文章编号:1672-3031(2021)01-0033-12

考虑气象因子不确定性的参考作物蒸散量预报方法

韩 信[1,2], 张宝忠[1], 魏 征[1], 李益农[1], 陈 鹤[1]
(1. 中国水利水电科学研究院 流域水循环模拟与调控国家重点实验室, 北京 100038;
2. 中国农业大学 水利与土木工程学院, 北京 100083)

摘要: 参考作物蒸散量(ET_0)的准确预测预报对于制定作物灌溉制度与实时灌溉调度具有重要意义, 然而气象因子的不确定性极大的影响着ET_0的预测精度。因此本研究采用马尔科夫蒙特卡罗模拟与自适应采样算法相结合的方法(AM-MCMC)对气象因子的不确定性进行修正, 以气象站实测ET_0作为标准值, 利用径向基神经网络(RBF)模型建立气象因子与ET_0的映射关系, 建立基于气象因子不确定性的ET_0不确定性预测模型(CU-RBF), 并以华北平原农田下垫面为例进行验证。结果表明, 与传统的RBF确定性预报结果相比, CU-RBF预测结果的各精度评价效果均有所提高, 纳什系数提高了10%, 均方根误差和平均绝对误差分别降低了16.94%、17.05%, 且单独修正平均风速的CU-RBF$_w$预测模型效果比分别单独修正最高温度、平均相对湿度的预测模型效果好。考虑气象因子不确定性开展ET_0的预报研究, 减小了预测值与实际值的误差, 可为农田下垫面的未来水分管理提供科学依据。

关键词: 参考作物蒸散量; 气象因子; 不确定性; 贝叶斯预报系统; 径向基神经网络
中图分类号: P338 **文献标识码:** A **doi:** 10.13244/j.cnki.jiwhr.20200167

1 研究背景

参考作物蒸腾量(ET_0)是水资源与灌溉管理的重要数据, 是水分平衡和灌溉调度的关键因素[1-3], 其计算和预测方法不仅成为农田生态系统水分循环和水平衡研究的重要领域, 同时在农田灌溉制度优化和水土资源配置等方面具有重要作用[4]。因此, 为了更好地管理作物灌溉用水量以及提高作物水分利用效率, 亟待对作物ET_0进行准确预测。

1998年FAO-56推荐的Penman-Monteith (PM)模型是计算ET_0的标准计算方法, 能够得到较精确的结果[1]。ET_0与气候变化等自然因素密切相关[5]。近年来涌现出诸多的ET_0预测方法, 如时间序列法[6-7]、灰色模型法[8]和经验公式法[9-10]。由于ET_0与气象因子之间存在复杂的非线性关系, 常规的预测模型忽视其复杂的非线性关系造成预测精度不高, 因此基于神经网络建立预测模型能够考虑众多因素对ET_0的影响[11-12], 具有良好的应用推广价值。且径向基人工神经网络(RBF)较Back Propagation(BP)神经网络具有更好的适用性[13-14]。Ozgur[15]用Levenberge Marquardt(LM)训练算法建立了基于RBF模型的ET_0预测, 并得到较好的结果, Sudheer等[16]利用有限的气象资料建立了估算水稻日蒸散量的RBF模型, 模型预测性能可靠。但是影响ET_0的气象因子本身也具有不确定性[17], 因此, 近年来不确定性分析逐渐受到关注, 但是考虑气象因子不确定性的影响对ET_0预测的研究较少。

本研究以华北平原农田下垫面为研究对象, 以研究区1981—2018年气象因子和ET_0(PM模型计算)资料序列为基础, 在贝叶斯理论框架下, 根据马尔科夫蒙特卡罗模拟与自适应采样算法结合的方法修正ET_0影响因子, 基于RBF模型构建ET_0不确定性预测模型。

收稿日期: 2020-08-12; 网络首发时间: 2021-01-25
网络首发地址: https://kns.cnki.net/kcms/detail/11.5020.TV.20210122.1708.003.html
基金项目: 国家自然科学基金(51822907); 中国水利水电科学研究院"五大人才"计划(ID0145B742017)
作者简介: 韩信(1990-), 博士生, 主要从事灌区需耗水预测预报研究。E-mail: xinhan0111@163.com
通讯作者: 张宝忠(1981-), 教授级高级工程师, 主要从事蒸散发尺度效应、现代灌区高效用水理论与技术研究。E-mail: zhangbz@iwhr.com

2 预报方法简介

2.1 研究区概况与数据来源 北京市大兴区(39°26′—39°51′N，116°13′—116°43′E)位于华北平原北部永定河冲击平原，总面积1031 km^2，属于温带半湿润季风气候。季节变化明显，夏季短而炎热，冬季长而寒冷。多年平均气温12.1 ℃，平均最高气温14.8 ℃，最低气温6.7 ℃，平均相对湿度53%，年平均风速1.84 m/s，年平均蒸散量1080 mm，多年年平均降雨量540 mm，7—9月降雨较多，降雨量占全年降雨总量的80%以上。北京市大兴区下垫面主要为农田，包括玉米/小麦、大豆，其中以玉米和小麦轮作为主，冬小麦整个生育期为260天左右(10月1日—次年6月30日)，在正常年份冬小麦需补充灌溉，以保证作物对水分的需求。夏玉米生长期约90天左右(7月1日—9月30日)，夏玉米全生育期不灌水[18]。

从中国气象科学共享服务网(http：//cdc.cma.gov.cn)收集了北京市大兴区1981—2018年的逐日历史气象数据和2013—2018年的逐日天气预报数据，建模数据系列长度统一采用1981—2018年共38年的1—12月逐月数据。气象数据包括最高温度、最低温度、平均温度、平均相对湿度、最小相对湿度、日照时数、最大风速、极大风速、平均风速、参考作物蒸散量。天气预报数据及信息包括：最高温度、最低温度、相对湿度及天气情况等，为了保持前后因子的一致性，最终选取最高温度(T_{max})、最低温度(T_{min})、相对湿度(RH)和平均风速(Ws)建立ET_0预测模型。天气预报信息中T_{max}、T_{min}、RH可以直接利用，Ws则需要根据研究区天气情况预报和气象标准进行解析[19]。根据风速对地面的影响而引起的各种现象，按照风速等级确定距离平面高处2 m的平均风速(表1)。

表1 风速等级

风级	标准	风速/(m/s)	均值/(m/s)	风级	标准	风速/(m/s)	均值/(m/s)
0	无风	0~0.1	0	7	劲风	10.4~12.8	12.0
1	轻风	0.2~1.1	0.7	8	大风	12.9~15.5	14.2
2	轻风	1.2~2.5	1.5	9	烈风	15.6~18.3	17.2
3	微风	2.6~4.0	3.0	10	狂风	18.4~21.2	19.4
4	和风	4.1~5.9	5.2	11	暴风	21.3~24.4	23.2
5	清风	6.0~8.0	6.7	12	飓风	24.5~27.6	26.2
6	强风	8.1~10.3	9.0				

2.2 模型方法

2.2.1 *参考作物蒸散量标准值* 以从中国气象科学共享服务网(http：//cdc.cma.gov.cn)获取的研究区实测的逐日参考作物蒸散量(ET_0)为标准值。

2.2.2 *基于气象因子不确定性的RBF模型构建* 利用径向基人工神经网络模型(RBF-ANN)建立气象因子与ET_0的映射关系，并将其作为贝叶斯概率预报系统的似然函数，以ET_0标准值为后验信息，对ET_0影响因子先验信息进行贝叶斯修正，利用基于自适应算法的马尔可夫链蒙特卡罗随机模拟算法获取各气象因子的后验密度。最后将修正后的因子结合RBF-ANN模型构建考虑气象因子不确定性的ET_0预报模型(CU-RBF)。

(1)因子不确定性修正。基于贝叶斯概率预报系统对气象因子的不确定性进行修正。贝叶斯概率预报系统由Krzysztofowicz[20]提出，是一种通用的概率水文预报理论，可以与确定性水文模型耦合，考虑因子不确定性的ET_0预测是在贝叶斯推断的基础上提出的，计算式为：

$$h(y|x)=\frac{f(y)p(x|y)}{\int f(y)p(x|y)\mathrm{d}y} \tag{1}$$

式中：$h(y|x)$为后验分布；$p(x|y)$为x对y的条件概率；$f(y)$为y的边缘密度，即先验分布。

假设气象数据X(x_1为最高温度、x_2为最低温度、x_3为平均相对湿度、x_4为平均风速)的先验密度为$g(x)$；ET_0预测模型输出参考作物蒸散量S_n已知时，X的似然函数为$f(S|X)$。利用贝叶斯理论修正影响因子的不确定性，输出S_n的期望值为：

$$k(S_n|X)=\int_{-\infty}^{+\infty} f(S_n|X)g(X)\mathrm{d}X \tag{2}$$

$$\varphi(X|S_n)=\frac{f(S_n|X)g(X)}{k(S_n|X)}=\frac{f(S_n|X)g(X)}{\int_{-\infty}^{+\infty} f(S_n|X)g(X)\mathrm{d}X} \tag{3}$$

式中：φ为$X\left(X=\{x_1,\ x_2,\ x_3\}\right)$的水文不确定性的定量表达；$k$为归一化常数。

(2)修正后因子计算。AM算法是由Haario等[21]提出的一种有效的MCMC采样器，其主要特点是随机抽样的参数空间初始协方差矩阵由先验密度确定的多维正态分布，AM算法的主要步骤如下：

(a)初始化，$i=0$；

(b)计算转移密度的协方差矩阵：

$$C_i=\begin{cases}C_0, & i\leqslant t_0\\ s_d\left(Cov\left(X_0,\ X_1\cdots X_{i-1}\right)\right)+s_d\varepsilon I_d\end{cases} \tag{4}$$

式中：C_0为初始协方差；ε为一个较小的正数，避免C_i为奇异矩阵；s_d取值为$2.4^2/d$；I_d为d维单位矩阵；t_0为初次抽样次数。

第一次迭代的协方差计算式为：

$$C_{i+1}=\frac{i-1}{i}C_i+\frac{s_d}{i}\left(i\,\overline{X_{i-1}}\overline{X}_{i-1}^{\mathrm{T}}-(i+1)\overline{X_i}\,\overline{X_i^{\mathrm{T}}}+X_i X_i^{\mathrm{T}}+\varepsilon I_d\right) \tag{5}$$

式中：$\overline{X_{i-1}}$、$\overline{X_i}$分别为前$i-1$次、i次抽样的均值；X_i^{T}为向量X_i的转置。

(c)从转移密度$N\left(X_{iv},\ C_i\right)$中产生新的样本$X_i^{*}$。

(d)计算新样本X_i^{*}的接受概率，计算式为：

$$\alpha=\min\left\{1,\ \frac{f\left(S_n|X_i^{*}\right)g\left(X_i^{*}\right)}{f\left(S_n|X_i\right)g\left(X_i\right)}\right\} \tag{6}$$

(e)产生一个均匀随机数$\mu\sim U[0,\ 1]$

(f)若$\mu<\alpha$，接受$X_{i+1}=X_i^{*}$，反之，$X_{i+1}=X_i$

(g)$i=i+1$，重复步骤(b)—步骤(g)，直到达到预定精度。

(3)CU-RBF模型构建。径向基函数网络(RBF)由Broomhead提出[22]。该模型具有较快的收敛速度，在很多领域得到广泛应用[23-24]。RBF网络模型主要包括输入层、隐含层和输出层，RBF模型的表达式为：

$$F(X)=\sum_{i=1}^{q} w_i\varphi_i\left\|X-c_i\right\| \tag{7}$$

φ为可逆高斯函数：

$$\varphi(t)=\exp\left(-\frac{t^2}{\delta^2}\right) \tag{8}$$

式中：q为隐含层节点个数即样本容量；w_i为隐藏层各节点到输出层$F(X)$的权因子；c_i为第i个径向基函数的中心值；δ为径向基函数的变量，决定了该径向基函数围绕中心点的宽度。

模型的建立通过Matlab2017b的RBF工具箱来实现，具体函数的调用格式为：

$$net=newrb(P,\ T,\ goal,\ spread,\ MN,\ DF) \tag{9}$$

式中：P、T分别为输入和输出变量；$goal$为均方误差，取$goal=0.001$，避免过度拟合；$spreads$为RBF函数的宽度，通过隐含层神经元的中心距离确定；MN为ANN学习过程中神经元最大数目；

DF 为2次显示之间添加神经元的个数。

仿真函数调用为：

$$Y=\mathrm{sim}(net,\ X) \tag{10}$$

式中：Y为预测目标值；X为输入测试矩阵，net 为式(9)中已经学习好的网络。

(4)训练集、验证集及测试集。选择1981—2018年1—12月444组修正后的历史气象月数据(T_{max}、T_{min}、RH和Ws)和以从中国气象科学共享服务网(http：//cdc.cma.gov.cn)获取的研究区逐日ET_0累加得到的月ET_0作为训练集；选择2013—2015年36组修正后的历史天气预报月数据(根据天气预报日值累加所得）和月ET_0数据作为验证集；选择2016—2018年36组修正后的历史天气预报月数据(根据天气预报日值累加所得)作为测试集。

2.3 模型评价 对于使用RBF神经网络模型预测值与PM计算标准值之间的相互比较，使用了5个评价指标，包括决定系数(R^2)、纳什系数(NSE)、均方根误差($RMSE$)、平均绝对误差(MAE)和相对误差(RE)来评估模型的预测性能[25]，计算如下：

$$R^2=\frac{\sum_{i=1}^{n}\left(x_i-\bar{x}\right)^2\left(y_i-\bar{y}\right)^2}{\sum_{i=1}^{n}\left(x_i-\bar{x}\right)^2\sum_{i=1}^{n}\left(y_i-\bar{y}\right)^2} \tag{11}$$

$$NSE=1-\frac{\sum_{i=1}^{n}\left(y_i-x_i\right)^2}{\sum_{i=1}^{n}\left(y_i-\bar{y}\right)^2} \tag{12}$$

$$RMSE=\sqrt{\sum_{i=1}^{n}\frac{\left(x_i-y_i\right)^2}{n}} \tag{13}$$

$$MAE=\frac{\sum_{i=1}^{n}\left|x_i-y_i\right|}{n} \tag{14}$$

$$RE=\frac{x_i-y_i}{y_i}\times 100\% \tag{15}$$

式中：x_i为ET_0预报值(利用修正后的气象数据结合径向基神经网络预测所得)；y_i为ET_0标准值(从中国气象科学共享服务网(http://cdc.cma.gov.cn)获取的研究区逐日ET_0)；y为标准值均值；i为预报样本序列，i=1，2，…，x；n为预报值的样本数。

3 结果与分析

3.1 数据集及先验密度 图1和表2为华北平原农田下垫面1981—2018年气象因子和ET_0的数据系列，气象因子包括最高温度(T_{max})、最低温度(T_{min})、相对湿度(RH)、平均风速(Ws)和ET_0。T_{max}、T_{min}、RH、Ws和ET_0多年平均值分别为15.15 ℃、6.74 ℃、44.20%、1.89 m/s和1063 mm，多年偏差系数分别为-0.36、-0.34、0.65、-0.36和-0.68，多年的气象因子和ET_0都在均值周围有微小的波动，标准偏差分别为0.49 ℃、0.53 ℃、3%、0.16 m/s和0.1 mm。

图2为气象因子的正态概率分布。由图2可知，各气象因子均近似服从正态分布，通过SPSS软件分析所知各因子的正态性假设均通过5%的显著性水平。ET_0影响因子的先验密度和标准方差见表3，由表3可以看出，各月Ws的分布差异性较大，变差系数(C_V均值为0.13)比T_{max}(C_V均值为0.11)、T_{min}(C_V均值为0.06)和RH(C_V均值为0.07)的大，表明Ws相对其他气象因子的不确定性较强。

3.2 气象因子不确定性识别 由于本研究所选气象因子为4个变量，即T_{max}、T_{min}、RH、Ws，因此C_0矩阵对角线元素取为各变量的先验方差。设定AM-MCMC算法的初始抽样次数为2000，运行次数38次，每次采样10 000个，这样共抽取有效模拟样本数为304 000个，用于每月气象因子后验分布的统

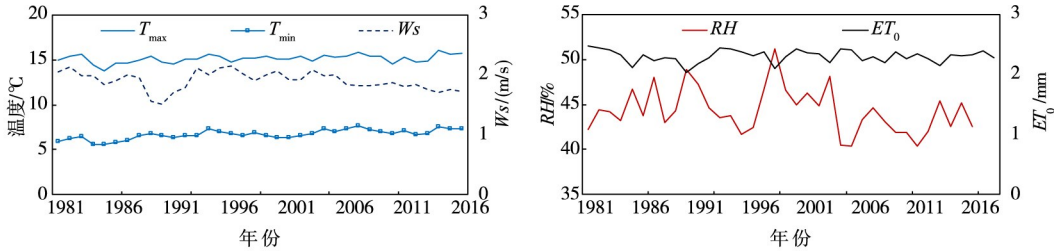


图1　研究区1981—2018年气象参数及ET_0资料系列

表2　气象参数和ET_0

因子	均值	中值	*RMSE*	变差系数
T_{max}/℃	15.16	15.24	0.49	−0.36
T_{min}/℃	6.74	6.75	0.53	−0.34
RH/%	44.20	44	3	0.65
Ws/(m/s)	1.89	1.90	0.16	−0.36
ET_0/(mm)	2.30	2.32	0.10	−0.68

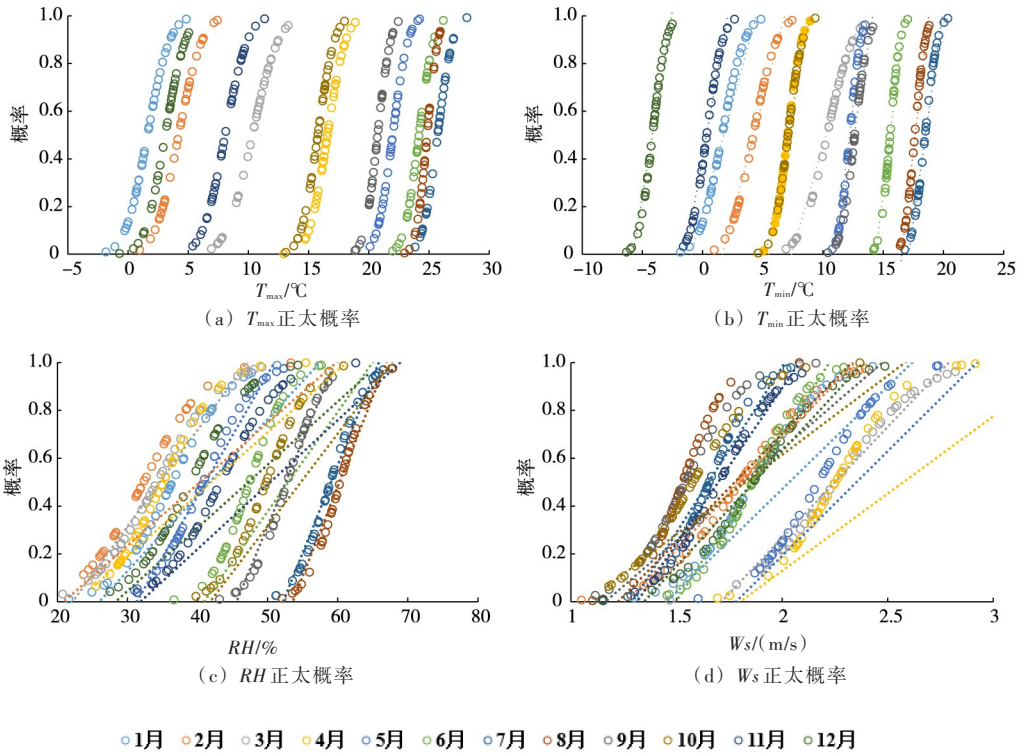


图2　各气象因子的正态概率图

计分析。气象因子在迭代2000次后已经收敛，所抽取的样本已具有其总体的统计特征。

分别以3月(作物生长早期)、7月(作物生长中期)和10月(作物生长后期)典型月为例，所抽取各影响因子的后验密度直方图见图3—图5。T_{max}、T_{min}、*RH*、*Ws*的后验密度分别为：最高温度x_1~N(10.46，0.98^2)，最低气温x_2~N(1.49，0.56^2)，相对湿度x_3~N(34.62，0.02^2)，平均风速x_4~N(2.27，0.13^2)；最高温度x_1~N(25.73，0.52^2)，最低气温x_2~N(18.54，0.35^2)，相对湿度x_3~N(58.97，0.01^2)，平均风速x_4~N(1.65，0.06^2)；最高温度x_1~N(16.03，0.68^2)，最低气温x_2~N(7.03，0.41^2)，相对湿度x_3~N(49.69，0.01^2)，平均风速x_4~N(1.60，0.07^2)。对于*Ws*先验密度的修正较T_{max}、T_{min}和*RH*大，在相同的显著性水平条件下，各影响因子的置信区间不同，其中*Ws*比T_{max}、T_{min}和*RH*的范围大，说明*Ws*具有较强的不确定性，主要是因为*Ws*受到外界的干扰较为敏感。因此，后验信息对*Ws*的修正程

表3　各月ET_0影响因子的先验密度

月份	T_{max}/℃		T_{min}/℃		RH/%		Ws/(m/s)	
	均值	变异系数	均值	变异系数	均值	变异系数	均值	变异系数
1	1.62	0.09	−6.00	−0.20	36.41	0.07	1.86	0.14
2	4.21	0.37	−3.38	−0.34	32.30	0.07	1.80	0.17
3	10.34	0.16	1.24	0.95	34.20	0.06	2.25	0.14
4	16.56	0.07	7.06	0.13	35.09	0.05	2.25	0.11
5	21.99	0.05	12.22	0.06	40.82	0.04	2.17	0.12
6	24.17	0.04	15.57	0.04	47.44	0.04	1.86	0.11
7	25.72	0.04	18.48	0.04	58.97	0.04	1.65	0.11
8	24.85	0.03	17.63	0.04	60.34	0.04	1.53	0.11
9	20.74	0.04	12.63	0.07	52.78	0.05	1.54	0.14
10	15.77	0.07	7.09	0.14	49.82	0.07	1.58	0.17
11	8.07	0.18	0.33	0.17	43.28	0.07	1.70	0.13
12	3.09	0.43	−4.16	−0.22	38.99	0.29	1.86	0.16

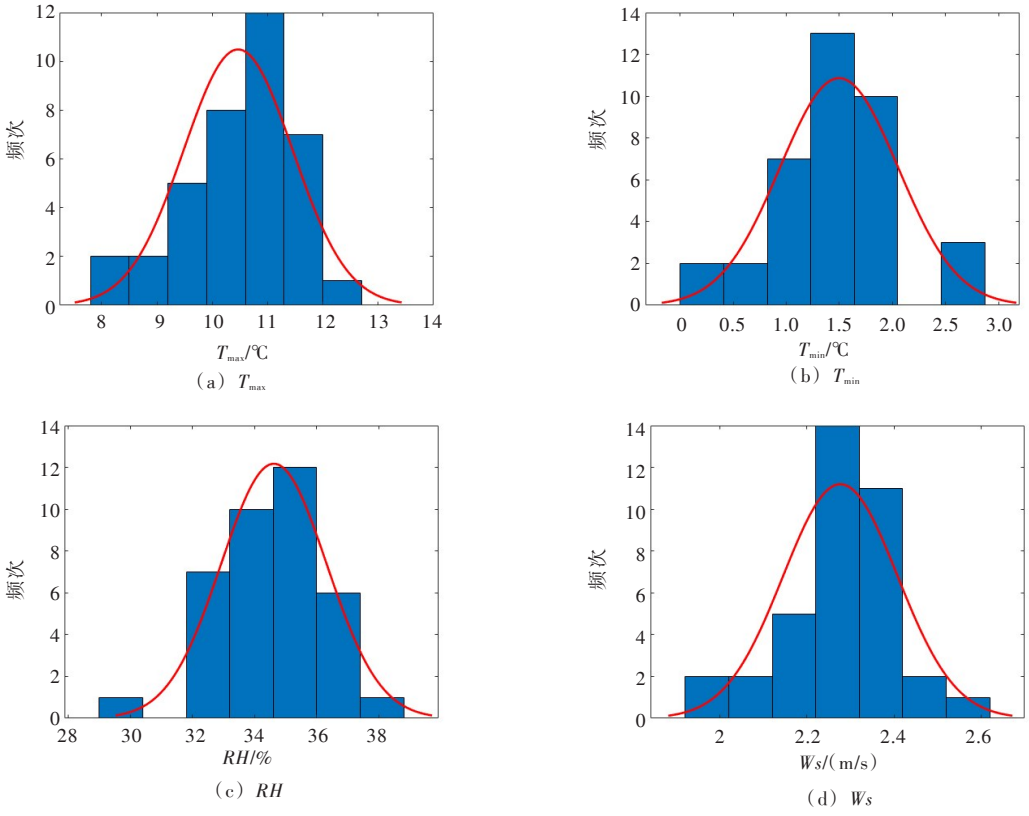


图3　3月份频率直方图和密度曲线

度较其他3个因子大。Pereira等[4]的研究结果也表明为了避免因Ws的不确定性带来的作物耗水预测不确定性，在进行耗水预测时将不考虑Ws，而仅考虑T和RH等因子。由此可见，考虑Ws进行ET_0预测时，对其不确定进行修正是必要的。

3.3　参考作物蒸散量预测

3.3.1　单气象因子不确定性修正对ET_0预测影响　由3.2节可知，在相同的显著性水平条件下，各气象因子的均值置信区间范围不同，其中Ws比T_{max}、T_{min}和RH的范围大，说明Ws表现出较强的不确定性。图6和表4为预测期单独考虑修正某一因子(T_{max}、Ws和RH)后RBF预测ET_0的效果。

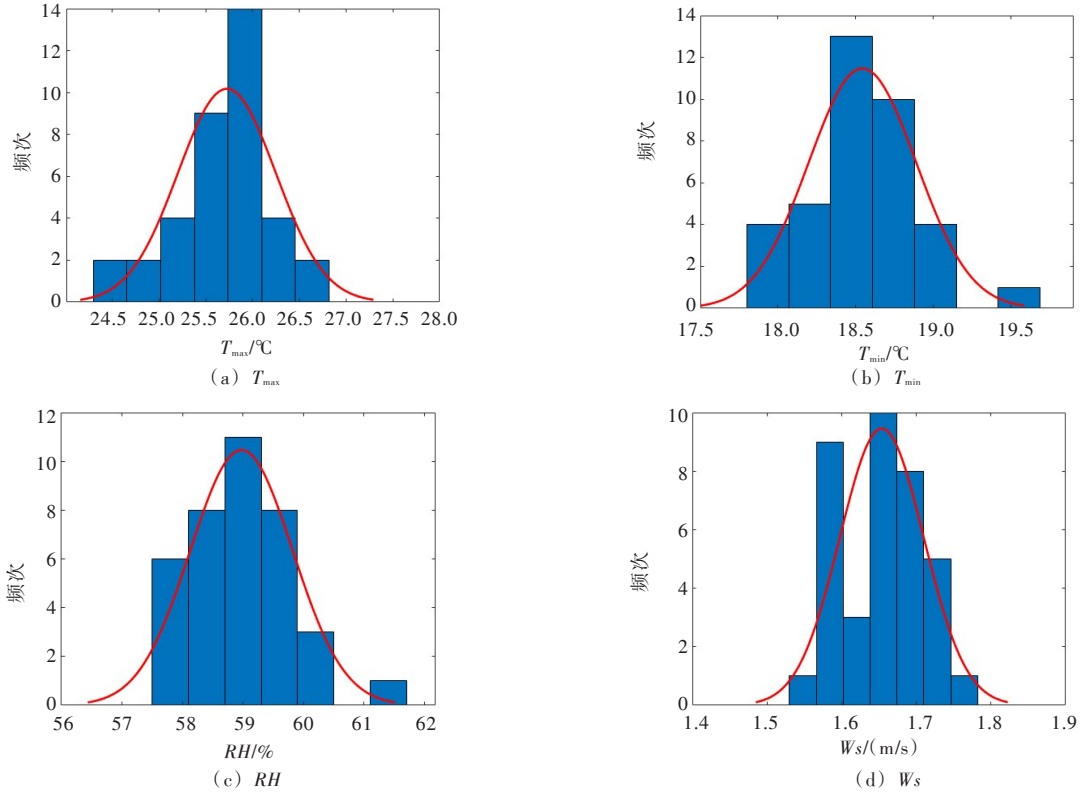


图4　7月份频率直方图和密度曲线

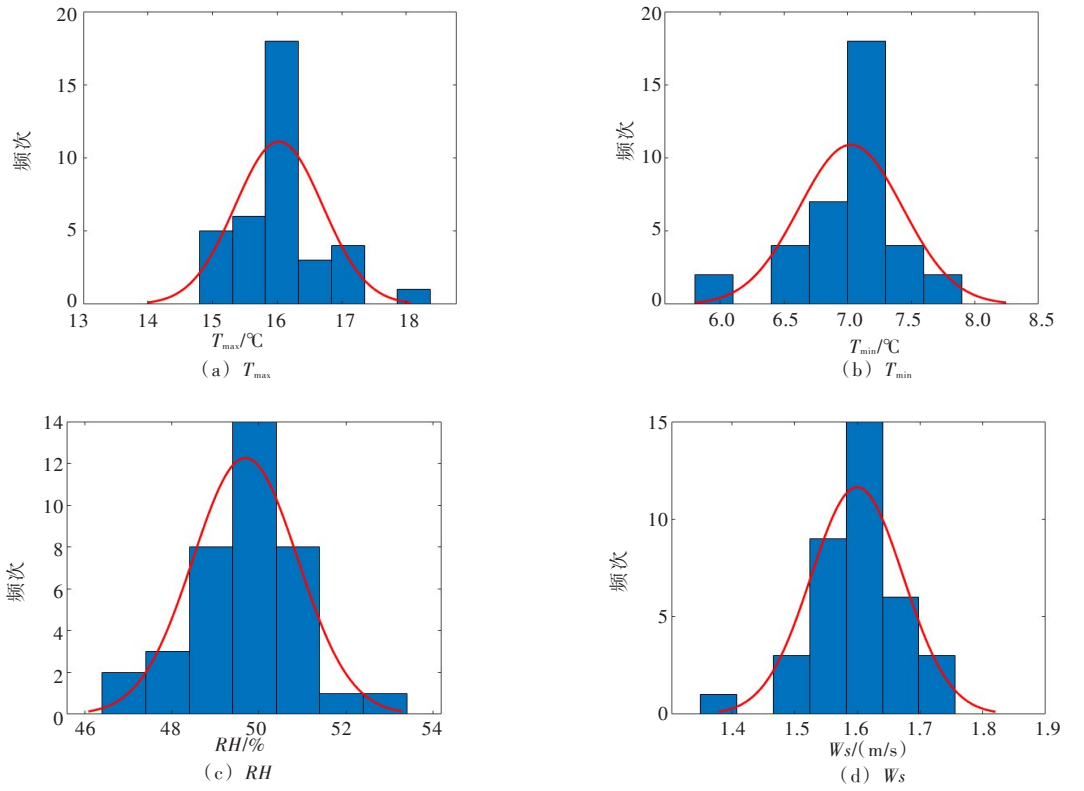


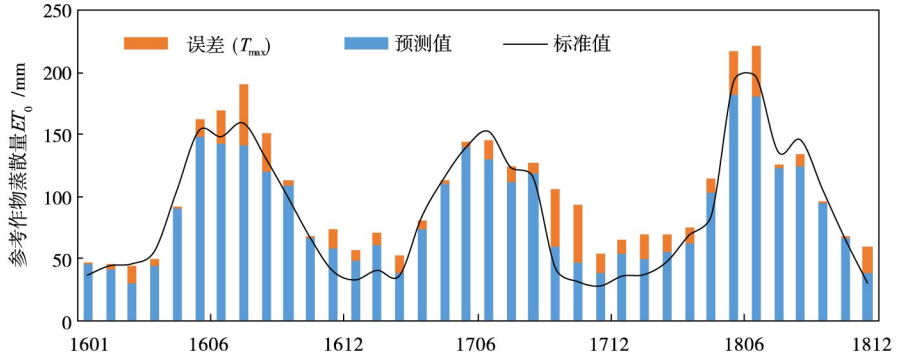
图5　10月份频率直方图和密度曲线

由图6和表4可知，当单独对T_{max}修正后，基于RBF模型的ET_0的预测值与标准值的变化趋势基本一致，且效果较未修正前好，模型评价参数效果均有所提高，R^2、NSE分别增加0.04、0.01，

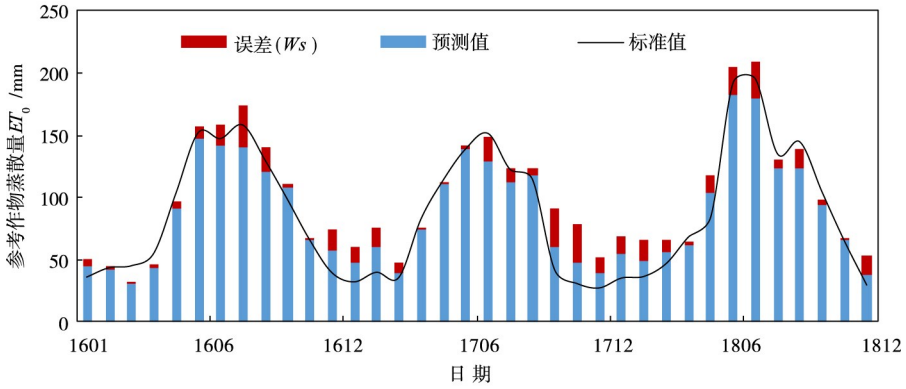
表4　分别单独修正气象因子不确定性修正前后ET_0预测效果

参数	RBF	CU-RBF	CU-RBF$_{Tmax}$	CU-RBF$_{Ws}$	CU-RBF$_{RH}$
R^2	0.89	0.97	0.93	0.95	0.90
NSE	0.90	0.99	0.91	0.92	0.90
RMSE/mm	46.27	38.43	45.55	40.19	46.06
MAE/mm	1.29	1.07	1.27	1.12	1.28
RE/%	3.34	−0.02	3.12	1.63	3.2

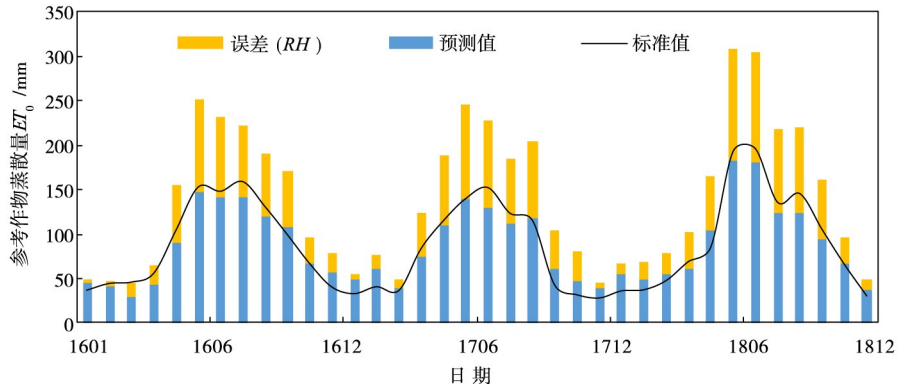
注：RBF代表确定性ET_0预测模型，CU-RBF代表考虑气象因子不确定性的ET_0预测模型；CU-RBF$_{Tmax}$代表单独修正最高温度不确定性的ET_0预测模型；CU-RBF$_{Ws}$代表单独修正平均风速不确定性的ET_0预测模型；CU-RBF$_{RH}$代表单独修正平均相对湿度不确定性的ET_0预测模型。



(a)最高温度



(b)平均风速



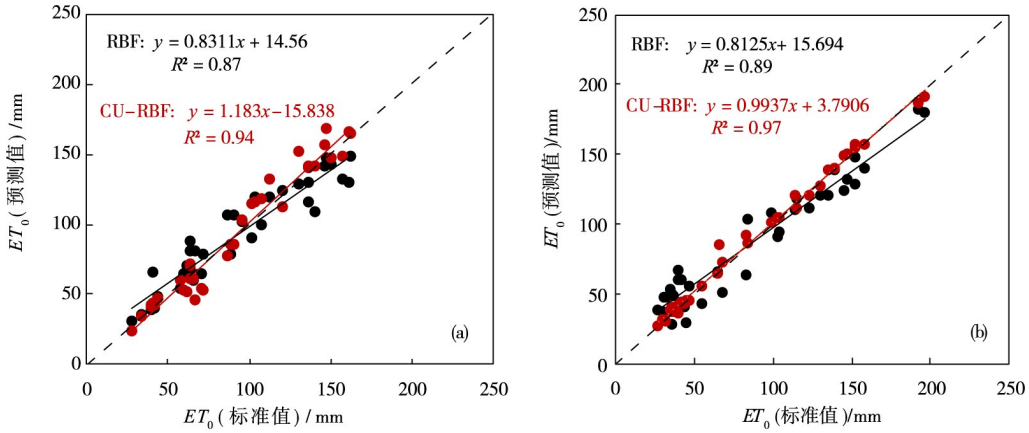
(c)相对湿度

(图中横坐标中前2个数代表年份，后2个数代表月份，如1601中16代表2016年，01代表1月；图中误差(T_{max})为考虑修正最高气温后预测值与标准值的误差，误差(*Ws*)为考虑修正平均风速后预测值与标准值的误差，误差(*RH*)为考虑修正相对湿度后预测值与标准值的误差)

图6　最高温度、相对湿度和平均风速分别修正前后ET_0预测效果

RMSE、*MAE* 和 *RE* 分别减少 0.72 mm、0.02 mm 和 0.22%，当分别单独考虑 *Ws* 和 *RH* 修正后，基于 RBF 模型的 ET_0 的预测值与标准值的变化趋势基本一致，效果均较未修正前好，模型评价参数效果均有所提高。R^2、*NSE* 分别增加 0.06、0.01 和 0.02、0.01，*RMSE*、*MAE* 和 *RE* 分别减少 6.08 mm、0.17 mm、1.71% 和 0.21 mm、0.01 mm、0.14%。由图 6 对比可知，单独对 *Ws* 修正，相较于分别单独修正 T_{max} 和 *RH* 时的预测效果较好，可能是因为风速与气象因子以外的农田下垫面、观测高度等有关，修正后的 *Ws* 能够削弱外界条件对其的不确定性影响。而单独对 *RH* 进行修正时预测效果较差，R^2、*NSE* 分别相差 0.05、0.02，*RMSE*、*MAE* 和 *RE* 分别相差 5.87mm、0.16mm、1.57%，可能是因为 *RH* 与降雨有直接关系，该研究结果与 Mohmmad、刑贞相等研究结果一致[26-27]，在降雨条件下，各个气象因子的不确定性增加，未对其他气象因子进行修正必然会造成预测的误差。

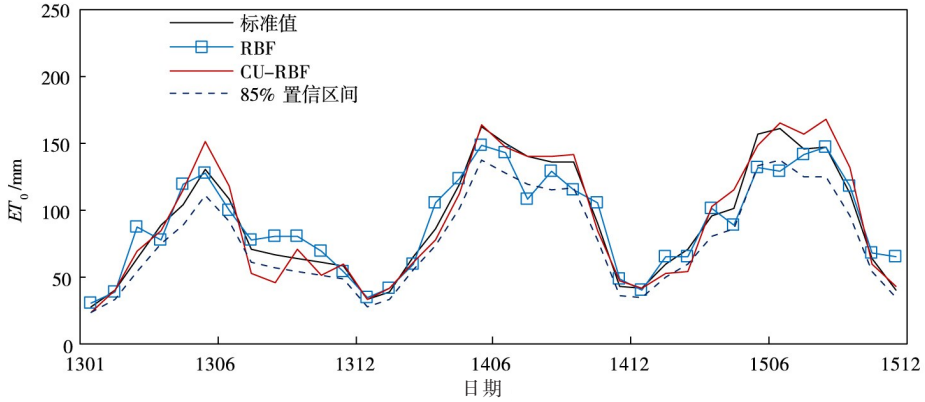
3.3.2　考虑气象因子不确定性修正的 ET_0 预测　以 AM-MCMC 算法随机模拟每月 8000 组 ET_0 影响因子相应的 RBF 预报值为对应月份 ET_0 的预测集合，将均值作为该月的 ET_0 预测值，并得出指定概率(85%)的置信区间，实现了考虑了 RBF 模型输入不确定性对 ET_0 预报不确定性的影响(CU-RBF)。其中 2013—2015 年为验证期，2016—2018 年为测试期，验证期和测试期的各月 ET_0 计算与实测过程以及 RBF 的确定性和不确定性预报过程分别见图 7 和图 8。



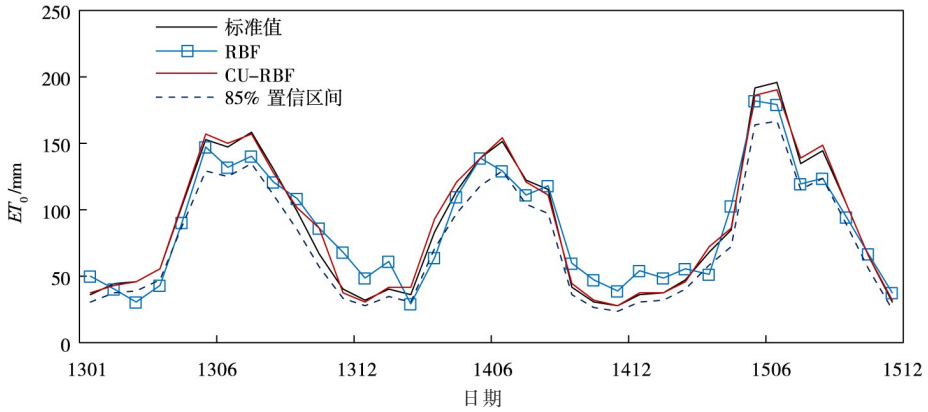
(a)验证期(2013—2015 年)　　(b)测试期(2016—2018 年)

图 7　验证期和测试期 RBF、CU-RBF 与标准值相关性分析

由图 7(a)、图 8(a)和表 5 可以看出，验证期(2013—2015)和测试期(2016—2018)在未考虑气象因子不确定性下建立的 ET_0 预测模型(RBF)预测值与基于 PM 模型计算的标准值的相关性 R^2 分别为 0.87 和 0.89，拟合回归系数分别为 0.83 和 0.81，*NSE* 分别为 0.88、0.93。RBF 确定性模型预测得到的 ET_0 与 PM 模型计算的标准值趋势基本一致，月均值分别为 91.28 mm 和 88.98 mm，均方根 *RMSE* 和 *MAE* 分别为 50.91 mm、46.27 mm 和 1.41 mm、1.29 mm；均值 *RE* 分别为 6.99%、3.34%。由图 7(b)、图 8(b)和表 5 可以看出，验证期和测试期在考虑气象因子不确定性下建立的 ET_0 概率预测模型(CU-RBF)预测值与基于 PM 模型计算的标准值的相关性的 R^2 分别为 0.94 和 0.97，拟合回归系数分别为 1.18 和 0.99，*NSE* 分别为 0.90、0.99。CU-RBF 确定性模型预测得到的 ET_0 与 PM 模型计算的标准值趋势基本一致，相较于单独考虑 T_{max}、*RH*、*Ws* 的预测模型效果较好，*NSE* 增加 0.08；月均值分别为 92.18 mm 和 91.05 mm，*RMSE* 和 *MAE* 分别为 47.28 mm、38.43 mm 和 1.31 mm、1.07 mm；均值 *RE* 分别为 1.33%、-0.02%。综上分析可知，无论在验证期和测试期，CU-RBF 模型预测的 ET_0 与标准值的 R^2、*NSE* 均有所提高，*RMSE*、*MAE* 和 *RE* 均有所下降。R^2、*NSE* 分别提高 0.07、0.08 和 0.09、0.06，*RMSE*、*MAE* 和 *RE* 分别下降 3.36 mm、7.84 mm，0.1 mm、0.22 mm 和 5.36%、3.36%。且 CU-RBF 能给出预报值的 85% 置信区间，其中 ET_0 标准值包含在指定的概率区间内的比例较高。Sudheer、邢贞相和德佳硕等[16,27-28]研究同样表明气象因子的不确定性必然影响作物需水预测的精度，在进行基于神经网络模型对参考作物蒸散量预测前对气象因子的不确定性修正能够较大程度的提升其预测精度。



（a）验证期（2013—2015年）



（b）测试期（2016—2018年）

图8　验证期和测试期RBF、CU-RBF预测值与标准值对比

表5　CU-RBF和RBF逐月ET_0预测精度评价

参数	验证期(2013—2015年)		测试期（2016—2018年）	
	RBF	CU-RBF	RBF	CU-RBF
均值/mm	91.28	92.18	88.98	91.05
R^2	0.87	0.94	0.89	0.97
NSE	0.88	0.97	0.90	0.99
RMSE/mm	50.91	47.28	46.27	38.43
MAE/mm	1.41	1.31	1.29	1.07
RE/%	6.69	1.33	3.34	−0.02

本研究验证了气象因子不确定性修正在参考作物蒸散量预测方面实际应用的可行性，可为农田下垫面的未来水分管理提供科学依据。

4　结论

本研究通过分析华北平原区农田下垫面气象因子和ET_0的变化情况，结合贝叶斯理论，利用基于自适应采样算法的AM-MCMC求解ET_0影响因子（最高温度、最低温度、相对湿度、平均风速）的后验概率密度，应用RBF-ANN建立ET_0与气象因子的函数关系，进行ET_0预报，得到以下结论：

（1）各气象因子均近似服从正态分布，且*Ws*的变差系数比T_{max}、T_{min}和*RH*的大，相对其他主要气象因子的不确定性较强。

（2）典型月份（3月、7月和10月）的后验密度分别为：T_{max}~N（10.46，0.98^2），T_{min}~N（1.49，

0.56^2)，RH~N(34.62，0.02^2)，Ws~N(2.27，0.13^2)；T_{max}~N(25.73，0.52^2)，T_{min}~N(18.54，0.35^2)，RH~N(58.97，0.01^2)，Ws~N(1.65，0.06^2)；T_{max}~N(16.03，0.68^2)，T_{min}~N(7.03，0.41^2)，RH~N(49.69，0.01^2)，Ws~N(1.60，0.07^2)。

(3)单独修正Ws不确定性的CU-RBF$_{Ws}$模型比分别单独修正T_{max}和RH的CU-RBF预测模型好，R^2、NSE分别为0.95、0.92，$RMSE$、MAE和RE分别为40.19 mm，1.12 mm和1.63%。

(4)在验证期和测试期，考虑气象因子不确定性构建的CU-RBF模型的预报精度均有很大程度的提高。R^2、NSE分别提高0.07、0.08和0.09、0.06，$RMSE$、MAE和RE分别下降3.36 mm、7.84 mm，0.1 mm、0.22 mm和5.36%、3.36%，且CU-RBF能得到85%置信区间的预报值。

参 考 文 献：

[1] ALLEN R G, PEREIRA L S, RAES D, et al. Crop Evapotranspiration-Guidelines for Computing Crop Water Requirements-FAO Irrigation and Drainage Paper56[M]. FAO Rome 300(9), 1998.

[2] RANA G, KATERJI N. Measurement and estimation of actual evapotranspiration in the field under Mediterranean climate: a review[J]. European Journal of Agronomy, 2000, 13(2/3): 125-153.

[3] 李久生，李益农，栗岩峰，等. 现代灌溉水肥精量调控原理与应用[J]. 中国水利水电科学研究院学报，2018，16(5)：55-66.

[4] PEREIRA A, PRUITT W. Adaptation of the thornthwaite scheme for estimating daily reference evapotranspiration [J]. Agricultural Water Management, 2004, 64: 251-257.

[5] NIU J P, SU X L. Simulation and estimation of reference evapotranspiration responding to climate change in Shiyang[J]. Journal of Hydraulic Engineering, 2014, 45(3): 286-295.

[6] MARINO M A, TRACY J C, TAGHAVI S A. Forecasting of reference crop evapotranspiration [J]. Agricultural Water Management, 1993, 24(3): 163-187.

[7] 张郑贤，刘艺，张锋贤. 基于时间序列模型的济南趵突泉地下水位预测[J]. 中国水利水电科学研究院学报，2019，17(1)：53-61.

[8] 迟道才，王海南，李雪，等. 灰色新陈代谢GM(1,1)模型在参考作物腾发量预测中的应用研究[J].节水灌溉，2011(8)：32-35.

[9] IRMAK S, ALLEN R G, WHITTY E B. Daily grass and alfalfa-reference evapotranspiration estimates and alfalfa-to-grass evapotranspiration ratios in Florida[J]. Journal of Irrigation and Drainage Engineering, 2003, 129(5): 360-370.

[10] 黄强，陈子燊. 多种蒸散发公式在珠江流域的适用性分析[J]. 热带地理，2014，34(6)：737-735.

[11] 孙静，阮本清，蒋任飞，等. 青铜峡灌区参考作物蒸发蒸腾量与气象因子的灰色关联度分析[J]. 中国水利水电科学研究院学报，2006，4(3)：232-235.

[12] 蒋任飞，阮本清，韩宇平，等. 基于BP神经网络的参照腾发量预测模型[J]. 中国水利水电科学研究院学报，2005，3(4)：308-311.

[13] RUI Z, ZHANG J K, LI G Y. Research on attributes matching method based on rbf neural network in heterogeneous databases[J]. Journal of Chemical and Pharmaceutical Research, 2015, 7(3): 1234-1242.

[14] 田琳静，宋文龙，卢亦竹，等. 基于深度学习的农业区土地利用无人机监测分类[J]. 中国水利水电科学研究学报，2019，17(4)：312-320.

[15] OZGUR K. Evapotranspiration modelling from climatic data using a neural computing technique[J]. Hydrological Processes, 2007, 21: 1925-1934.

[16] SUDHEER K P, GOSAIN A K, RAMASASTRI K S. Estimating actual evapotranspiration from limited climatic data using neural computing technique [J]. Journal of Irrigation and Drainage Engineering, 2003, 129(3): 214-221.

[17] ALLAWI M F, AHMED E S. Utilizing RBF-NN and ANFIS methods for multi-lead ahead prediction model of evaporation from reservoir [J]. Water Resources Management, 2016, 30: 4773-4788.

[18] HAN X, ZHOU Q Y, ZHANG B Z, et al. Research on variation rule of sensible heat flux in field under different

soil moisture content and underlying surface by large aperture Scintillometer [C]//IFIP International Federation for Information Processing . 2019 .
[19] 闫国臣, 李先立, 李小荷 . 风力等级、风速与风压的对应关系研究[J] . 技术交流, 2014(8): 56-57 .
[20] KRZYSZTOFOWICZ R . Bayesian theory of probabilistic forecasting via deterministic hydrologic model [J] . Water Resources Research, 1999, 35(9): 2739-2750 .
[21] HAARIO H . An adaptive metropolis algorithm [J] . Bernoulli, 2001, 7(2): 223-242 .
[22] BROOMHEAD D S, LOWE D . Multivariable functional interpolation and adaptive networks[J] . Complex System, 1988, 2(3): 321-355 .
[23] 袁飞, 任立良, 姜红梅, 等 . MATLAB 神经网络工具箱在径流模拟中的应用[J] . 人民长江, 2003, 34(6): 38-40 .
[24] 牛有田, 谢迎涛, 曹向陶, 等 . 基于Matlab的BP神经网络在太阳耀斑级别预测中的应用[J] . 河南师范大学学报(自然科学版), 2014, 42(3): 39-42 .
[25] 任政, 盛东 . 基于多目标 GLUE 算法的新安江模型参数不确定性研究[J] . 水电能源科学, 2016, 34(3): 15-18 .
[26] MOHMMAD J B, HOWARD G . Competition for pulsed resources: an experimental study of establishment and coexistence for an arid-land grass [J] . Oecologia, 2006, 148(4): 555-563 .
[27] 邢贞相, 张涵, 付强, 等 . 考虑气象因子不确定性的概率降水预报研究[J] . 灌溉排水学报, 2018, 37(10): 100-107 .
[28] 德佳硕, 郭萍, 张成龙, 等 . 考虑气象因子的不确定性灌溉水资源优化配置[J] . 排灌机械工程学报, 2019, 37(6): 540-544 .

Prediction method of reference crop evapotranspiration considering the uncertainty of meteorological factors

HAN Xin[1,2], ZHANG Baozhong[1], WEI Zheng[1], LI Yinong[1], CHEN He[1]
(1. *State Key Laboratory of Simulation and Regulation of Water Cycle in River Basin, China Institute of Water Resources and Hydropower Research, Beijing* 100038, *China*;
2. *China Agricultural University of Water Conservancy and Civil Engineering, Beijing* 100083, *China*)

Abstract: The accurate prediction of reference crop evapotranspiration (ET_0) is of great significance for the formulation of crop irrigation schedule and real-time irrigation scheduling. However, the uncertainty of meteorological factors greatly affects the prediction accuracy of ET_0. Therefore, in this study, Markov Monte Carlo simulation combined with adaptive sampling algorithm (AM-MCMC) was used to modify the uncertainty of meteorological factors. ET_0 measured by meteorological station was taken as standard value, and radial basis function neural network (RBF) model was used to describe the mapping relationship between meteorological factors and ET_0. Then ET_0 uncertainty prediction model (CU-RBF) considering the uncertainty of meteorological factors was established. The farmland-underlying surface of North China Plain was taken as an example to verify the model. The results show that, compared with the traditional *RBF* deterministic prediction results, the accuracy evaluation effects of CU-RBF prediction results are improved, the *NSE* is increased by 10%, the *RMSE* and *MAE* are reduced by 16.94% and 17.05% respectively. Moreover, the prediction model with correction of average *Ws* is more effective than that with correction of T_{max} and *RH*. Considering the uncertainty of meteorological factors, the prediction of ET_0 is more consistent with the actual growth status of the crop, which provides a scientific basis for improved water management during crop production.

Keywords: reference evapotranspiration; meteorological factors; uncertainty; Bayesian forecasting system; radial basis function neural network

(责任编辑: 王学凤)