

郁莹珺,徐达宇,寿国忠,等. 基于经验模态分解和小波神经网络的温室温湿度预测[J]. 江苏农业科学,2019,47(1):211-216.
doi:10.15889/j.issn.1002-1302.2019.01.051

基于经验模态分解和小波神经网络的温室温湿度预测

郁莹珺¹, 徐达宇^{1,2}, 寿国忠^{2,3}, 王佩欣^{2,3}

(1. 浙江农林大学信息工程学院,浙江临安 311300; 2. 浙江农林大学/浙江省林业智能监控和信息技术研究重点实验室,浙江临安 311300;
3. 浙江农林大学工程学院,浙江临安 311300)

摘要:温室湿度的准确预测有助于及时调节温室小环境,温湿度预测模型是温室控制的重要基础,提高预测精度有助于提高生产水平。针对温室系统具有非线性、非平稳性等特点,提出一种基于经验模态分解(empirical mode decomposition,简称 EMD)和小波神经网络(wavelet neural network,简称 WNN)的温室温湿度组合预测方法。首先,利用经验模态分解方法将原始时间序列分解成一系列分量;然后对各分量分别构建小波神经网络模型进行预测;最后叠加各子序列得到预测值。结果表明,运用 EMD-WNN 组合的温度模型有效性为 0.993 4,湿度模型有效性为 0.978 1,且优于单独 WNN 模型和 BP 神经网络模型的预测结果,可有效提高短期温室温湿度预测的精度。

关键词:经验模态分解;小波神经网络;模型构建;温室;温度;湿度;预测

中图分类号: S625.5⁺1 **文献标志码:** A **文章编号:** 1002-1302(2019)01-0211-05

温室作物生产是农业生产发展的一个新阶段,相较于大田作物生产,其生产过程受外界气候变化的影响较小,能够满足人们在不同季节对各种农产品的需求。现代化温室可以有效地调控温度、湿度、光照、二氧化碳浓度以及土壤温湿度等环境因子,营造一个与室外大气候环境相对隔离的小气候环境,减小作物生长对自然环境的依赖性。我国温室发展迅速,但单位面积产量与西方发达国家相比,仍较为落后。温室小气候环境是影响作物生长和产量的主要条件之一,为满足作物对其生长环境的不同要求,须要分析温室小气候的变化。如何模拟温室小气候环境,提高环境因子的预测精度,进而快速地对温室环境进行调节和控制,提高温室的生产力,是我国温室发展亟待解决的问题。

由于温室是一个典型的非线性、时变的复杂系统,外界气候变化、温室内部作物的生理作用和各种调控措施都会对温室小气候环境产生影响,因此其模型很难通过机理法用简单的数学公式或传递函数来描述^[1]。随着智能计算的发展,利用人工神经网络技术解决温室建模的相关问题逐渐成为研究热点。人工神经网络具有较强的学习能力以及较好的自组织、自适应能力,能够通过数据的内在联系建立模型,它可以自动从历史数据中提取相关信息,从而有效地解决传统预测方法面临的许多局限和困难,因此鉴于其在建模中的优势,人工神经网络成为短期环境因子预测的一种性能较好的方法。王定成利用支持向量机回归建模方法,根据历史数据建立了温室气候模型^[2]。李倩等针对不同通风条件下南方塑料大

棚内温湿度状况,建立相应的反向传播(back propagation,简称 BP)神经网络预测模型,结果表明,该模型对于不同季节、不同通风条件、不同作物的大棚温湿度模拟都有较高的精度^[3]。金志凤等利用气象数据,构建了基于 BP 神经网络的杨梅大棚内气温预测模型,该模型试验精度明显高于同时利用逐步回归法建立的模型^[4]。Fourati 采用 Elman 神经网络(elman neural network)建立温室温湿度预测模型,该模型包括 6 个输入节点、3 个隐节点、2 个输出节点,试验得到,温度误差为 0.3℃,湿度误差为 4%^[5]。邹伟东等基于正交基函数的改进型极限学习机对日光温室环境因子进行辨识,建立日光温室温湿度环境因子预测模型,预测结果表明,温度模型有效性为 0.943 4,湿度模型有效性为 0.920 8^[6]。

温室的结构从根本上决定了温室内的作物生长对室外环境气象条件的依赖性已大幅减小。目前关于室外环境气象条件对温室内环境因子影响的研究较多,但针对温室内环境因子开展的模拟预测较少。因此,本研究拟利用温室内小气候数据,建立预测模型,对温室的温湿度环境进行模拟和分析,以期对温室环境调控提供科学依据。针对温湿度时间序列具有非线性和非平稳性的特点,本研究提出一种基于经验模态分解(empirical mode decomposition,简称 EMD)和小波神经网络(wavelet neural network,简称 WNN)的温湿度短期组合预测模型,结合各方法的特点,通过优势互补提高预测精度。该方法首先利用经验模态分解将时间序列分解为一系列具有不同特征尺度的数据序列分量;然后针对每组序列的自身特点构建其小波神经网络模型,并对各分量进行预测;最后将各分量预测结果叠加得到最终预测值,并通过误差分析,验证模型的预测效果。

1 经验模态分解

经验模态分解是一种能够将非平稳信号平稳化处理的信号分析方法^[7],具有直观性和适应性,在很多领域中得到了广泛应用^[8-11]。其假设任何复杂信号均由若干个频率特征

收稿日期:2017-09-04

基金项目:浙江省自然科学基金(编号:LQ17G010003);浙江农林大学人才启动项目(编号:2012FR070)。

作者简介:郁莹珺(1992—),女,浙江临安人,硕士研究生,主要从事农林物联网方面的研究。E-mail:120664963@qq.com。

通信作者:寿国忠,博士,教授,主要从事农业物联网技术的研究。E-mail:gzzhou@zafu.edu.cn。

不同的本征模态函数 (intrinsic mode function, 简称 IMF) 组成, 且每一个 IMF 都是相互独立的。分解出来的各 IMF 分量包含了原信号在不同时间尺度上的局部特征信号。经验模态分解的目的是把复杂的信号分解成有限个本征模态函数之和。通过将时间序列与具有不同频率的本征模态分量进行匹配, 将时间序列中不同尺度的分量逐级分解出来, 产生一系列具有相同特征尺度的数据序列。分解后的数据序列与原始时间序列相比具有更强的规律性, 因此经验模态分解更适用于处理非线性、非平稳性的时间序列。EMD 分解步骤如下。

(1) 求出原始时间序列 $x(t)$ 中所有的极大值、极小值点, 并用三次样条插值函数拟合形成其上、下包络线 $e_{up}(t)$ 、 $e_{low}(t)$ 。

(2) 计算上、下包络线的平均值 $m_1(t)$ 。

$$m_1(t) = \frac{e_{up}(t) + e_{low}(t)}{2} \quad (1)$$

(3) 由原数据减去包络平均值后得到新数据 $h_1(t)$ 。

$$h_1(t) = x(t) - m_1(t) \quad (2)$$

若 $h_1(t)$ 还存在负的局部极大值和正的局部极小值, 说明这还不是一个本征模态函数, 须要继续进行筛选。将 $h_1(t)$ 视为新的序列 $x(t)$, 重复步骤 (1)、(2) k 次, 直到 $h_{1k}(t)$ 满足 IMF 条件, 记 $c_1(t) = h_{1k}(t)$, 则 $c_1(t)$ 为分解后得到的第 1 个 IMF 分量。

(4) 从原始信号中分离出 IMF 分量 $c_1(t)$, 得到剩余分量 $r_1(t)$ 。

$$r_1(t) = x(t) - c_1(t) \quad (3)$$

将剩余分量 $r_1(t)$ 作为新的原始序列, 重复上述步骤, 筛选可得到其余 IMF 分量 $c_1(t), c_2(t), c_3(t), \dots, c_i(t)$, 以及余量 $r_N(t)$ 。因此, 原始时间序列 $x(t)$ 可被分解为

$$x(t) = \sum_{i=1}^N c_i(t) + r_N(t) \quad (4)$$

2 小波神经网络原理

小波神经网络起源于小波变换, 是小波理论与人工神经网络相结合的一种前馈型神经网络^[12]。小波神经网络综合了两者的特点, 既具有小波变换优越的时频特征提取能力, 又具有神经网络的自学习能力以及对非线性输入、输出关系的任意逼近能力, 因此被有效地应用于预测、信号处理、故障诊断等众多领域^[13-16]。

小波神经网络以 BP 神经网络拓扑结构为基础, 用小波基函数代替传统激励函数作为隐含层节点的传递函数, 信号前向传播, 误差反向传播。同时, 相应的输入层到隐含层、隐含层到输出层权值及隐含层阈值分别由小波基函数的伸缩与平移参数所确定。3 层小波神经网络的拓扑结构见图 1。

当输入样本序列为 $X_i (i = 1, 2, \dots, k)$ 时, 隐含层的输出计算公式为

$$h(j) = h_j \left(\frac{\sum_{i=1}^k w_{ij} x_i - b_j}{a_j} \right), j = 1, 2, \dots, l \quad (5)$$

式中: $h(j)$ 为隐含层第 j 个节点的输出; h_j 为小波基函数; w_{ij} 为输入层和隐含层的连接权值; a_j 为小波基函数的伸缩因子; b_j 为小波基函数的平移因子; l 为隐含层节点数。

本研究采用 Morlet 函数作为小波基函数, 其在预测模型




图1 小波神经网络拓扑结构

中具有较强的鲁棒性和自适应性, 具体公式为

$$y = \cos(1.75x) e^{-\frac{x^2}{2}} \quad (6)$$

小波神经网络输出层计算公式为

$$Y(k) = \sum_{j=1}^l w_{jk} h(j), k = 1, 2, \dots, m \quad (7)$$

式中: w_{jk} 为隐含层到输出层权值; m 为输出层节点数。

小波神经网络学习的基本策略是采用梯度修正法修正网络的权值和小波基函数系数。小波神经网络算法的具体步骤为 (1) 初始化网络。 (2) 把样本分为训练样本和测试样本。 (3) 输入训练样本, 获得预测输出, 计算预测输出与期望输出的误差, 具体计算方法见公式 (8)。 (4) 根据误差 e 修正网络权值和小波函数参数, 使得预测值逼近期望值。 (5) 判断算法是否结束。如没有结束, 返回步骤 (3)。

$$e = \sum_{k=1}^m yn(k) - y(k) \quad (8)$$

式中: $y(k)$ 为预测输出; $yn(k)$ 为期望输出。

3 基于 EMD - WNN 的组合预测方法

温室内温湿度时间序列具有较强的非线性、非平稳性, 因此在使用常规学习预测方法时难以取得较好的效果。鉴于经验模态分解技术在非平稳数据处理中的突出优势, 本研究提出一种基于 EMD - WNN 组合的预测方法。首先对原始时间序列进行 EMD, 使其产生一系列不同尺度的 IMF 分量, 实现序列平稳化; 然后针对各分量建立适合的小波神经网络预测模型; 最后将各分量的预测值叠加得到最终预测值。

EMD - WNN 预测模型的具体结构流程 (图 2) 为 (1) 利用经验模态分解方法对原始时间序列进行分解, 得到 IMF 各分量 $c_i(t)$ 和余量 $r_N(t)$ 。 (2) 分别对各 IMF 分量 $c_i(t)$ 和 $r_N(t)$ 建立小波神经网络预测模型, 得到各分解序列的预测值。 (3) 将各分量预测值叠加得到最终预测结果。 (4) 与实际测量值对比, 计算误差指标并进行误差分析。

4 试验过程

4.1 试验数据来源

试验数据来源于浙江省建德市某温室, 该温室长 64 m, 宽 32 m, 边高为 3 m, 南北向为拱形, 拱高 4.8 m。试验期间温室内种植作物为草莓。温室环境因子数据由基于无线传感网络的智能温室监控系统自动采集获得。试验时间为 2017 年 2 月 13 日 0:00 至 4 月 14 日 23:00, 采集的数据为距地面 1.5 m 高度处的温室内温度和湿度, 采样周期为 1 h, 去除异常数据后共获得 1 220 个样本数据, 其原始时间序列如图 3 所示。

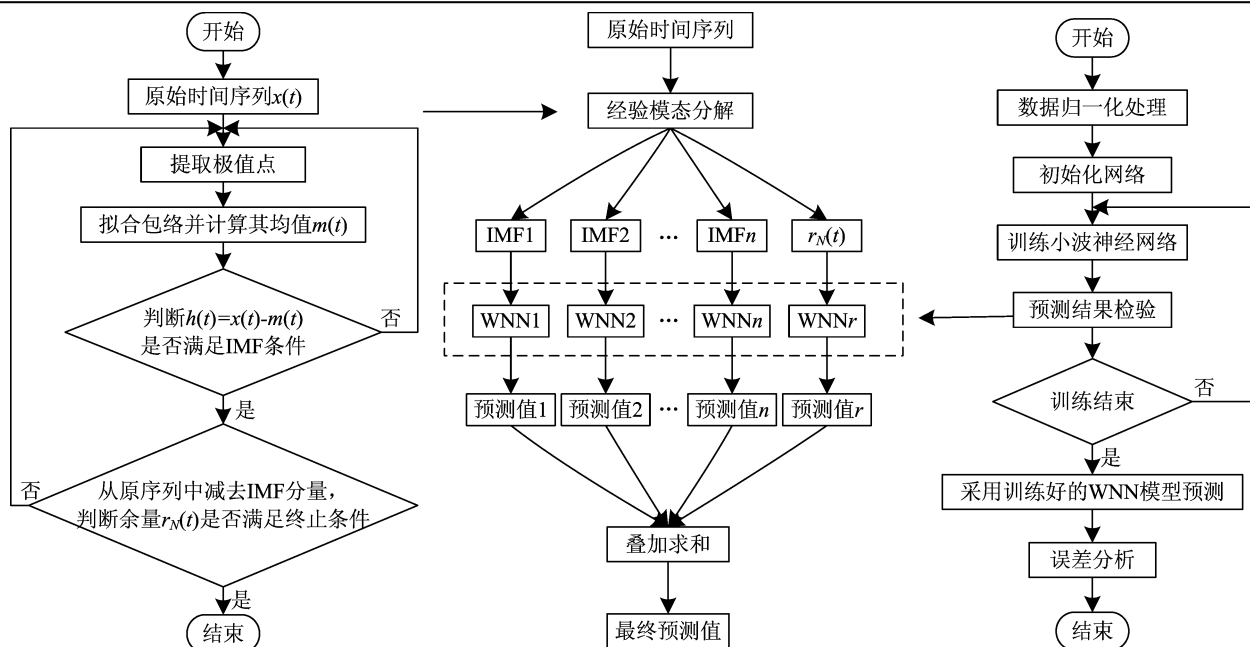


图2 EMD-WNN 组合预测流程




图3 温室内温度、湿度原始时间序列

4.2 预测过程

首先对原始时间序列进行经验模态分解,分解结果如图4、图5所示。根据频率不同,可以将分解结果划分高频部分、低频部分、残余项等3部分。以温度时间序列为例,IMF1~IMF3为高频部分,表示温度具有不平稳性;IMF4~IMF7为低频部分,表示温度具有较平稳的周期波动性;残余项 $r(t)$ 则表示在试验期间,温度呈稳定上升趋势。而对于湿度时间序列来说,IMF1~IMF4为高频部分,表示湿度变化具有不平稳性;IMF5~IMF8为低频部分,表示湿度具有周期变化性;残余项则表明在试验期间,湿度总体呈现波动变化。

然后,使用EMD-WNN预测模型对试验数据进行训练。选取2月13日至4月13日的1196个数据作为训练集,选取4月14日的24个数据作为测试集。采用具有单隐含层的3层小波神经网络建立预测模型进行预测,网络结构为4-6-1(输入层节点数为4个,隐含层节点数为6个,输出层节点数为1个)。其中,输入层输入当前时间点前4个时间点的数

据;隐含层节点由小波基函数构成,节点数为6个;输出层输出当前时间点的预测数据。

少,网络从样本中获取的信息较少,不足以概括和体现训练样本的规律;如果数量过多,又可能出现过拟合现象。关于隐含层节点数的确定,目前还没有成熟的理论进行指导,通常根据建模经验和试凑法来确定隐含层的节点数。根据网络训练过程中误差目标函数的收敛情况以及预测值与真实值的拟合情况不断对其进行调整,最终确定隐含层节点数为6。

为提高神经网络训练的效率和网络的泛化性能,在训练前对所有样本数据进行归一化处理。所有试验均在具有3.3 GHz中央处理器(central processing unit,简称CPU)与8 G内存的计算机上完成,仿真软件为Matlab 2016a。

5 结果与分析

本研究同时采用WNN预测模型和BP神经网络模型对原始时间序列进行预测试验。图6为基于EMD-WNN模型的预测结果,图7为3种模型的预测结果。

为评价和比较试验结果,本研究选取预测中常用的性能指标平均绝对百分比误差(mean absolute percentage error,简称MAPE)、均方根误差(root mean square error,简称RMSE)、模型有效性(model validity,简称MV)来评估模型的准确性。计算公式分别为




图4 温度时间序列 EMD 分解结果




图5 湿度时间序列 EMD 分解结果

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y'_i - y_i}{y_i} \right|; \quad (10)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y'_i - y_i)^2}; \quad (11)$$

$$MV = 1 - \frac{\sum_{i=1}^n (y'_i - y_i)^2}{\sum_{i=1}^n (y'_i - \bar{y})^2}. \quad (12)$$

式中: y_i 为实际测量值; y'_i 为预测值; \bar{y} 为实际测量值的平均

值; n 为数据个数。3 种预测模型各评价指标结果如表 1 所示。

表 1 3 种预测模型结果评价指标

预测模型	温度(℃)			湿度(%)		
	MAPE	RMSE	MV	MAPE	RMSE	MV
EMD-WNN	0.09	0.586 0	0.993 4	0.12	2.862 8	0.978 1
WNN	0.16	1.090 0	0.974 7	0.18	6.526 7	0.876 4
BP	0.19	1.248 8	0.970 9	0.20	6.808 2	0.854 0

从图 6、图 7、表 1 可以看出:(1)3 种预测模型均可以对温湿度时间序列的变化进行有效跟踪,表明利用人工神经网络进行模拟预测是行之有效的。(2)EMD-WNN 模型和 WNN 模型的预测精度均比 BP 神经网络模型有所提高,说明与 BP 神经网络相比,小波神经网络对温湿度的预测效果更为理想,体现了小波神经网络的优越性。(3)与单独的 WNN 模型相比,运用 EMD-WNN 组合模型对温室小气候环境进

行模拟预测精度有了一定的提高,尤其在波动较大的转折点较为明显;同时,运用 EMD-WNN 组合模型的湿度均方根误差减小 0.504 ℃,湿度均方根误差减小 3.663 9 百分点,温度模型有效性相对提高 0.018 7 ℃,湿度模型有效性相对提高了 0.101 7 百分点。结果表明,对温湿度时间序列采用科学有效的算法降低其不稳定性是有必要的。




图6 EMD-WNN 模型预测结果




图7 3 种模型预测结果

6 结论

本研究提出一种基于 EMD-WNN 的温室温湿度短期组合预测模型,从研究对象的特性出发,采用多算法融合的组合预测思路来提高预测精度。首先利用经验模态分解对时间序列进行平稳化处理,然后对其进行训练、检验,进而预测未来 1 d 的温湿度变化。试验结果表明,该模型网络结构简单,收敛速度快,既发挥了经验模态分解的优势,又继承了小波变换良好的时频局部化特性,能充分地分析环境因子的变化规律,并获取其变化过程中的大体趋势与细节信息,具有实际应用价值。但环境因子的影响因素众多,具有很大的随机性,导致个别时间点的预测值存在较大的相对误差,因此该模型有待于进一步完善。

参考文献:

- [1] 徐立鸿,苏远平,梁毓明. 面向控制的温室系统小气候环境模型要求与现状[J]. 农业工程学报,2013,29(19):1-15.
- [2] 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.
- [3] 李倩,申双和,曹雯,等. 南方塑料大棚冬春季温湿度的神经

- 网络模拟[J]. 中国农业气象,2012,33(2):190-196.
- [4] 金志凤,符国槐,黄海静,等. 基于 BP 神经网络的杨梅大棚内气温预测模型研究[J]. 中国农业气象,2011,32(3):362-367.
- [5] Fourati F. Multiple neural control of a greenhouse [J]. Neurocomputing,2014,139(SI):138-144.
- [6] 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(24):194-200.
- [7] Huang N, Shen Z, Long S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proceedings of the Royal Society A - Mathematical Physical and Engineering Sciences,1998,454(1971):903-995.
- [8] 叶林,刘鹏. 基于经验模态分解和支持向量机的短期风电功率组合预测模型[J]. 中国电机工程学报,2011,31(31):102-108.
- [9] 姚冠新,顾晴. 基于经验模态分解和支持向量机的农产品价格短期预测[J]. 江苏农业科学,2014,42(9):402-405.
- [10] 贾嵘,李涛涛,夏洲,等. 基于随机共振和经验模态分解的水力发电机组振动故障诊断[J]. 水利学报,2017,48(3):334-340,350.
- [11] 王贺,胡志坚,陈珍,等. 基于集合经验模态分解和小波神经网络的短期风电功率组合预测[J]. 电工技术学报,2013,28(9):137-144.

陈俐均,杜尚丰,梁美惠,等. 温室温湿度解耦控制策略[J]. 江苏农业科学,2019,47(1):216-220.
doi:10.15889/j.issn.1002-1302.2019.01.052

温室温湿度解耦控制策略

陈俐均,杜尚丰,梁美惠,何耀枫

(中国农业大学信息与电气工程学院,北京 100083)

摘要:生产型温室的温湿度调控大多采用简单的比例积分微分(proportional integral derivative,PID)控制策略,但温湿度模型具有强耦合特性,导致基于 PID 控制的温湿度变化相互影响,设定点跟踪效果不理想。本研究提出一种温湿度解耦控制方法,首先构建温室温湿度机理模型,将其转换为仿射非线性系统,利用坐标变换和非线性状态反馈,将原系统解耦为 2 个独立的积分加时延系统;然后基于此等价系统设计 PID 控制器,使系统状态有效跟踪设定值;最后进行仿真验证。结果表明,提出的解耦策略可以解除温湿度间的耦合关系,基于 PID 控制器的解耦温湿度系统设定值跟踪效果良好。

关键词:温室;温湿度;非线性控制系统;解耦;PID 控制

中图分类号: S625. 5⁺1 **文献标志码:** A **文章编号:** 1002-1302(2019)01-0216-05

温室特殊的结构形成了一个与外界大气候环境相对隔离的内部小气候环境,内部环境的调控直接影响作物产量、品质以及整个生产周期的经济效益^[1-2]。温室环境因子受到室外不可测不可控干扰以及控制设备输入等的影响^[3],具有强耦合特性^[4],这种特性使得基于模型的温室环境调控算法设计复杂度增大,各环境因子的控制并不完全独立,控制回路相互耦合^[5]。

对于温室环境调控,国内外研究集中于设计一系列优化算法来调控温湿度 2 种关键因子。优化控制方法主要包括模糊逻辑算法、神经网络算法、遗传算法以及预测控制等^[6]。其中模糊控制^[7]为不依赖模型的控制,这类控制策略在一定程度上可以提高温室生产的自动化程度,但究其本质仍是一种经验控制,此类控制较少涉及实际系统状态与设定值的偏差大小。神经网络^[8]、遗传算法^[9-11]和预测控制^[12]等都涉及优化指标,这类算法一般基于非线性模型,经过实时滚动的计算过程搜索最优的控制输入,寻优过程复杂,计算量较大,不适于实际的温室生产管理^[11,13]。

实际温室温湿度调控经常采用开关控制和比例积分微分(proportional integral derivative,PID)控制^[14]。开关控制策略是不基于模型的经验控制,设定点跟踪效果较差。PID 控制

器结构简单、易实现,在温室工程应用中被广泛使用^[11],但若将 PID 控制器直接用于温室温湿度系统,则会由于系统的强耦合特性,导致温湿度调控相互影响,超调量大,调控效果不理想。

综上,为改善 PID 调控效果,本研究提出温室温湿度反馈线性化解耦策略:构建温室温湿度模型,将其描述为仿射非线性系统;基于反馈线性化理论,实现温湿度解耦,获得等价的积分加时延系统;基于等价系统设计 PID 控制器;对提出的策略进行仿真验证。

1 温室温湿度反馈线性化解耦

1.1 温室温湿度模型

假设温室内部空气、水蒸气混合分布均匀,将温湿度视为集总参数。温室内温度变化与室外太阳短波辐射增热量、室内外空气经由围护材料的热交换、室内空气与土壤的热交换、作物蒸腾作用消耗的潜热、自然通风引起的对流热交换以及加热器的热量输入有关;温室内湿度变化与作物蒸腾作用的增湿量以及通风损耗有关。根据能量和物质守恒定律,建立温室温湿度动态微分方程如式(1)、式(2)^[15-16],模型各参数含义见表 1。

$$\rho_a C_a V_h = \frac{dT_g}{dt} = \eta GA_h + k_{cov} (T_o - T_g) A_{cov} + k_{soil} (T_s - T_g) A_h - \lambda E_{tran} A_h + \rho_a C_a (\kappa + \theta w + v w u_w) (T_o - T_g) A_{ven} + u_h k_{heat} (T_p - T_g) \quad (1)$$

$$\frac{V_h}{A_h} \frac{dV_g}{dt} = E_{tran} + (\kappa + \theta w + v w u_w) (V_o - V_g) \quad (2)$$

收稿日期:2017-09-19

基金项目:国家自然科学基金(编号:61174088,60374030)。

作者简介:陈俐均(1990—),女,山西运城人,博士,主要从事温室环境控制研究。E-mail:455135092@qq.com。

通信作者:杜尚丰,博士,教授,主要从事复杂系统控制研究。

E-mail:13520760485@126.com。

[12] Zhang Q, Benveniste A. Wavelet networks[J]. IEEE Transactions on Neural Networks, 1992, 3(6): 889-898.

[13] 侯泽宇, 卢文喜, 陈社明. 基于小波神经网络方法的降水量预测研究[J]. 节水灌溉, 2013(3): 31-34.

[14] 成谢锋, 傅女婷, 陈胤, 等. 一种心音小波神经网络识别系统[J]. 振动与冲击, 2017, 36(3): 1-6.

[15] 靳然, 李生才. 基于小波神经网络和 BP 神经网络的麦蚜发生期预测对比(英文)[J]. 植物保护学报, 2016, 43(3): 353-361.

[16] 程声烽, 程小华, 杨露. 基于改进粒子群算法的小波神经网络在变压器故障诊断中的应用[J]. 电力系统保护与控制, 2014(19): 37-42.