

二次聚类与神经网络结合的日光温室温度二步预测方法

陈昕 唐湘璐 李想 刘天麒 贾璐 卢韬

(中国农业大学信息与电气工程学院, 北京 100083)

摘要: 精确预测日光温室温度是实现温室精准调控的前提。由于温室是复杂非线性系统,受室内外众多环境因素影响,且部分因素难以准确测量和建模,因此,难以通过机理分析建立室外因素精确影响室内温度的物理模型。而现有时间序列分析、人工神经网络等仅基于数据的方法预测准确度也较低。本文提出连续时间段聚类与BP神经网络相结合的二步日光温室温度预测方法。首先,进行二次聚类,对室外温度情况相似的日进行聚类,并将全年划分为若干个类似时间段,根据连续时间段内相似日的数量进行聚类,将全年内的连续时间段归入若干类别。其次,对不同类别的时间段,分别采用BP神经网络建立室外温度、相对湿度、太阳辐射、风速和温室室内温度间的关联模型,通过数据训练,能够较为准确的根据室外环境数据预测室内温度。通过涿州实验农场2年数据试验验证,通过二次聚类,全年连续时间段可划分为3类,通过分别建立BP神经网络并分别训练,结果表明本方法预测误差仅为6.23%,与现有未分类的BP神经网络预测算法对比,本文方法有效地提高了准确度,平均误差降低5.4个百分点。

关键词: 温室; 温度预测; 二次聚类分析; BP神经网络

中图分类号: TP391.9 文献标识码: A 文章编号: 1000-1298(2017)S0-0353-06

Two-steps Prediction Method of Temperature in Solar Greenhouse Based on Twice Cluster Analysis and Neural Network

CHEN Xin TANG Xianglu LI Xiang LIU Tianqi JIA Lu LU Tao

(College of Information and Electrical Engineering, China Agricultural University, Beijing 100083, China)

Abstract: Accurate prediction of indoor temperature in solar greenhouse is a precondition to accurately control the greenhouse. Because indoor temperature in solar greenhouse is affected by several outdoor environmental factors and the heat conduction mechanism is complex, indoor temperature changes severely in different time. Thus, it is difficult to establish an accurate physical model that describes how outdoor factors affect indoor temperature by mechanism analysis. The accuracy of existing prediction methods based on neural network is low. So, this paper proposed a two-steps method to predict indoor temperature in solar greenhouse based on twice cluster analysis and back propagation (BP) neural network. The first step of the method was two clustering. Similar days were classified to several categories according to clustering of outdoor temperature. Then a whole year training data were split to several continuous time frames. The frames were classified into different categories by clustering of similar days. In the second step, for different categories of time frames, different BP neural networks respectively modeled the relationships between input variables i. e. outdoor temperature, relative humidity, solar radiation, and wind speed and output variable i. e. indoor temperature. The models could be used to predict indoor temperature in solar greenhouse when the outdoor environment was detected. In experiments, two years data was collected from Zhuozhou. For the data, continuous time frames were split to 3 categories. Through the establishment of BP neural network and training respectively, the results show that the prediction error of this method is only 6.23%. Compared with the existing BP neural network prediction algorithm, this method can effectively improve the accuracy, and the average error is reduced by 5.4 percentage points.

Key words: greenhouse; temperature prediction; twice clustering analysis; back propagation neural network

收稿日期: 2017-07-17 修回日期: 2017-11-20

基金项目: 国家自然科学基金项目(61601471)、北京市自然科学基金项目(4164090)和中央高校基本科研业务费专项资金项目(2017QC077)

作者简介: 陈昕(1974—),男,副教授,主要从事农业大数据挖掘算法研究,E-mail: chxin@cau.edu.cn

引言

智能温室需要更精确的控制温度。而温室是一个大滞后的惯性系统^[1]。首先,温室内温度变化具有滞后性,由于热传导的速度限制,当室外环境因素发生变化后,在几分钟至几十分钟后温室内温度才完成变化。其次,控制措施生效也有滞后性,加温或降温措施开启后几十分钟才能生效。常规的设定值控制方法是阈值控制,即当温度低于下设定点时系统开始加温,当温度高于上设定点时系统开始降温。由于数据采集的滞后和反馈的滞后,这种控制方法将引起温度较大波动,且能耗高、系统稳定性差,不利于作物的生长^[2]。因此,预测下一时刻温度成为精确调控温室的前提。

同时,温室是一个非线性的多输入、多输出复杂系统^[3],影响温室温度的因素包括室外温度、湿度、光照强度、风速、风向、大气压等易于测量和建模的因素,还包括温室结构、覆盖材料、通风机构状态、加热和降温设施的状态、管理运行状态等不易于测量和建模的因素。

传统的线性参数法^[4]、能量平衡法^[5]等温室小气候建模方法,通过研究温室耗散、热辐射、热传导等机制,建立温室室外气候与温室内温度的机理模型。这类方法需要对影响温室的各种因素都准确监控和建模,面对上述难以测量和建模的各种因素,这些基于机理模型的预测不够准确,模型中容纳的因子也较少。

时间序列分析方法^[2],通过之前的历史温度序列和当前温度对下一时刻温度进行推导,认为历史数据隐含了各类因素的综合作用规律,避免了对影响因素的建模。但并未将易于测量的各类外界环境因素纳入考虑,对室外环境突变(下雨、刮风、冰雹等)情况缺乏应对,因此,温度预测的准确度仍然不够理想。

实际上,需要建立温室室外易于测量因素与室内温度的多输入非线性关联模型,同时避免对温室难以测量因素的建模。非线性关联模型构建方面的尝试有主成分分析方法^[6]、支持向量机方法^[7]等,但准确度仍然较低。

神经网络是较为有效的多因素关联关系建模方法,它不属于简单的物理机理模型,它的“黑盒”性质使之在建模时无需考虑温室耗散、热辐射等因素的影响,可一定程度上避免对外形建模等难点,更好的反映温室室外因素和温室内温度的内在联系,是温室环境建模的研究热点。BP神经网络、模糊神经网络等被大量研究用于温室温湿度、光照等小气候因

素的预测^[8-19]。这类方法的精确度较机理模型方法有所提高,但预测精度仍然有改进空间。主要问题在于,上述方法仅训练一个模型来应对所有情景。而面对外部环境差异较大的不同时间段,预测效果难免产生起伏。

PETERSSON等^[20]在风能领域提出了一种对时间相关数据的预测方法,通过对相似数据聚类,并针对不同类别训练不同的神经网络,有效地提高了预测精度。

本文借鉴上述方法提出一种连续时间段聚类与BP神经网络相结合的二步日光温室温度预测方法,以有效提高温室室内温度预测精度。

1 二步日光温室温度预测方法

1.1 二步日光温室温度预测方法流程

二步日光温室温度预测方法过程如图1所示。包括二次聚类和神经网络建模两个步骤。首先对室外气象数据进行全年相似日无监督聚类,再将全年按照半月划分为多个连续时间段,根据每个时间段内各类相似日数量所占比例,将室外气象数据时间段通过聚类,划分为若干类。对不同类别的时间段分别建立以室外辐射、室外湿度、室外风速、室外温度等温室室外环境因子作为输入,室内温度为输出的BP神经网络模型,用于今后相同类别时间段的温室室内温度预测。




图1 二步日光温室温度预测方法过程

Fig.1 Process of the two-steps method to predict indoor temperature in solar greenhouse

在一定的时间段内,如半个月时间跨度,不同日期的宏观气候状况基本类似,气温等各种条件波动较小,对温室室内温度的影响具有相似性,因此可以作为一类看待。而对于不同时间段,随着季节转变等变化,其气候因素变化较大,对温室室内温度的影响可能有所不同,需要将不同时间段划分为多个类别。针对各类别时间段,分别构建外界环境因素对温室内温度影响的模型,有望提高预测精度。

1.2 室外温度的二次聚类

由于室外温度因素最准确地反映了每日随季

节变化的宏观气候条件,因此采用室外温度作为日相似聚类和时间段相似聚类的因素。第1次聚类,考察每日温度变化状况,并对根据温度向量的相似度将日归为多类;第2次聚类,考察不同时间段包含的相似日的分布,对类似的时间段进行归类。

第1次聚类:按照每日的室外温度变化分布特点对相似日进行聚类。

为了对温度相似日进行聚类,构造能反映每天室外温度变化特性的日温度分布向量

$$A_p = [a_{p1}, a_{p2}, \dots, a_{pn}, a_{pmax}, a_{pmin}, a_{pmean}] \quad (1)$$

式中 A_p ——第 p 天的温度描述向量,该向量反映了室外环境温度随时间变化规律

$a_{p1}, a_{p2}, \dots, a_{pn}$ ——第 p 天等分各时刻温度

a_{pmax} ——当天最高温度

a_{pmin} ——当天最低温度

a_{pmean} ——当天日平均温度

对全年日温度分布向量的集合采用 K-means 聚类方法进行日相似性聚类,可划分为 C 类。

第2次聚类:按照时间段包含相似日的分布,对时间段进行聚类。

首先,将全年时间划为 t 个连续时间段。时间段长度选择原则是,在同一时间段,宏观气候变化相对较为平稳。统计每个时间段中第1类到第 C 类相似日子的数量。构造连续时间段相似日统计向量

$$S_t = [s_{t1}, s_{t2}, \dots, s_{tC}, s_{tmax}, s_{tmin}, s_{tmean}] \quad (2)$$

式中 S_t ——第 t 个时间段的相似日统计向量

$s_{t1}, s_{t2}, \dots, s_{tC}$ ——在第 t 个连续时间段中,每类相似日的数量(从第1类到第 C 类)占时间段总天数的百分比

$s_{tmax}, s_{tmin}, s_{tmean}$ ——第 t 个连续时间段中室外最高温度、最低温度和平均温度

将构造好的连续时间段相似日统计向量的集合通过 K-means 聚类算法进行第2次聚类,可划分为 M 类。

1.3 BP神经网络预测模型建模与训练

BP神经网络是一种按照误差逆向传播算法训练的多层前馈神经网络。BP神经网络在输入层与输出层之间有若干隐藏层神经元,其状态的改变则能影响输入与输出之间的关系。计算过程由正向计算过程和反向计算过程组成。正向传播过程,输入模式从输入层经隐单元层逐层处理,并转向输出层,每层神经元的状态只影响下一层神经元的状态。如果在输出层不能得到期望的输出,则转入反向传播,

将误差信号沿原来的连接通路返回,通过修改各神经元的权值,使得误差信号最小。

将温室外各气象参数(大气温度、相对湿度、太阳辐射、风速、风向、降雨量、大气压强等)与日光温室内温度进行相关性分析。由分析结果可知,室外气象站所测得的大气温度、相对湿度、太阳辐射、风速与日光温室内的环境温度的相关性均通过了0.05水平的显著性检验。因此,可将温室外大气温度、相对湿度、太阳辐射、风速4个要素作为BP神经网络模型的输入因子。日光温室环境温度作为输出因子。

神经网络模型如图2所示。模型为4-20-1三层结构BP神经网络模型。含有4个输入,分别为室外大田气象站所测的空气温度 T_{out} 、相对湿度 H_{out} 、太阳总辐射 W_{out} 和风速 R_{out} ;1个输出,为温室内温度 T_{in} ;模型选用1个隐含层,通过模型调优,隐含层神经元为20个。通过优化测试,隐含层选用 logsig 传递函数,输出层选用 purelin 传递函数,网络训练算法采用 traingd 算法,选择5000作为最大训练次数,0.001作为目标误差值,0.05作为初始学习率。在构建BP神经网络预测模型前,需要对所有室外气象输入因子进行归一化处理,输出温室内温度数据后再进行反归一化处理。




图2 三层结构BP神经网络模型

Fig.2 BP neural network model with 4-20-1 three layers

对于训练数据,划分为 M 类时间段后,每类分别训练一个BP神经网络模型,不同的模型参数不同。对于新的室外温度数据,可以将其归纳入某类,采用相应的BP神经网络模型,将室外温度输入,即可得到室内的预测温度。

2 试验与结果分析

2.1 数据采集

试验数据采自中国农业大学涿州农场,该农场位于 $39^{\circ}29'N, 115^{\circ}59'E$ 。温室内环境数据来源于涿州农场1号日光温室,该温室东西长60m,南北宽8m,总面积为 $480m^2$,采用冷弯钢架结构,温室内部

种植草莓,共种植70垄,每垄2行,垄宽0.50 m,过道宽0.30 m,垄间距为0.75 m。

室内温度数据来自于室内温度传感器,室外气象参数由该日光温室北侧50 m左右气象站自动采集记录,气象站上装有温度传感器、湿度传感器、风速传感器、风向传感器、雨量传感器、太阳辐射传感器、气压传感器。数据集的时间跨度为2014年1月1日0时到2015年12月31日24时之间,采样时间间隔为1 h。

2.2 二次聚类

2.2.1 日相似性聚类

首先对该涿州农场室外气象站所测2014年全年温度数据进行第1次聚类——日相似性聚类。为了第2次时间段聚类有更显著的区分效果,因此这里的分类越多越好,但当分类过多时,不同类别间会产生重叠,影响分类效果。

如表1所示,当 $C=4$ 时,分类效果最好,数据项与所属类中心点最大距离比 C 为2、3时显著减小,且该值仅略大于中心点间最小距离,说明类别间仅产生轻微重叠。而 $C=5$ 时,由于类别间产生了较为严重的重叠,数据项与所属类中心点的距离并未显著减小。因此, $C=4$ 时分类效果最好。4类相似日的聚类中心见图3。

表1 不同类别数时的相似日聚类效果比较

Tab.1 Effect of similar days clustering under different number of categories

类别数	中心点间	数据项与所属类中心点
	最小距离	最大距离
2	105.76	50.80
3	53.32	36.47
4	26.04	29.45
5	19.39	28.16




图3 相似日聚类4个聚类中心

Fig.3 Four centers of clustering with similar days

2.2.2 连续时间段聚类

考虑到气候宏观变化,将半个月(15 d或16 d)

作为一个时间段,从每年1月开始至12月,全年可划分为24个连续时间段。根据每个时间段中4类相似日的比例,对连续时间段进行聚类。

通过表2与图4可以发现,将24个连续时间段分为4类时效果最好。但分为4类时,有两类包含的时间段过少,不利于后续的BP神经网络训练。因此本文采用次优的聚类方案,将24个连续时间段分为3类。

表2 不同类别数时的连续时间段聚类效果比较

Tab.2 Effect of continuous time clustering under different number of categories

类别数	中心点间	数据项与所属类中心点
	最小距离	最大距离
2	0.954	0.860
3	0.909	0.641
4	0.856	0.431




图4 2014年不同时间段内各类相似日占比

Fig.4 Proportion of every category of similar days during different periods in 2014

2014年数据和2015年数据的时间段分类结果如表3所示。分析时间段类别I、II、III中的时间段分布规律可知,聚类结果与季节有着很大的相关性,室外温度特性不同的3个时间段分别为:12月—3月、4月—5月与10月—11月、6月—9月,除了在季节交替处存在反复变换情况,总体来说相邻时间段基本属于同一类别。

表3 2014年及2015年连续时间段聚类效果

Tab.3 Results of continuous time clustering in 2014 and 2015

年份	类别	时间段
2014	I	6,7,8,9,20,21
	II	10,11,12,13,14,15,16,17,18,19,22
	III	1,2,3,4,5,23,24
2015	I	4,6,7,8,9,19,20,21
	II	10,11,12,13,14,15,16,17,18
	III	22,23,24,1,2,3,5

同时,2015年室外气象数据的聚类结果与2014年基本一致,室外温度特性变化季节性分布基本无异。故推断,对任意一年的全年气象数据采用基于连续时间段聚类方法,得到的分类结果在不同年份上具有推广性,可用于其他年份的建模预测。

2.3 BP神经网络模型训练

利用2014年数据,对BP神经网络进行训练,并利用2015年数据对训练效果进行测试。

训练数据,输入是每个监控时刻室外大田气象站所测的空气温度 T_{out} 、相对湿度 H_{out} 、太阳总辐射 W_{out} 和风速 R_{out} ;输出是温室内温度 T_{in} 。

以第Ⅲ类时间段的BP神经网络模型为例。图5反映了该模型的训练过程,通过135次迭代,训练效果达到最优。训练完成的模型通过同属第Ⅲ类时间段的2015年12月下半月的数据进行检验。检验结果如图6所示,预测值与实测值较为均匀地分布在 $y=x$ 直线附近,两者之间的相关系数为0.9506,表明预测值与实测值之间有着很好的拟合精度,说明训练出的BP神经网络有较高的预测精度。




图5 第Ⅲ类时间段的BP神经网络训练迭代过程的变化曲线

Fig. 5 Process of training iteration of BP neural network for the 'Ⅲ' category of periods




图6 第Ⅲ类时间段BP神经网络预测值与实测值对比
Fig. 6 Comparison of measured values and predicted values from BP neural network for the 'Ⅲ' category of periods

2.4 预测效果对比分析

比较3种方法的预测效果:传统数据拟合常用

的回归分析法;未进行输入分类的常规BP神经网络方法;本文二步方法。

选取2014年1月1日至2014年12月31日数据作为训练集,2015年1月1日至2015年12月31日数据作为测试集。

3种方法的预测误差如表4所示,2015年12月1日—5日数据的局部预测效果和误差比较如图7所示。其中平均相对误差为

$$e = \frac{\sum_{i=1}^N (p_i - m_i) / m_i}{N} \times 100\% \quad (3)$$


式中 p_i ——该时刻用某方法预测的温室内温度
 m_i ——该时刻温室内温度测量值

表4 3种方法预测效果对比


Tab. 4 Effects of the three prediction methods

预测方法	平均相对	误差标准	最大误差/	最小误差/
	误差/%	差/%	%	%
回归分析	13.12	11.62	58.85	0.13
BP神经网络	11.63	8.65	53.48	0.07
二步方法	6.23	3.63	22.59	0.07

结果显示,如果不做输入的二次聚类,直接用BP神经网络对本数据做训练,平均相对误差达到11.63%,仅略优于回归分析的13.12%,同时,该方法误差范围较大,最大误差达到53.48%,误差标准差达到8.65%。而本文所提出的二步预测方法,显



(a) 实测值与3种方法预测值的比较



(b) 3种方法相对误差的比较

图7 不同方法温室温度预测效果比较

Fig. 7 Effects of the three prediction methods

著地提高了预测精确度,平均相对误差仅 6.23%,相较于单纯的 BP 神经网络方法,降低了 5.4 个百分点。同时,本文方法还有效地控制了误差范围,最大误差仅 22.59%,相较于单纯的 BP 神经网络方法降低了 30.89 个百分点。误差标准差仅 3.63%,仅为单纯 BP 神经网络误差标准差的 41.9%。

3 结论

(1)提出二次聚类 and BP 神经网络相结合的二步日光温室温度预测方法。首先,通过聚类将室外气象数据时间段划分为若干类。对不同类别的时间

段分别建立温室室外环境因素与室内温度的 BP 神经网络模型,为今后相同类别时间段的温室室内温度预测提供了新的手段。

(2)分别针对 3 类时间段训练温室室外环境因素与室内温度间的 BP 神经网络模型,显著地提高了温度预测精确度,平均相对误差仅 6.23%,相较于未聚类的 BP 神经网络方法,误差降低了 5.4 个百分点。误差标准差仅 3.63%,仅为单纯 BP 神经网络误差标准差的 41.9%。说明本文提出的二步日光温室温度预测方法具有较高的预测精确度,显著优于仅采用神经网络的预测方法。

参 考 文 献

- 邓璐娟,张侃谕,龚幼民,等. 温室环境多级控制系统及优化目标值设定的初步研究[J]. 农业工程学报, 2005, 21(5): 119-122.
- DENG Lujuan, ZHANG Kanyu, GONG Youmin, et al. Preliminary study on hierarchical greenhouse environment control system and setting of the optimized target values[J]. Transactions of the CSAE, 2005, 21(5): 119-122. (in Chinese)
- 左志宇,毛罕平,张晓东,等. 基于时序分析法的温室温度预测模型[J]. 农业机械学报, 2010, 41(11): 173-177.
- ZUO Zhiyu, MAO Hanping, ZHANG Xiaodong, et al. Forecast model of greenhouse temperature based on timeseries method[J]. Transactions of the Chinese Society for Agricultural Machinery, 2010, 41(11): 173-177. (in Chinese)
- 李锡文,杨明金,杨仁全. 现代温室环境智能控制的发展现状及展望[J]. 农机化研究, 2008, 30(4): 9-13.
- LI Xiwen, YANG Mingjin, YANG Renquan. The development status and prospect of modern greenhouse environment intelligent control[J]. Journal of Agricultural Mechanization Research, 2008, 30(4): 9-13. (in Chinese)
- 王孝卿,李楠,薛晓萍. 寿光日光温室小气候变化规律及模拟方法[J]. 中国农学通报, 2012, 28(10): 236-242.
- WANG Xiaqing, LI Nan, XUE Xiaoping. The microclimate change rules and simulation method of greenhouse in Shouguang City [J]. Chinese Agricultural Science Bulletin, 2012, 28(10): 236-242. (in Chinese)
- 孟力力,杨其长, BOTG P A, 等. 日光温室热环境模拟模型的构建[J]. 农业工程学报, 2009, 25(1): 164-170.
- MENG Lili, YANG Qichang, BOTG P A, et al. Visual simulation model for thermal environment in Chinese solar greenhouse[J]. Transactions of the CSAE, 2009, 25(1): 164-170. (in Chinese)
- 李宁,申双和,黎贞发,等. 基于主成分回归的日光温室室内低温预测模型[J]. 中国农业气象, 2013, 34(3): 306-311.
- LI Ning, SHEN Shuanghe, LI Zhenfa, et al. Forecast model of minimum temperature inside greenhouse based on principal component regression[J]. Chinese Journal of Agrometeorology, 2013, 34(3): 306-311. (in Chinese)
- 王定成. 温室环境的支持向量机回归建模[J]. 农业机械学报, 2004, 35(5): 106-109.
- WANG Dingcheng. SVM regression modeling for greenhouse environment[J]. Transactions of the Chinese Society for Agricultural Machinery, 2004, 35(5): 106-109. (in Chinese)
- AI T, YU J Q, LIU Y F, et al. Study on neural network self-tuning PID control for temperature of active solar house heating system [C]//International Workshop on Intelligent Systems and Applications. IEEE, 2010: 1-4.
- ZHANG X Y. A novel greenhouse control system based on fuzzy neural network[J]. Applied Mechanics & Materials, 2014, 668-669: 415-418.
- OUTANOUTE M, LACHHAB A, ED-DAHAK A, et al. A neural network dynamic model for temperature and relative humidity control under greenhouse[C]//International Workshop on Rfid& Adaptive Wireless Sensor Networks. IEEE, 2015: 6-11.
- QI K, CHEN Y, LIU B, et al. Research on neural network model for greenhouse temperature predictive control[J]. Lecture Notes in Electrical Engineering, 2013, 254: 551-557.
- FERREIRA P M, FARIA E A, ERUANO A. Neural network models in greenhouse air temperature prediction [J]. Neurocomputing, 2002, 43(4): 51-75.
- ZHAO H, SHI L R, WANG H J. Sunlight greenhouse temperature prediction model based on bayesian regularization BP neural network[J]. Applied Mechanics & Materials, 2015, 740: 871-874.
- FATHIF. Multiple neural control of a greenhouse[J]. Neurocomputing, 2014, 139(4): 138-144.
- 杜尚丰,李迎霞,陈亮,等. 温室环境神经网络建模[J]. 计算机测量与控制, 2006, 14(7): 887-889.
- DU Shangfeng, LI Yingxia, CHEN Liang, et al. Modeling greenhouse environment with artificial neural networks[J]. Computer Measurement & Control, 2006, 14(7): 887-889. (in Chinese)
- 邹伟东,张百海,姚分喜,等. 基于改进型极限学习机的日光温室温湿度预测与验证[J]. 农业工程学报, 2015, 31(24): 194-200.
- ZOU Weidong, ZHANG Baihai, YAO Fenxi, et al. Verification and forecasting of temperature and humidity in solar greenhouse based on improved extreme learning machine algorithm[J]. Transactions of the Chinese Society of Agricultural Engineering, 2015, 31(24): 194-200. (in Chinese)
- 邹秋滢,纪建伟,李征明. 基于 ANFIS 的温室小气候环境因子预测模型辨识[J]. 沈阳农业大学学报, 2014, 45(4): 503-507.
- ZOU Qiuying, JI Jianwei, LI Zhengming. Identification of greenhouse microclimate environmental factors prediction model based on ANFIS[J]. Journal of Shenyang Agricultural University, 2014, 45(4): 503-507. (in Chinese)
- 王万良,李敏,李勤学,等. 温室环境的模糊逻辑网络建模与智能控制[J]. 机电工程, 2000, 17(2): 63-66.
- WANG Wanliang, LI Min, LI Qinxue, et al. Adaptive fuzzy logic network model and intelligent control for greenhouse climate [J]. Mechanical & Electrical Engineering Magazine, 2000, 17(2): 63-66. (in Chinese)
- MIRANDA L, SCHUCH I, DANNEHL D, et al. Using artificial neural networks to predict the climate in a greenhouse: first simulation results on a semi-closed system[J]. Acta Horticulturae, 2015, 1099(2): 137-144.
- PETERSSON A, THIRINGER T, HARNEFORS L, et al. Modeling and experimental verification of grid interaction of a DFIC wind turbine[J]. IEEE Transactions on Energy Conversion, 2005, 20(4): 878-886.