

臺灣測站月季平均溫度綜合預報技術發展

陳苡甄¹ 馮智勇¹ 劉人鳳² 陳孟詩²
多采科技有限公司¹ 中央氣象局²

摘要

氣候動力模式存在系統性偏差和低解析度等問題，這會影響模式系集預報衍伸至臺灣測站月季機率預報發展，因此，透過統計後處理方式可提升多模式系集預報系統的技術和可靠度。本研究使用CWB2T2、CWB1T1和NCEP CFSv2重預報資料發展月季溫度綜合預報四步驟流程。首先，採用分位數映射法(Quantile Mapping, QM)用於移除模式原始預報的系統性偏差，接著使用校準(Calibration model)和橋接(Bridging model)模型得到測站降尺度預報。以測站相鄰四個模式格點溫度預報迴歸作為校準模型，以模式輸出的遙相關大尺度環流指標迴歸作為橋接模型。最後，經由貝氏模型平均法(Bayesian Model Average, BMA)整合降尺度預報並假設其條件機率為常態分布。透過遮蔽年實驗採交叉驗證方式評估前三個月預報技術與可靠度，結果顯示，測站溫度BMA預報不僅僅是在冬夏季對於月預報也是有技術性的。該流程目前已作業化定期產製預報產品，並以2019年整年溫度預報進行預報表現評估。

關鍵字：貝氏模型平均法、分位數映射法

一、前言

隨著多模式與系集模式預報指引快速增加，而氣候動力模式存在系統性偏差和低解析度問題，預報人員於作業階段實不易快速且有效整合大量預報資訊，也不利於由北中南東的四個代表測站擴增至全臺綜觀測站站點以提高預報精緻度。

氣象局已於「研發短期氣候綜合預報系統計畫案」、「小區域天氣與短期氣候統計預報技術之研發案」，針對臺灣25測站月季平均溫度預報作業需求發展以貝氏模型平均法為核心技術的統計後處理作業化流程，建置包含代表預報、偏差校正、統計降尺度以及綜合預報等四步驟建置流程。透過統計後處理方式，首先移除模式原始預報的系統性偏差並進行測站降尺度預報，最後經由BMA估計權重與變異數參數而整合為一個描述完整溫度量值的機率密度函數(Probability Density Function, PDF)，再依據測站觀測氣候值提供偏低/正常/偏高的三分類預報指引，可依此發展臺灣高解析格點平均溫度綜合預報指引以及臺灣測站月季累積雨量綜合預報指引。「天氣與短期氣候統計後處理技術之研發委外案」完成適用於臺灣地區平均溫度與累積雨量的通用綜合預報指引產製系統，可將綜合預報建置於臺灣測站與模式格點。

以下先行說明Raftery等人提出的BMA機率預報模型與參數估計方式，並以BMA為核心技術開發一套適用於測站與格點平均溫度與累積雨量的通用綜合預報指引產製系統以及測站溫度BMA預報模型建置方案，透過歷史資料以交叉驗證方式(即遮蔽預報年)

評估前三個月預報技術與可靠度，最後綜整研究結論與建議，以為後續發展作業系統參考。

二、BMA機率預報模型建置

假設測站溫度觀測值為 y ，而 K 種模式的預報值為 M_1, M_2, \dots, M_k 並且已知資料 D 的情況下，BMA模型描述物理量發生的機率為：

$$p(y|D) = \sum_{k=1}^K p(M_k|D) p(y|M_k, D) \quad (1)$$

其中， $p(y|M_k, D)$ 為各模式利用已知資料 D 估計 y 發生之條件機率密度函數，而 $p(M_k|D)$ 則為各模式的後驗機率，代表模式擬合 D 資料的優劣程度。由於當模式數量大於1時，必須滿足 $\sum_{k=1}^K p(M_k|D) = 1$ 的條件，因此後驗機率可視為權重值。

Raftery等人假設 f_1, f_2, \dots, f_k 分別代表 K 種系集模式成員經過系統性誤差調整後的『最佳』預報值，而 $g_k(y|f_k)$ 為在已知 f_k 時的 y 條件機率密度函數，則BMA模型描述溫度發生機率為：

$$p(y|f_1, f_2, \dots, f_k) = \sum_{k=1}^K \omega_k g_k(y|f_k) \quad (2)$$

其中， ω_k 為第 k 個成員的後驗機率，代表第 k 個模式在訓練期中成為最佳預報的機率，並滿足條件 $\sum_{k=1}^K \omega_k = 1$ ； $g_k(y|f_k)$ 表示在給定預報值 f_k 條件下 y 的PDF。因此BMA模型的預報PDF可視為 K 個模式預報PDF的加權平均，意即以每個模式的後驗機率 ω_k 為權重進行加權平均。當物理量為溫度時，模式預報與實際觀測數據分布會非常接近常態分布 (normal

distribution)，因此可假設 $g_k(y|f_k)$ 為常態分布，其平均值為 $a_k + b_k f_k$ ，標準差為 σ ，可表示為：

$$y|f_k \sim N(a_k + b_k f_k, \sigma^2) \quad (3)$$

因此，BMA模型描述物理量發生機率的期望值為：

$$E(y|f_1, f_2, \dots, f_k) = \sum_{k=1}^K \omega_k (a_k + b_k f_k) \quad (4)$$

BMA模型中之未知參數 a_k 、 b_k 、 ω_k 及 σ ，需透過訓練期資料進行估計。其中， a_k 與 b_k 可使用簡單線性迴歸 (simple regression) 逐站進行估算，代表各模式系統性誤差校正參數； ω_k 及 σ 則透過最大化概似函數 (maximum likelihood) 的過程進行估計。假設預報誤差在時間 (t) 與空間 (s) 上不相關，對數概似函數可寫為 $\sum_{st} \log \left(\sum_{k=1}^K \omega_k g_k(y_{st}|f_{kst}) \right)$ ，則可透過EM演算法求解 ω_k 及 σ 。

EM演算法分為E步驟 (Expectation) 計算概似函數，與M步驟 (Maximization) 找出最大化概似函數的最佳化參數。首先假設一個潛在變數 z_{kst} ，當 $z_{kst}=1$ 時，代表第k個模式在s測站及t時間時有為最佳預報值，反之則 $z_{kst}=0$ ；意即 $\{z_{1st}, z_{2st}, \dots, z_{kst}\}$ 中只有一個為1，其餘皆為0。求解時先給定待估計參數 ω_k 及 σ 初始猜測值，於第j次迭代的E步驟中計算：

$$\hat{z}_{kst}^{(j)} = \frac{\omega_k^{j-1} g(y_{st}|f_{kst}, \sigma^{(j-1)})}{\sum_{i=1}^K \omega_i^{j-1} g(y_{st}|f_{ist}, \sigma^{(j-1)})} \quad (5)$$

式中， $g(y_{st}|f_{kst}, \sigma^{(j-1)})$ 代表期望值為 $a_k + b_k f_{kst}$ ，標準差為 $\sigma^{(j-1)}$ 的常態分布函數。計算 $\hat{z}_{kst}^{(j)}$ 後，再於M步驟中計算 ω_k 及 σ 為：

$$\omega_k^{(j)} = \frac{1}{n} \sum_{s,t} \hat{z}_{kst}^{(j)} \quad (6)$$

$$\sigma^{2(j)} = \frac{1}{n} \sum_{s,t} \sum_{k=1}^K \hat{z}_{kst}^{(j)} (y_{st} - f_{kst})^2 \quad (7)$$

其中，n為訓練資料數。反覆迭代計算式(5)~式(7)的過程將使概似函數值逐漸增加，直到相鄰兩次迭代的對數概似函數值的相對誤差小於1E-10時(或迭代次數達10,000次)，參數 ω_k 及 σ 收斂完成求解。

三、臺灣測站溫度BMA預報校驗

(一) 通用綜合預報指引產製系統流程架構

圖1為這套通用綜合預報指引產製系統，包含代表預報、偏差校正、統計降尺度以及綜合預報等四步驟流程架構。在有限的訓練期資料量以及每個預報因子有權重與變異數兩個待估參數，基於數學上的考量要求解的未知數需遠小於建模資料量，建議使用系集模式的代表性預報，因此溫度使用系集平均 (mean/MME)。採用QM法用於移除模式原始預報的系統性偏差。參考Schepen et al.(2014)作法分成 Calibration model和Bridging model得到測站降尺度預報。最

後，經由BMA整合降尺度預報並假設其條件機率為常態分布。

(二) 測站溫度BMA預報模型建置方案

圖2左側為測站溫度BMA預報模型建置方案，採平地站一起建模，山區、離島站各自建模。平地站一起建置增加訓練期資料量提高獲得最佳解唯一解的機率，受到地理位置差異山區、離島各自建模。

而測站降尺度預報使用三個模式的溫度預報空間內插至測站，三個模式的溫度預報以相鄰四個模式格點溫度預報迴歸觀測溫度，三個模式以副熱帶高壓 (GH)、東亞主槽 (CuiXP) 等氣候指標迴歸觀測溫度，以及CWB1T1、CFSv2模式以南海海溫指標 (SCS) 迴歸觀測溫度，透過BMA整合所有測站降尺度預報共14個預報因子。圖2右側標示所使用的氣候指標範圍。

(三) 機率預報校驗方法

1. 準確率 (Percent Correct, PC)

PC用於評估預報命中正確類別的比例。如下表預報和觀測透過各自門檻分成三分類，分析這次預報相較於預報門檻是落在偏低/正常/偏高，對應的觀測也依照觀測門檻評估是落在偏低/正常/偏高，統計所有樣本並依照式(8)計算即可求得PC值。PC=1時為完美預報，值域介於 0~1 之間。

FST \ OBS	Below	Normal	Above
Below	N₁₁	N ₂₁	N ₃₁
Normal	N ₁₂	N₂₂	N ₃₂
Above	N ₁₃	N ₂₃	N₃₃

$$PC = (N_{11} + N_{22} + N_{33}) / N_{total} \quad (8)$$

2. 機率預報技術得分 (Ranked Probability Skill Score, RPSS)

RPSS用於評估三分類機率預報誤差相對於氣候值機率的技術，如式(9)：

$$RPSS = 1 - RPS / RPS_{ref} \quad (9)$$

其中

$$RPS = \sum_{n=1}^k (Y_n - O_n)^2 \quad (10)$$

Y_n 為預報之累積機率， O_n 為觀測之累積機率。 RPS_{ref} 為氣候值之RPS (本研究定義為0.33, 0.34, 0.33)。RPSS=1時為完美預報，介於 0~1 之間代表有預報技術，若小於 0 則代表沒有預報技術。

(四) 測站溫度BMA歷史預報校驗

圖3、4為測站溫度BMA預報與系集模式直接內插至測站溫度預報的PC和RPSS校驗。藍線為BMA預報，綠線為MME，其餘為單一系集模式。上至下為前一至三個月預報目標時間，左(右)為月(季)預報。顯示BMA與MME在類別預報表現相當，三分類機率預報以BMA穩定優於MME與單一系集模式，且分季預報校驗結果會明顯優於分月預報。

目前通用綜合預報指引產製系統每月自動產製臺灣25個測站未來三個月(季)溫度三分類預報指引。圖5(左)為測站溫度BMA PDF，線條顏色代表不同降尺度方法，線條種類代表不同氣候模式，透過訓練期資料BMA給予不同預報因

子權重與標準差，紅線為整合所有預報因子的BMA PDF，再依據測站觀測氣候值提供偏低/正常/偏高的三分類預報指引，BMA期望值預報以紅實心表示(EXP)，校驗階段標示預報對應觀測以黃色星號表示(OBS)。圖5(右)為測站溫度BMA三分類機率預報空間分布，將所有測站三分類機率預報以直條圖繪製於地圖上，標示測站觀測氣候值的門檻與三分類機率預報。校驗階段標示觀測所在類別(黃色星號)，並於右下角紀錄預報命中觀測類別的測站數，評估三分類機率預報的準確性。

統計2019年作業化定期產製臺灣25個測站未來三個月(季)溫度預報指引，評估BMA三分類最大面積命中觀測類別的比例，如圖6所示，紅/黃/藍長條圖依序為前一至三個月預報目標時間，左(右)為月(季)預報。顯示多數時間都有六至八成的命中率，五月為特例因模式都預報偏高但觀測落在偏低。

四、結果討論

利用BMA客觀整合CWB2T2、CWB1T1和NCEP CFSv2輸出資料，每月自動產製臺灣25個測站未來三個月(季)溫度及雨量三分類預報指引。校驗結果顯示BMA產品多數時間可優於模式系集平均預報指引。

將月(季)長期預報由北中南東的四個代表測站擴增至全臺綜觀測站站點，目標是發展至臺灣高解析網格提高預報精緻度。

BMA以較少資料量即可提供與MME相當水準預報，並具提供溫度量值預報的可行性。BMA提供完整機率密度函數，後續衍生產品將不再侷限於三分類機率預報。

五、參考文獻

1. 交通部中央氣象局，2016、2017：「研發短期氣候綜合預報系統計畫案」期末報告
2. 交通部中央氣象局，2018：「小區域天氣與短期氣候統計預報技術之研發案」期末報告
3. 交通部中央氣象局，2019：「天氣與短期氣候統計後處理技術之研發委外案」期末報告
4. Peng, Z., Q. Wang, J. C. Bennett, P. Pokhrel, and Z. Wang, 2014: Seasonal precipitation forecasts over China using monthly large-scale oceanic-atmospheric indices. *J. Hydrol.*, 519, 792–802.
5. Peng, Z., Q. Wang, J. C. Bennett, A. Schepen, F. Pappenberger, P. Pokhrel, and Z. Wang, 2014: Statistical calibration and bridging of ECMWF System4 outputs for forecasting seasonal precipitation over China. *J. Geophys. Res. Atmos.*, 119, 7116–7135.
6. Raftery, A. E., T. Gneiting, F. Balabdaoui, and M. Polakowski, 2005: Using Bayesian model

averaging to calibrate forecast ensembles. *Mon. Wea. Rev.*, 133, 1155–1174.

7. Schepen, A., Q. J. Wang, and D. E. Robertson, 2014: Seasonal forecasts of Australian rainfall through calibration and bridging of coupled GCM outputs. *Mon. Wea. Rev.*, 142, 1758–1770.
8. Strazzo, S., D.C. Collins, A. Schepen, Q. Wang, E. Becker and L. Jia, 2019: Application of a Hybrid Statistical–Dynamical System to Seasonal Prediction of North American Temperature and Precipitation. *Mon. Wea. Rev.*, 147, 607–625.

六、附圖

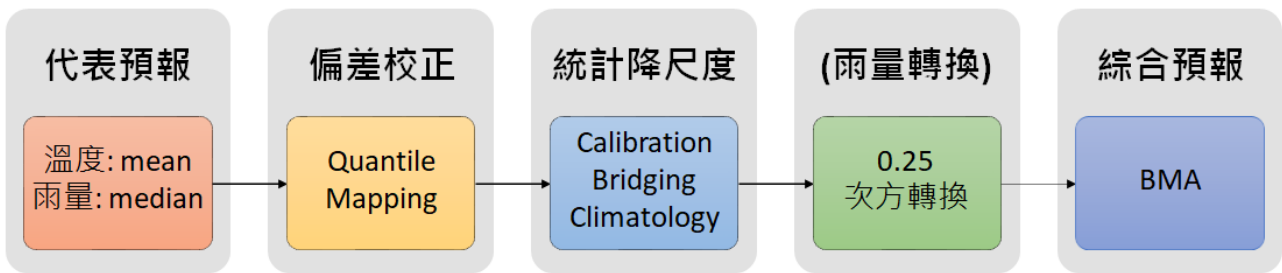


圖1 為通用綜合預報指引產製系統，包含代表預報、偏差校正、統計降尺度以及綜合預報等四步驟流程架構

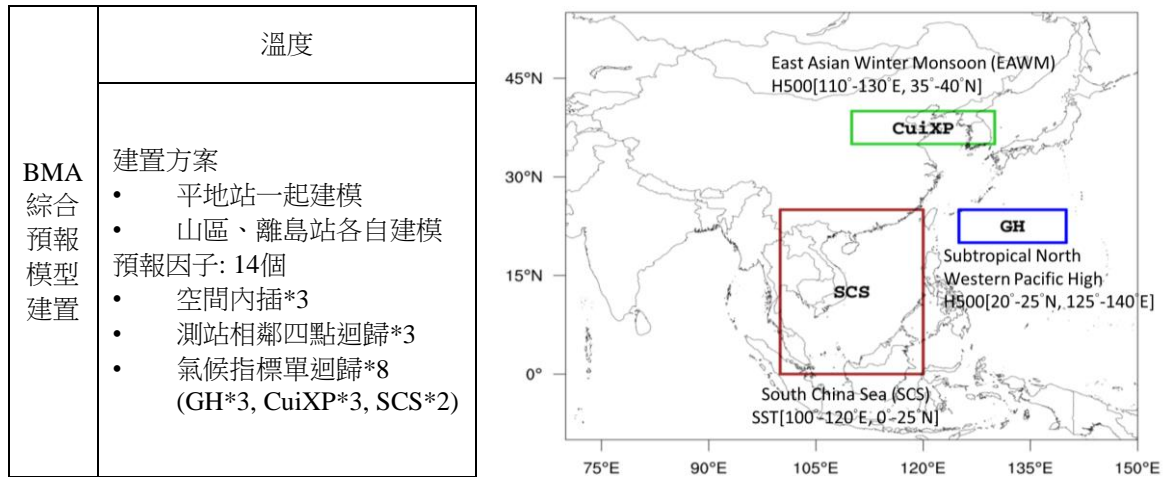


圖2 為測站溫度BMA綜合預報模型建置方案以及使用的氣候指標範圍

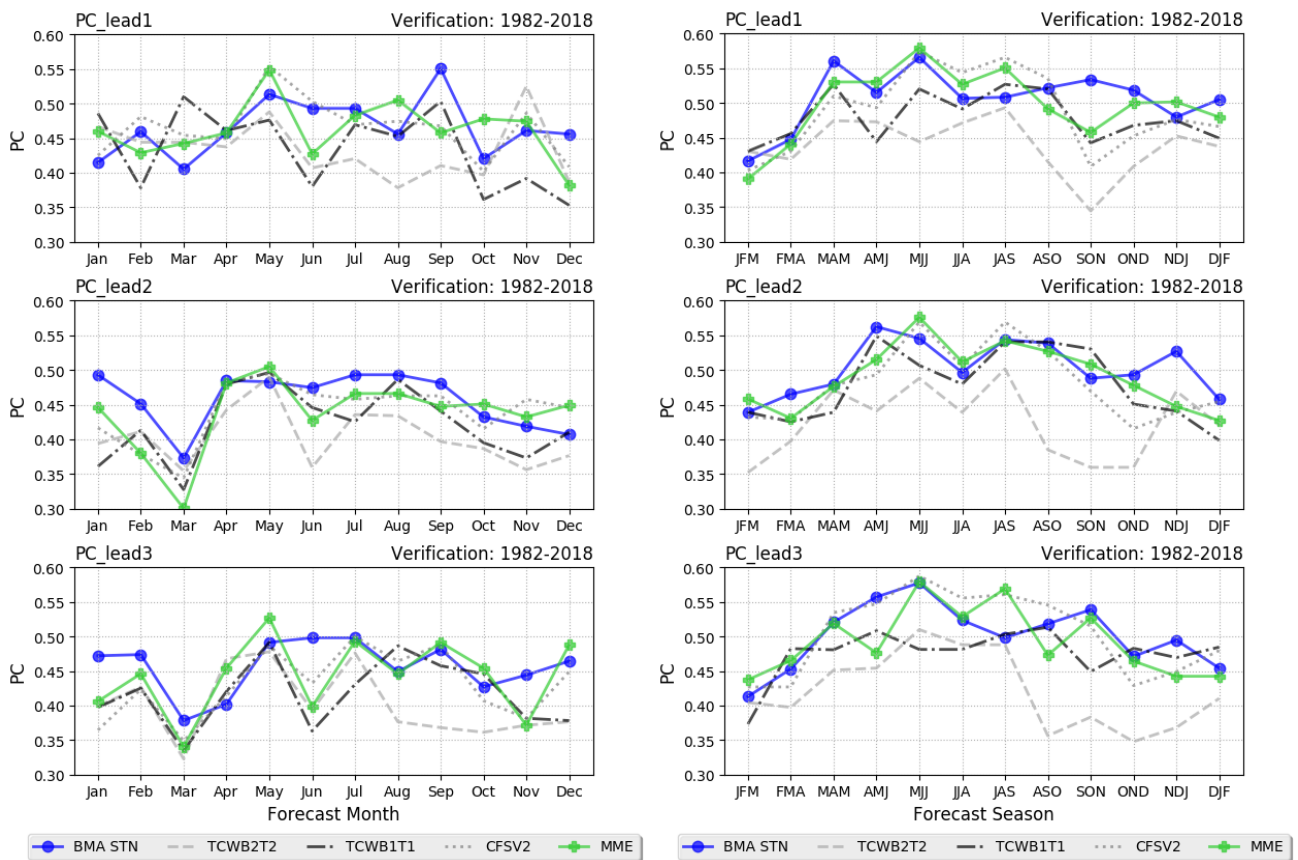


圖3 為測站溫度BMA預報與系集模式直接內插至測站溫度預報的類別預報校驗 (PC)

藍線為BMA，綠線為MME，其餘為單一系集模式

上至下為前一至三個月預報目標時間，左(右)為月(季)預報

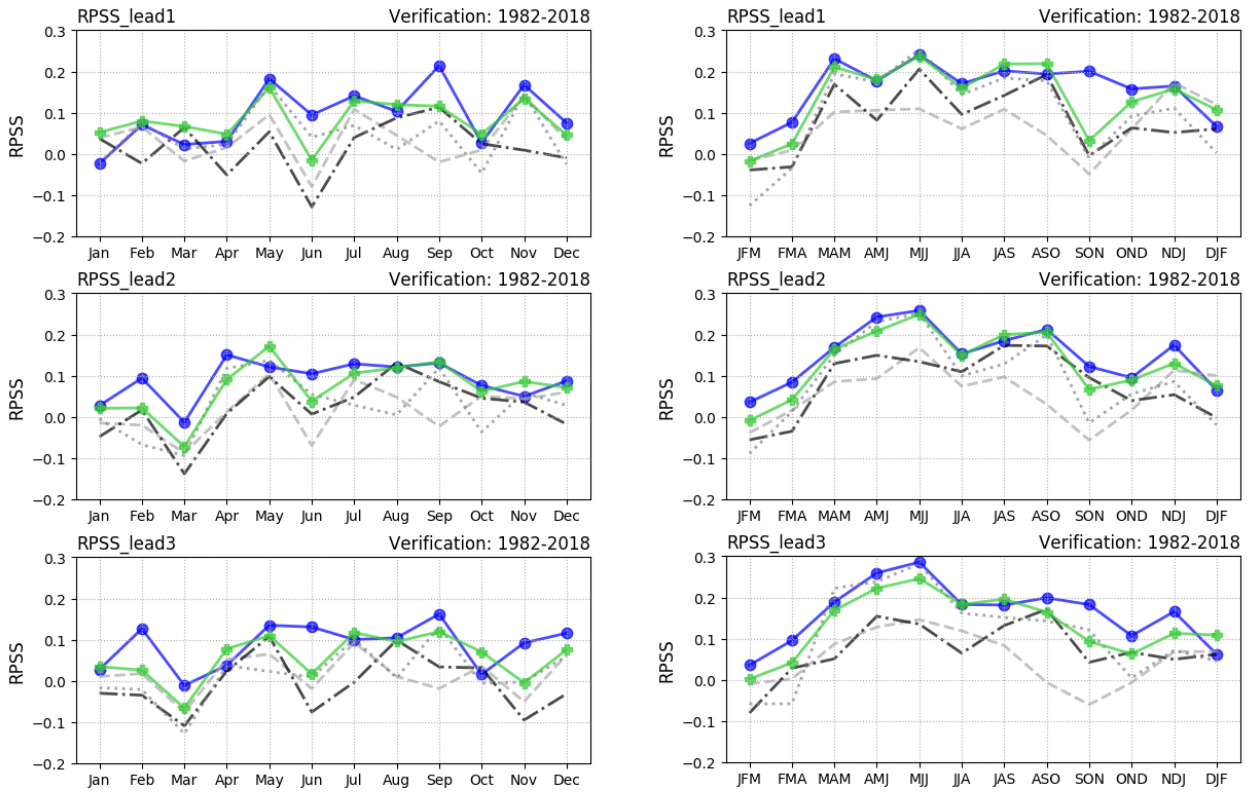


圖4 同圖3，為三分類累積機率預報校驗 (RPSS)

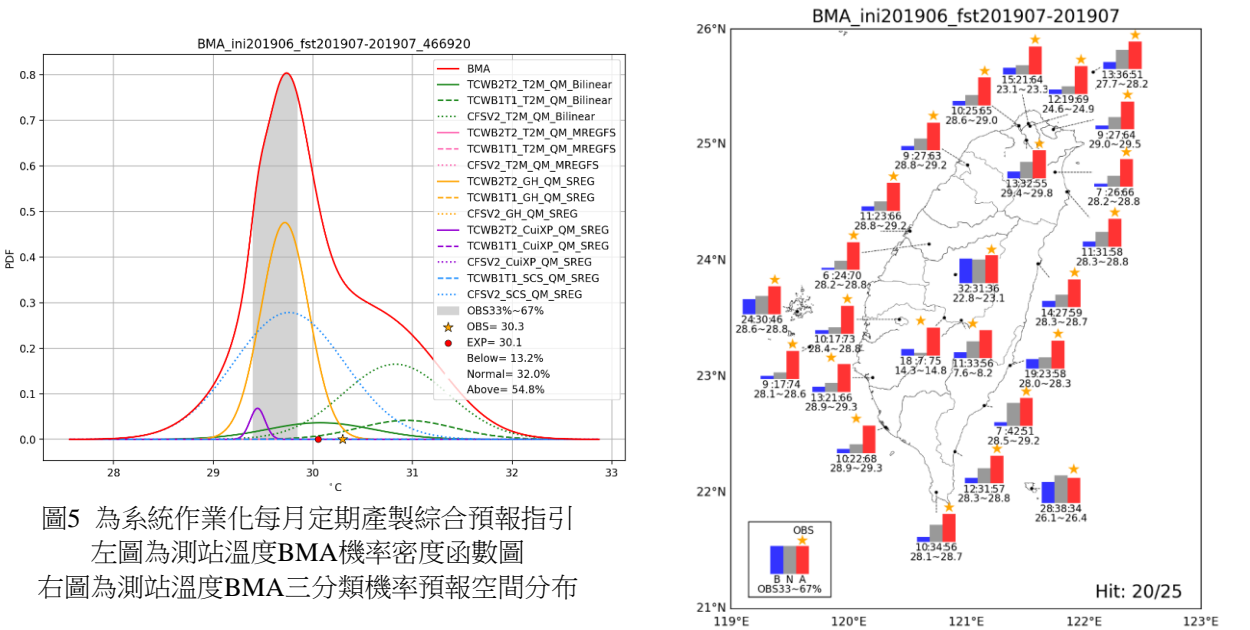


圖5 為系統作業化每月定期產製綜合預報指引
左圖為測站溫度BMA機率密度函數圖
右圖為測站溫度BMA三分類機率預報空間分布

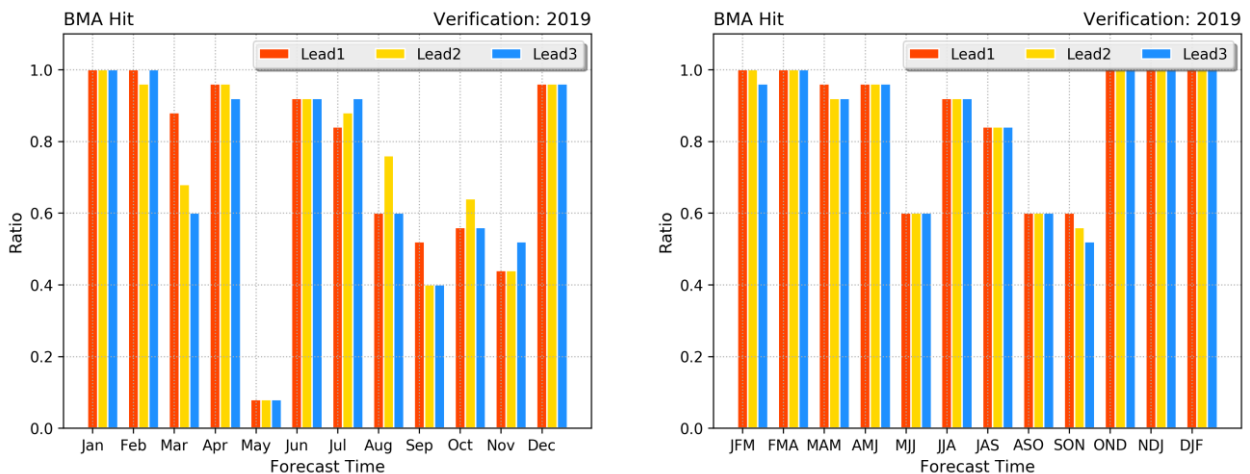


圖6 為2019年作業化定期產製未來三個月(季)測站溫度BMA三分類最大面積命中觀測類別的比例
紅/黃/藍長條圖依序為前一至三個月預報目標時間

Development of an integrated statistical-dynamical forecast model to monthly and seasonal Temperature Prediction in Taiwan

**Yi-Chen Chen¹, Chih-Yung Feng¹, Enya Ren-Feng Liu², Meng-Shih Chen²
Manysplendid Infotech Ltd., Taipei, Taiwan¹
Central Weather Bureau, Taipei, Taiwan²**

Abstract

Dynamical climate models suffer from systematic biases and low resolution, which prevents deriving Taiwan station-wise seasonal and monthly probabilistic forecasts from ensemble members. Hence, statistical postprocessing methods can improve the skill and reliability of multi-model ensemble forecasting systems. This study proposes a procedure for deriving seasonal temperature forecasts from CWB2T2, CWB1T1 and NCEP CFSv2 reforecasts. First, quantile mapping (QM) is used for removing ensemble mean bias in the raw forecast. Then, calibration and bridging models were used to obtain station-wise downscaling forecasts. Calibration models are established using the ensemble mean temperature of the nearest four model grid points surrounding a station as predictors. Bridging models are built using model reforecasts of relevant large-scale oceanic-atmospheric indices as predictors. Finally, all these downscaling forecasts are merged through Bayesian model averaging (BMA) under a conditional normal distribution assumption. Forecast skill and reliability are evaluated through a leave-one-year-out cross-validation for 1-month to 3-month lead forecasts. Results show that the station-wise BMA consensus temperature probabilistic forecasts are skillful not only for summer and winter but also for monthly ones. The proposed procedure has been implemented to regularly produce experimental forecast guidance for 2019.

Key word: Bayesian Model Average, Quantile Mapping