

基于机器学习技术的蒸发皿蒸发量估算模型

龙亚星^{1,2} 黄勤³ 李成伟¹

(1 陕西省大气探测技术保障中心, 西安 710015; 2 秦岭和黄土高原生态环境气象重点实验室, 西安 710016;

3 陕西省气象信息中心, 西安 710015)

摘要 为了弥补国家级气象观测站小型蒸发皿停止观测后蒸发量观测资料的空缺, 建立了陕北、关中和陕南 3 个区域数据集以及榆林、泾河和汉中 3 个单站数据集, 通过建立和优化 KNN、MLP 模型及其参数, 分别建立蒸发量区域估算模型、单站估算模型并对其进行检验。结果表明: ①进行区域蒸发量估算时, KNN 模型表现出良好的泛化性能, 均方误差、总相对误差和准确率指标值平均分别为 0.42、2.1%、57.0%; 陕北 MLP 模型的泛化性能较差; ②进行单站蒸发量估算时, 基于 k 近邻法的单站估算模型性能优于区域估算模型, 均方误差、准确率指标值平均分别为 0.48、55.0%, 榆林与泾河总相对误差指标绝对值平均为 1.6%, 汉中总相对误差指标值相对偏高, 达到 10.3%。本研究为不同气候区域及单站日、月、季和年蒸发皿蒸发量估算以及日蒸发量数据质量控制提供了一种基于机器学习的方法。

关键词 k 近邻法; 神经网络; 蒸发量; 估算; 检验

中图分类号: P412 **DOI:** 10.19517/j.1671-6345.20200211 **文献标识码:** A

引言

机器学习是人工智能研究领域中的一个极其重要的研究方向, 在当下的大数据时代背景下, 捕获数据并从中发现有价值的信息或模式, 成为气象行业创新综合观测、预报预测和气象服务方式的重要手段^[1-2]。基于气象观测数据, 机器学习技术在农业用水调度、空气质量预测、天气雷达超折射回波识别等社会生产生活领域中得到了广泛应用^[3-5]。蒸发是水循环的重要环节, 是自然界物质能量循环代谢的主要手段, 通过蒸发将植物、土壤、大气和水分紧密的联系在一起, 其在全球气候变化研究中具有敏感的指示作用^[6-10]。

有研究表明, 西北干旱区蒸发潜在在 1993 年出现了一个明显的转折变化, 由显著下降逆转为显著上升的趋势, 气候变暖、蒸发水平增大对西北干旱区生态效应的负作用已日趋凸显^[11]。于占江等^[12]分析近 40 年京津冀蒸发皿蒸发量与影响因子的相关系数发现, 气温日较差、日照时数和平均风速是影响

京津冀地区蒸发皿蒸发量变化的主要因子, 在平原地区, 平均风速是主导因子; 在山区和高原地区, 日照时数是主导因子。申双和等^[13]利用中国 472 个气象站 1957—2001 年 20 cm 口径蒸发皿的实测资料分析了中国小型蒸发皿蒸发量的变化趋势及其变化原因, 结果表明: 尽管在这 45 年间中国年平均气温以 0.2 °C/10a 的趋势递增, 但是蒸发皿蒸发量总体上却以 -34.12 mm/10a 的速度递减; 通过对彭曼公式中能量平衡项和空气动力项的分析表明, 东部蒸发皿蒸发量的下降主要是因为供蒸发的能量显著减少, 而西部地区蒸发皿蒸发量的下降主要是供蒸发的动力下降所致; 对各气象因子的趋势分析和相关分析表明, 影响蒸发量的主要因子为风速和日照时数。陕西位于中国西北内陆东部, 以北山和秦岭为界, 从北到南为温带干旱性气候、暖温带湿润性气候和亚热带大陆性气候 3 个气候带, 形成陕北黄土高原、关中平原和陕南秦巴山地, 地貌多样, 具有多种农牧业生产方式, 用水矛盾突出, 生态环境问题是该区域的重要问题^[14-16]。

<http://www.qxkj.net.cn> 气象科技

秦岭和黄土高原生态环境气象重点实验室开放研究基金课题(2020G-11)资助

作者简介: 龙亚星, 男, 1984 年生, 硕士, 工程师, 主要从事气象探测装备保障及技术研究工作, Email: yassin@sina.cn

收稿日期: 2020 年 5 月 29 日; 定稿日期: 2020 年 9 月 8 日

全国地面气象观测自动化改革后,小型蒸发皿人工观测任务全部取消,涉及全国 2 000 余个国家级气象观测站。如何弥补国家基准气候站、基本气象观测站冬季结冰期以及(常规)气象观测站蒸发皿蒸发量观测资料的空缺,是一个值得研究的科学问题。吴华斌等^[17]利用地面气象观测资料,探讨了日蒸发量与其他气象因子的相关性,建立了基于多元线性回归的日蒸发量估算方程,年蒸发量估算值与实测值的平均相对误差达到 17.2%,估算绝对误差在 $[-1.0, 1.0]$ 区间的比例达到 83.2%。徐俊增等^[18]建立了基于气象预报的参考作物蒸发蒸腾量的神经网络预测模型,平均相对误差达到 17.9%,相对误差在 20%范围内的合格率为 76.0%。闵骞^[19]以彭曼公式为基础,根据中长期气候预报中一般可给出的月、旬平均气温和中雨(雪)以上降水天数,对彭曼公式进行分解,通过分别建立月、旬水面辐射平衡值 R 、空气干燥力 E_a 2 个参数的预测模式,建立月、旬水面蒸发量预测模型,月、旬水面蒸发量的预测平均相对误差分别达到 11.9%、11.2%,相对误差在 20%以内的合格率分别为 70.4%、72.2%。以上建立的估算或预测模型均达到了生产上的一般精度要求,但部分指标值如平均相对误差、绝对误差等还存在提升的空间,且彭曼公式虽然可应用于蒸发皿蒸发量估算,但原公式中的水面辐射平衡值 R 和空气干燥力 E_a 参数还需要根据区域气候特征进行本地化修正,计算过程复杂。本文旨在利用常规地面气象观测资料,研究基于机器学习技术的不同气候区域、不同时间尺度的蒸发皿蒸发量估算方法,同时探索基于机器学习技术的日蒸发量数据质量控制内部一致性检查方法^[20]。

1 资料与方法

1.1 资料来源

本文选取陕西省 15 个国家基准(基本)气象站 2004—2015 年的逐日地面气象观测数据,数据均通过 CIMISS 气象数据统一服务接口获取,资料站点分布见图 1。

各气象站蒸发皿蒸发量在结冰期由 314 cm² 表面积、约 10 cm 高的小型蒸发皿观测,其余时间由表面积 3000 cm²、深度 60 cm 的 E-601B 大型蒸发皿测得。2 种蒸发皿的主要性能参数见表 1。

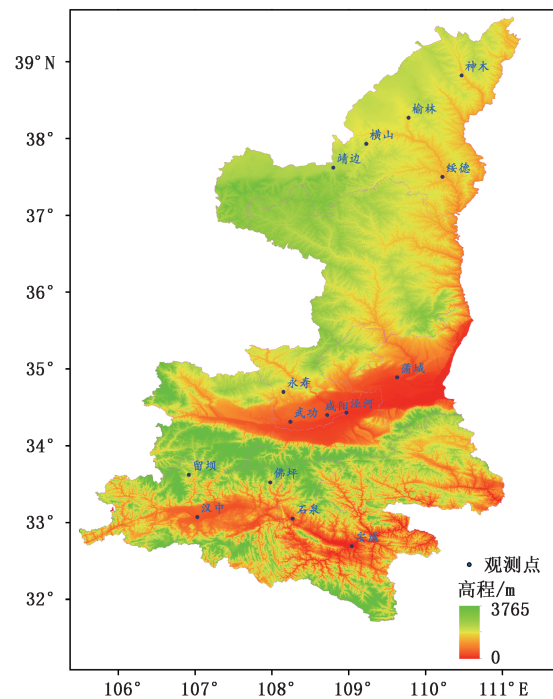


图 1 陕西省 15 个国家基准(基本)气象站分布

表 1 小型蒸发皿与 E-601B 大型蒸发皿主要性能参数及观测资料精度

	器口		器口离		分辨率	准确度
	口径	面积	深度	地高度		
	cm	cm ²	cm	cm	mm	
小型蒸发皿	20	314	10	70	0.1	±1.5%
E-601B 大型蒸发皿	61.8	3 000	68.7	30	0.1	±0.2(≤10 mm) ±2%(>10 mm)

影响蒸发的主要气象因子为动力因子、热力因子和水分因子^[21],因此选择逐日平均气压、平均气温、日照时数等 15 个气象要素作为影响蒸发(响应变量)的特征变量,某一日的特征变量及响应变量构成 1 个实例。为避免资料插补带来的误差影响,对于特征变量或响应变量存在缺测或数据错误的实例,不纳入数据集。同时,由于区别表面有无自由水存在的状况非常有必要,因此需要考虑水量、水的状态;且在干燥和半干燥地区,有必要区别蒸发面的大小及形状,因此将小型蒸发皿蒸发量折算为大型蒸发皿 E-601B 蒸发量,折算系数 τ 取陕西省年平均值 0.62^[22-25]。本文估算及检验的蒸发皿蒸发量与大型蒸发皿蒸发量对应。

分别建立陕北、关中和陕南 3 个区域数据集,以

及分别属于陕北、关中和陕南的榆林、泾河和汉中 3 个单站数据集。每 1 个数据集包括训练集、验证集和测试集,训练集用于训练和构建模型,验证集用于参数优化及模型的选择,测试集用于对最终选择的模型进行检验评估。各区域、单站 2005—2014 年日资料中,75%的实例被随机地划分为训练集,其余 25%的实例作为验证集。数据集基本情况见表 2。

表 2 区域及单站数据集基本情况

数据集	训练集、验证集		测试集		
	资料时段	实例数量	资料时段	实例数量	
区域	陕北	2005—2014	18192	2015	1823
	关中	2005—2014	18139	2015	1818
	陕南	2005—2014	17971	2015	1820
单站	榆林	2005—2014	3631	2015	364
	泾河	2005—2014	3578	2015	365
	汉中	2005—2014	3615	2015	365

表 3 年尺度下蒸发皿蒸发与各气象要素的 Pearson 相关系数

气象要素	相关系数					
	陕北	榆林	关中	泾河	陕南	汉中
平均气压	-0.272 *	-0.650 *	-0.116 *	-0.655 *	0.033 *	-0.572 *
最高气压	-0.280 *	-0.651 *	-0.118 *	-0.636 *	0.031 *	-0.558 *
最低气压	-0.279 *	-0.668 *	-0.124 *	-0.685 *	0.026 *	-0.605 *
平均海平面气压	-0.753 *	-0.746 *	-0.659 *	-0.679 *	-0.564 *	-0.610 *
平均气温	0.776 *	0.773 *	0.734 *	0.743 *	0.663 *	0.713 *
最高气温	0.799 *	0.800 *	0.772 *	0.774 *	0.746 *	0.769 *
最低气温	0.699 *	0.710 *	0.643 *	0.673 *	0.530 *	0.619 *
平均水气压	0.355 *	0.346 *	0.422 *	0.463 *	0.473 *	0.549 *
平均相对湿度	-0.435 *	-0.435 *	-0.439 *	-0.433 *	-0.350 *	-0.469 *
最小相对湿度	0.003	0.006	-0.421 *	-0.398 *	-0.409 *	-0.434 *
平均 2 min 风速	0.334 *	0.319 *	0.382 *	0.372 *	0.195 *	0.326 *
平均地面温度	0.817 *	0.815 *	0.775 *	0.778 *	0.727 *	0.769 *
最高地面温度	0.866 *	0.870 *	0.844 *	0.820 *	0.801 *	0.823 *
最低地面温度	0.647 *	0.664 *	0.582 *	0.621 *	0.506 *	0.583 *
日照时数	0.493 *	0.473 *	0.540 *	0.534 *	0.639 *	0.663 *

注: * 表示通过 $p < 0.01$ 的显著性水平检验。

1.3 评价指标

本文机器学习模型的评价指标包括:均方误差 M_{SE} (Mean Square Error, MSE)、总相对误差 T_{RE} (Total Relative Error, TRE)、准确率 C_R (Correct Rate, CR) 以及决定系数 R^2 , 评价估算值偏离实际观测值的程度和估算准确率, M_{SE} 为损失度量指标^[26]。

$$M_{SE} = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (2)$$

利用 SPSS 软件分别对各数据集 2005—2014 年数据进行分析,得出年尺度下蒸发皿蒸发与各气象要素的 Pearson 相关系数(表 3),可以看出,同一类别的气象要素中,平均量一般不是最大的影响因素;平均气压、最高气压和最低气压对陕北、关中和陕南各区域整体和区域内代表性站点的影响程度存在较大差异,说明进行区域或单站蒸发量估算时需要考虑的主要气象因子及其权重系数不同。

1.2 资料标准化

在机器学习中,为便于训练和更好地反映各特征变量与响应变量之间的相关关系,对表 3 中的所有特征变量数据进行标准化,处理方法如下:

$$X_{i_std} = \frac{X_i - \bar{X}_i}{S_i} \quad (1)$$

式中, X_{i_std} 为第 i 个特征变量标准化后的值, X_i 为原始值, \bar{X}_i 为平均值, S_i 为标准差;标准化后的每一个特征变量的均值为 0、标准差为 1。

$$T_{RE} = \left(\sum_{i=1}^n \hat{y}_i - \sum_{i=1}^n y_i \right) / \sum_{i=1}^n y_i \quad (3)$$

$$C_R = \frac{F}{n} \quad (4)$$

$$R^2 = 1 - \frac{S_{res}}{S_{tot}}$$

$$S_{res} = \sum_{i=1}^n (y_i - \hat{y}_i)^2,$$

$$S_{\text{tot}} = \sum_{i=1}^n (y_i - \bar{y})^2 \quad (5)$$

式中, \hat{y}_i 为第 i 个实例的响应变量估算值, y_i 为响应变量观测值, \bar{y} 为响应变量观测值均值, F 为数据集中估算值与观测值的绝对误差不超过 0.4 mm (即蒸发量 ≤ 10 mm 时的 2 倍最大允许误差) 的频数^[21,27-28]。

2 估算模型

2.1 回归方法

根据日平均气压、平均气温等进行蒸发皿蒸发量估算,属于监督学习中的回归问题,学习的目标是选择损失最小的模型。本文采用的回归方法为 k 近邻法(KNN)、多层感知机(MLP)。KNN 回归的主要算法如下:给定 1 个训练数据集,在训练数据集中找到与测试数据集中实例最邻近的 k 个实例,然后将这 k 个邻居的平均值作为该测试实例的估算值。本文中,KNN 回归方法优化的参数为: k 值($n_{\text{neighbors}}=k$),由于数据集已进行标准化,本文距离度量采用欧式距离。

MLP 又称为前馈人工神经网络,是一种广义的线性模型,除了输入、输出层,其中间可以有多个隐层,层与层之间为全连接,执行多层处理后得到结论。在 MLP 中,多次重复计算线性回归估算模型中加权求和的过程,并计算代表中间过程的隐单元,然后再计算这些隐单元的加权求和并得到最终结果。本文中,MLP 回归方法优化的参数为:隐层数量($\text{hidden_layer_sizes}$)、迭代次数(max_iter)。

2.2 初始模型

基于陕北、关中和陕南训练集及验证集,分别利用 KNN($n_{\text{neighbors}}=5$)、MLP($\text{hidden_layer_sizes}=100, \text{max_iter}=200$) 2 种回归方法及其默认参数建立区域估算模型,模型在验证集上的指标值如表 4 所示。

从表 4 可以看出,除关中及陕南的 TRE 指标外,MLP 模型各指标均优于 KNN 模型:MSE 平均约低 0.1、 R^2 约高 3%、CR 约高 4%。KNN、MLP 回归模型的总相对误差 TRE 均在 2% 以内,但不同气候区域的 R^2 指标性能差异较明显,均呈现以下特点:陕北 > 关中 > 陕南,级差平均约为 4%。

表 4 KNN、MLP 模型在默认参数时的估算指标值

评价指标	陕北	关中	陕南	
KNN	MSE	0.63	0.55	0.35
	TRE	-0.8%	-0.4%	-0.3%
	CR	56.2%	58.2%	58.6%
	R^2	0.906	0.868	0.804
MLP	MSE	0.48	0.47	0.29
	TRE	0.3%	1.0%	-1.1%
	CR	60.4%	62.4%	61.2%
	R^2	0.928	0.883	0.842

2.3 参数优化

为确保 KNN、MLP 模型具有最优泛化性能,利用 S 折交叉验证 (S -fold cross validation)、管道 (Pipe) 和网格搜索技术 (GridSearch),根据各模型 R^2 指标性能和时间复杂性选择最优模型参数^[26,29]。基于陕北、关中、陕南训练集及验证集的 KNN 模型不同 k 值 ($k \in [1, 100]$) 的 R^2 曲线、MLP 模型不同隐层数量及迭代次数的 R^2 热图如图 2 所示。

从图 2 可以看出,各回归方法在默认参数条件下均未达到 R^2 最优估算性能,但部分达到次优。图 2a 表明,KNN 模型在不同区域的最优参数 (即 k 值) 基本接近: $n_{\text{neighbors}}=20$,默认值 $n_{\text{neighbors}}=5$ 与其相差较大;图 2b 表明,陕北 MLP 模型的最优参数为: $\text{hidden_layer_sizes}=10, \text{max_iter}=1000$,其在默认参数时的 R^2 值较低,且可以看出,陕北 MLP 模型对参数较为敏感;从图 2c、d 看出,关中、陕南 MLP 模型的最优参数均为: $\text{hidden_layer_sizes}=(5, 12), \text{max_iter}=200$,且默认参数为其次优参数。

2.4 估算模型检验

2.4.1 区域蒸发量估算

基于以上构建的区域估算模型及最优参数,利用 2015 年陕北、关中和陕南各区域测试集分别检验区域估算模型的应用效果,估算值与观测值的散点图及其拟合曲线以及评价指标值、估算值绝对误差分布等如图 3 所示。

从图 3a、b、c 可以看出,陕北 KNN 模型在测试集上具有良好的泛化性能,且各指标均优于 MLP 模型;MLP 模型泛化性能较差:MSE、TRE 分别达到 3.16、20.4%,而 R^2 、CR 分别仅为 0.459、27.8%,估算值绝对误差在 $[-1.0, 1.0]$ 区间的比例

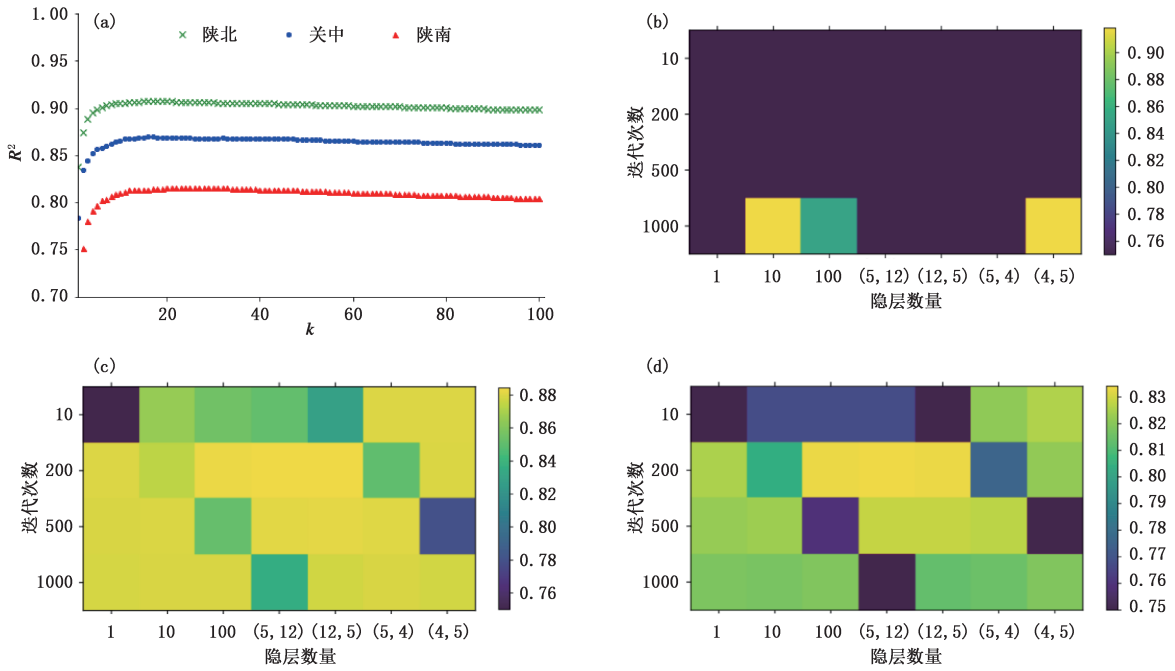


图 2 回归模型不同参数在验证集上的 R^2 值:

(a)KNN 模型 R^2 曲线,(b)陕北 MLP 模型 R^2 热图,(c)关中 MLP 模型 R^2 热图,(d)陕南 MLP 模型 R^2 热图

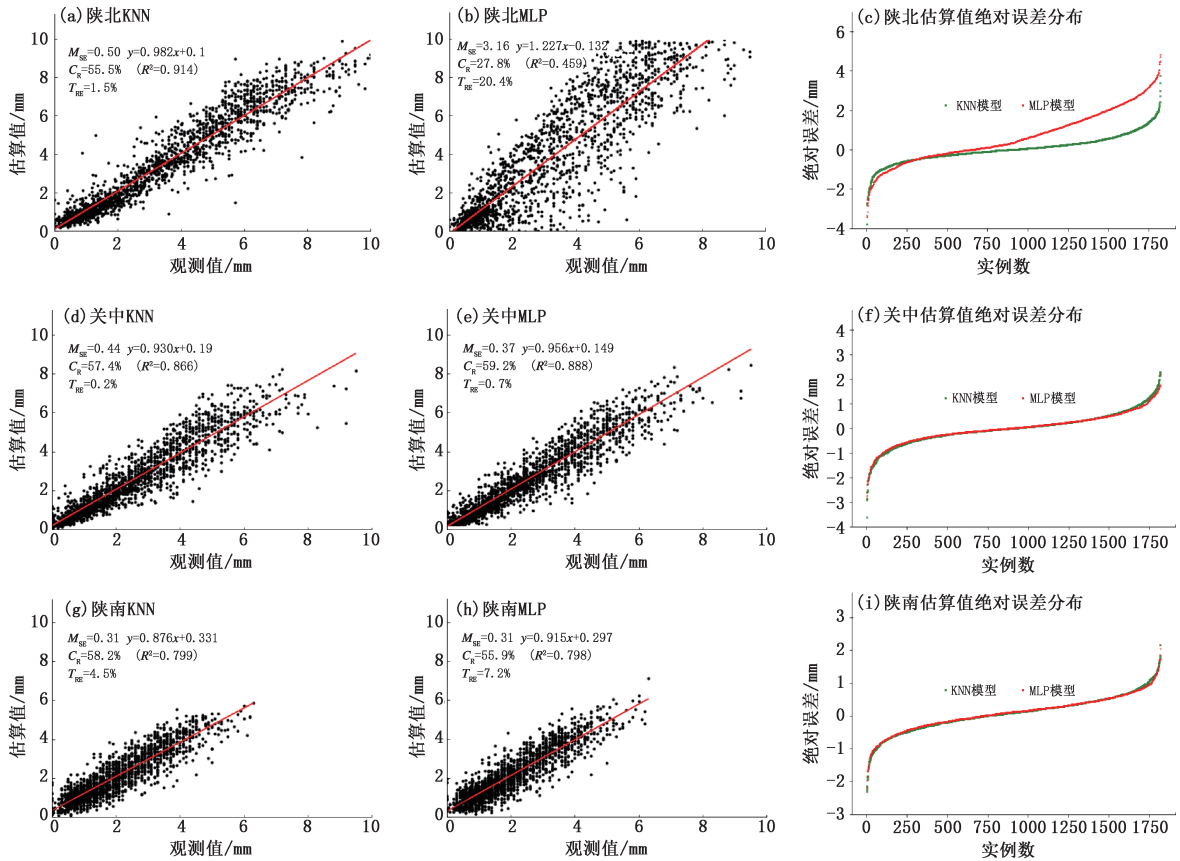


图 3 2015 年陕北、关中、陕南蒸发量估算值与观测值散点,评价指标值与估算值绝对误差

仅为 55.4%。从图 3d、e、f 可以看出,关中 MLP 模型的 MSE、 R^2 和 CR 指标均略优于 KNN 模型, TRE 指标相对较差, KNN、MLP 模型估算值绝对误差在 $[-1.0, 1.0]$ 区间的比例分别为 86.3%、89.8%。从图 3g、h、i 可知, KNN、MLP 模型在陕南的估算值指标性能基本接近,其绝对误差在 $[-1.0, 1.0]$ 区间的比例分别为 92.2%、94.4%。KNN、MLP 模型在关中、陕南均具有良好的泛化性能。

2.4.2 单站蒸发量估算

由于 KNN 模型在陕北、关中和陕南蒸发量估算过程中均表现出良好的泛化性能,因此分别利用 KNN 区域估算模型及其最优参数 ($n_neighbors = 20$),对各区域的代表性站点即榆林、泾河和汉中的 2015 年蒸发量进行估算。同时,基于榆林、泾河和汉中 2005—2014 年观测数据,分别建立各站点的 KNN 单站估算模型及其最优参数(榆林: $n_neighbors = 15$, 泾河、汉中: $n_neighbors = 25$),对各站点 2015 年蒸发量进行估算。基于区域估算模型、单站估算模型的单站蒸发量估算值与观测值的散点图及

其拟合曲线以及评价指标值、估算值绝对误差分布如图 4 所示。

从图 4 可以看出,基于单站估算模型的单站蒸发量估算指标性能均优于基于区域估算模型的单站蒸发量估算指标性能:榆林 CR 偏高 9.9%, TRE 偏低 5.6%, 区域估算模型的 TRE 值达到 $-7.1%$, 区域、单站模型估算值绝对误差在 $[-1.0, 1.0]$ 区间的比例分别为:84.7%、83.8%;泾河 MSE 偏低 0.21, CR 偏高 4.3%, TRE 偏低 10.5%, 区域估算模型的 TRE 值达到 $-12.7%$, 区域、单站模型估算值绝对误差在 $[-1.0, 1.0]$ 区间的比例分别为:78.4%、79.6%;汉中 MSE 偏低 0.11, CR 偏高 8.2%, TRE 偏低 0.8%, 区域、单站模型的 TRE 值均相对较高,分别达 11.1%、10.3%, 区域、单站模型估算绝对误差在 $[-1.0, 1.0]$ 区间的比例分别为:88.9%、94.2%。同时可以看出,榆林、泾河单站模型估算值绝对误差分布在 0.0 mm 时对应的实例数约为 200,而汉中对应的实例数约为 100,这可能与各单站模型的鲁棒性以及陕北、关中和陕南各区域天气、气候特征有关。

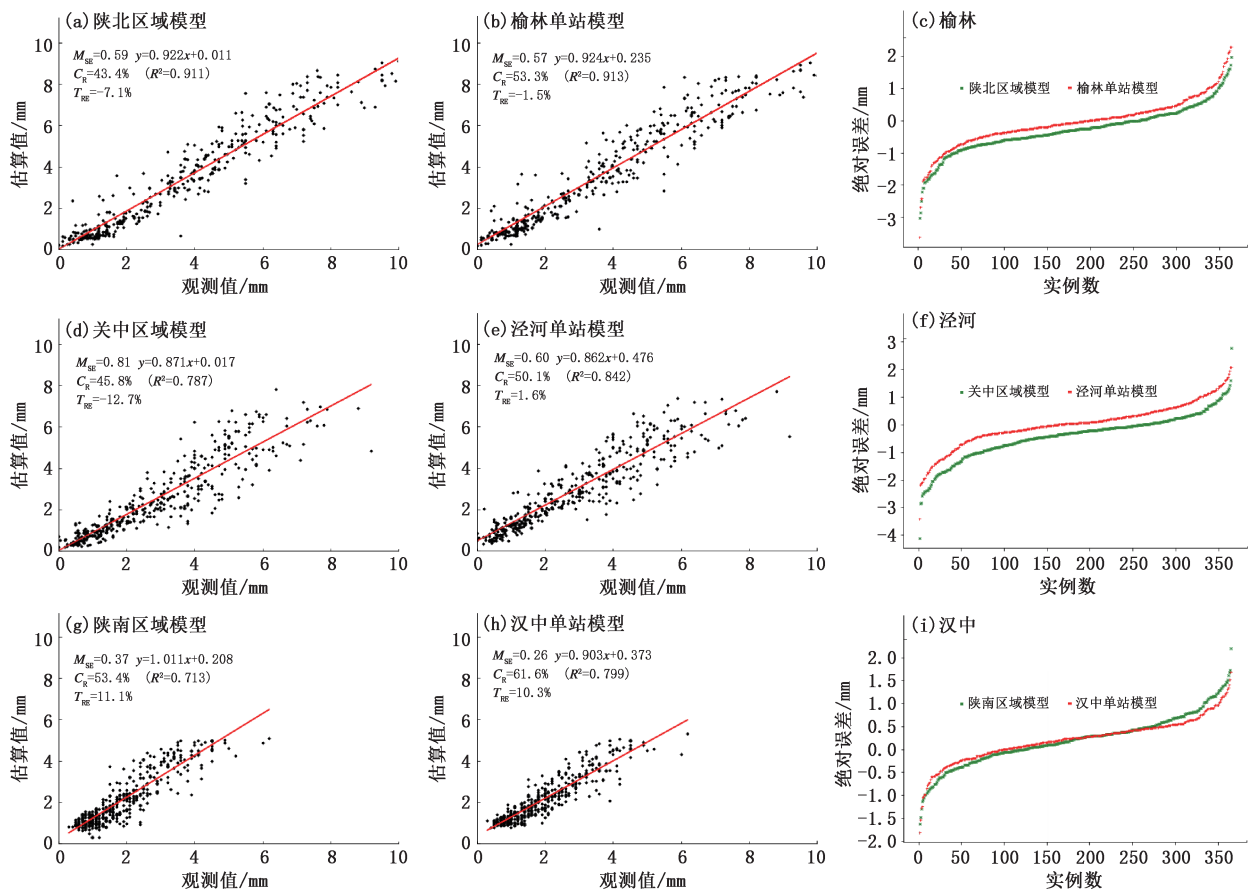


图 4 2015 年榆林、泾河、汉中蒸发量估算值与观测值散点,评价指标值与估算值绝对误差

3 结论与讨论

本文在建立陕北、关中和陕南区域数据集以及榆林、泾河和汉中单站数据集的基础上,分析了气温、地温和日照等气象要素与蒸发皿蒸发的相关性,通过优化模型参数,分别建立了蒸发量区域估算模型、单站估算模型,得出如下结论:

(1)年尺度下,影响陕北、关中和陕南各区域以及各区域代表性站点榆林、泾河和汉中蒸发皿蒸发量变化的主要因子存在差异,且同一类别气象要素中,平均量一般不是最大的影响因子;平均气压、最高气压和最低气压对陕北、关中和陕南各区域整体影响较小,但对各单站的影响较大。

(2)KNN、MLP 估算模型在默认参数条件下均未达到最优 R^2 估算性能,KNN 模型在不同区域的最优 k 值基本接近($n_neighbors = 20$),但默认值($n_neighbors = 5$)与其差距较大,陕北 MLP 模型对参数选择较为敏感,关中、陕南 MLP 模型的最优参数相同,且默认参数为其次优参数。

(3)进行区域蒸发量估算时,KNN 模型表现出良好的泛化估算性能,其 MSE、TRE 和 CR 指标值平均分别为 0.42、2.1%、57.0%;陕北 MLP 模型的泛化性能较差,MSE、TRE 和 CR 指标值分别为 3.16、20.4%、27.8%;关中 MLP 模型的 MSE、CR 指标略优于 KNN 模型,TRE 指标则相比较劣;陕南 KNN、MLP 模型指标性能基本接近。

(4)进行单站蒸发量估算时,基于 k 近邻法的 KNN 单站估算模型性能优于区域估算模型,MSE、CR 指标值平均为 0.48、55.0%,榆林与泾河 TRE 指标绝对值平均为 1.6%,汉中 TRE 指标值偏高,达到 10.3%。

以上研究结论及其与文献^[17-19]的评价指标简单对比表明,本文建立的蒸发皿蒸发量估算模型部分评价指标表现良好,可以为陕西省不同气候区域及单站、不同时间尺度的蒸发量估算以及日蒸发量数据质量控制提供一种基于机器学习的方法。但是本文也存在一些问题,如未对其他估算或预测模型如彭曼公式进行本地化参数修正、验证以及与本文建立的估算模型进行基于同一数据集的检验与对比分析,也未对 MLP 模型应用于陕北蒸发量估算时泛化性能较差、汉中单站蒸发量估算时 TRE 指标

值偏高的原因进行分析。因此,下一步将对影响蒸发皿蒸发变化的主要气象因子在不同气候区域及单站、不同时间尺度上的变化特征进行研究,并对不同模型在同一数据集上的检验效果。

参考文献

- [1] 许小峰. 从物理模型到智能分析——降低天气预报不确定性的新探索[J]. 气象, 2018, 44(3): 341-350.
- [2] 彭昱忠, 王谦, 元昌安, 等. 数据挖掘技术在气象预报研究中的应用[J]. 干旱气象, 2015, 33(1): 19-27.
- [3] 陈晟. 基于机器学习的黑河中游作物需水量模型研究[D]. 合肥: 中国科学技术大学, 2018.
- [4] 曲悦, 钱旭, 宋洪庆, 等. 基于机器学习的北京市 PM_{2.5} 浓度预测模型及模拟分析[J]. 工程科学学报, 2019, 41(3): 401-407.
- [5] 杜言霞, 于子敏, 温继昌, 等. 基于神经网络技术的天气雷达超折射回波识别[J]. 气象科技, 2018, 46(4): 644-650.
- [6] 祁添焱, 张强, 王月, 等. 1960~2005 年中国蒸发皿蒸发量变化趋势及其影响因素分析[J]. 地理科学, 2015, 35(12): 1599-1606.
- [7] Solomon S. Climate Change 2007: The Scientific Basis—Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change [R]. Cambridge and New York: Cambridge University Press, 2007.
- [8] Fu G B, Charles S P, Yu J J, et al. A critical overview of pan evaporation trends over the last 50 years [J]. Climatic Change, 2009, 97(1/2): 193-214.
- [9] 左洪超, 鲍艳, 张存杰, 等. 蒸发皿蒸发量的物理意义、近 40 年变化趋势的分析和数值试验研究[J]. 地球物理学报, 2006, 49(3): 680-688.
- [10] 蒋冲, 王飞, 刘思洁, 等. “蒸发悖论”在秦岭南北地区的探讨[J]. 生态学报, 2013, 33(3): 844-855.
- [11] 陈亚宁, 李稚, 范焯婷, 等. 西北干旱区气候变化对水文水资源影响研究进展[J]. 地理学报, 2014, 69(9): 1295-1304.
- [12] 于占江, 杨鹏. 近 40 年京津冀蒸发皿蒸发量变化特征及影响因素[J]. 气象科技, 2018, 46(6): 1180-1187.
- [13] 申双和, 盛琼. 45 年来中国蒸发皿蒸发量的变化特征及其成因[J]. 气象学报, 2008, 66(3): 452-460.
- [14] 高蓓, 范建忠, 卫海燕, 等. 陕西蒸发量变化时空分布研究[J]. 中国农学通报, 2015, 31(2): 225-233.
- [15] 中国气象百科全书总编委会. 中国气象百科全书·综合卷[M]. 北京: 气象出版社, 2016: 407-410.
- [16] 陕西省地方志编纂委员会. 陕西省志·气象志[M]. 北京: 气象出版社, 2001.
- [17] 吴华斌, 王潜梅, 黄小丹. 基于多元线性回归的日蒸发量估算与应用[J]. 广东气象, 2012, 34(4): 51-53.
- [18] 徐俊增, 彭世彰, 张瑞美, 等. 基于气象预报的参考作物蒸发蒸腾量的神经网络预测模型[J]. 水利学报, 2006, 37(3): 376-379.
- [19] 闵骞. 利用彭曼公式预测水面蒸发量[J]. 水利水电科技进展,

- 2001,21(1):37-39.
- [20] QX/T 118-2010 地面气象观测资料质量控制[S].
- [21] 世界气象组织. 气象仪器和观测方法指南[Z]. 6 版. 日内瓦, 世界气象组织, 1996:202-210.
- [22] 任芝花, 黎明琴, 张纬敏. 小型蒸发器对 E-601B 蒸发器的折算系数[J]. 应用气象学报, 2002, 13(4):508-512.
- [23] 杨允凌, 王丛梅, 杨丽娜. 蒸发对比观测及折算系数[J]. 气象科技, 2013, 41(1):37-41.
- [24] 刘红霞, 王飞. E-601B 型蒸发器与小型蒸发器测值对比分析[J]. 气象科技, 2013, 41(5):852-856.
- [25] 刘波, 肖子牛, 马柱国. 中国不同干湿区蒸发皿蒸发和实际蒸发之间关系的研究[J]. 高原气象, 2010, 29(3):629-636.
- [26] 李航. 统计学习方法[M]. 北京:清华大学出版社, 2015.
- [27] 中国气象局. 地面气象观测规范[M]. 北京:气象出版社, 2003.
- [28] 郑亮, 黄小静, 刘宗庆, 等. 新型蒸发校准误差修正[J]. 气象科技, 2018, 46(4):665-669.
- [29] Muller A C, Guido S. Python 机器学习基础教程[M]. 张亮译. 北京:人民邮电出版社, 2019.

Estimation Model of Pan Evaporation Based on Machine Learning Technology

LONG Yaxing^{1,2} HUANG Qin³ LI Chengwei¹

(1 Shaanxi Provincial Atmospheric Detection Technical Support Center, Xi'an 710015; 2 Key Laboratory of Eco-Environment and Meteorology for the Qinling Mountains and Loess Plateau, Xi'an 710016;

3 Shaanxi Provincial Meteorological Information Center, Xi'an 710015)

Abstract: In order to make up for the lack of evaporation data after the stop of evaporation pan manual observations at the National Meteorological Observatory, three regional datasets of the northern Shaanxi, Guanzhong and southern Shaanxi and three single station datasets of Yulin, Jinghe and Hanzhong are established. By establishing and optimizing the KNN (K-Nearest Neighbor method) and MLP (Multi-Layer Perceptron) models and its parameters, the regional estimation model of evaporation and the single station estimation model are constructed and verified respectively. The results show that: (1) While estimating the regional evaporation, the KNN model shows good generalization performance, and the average Mean Square Error, Total Relative Error and Correct Rate values are 0.42 and 2.1%, 57.0%, respectively; the generalization performance of the MLP model in the northern Shaanxi is poor. (2) While estimating the evaporation of a single station, the performance of the single station estimation model based on the K-nearest neighbor method is superior to the regional estimation model, and the average Mean Square Error and Correct Rate index values are 0.48 and 55.0%, the absolute average value of Total Relative Error at Yulin and Jinghe 1.6%, and that at Hanzhong is relatively high, reaching 10.3%. This research provides a tool based on the Machine Learning for the estimation of daily, monthly, seasonal and annual evaporation in different climate regions and single stations and the quality control of daily evaporation data.

Keywords: K-nearest neighbor method; neural network; evaporation; estimation; verification