doi:10.6041/j.issn.1000-1298.2021.07.031

基于数值天气预报后处理的参考作物蒸散量预报改进

姚付启[1]　董建华[2]　范军亮[3]　曾文治[4]　吴立峰[2]

(1.鲁东大学水利工程学院,烟台 264010;2.南昌工程学院水利与生态工程学院,南昌 330099;
3.西北农林科技大学水利与建筑工程学院,陕西杨凌 712100;
4.武汉大学水资源与水电工程科学国家重点实验室,武汉 430072)

摘要:针对基于数值天气预报(Numerical weather prediction,NWP)对参考作物蒸散量(Reference crop evapotranspiration,ET_0)进行预报通常需要数据偏差校正的问题,基于 LightGBM 机器学习方法和我国西北地区 9 个气象站点数据提出一种对第二代全球集合预报系统(Global ensemble forecast system,GEFSv2)预报气象因子进行偏差校正的方法(M3)。该方法使用太阳辐射、最高和最低气温、相对湿度和风速集合分别对每个气象因子进行重预报,再计算 ET_0。使用等距离累积分布函数(EDCDFm,M1)和单气象因子输入的 LightGBM 法(M2)对模型精度进行评估。结果表明,GEFSv2 的预报因子与相应的观测气象因子之间存在不匹配问题,其不匹配程度因气象因子不同而不同,太阳辐射的匹配度较高,相对湿度的匹配度较低。M3 模型有助于缓解数据不匹配问题。M1、M2 和 M3 方法在 9 站点预报 ET_0 的平均均方根误差(RMSE)分别介于 0.66 ~ 0.93 mm/d、0.57 ~ 0.83 mm/d 和 0.53 ~ 0.79 mm/d,平均绝对误差(MAE)分别介于 0.44 ~ 0.61 mm/d、0.38 ~ 0.56 mm/d 和 0.35 ~ 0.53 mm/d,决定系数(R^2)分别介于 0.82 ~ 0.91、0.84 ~ 0.93 和 0.86 ~ 0.94。3 种方法均在夏季误差最大,1 ~ 16 d 平均 RMSE 分别为 1.21、1.18、1.04 mm/d。各预报因子中太阳辐射对 ET_0 预报误差影响最大,其后依次是风速、最高气温、相对湿度和最低气温。在后处理过程中,NWP 的最高气温预报值对其他因子预报精度的贡献最大、对相对湿度预报精度的贡献最小。建议在进行 NWP 偏差校正时,应考虑数据不匹配问题,通过多因子校正来弥补预报精度的不足。

关键词:参考作物蒸散量;预报;轻量级提升树算法;偏差校正;数值天气预报;机器学习

中图分类号:S161.4　　**文献标识码**:A　　**文章编号**:1000-1298(2021)07-0293-11　　**OSID**:

Improvement of Reference Crop Evapotranspiration Forecasting Based on Numerical Weather Prediction Post Processing

YAO Fuqi[1]　DONG Jianhua[2]　FAN Junliang[3]　ZENG Wenzhi[4]　WU Lifeng[2]

(1. *School of Hydraulic Engineering*, *Ludong University*, *Yantai* 264010, *China*
2. *School of Hydraulic and Ecological Engineering*, *Nanchang Institute of Technology*, *Nanchang* 330099, *China*
3. *College of Water Resources and Architectural Engineering*, *Northwest A&F University*, *Yangling*, *Shaanxi* 712100, *China*
4. *State Key Laboratory of Water Resources and Hydropower Engineering Science*, *Wuhan University*, *Wuhan* 430072, *China*)

Abstract: Reference crop evapotranspiration (ET_0) forecasting is of great significance for irrigation decision making and water resources management. ET_0 forecasting using numerical weather prediction (NWP) has been proved to be an effective method, but this method usually requires bias correction. A bias correction method (M3) for the forecast weather factors from the global ensemble forecast system (GEFSv2) was established based on the LightGBM machine learning method and the data of nine meteorological stations in Northwest China. In this method, solar radiation, maximum and minimum temperature, relative humidity and wind speed were used to reforecast each meteorological factor respectively, and then ET_0 was calculated. The performance of the M3 model was evaluated by equidistant cumulative distribution function (EDCDFm, M1) and LightGBM method (M2) with single meteorological factor as input. The results showed that there was a mismatch between the forecast factors

收稿日期:2021-03-22　修回日期:2021-04-12

基金项目:山东省自然科学基金项目(ZR2020ME254、ZR2020QD061)和国家自然科学基金项目(51879196、51309016)

作者简介:姚付启(1981—),男,副教授,博士,主要从事水土资源高效利用研究,E-mail:fuqiyao163@163.com

通信作者:吴立峰(1985—),男,讲师,博士,主要从事农业水热能量循环模拟研究,E-mail:china.sw@163.com

of GEFSv2 and the corresponding observed meteorological factors. The degree of mismatch varied with the meteorological factors. The matching degree of solar radiation was the highest, and relative humidity was the lowest. The newly established M3 model was superior to both M1 and M2 methods in predicting meteorological factors. In terms of ET_0 forecasting, the average root mean squared error (RMSE) of M1, M2 and M3 were in the range of 0.66 ~ 0.93 mm/d, 0.57 ~ 0.83 mm/d and 0.53 ~ 0.79 mm/d at nine stations, the mean squared error (MAE) were in the range of 0.44 ~ 0.61 mm/d, 0.38 ~ 0.56 mm/d and 0.35 ~ 0.53 mm/d, and the R^2 were 0.82 ~ 0.91, 0.84 ~ 0.93 and 0.86 ~ 0.94, respectively. The error of the three methods were the largest in summer, and the average RMSE from 1 day to 16 days were 1.21 mm/d, 1.18 mm/d and 1.04 mm/d, respectively. Among all forecasting factors, solar radiation had the greatest influence on ET_0 forecasting error, followed by wind speed, maximum temperature, relative humidity and minimum temperature. In the post-process, the maximum temperature forecast value of NWP had the largest contribution to the forecast of other factors, while the contribution of relative humidity was the least. It was suggested that data mismatch should be considered in NWP bias correction, and multi-factor correction should be used to improve the prediction accuracy.

Key words: reference crop evapotranspiration; forecasting; LightGBM; bias correction; numerical weather prediction; machine learning

0 引言

准确的蒸散量预报对作物需水量、驱动水文和作物生长模型评估以及农业和水资源管理决策具有重要意义。蒸散量可以通过蒸渗仪、涡动相关和波文比等系统观测,但这些设备通常价格昂贵,且维护成本很高[1]。作物的实际蒸散量更多采用参考作物蒸散量(ET_0)函数进行推导[2]。

Penman - Monteith 方程(以下简称 FAO56 PM)[3]是国际公认的计算 ET_0 的标准方法。FAO56 PM 方程是一种基于物理的方法,结合了生理和空气动力学参数[2],并不需要参数本地化校正。然而,FAO56 PM 方程要求太阳辐射、气温、风速和相对湿度等气象资料齐全。

近年来,学者们不断尝试使用公共天气预报信息进行未来 ET_0 的预测。CAI 等[4]将公共天气预报的多云情况、每日最高和最低温度以及风速等级转换为 FAO56 PM 公式所需的信息,获得了理想的 ET_0 预报精度。LUO 等[5]使用 1 ~ 7 d 公共天气预报和 Hargreaves - Samani 模型进行 ET_0 预报,其均方根误差(RMSE)介于 0.87 ~ 1.36 mm/d,相关系数介于 0.64 ~ 0.86。CHANG 等[6]使用改用 Thornthwaite 模型基于公共天气预报的气温数据对 ET_0 进行了预报。YANG 等[7]研究发现,天气预报风速对 ET_0 估算精度低于多年的日平均风速。

进入 21 世纪以来,数值天气预报(Numerical weather prediction,NWP)模型在高空探测影响天气过程、气候变化和全球尺度天气异常方面取得了巨大的进展[8]。如同基于卫星和雷达观测的数据同化技术[9-10],NWP 的进步是计算机能力增强、模型的时空高分辨率以及预报技术和工具改进的直接结果。NWP 基于流体动力学方程通过确定性或概率的方法来描述大气运动,需要明确的边界条件。初始条件的偏差、方程的简化或某些因素的低预测性都可能造成天气预报失灵。因此,预报的结果需要对逐个变量和逐个站点进行检查。通常使用地面气象站点数据对 NWP 的网格值进行偏差校正或后处理[11]。MEDINA 等[12]采用欧洲中尺度天气预报系统(EC)、英国气象局预报系统(BMO)和美国全球集合预报系统(GEFS)集合预报的方法来改进单个 NWP 模型预报能力的不足。

机器学习算法由于具有极强的非线性拟合能力,已被应用于气象数据的空间校正、ET_0 预测预报等领域。LUO 等[13]将 ANN 和天气预报相结合,预测我国不同地区的 ET_0。YIN 等[14]评估了 4 种神经网络方法在预报 ET_0 中的表现,发现多层感知器的效果最好。TRAORE 等[15]使用双向长短记忆神经网络对 ET_0 进行了 7 d 预报。LU 等[16]使用蝙蝠算法耦合 XGBoost 对未来 1 ~ 3 个月的 ET_0 进行了预测。

目前,基于 NWP 对 ET_0 预报的预报期多为 7 d 以内,从灌溉决策的角度,迫切需要预报期为 15 d 以上的可靠方法。以往研究多为基于单气象要素的偏差校正,但 NWP 输出气象因子的预报结果与相应观测值是否匹配尚不明确,其他预报因子是否蕴藏着提高 ET_0 预报性能的重要信息等相关研究还未见报道。因此,本研究以第二代全球集合预报系统在我国西北地区的输出产品为例,以 1 ~ 16 d 为预报期,基于 LightGBM 机器学习模型,检验 NWP 气象预报因子与相应观测值的匹配程度,探索使用多输出结果提高单个气象要素预报精度的可能性,以提高 ET_0 的预报能力。

1　材料与方法

1.1　研究区域概况

西北干旱区位于中国内陆西北部，属大陆性内陆气候区。气候干燥，年降水量主要分布在 200 ~ 400 mm，水资源比较紧缺。天然植被的分布以典型干草原、荒漠草原、荒漠为主。年平均气温 5 ~ 10℃。四季分明，昼夜温差大，全年日照达 3 000 h，无霜期 170 d 左右，是全国太阳辐射资源最充足的地区之一，特别适宜农作物及瓜果生长。

1.2　数据来源

本研究数据来源有 2 个，其中气象站点数据来自中国气象数据共享网（http://www.cma.cn），选取了中国西北地区 9 个站点（图 1）作为研究对象，气象数据包括：每日 2 m 高处最高和最低气温（T_{max} 和 T_{min}）、地表总辐射（R_s）、相对湿度（R_H）和 2 m 高处风速（U_2）（表 1）。数值天气预报数据来自 NOAA 的第二代全球集合预报系统（GEFSv2）[17]，1 ~ 8 d 和 9 ~ 16 d 的空间分辨率分别为 0.5° × 0.5° 和 1° × 1°。数据包括未来 1 ~ 16 d 的 2 m 最高和最低气温、向下短波辐射、比湿度、U 和 V 方向风速，时间分辨率为 4 h 和 6 h，其中比湿度转换为相对湿度，U 和 V 方向风速经加权平均获得平均风速。2 个数据集数据分为 2 部分，2005—2014 年用于模型建模（训练），2015—2019 年用于检验模型。

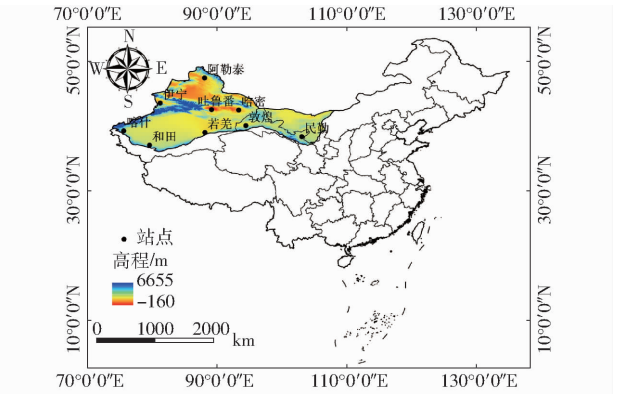

图 1　气象站的空间分布

Fig. 1　Spatial distribution of weather stations

表 1　本研究所选气象站点概况

Tab. 1　Basic information of selected meteorological stations

站号	站点	纬度/(°)	经度/(°)	海拔/m	R_s/(MJ·m^{-2}·d^{-1})	T_{max}/℃	T_{min}/℃	R_H/%	U_2/(m·s^{-1})	ET_0/(mm·d^{-1})
1	阿勒泰	47.44	88.05	736.9	15.11	10.86	-1.28	58.17	1.70	2.56
2	伊宁	43.57	81.20	664.3	15.08	16.61	2.79	64.45	1.35	2.59
3	吐鲁番	42.56	89.12	37.2	15.34	21.84	8.63	39.79	0.88	3.15
4	喀什	39.28	75.58	1 290.7	15.64	18.49	5.99	49.90	1.33	3.17
5	若羌	39.02	88.10	889.3	16.70	20.20	4.26	40.28	1.84	3.75
6	和田	37.08	79.56	1 374.7	16.14	19.34	7.35	41.24	1.45	3.39
7	哈密	42.49	93.31	737.9	17.09	18.16	3.09	43.44	1.37	3.19
8	敦煌	40.09	94.41	1 139.6	17.61	18.25	2.25	42.31	1.51	3.27
9	民勤	38.38	103.05	1 368.5	16.60	16.28	1.67	44.47	1.96	3.22

1.3　研究方法

1.3.1　反距离权重法

反距离权重（IDW）法基于两个假设：未知值附近的点影响比远的控制点影响更大；影响程度（权重）与彼此之间的距离的倒数成指数关系[18]，其计算式为

$$Z = \frac{\sum_{i=1}^{n} \frac{z_i}{D_i^p}}{\sum_{i=1}^{n} \frac{1}{D_i^p}} \tag{1}$$

式中　Z——被插值点的值

z_i——控制点的值

D_i^p——权重系数，本研究中 p 取 2

本研究使用气象站点周围 NWP 的 4 个控制点信息并使用 IDW 法进行插值。

1.3.2　等距累积分布函数法

累积分布函数匹配（CDFm）方法[19]是一种广泛应用的偏差校正方法，它需要假设模型和观测数据的累积分布一致。为了克服这一问题，LI 等[20]提出了等距累积分布函数匹配（EDCDFm）法，该方法对模型和观测的累积分布曲线进行了偏差的校正。EDCDFm 定义为

$$X_{m'} = X_m + F_o^{-1}(F_{s'}(X_{s'})) - F_s^{-1}(F_{s'}(X_{s'})) \tag{2}$$

式中　F——累积频率函数

F^{-1}——累积频率函数的反函数

$X_{m'}$——校正后的未来模型预测值

X_m——数值天气预报的未来模型预测值

下角 o 表示历史训练期观测值，s 表示历史训练期模拟值，s'表示未来模型模拟值。

本研究中,首先使用 IDW 方法将 NWP 数据插值到气象站点,然后使用 3 次函数对气象因子的累积频率曲线进行拟合。

1.3.3 LightGBM 法

LightGBM 是传统 GBDT 的一种高效改进算法,擅长处理高维数据,能提高计算效率,同时保证高模型精度[21]。传统的决策树算法采用层次策略对树进行生长,对同一层的叶子不加区分地进行处理,造成了不必要的计算成本(图 2)。为了降低训练数据的维数,该算法的决策树采用叶向生长策略。每一次从所有的叶子中,找到一个最大的分裂增益,然后分裂完成一个循环[22]。为了避免在样本量不足时过拟合,有必要增加树的最大深度限制。LightGBM 还可以使用 Gini 得分对输入特征的重要性进行排序,在建模时剔除干扰因子。本研究中,LightGBM 分别基于两种方式进行建模(表 2),第 1 种为使用单因子对单因子的方式对气象因子进行偏差校正,记为 M2 方法,该方法每个站点训练样本数为4 × 3 652 = 14 608 个,检验样本数为4 × 1 826 = 7 304 个;第 2 种同时使用 5 个气象因子依次对其中一个气象因子进行偏差校正,记为 M3 方法。使用预报期 1 ~ 16 d 分别作为输入,观测值作为输出来建立模型,M2 方法的输入特征数量是 4 站点 × 6 个时刻(第 4 天开始 4 个时刻),共 24(16)个,M3 方法的输入特征数量是 4 站点 × 6 个时刻(第 4 天开始 4 个时刻) × 5 要素,共 120(80)个。本研究中所需要调参的参数有:最大树深、学习率和树的个数,调参使用网格搜索法[23]。

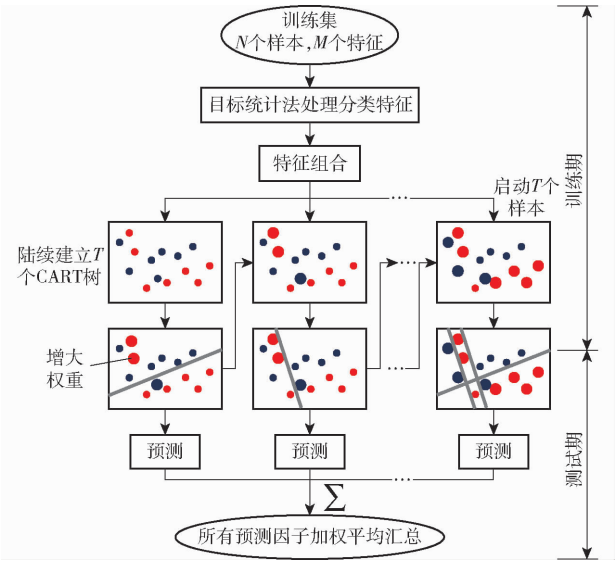

图 2 LightGBM 结构图

Fig. 2 Structure diagram of LightGBM

表 2 本研究所使用偏差校正方法

Tab. 2 Bias correction method used

编号	模型	输入(GEFS 数据)	输出(中国气象网数据)	GEFS 数据说明
M1	EDCDFm	R_s	R_s	前 3 d 每 4 h 一个数据,第 4 天开始每 6 h 一个数据,将其整合为每天一个数据。训练样本数:4 站 × 3 652 d = 14 608 个;检验样本数为 4 站 × 1 826 d,共 7 304 个
		T_{max}	T_{max}	
		T_{min}	T_{min}	
		R_H	R_H	
		U_2	U_2	
M2	LightGBM	R_s	R_s	前 3 d 每 4 h 一个数据,第 4 天开始每 6 h 一个数据,R_s 只在白天有数据,是其他气象因子数据量 1/2。R_s 训练样本数:4 × 3 652 × 4(2),共 58 432(29 216)个;检验样本数 4 × 1 826 × 4(2),共 29 216(14 608)个;T_{max}、T_{min}、R_H、U_2 的训练和检验样本数分别为 R_s 相应样本数 2 倍
		T_{max}	T_{max}	
		T_{min}	T_{min}	
		R_H	R_H	
		U_2	U_2	
M3	LightGBM	R_s、T_{max}、T_{min}、R_H、U_2	R_s	前 3 d 每 4 h 一个数据,第 4 天开始每 6 h 一个数据。R_s、T_{max}、T_{min}、R_H、U_2 训练样本数为 4 × 3 652 × 8(4) × (4 + 0.5),共 262 944(131 472)个;检验样本数:4 × 3 652 × 8(4) × (4 + 0.5),共 131 472 个
		R_s、T_{max}、T_{min}、R_H、U_2	T_{max}	
		R_s、T_{max}、T_{min}、R_H、U_2	T_{min}	
		R_s、T_{max}、T_{min}、R_H、U_2	R_H	
		R_s、T_{max}、T_{min}、R_H、U_2	U_2	

1.4 FAO - 56 Penman - Monteith 模型

采用 FAO - 56 PM 法[23]计算西北地区 9 个站点的 ET_0,计算公式为

$$ET_0 = \frac{0.408\Delta(R_n - G) + \gamma \dfrac{900}{T_{mean} + 273} U_2 (e_s - e_a)}{\Delta + \gamma(1 + 0.34U_2)} \tag{3}$$

式中 ET_0——参考作物蒸散量,mm/d

R_n——地表净辐射,MJ/(m²·d)

G——土壤热通量密度,MJ/(m²·d)

T_{mean}——2 m 高处的平均气温,℃

e_s、e_a——饱和与实际水汽压,kPa

Δ——蒸汽压曲线的斜率,kPa/℃

γ——温度计常数,kPa/℃

1.5 评估指标

采用均方根误差(RMSE)、决定系数(R^2)和平均绝对误差(MAE)来评估气象因子误差。

2 结果与分析

2.1 气象因子预报精度比较

2.1.1 气温

气温是影响饱和水汽压和地面长波辐射收支的重要因子,从而间接影响了 ET_0 的变化。3 种方法在未来 16 d 的 T_{max} 预报精度如图 3a ~ 3c 所示。随着预报天数的增加,T_{max} 的预报精度呈下降趋势。M1、M2 和 M3 方法在 9 站点平均 RMSE 介于 2.57 ~ 5.03℃、2.31 ~ 4.82℃ 和 2.01 ~ 4.36℃,MAE 介于 1.90 ~ 3.89℃、1.71 ~ 3.75℃ 和 1.48 ~ 3.40℃;R^2 介于 0.87 ~ 0.97、0.87 ~ 0.97 和 0.89 ~ 0.98。由此可以看出,3 种方法的精度由高到低依次是 M3、M2 和 M1。

T_{min} 的预报精度也随预报期的延长而下降(图 3d ~ 3f),但总体上误差小于 T_{max},其 M1、M2 和 M3 方法在 9 站点平均 RMSE 介于 2.11 ~ 4.03℃、2.65 ~ 4.10℃ 和 2.26 ~ 3.76℃,MAE 介于 1.90 ~ 3.41℃、2.28 ~ 3.39℃ 和 1.94 ~ 3.06℃,R^2 介于 0.88 ~ 0.97、0.87 ~ 0.95 和 0.90 ~ 0.96。尽管 M1 方法在站点 6、9 等表现优于 M2 方法,但是在站点 1、2、3 精度明显低于 M2 方法,特别是在预报期 9 ~ 16 d 精度较差。总体上,M3 方法优于 M1 和 M2 方法,其在预报期前 8 d 精度稍高于 M1 方法,但是 9 ~ 16 d 明显优于 M1 方法。

2.1.2 地表总辐射

辐射是蒸散的最主要能量来源,其直接主导地表气温变化。3 种方法在不同站点预报 R_s 的表现如图 3g ~ 3i 所示。3 种方法在预报 R_s 的前 8 d 精度逐渐下降,在第 9 天开始由于网格尺度变大造成了 R_s 明显下降,其后精度又逐渐下降。其中,M1、M2 和 M3 方法在 9 站点平均 RMSE 介于 3.44 ~ 5.23 MJ/(m²·d)、3.53 ~ 5.22 MJ/(m²·d) 和 3.22 ~ 4.91 MJ/(m²·d),MAE 介于 2.52 ~ 3.76 MJ/(m²·d)、2.57 ~ 3.83 MJ/(m²·d) 和 2.37 ~ 3.64 MJ/(m²·d),R^2 介于 0.82 ~ 0.59、0.81 ~ 0.57 和 0.85 ~ 0.61(从前期到后期)。总体上,M3 方法表现优于 M1 和 M2 方法,而 M1 和 M2 方法误差比较接近。此外,3 种方法在站点 1、2、9 的误差较大,特别是 9 ~ 16 d,RMSE 超过了 5 MJ/(m²·d),R^2 也在 0.5 以下。

2.1.3 风速

风速是影响空气阻力的重要因子。3 种方法在不同站点预报 U_2 表现如图 3j ~ 3l 所示。3 种方法在预报 U_2 不同站点呈现明显差异。在站点 2、3、6、7,3 种方法在预报期 1 ~ 16 d 都呈现较好的表现。而在站点 4 总体表现较差。其他站点前 8 d 比后 8 d 的精度高 50% 以上。其中,M1、M2 和 M3 方法在 9 个站点平均 RMSE 介于 0.67 ~ 0.87 m/s、0.53 ~ 0.69 m/s 和 0.49 ~ 0.64 m/s,MAE 介于 0.48 ~ 0.62 m/s、0.39 ~ 0.51 m/s 和 0.36 ~ 0.47 m/s,R^2 介于 0.03 ~ 0.24、0.04 ~ 0.37 和 0.10 ~ 0.43。

2.1.4 相对湿度

相对湿度(R_H)是估算饱和水汽压亏缺的重要因子。3 种方法在不同站点预报 R_H 表现如图 3m ~ 3o 所示。3 种方法在预报 R_H 的前 8 d 精度快速下降,在第 9 天开始由于网格尺度变大造成了精度急剧下降,部分站点的精度已经接近随机分布,可以看出 GEFSv2 总体上预报 R_H 的能力比较一般。其中,M1、M2 和 M3 方法在 9 站点平均 RMSE 介于 15.0% ~ 17.2%、11.7% ~ 14.4% 和 10.0% ~ 13.1%,MAE 介于 12.0% ~ 13.5%、9.0% ~ 11.4% 和 7.6% ~ 10.2%,R^2 介于 0.19 ~ 0.42、0.25 ~ 0.53 和 0.36 ~ 0.66。可以看出,M3 方法优于 M2 和 M1 方法,而 M2 方法优于 M1 方法。

2.2 ET_0 预报精度比较

3 种方法在不同站点预报 ET_0 表现如图 3p ~ 3r 所示。3 种方法在预报 ET_0 误差随预报期延长呈上升趋势,其中,M1、M2 和 M3 方法在 9 站点平均 RMSE 介于 0.66 ~ 0.93 mm/d、0.57 ~ 0.83 mm/d 和 0.53 ~ 0.79 mm/d,MAE 介于 0.44 ~ 0.61 mm/d、0.38 ~ 0.56 mm/d 和 0.35 ~ 0.53 mm/d,R^2 介于 0.82 ~ 0.91、0.84 ~ 0.93 和 0.86 ~ 0.94。可以看出,3 种方法的精度从高到低依次是 M3、M2 和 M1。从站点看,站点 3、7 的精度最高,1 ~ 16 d 的误差都没有超过 0.8 mm/d,而站点 4、9 的误差较大,特别是 9 ~ 16 d,其 RMSE 已经超过了 1 mm/d。

3 种方法在站点 5 不同预报时段 FAO56 PM 估算值与预报值的散点图如图 4 所示。M1 方法在预报期 1 ~ 16 d 的 R^2 从 0.91 下降到 0.82,从第 4 天起存在着严重的高估问题,特别是 PM 估算值大于 3 mm/d 时,有大量点预报值达到了 8 mm/d 以上。M2 方法在预报期 1 ~ 16 d 的 R^2 从 0.92 下降到 0.84,与 M1 方法相比,散点更接近于 1∶1 线附近,在 PM 估算值大于 8 mm/d 时,存在一定的低估问题。M3 方法在预报期 1 ~ 16 d 的 R^2 从 0.93 下降到 0.85,与 M1 和 M2 方法相比,其散点更接近于 1∶1 线附近,且在预报期 1 d 提升最明显,此后提升效果逐渐减弱。

从农业灌溉角度出发,一个灌溉周期连续多日

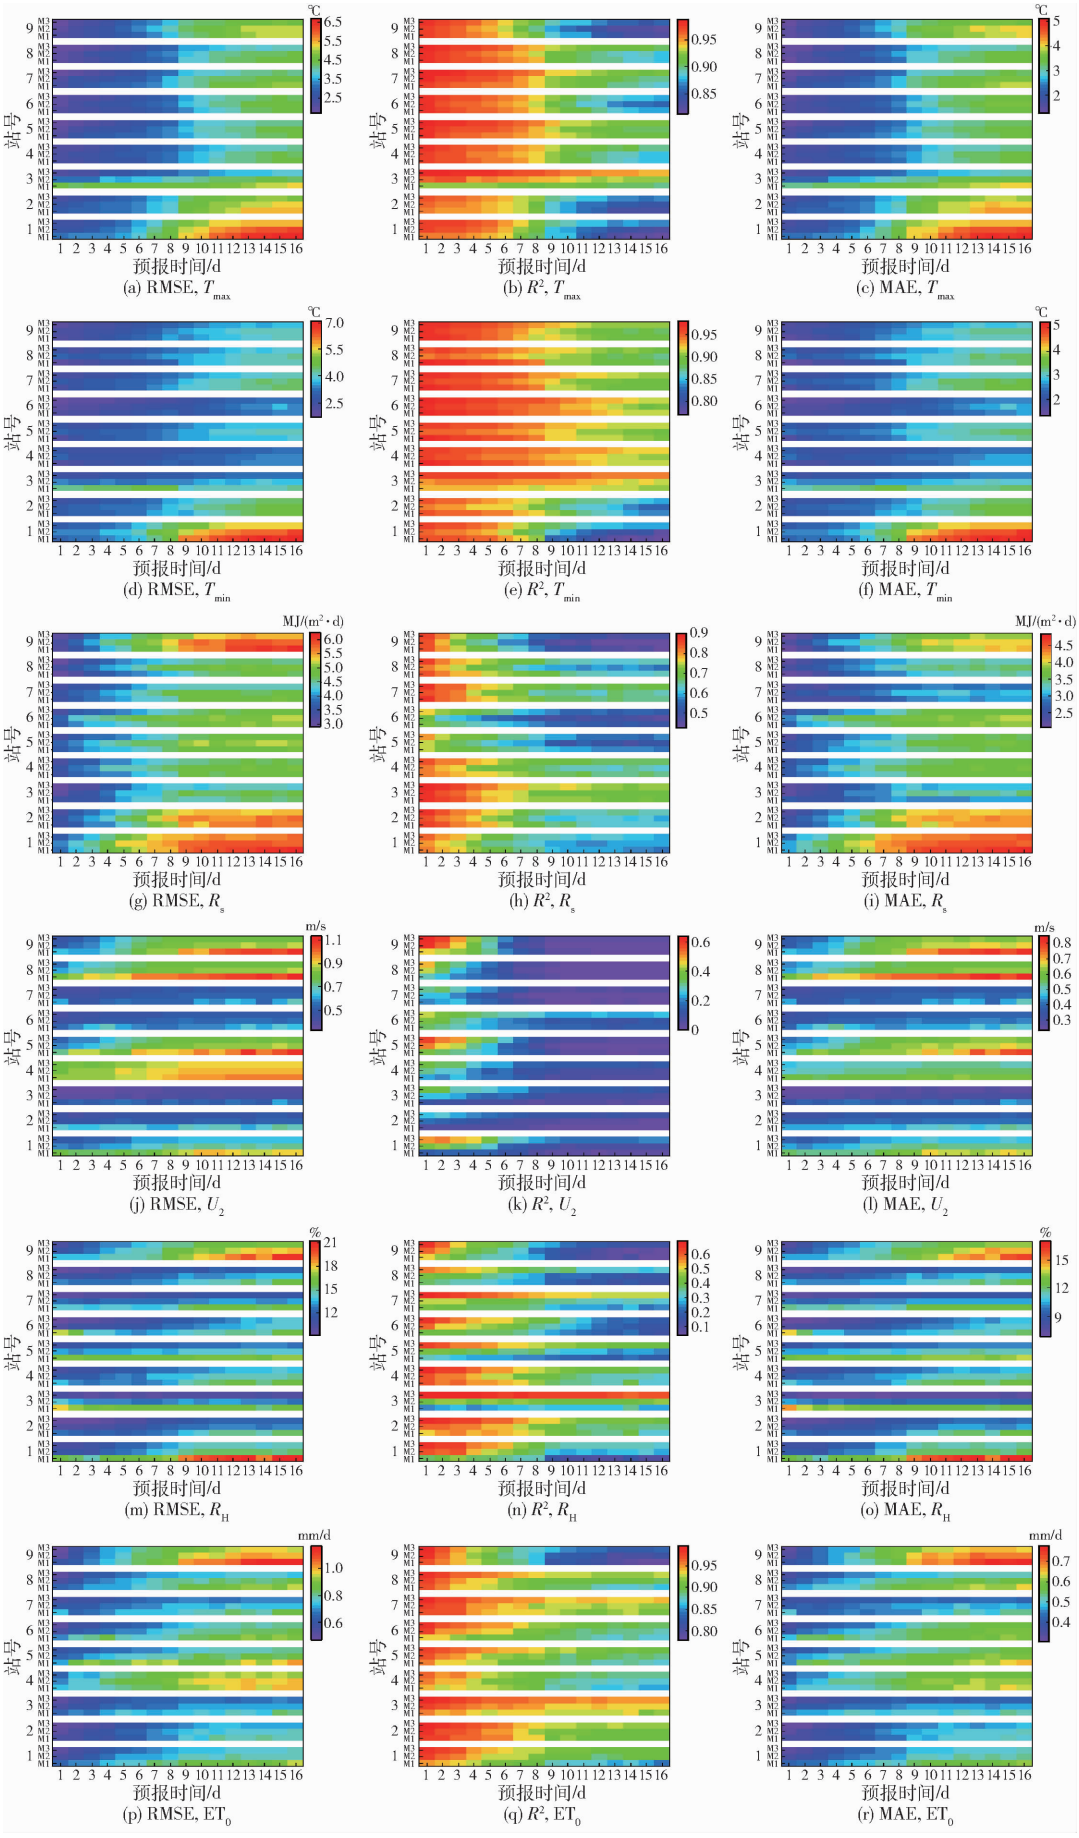

图 3 不同方法气象因子预报统计指标

Fig. 3 Statistical indicators of meteorological factors forecast by different methods

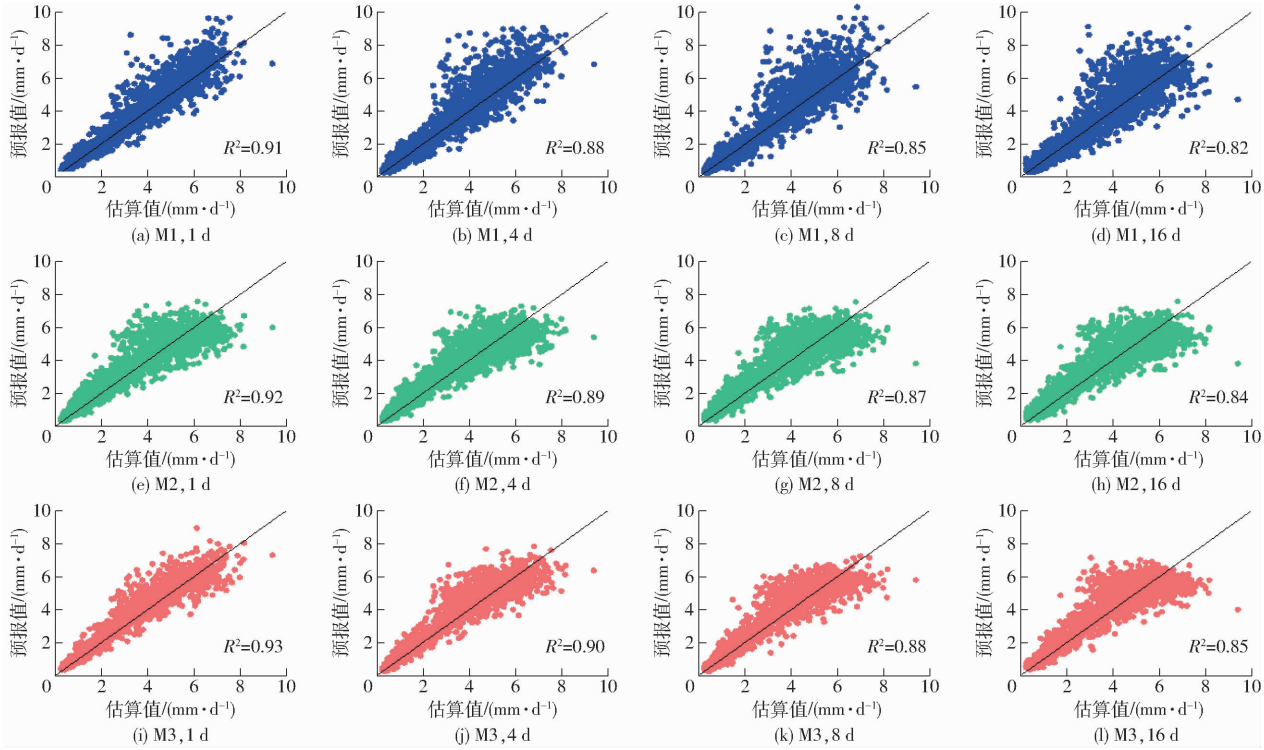

图 4　不同方法 ET_0 预报值与 FAO56 PM 估算值散点图

Fig. 4　Scatter plots of forecasting and FAO56 PM values of ET_0 by different methods

的平均误差比单日误差更适宜为灌溉决策提供参考，因此，计算了 1 ~ 8 d 和 1 ~ 16 d 3 种方法的统计指标，并列出了未进行偏差校正（仅使用 IDW 方法）的统计指标作为对照，其结果如表 3 所示。从表 3 可以看出，IDW 方法下只有站点 2、3 的 RMSE 在 1 mm/d 以内，说明该数据集整体误差很大难以直接使用，需要偏差校正。对比以上 4 种方法统计指标可以看出，M1、M2、M3 3 种方法均可以大幅度降低模型的预报误差。与 IDW 方法相比，M1、M2 和 M3 方法的 RMSE 在 9 个站点 1 ~ 8 d 分别下降 26% ~65% 、24% ~70% 和 31% ~73%，在 9 ~ 16 d 分别下降 20% ~63% 、20% ~68% 和 24 ~70%。尽管 M3 方法相比 M1 方法在 1 ~ 8 d 和 1 ~ 16 d 分别有 13% 和 15% 的提升，但是两者 RMSE 的绝对误差在0. 15 mm/d以内。从全年角度来看可能并没有明显的优势。因此，有必要评估不同方法在不同季节，特别是灌溉季节的表现。

2.3　ET_0 预报季节差异

3 种方法在不同季节的 RMSE 如图 5 所示。在春季，M1、M2 和 M3 方法的 1 ~ 16 d 平均 RMSE 为 0. 89、0. 90、0. 80 mm/d。3 种方法的 RMSE 随预报期的延长呈增加趋势，其中 M1 方法的 RMSE 从 0. 74 mm/d 增加到 1. 03 mm/d，M2 方法从 0. 86 mm/d 缓慢增加到 0. 94 mm/d，M3 方法的 RMSE 在前 8 d 从 0. 61 mm/d 快速增加到 0. 83 mm/d，之后增速逐渐放缓，在 16 d 达到 0. 9 mm/d。对比 M1 和 M2 方法可以看出，在前 8 d，M1 方法表现优于 M2 方法，而在后 8 d，M2 方法优于 M1 方法。

在夏季，3 种方法的表现与春季相似，1 ~ 16 d 平均 RMSE 为 1. 21、1. 18、1. 04 mm/d。不同之处在于由于夏季 ET_0 比春季更高，因此夏季的误差更大。M1 方法的 RMSE 在 0. 98 ~ 1. 4 mm/d，而 M2 和 M3 方法可以把最大误差控制在 1. 2 mm/d 附近。此外，在前 6 d，M1 方法表现优于 M2 方法，而在 6 d 以后 M2 方法优于 M1 方法。秋季和冬季呈现与春季和夏季相似的趋势。M3 方法在预报初期优于其余 2 种方法，但随着预报期增长，其优势逐渐变小，在 8 d 以后，3 种方法的 RMSE 相差约在0. 1 mm/d。

2.4　气象因子对误差的影响

为了发现 NWP 系统的不足之处，进一步评估了单个气象因子的预报误差对 ET_0 预报精度的影响。使用 M3 方法并分别使用 1 种预报数据与其余 4 种观测数据组合代入 PM 公式，来评估气象因子预报误差对 ET_0 误差的影响，结果见图 6。从图 6a、6b 可以看出，最高和最低气温的误差对 ET_0 误差的影响在不同季节有所差异，由大到小为春季、夏季、秋季、冬季。此外，T_{max} 预报误差对 ET_0 造成的误差比 T_{min} 大。在夏季，R_s 的误差对 ET_0 影响更大，ET_0 的 RMSE 在 1 ~ 16 d 介于 0. 55 ~ 0. 83 mm/d（图 6c），与前文相比，其误差已经达到了总误差的 70% 以上。而春季，由于 R_s 预报误差导致 ET_0 的最大 RMSE仅为0. 42 mm/d。U_2 预报误差对 ET_0 影响在

表 3 不同方法下 ET_0 在 1 ~ 8 d 和 1 ~ 16 d 累计误差

Tab.3 ET_0 cumulative errors of different methods in 1 ~ 8 d and 1 ~ 16 d

站号	模型	RMSE/(mm·d^{-1})		R^2		MAE/(mm·d^{-1})	
		1 ~ 8 d	1 ~ 16 d	1 ~ 8 d	1 ~ 16 d	1 ~ 8 d	1 ~ 16 d
1	M1	0.74	0.81	0.87	0.84	0.47	0.52
	M2	0.66	0.72	0.89	0.87	0.42	0.47
	M3	0.62	0.69	0.90	0.88	0.40	0.45
	IDW	1.28	1.52	0.80	0.76	0.91	1.09
2	M1	0.61	0.69	0.91	0.88	0.39	0.44
	M2	0.62	0.69	0.90	0.88	0.40	0.44
	M3	0.57	0.65	0.92	0.89	0.36	0.42
	IDW	0.82	0.86	0.87	0.84	0.57	0.60
3	M1	0.71	0.74	0.89	0.88	0.49	0.50
	M2	0.63	0.67	0.91	0.90	0.42	0.44
	M3	0.60	0.63	0.92	0.91	0.38	0.40
	IDW	0.99	0.97	0.83	0.83	0.73	0.71
4	M1	0.80	0.88	0.87	0.85	0.51	0.56
	M2	0.82	0.89	0.88	0.85	0.51	0.56
	M3	0.78	0.86	0.89	0.86	0.48	0.53
	IDW	1.57	1.34	0.84	0.80	1.14	0.94
5	M1	0.87	0.90	0.87	0.85	0.56	0.58
	M2	0.73	0.78	0.89	0.86	0.50	0.54
	M3	0.66	0.72	0.91	0.88	0.45	0.49
	IDW	2.46	2.43	0.84	0.79	1.87	1.81
6	M1	0.78	0.83	0.86	0.85	0.53	0.56
	M2	0.67	0.74	0.89	0.86	0.47	0.53
	M3	0.62	0.70	0.91	0.88	0.43	0.49
	IDW	2.05	1.84	0.81	0.78	1.45	1.26
7	M1	0.71	0.76	0.90	0.89	0.45	0.48
	M2	0.67	0.70	0.90	0.89	0.43	0.45
	M3	0.61	0.65	0.92	0.90	0.39	0.41
	IDW	1.04	1.29	0.87	0.82	0.72	0.87
8	M1	0.73	0.81	0.88	0.86	0.51	0.56
	M2	0.70	0.75	0.89	0.87	0.47	0.51
	M3	0.63	0.69	0.91	0.89	0.43	0.47
	IDW	1.70	1.41	0.82	0.79	1.23	1.00
9	M1	0.75	0.92	0.87	0.81	0.48	0.60
	M2	0.73	0.85	0.87	0.82	0.49	0.58
	M3	0.71	0.82	0.87	0.83	0.47	0.56
	IDW	2.03	1.80	0.82	0.75	1.48	1.27

春季和夏季相差不大,其 ET_0 的最大 RMSE 约为 0.4 mm/d,秋季则高于冬季(图 6d)。R_H 预报误差对 ET_0 影响较小,在夏季与春季相差不大,其 ET_0 的最大 RMSE 约为 0.2 mm/d(图 6e)。对比不同气象因子造成的影响可以看出,R_s 对 ET_0 误差贡献最大,其后依次是 U_2、T_{max}、R_H 和 T_{min}。从 2.1 节可以看出,各气象因子中预报误差最大的是 U_2,其后依次是 R_H、R_s、T_{max} 和 T_{min}。由于不同因子对 ET_0 的贡献度不同,造成了其自身预报误差与对 ET_0 的误差贡献有所不同。尽管 U_2 的误差最大,但由于其对 ET_0 影响较小,因此对 ET_0 误差影响仅排在第 2 位,而 R_s 尽管预报精度排第 3,但由于其对 ET_0 贡献最大,因此其对 ET_0 误差的贡献也最大。这表明提高 R_s 的预报精度是更准确预报 ET_0 的关键。

2.5 预报气象因子与观测气象因子之间关系

为更好地认识数值天气预报系统气象因子内在的联系,基于 LightGBM 模型对气象因子进行偏差校正基础上,通过算法对因子贡献度评分(Gini 值)绘制预报气象因子之间的相关关系图,其各输入因子对输出气象因子的得分结果如图 7 所示。可以看出,GEFS_T_{max} 信息对于提升 T_{max}、T_{min}、R_H 和 U_2 的预报精度都有较大的帮助。GEFS_T_{max} 的 Gini 值为 2.1,其中仅有约 0.9 的得分用于预报 T_{max},约 0.6 的得分用于预报 T_{min},甚至高于 GEFS_T_{min} 对 T_{min} 的预报得分(0.25),这说明与 T_{min} 变化规律最接近的是 GEFS_T_{max},而非 GEFS_T_{min}。

GEFS_R_s 除主要用于预报 R_s 外,对 R_H 和 U_2 的预报稍有帮助。此外,GEFS_R_H 对 R_H 预报得分只有 0.2,而 GEFS_T_{max} 对 R_H 预报得分为 0.45,高于前者。这说明使用 GEFS_T_{max} 来预报 R_H 比 GEFS 的 GEFS_R_H 预报更有效。综合来看,T_{max} 对其他因子预报的贡献最大,其后依次是 R_s、T_{min}、U_2 和 R_H。另一方面,多因子预报对太阳辐射预报的帮助最小。以上信息说明,预报因子与观测气象因子之间存在不匹配的问题,不匹配程度与因子有关,其中 R_s 的匹配度最高,R_H 匹配度最低。这也证明了本研究使用多因子偏差校正的合理性。

3 讨论

目前,ET_0 预报主要基于公共天气预报和数值天气预报。公共天气预报容易获得、只需要简单转换就可以使用,跟经验模型结合更能简化计算流程[24],但由于数据的完整度存在问题,公共天气预报的预报期通常较短,多为 7 d 以内[5-7,25-26]。数值天气预报具有更完整的数据集,且预报期更长,通常可以预报 10 d 以上,甚至 1 个月。但数值天气预报通常前处理比较复杂,并且需要偏差校正,这给其广泛使用带来了一定的困难,在 NWP 基础上进行后处理,构建预报数据集有助于简化其复杂度。YANG 等[7]比较了不同 4 种风速输入方式在中国不同气候区 ET_0 预报的表现,其中在干旱区 RMSE 介于 0.95 ~ 0.99 mm/d,MAE 介于 0.67 ~ 0.70 mm/d。本研究中,M3 方法在 9 站点 1 ~ 16 d 平均 RMSE 介于 0.53 ~ 0.79 mm/d,MAE 介于 0.35 ~ 0.53 mm/d,说明 NWP 结合后处理方法比公共天气预报的精度更高。此外,本研究结果还证明了机器学习方法比统

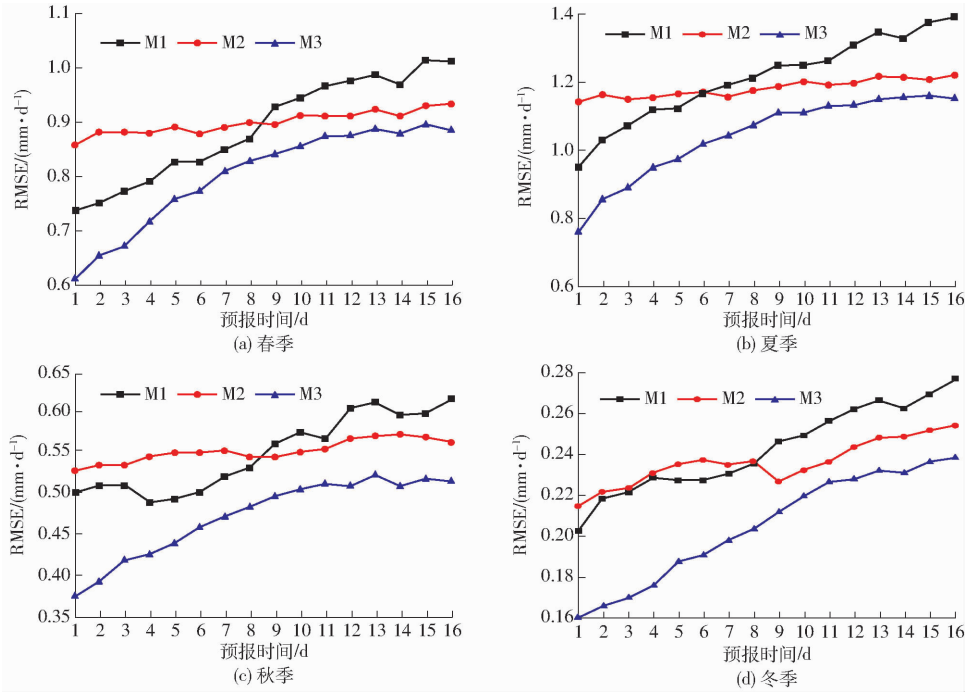

图 5　不同方法 ET_0 在各季节预报差异

Fig. 5　Forecasting ET_0 of different methods in different seasons

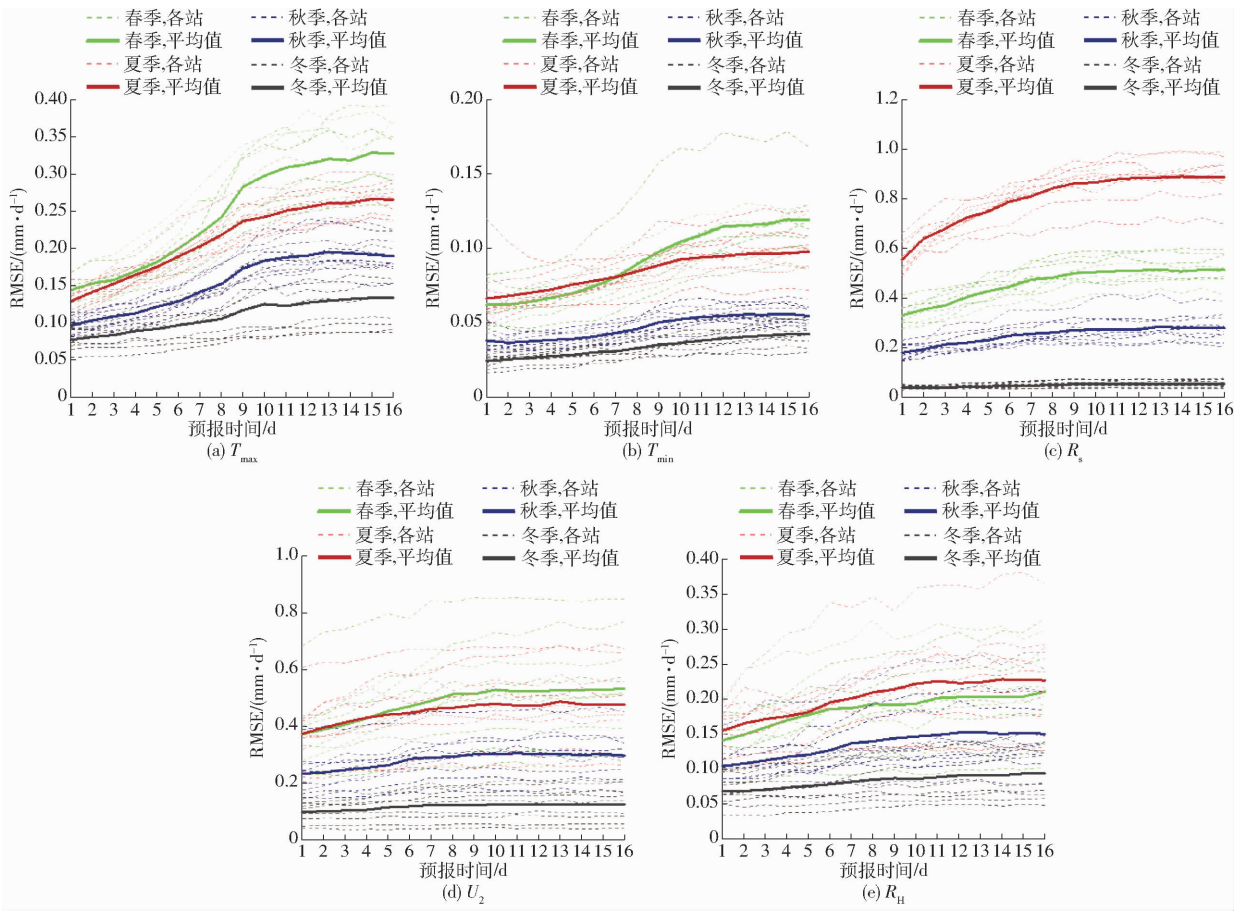

图 6　不同预报气象因子对 ET_0 误差的影响

Fig. 6　Influence of different forecast meteorological factors on ET_0 RMSE

计方法精度更高，在相同输入条件下，M2 方法比 M1 方法 RMSE 低 12.0% ~ 15.7%，MAE 低 8.9% ~ 15.8%。

对 NWP 数据进行后处理可以提高模型精度，MEDINA 等[27]比较了 3 种基于统计的后处理方法（非其次高斯回归、仿射核修整和贝叶斯模型平均）

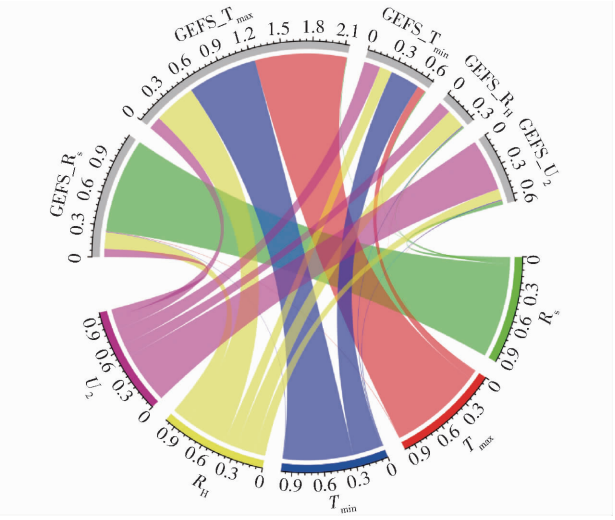

图 7 预报气象因子与实测气象因子之间关系

Fig. 7 Relationship between forecast and measured meteorological factors

对 ET_0 预报的提升效果,发现 3 种方法都能有效提高 ET_0 预报精度。统计方法的不足之处在于通常只能单因素偏差校正,如使用辐射预报值跟辐射实测值建立关系。本研究发现,预报因子和对应的观测因子之间存在不匹配的问题,如与 T_{min}、R_H 最匹配的预报因子是 T_{max},同样 R_H 最相关的预报因子也是 T_{max}。也就是说名义上预报的某气象因子由于预测误差原因与实测的另一个气象因子的关系更加紧密。这首先由于气象因子之间本身就存在着互相影响的关系,如辐射是造成气温日变化的主要原因,同样气温会影响空气中容纳的水汽含量,进而影响到相对湿度;其次,可能是由于 NWP 产品基于物理模型,需要对气象要素之间复杂的非线性关系进行简化;最后,NWP 的边界条件往往比较难以控制,这就造成了一定程度预报精度的下降[28],而部分有价值的信息被隐藏在了其他预报因子之中,使用 LightGBM 这类基于提升树的集合算法,可以将多维输入共同作为输入特征,发掘其中的非线性关系并剔除干扰特征。综上,推荐在对 NWP 数据进行偏差校正时,应考虑使用更多的相关因子建模,来改善 NWP 模型的不足。考虑到本研究中太阳辐射的预报精度还有待进一步提高,今后应使用数值天气预报中更多预报因子,如降水量、云量、反照率、土壤热通量等来提高太阳辐射的预报精度,进而进一步提升 ET_0 预报能力。

4 结论

(1)预报因子与实测气象因子之间存在不匹配问题,其中太阳辐射的匹配度较高,最低气温、相对湿度的匹配度较低,需要借助最高气温等信息进行校正,使用多因子共同预报气象因子有助于气象因子校正。

(2)校正后统计指标显示,M3 方法在太阳辐射、最高和最低气温、相对湿度和风速预报上均优于 M1 和 M2 方法。M1、M2 和 M3 方法在 9 站点预报 ET_0 平均 RMSE 分别介于 0.66 ~ 0.93 mm/d、0.57 ~ 0.83 mm/d 和 0.53 ~ 0.79 mm/d,MAE 分别介于 0.44 ~ 0.61 mm/d、0.38 ~ 0.56 mm/d 和 0.35 ~ 0.53 mm/d,R^2 分别介于 0.82 ~ 0.91、0.84 ~ 0.93 和 0.86 ~ 0.94。3 种方法均在夏季误差最大,1 ~ 16 d 平均 RMSE 分别为 1.21、1.18、1.04 mm/d。

(3)各预报因子中太阳辐射对 ET_0 预报误差影响最大,其后依次是风速、最高气温、相对湿度和最低气温。最高气温预报对其他因子预报精度的贡献最大、对相对湿度预报精度的贡献最小。

参 考 文 献

[1] ZHANG B, KANG S, LI F, et al. Comparison of three evapotranspiration models to Bowen ratio-energy balance method for a vineyard in an arid desert region of Northwest China[J]. Agricultural and Forest Meteorology, 2008, 148(10): 1629 - 1640.

[2] PELOSI A, MEDINA H, VILLANI P, et al. Probabilistic forecasting of reference evapotranspiration with a limited area ensemble prediction system[J]. Agricultural Water Management, 2016, 178: 106 - 118.

[3] ALLEN R G. Crop evapotranpiration[R]. FAO56 Irrigation and Drainage Paper, 1998.

[4] CAI J, YU L, LEI T, et al. Estimating reference evapotranspiration with the FAO Penman - Monteith equation using daily weather forecast messages[J]. Agricultural & Forest Meteorology, 2007, 145(1 - 2): 22 - 35.

[5] LUO Y, CHANG X, PENG S, et al. Short-term forecasting of daily reference evapotranspiration using the Hargreaves - Samani model and temperature forecasts[J]. Agricultural Water Management, 2014, 136(1): 42 - 51.

[6] CHANG X, WANG S, GAO Z, et al. Forecast of daily reference evapotranspiration using a modified daily Thornthwaite equation and temperature forecasts[J]. Irrigation and Drainage, 2019, 68(2): 297 - 317.

[7] YANG Y, CUI Y, BAI K, et al. Short-term forecasting of daily reference evapotranspiration using the reduced-set Penman - Monteith model and public weather forecasts[J]. Agricultural Water Management, 2019, 211: 70 - 80.

[8] SRIVASTAVA P, HAN D, RAMIREZ M, et al. Comparative assessment of evapotranspiration derived from NCEP and ECMWF global datasets through Weather Research and Forecasting model[J]. Atmospheric Science Letters, 2013, 14(2): 118 - 125.

[9] WENG F, LIU Q. Satellite data assimilation in numerical weather prediction models. Part I: forward radiative transfer and

Jacobian modeling in cloudy atmospheres[J]. Journal of the Atmospheric Sciences, 2003, 60(21): 2633 - 2646.
[10] GREGOW E, SALTIKOFF E, ALBERS S, et al. Precipitation accumulation analysis - assimilation of radar-gauge measurements and validation of different methods[J]. Hydrology & Earth System Sciences, 2013, 17(10): 4109 - 4120.
[11] VANELLA D, INTRIGLIOLO D S, CONSOLI S, et al. Comparing the use of past and forecast weather data for estimating reference evapotranspiration[J]. Agricultural and Forest Meteorology, 2020, 295: 108196.
[12] MEDINA H, TIAN D, SRIVASTAVA P, et al. Medium-range reference evapotranspiration forecasts for the contiguous United States based on multi-model numerical weather predictions[J]. Journal of Hydrology, 2018, 562: 502 - 517.
[13] LUO Y, TRAORE S, LYU X, et al. Medium range daily reference evapotranspiration forecasting by using ANN and public weather forecasts[J]. Water Resources Management, 2015, 29(10): 3863 - 3876.
[14] YIN J, DENG Z, INES A V, et al. Forecast of short-term daily reference evapotranspiration under limited meteorological variables using a hybrid bi-directional long short-term memory model (Bi - LSTM)[J]. Agricultural Water Management, 2020, 242: 106386.
[15] TRAORE S, LUO Y, FIPPS G. Deployment of artificial neural network for short-term forecasting of evapotranspiration using public weather forecast restricted messages[J]. Agricultural Water Management, 2016, 163: 363 - 379.
[16] LU X, FAN J, WU L, et al. Forecasting multi-step ahead monthly reference evapotranspiration using hybrid extreme gradient boosting with grey wolf optimization algorithm[J]. Computer Modeling in Engineering & Sciences, 2020, 125(2): 699 - 723.
[17] 朱跃建. 基于最新全球集合预报系统的可预报性评估[J]. 大气科学学报,2020,43(1): 193 - 200.
ZHU Yuejian. An assessment of predictability through state-of-the-art global ensemble forecast system[J]. Transactions of Atmospheric Sciences, 2020, 43(1): 193 - 200. (in Chinese)
[18] BARTIER P M, KELLER C P. Multivariate interpolation to incorporate thematic surface data using inverse distance weighting (IDW)[J]. Computers & Geosciences, 1996, 22(7): 795 - 799.
[19] PANOFSKY H A, BRIER G W. Some application of statistics to meteorology[D]. State Univ., 1968.
[20] LI H, SHEFFIELD J, WOOD E F. Bias correction of monthly precipitation and temperature fields from Intergovernmental Panel on Climate Change AR4 models using equidistant quantile matching[J]. Journal of Geophysical Research: Atmospheres, 2010, 115: D10101.
[21] KE G, MENG Q, FINLEY T, et al. LightGBM: a highly efficient gradient boosting decision tree[J]. Advances in Neural Information Processing Systems, 2017, 30: 3146 - 3154.
[22] 苏宝峰,张旭东,米志文,等.基于光照度的农田蒸散量估算方法研究[J/OL].农业机械学报, 2021,52(4):285 - 292,310.
SU Baofeng, ZHANG Xudong, MI Zhiwen, et al. Forecasting method of hay evapotranspiration based on illumination[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2021,52(4): 285 - 292,310. https://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag=1&file_no=20210430&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2021.04.030. (in Chinese)
[23] FAN J, MA X, WU L, et al. Light Gradient Boosting Machine: an efficient soft computing model for estimating daily reference evapotranspiration with local and external meteorological data[J]. Agricultural Water Management, 2019, 225: 105758.
[24] 江显群, 陈武奋, 邵金龙. 基于公共天气预报的参考作物腾发量预报[J].排灌机械工程学报,2019, 37(12): 1077 - 1081.
JIANG Xianqun, CHEN Wufen, SHAO Jinlong. Forecast of reference crop evapotranspiration based on public weather forecast [J]. Journal of Drainage and Irrigation Machinery Engineering,2019, 37(12): 1077 - 1081. (in Chinese)
[25] 徐俊增,刘文豪,刘博弈, 等.基于天气预报的参考作物腾发量预报方法比较[J].河海大学学报(自然科学版), 2019, 47(2): 156 - 162.
XU Junzeng, LIU Wenhao, LIU Boyi, et al. Comparison of three reference crop evapotranspiration forecasting methods based on weather forecast[J]. Journal of Hohai University (Natural Sciences),2019, 47(2): 156 - 162. (in Chinese)
[26] 崔宁博, 魏俊, 赵璐,等. 基于 MEA - BPNN 的西北旱区参考作物蒸散量预报模型[J/OL].农业机械学报,2018, 49(8): 228 - 236,307.
CUI Ningbo, WEI Jun, ZHAO Lu, et al. Reference crop evapotranspiration prediction model of arid areas of Northwest China based on MEA - BPNN[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(8): 228 - 236, 307. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag=1&file_no=20180827&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2018.08.027. (in Chinese)
[27] MEDINA H, TIAN D. Comparison of probabilistic post-processing approaches for improving numerical weather prediction-based daily and weekly reference evapotranspiration forecasts[J]. Hydrology and Earth System Sciences, 2020, 24(2): 1011 - 1030.
[28] 夏兴生,朱秀芳,潘耀忠,等. 地表太阳辐射经验值对参考作物需水量计算的影响[J/OL].农业机械学报,2020, 51(2): 254 - 266.
XIA Xingsheng, ZHU Xiufang, PAN Yaozhong, et al. Influence of solar radiation empirical values on reference crop evapotranspiration calculation in different regions of China[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(2): 254 - 266. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag=1&file_no=2002028&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2020.02.028. (in Chinese)