

植物工厂地源热泵系统热负荷 BP 神经网络预测及验证

石惠娴, 孟祥真, 游煜成, 张中华, 欧阳三川, 任亦可

(同济大学新农村发展研究院国家设施农业工程技术研究中心, 上海 200092)

摘要: 为提高水蓄能型地下水源热泵自然光植物工厂供热系统节能性, 供热系统必须能够很好地预测热负荷变化。针对自然光植物工厂热环境系统非线性特点, 利用具有很强非线性映射能力的 BP 神经网络 (back propagation, BP), 选取室内外空气干球温度、太阳辐射强度、室内相对湿度和绝对湿度、室内风速等输入参数, 确定算法步骤和评价指标, 构建神经网络模型预测植物工厂次日负荷。采用 Matlab 神经网络工具箱对崇明试验基地水蓄能型地源热泵自然光植物工厂的样本集进行训练, 训练后误差函数值为 0.002 999 94, 神经网络收敛。通过对热负荷预测值与实际值, 证明了神经网络预测热负荷值与实际值趋势一致, 基本误差在 $\pm 6\%$ 以内, 结果表明神经网络法可以用于植物工厂次日热负荷预测。通过热负荷预测能够更加科学地调整供热系统运行模式, 更好地匹配植物工厂需求热量与热泵的输出能量, 实现运行节能和降低供能成本的目的。

关键词: 热能; 神经网络; 算法; 热负荷预测; 植物工厂; 水蓄能; 地源热泵

doi: 10.11975/j.issn.1002-6819.2019.02.025

中图分类号: S215; TK124

文献标志码: A

文章编号: 1002-6819(2019)-02-0196-07

石惠娴, 孟祥真, 游煜成, 张中华, 欧阳三川, 任亦可. 植物工厂地源热泵系统热负荷 BP 神经网络预测及验证[J]. 农业工程学报, 2019, 35(2): 196—202. doi: 10.11975/j.issn.1002-6819.2019.02.025 <http://www.tcsae.org>

Shi Huixian, Meng Xiangzhen, You Yucheng, Zhang Zhonghua, Ouyang Sanchuan, Ren Yike. Prediction and verification on heating load of ground source heat pump heating system based on BP neural network for plant factory[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2019, 35(2): 196—202. (in Chinese with English abstract) doi: 10.11975/j.issn.1002-6819.2019.02.025 <http://www.tcsae.org>

0 引言

维持植物工厂内适宜运行温度对于作物生长非常重要, 但冬季巨大的供热能耗日益成为影响植物工厂经济运行的主要问题。在欧洲用于植物工厂冬季供热的成本大约为植物工厂总运行费用的 30%以上。在中国北纬 35°左右地区的植物工厂, 冬季供热耗能约占总生产成本的 30%~40%, 在北纬 40°左右的地区, 约占 40%~50%, 北纬 43°以上的地区约占 60%~70%^[1-2]。并且燃煤锅炉等传统加热设备污染环境^[3]。因此从源头上选择可再生能源供能植物工厂系统, 并跟踪预测植物工厂热负荷变化, 及时调控供热系统, 成为实现节能降耗的关键^[4-10]。但植物工厂热负荷预测的研究较少, 有学者通过天气预测系统和稳态热模型预测温室供热需求^[11-12]。

自然光型植物工厂热负荷变化具有动态性、时变性、多扰性和不确定性等^[13-16]。人工神经网络 (artificial neural networks, ANN) 模型非常适合对负荷变化进行预测^[17-19]。其中, 反向传播的 BP 神经网络模型具有很强的非线性映射能力^[20-22], 主要集中用于建筑负荷预测^[23], 国内外学者对于 BP 神经网络预测植物工厂热负荷研究较少。

Ahmad 等^[24]为了提高负荷预测精度, 通过 6 种模型

来预测水源热泵供暖和制冷负荷需求, 得到 BP 神经网络模型预测 7 d 能源需求的平均绝对误差为 2.592%。Castañeda-Miranda 等^[25]通过 BP 神经网络算法设计和实现在墨西哥中部地区某温室的智能控制, 在夏季和冬季预测的准确率分别达到 0.954 9 和 0.959 0。Taki 等^[26]通过运用多层感知器神经网络预测位于伊朗西北部某温室内部温度, 证明此方法适用于估计温室中的实际数据和预测能量变化。张经博等^[27]通过利用改进的遗传算法优化 BP 神经网络初始权值和网络结构, 对建筑供暖系统热负荷进行短期预测。

考虑到植物工厂热负荷与建筑热负荷都具有非线性特点, 采用 BP 人工神经网络模型对植物工厂次日热负荷进行预测^[28-29], 以期及时调整供热系统的供热模式和供能量, 及时降低热泵不必要的运行时间, 或者避免供热量不足对作物产量和品质的影响, 以促进植物工厂供热系统节能控制优化。

1 水蓄能型地下水源热泵植物工厂供热系统

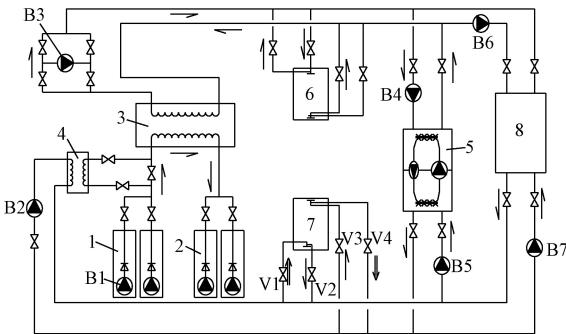
自然光植物工厂位于上海市崇明区国家设施农业工程技术研究中心基地。其中自然光植物工厂外围护结构为 5 mm 厚的单层浮法玻璃, 总面积为 21 180 m², 分为 A, B, C 3 区, 其中 A 区的 A2, A4, A6, A7, A8, A9, A10 共 7 栋温室采用水蓄能型地下水源热泵空调系统供能, 其供热面积为 5 880 m²。基地采用的地源热泵机组为 Carrier 公司生产的 30HXC200-PH3opt150 型热泵, 其最大制热量可达 800 kW。水蓄能型地下水源热泵植物工厂

收稿日期: 2018-08-11 修订日期: 2018-11-09

基金项目: 国家高技术研究发展计划 (863 计划) 资助项目
(2013AA103006-02)

作者简介: 石惠娴, 副教授, 博士, 主要从事可再生能源应用于农业设施领域理论和实践研究。Email: huixian_shi@tongji.edu.cn

供热系统如图 1 所示, 主要由地下水换热系统、蓄能系统、供能系统等组成。



1.热水井 2.冷水井 3.低温板式换热器 4.高温板式换热器 5.热泵机组
6.蓄冷水箱 7.蓄热水箱 8.植物工厂
1.Hot water well 2.Cold water well 3.Low temperature plate heat exchanger
4.High temperature plate heat exchanger 5.Heat pump unit 6.Cool storage tank
7.Hot storage tank 8.Plant factory
注: B1 为潜水泵, B2-B7 为循环水泵, V1-V4 为电磁阀。
Note: B1 is submersible pump; B2-B7 are circulating water pumps; V1-V4 are electromagnetic valves.

图 1 水蓄能型地源热泵植物工厂供热系统

Fig.1 Water storage ground source heat pump heating system of plant factory

地源热泵机组运行模式应随不同热负荷变化而发生变化。在冬季, 当热泵机组供热量大于植物工厂热负荷, 机组边储热边供热, 热水井中的潜水泵抽取地下水依次通过除砂器、水源侧电子除垢仪等水处理设备进入低温板式换热器水源侧, 经过低温板式换热器提取热量后回灌到冷水井, 蓄冷水箱下侧的冷水进入低温板式换热器吸收地下水的热量后回到蓄冷水箱的上侧。升温的蓄冷水箱上侧冷水进入热泵蒸发器侧, 经蒸发器提取热量后返回蓄冷水箱下侧, 蒸发器吸收的热量经冷凝器释放, 冷凝器出水管温度升高, 部分进入空气处理机组 (air treatment unit, ATU) 的热水进水管对植物工厂供热, 剩余进入蓄热水箱上侧进行储热, 此时在蓄热水箱处电磁阀 V2 和 V3 打开, 电磁阀 V1 和 V4 关闭。当热泵机组供热量和蓄热水箱供热量都小于植物工厂热负荷时, 蓄热水箱和热泵机组联合供热, 机组供热流程和机组边储热边供热模式中相同, 热泵停止对蓄热水箱蓄热, 此时在蓄热水箱处电磁阀 V1 和 V4 打开, 电磁阀 V2 和 V3 关闭, 抽取蓄热水箱上侧热水进入空气处理机组的热水进水管, 从而对植物工厂供热。

当供热系统需求侧——植物工厂内热负荷不同, 供热系统会采用不同的运行模式进行供能。根据气象数据及植物工厂环境实时运行数据提前对供热系统需求侧热负荷进行预测, 根据需求提前做出供能策略调整, 能够最大限度地实现系统供能节能。

2 植物工厂热负荷 BP 神经网络预测算法流程及参数确定

2.1 BP 神经网络算法流程

BP 神经网络算法是由人工神经元按照某种模式连接而构成的, 有输入层、隐含层和输出层 3 个层次。确定

BP 神经网络算法流程, 首先初始化各层权系数和阈值, 随机选取样本值提供给网络, 计算隐含层和输出层的输出值。然后计算输出层的一般化误差, 将误差反向传播至隐含层, 计算隐含层的一般化误差, 调整隐含层和输出层的权系数和阈值。重新选取样本值输入网络, 通过重复以上算法流程, 直到网络全局误差函数小于预先设定的一个极小值, 即网络收敛。当误差函数大于预先设定值, 则网络无法收敛。

2.2 输入参数及输出变量的选择

为了使热负荷预测既可以满足植物工厂的供热需求同时又能兼顾节能的要求, 需要对 BP 神经网络的输入变量、输出变量进行合理选择。

2.2.1 输入参数的选择

输入参数样本应具有完整的大气温度、大气湿度以及太阳辐射强度, 这三者是影响地源热泵系统负荷的最重要因素。因此输入参数包括室内外空气干球温度、太阳辐射强度、室内相对湿度、室内绝对湿度、室内风速等。对于植物工厂而言, 次日天气状况对热负荷影响很大。实践证明, 当冬季晴天时, 自然光植物工厂的供热负荷很小, 有时甚至不需要供热。因此, 在对供热负荷进行预测时需要将天气类型分为晴、多云、阴、雨 4 类。本文以冬季阴天极端天气条件下为例, 对供热负荷进行预测。

对于供热系统而言, 只需要知道室内供热负荷总情况, 不需要对其划分为人员负荷、设备负荷和其他负荷等。因此选择前一天的逐时热负荷参数作为输入参数。

2.2.2 输出变量的选择

需要利用前一天的逐时参数来预测植物工厂第二天的逐时热负荷, 因此对地源热泵系统热负荷预测的输出变量确定为第二天逐时植物工厂热负荷值。

2.3 隐含层数及节点数确定

2.3.1 隐含层数确定

隐含层是连接神经网络输入与输出的“枢纽”, 是一个“暗箱”, 真正的网络模型就是由这个“暗箱”来决定的。目前, 对隐含层的选择没有固定的理论依据。Kolmogorov 定理表明: 采用一层中间层, 即 3 层神经网络已经能够解决地源热泵系统负荷预测的问题^[30]。采用 3 层以上的神经网络会使误差反向传播的计算过程变得非常复杂, 训练时间急剧增加, 而且局部最小误差也会增加, 最终误差函数也可能无法收敛, 网络的连接权系数矩阵也很难调整到最小误差处。因此, 确定采用的隐含层数为 1。

2.3.2 隐含节点数确定

找到最优的隐含层节点数对网络的结构非常关键。研究 BP 神经网络用于地源热泵系统负荷预测, 是运用函数拟合功能, 通过训练证实选用式 (1) 效果更好。经多次试验选用 $a=10$ 时, 效果比较好, 同时: $n=9$, $m=1$, 隐含节点数 $n_1=13$ 。

$$n_1 = \sqrt{n+m} + a \quad (1)$$

式中 n 为输入神经元数; n_1 为隐藏层节点数; m 为输出神经元数; a 为 0 至 10 之间的常数。

2.4 BP 神经网络算法各项参数确定

2.4.1 BP 神经网络初始权值确定

选择权系数初始值是否得当直接影响到 BP 神经网络学习是否收敛及是否陷入局部最小情况, 对负荷预测的准确性至关重要。调整输出层和隐含层的权系数公式分别见式(2)、(3)。

$$v_{jt}(N+1) = v_{jt}(N) + \alpha \cdot e_t \cdot c_j \quad (2)$$

$$w_{ij}(N+1) = w_{ij}(N) + \beta \cdot f_j \cdot \alpha_i \quad (3)$$

式中 $0 < \alpha < 1$; $0 < \beta < 1$; v_{jt} 为从输入向量的第 j 个分量到输出向量第 t ($1, \dots, q$) 个分量的权重; N 为训练次数; e_t 为输出层的一般化误差; c_j 为隐含层节点 j 的输出值; w_{ij} 为从输入向量的第 i ($1, \dots, n$) 个分量到输出向量第 j ($1, \dots, p$) 个分量的权重; f_j 为隐含层的一般化误差。

由式(2)、(3)可知, 初始权值如果能使每个神经元的状态值都趋近于零是最理想的。但是如果全都等于零或某同一个数, 系统将不可能继续进行训练。初始值取 $(-0.3, 0.3)$ 之间的随机数一般情况下能很好的保证网络训练的稳定性, 且初始值在 $(-0.3, 0.3)$ 之间的 BP 神经网络训练速度明显高于 $(-1, 1)$ 之间的 BP 神经网络。因此选用初始连接权值 $(-0.3, 0.3)$, 网络的训练性能比较稳定, 不需对初始连接权进行修正。

2.4.2 学习率和动量因子确定

学习率直接影响连接权矩阵变化的范围和速率。通过参考文献以及反复实践^[31-32], 选取学习率为 $0.25 \sim 0.30$, 在此范围内神经网络的收敛概率是最大的。为了避免网络连接权系数矩阵的修正陷入局部能量最小的困境, 采用动量因子法对其进行改进^[33]。取初始动量因子 $m_c=0.9$, 不再对其进行调整, 即惯性修正项在每次连接权系数矩阵修正时所起的作用的比重是相等的。

2.5 BP 神经网络拓扑结构确定

根据以上针对植物工厂地源热泵供热系统热负荷预测特点的分析, 建立植物工厂地源热泵系统热负荷 BP 神经网络预测拓扑结构和参数选择, 如图 2 所示。

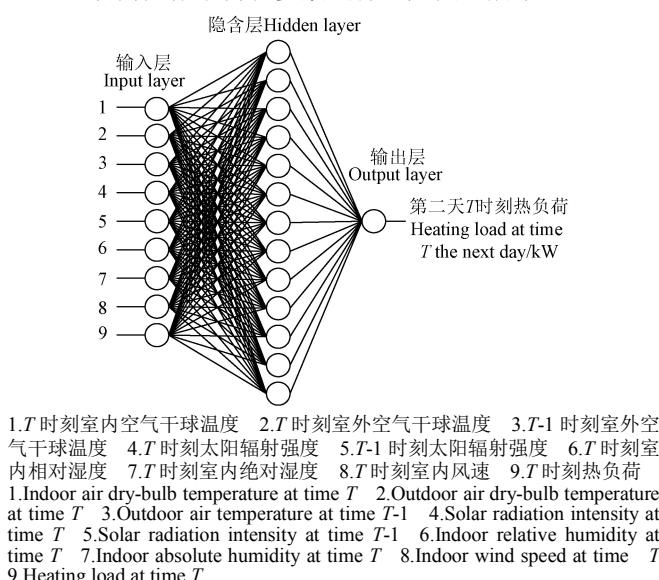


图 2 植物工厂地源热泵供热系统热负荷 BP 神经网络预测拓扑模型结构

Fig.2 BP neural network topology model structure for heating load of ground source heat pump heating system of plant factory

图 2 中 BP 神经网络为全互连连接网络, 每个处理单元的输出都将与下一层中的每个处理单元相连, 但同层之间的处理单元不形成连接。根据已确定的输入层参数、隐含层层数、节点数和输出层参数, 输入层神经元数为 9, 隐含层的神经元数为 13, 需要通过不断地调试调整, 确定输出层神经元数为 1, 进行第二天 T 时刻植物工厂预测热负荷。

3 植物工厂次日热负荷 BP 神经网络预测实现过程

3.1 BP 神经网络样本集的选取

BP 神经网络需要已知负荷值作为原始目标值来训练网络。试验数据样本值获取来自崇明水蓄能型地下水源热泵供能的自然光植物工厂。植物工厂中地源热泵系统数据采集匹配各种感测器实时监控参数, 包括室外气象站含有风速风向和气温等计量计、测量全天日照量的辐射量计、相对湿度计等, 能够准确提供模型所需参数。

崇明自然光植物工厂至 2018 年 4 月已成功运行 5 个冬天, 通过筛选和对比, 选取 2017 年冬季 1 月 19 日至 1 月 29 典型的逐时负荷值(间接测量参数)和对应的气象参数(直接测量参数)作为样本集, 其中选取 1 月 19 日至 1 月 28 日为训练集, 1 月 29 日为验证集。植物工厂内外各气象参数和所需设备参数随时间变化曲线见图 3 所示。

植物工厂冬季逐时供热负荷见式(4)。根据冬季逐时供热负荷公式, 由图 3b ATU 供回水温差和 ATU 热水流量数据, 计算得出 1 月 19 日至 28 日植物工厂内热负荷随时间的变化情况, 如图 4 所示。通过曲线可以看出受各天气因素影响, 植物工厂每天所需供热量呈现出明显的非线性变化。

$$Q_{\text{load}} = c_w m_w \Delta t_w = c_w \rho_w V_w \Delta t_w \quad (4)$$

式中 Q_{load} 为植物工厂冬季逐时供热负荷, kW ; c_w 为水比热容, $\text{kJ/kg}^{\circ}\text{C}$; Δt_w 为 ATU 供回水温差, $^{\circ}\text{C}$; ρ_w 为热水密度, kg/m^3 ; V_w 为 ATU 热水流量, m^3/s 。

3.2 BP 神经网络训练与仿真

对所选取的逐时热负荷和各气象参数进行 BP 神经网络训练, 利用 Matlab 神经网络工具箱特有的网络训练功能, 训练仿真步骤如下:

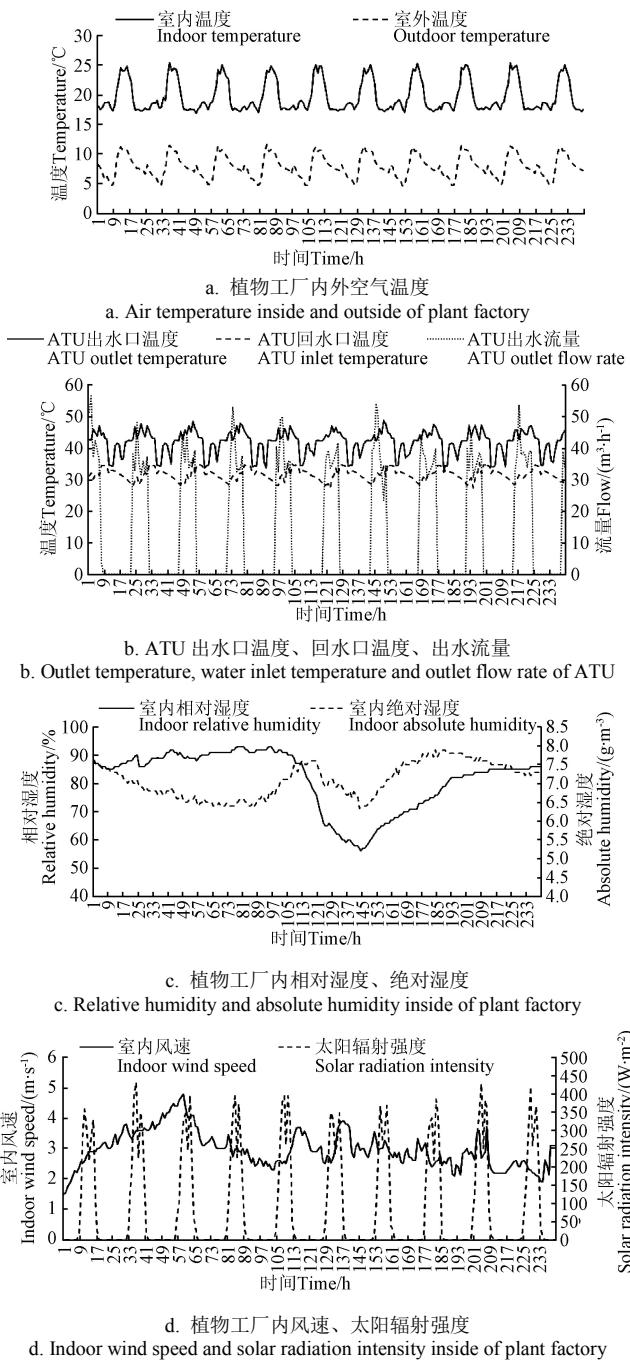
1) 将样本数据以矩阵的形式输入到均值 P 中, 形成 9 行 2 880 ($12 \times 24 \times 10$) 列的矩阵, 将输出以矩阵的形式输入到矩阵 T 中, 形成 1 行 2 880 列的矩阵;

2) 对输入矩阵进行归一化, 按式(5)、(6)进行数据预处理, 将数据处理成 0~1 之间的数值。

$$x_i = \frac{(x_{d,t} - x_{d,\min})}{(x_{d,\max} - x_{d,\min})} \quad (5)$$

$$y_i = \frac{(y_{d,t} - y_{d,\min})}{(y_{d,\max} - y_{d,\min})} \quad (6)$$

式中 x_i 为归一化神经网络的输入值; $x_{d,t}$ 为原始输入值; $x_{d,\min}$ 为原始输入值的最小值; $x_{d,\max}$ 为原始输入值中的最大值; y_i 为归一化后神经网络的目标值(教师值); $y_{d,t}$ 为表示原始目标值; $y_{d,\min}$ 为表示原始目标值中的最小值; $y_{d,\max}$ 为表示原始目标值中的最大值。



注: ATU, 空气处理机组。

Note: ATU, air treatment unit.

图3 植物工厂室内外环境和设备参数1月19日至28日随时间变化曲线
Fig.3 Indoor and outdoor environment and equipment parameters of plant factories change with time from January 19th to 28th

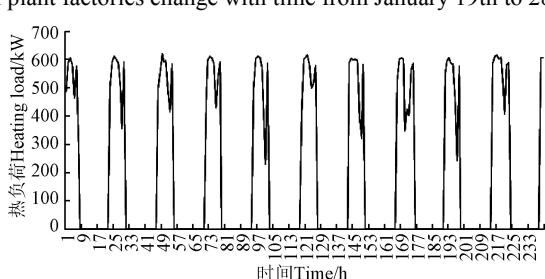


图4 植物工厂内1月19日至28日热负荷随时间变化曲线
Fig.4 Heating load as function of time from January 19th to 28th inside of plant factory

3) 新建一个神经网络, 其中隐含层神经元数为 13, 隐含层传递函数选用 sigmoid 函数; 输入层神经元数为 9, 输出函数选用 purelin 函数, 实现语句为

```
net=newff(minmax(p),[13,1],{'sigmoid','purelin'},'train
gdm');
```

4) 将输入层和隐含层权值、阈值设置为任意值:

```
inputweights=rand; inputbias=rand;
layerweights=rand; layerbias=rand;
```

5) 设置各项参数:

```
net.trainparam.show=50; % (后面内容为注释) 显示步长为 50
```

```
net.trainparam.Ir=0.25; % 学习速度为 0.25
```

```
net.trainparam.mc=0.9; % 动量参数为 0.9
```

```
net.trainparam.epochs=500 00; % 最大训练次数为 500 00
```

```
net.trainparam.goal=0.003; % 训练目标允许误差为 0.003
```

6) 开始训练网络: [net,tr]=train(net,p,t); % 不断调试, 减小误差

7) 用训练好的网络进行仿真: A=sim(net,p); % 仿真输出为 A

8) 将仿真输出还原: Tg=A(max(T)-min(T))+min(T)

3.3 BP 神经网络收敛评价指标

BP 神经网络是否收敛的常用评价指标包括: 标准偏差 (δ)、偏差系数 (coefficient of variation, CV)、期望偏差百分数 (expected error percentage, EEP), 见式(7)至(9)。

$$\delta = \sqrt{\frac{\sum_{t=1}^n (y_{\text{pred},t} - y_{\text{data},t})^2}{n}} \quad (7)$$

$$CV = \sqrt{\frac{\sum_{t=1}^n (y_{\text{pred},t} - y_{\text{data},t})^2}{n}} \times 100 \quad (8)$$

$$EEP = \sqrt{\frac{\sum_{t=1}^n (y_{\text{pred},t} - y_{\text{data},t})^2}{n}} \times 100 \quad (9)$$

式中 $y_{\text{pred},t}$ 为节点 t 的预测值; $y_{\text{data},t}$ 为节点 t 的计算值; \bar{y}_{data} 为计算值的平均值; $y_{\text{data,max}}$ 为计算值的最大值。

4 植物工厂次日热负荷预测值与实际值验证

利用 3.2 程序语句通过 Matlab 神经网络工具箱建立、训练及仿真, 实际编程过程经过反复调试, 确定输入、输出层传递函数、神经元数、初始允许误差和学习率, 由于初始权值和阈值随机, 每次训练网络时间不等。图 5 为 9 个输入样本训练收敛图像, 随着训练次数的增加误差函数最终会无限趋近于一个值, 此误差值越小说明训练的结果越好。

通过图 5 曲线可以看出, 误差函数随着训练次数的增加逐渐减小, 在训练 112 28 次时达到 0.002 999 94, 小于设定的最大允许误差 0.003。说明神经网络是收敛的, 预测效果好。

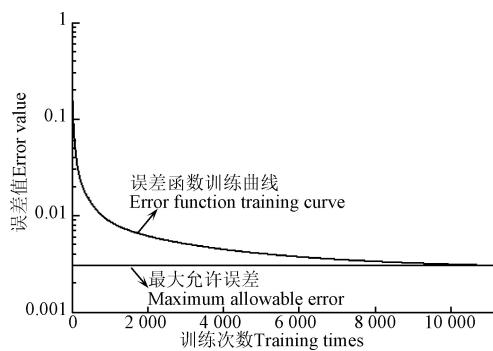


图 5 9 个输入样本训练收敛图像

Fig.5 Training convergence image of nine input samples

为了验证预测结果的准确性，在训练数据集中随机选取 27 日预测数据与实际热负荷进行比较，以确保预测结果在模型训练的时间范围内是准确的，再进一步拓展验证验证集 29 日预测结果的准确性，从两方面充分说明预测结果的准确性。1月 27 日和 29 日的热负荷预测值与实际值比较，结果如图 6 所示，运用 BP 神经网络预测热负荷值与实际值趋势一致，误差基本控制在±6%以内。由式(7)~(9)计算可知，负荷预测值与实际值的标准偏差 $\delta=21.61$ ，偏差系数 $CV=7.45\%$ ，期望偏差百分数 $EEP=3.47\%$ ，预测效果是比较理想的。

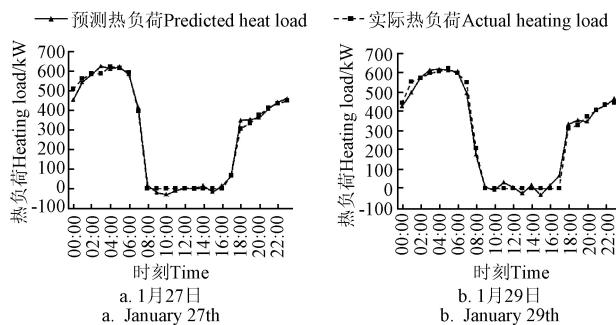


图 6 1 月 27 日和 1 月 29 日热负荷实际值与预测值比较

Fig.6 Comparison between actual value and predicted value of heating load from January 26th to 29th

图 3b 中 ATU 的出水流量为 0 时说明空气处理机组不运行，植物工厂内空气处理机组不运行时，认为植物工厂内热负荷为 0。由图 6 可以看出：1月 27 日和 1 月 29 日植物工厂热负荷主要集中时段为 0:00—6:00，17:00—24:00，而这些时段大多处于上海地区谷电价时间区间内。植物工厂热泵与蓄热水箱的基本搭配原则为：在电价低谷时段热泵机组边储热边向植物工厂供热，电价高峰时段仅由蓄热水箱供热，电价平价阶段采用热泵和蓄热水箱联合供热模式或热泵机组边储热边供热模式。具体运行情况根据植物工厂实时的供热能耗以及蓄热水箱的蓄热量决定，通常情况下，供热期间热泵不需要满负荷运行，多余的热量存储在蓄热水箱中。由于蓄热水量会存在热量的损耗，通过 BP 神经网络对植物工厂地源热泵供热系统次日热负荷进行预测，可以对蓄热水箱的蓄热时间进行指导，根据次日热负荷的需求量和电价峰谷政策调控热泵的供热时间及输出功率。各气象参

数是动态变化的，本文以 1 h 为间隔来计算热负荷，预测热负荷值与实际值趋势一致，误差基本控制在±6%以内，如果想得到更加精确的预测结果，可以在后续的研究中进一步缩小计算的时间间隔，实现更加精准的调控。同时根据植物工厂所需热负荷对供能量和供能模式进行调整，能够更好的维持植物工厂环境的稳定性，提升作物的品质和产量。

5 结 论

针对植物工厂室内热环境的非线性特性，提出利用神经网络 BP 算法预测植物工厂热负荷；依据冬季典型运行工况试验数据，利用 BP 神经网络算法建立热负荷预测模型，并通过使用 Matlab 神经网络工具箱对数据进行训练，训练后误差函数的值为 0.002 999 94，小于设定值 0.003，说明神经网络收敛；最后通过热负荷预测值与实际值验证，误差基本控制在±6%以内，证明 BP 神经网络预测植物工厂热负荷的精确性，说明可以采用 BP 神经网络较为准确地预测植物工厂次日负荷，为蓄能型地下水源热泵供能植物工厂运行提供节能指导。

根据所预测的热负荷大小，调整运行策略和运行模式，尽量在谷电价时段热泵满负荷或者高负荷运行，盈余的输出热储存到蓄热水箱中。在平电价或峰电价中减少热泵的输出功率，使用蓄热水箱供能，从而降低运行成本。本文研究表明 BP 神经网络算法还适合应用于自然光植物工厂。

[参 考 文 献]

- [1] 方慧，杨其长，孙骥. 地源热泵在日光温室中的应用[J]. 西北农业学报, 2010, 19(4): 196—200.
Fang Hui, Yang Qichang, Sun Ji. Application of ground-source heat pump in greenhouse[J]. Acta Agriculturae Boreali-occidentalis Sinica, 2010, 19(4): 196—200. (in Chinese with English abstract)
- [2] Bargach M N, Dahman A S, Boukallouch M. A heating system using flat plate collectors to improve the inside greenhouse microclimate in Morocco[J]. Renewable Energy, 1999, 18(3): 367—381.
- [3] Taghavifar H, Mardani A. Prognostication of energy consumption and greenhouse gas (GHG) emissions analysis of apple production in West Azarbayjan of Iran using artificial neural network[J]. Journal of Cleaner Production, 2015, 87(1): 159—167.
- [4] 江亿，彭琛，燕达. 中国建筑节能的技术路线图[J]. 建设科技, 2012(17): 12—19.
- [5] Lim J H, Song J H, Song S Y. Development of operational guidelines for thermally activated building system according to heating and cooling load characteristics[J]. Applied Energy, 2014, 126(126): 123—135.
- [6] González P A, Zamarreño J M. Prediction of hourly energy consumption in buildings based on a feedback artificial neural network[J]. Energy & Buildings, 2005, 37(6): 595—601.
- [7] Briana S, Gerrit H, Ronaldw M C. Artificial neural networks for automated year-round temperature prediction[J].

- Computers and Electronics in Agriculture, 2009, 68(1): 52—61.
- [8] 石惠娴, 任亦可, 孟祥真, 等. 植物工厂水蓄能型地下水热泵供热系统节能运行特性研究[J]. 农业工程学报, 2018, 34(23): 157—163.
Shi Huixian, Ren Yike, Meng Xiangzhen, et al. Research on energy-saving operating characteristics of water storage groundwater source heat pump heating system in plant factory[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2018, 34(23): 157—163. (in Chinese with English abstract)
- [9] 沈兴来. 能源系统中电、气、冷、热负荷预测综述[J]. 电子世界, 2017(11): 28—28.
- [10] 张琦, 谢慕君, 贾其臣, 等. 热负荷预测中最有影响力参数测定[J]. 长春工业大学学报, 2017, 38(2): 150—154.
Zhang Qi, Xie Mujun, Jia Qichen, et al. Heat load forecasting input variable selection[J]. Journal of Changchun University of Technology, 2017, 38(2): 150—154. (in Chinese with English abstract)
- [11] Vogler-Finck P J C, Bacher P, Madsen H. Online short-term forecast of greenhouse heat load using a weather forecast service[J]. Applied Energy, 2017, 205: 1298—1310.
- [12] Ahamed M S, Guo H, Tanino K. A quasi-steady state model for predicting the heating requirements of conventional greenhouses in cold regions[J]. Information Processing in Agriculture, 2017, 5(1): 33—46.
- [13] 程秀花, 毛罕平, 伍德林, 等. 玻璃温室自然通风热环境时空分布数值模拟[J]. 农业机械学报, 2009, 40(6): 179—183.
Cheng Xiuhua, Mao Hanping, Wu Delin, et al. Numerical simulation of thermal profiles in spatial and temporal field for natural ventilated glasshouse[J]. Transactions of the Chinese Society of Agricultural Machinery, 2009, 40(6): 179—183. (in Chinese with English abstract)
- [14] He Fen, Ma Chengwei. Modeling greenhouse air humidity by means of artificial neural network and principal component analysis[J]. Computers and Electronics in Agriculture, 2010, 71(1): 19—23.
- [15] Wang H, Sánchez-Molina J A, Li M, et al. Leaf area index estimation for a greenhouse transpiration model using external climate conditions based on genetics algorithms, back-propagation neural networks and nonlinear autoregressive exogenous models[J]. Agricultural Water Management, 2017, 183: 107—115.
- [16] 陈教料, 胥芳, 张立彬, 等. 基于 CFD 技术的玻璃温室加热环境数值模拟[J]. 农业机械学报, 2008, 39(8): 114—118.
Chen Jiaoliao, Xu Fang, Zhang Libin, et al. CFO-based Simulation of temperature distribution in glass greenhouse with forced-air heater[J]. Transactions of the Chinese Society of Agricultural Machinery, 2008, 39(8): 114—118. (in Chinese with English abstract)
- [17] Kumar R, Aggarwal R K, Sharma J D. Energy analysis of a building using artificial neural network: A review[J]. Energy & Buildings, 2013, 65(4): 352—358.
- [18] Panigrahi S, Behera H S. A hybrid ETS-ANN model for time series forecasting[J]. Engineering Applications of Artificial Intelligence, 2017, 66: 49—59.
- [19] Chou J S, Bui D K. Modeling heating and cooling loads by artificial intelligence for energy-efficient building design[J]. Energy and Buildings, 2014, 82: 437—446.
- [20] Meng Anbo, Ge Jiafei, Yin Hao, et al. Wind speed forecasting based on wavelet packet decomposition and artificial neural networks trained by crisscross optimization algorithm[J]. Energy Conversion & Management, 2016, 114: 75—88.
- [21] Guo Zhenhai, Wu Jie, Lu Haiyan, et al. A case study on a hybrid wind speed forecasting method using BP neural network[J]. Knowledge-Based Systems, 2011, 24(7): 1048—1056.
- [22] 代爱妮, 周晓光, 刘相东, 等. 基于 BP 神经网络的旁热式辐射与对流粮食干燥过程模型[J]. 农业机械学报, 2017, 48(3): 351—360.
Dai Aini, Zhou Xiaoguang, Liu Xiangdong, et al. Model of drying process for combined side-heat infrared radiation and convection grain dryer based on BP neural network[J]. Transactions of the Chinese Society of Agricultural Machinery, 2017, 48(3): 351—360. (in Chinese with English abstract)
- [23] Wang Lan, Lee E W M, Yuen R K K. Novel dynamic forecasting model for building cooling loads combining an artificial neural network and an ensemble approach[J]. Applied Energy, 2018, 228: 1740—1753.
- [24] Ahmad T, Chen Huanxin. Short and medium-term forecasting of cooling and heating load demand in building environment with data-mining based approaches[J]. Energy & Buildings, 2018, 166: 460—476.
- [25] Castaeda-Miranda A, Castao V M. Smart frost control in greenhouses by neural networks models[J]. Computers & Electronics in Agriculture, 2017, 137: 102—114.
- [26] Taki M, Ajabshirchi Y, Ranjbar S F, et al. Heat transfer and MLP neural network models to predict inside environment variables and energy lost in a semi-solar greenhouse[J]. Energy & Buildings, 2016, 110: 314—329.
- [27] 张经博, 郭凌, 王朝霞, 等. 基于遗传算法优化 BP 神经网络的供暖系统热负荷预测模型[J]. 兵器装备工程学报, 2014, 35(4): 152—156.
Zhang Jingbo, Guo Ling, Wang Chaoxia, et al. Thermal load forecasting model of heating system based on genetic algorithm optimization BP neural network[J]. Journal of Ordnance Equipment Engineering, 2014, 35(4): 152—156. (in Chinese with English abstract)
- [28] 陈晓冉. 水蓄冷空调系统负荷预测方法的研究[D]. 天津: 天津大学, 2009.
Chen Xiaoran. Research of Cooling Load Prediction Method in Water Storage Air Conditioning System[D]. Tianjin: Tianjin University, 2009. (in Chinese with English abstract)
- [29] Xie Ling. The heat load prediction model based on BP neural network-markov model[J]. Procedia Computer Science, 2017, 107: 296—300.

- [30] 孙敬. 基于遗传神经网络的空调房间送风量预测研究[D]. 南京: 南京工业大学, 2006.
- Sun Jing. Study on Air Supply Volume Prediction of Air-Condition Room based on GA-ANN[D]. Nanjing: Nanjing University of Technology, 2006. (in Chinese with English abstract)
- [31] Ren Guanghua, Cao Yuting, Wen Shiping, et al. A modified elman neural network with a new learning rate scheme[J]. Neurocomputing, 2018, 286:11–18.
- [32] Takase T, Oyama S, Kurihara M. Effective neural network training with adaptive learning rate based on training loss[J]. Neural Networks, 2018, DOI: 10.1016/j.neunet.2018.01.016.
- [33] 田野. 基于动量因子的神经网络群电流负荷预测模型[J]. 电力系统保护与控制, 2016, 44(17): 31–38.
- Tian Ye. A forecasting model for current load of neural network group based upon momentum factor[J]. Power System Protection and Control, 2016, 44(17): 31–38. (in Chinese with English abstract)

Prediction and verification on heating load of ground source heat pump heating system based on BP neural network for plant factory

Shi Huixian, Meng Xiangzhen, You Yucheng, Zhang Zhonghua, Ouyang Sanchuan, Ren Yike

(New Rural Development Institute of Tongji University, National Engineering Research Center of Protected Agriculture, Shanghai 200092, China)

Abstract: It is important for crop growth to maintain suitable temperature in plant factory, however large heating energy consumption has been proved to be an obstacle that restricts its development. In Europe, the cost of heating accounts for about 30% of the total operation cost during the winter, but in the north of latitude 43° of China, the proportion reaches 60% to 70%. The traditional heating equipment such as coal-fired boilers has an energy utilization rate of only 40% to 50%. So it is very necessary to apply renewable energy to plant factory. Regulating heating modes by tracking and predicting the heating load changes in plant factory is the key to achieve energy saving. Because of the high energy consumption in winter, accurate heating load prediction can improve the energy saving effect of groundwater source heat pump with water energy storage. Changes of heating load in natural light plant factory are dynamic, time-varying, highly turbulent and uncertain. Artificial neural networks is ideal for predicting load changes, especially BP (back propagation) neural network has strong nonlinear mapping ability, which is generally used by many scholars for building heating load prediction, but rarely in plant factory. Given that heating load of both plant factory and building have nonlinear characteristics, we used BP neural network to predict the next day's heating load of plant factory to promote energy-saving control optimization. The BP neural network model has three levels: input layer, hidden layer and output layer. Input parameters include indoor and outdoor air temperature, solar radiation intensity, indoor relative humidity, indoor absolute humidity, indoor wind speed, etc. For plant factory, the next day's weather condition has a significant impact on the heating load. The output variable is determined as the next day's hourly glass greenhouse load value. The number of neurons in the input layer was 9, the number of neurons in the hidden layer was 13, the selected layer number of hidden layers was 1, the learning rate was 0.25 to 0.30, and the initial momentum factor was 0.9. Common evaluation indicators used to determine whether the neural network converges, included standard deviation, coefficient of variation, and expected error percentage. After algorithm steps being determined, the next day's heating load was predicted based on reasonable algorithmic procedures and steps. Experimental data in the paper was obtained from a natural light plant factory powered by groundwater source heat pump with water energy storage system in Chongming National Facility Agricultural Engineering Technology Research Center. Using the neural network toolbox of Matlab to train and simulate the model to process the experimental data from January 19th to 28th, the value of the error function was 0.002 999 94 which was less than the set value of 0.003, so the neural network was convergent. Prediction effect can be drawn by comparison between the actual surveyed value and the predicted value of the heating load. The main heating load was concentrated on 0:00-6:00 and 17:00-24:00 o'clock in the plant factory, and most of these periods were in the cheap electricity price period of Shanghai. Adjusting the operating strategy and operating mode of the energy supply system were based on the predicted heating load, the heat pump operated at full load or high load during the period of cheap electricity prices, and excess heat was stored in the hot storage tank. The hot storage tank provided heat to plant factory during the period of moderate and expensive electricity price. In this case, the energy cost would be reduced. Therefore, it was significantly economical to control start-stop time of the groundwater source heat pump with water energy storage for plant factory heating project. The error was controlled within $\pm 6\%$ basically between the actual value and the predicted value of the heating loads. Therefore, the results showed that the BP neural network was suitable for the next day's heating load prediction of plant factory.

Keywords: thermal energy; neural networks; algorithms; heating load prediction; plant factory; water energy storage; ground source heat pump