題，DecayingAverage 方法減少這兩處高報問題，然而於西部海岸部分則呈現過修正高報問題；IConvLSTM 於此案例中，無論海洋及陸地白色面積皆最大，高低報問題較少。

表 1 2018 年 8 月 16 日第 4 預報場比較表

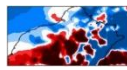

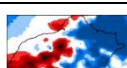
預報場	ME 圖	MAE	海洋 MAE	陸地 MAE
OP		1.8140	1.5204	2.1129
Decaying Average		1.7670	1.7640	1.7684
IConvLSTM		1.4484	1.5812	1.3169

表 2 為 2018 年 8 月 16 日第 14 個預報場(晚上十一點, UTC+8)預測結果，原始預報場整體 MAE 為 1.169，海洋部分為 1.7232，陸地為 0.6114，DecayingAverage 修正技術整體 MAE 為 0.5884 海洋陸地為 0.7239、0.4540，於整體有 50%的修正幅度；IConvLSTM 整體修正幅度為 54%。ME 誤差圖分析部分，原始預報場於雪山山脈與基隆、宜蘭外海皆有嚴重高報問題，DecayingAverage 方法明顯減少海洋與陸地高低報問題；IConvLSTM 於此案例中，同樣明顯減少原始預報場高低報區域，然而於西部海岸呈現輕度高報。

表 2 2018 年 8 月 16 日第 14 預報場比較表

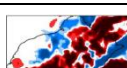
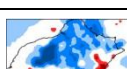
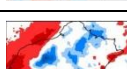
預報場	ME 圖	MAE	海洋 MAE	陸地 MAE
OP		1.169	1.7321	0.6114
Decaying Average		0.5884	0.7239	0.4540
IConvLSTM		0.5320	0.5034	0.5604

表 3 為 2018 年 12 月 18 日第 5 個預報場(下午一點, UTC+8)預測結果，原始預報場整體 MAE 為 1.9467，海洋部分為 1.8028，陸地為 2.0919，DecayingAverage 修正技術整體 MAE 為 1.4505 海洋陸地為 1.8967、1，於陸地區域有較好的預測效果，高達 52%的修正幅度；IConvLSTM 整體修正幅度為 56%。ME 誤差圖分析部分，原始預報場於北台灣有嚴重高、低報問題，DecayingAverage 方法明顯減陸地高低報問題；

IConvLSTM 於此案例中，海洋與陸地白色區域皆最大，效果最好。

表 3 2018 年 12 月 18 日第 5 預報場比較表



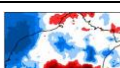
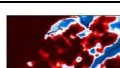
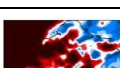
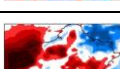
預報場	ME 圖	MAE	海洋 MAE	陸地 MAE
OP		1.9467	1.8028	2.0919
Decaying Average		1.4505	1.8967	1.0
IConvLSTM		0.8393	1.0413	0.6353

表 4 為 2018 年 12 月 18 日第 15 個預報場(晚上十一點, UTC+8)預測結果，原始預報場整體 MAE 為 3.7905，海洋部分為 4.9934，陸地為 2.5780，DecayingAverage 修正技術整體 MAE 為 2.1943 海洋陸地為 2.7791、1.6029，整體修正幅度為 42%；IConvLSTM 整體修正幅度高達 77%。ME 誤差圖分析部分，原始預報場於北台灣有嚴重高、低報問題，DecayingAverage 仍然無法有效解決高低報問題；IConvLSTM 於此案例中，海洋與陸地區域修正效果明顯效果最好。

表 4 2018 年 12 月 18 日第 15 預報場比較表

預報場	ME 圖	MAE	海洋 MAE	陸地 MAE
OP		3.7905	4.9934	2.5780
Decaying Average		2.1943	2.7791	1.6029
IConvLSTM		0.8393	0.5606	0.8812

由以上四個預測案例得證，無論冬天或是夏天，白天或是晚上本論文提出之 IConvLSTM 皆有最佳修正效果，尤其是山地高報地區以及宜蘭外海高報區域。

四、結論與建議

台灣地形極為複雜，同時具有盆地、高原、平原、丘陵、山地五大地形，讓天氣的時空特性變得更為複雜。因此，本論文提出一個基於 GoogleNet Inception 多尺度卷積核的修正版 ConvLSTM 演算法模型，透過捕捉不同地形之特徵來提升模型的預測能力。本研究以所提出的修正演算法對北台灣範圍進行溫度預報誤差修正建模。訓練使用 2017 至 2019 年資料扣除測試集，測試集為三年每月 15 日至 19 日資料。模型預測結果會和原始預報誤差以及 Decaying Average 方法進行比較。

實驗結果顯示，在北台灣第一日預報場，以平均絕對誤差(MAE)做比較。原始預報場、DecayingAverage 和本研究提出模型的 MAE 分別為 1.9855、1.6422 和 0.7347。相較於原始預報場，DecayingAverage 和本研究提出模型的修正幅度分別為 17.29%和 62%。上述結果說明深度時空模型能夠有效校正數值天氣系統的預報誤差，以本研究所提出的修正模型表現最佳。另外，分別比較提出模型與 DecayingAverage 在北台灣的陸地與海洋處之個案。將個案預測結果視覺化後，可以發現本研究提出之模型均優 DecayingAverage，驗證所提出模型已經具有實際作業的預報能力。本論文所使用資料為 2017 至 2019 三年資料作為訓練集與測試集，未來取得新年份溫度資料，由於不同年度氣候狀態可能有所差異，需使用模型預測新資料溫度誤差，驗證模型跨年度預測的泛用性；並使用本研究提出的模型架構擴增至全台 247401 個網格點溫度預測。因為全台混和地形時空特性更加複雜，模型需要做出修正才能於大範圍混和地形進行溫度預報誤差修正。同時若能提供更長時間準確預測幫助人類超前部屬，並進行風險管理，便能創造出更多價值，因此未來可以將此模型延伸至第 2 日預報場(第 25 小時~48 小時)以及第 3 日預報場(第 49 小時~第 72 小時)，驗證 IConvLSTM 模型於長時空資料特性捕捉能力，增加其實用價值。另外，除了對提出模型做進一步的超參數最佳化，也可以考慮納入其他時空演算法機制，如:Attention、TCN、GCN、predrnn、Memory In Memory 等，提升模型的準確度。

溫度預報與人類生活及財產息息相關，準確的溫度預報可以幫助緊急管理並減少經濟損失，創造大量的商業價值，如：農作物種植、冰品銷售、電力調度等。準確預測溫度也可以提供相關單位進行風險管理，提早應對以降低衝擊，並將資源調度最大化，提高商業價值及人類生活品質。人類生活範圍大多為陸地，未來可以針對陸地區域單獨建模，降低海洋特徵對模型的比重，提高陸地區域預測準確度，使人類生活品質能更直接受惠。

參考文獻

- 張蘭慧 (2011)。數值天氣預報產品的即時誤差訂正方法研究及應用。中國蘭州大學博士論文。
- 陳怡儒、洪景山 (2017)。應用 decaying average 方法進行地面溫度預報偏差修正之研究。大氣科學, 45(1), 25-42。
- Agethen, S., & Hsu, W. H. (2019). Deep multi-kernel convolutional lstm networks and an attention-based mechanism for videos. *IEEE Transactions on Multimedia*, 22(3), 819-829.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., ... & Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*.
- Karevan, Z., & Suykens, J. A. (2020). Transductive LSTM for time-series prediction: An application to weather forecasting. *Neural Networks*, 125, 1-9.
- Karevan, Z., & Suykens, J. A. (2020). Transductive LSTM for time-series prediction: An application to weather forecasting. *Neural Networks*, 125, 1-9.
- Kreuzer, D., Munz, M., & Schlüter, S. (2020). Short-term temperature forecasts using a convolutional neural network—An application to different weather stations in Germany. *Machine Learning with Applications*, 2, 100007.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444
- Lin, H., Hua, Y., Ma, L., & Chen, L. (2019, February). Application of ConvLSTM network in numerical temperature prediction interpretation. In *Proceedings of the 2019 11th International Conference on Machine Learning and Computing* (pp. 109-113).
- Lotter, W., Kreiman, G., & Cox, D. (2016). Deep predictive coding networks for video prediction and unsupervised learning. *arXiv preprint arXiv:1605.08104*.
- Sayeed, A., Choi, Y., Jung, J., Lops, Y., Eslami, E., & Salman, A. K. (2020). A Deep Convolutional Neural Network Model for improving WRF Forecasts. *arXiv preprint arXiv:2008.06489*.
- Shi, X., Chen, Z., Wang, H., Yeung, D. Y., Wong, W. K., & Woo, W. C. (2015). Convolutional LSTM network: A machine learning approach for precipitation nowcasting. *arXiv preprint arXiv:1506.04214*.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., & Rabinovich, A. (2015). Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1-9).
- Tekin, S. F., Karaahmetoglu, O., Ilhan, F., Balaban, I., & Kozat, S. S. (2021). Spatio-temporal Weather Forecasting and Attention Mechanism on Convolutional LSTMs. *arXiv preprint arXiv:2102.00696*.
- Zhu, G., Zhang, L., Shen, P., & Song, J. (2017). Multimodal gesture recognition using 3-D convolution and convolutional LSTM. *Ieee Access*, 5, 4517-4524.

The Study on Multi-scale Convolutional Long Short-Term Memory Neural Network for Temperature Bias Prediction

Abstract

Weather forecasting is closely related to human life and property. Accurate weather forecasting can help emergency management and reduce economic loss, and create a lot of business value. improve business value and human quality of life.

Traditional numerical weather prediction system is a method to predict future climate by inputting weather data from weather stations, weather radar and balloons, and constructing weather prediction models through supercomputers to deduce complex atmospheric equations. Due to the complexity and uncertainty of weather, it is not possible to adapt to the mathematical formula, thus generating weather prediction errors, and there is still a long way to go to correct weather prediction errors and improve the accuracy of prediction.

the Central Weather Bureau, MOTC currently uses the Decaying Average method for temperature forecast error correction. The Decaying Average method uses a fixed weight to calculate the delayed relationship between the current point in time and the temperature forecast error of the previous moment, which has achieved good results, but there is still a gap with the actual observation.

In recent years, the development of deep learning and the advancement of computer computing power have led to the gradual formation of deep learning algorithms for weather prediction, among which the long convolutional long short-term memory neural network has become the classical algorithm for capturing the spatial and temporal characteristics of weather.

This paper uses a deep learning model to correct the error of the first day of temperature prediction in Northern Taiwan, and uses three years of data from the Central Weather Bureau from 2017 to 2019 from the 15th to the 19th of each month as the test set, and three years of data minus the test set for modeling.

The result shows that the Mean Absolute Error (MAE) of the Day 1 forecast field in Northern Taiwan. The MAEs of the original forecast field, DecayingAverage, ConvLSTM model and the proposed model are 1.9855, 1.6422, 0.9201 and 0.7347, respectively. the depth-time model can effectively correct the forecast errors of the numerical weather system, among which the proposed model performs the best.

Keywords: Decaying Average, ConvLSTM, spatio-temporal sequence ,deep learning, Forecast error correction, NWP