

doi:10.6041/j.issn.1000-1298.2020.S2.041

# 基于长短期记忆的柑橘园蒸散量预测模型

谢家兴<sup>1,2</sup> 高鹏<sup>1</sup> 孙道宗<sup>1,2</sup> 陈文彬<sup>1</sup> 陈绍楠<sup>1</sup> 王卫星<sup>1,3</sup>

(1. 华南农业大学电子工程学院, 广州 510642; 2. 广东省农情信息监测工程技术研究中心, 广州 510642;

3. 广东省智慧果园科技创新中心, 广州 510642)

**摘要:** 传统的柑橘灌溉方式主要依赖人工经验,一方面有可能导致灌溉时机不准确,另一方面有可能造成灌溉量过高或者过低,对果实的生长都会产生负面影响。柑橘果园水分蒸散量是表征耗水量的重要指标。为了实现大面积柑橘果园蒸散量(Evapotranspiration, ET)的准确估算,制定更加科学精细化的灌溉策略,基于气象数据集,应用长短期记忆(Long short-term memory, LSTM)、极限学习机(Extreme learning machine, ELM)和广义回归神经网络(General regression neural network, GRNN)方法对蒸散量建立预测模型并验证其准确性。结果表明,LSTM模型的平均绝对误差(Mean absolute error, MAE)和均方根误差(Root mean square error, RMSE)是3种模型中最优的,ELM和GRNN模型的性能接近。为了估算3种模型结果的可信度,在训练时加入了蒙特卡洛不确定性分析方法。结果表明,LSTM模型在不同输入特征数量下具有较高的精度,而ELM模型存在预测值偏高的现象,GRNN模型则偏低。

**关键词:** 蒸散量; 柑橘园; 预测模型; 长短期记忆; 广义回归神经网络; 极限学习机

**中图分类号:** S666; TP391.41 **文献标识码:** A **文章编号:** 1000-1298(2020)S2-0351-06

## Modeling on Prediction of Evapotranspiration of Citrus Orchard Based on LSTM

XIE Jiaying<sup>1,2</sup> GAO Peng<sup>1</sup> SUN Daozong<sup>1,2</sup> CHEN Wenbin<sup>1</sup> CHEN Shaonan<sup>1</sup> WANG Weixing<sup>1,3</sup>

(1. College of Electronic Engineering, South China Agricultural University, Guangzhou 510642, China

2. Guangdong Engineering Research Center for Monitoring Agricultural Information, Guangzhou 510642, China

3. Guangdong Modern Agricultural Science and Technology Innovation Center for Intelligent Orchard, Guangzhou 510642, China)

**Abstract:** Citrus is an important fruit and it's strongly relevant between quality and irrigation. Traditional irrigation strategies relying on human experience caused two problems, i. e. inaccurate irrigation timing and quantity. Both of the two problems have negative influence on citrus. The evapotranspiration of citrus orchard is an important index of water consumption. In order to evaluate citrus orchard evapotranspiration (ET) to make more scientific and precise irrigation strategies, the long short-term memory (LSTM), extreme learning machine (ELM) and general regression neural network (GRNN) methods were applied to model ET and test its performance based on climatic data. The result showed that LSTM performed the best in mean absolute error (MAE) and root mean square error (RMSE) than the other two models. And ELM model performed closely to GRNN. In order to evaluate the certainty of three models, the Monte Carlo analysis method was added to the process of training. The result indicated that LSTM had good accuracy in different input features while ELM tended to overestimate ET and GRNN tended to underestimate ET. It's practical to applicate the proposed method to make precise irrigation strategies.

**Key words:** evapotranspiration; citrus orchard; long short-term memory; general regression neural network; extreme learning machine

收稿日期: 2020-08-13 修回日期: 2020-09-20

**基金项目:** 广东省科技专项资金(“大专项+任务清单”)项目(2020020103)、广东省重点领域研发计划项目(2019B020214003)、广东省教育厅特色创新类项目(2019KTSCX013)、国家荔枝龙眼产业技术体系建设专项资金项目(CARS-32-14)、广东省现代农业产业技术体系创新团队建设专项资金项目(2019KJ108)和广东省大学生科技创新培育专项资金项目(PDJH2019B0080)

**作者简介:** 谢家兴(1979—),男,讲师,博士,主要从事农业物联网和电子信息技术在农业上的应用研究,E-mail: xjx1998@scau.edu.cn

**通信作者:** 王卫星(1963—),男,教授,博士生导师,主要从事农业物联网、无线传感器网络在农业上的应用研究,E-mail: weixing@scau.edu.cn

## 0 引言

柑橘作为一种重要的经济作物,能够在多种气候条件下生长。我国柑橘产量和种植面积均位居世界第一,年总产量在4 000万t以上<sup>[1-2]</sup>。但由于柑橘果园灌溉仍然依靠人工经验进行,使得水资源利用率低。柑橘生长需要合理的灌溉量,而过多或过少的水分均会对产量和品质产生负面影响。随着精准农业研究的不断发展,科学的灌溉理论能实现按需按量灌溉,对柑橘的生长至关重要<sup>[3-4]</sup>。

根据联合国粮农组织(FAO)的研究,作物蒸散量(Evapotranspiration, ET)是反映作物耗水量的重要指标<sup>[5]</sup>。如何对ET进行估算或者计算成为确定柑橘需水量的关键。ET与多种因素相关,是一种多参数非线性问题。对ET影响最大的因素包括作物系数、温度、相对湿度、风速、日辐射量等<sup>[6]</sup>。确定柑橘果园蒸散量的传统方法主要有3种:基于FAO-56 P-M模型估算参考作物蒸散量,其精确度很高,但缺点是需要的参数过多,计算较复杂;利用能量平衡法<sup>[7]</sup>来估算柑橘果园的蒸散量,优点在于精确度高,但参数的测量比较繁琐,而且难以对整体果园进行测量,因此其应用受到了限制;利用涡动相关法进行测量,测量精度较高,但是相应仪器操作复杂,价格昂贵,同样不适合大规模应用。

近几年,机器学习得到了快速发展。从早期的单层神经网络模型,到目前的深度学习模型,对于非线性问题的特征拟合方面的应用越来越广泛。因此,许多研究人员利用机器学习模型对参考蒸散问题进行了评估。ABDULLAH等<sup>[8]</sup>利用ELM极值学习机对ET进行了预测,该研究使用了最高温度、最低温度、相对湿度、2 m高度风速等参数作为输入,网络结构为5个输入层,每层分别使用一个气象参数矩阵作为输入,使用10个隐藏层来计算训练参数,输出层为ET。分析结果表明,输入的气象参数越多,拟合的RMSE和MAE越小, $R^2$ 越大,但是当计算参数较多或者过少时,需要较多的计算资源才能实现网络的收敛。FENG等<sup>[9]</sup>利用极值学习和广义回归神经网络方法对参考蒸散量进行建模。TORRES等<sup>[10]</sup>利用MVRVM模型和有限的天气数据对潜蒸散量进行了预测研究。该研究使用了直接和非直接的方法,分别使用预测的天气数据矩阵和计算后的ET矩阵进行建模和计算。在经过尺度变换和反变换后,发现非直接方法和直接方法的效果比较接近,但是在多日的预测中,非直接方法的精度衰减比直接方法更慢。说明对输入的天气数据序列进行预处理和变

换能够提高模型的鲁棒性和精度。GHOSE等<sup>[11]</sup>在印度东部干旱区域使用DRNN模型研究地表径流和蒸散量,来对地下水位进行预测,证实了蒸散量和径流对模型的影响较大,而且较大的降雨量能够减小计算损失,提高模型精度。MAJHI等<sup>[12]</sup>使用深度LSTM模型对日蒸发量进行预测,该研究使用了多输入-单输出型的有监督型训练模型。研究者将输入分为5组使用了32个LSTM节点和2层全连接层进行训练,结果表明在给定的网络结构下,输入的参数越多,模型的RMSE越低,而 $R^2$ 和效率因子(Efficiency factor, EF)越高,表明模型拟合效果越好。LSTM模型在时间更长尺度上进行预测,也表现出了较好的预测效果。与经验模型对比也表明,深度LSTM模型的效果比经验模型更好,能够更好地用于预测。

本文使用气象数据集,基于PM方程计算参考蒸散量,利用LSTM、GRNN和ELM模型,对气象数据与参考蒸散量进行建模,并对各组建模结果进行验证,测试模型性能。

## 1 材料与方法

### 1.1 试验地概况

研究区域位于广西壮族自治区梧州市柑橘园<sup>[13]</sup>,面积约13.33 hm<sup>2</sup>,当地气候为亚热带季风气候,但是由于该地为山地环境,不同季节降雨量不均衡,全年平均降雨量约1 450 mm,即平均月降雨量约为120 mm,但在春季和冬季,降雨量只有30~50 mm。然而,当地的重要经济作物柑橘,几乎是依靠人工经验和自然降雨来进行生产和种植,在降雨匮乏季节,更加需要精确合理的灌溉调度来保证作物生长所需的水分。本文所使用的数据集来自气象局气象数据,从2000年到2018年共6 910条数据,数据记录了梧州市经度、纬度、海拔、最高温度、最低温度、日降雨量、相对湿度、风速(10 m高度)、气压、日照时长等气象数据。这些数据的关键信息如表1、2所示。数据集中包括部分无效数据,在数据预处理环节中,将这些数据剔除,保证输入数据集的所有数据维度相同,完成这些操作后,有效数据共6 874条。将数据集按7:3划分为训练集和测试集。

表1 数据概况

Tab.1 Details of dataset

地点	纬度/ (°)	经度/ (°)	数据量/ 条	训练集数 据量/条	测试集 数据量/条
梧州市	23.57	111.25	6 874	4 812	2 062

表 2 气象数据相关性分析  
Tab. 2 Correlation of climatic data

参数	最高温度	最低温度	平均温度	降雨量	气压	风速	日照时长	相对湿度
最高温度	1							
最低温度	0.89	1						
平均温度	0.98	0.97	1					
降雨量	0.021	0.150	0.081	1				
气压	-0.81	-0.88	-0.87	-0.20	1			
风速	-0.130	-0.068	-0.100	0.064	0.062	1		
日照时长	-0.670	-0.700	-0.700	-0.083	0.590	0.067	1	
相对湿度	0.042	0.250	0.140	0.360	0.210	0.018	-0.041	1

从表 2 可以看出,最高温度、最低温度和平均温度之间具有较强相关关系,气压与各个天气因子均呈现负相关关系,降雨量、风速、湿度与 3 种温度参数间均不存在明显相关关系。气象数据集中不包含  $ET_0$ ,因此为了将数据集转换为适合监督学习的数据集,采用 TORRES 等<sup>[10]</sup>的研究思路,利用 PM 方程计算  $ET_0$ 。从而建立起新的包含  $ET_0$  的监督学习数据集。

蒸散量计算公式为

$$ET_0 = \frac{0.408\Delta(R_n - G) + \gamma \frac{900}{T + 273} u_2 (e_s - e_a)}{\Delta + \gamma(1 + 0.34u_2)} \quad (1)$$

式中  $ET_0$ ——日参考蒸散量,mm/d  
 $R_n$ ——净辐射量,MJ/(m<sup>2</sup>·d)  
 $G$ ——土壤热通密度,MJ/(m<sup>2</sup>·d)  
 $T$ ——2 m 高度平均空气温度,℃  
 $u_2$ ——2 m 高度风速,m/s  
 $e_s$ ——饱和蒸汽压,kPa  
 $e_a$ ——实际蒸汽压,kPa  
 $\Delta$ ——蒸汽压力曲线斜率,kPa/℃  
 $\gamma$ ——温湿度常数,kPa/℃

辐射计算公式为

$$R_s = \left( a_s + b_s \frac{t}{t_{max}} \right) R_a \quad (2)$$

式中  $R_s$ ——太阳辐射,MJ/(m<sup>2</sup>·d)  
 $R_a$ ——地外辐射,MJ/(m<sup>2</sup>·d)  
 $t$ ——日照时长,h  $t_{max}$ ——最大日照时长,h  
 $a_s, b_s$ ——常数,取 0.25 和 0.50

### 1.2 预测模型

GRNN 模型是由 SPECHT<sup>[14]</sup>提出的用于拟合连

续非线性数据模型,它基于径向基网络,具有较好的非线性拟合功能。ELM 模型是由 HUANG 等<sup>[15]</sup>提出,它的特点是在保证精度的前提下获得较快的收敛速度。LSTM 模型<sup>[16-17]</sup>是一种特殊的 RNN 网络,它包含了能够控制丢弃信息的门,而且采用求和代替梯度求导,因此不但能够储存状态信息,还能够避免 RNN 网络的梯度消失问题。

神经网络可以对线性和非线性问题进行拟合并得到精确度、预测方差等数据,但模型给出的预测结果并不一定都可靠,因此模型的不确定性(Uncertainty)越来越受到关注。在水文学领域的研究中,很少涉及模型不确定性<sup>[18]</sup>。本文几种模型均由数据进行驱动,其不确定性主要来自两方面,一是随机不确定性,二是认知不确定性。随机不确定性是由模型或系统本身随机性造成,认知不确定性主要源于不充分的或者具有倾向性的数据。因此本文训练结果包括蒙特卡洛 dropout 机制计算模型不确定性均值与方差,用以表征模型的可信度。

### 1.3 模型性能指标

本文模型采用性能指标均方根误差(Root mean square error, RMSE)和平均绝对误差(Mean absolute error, MAE)来进行表征。

## 2 结果与分析

### 2.1 模型性能

网络训练时,输入数据集特征分为 4 组,分别是 10、7、5、3 个特征,各组包含的具体特征如表 3 所示。模型训练时,分多次分别输入 4 组特征数据,并统计结果,其性能表现数据如图 1 所示。

表 3 输入特征分组

Tab. 3 Input features

10 个特征	7 个特征	5 个特征	3 个特征
经度、纬度、海拔、最高温度、最低温度、日降雨量、相对湿度、风速(10 m 高度)、日照时长	最高温度、最低温度、日降雨量、相对湿度、风速(10 m 高度)、气压、日照时长	最高温度、最低温度、相对湿度、风速(10 m 高度)、日照时长	最高温度、最低温度、风速

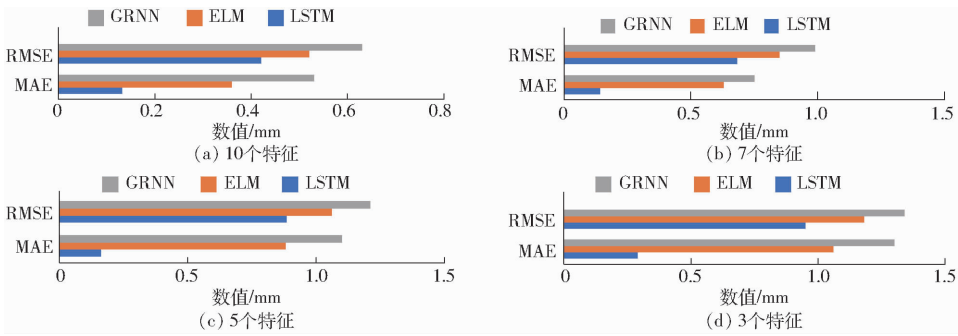


图1 3种模型性能表现图

Fig.1 Performance diagrams of three models

由图1可以看出,随着特征数的减少,模型的MAE和RMSE会增大,表明输入数据特征越丰富,模型拟合效果越好。3种模型中,LSTM模型的性能表现最好,其MAE为0.13~0.29, RMSE为0.42~0.95,整体性能指标较好,说明该模型的拟合精度较高。从输入特征角度分析,当特征数由10个减少到7个后,其LSTM的MAE几乎不变,说明经度和纬度和海拔3个特征对于蒸散量估算的影响不大<sup>[19]</sup>。而当输入特征为最高温度、最低温度和风速时,LSTM的MAE产生了较明显的变化,说明风速和日照时长对蒸散量估算值的影响较大<sup>[20]</sup>,这为制定灌溉策略提供了一定的帮助。ELM模型的MAE为0.36~1.06, RMSE为0.52~1.18,从直方图可以看出,其模型受输入特征变化影响较明显,特征较多时其精度较好,但总体性能表现不如LSTM模型。GRNN模型的MAE为0.53~1.30, RMSE为0.64~

1.34,与ELM模型类似,其误差随着输入特征的减少而增加,整体性能表现与ELM模型接近,但两者性能均不如LSTM模型。

## 2.2 模型的不确定性

模型的不确定性表征模型拟合结果的自信度,本文从不确定性均值和方差两个维度进行比较。由图2可以看出,LSTM模型不确定性均值为4.50~4.67,不确定性方差为3.346~3.570,随着输入特征的减少,总体变化不大,侧面说明了模型在不同特征组合输入下的自信程度。ELM模型不确定性均值为4.39~4.89,方差为5.824~6.9,其不确定性相比LSTM较大,反映了时间序列模型在ET建模方面具有更好的鲁棒性。GRNN模型不确定性均值为4.297~4.85,方差为6.049~7.21,受输入特征的影响较明显,表明该模型的拟合自信程度较低,鲁棒性较差。

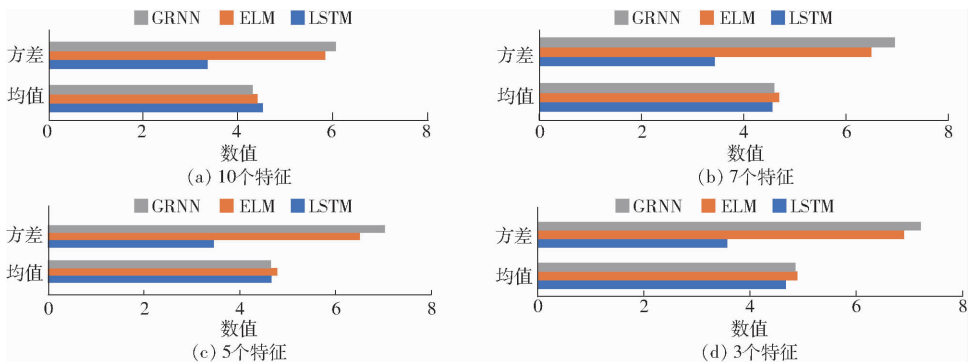


图2 模型不确定性

Fig.2 Uncertainty of models

## 2.3 预测结果与原始数据计算结果对比

在生成模型的基础上,利用气象数据,经过尺度变换后重新输入模型,获取模型预测值,并与PM方程的计算值进行对比,结果如图3~5所示。由图3可以看出,LSTM预测值与PM方程计算值接近,两者具有较高的相关性,说明模型对ET的预测有效<sup>[21]</sup>。由图4可以看出,ELM模型的预测值与PM方程计算值相比,存在高估现象,其总体趋势一致,但是误差和稳定性不如LSTM模型。图5显示,

GRNN模型的预测情况与ELM模型预测效果存在较大不同,相对于PM方程计算的理论值,GRNN模型存在低估ET值的情况。双周期移动平均趋势图显示,GRNN模型的偏差明显偏大,说明该模型在数据集上的泛化能力较差,这可能是因为在长时段、单日预测模型下,GRNN模型难以结合过去的气象数据来进行预测<sup>[22]</sup>,其更偏向于多维数据的回归拟合。ELM模型用来求解单隐层网络收敛,其模型在训练与拟合上具有较快的收敛速度,但是参数较少




图3 LSTM模型拟合值与PM方程计算值对比

Fig. 3 Comparing of LSTM and PM equation

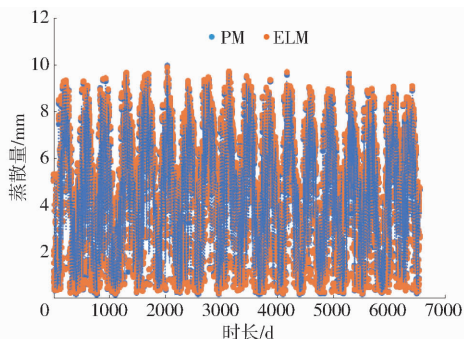


图4 ELM模型拟合值与PM方程计算值对比

Fig. 4 Comparing of ELM and PM equation

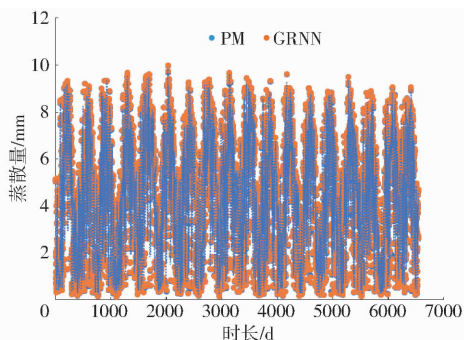


图5 GRNN模型拟合值与PM方程计算值对比

Fig. 5 Comparing of GRNN and PM equation

导致模型对长时段的气象数据预测结果波动大, 而造成其总体误差偏大, 稳定性不如 LSTM 模型。影响气象变化的因素很多, 果园面积一般较大, 且处于空旷的环境中, 风速、温度与饱和汽压等因素的变

化对果园作物  $ET_0$  都会产生影响, 但这些非线性因素的变化又是连续时变的, 因此 LSTM 模型的特点决定了它能够储存过去的信息, 并基于过去的信息从而对未来的信息进行预测。由图 3 可以看出, LSTM 模型拟合的数据与理论计算数据的吻合度较高, 且随着温度等气象因子变化呈现出高低起伏的特征。

### 3 结论

(1) 利用气象数据集, 以 PM 方程计算的理论  $ET_0$  值为基准, 将数据集划分为不同的特征组合, 分别输入 LSTM、GRNN、ELM 模型中, 对各个模型性能进行了测试, 引入了蒙特卡洛不确定性从侧面表征模型的可靠性。之后利用气象数据对生成的模型进行测试, 获得预测的  $ET_0$  数据, 并与 PM 方程计算的理论值进行了对比。

(2) 基于时间序列的 LSTM 模型在  $ET_0$  的预测方面展现出了较好的性能, 与 ELM 和 GRNN 模型相比, LSTM 模型在 MAE 和 RMSE 指标方面具有优势, 而 LSTM 模型的 RMSE 随着输入特征的减少, LSTM 展现出了较好的鲁棒性。3 种模型中, LSTM 模型的性能表现最好, 其 MAE 为 0.13 ~ 0.29 mm, RMSE 为 0.42 ~ 0.95 mm, ELM 模型 MAE 为 0.36 ~ 1.06 mm, RMSE 为 0.52 ~ 1.18 mm, GRNN 模型 MAE 为 0.53 ~ 1.30 mm, RMSE 为 0.64 ~ 1.34 mm。随着输入特征的减少, ELM 模型和 GRNN 模型的性能指标下降, 而 LSTM 模型的性能指标几乎不变, 这一结果意味着在许多气象资料缺乏的地区, 仅需要少量的气象特征参数, 即可实现对  $ET_0$  较高精度的预测。在模型的不确定方面, 本文从不确定性均值和方差两个维度进行比较。LSTM 模型不确定性均值范围为 4.50 ~ 4.67 mm, 不确定性方差为 3.346 ~ 3.570  $mm^2$ , 随着输入特征的减少, 总体变化不大, 而 ELM、GRNN 模型不确定性均值与方差都比 LSTM 模型大, 这说明 LSTM 模型在  $ET_0$  预测方面具有更好的鲁棒性。

### 参 考 文 献

- [1] 许倍铭, 韩雪松, 廖海, 等. 广西柑橘生产现状及发展前景探析[J]. 现代农业科技, 2020(3): 113 - 114.  
XU Beiming, HAN Xuesong, LIAO Hai, et al. Analysis of citrus production status and development prospect in Guangxi[J]. Modern Agricultural Science and Technology, 2020(3): 113 - 114. (in Chinese)
- [2] 岳学军, 凌康杰, 王林惠, 等. 基于高光谱和深度迁移学习的柑橘叶片钾含量反演[J]. 农业机械学报, 2019, 50(3): 186 - 195.  
YUE Xuejun, LING Kangjie, WANG Linhui, et al. Inversion of potassium content for citrus leaves based on hyperspectral and deep transfer learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(3): 186 - 195. (in Chinese)
- [3] 杨伟志, 孙道宗, 刘建梅, 等. 基于物联网和人工智能的柑橘灌溉专家系统[J]. 节水灌溉, 2019, 44(9): 116 - 120, 124.  
YANG Weizhi, SUN Daozong, LIU Jianmei, et al. Citrus irrigation expert system based on internet of things and artificial

- intelligence[J]. *Water Saving Irrigation*, 2019, 44(9): 116–120,124. (in Chinese)
- [4] 谢家兴, 高鹏, 莫昊凡, 等. 荔枝园智能灌溉决策系统模糊控制器设计与优化[J]. *农业机械学报*, 2018, 49(8): 26–32,58.  
XIE Jiaying, GAO Peng, MO Haofan, et al. Design and optimization of intelligent irrigation decision system in litchi orchard based on fuzzy controller[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2018, 49(8): 26–32,58. (in Chinese)
- [5] ALLEN R G, PEREIRA L S, RAES D, et al. Crop evapotranspiration-guidelines for computing crop water requirements-FAO irrigation and drainage paper 56[J]. *FAO-Food and Agriculture Organisation of the United Nations*, 1998, 300(9): D05109.
- [6] DZIKITI S, VOLSCHENK T, MIDGLEY S J E, et al. Estimating the water requirements of high yielding and young apple orchards in the winter rainfall areas of South Africa using a dual source evapotranspiration model[J]. *Agricultural Water Management*, 2018, 208: 152–162.
- [7] CONSOLI S, O'CONNELL N, SNYDER R. Estimation of evapotranspiration of eifferent-sized navel-orange tree orchards using energy balance[J]. *Journal of Irrigation and Drainage Engineering*, 2006, 132(1): 2–8.
- [8] ABDULLAH S S, MALEK M A, ABDULLAH N S, et al. Extreme learning machines: a new approach for prediction of reference evapotranspiration[J]. *Journal of Hydrology*, 2015, 527: 184–195.
- [9] FENG Y, PENG Y, CUI N, et al. Modeling reference evapotranspiration using extreme learning machine and generalized regression neural network only with temperature data[J]. *Computers and Electronics in Agriculture*, 2017, 136: 71–78.
- [10] TORRES A F, WALKER W R, MCKEE M. Forecasting daily potential evapotranspiration using machine learning and limited climatic data[J]. *Agricultural Water Management*, 2011, 98(4): 553–562.
- [11] GHOSE D, DAS U, ROY P. Modeling response of runoff and evapotranspiration for predicting water table depth in arid region using dynamic recurrent neural network[J]. *Groundwater for Sustainable Development*, 2018, 6: 263–269.
- [12] MAJHI B, NAIDU D, MISHRA A P, et al. Improved prediction of daily pan evaporation using Deep-LSTM model[J]. *Neural Computing and Applications*, 2020, 32(12): 7823–7838.
- [13] 黄晓雁, 刘灼梧, 李锦锋, 等. 梧州市柑橘无病苗木生产现状及发展对策[J]. *农业科技通讯*, 2019(7): 243–245.  
HUANG Xiaoyan, LIU Zhuowu, LI Jinfeng, et al. Present situation and development countermeasure of citrus disease-free seedling production in Wuzhou city[J]. *Bulletin of Agricultural Science and Technology*, 2019(7): 243–245. (in Chinese)
- [14] SPECHT D F. A general regression neural network[J]. *IEEE Transactions on Neural Networks*, 1991, 2(6): 568–576.
- [15] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications[J]. *Neurocomputing*, 2006, 70(1): 489–501.
- [16] ZHANG J, ZHU Y, ZHANG X, et al. Developing a long short-term memory (LSTM) based model for predicting water table depth in agricultural areas[J]. *Journal of Hydrology*, 2018, 561: 918–929.
- [17] 杨亮, 刘春红, 郭昱辰, 等. 基于 EMD-LSTM 的猪舍氨气浓度预测研究[J]. *农业机械学报*, 2019, 50(增刊): 353–360.  
YANG Liang, LIU Chunhong, GUO Yuchen, et al. Prediction of ammonia concentration in fattening piggery based on EMD-LSTM[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2019, 50(Supp.): 353–360. (in Chinese)
- [18] FANG K, SHEN C, KIFER D. Evaluating aleatoric and epistemic uncertainties of time series deep learning models for soil moisture predictions[J]. *arXiv*: 2019, 1906.04595.
- [19] AHMAD M, MANGRIO A G, AKBAR G, et al. Design, evaluation and irrigation scheduling of drip irrigation system on citrus orchard[J]. *Pakistan Journal of Meteorology*, 2015, 12(23): 12.
- [20] GASQUE M, MARTÍ P, GRANERO B, et al. Effects of long-term summer deficit irrigation on 'Navelina' citrus trees[J]. *Agricultural Water Management*, 2016, 169: 140–147.
- [21] GARCÍA-TEJERO I, ROMERO-VICENTE R, JIMÉNEZ-BOCANEGRA J A, et al. Response of citrus trees to deficit irrigation during different phenological periods in relation to yield, fruit quality, and water productivity[J]. *Agricultural Water Management*, 2010, 97(5): 689–699.
- [22] ADEYEMI O, GROVE I, PEETS S, et al. Dynamic neural network modelling of soil moisture content for predictive irrigation scheduling[J]. *Sensors, Multidisciplinary Digital Publishing Institute*, 2018, 18(10): 3408.