

文章编号: 2095-2163(2023)09-0168-04

中图分类号: S625;TP183

文献标志码: A

基于 GA-BP 神经网络的温室温度预测研究

李其操, 董自健

(江苏海洋大学 电子工程学院, 江苏 连云港 222005)

摘要: 温度对于温室内作物的生长起着重要的作用, 为了更精准的管理和控制温室内的温度, 提出了基于遗传算法优化的 BP 神经网络预测模型 (GA-BP), 对温室内温度进行预测。本文利用遗传算法对 BP 神经网络的权值和阈值进行优化, 使模型避免出现局部最优, 有效改善了传统 BP 神经网络预测模型的性能, 使预测出的温度更加精准。实验证明, 选择隐藏层节点数为 7 时, GA-BP 神经网络预测模型的预测结果最佳, 平均绝对误差 (MAE)、均方误差 (MSE) 和平均绝对百分比误差 (MAPE) 分别为 0.441、0.276、0.525。与传统 BP 神经网络预测模型相比分别提升了 13.2%、38.4%、21.5%。

关键词: 遗传算法; BP 神经网络; 温室温度; 预测模型

Greenhouse temperature prediction based on GA-BP neural network

LI Qicao, DONG Zijian

(School of Electronic Engineering, Jiangsu Ocean University, Lianyungang Jiangsu 222005, China)

[Abstract] Temperature plays an important role in the growth of crops in the greenhouse. In order to manage and control the temperature in the greenhouse more accurately, a genetic algorithm-optimized BP neural network prediction model (GA-BP) was proposed to predict the temperature in the greenhouse. In this paper, the genetic algorithm is used to optimize the weights and thresholds of the BP neural network, so that the model avoids local optimization, effectively improves the performance of the traditional BP neural network prediction model, and makes the predicted temperature more accurate. Experiments show that when the number of hidden layer nodes is selected to be 7, the prediction result of the GA-BP neural network prediction model is the best, and the mean absolute error (MAE), mean square error (MSE) and mean absolute percentage error (MAPE) are 0.441, 0.276, and 0.525 respectively. Compared with the traditional BP neural network prediction model, it has increased by 13.2%, 38.4%, and 21.5% respectively.

[Key words] genetic algorithm; BP neural network; greenhouse temperature; prediction model

0 引言

中国是排在世界前列的农业生产大国, 温室的面积占据着世界首位。温室内的环境因素对于作物的生长有着至关重要的影响^[1-2]。目前, 温室的调控方式大多是凭借工人的生产经验, 通过获得的传感器数据, 进行预判性的调控。因此, 能够精准的预测出温室内的温度情况, 对温室调控系统有很大的帮助。

近年来, 许多学者提出了针对温度预测的方法。如: 左志宇^[3]提出采用时序分析法建立温度预测模型的方法; 徐意^[4]构建了基于 RBF 神经网络的温室温度预测模型; 徐宇^[5]构建了基于复数神经网络的温室温度预测模型; 王红君^[6]利用贝叶斯正则化算

法对 BP 神经网络进行改进, 降低了影响温度的因子之间的耦合度等。

但是, 上述预测模型都容易出现陷入局部最优的情况。因此, 本文利用遗传算法, 对 BP 神经网络的初始权值和阈值进行优化, 使预测模型避免出现局部最优的情况, 从而对温室内温度进行更精准的预测。

1 GA-BP 神经网络预测模型的构建

1.1 BP 神经网络

BP 神经网络的主要思想是: 训练数据通过前馈网络训练后得到输出数据, 将输出数据与期望数据进行对比得到误差, 反向传播网络将得到的误差反向输入输出层, 对网络的连接权值和阈值进行反复

作者简介: 李其操 (1997-), 男, 硕士研究生, 主要研究方向: 农业物联网; 董自健 (1973-), 男, 博士, 教授, 主要研究方向: 检测与控制、通信技术。

通讯作者: 董自健 Email: dzjian@126.com

收稿日期: 2022-10-20

训练,缩小网络输出和期望输出之间的误差。

输入、输出层为单层结构,而隐藏层可以是单层或多层。输入层、隐藏层、输出层之间的神经元都是相互连接的,为全连接。BP神经网络结构如图1所示。

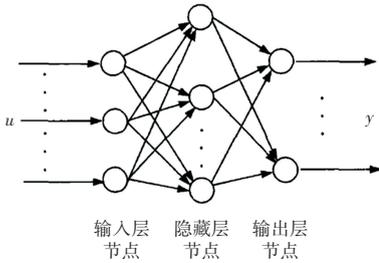


图1 BP神经网络结构图

Fig. 1 Structure of BP neural network

假设输入层节点数为 n , 隐藏层节点数为 l , 输出层节点数为 m , 输入层到隐藏层的权重为 ω_{ij} , 隐藏层到输出层的权重为 ω_{jk} , 输入层到隐藏层的阈值为 a_j , 隐藏层到输出层的阈值为 b_k , 学习速率为 η , 激励函数为 $g(x)$ 。其中,激励函数为 $g(x)$ 取 sigmoid 函数。形式如式(1)所示:

$$g(x) = \frac{1}{1 + e^{-x}} \quad (1)$$

隐藏层的输出如式(2)所示:

$$H_j = g\left(\sum_{i=1}^n \omega_{ij} x_i + a_j\right) \quad (2)$$

输出层的输出如式(3)所示:

$$O_k = \sum_{j=1}^l H_j \omega_{jk} + b_k \quad (3)$$

网络误差如式(4)所示:

$$e_k = Y_k - O_k \quad (4)$$

其中, Y_k 为期望输出。

输入层到隐藏层权值的更新公式如式(5)所示:

$$\omega_{ij} = \omega_{ij} + \eta H_j (1 - H_j) x_i \sum_{k=1}^m \omega_{jk} e_k \quad (5)$$

隐藏层到输出层权值的更新公式如式(6)所示:

$$\omega_{jk} = \omega_{jk} + \eta H_j e_k \quad (6)$$

隐藏层节点阈值的更新公式如式(7)所示:

$$a_j = a_j + \eta H_j (1 - H_j) \sum_{k=1}^m \omega_{jk} e_k \quad (7)$$

输出层节点阈值的更新公式如式(8)所示:

$$b_k = b_k + \eta e_k \quad (8)$$

由于BP神经网络的初始连接权值和阈值是随机选定,可能会使网络陷入局部极值,权值收敛到局部最小值,从而出现网络训练失败,模型的预测精度不高的结果。因此,本文采用遗传算法对BP神经网络进行优化,得到权值和阈值的最优解,使模型能够更高效的训练和更精准的预测。

1.2 遗传算法

(1)初始化种群。种群中的个体由BP神经网络中输入层到隐藏层的权值、隐藏层的阈值、隐藏层到输出层的权值和输出层的阈值编码而成。

(2)适应度函数。适应度函数用于表明BP神经网络中权值和阈值的优劣性,个体适应度值为训练数据预测误差绝对值之和。适应度函数的计算公式如式(9)所示:

$$F_i = k \left(\sum_{i=1}^n abs(y_i - o_i) \right) \quad (9)$$

式中: k 为系数, n 为神经网络输出节点数量, y_i 为神经网络第 i 个节点的期望输出, o_i 为神经网络第 i 个节点的预测输出。

(3)选择操作。选择操作从旧群体中以一定概率选择优良个体组成新的种群,以繁殖得到下一代个体,本文采用轮盘赌法,每个个体 i 被选择的概率 p_i 如式(10)所示:

$$p_i = \frac{F_i}{\sum_{j=1}^N F_j} \quad (10)$$

式中: N 为种群规模, F_i 为第 i 个个体的适应度值。

(4)交叉操作。交叉操作是指从种群中随机选择两个个体,通过两个染色体的交换组合,把父串的优秀特征遗传给子串,从而产生新的优秀个体,由于个体采用实数编码,所以交叉操作采用实数交叉法^[7]。第 j 个个体 S_j 和 k 个个体 S_k 在 i 位的交叉过程如式(11)所示:

$$\begin{cases} S_{j,i} = S_{j,i}(1 - b) + S_{k,i} \cdot b \\ S_{k,i} = S_{k,i}(1 - b) + S_{j,i} \cdot b \end{cases} \quad (11)$$

式中 b 为 $[0, 1]$ 区间内的随机数。

(5)变异操作。为了防止遗传算法在优化过程中陷入局部最优解,在搜索过程中,需要对个体进行变异。经过交叉操作后得到新的染色体后,随机选择染色体上的若干个基因,将这若干个基因的值进行随机修改,从而更新了染色体的基因,突破了搜索的限制,更有利于获取全局最优解^[8]。选择第 i 个

个体的第 j 个基因 a_{ij} 进行变异,操作过程如式(12)、式(13)所示:

$$a_{ij} = \begin{cases} a_{ij} + (a_{\max} - a_{ij}) \cdot f(s) & r > 0.5 \\ a_{ij} - (a_{ij} - a_{\min}) \cdot f(s) & r \leq 0.5 \end{cases} \quad (12)$$

$$f(s) = r \left(1 - \frac{s}{G_{\max}} \right) \quad (13)$$

式中: a_{\max} 、 a_{\min} 分别是个体 i 的最大值和最小值, s 是迭代次数, G_{\max} 是最大进化次数, r 为 $[0, 1]$ 区间内的随机数。

1.3 GA-BP 神经网络预测模型

GA-BP 神经网络预测模型由遗传算法(Genetic Algorithms, GA)优化部分和 BP 神经网络两部分组成。由于种群中的每个个体都包含了 BP 神经网络的初始权值和阈值,遗传算法部分的作用是优化 BP 神经网络的权值和阈值。通过计算 BP 神经网络的误差,得到个体适应度值。经过遗传算法的选择、交叉和变异操作找到最优适应度值的个体。对最优个体进行解码,得到权值和阈值,赋值给 BP 神经网络,再使用反向传播进行训练。

GA-BP 神经网络预测模型的执行过程如图 2 所示。

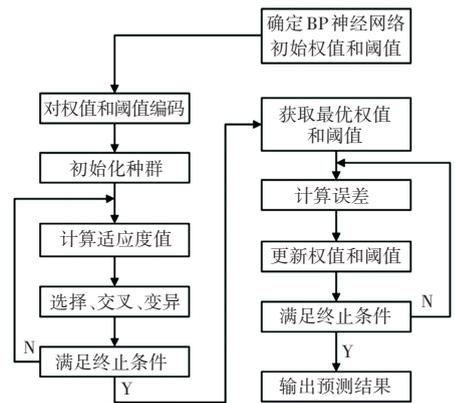


图 2 遗传算法优化 BP 神经网络流程图

Fig. 2 Flow chart of genetic algorithm to optimize BP neural network

2 实验与结果分析

2.1 样本数据采集

本文实验数据采集自连云港赣榆葡萄园第 6 号温室,选用温度、湿度、二氧化碳浓度、土壤氮含量、土壤磷含量和土壤钾含量作为样本数据。每 15 min 采集一次数据,共采集了 2 292 组样本数据。为了实验测试更方便,本文选用其中 2 000 组数据,并将前 80% 的样本数据作为训练样本,剩余的 20% 样本数据作为测试样本。部分样本数据见表 1。

表 1 部分样本数据

Tab. 1 Partial sample data

日期	时间	温度/°C	湿度/%	二氧化碳浓度/(ppm)	土壤氮含量/%	土壤磷含量/%	土壤钾含量/%
2022/8/21	18:40:38	28.2	87	361	25.2	26	70
2022/8/21	19:19:41	27.8	86	359	25.2	25	70
2022/8/21	19:34:55	27.8	86	360	25.1	26	70
2022/8/21	19:50:10	27.6	86	359	25.2	25	70
2022/8/21	20:05:24	27.6	86	358	25.2	25	70
2022/8/21	20:20:39	27.5	86	358	25.2	25	68

2.2 模型参数设定

2.2.1 BP 神经网络结构

根据所获得的样本数据,将输入层节点设定为 5,即 5 个特征,分别为湿度、二氧化碳浓度、土壤氮含量、土壤磷含量和土壤钾含量数据;输出层节点为 1 个,特征为温度数据;通过试凑法确定隐藏层节点为 7 个。因此,BP 神经网络的结构为 5-7-1。

2.2.2 遗传算法参数设定

由于过多的迭代次数会影响模型的训练效率,且适应度曲线在迭代 50 次后的变化幅度不大,因此本实验将进化迭代次数设定为 50 次,种群规模为 30,交叉概率为 0.3,变异概率为 0.1。图 3 为遗传算法的适应度曲线。

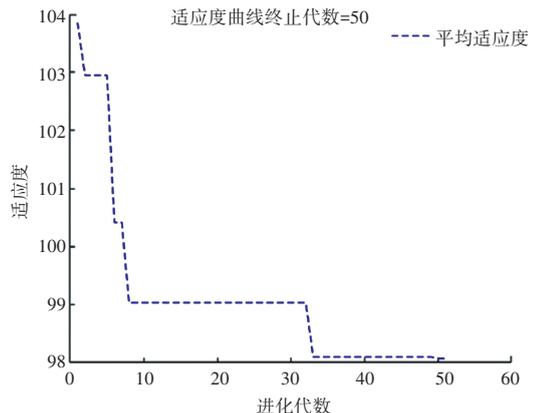


图 3 遗传算法适应度曲线

Fig. 3 Genetic algorithm fitness curve

2.3 模型评价标准

为了评定预测模型的性能,本文以平均绝对误差(MAE)、均方误差(MSE)和平均绝对百分比误差(MAPE)作为评判预测模型性能优劣的标准。各评估误差指标的计算公式如式(14)~式(16)所示:

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (14)$$

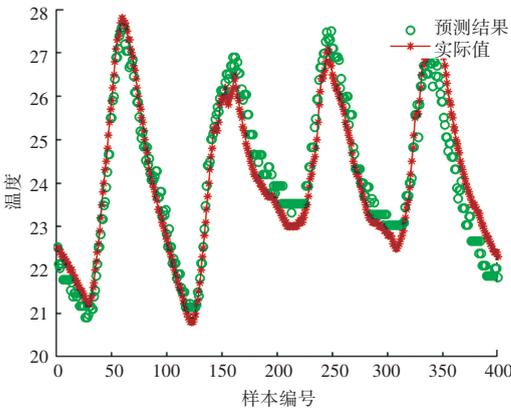
$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (15)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (16)$$

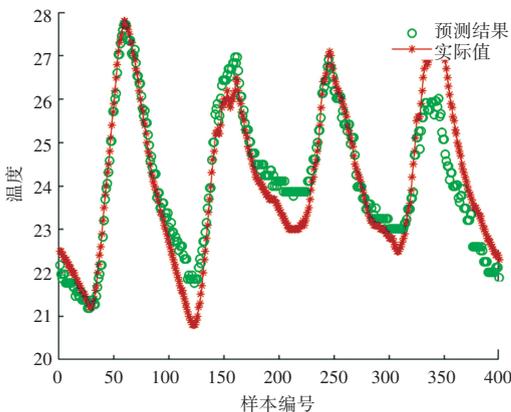
式中: \hat{y}_i 为模型的预测值, y_i 为真实值, n 为样本数。所得的值越小,则模型的性能越优异。

2.4 预测结果及分析

通过MATLAB软件对GA-BP神经网络预测模型和传统BP神经网络预测模型进行验证,得到的预测对比结果如图4所示。



(a) GA-BP网络预测输出



(b) BP网络预测输出

图4 GA-BP与BP训练效果对比图

Fig. 4 Comparison of GA-BP and BP training effects

由图4可知,GA-BP神经网络预测模型与传统BP神经网络预测模型相比,GA-BP的预测效果更优,预测结果更贴近实际值。

评价结果见表2。可以看出,GA-BP预测模型的各项误差指标均小于传统BP预测模型。实验证明,GA-BP神经网络预测模型具有更好的预测效果。

表2 模型的评价指标对比

Tab. 2 Comparison of evaluation indicators of the models

评价指标	GA-BP	BP
MAE	0.441	0.508
MSE	0.276	0.448
RMSE	0.525	0.669

3 结束语

本文以温室内湿度、二氧化碳浓度和土壤氮磷钾含量与温度有关的影响因子作为输入量,以温度作为输出量,通过遗传算法优化BP神经网络的权值和阈值,构建了GA-BP神经网络预测模型。实验证明,GA-BP神经网络预测模型能够更精准的进行温室内温度预测,对于温室管理有一定的参考价值。

参考文献

- [1] 王军伟. 苏北地区日光温室构型优化、室内温湿度分析及应用效果初探[D]. 南京:南京农业大学,2015.
- [2] 王克安,李絮花,吕晓惠,等. 不同结构日光温室温湿度变化规律及其对番茄产量和病害的影响[J]. 山东农业科学,2011,235(3):33-36.
- [3] 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):173-177,182.
- [4] 徐意,项美晶. 基于RBF神经网络的温室温度调控研究[J]. 农机化研究,2010,32(3):74-76.
- [5] 徐宇,冀荣华. 基于复数神经网络的智能温室温度预测研究[J]. 中国农机化学报,2019,40(4):174-178.
- [6] 王红君,史丽荣,赵辉,等. 基于贝叶斯正则化BP神经网络的日光温室温度预测模型[J]. 湖北农业科学,2015,54(17):4300-4303.
- [7] 曹雪丽. 配送中心订单分批处理随机服务系统模型与优化研究[D]. 北京:北京物资学院,2012.
- [8] 高基旭,王珺. 一种基于遗传算法的多边缘协同计算卸载方案[J]. 计算机科学,2021,48(1):72-80.