

吴柏莹,智协飞,陈超辉,等,2022. 基于复卡尔曼滤波技术的华东区域风的多模式集成预报研究[J]. 气象,48(4):393-405. Wu B Y, Zhi X F, Chen C H, et al, 2022. Multi-model ensemble forecasts of wind over East China by using augmented complex extended Kalman filter[J]. Meteor Mon, 48(4):393-405(in Chinese).

基于复卡尔曼滤波技术的华东区域风的多模式集成预报研究^{*}

吴柏莹^{1,2} 智协飞^{1,2} 陈超辉³ 张秀年⁴

1 南京信息工程大学气象灾害预报预警与评估协同创新中心/气象灾害教育部重点实验室, 南京 210044

2 天气在线气象应用研究所, 江苏无锡 214000

3 国防科技大学气象海洋学院, 长沙 410073

4 云南省气象台, 昆明 650034

提 要: 基于欧洲中期天气预报中心的业务预报系统(EC)、美国国家环境预报中心的全球预报系统(GFS)、我国的中尺度数值业务预报系统(CMA-MESO)和全球预报系统(CMA-GFS)这 4 个预报系统的华东及周边地区($20^{\circ}\sim 40^{\circ}\text{N}$, $110^{\circ}\sim 130^{\circ}\text{E}$) 2020 年 1—4 月逐日地面和高空风的 0~72 h 预报资料, 利用复卡尔曼滤波方法(augmented complex extended Kalman filter, ACEKF)对其进行多模式集成预报试验, 并对结果进行检验和评估。结果表明, ACEKF 方法的预报效果优于多模式消除偏差集合平均、多模式超级集合预报等方法, 能够进一步降低风速预报的误差, 提高风场预报的预报准确率。ACEKF 在高空风速预报上的改进效果要优于地面风速预报, 在地形复杂地区改进效果更优, 在所有预报时效的均方根误差和距平相关系数上均有体现。

关键词: 复卡尔曼滤波技术, 多模式集成预报, 风速, 数值预报

中图分类号: P456

文献标志码: A

DOI: 10.7519/j.issn.1000-0526.2022.011901

Multi-Model Ensemble Forecasts of Wind over East China by Using Augmented Complex Extended Kalman Filter

WU Baiying^{1,2} ZHI Xiefei^{1,2} CHEN Chaohui³ ZHANG Xiunian⁴

1 Collaborative Innovation Center on Forecast and Evaluation of Meteorological Disasters/Key Laboratory of Meteorological Disasters, Ministry of Education, Nanjing University of Information Science and Technology, Nanjing 210044

2 Weather Online Institute of Meteorological Applications, Jiangsu, Wuxi 214000

3 Institute of Meteorology and Oceanography, National University of Defense Technology, Changsha 410073

4 Yunnan Meteorological Observatory, Kunming 650034

Abstract: Based on EC, GFS, CMA-MESO and CMA-GFS, the 0–72 h ensemble forecasts of daily surface and high-altitude zonal wind and meridional wind from January to April 2020 from the four models for East China and surrounding areas ($20^{\circ}\sim 40^{\circ}\text{N}$, $110^{\circ}\sim 130^{\circ}\text{E}$) are evaluated with the augmented complex extended Kalman filter (ACEKF) method. The results show that the ACEKF method outperforms the bias-removed ensemble mean, super-ensemble forecast and single-mode forecasts, and can further reduce the

^{*} 华东空管局研发项目(2019h463)、国家自然科学基金重大研究计划集成项目(91937301)和中国气象局气象预报业务关键技术的发展专项[YBGJXM(2020)5A]共同资助

2021 年 1 月 21 日收稿; 2022 年 1 月 19 日收修定稿

第一作者: 吴柏莹, 主要从事数值天气预报研究. E-mail: wubaiying@foxmail.com

通讯作者: 智协飞, 主要从事数值天气预报、气候变化及人工智能应用研究. E-mail: zhi@nuist.edu.cn

wind speed forecast errors. ACEKF can improve the upper-air wind speed forecasts better than those at ground level. In complex terrain areas the improved wind speed forecast is much better. These results are also reflected in the root-mean-square error and anomaly correlation coefficient for all forecast times.

Key words: augmented complex extended Kalman filter (ACEKF), multi-model ensemble forecast, wind speed, numerical prediction

引 言

大气是高度非线性的混沌系统、数值模式初始场具有不确定性、物理过程参数化方案还不够完善, 这几点因素导致单一数值预报存在预报不确定性问题。集合预报技术基于大气非线性运动使得传统的确定性预报向概率预报转变, 从而能为用户提供更全面完整的信息(Leith, 1974)。

目前最具代表性的全球集合预报系统(global ensemble prediction system, GEPS)包括美国国家环境与预报中心, 欧洲中期天气预报中心和加拿大气象局(Canadian Meteorological Centre, CMC), 这几个中心所采用的初始扰动方法与集合预报结果都有一定差异, 国内对集合预报的研究也方兴未艾。田伟红和庄世宇(2008)采用集合变换卡尔曼滤波(ensemble transform Kalman filter, ETKF)方法对我国的 GRAPES 预报模式做集合预报的扰动, 取得一定效果。不同国家的模式在分辨率、参数化方案、资料同化等方面差异明显, 各有优劣。所以, 如果能将各模式结果组合起来, 整合优点, 可以减小单个模式的系统误差, 多模式集成预报这个概念应运而生。Krishnamurti et al(1999)将多元线性回归方法应用到多模式集成预报之中, 这也是最早被提出的超级集合预报方法。经对比分析结果, 超级集合预报提高了天气尺度预报和季节尺度气候预测的预报技巧, 比单个模式的预报效果优秀。

多模式集成预报在我国的研究与应用虽然起步较晚, 但也已取得许多成果。智协飞等(2009)基于 TIGGE 资料中气温这个物理量, 进行不同地区的超级集合预报试验, 发现超级集合预报误差比单模式预报减小很多。张涵斌等(2015)也集合了 TIGGE 下各模式预报资料, 得到了西太平洋气旋预报, 效果较好。林春泽等(2009)发展了滑动训练期消除偏差集合平均(running-bias removed ensemble mean, R-BREM)和滑动训练期超级集合预报(running super-ensemble forecast, R-SUP), 训练期每日向

后滑动, 使得每次预报的都为训练期后一天的日期, 降低了季节影响的误差, 预报效果优于固定的训练期。在地面气温的延伸期预报中, 崔慧慧和智协飞(2013)也证明了多模式集成能够较好地改善单模式预报效果。Zhi et al(2012)研究了 2007 年北半球夏季地面 2 m 气温, 其结果表明短期的预报(24~72 h), 超级集合的预报效果要远优于单个模式的预报结果, 而对于中短期的预报(96~168 h), 超级集合预报也能有效改善集合成员的预报结果。针对集合降水预报订正, 目前贝叶斯模式平均和频率匹配订正法业务上较为常用, 已有不少研究。针对不同区域降水预报采用分级贝叶斯模式平均改进(Ji et al, 2019; 祁海霞等, 2020)。频率匹配订正法在集合降水预报订正上, 明显消除了大范围小雨空报, 提高了晴雨预报准确率, 降水落区分布更加合理(智协飞和吕游, 2019; 李俊等, 2015)。Ji et al(2020)还采用基于目标的 MODE 评估(method for object-based diagnostic evaluation)对多模式降水预报进行集合, 所得预报结果优于传统的基于点对点评估的多模式超级集合预报。近年来, 人工智能方法在科学计算、回归预测模型上应用较广。应用到多模式集成预报之中的神经网络方法, 也显露一定的优势。智协飞等(2020)和 Peng et al(2020)利用浅层神经网络、长短期记忆神经网络、自然梯度提升等机器学习方法与传统多模式集成预报方法进行对比, 发现 LSTM 方法对于较长预报时效的地面气温预报改进效果较好, 更多改进在我国西北、华北、东北等地区。上述研究均已充分证明了多模式集成预报的相对优越性, 可用于业务预报中, 更好地提高气象服务水平。

卡尔曼滤波是一种根据观测和预报数据自适应迭代权重系数减小误差的有力工具。它的迭代计算过程较为简单, 线性拟合能力较强, 对于噪声的处理效果好, 因此被广泛应用。然而将卡尔曼滤波应用于多模式集成预报的研究目前并不多, 尤其在气象领域。基于卫星降水资料, Krishnamurti et al(2003)采用卡尔曼滤波, 对卫星降水资料进行线性

拟合,这也是该方法在气象领域中的较早尝试。随后,Rixen et al(2009)、Rixen and Fevreira-Coelho(2007)与 Lenartz et al(2010)利用卡尔曼滤波集合各个海洋模式的结果,对48 h海表温度的预报也取得较好效果。智协飞和黄闻(2019)基于TIGGE资料集中多个模式预报的结果,利用卡尔曼滤波方法对气温和降水预报进行多模式集成预报研究,发现该方法对地面2 m气温和短预报时效的降水均有明显改进。智协飞和赵忱(2020)将卡尔曼滤波技术和频率匹配法相结合,对2016年夏季中国区域降水预报进行了订正,发现降水落区预报和降水中心的量级预报效果均比其他多模式集成预报更加准确。近年来,数值模式日益提高了高低层大尺度变量(如500 hPa高度场、地面温度等)的预报准确率。然而,对于风场的预报仍然存在较大误差,并且风场作为一种具有二维变量的要素,除了对各分量进行预报,还需要考察矢量风场纬向和经向分量之间的联系和配合,这也是目前风场预报存在不足的部分原因。He et al(2015)将卡尔曼滤波方法进行扩展变形,将台风位置表示成复数,实部(虚部)表示台风路径的经度(纬度),在台风路径的多模式集成预报中取得较好效果。这种适用于二维矢量订正的复卡尔曼滤波方法在本文中被应用于风场的预报订正。

卢晔等(2015)分析总结了华东区域风速变化特征。华东地区海岸线绵长,作为我国一大平原地带,不仅地理位置特殊而且人口密集,对风场预报的准确预报对于航空和风能开发都具有重要的意义。本文对2020年1—4月华东区域地面和高空风速的预报资料进行多模式集成预报试验。

1 资料与方法

1.1 资料

1.1.1 模式预报资料

①欧洲中期天气预报中心(European Centre for Medium-Range Weather Forecasts, ECMWF)风场预报资料(u, v),地面水平分辨率为 0.125° ,高空各层水平分辨率为 0.25° ,逐日起报时间为12:00 UTC,预报时效为0~72 h,每隔3 h输出一次预报结果。垂直层次主要包括700、850、925、950和1000 hPa、地面10 m等。时间取2020年1月13日至4月13日。研究区域取 $20^\circ\sim 40^\circ\text{N}$ 、 $110^\circ\sim 130^\circ\text{E}$ 。

②同期、同区域中国气象局的中尺度数值业务预报系统(CMA-MESO)风场预报资料,各层水平分辨率均为3 km,初始场时间间隔为24 h,逐日起报时间为12:00 UTC,预报时效为0~72 h,每隔3 h输出一次预报结果。垂直层次主要包括700、750、800、850、900、925、950、975和1000 hPa、地面10 m等。

③同期、同区域美国国家环境预报中心的全球预报系统(Global Forecast System, GFS)风场预报资料,各层水平分辨率均为 0.5° ,初始场时间间隔为24 h,逐日起报时间为12:00 UTC,预报时效为0~72 h,每隔3 h输出一次预报结果。垂直层次主要包括700、750、800、850、900、925、950、975和1000 hPa、地面10 m等。

④同期、同区域中国气象局全球预报系统(CMA-GFS)风场预报资料,各层水平分辨率均为 0.25° ,初始场时间间隔为24 h,逐日起报时间为12:00 UTC,预报时效为0~72 h,每隔3 h输出一次预报结果。垂直层次主要包括700、800、850、925、975和1000 hPa、地面10 m等。

1.1.2 再分析资料

用来评估模式预报技巧的观测资料的质量、分辨率、覆盖的地理范围等都应考虑。实测站点资料能更好地反映真实物理量情况,能更加客观地检验多模式集成预报,但是对于格点精度较高的预报资料,观测资料存在不够精细和缺测较多等缺点,容易导致额外的误差。ERA5资料是ECMWF打造的最新一代再分析资料。孟宪贵等(2018)指出,ERA5在其前身ERA-Interim(Uppala et al, 2008)的基础上实现了很大升级,时空分辨率大幅提升,提供的变量增加到240种。所以经过综合考量,本文选择ERA5资料作为评估用“观测”资料。

ERA5再分析资料:地面10 m水平分辨率为 0.125° ,高空各层水平分辨率为 0.25° ,高空垂直层次主要包括700、750、800、850、925、950、975和1000 hPa等。所取时间和区域同ECMWF预报资料。

1.2 方法

1.2.1 数据预处理

由于各个模式预报资料及观测资料的分辨率并不完全一致,为了得到华东地区更为精细化的气象要素数据,在试验之前需要对数据进行预处理和插

值。本文先采用线性插值的方法将各中心预报数据的预报时效统一为 0~72 h, 各预报时效间隔为 1 h。对比后选取最优区域插值方法, 将低分辨率的格点预报数据插值到高分辨率的网格上。本文将各模式地面预报值统一插值到 $0.125^\circ \times 0.125^\circ$ 经纬网格上, 高空预报值插值到 $0.25^\circ \times 0.25^\circ$ 经纬网格上。将高空等压面上风速数据插值到等位势高度层(约为 0~3 000 gpm, 垂直方向间隔为 300 gpm), 得到高空非常规层垂直风场。这样处理的目的是能得到水平和垂直方向上高分辨率的风场预报资料, 用于民航飞行的气象保障。

得到统一的高时空分辨率风场资料后, 再基于均方根误差、距平相关系数等评估方法, 采用简单集合平均(ensemble mean, EMN)、消除偏差集合平均、超级集合预报、适用于矢量二维风场订正的复卡尔曼滤波技术等方法对多模式预报数据进行集合。

1.2.2 反距离权重法插值

反距离权重法插值(inverse distance weight, IDW), 是按照目标站点与已有网格点间的距离反比分配权重, 距离较近的数据点权重较高, 距离较远的数据点分配的权重较小。

$$Z = \frac{\sum_{i=1}^n Z_i / d_i^a}{\sum_{i=1}^n 1 / d_i^a} \quad (1)$$

式中: Z 为目标站点的物理量要素, Z_i 为站点 i 的要素值, n 为站点数, d_i 为与第 i 个站点的距离, a 为反比例系数(一般取 2)。

1.2.3 多模式简单集合平均

多模式简单集合平均(EMN)对参与多模式集成的各模式预报结果进行简单平均。计算公式如下:

$$F_{\text{EMN}} = \frac{1}{N} \sum_{i=1}^N F_i \quad (2)$$

式中: F_{EMN} 为经 EMN 方法集合后的预报值, N 为预报模式的总数, F_i 为模式 i 的预报值。

1.2.4 多模式超级集合预报和消除偏差集合平均

多模式超级集合预报(super-ensemble forecast, SUP)和多模式消除偏差集合平均(bias-removed ensemble mean, BREM)的公式如下所示:

$$F_{\text{SUP}} = \bar{O} + \sum_{i=1}^N a_i (F_i - \bar{F}_i) \quad (3)$$

$$F_{\text{BREM}} = \bar{O} + \frac{1}{N} \sum_{i=1}^N (F_i - \bar{F}_i) \quad (4)$$

式中: F_{SUP} 为超级集合预报值, F_{BREM} 为消除偏差集合平均预报值, $\bar{O}$ 为观测值在训练期间的平均, N 为参与多模式集成的模式总数, $\bar{F}_i$ 为模式 i 在训练期内预报值的平均, a_i 为每个模式的权重系数。

本文都采用滑动训练期方法(智协飞等, 2009), 即设置一个最优长度的时间段为训练期, 逐日向后滑动, 这样能根据季节实时更替各模式预报权重, 更为准确。

BREM 和 SUP 的方法将整个时间段分成训练期和预报期两部分。本文经过调试, 得到最优训练期长度为 40 d。采用滑动训练期方法, 2020 年 2 月 22 日至 4 月 13 日设为预报期, 2020 年 1 月 1 日至 2 月 21 日设为训练期, 进行多模式集成试验。例如: 2020 年 2 月 22 日的多模式集成预报结果就是训练该日前 40 d 的预报数据。即 2020 年 1 月 1 日至 2 月 21 日为训练期, 在训练期间计算出各个模式预报效果, 在预报期中进行集合。

1.2.5 卡尔曼滤波和复卡尔曼滤波多模式集成方法

卡尔曼滤波不同于常见的线性的多模式集成预报方法, 它是一种能够根据每个时次的预报和观测数据, 自适应迭代各模式预报的权重系数的非线性方法。然而, 即使采用滑动训练期的方法, 训练期间的观测值和预测值都是等价的。其实, 观测预报的重要性会随着时间的推移而增加, 即越接近预报时间, 观测预报的重要性就越大。因此, 自动调整模态权重系数的方法是非常有效的。这种想法与数据同化技术非常相似: 在训练期间, 从最佳初始猜测场出发, 确定权重系数; 在增加新的观测数据和预报数据时, 立即调整权重系数; 最后, 确定权重系数并用于预测。然后当新的预测开始时, 新的迭代又开始了。卡尔曼滤波长期以来被证明是消除系统误差的有力工具, 在数据同化领域得到了广泛的应用。卡尔曼滤波的优点是可以自动适应模型与观测值之间的差异以及非线性关系下的预测过程。

卡尔曼滤波的公式由预报和分析方程两部分组成。

预报方程:

$$\mathbf{W}_t^f = \mathbf{I} \mathbf{W}_{t-1}^a \quad (5)$$

$$\mathbf{P}_t^f = \mathbf{I} \mathbf{P}_{t-1}^a \mathbf{I}^T + \mathbf{Q} \quad (6)$$

分析方程:

$$\mathbf{K}_t = \mathbf{P}_t^f \mathbf{H}_t^T (\mathbf{H}_t \mathbf{P}_t^f \mathbf{H}_t^T + \mathbf{R})^{-1} \quad (7)$$

$$\mathbf{W}_t^a = \mathbf{W}_t^f + \mathbf{K}_t (\mathbf{Y}_t - \mathbf{H}_t \mathbf{W}_t^f) \quad (8)$$

$$\mathbf{P}_t^a = \mathbf{P}_t^f - \mathbf{K}_t \mathbf{H}_t \mathbf{P}_t^f \quad (9)$$

式中:上标 f 和 a 代表预报与分析状态,下标 t 表示时刻。 $\mathbf{P}$ 为权重误差协方差矩阵, $\mathbf{Q}$ 与 $\mathbf{R}$ 分别为模式误差协方差矩阵与观测误差协方差矩阵,它们均为对角阵。 $\mathbf{I}$ 代表单位向量,状态向量 $\mathbf{W}$ 代表各个模式在预报期中的权重占比系数,其展开如下式所示:

$$\mathbf{W}_t = (\omega_1^1, \omega_1^2, \dots, \omega_1^M, \omega_2^1, \dots, \omega_N^M)^T_{NM} \quad (10)$$

式中: N 与 M 分别代表参与的模式个数以及预报范围内的格点总数。这里我们假设,上一步的分析权重 $\mathbf{W}_a$ 可作为下一步的预报权重 $\mathbf{W}_f$ 。

观测算子 $\mathbf{H}$ 特殊排列了各个模式的预报值, $\mathbf{Y}$ 包含了观测值,式(8)中 $\mathbf{Y} - \mathbf{H}\mathbf{W}$ 为预报残差,当每一新的起报时次的预报和观测数据输入的时候, $\mathbf{Y} - \mathbf{H}\mathbf{W}$ 预报残差会进行更新。卡尔曼增益 $\mathbf{K}$ 类似比例系数,当 $\mathbf{K}$ 趋于 0 时,权重系数趋于稳定,算法收敛。 $\mathbf{H}$ 的结构如下:

$$\mathbf{H}_t = \begin{bmatrix} f_1^1(t) & \dots & 0 & \dots & f_N^1(t) & \dots & 0 \\ \vdots & & \vdots & & \vdots & & \vdots \\ 0 & \dots & f_1^M(t) & \dots & 0 & \dots & f_N^M(t) \end{bmatrix}_{M(NM)} \quad (11)$$

式中: $f(t)$ 为模式预报。

$\mathbf{P}$ 内元素之和随着算法迭代将趋近于 0,而 $\mathbf{Q}$ 始终保持不变。 $\mathbf{Q}$ 过大易导致算法不稳定,经过多次试验发现 $\mathbf{Q} < 0.01$ 时,最终的预报效果能够达到最优,我们经验性地设 $\mathbf{Q}$ 为 0.01,在本文中我们选取训练期间观测值 $\mathbf{Y}$ 的标准差作为 $\mathbf{R}$ 。

水平风场是一种二维矢量场,我们将它分解为纬向风和经向风,某一点的水平风可以简单地表示成复数,实部(虚部)表示纬向风(经向风)。该思路与台风的复卡尔曼滤波方法(augmented complex extended Kalman filter, ACEKF)类似。在 ACEKF 中,所有的初始矩阵除了观测算子 $\mathbf{H}$ 的长度变为 2,宽度扩展了 1 倍之外,其余向量长度均扩展了 1 倍,宽度变为 2。矩阵 $\mathbf{E}$ 为复卡尔曼滤波中矢量风场复数形式的示意,代表公式中的权重误差协方差矩阵 $\mathbf{P}$ 、模式误差协方差矩阵 $\mathbf{Q}$ 和观测误差协方差矩阵 $\mathbf{R}$ 。

$$\mathbf{E}^{\text{exp}} = \begin{bmatrix} \mathbf{E}^{\text{real}} & 0 \\ 0 & \mathbf{E}^{\text{imag}} \end{bmatrix} \quad (12)$$

相应的,预报期中的预报方程为:

$$\mathbf{S}_t = \sum_{i=1}^N \omega_i^f(t) f_i(t) \quad (13)$$

式中 $\mathbf{S}_t$ 为最终预报结果。

1.3 评估与检验

1.3.1 均方根误差

均方根误差(root mean square error, RMSE)的计算如下:

$$\text{RMSE} = \left[\frac{1}{N} \sum_{i=1}^N (F_i - O_i)^2 \right]^{\frac{1}{2}} \quad (14)$$

式中: N 是样本总数, F_i 为样本 i 的预报值, O_i 为样本 i 的观测值。RMSE 的数值越小,实测值和预报值的差值越小,表明预报越准确。

1.3.2 距平相关系数

距平相关系数(anomaly correlation coefficient, ACC)的计算如下:

$$\text{ACC} = \frac{\sum_{i=1}^N (F_i - \bar{F})(O_i - \bar{O})}{\sqrt{\sum_{i=1}^N (F_i - \bar{F})^2 \sum_{i=1}^N (O_i - \bar{O})^2}} \quad (15)$$

式中: F_i 为样本 i 的预报值, O_i 为样本 i 的观测值, $\bar{F}$ 为各模式在所有样本中预报的平均值, $\bar{O}$ 为与之对应的观测的平均值。ACC 是评估模式预报值和观测值的相关性的一个指标,其值越大,则表明模式的预报效果越好。

2 单个模式风速预报的检验评估

首先以均方根误差为评估指标来对比各个模式的预报效果。如图 1 所示,分别计算了 4 个模式(ECMWF、GFS、CMA-GFS、CMA-MESO)在预报期内华东区域预报时效为 24 h、时间平均的地面 10 m u 、 v 、全风速预报的均方根误差的地理分布。

在几个单模式中,ECMWF(简称 EC)、GFS 及 CMA-GFS 的预报技巧评分较高,其中 EC 模式预报的误差最小,GFS 次之,误差分布表现稳定,CMA-MESO 模式的预报技巧较差。误差最小的 EC 模式在区域分布上 RMSE 相较于 CMA-MESO 平均低了 $1.5 \text{ m} \cdot \text{s}^{-1}$ 左右。从整个华东地区来看,4 个模式对风速预报的误差的地理分布较为一致,大体显示出纬度从低到高 RMSE 逐渐增加的趋势。山东及广东、福建沿海地区均方根误差较大,长江以南内陆地区均方根误差较小。




图 1 预报期内华东地区 24 h 预报时效平均地面 10 m (a~d) 纬向风 u 、(e~h) 经向风 v 、(i~l) 全风速的 (a, e, i) EC、(b, f, j) GFS、(c, g, k) CMA-GFS、(d, h, l) CMA-MESO 模式预报的时间平均均方根误差的地理分布

Fig. 1 Geographical distribution of time average RMSE with 24 h lead time averaged surface 10 m (a~d) zonal wind, (e~h) meridional wind, and (i~l) total wind speed for (a, e, i) EC, (b, f, j) GFS, (c, g, k) CMA-GFS, and (d, h, l) CMA-MESO in East China during the averaged forecast period

EC 模式评分表现最好, 后续将应用多模式集成技术, 将预报技巧最优的单模式与传统的多模式集成、复卡尔曼滤波方法进行对比分析。

3 多模式风速集成预报结果分析

为更好研究华东地区对精细化风场的预报能力, 图 2 选取预报期内 EMN、BREM、SUP、ACEKF 方法及 EC 模式在预报时效为 24 h 的地面 10 m 风速预报的平均 RMSE 进行比较分析。由图 2 可知, EMN、BREM 方法预报效果较差, 在山东及广东部分地区地面风速 RMSE 较大, 约为 $1.5 \text{ m} \cdot \text{s}^{-1}$ 。不等权的多模式集成预报中, SUP 方法的预报效果有一定改进, ACEKF 预报效果最好, 华东地区误差明显减小。

为了进一步讨论 ACEKF 预报的优越性, 我们计算了地面 10 m ACEKF 预报相较其他多模式集成方法和单模式预报的均方根误差减小的百分比 (图 3)。ACEKF 相较 EMN 方法, 改进率最高。在广东沿海、福建地区、江淮地区地面风场 ACEKF 预报改进效果最好, 改进率约为 40%, 华东地区平均地面 10 m 风速预报 RMSE 改进率在 20% 左右。

图 4 选取高空具有代表性的几个位势高度层, 对比了 300、1500、2100、3000 gpm 的预报期内各模式纬向风速 24 h 预报的平均均方根误差。同地面 10 m 的结果一样, ACEKF 方法预报效果最好, SUP 方法次之。ACEKF 方法在 2100 gpm 高度层上预报均方根误差最大, 也与前面机场预报误差的垂直廓线一致。图 5 是 ACEKF 方法较其他多模式集成预报方法和 EC 单模式预报的均方根误差减小的百




图 2 预报期内华东地区 24 h 预报时效平均地面 10 m(a~e)纬向风 u 、(f~j)经向风 v 、(k~o)全风速的(a,f,k)EC、(b,g,l)EMN、(c,h,m)ACEKF、(d,i,n)BREM、(e,j,o)SUP 预报的均方根误差的地理分布

Fig. 2 Geographical distribution of RMSE with 24 h lead time averaged surface 10 m (a—e) zonal wind, (f—j) meridional wind, and (k—o) total wind speed for (a, f, k) EC, (b, g, l) EMN, (c, h, m) ACEKF, (d, i, n) BREM, and (e, j, o) SUP in East China during the averaged forecast period





图 3 预报期内华东区域 24 h 预报时效的地面 10 m(a~d)纬向风 u 、(e~h)经向风 v 、(i~l)全风速的 ACEKF 相较(a,e,i)EC、(b,f,j)EMN、(c,g,k)BREM、(d,h,l)SUP 预报的时间平均均方根误差改进率的地理分布

Fig. 3 Geographical distribution of the improvement rate of time average RMSE with 24 h lead time of ACEKF on surface 10 m (a—d) zonal wind u , (e—h) meridional wind v and (i—l) total wind speed in East China during the averaged forecast period compared with (a, e, i) EC, (b, f, j) EMN, (c, g, k) BREM, and (d, h, l) SUP



续图 3

Continued




图 4 预报期内华东区域 24 h 预报时效的(a~e)高空 300 gpm、(f~j)1500 gpm、(k~o)2100 gpm、(p~t)3000 gpm 纬向风 u 的(a,f,k,p)EC、(b,g,l,q)EMN、(c,h,m,r)ACEKF、(d,i,n,s)BREM、(e,j,o,t)SUP 预报的时间平均均方根误差的地理分布

Fig. 4 Geographical distribution of time average RMSE with 24 h lead time of (a, f, k, p) EC, (b, g, l, q) EMN, (c, h, m, r) ACEKF, (d, i, n, s) BREM, and (e, j, o, t) SUP of (a–e) 300 gpm, (f–j) 1500 gpm, (k–o) 2100 gpm, (p–t) 3000 gpm zonal wind u of East China during the averaged forecast period

分比。以 300 gpm 为例,华东地区平均预报均方根误差改进率在 53%左右,ACEKF 对高空风场预报的改进效果要优于地面风场。

图 6、图 7 为预报期内华东地区地面 10 m 和高空各层风速预报的平均均方根误差和距平相关系数(时间和空间上求平均),BREM、EMN 均方根误差

相比于 EC 预报略高,距平相关系数略低,SUP 和 EC 预报技巧相差无几,ACEKF 方法预报效果最

优。因区域较小、时间段较短,模式预报总体均方根误差较小、距平相关系数较高。随着预报时效延长,




图5 同图3,但为高空 300 gpm

Fig. 5 Same as Fig. 3, but on 300 gpm





图6 预报期内华东区域不同预报时效的(a~c)地面 10 m、(d~f)高空 300 gpm、(g~i)1500 gpm、(j~l)3000 gpm 的(a,d,g,j)纬向风 u 、(b,e,h,k)经向风 v 、(c,f,i,l)全风速的 EC、EMN、ACEKF、BREM、SUP 预报的区域、时间平均均方根误差折线图

Fig. 6 Area and time average RMSE of EC, EMN, ACEKF, BREM and SUP forecasts of (a~c) surface 10 m, (d~f) 300 gpm, (g~i) 1500 gpm, (j~l) 3000 gpm (a, d, g, j) zonal wind u , (b, e, h, k) meridional wind v and (c, f, i, l) total wind speed in East China during the forecast period at different lead times



续图 6
Continued




图 7 同图 6, 但为距平相关系数
Fig. 7 Same as Fig. 6, but for ACC

ACEKF 方法优势更加明显, 预报时效为 72 h, ACEKF 相比 BREM 方法, 均方根误差约改进 $1.3 \text{ m} \cdot \text{s}^{-1}$, 距平相关系数提高 0.1 左右。ACEKF 方法对高空预报的改进效果优于对地面预报的改进效果。

图 8、图 9 分别为地面 10 m 和高空 300 gpm 24 h 风预报均方根误差随预报时效和起报日的变化。地面 24 h 风速预报的 RMSE 基本小于 $1 \text{ m} \cdot \text{s}^{-1}$, 误

差随预报时效延长而增长。ACEKF 方法对高空 300 gpm 风预报具有明显改进, 比其他多模式集成预报以及 EC 单模式预报技巧都有很大改进。ACEKF 方法对于预报的稳定性也有一定改进。在预报期的第 12 日, 也就是 2020 年 3 月 4 日时模式预报误差比较大, 这一天有持续阴雨和大风预警。运用复卡尔曼滤波多模式集成对预报进行集合后对风速预报的改善比较明显。




图8 预报期内华东区域地面 10 m (a,d,g,j,m) 纬向风 u 、(b,e,h,k,n) 经向风 v 、(c,f,i,l,o) 全风速的 (a~c) EC、(d~f) EMN、(g~i) ACEKF、(j~l) BREM、(m~o) SUP 预报的区域平均的均方根误差随起报日、预报时效的变化

Fig. 8 Distribution of RMSE with time and forecast lead time for the regional average of (a—c) EC, (d—f) EMN, (g—i) ACEKF, (j—l) BREM, (m—o) SUP forecast in East China during the forecast period of 10 m (a, d, g, j, m) zonal wind u , (b, e, h, k, n) meridional wind v and (c, f, i, l, o) total wind speed





图9 同图8, 但为高空 300 gpm

Fig. 9 Same as Fig. 8, but for 300 gpm



续图 9

Continued

4 结论与讨论

本文利用简单集合平均、滑动训练期消除偏差集合平均、多模式超级集合预报和复卡尔曼滤波几种方法对 EC、GFS、CMA-MESO 和 CMA-GFS 共 4 个模式预报的 0~72 h 地面、高空风预报进行多模式集成,得到以下几点结论:

(1) ACEKF 能够进一步减小风场预报的误差,提高预报技巧,在纬向风、经向风、全风速预报上均有体现。

(2) 从风场预报结果来看,无论是对地面 10 m 风预报还是高空风预报,ACEKF 对经向风预报的改进效果都要优于纬向风预报,在预报 RMSE 和 ACC 上都有反映。

(3) ACEKF 对高空风场预报的改进效果要优于地面风场,对高空风速预报的改进率可达 53% 左右,而对地面风速预报的改进率只有约 20%。

(4) 随着预报时效延长,风场预报误差增大,但 ACEKF 方法对风场预报改进效果更为明显。

致谢: 本文的结果是在南京信息工程大学高性能计算中心计算获得的,在此表示由衷感谢!

参考文献

- 崔慧慧,智协飞,2013. 基于 TIGGE 资料的地面气温延伸期多模式集成预报[J]. 大气科学学报,36(2):165-173. Cui H H, Zhi X F, 2013. Multi-model ensemble forecasts of surface air temperature in the extended range using the TIGGE dataset[J]. Trans Atmos Sci, 36(2):165-173(in Chinese).

- 李俊,杜钧,陈超君,2015. “频率匹配法”在集合降水预报中的应用研究[J]. 气象,41(6):674-684. Li J, Du J, Chen C J, 2015. Applications of “frequency-matching” method to ensemble precipitation forecasts[J]. Meteor Mon, 41(6):674-684(in Chinese).

- 林春泽,智协飞,韩艳,等,2009. 基于 TIGGE 资料的地面气温多模式超级集合预报[J]. 应用气象学报,20(6):706-712. Lin C Z, Zhi X F, Han Y, et al, 2009. Multi-model superensemble forecasts of the surface temperature using the TIGGE data[J]. J Appl Meteor Sci, 20(6):706-712(in Chinese).

- 卢晔,何豫秦,庞翻,等,2015. 华东地区风速趋势变化特征及其原因分析[J]. 安徽农业科学,43(13):231-234. Lu Y, He Y Q, Pang F, et al, 2015. Trends characteristics and reason analysis of the wind velocity in the eastern region of China[J]. J Anhui Agri Sci, 43(13):231-234(in Chinese).

- 孟宪贵,郭俊建,韩永清,2018. ERA5 再分析数据适用性初步评估[J]. 海洋气象学报,38(1):91-99. Meng X G, Guo J J, Han Y Q, 2018. Preliminary assessment of ERA5 reanalysis data[J]. J Mar Meteor, 38(1):91-99(in Chinese).

- 祁海霞,彭涛,林春泽,等,2020. 清江流域降水的多模式 BMA 概率预报试验[J]. 气象,46(1):108-118. Qi H X, Peng T, Lin C Z, et al, 2020. Probabilistic forecasting of precipitation over the Qingjiang River Basin using BMA multimodel ensemble technique[J]. Meteor Mon, 46(1):108-118(in Chinese).

- 田伟红,庄世宇,2008. ETKF 方法在区域集合预报中的初步应用[J]. 气象,34(8):35-39. Tian W H, Zhuang S Y, 2008. Application of ETKF method to regional ensemble forecasts[J]. Meteor Mon, 34(8):35-39(in Chinese).

- 张涵斌,智协飞,王亚男,等,2015. 基于 TIGGE 资料的西太平洋热带气旋多模式集成预报方法比较[J]. 气象,41(9):1058-1067. Zhang H B, Zhi X F, Wang Y N, et al, 2015. Comparison of multimodel ensemble methods for western Pacific tropical cyclone forecast based on TIGGE data[J]. Meteor Mon, 41(9):1058-1067(in Chinese).

- 智协飞,黄闻,2019. 基于卡尔曼滤波的中国区域气温和降水的多模

- 式集成预报[J]. 大气科学学报, 42(2):197-206. Zhi X F, Huang W, 2019. Multimodel ensemble forecasts of surface air temperature and precipitation over China by using Kalman filter[J]. Trans Atmos Sci, 42(2):197-206(in Chinese).
- 智协飞, 林春泽, 白永清, 等, 2009. 北半球中纬度地区地面气温的超级集合预报[J]. 气象科学, 29(5):569-574. Zhi X F, Lin C Z, Bai Y Q, et al, 2009. Superensemble forecasts of the surface temperature in Northern Hemisphere middle latitudes[J]. Sci Meteor Sin, 29(5):569-574(in Chinese).
- 智协飞, 吕游, 2019. 基于频率匹配法的中国降水多模式预报订正研究[J]. 大气科学学报, 42(6):814-823. Zhi X F, Lyu Y, 2019. Calibration of the multimodel precipitation forecasts in China using the frequency matching method[J]. Trans Atmos Sci, 42(6):814-823(in Chinese).
- 智协飞, 王田, 季焱, 2020. 基于深度学习的中国地面气温的多模式集成预报研究[J]. 大气科学学报, 43(3):435-446. Zhi X F, Wang T, Ji Y, 2020. Multimodel ensemble forecasts of surface air temperature over China based on deep learning approach[J]. Trans Atmos Sci, 43(3):435-446(in Chinese).
- 智协飞, 赵忱, 2020. 基于集合成员订正的强降水多模式集成预报[J]. 应用气象学报, 31(3):303-314. Zhi X F, Zhao C, 2020. Heavy precipitation forecasts based on multi-model ensemble members[J]. J Appl Meteor Sci, 31(3):303-314(in Chinese).
- He C F, Zhi X F, You Q L, et al, 2015. Multi-model ensemble forecasts of tropical cyclones in 2010 and 2011 based on the Kalman filter method[J]. Meteor Atmos Phys, 127(4):467-479.
- Ji L Y, Zhi X F, Simmer C, et al, 2020. Multimodel ensemble forecasts of precipitation based on an object-based diagnostic evaluation[J]. Mon Wea Rev, 148(6):2591-2606.
- Ji L Y, Zhi X F, Zhu S P, et al, 2019. Probabilistic precipitation forecasting over East Asia using Bayesian model averaging[J]. Wea Forecasting, 34(2):377-392.
- Krishnamurti T N, Kishtawal C M, Larow T E, et al, 1999. Improved weather and seasonal climate forecasts from multimodel super-ensemble[J]. Science, 285(5433):1548-1550.
- Krishnamurti T N, Rajendran K, Vijaya Kumar T S V, et al, 2003. Improved skill for the anomaly correlation of geopotential heights at 500 hPa[J]. Mon Wea Rev, 131(6):1082-1102.
- Leith C E, 1974. Theoretical skill of Monte Carlo forecasts[J]. Mon Wea Rev, 102(6):409-418.
- Lenartz F, Mourre B, Barth A, et al, 2010. Enhanced ocean temperature forecast skills through 3-D super-ensemble multi-model fusion[J]. Geophys Res Lett, 37(19):L19606.
- Peng T, Zhi X F, Ji Y, et al, 2020. Prediction skill of extended range 2-m maximum air temperature probabilistic forecasts using machine learning post-processing methods[J]. Atmosphere, 11(8):823.
- Rixen M, Book J W, Carta A, et al, 2009. Improved ocean prediction skill and reduced uncertainty in the coastal region from multi-model super-ensembles[J]. J Mar Syst, 78:S282-S289.
- Rixen M, Ferreira-Coelho E, 2007. Operational surface drift prediction using linear and non-linear hyper-ensemble statistics on atmospheric and ocean models[J]. J Mar Syst, 65(1/2/3/4):105-121.
- Uppala S, Dee D, Kobayashi S, et al, 2008. Towards a climate data assimilation system: status update of ERA-Interim[J]. ECMWF Newsletter, 115:12-18.
- Zhi X F, Qi H X, Bai Y Q, et al, 2012. A comparison of three kinds of multimodel ensemble forecast techniques based on the TIGGE data[J]. Acta Meteor Sin, 26(1):41-51.

(本文责编:王蕾)