

2-23-2022

Energy Consumption Prediction for Air-conditioning System Based on Dynamic Temperature Control

Yan Bai

School of Science, Xi'an University of Architecture and Technology, Xi'an, 710055, China;
baiyan@xauat.edu.cn

Lulu Wu

School of Science, Xi'an University of Architecture and Technology, Xi'an, 710055, China;

Yin'e He

School of Science, Xi'an University of Architecture and Technology, Xi'an, 710055, China;

Yuying Wang

School of Science, Xi'an University of Architecture and Technology, Xi'an, 710055, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Energy Consumption Prediction for Air-conditioning System Based on Dynamic Temperature Control

Abstract

Abstract: To solve the problem of energy consumption prediction for air-conditioning systems implementing dynamic temperature control, *we designed a dynamic temperature control strategy and obtained a dataset on the hourly energy consumption of the air-conditioning system through EnergyPlus simulation. An improved particle swarm optimization-back propagation neural network (IPSO-BPNN) prediction model was built on the basis of energy consumption analysis by an integrated method. Clustering, classification, and correlation analysis methods were integrated to mine the energy consumption pattern of the air-conditioning system and determine the input variables for the prediction model. A nonlinear change strategy was designed to adjust the inertia weight and acceleration factor of the PSO algorithm and thereby improve the training speed and optimization effect.* An IPSO-BPNN model was constructed to predict the hourly energy consumption of the air-conditioning system. The results show that the convergence speed is significantly improved and that the average prediction accuracy is enhanced by 3.4%.

Keywords

dynamic temperature control, energy consumption simulation, integrated method, prediction model, IPSO-BPNN

Recommended Citation

Yan Bai, Lulu Wu, Yin'e He, Yuying Wang. Energy Consumption Prediction for Air-conditioning System Based on Dynamic Temperature Control[J]. Journal of System Simulation, 2022, 34(2): 366-375.

基于动态温度调控的空调系统能耗预测

白燕, 武璐璐, 贺引娥, 王玉英

(西安建筑科技大学 理学院, 陕西 西安 710055)

摘要: 针对动态温度调控的空调系统能耗预测问题, 设计了动态温度调控策略并通过 EnergyPlus 仿真得到空调系统逐时能耗数据集。在采用集成方法分析能耗的基础上, 建立改进 PSO 算法优化 BP 神经网络 (improved particle swarm optimization-back propagation neural network, IPSO-BPNN) 预测模型。集成聚类、分类和关联度分析方法挖掘空调系统能耗模式、确定预测模型的输入变量; 设计非线性变化策略调整 PSO 算法的惯性权重和加速度因子, 提高训练速度和优化效果; 建立 IPSO-BPNN 模型对空调系统逐时能耗进行预测。结果表明, 收敛速度明显提高, 且平均预测精度提高了 3.4%。

关键词: 动态温度调控; 能耗仿真; 集成方法; 预测模型; IPSO-BPNN

中图分类号: TU831; TP391.1

文献标志码: A

文章编号: 1004-731X(2022)02-0366-10

DOI: 10.16182/j.issn1004731x.joss.21-0741

Energy Consumption Prediction for Air-conditioning System Based on Dynamic Temperature Control

Bai Yan, Wu Lulu, He Yin'e, Wang Yuying

(School of Science, Xi'an University of Architecture and Technology, Xi'an, 710055, China)

Abstract: To solve the problem of energy consumption prediction for air-conditioning systems implementing dynamic temperature control, we designed a dynamic temperature control strategy and obtained a dataset on the hourly energy consumption of the air-conditioning system through EnergyPlus simulation. An improved particle swarm optimization-back propagation neural network (IPSO-BPNN) prediction model was built on the basis of energy consumption analysis by an integrated method. Clustering, classification, and correlation analysis methods were integrated to mine the energy consumption pattern of the air-conditioning system and determine the input variables for the prediction model. A nonlinear change strategy was designed to adjust the inertia weight and acceleration factor of the PSO algorithm and thereby improve the training speed and optimization effect. An IPSO-BPNN model was constructed to predict the hourly energy consumption of the air-conditioning system. The results show that the convergence speed is significantly improved and that the average prediction accuracy is enhanced by 3.4%.

Keywords: dynamic temperature control; energy consumption simulation; integrated method; prediction model; IPSO-BPNN

收稿日期: 2020-09-24

修回日期: 2020-11-13

基金项目: “十三五”国家重点研发计划项目(2018YFC0704500); 陕西省自然科学基金(2017JM5019); 陕西省建设厅科技发展计划项目(2019-K34); 陕西省教育科学规划课题(SGH18H111)

第一作者: 白燕(1979-), 女, 博士, 副教授, 研究方向为空调系统的优化与节能控制。E-mail: baiyan@xauat.edu.cn。

引言

舒适的室内热环境是人们身心健康和高效工作的前提。传统稳态热环境营造模式背后隐藏的健康与高能耗问题备受相关领域研究者的关注^[1]。目前, 动态热环境控制为室内热环境动态优化提供了有利途径, 可有效利用热环境的小幅规律性波动, 在满足热环境动态控制的同时实现舒适和健康的统一^[2-3]。自 20 世纪末, 清华大学赵荣义提出动态空调策略以来, 课题组从动态热环境人体反应试验及空调能耗等不同角度进行研究, 指出其健康、舒适和节能前景^[4-5]。清华大学朱颖心等通过大量的理论与实践研究, 发现合理的动态温度控制能够营造更加健康的室内热环境^[6]。刘争敏针对西安夏季典型工况工作日设计了一种动态温度调控策略, 实现了室内热环境能有效跟随室外温度的动态变化趋势^[7]。然而, 营造舒适的室内热环境是以一定的系统能耗为代价的。在建筑总能耗中, 暖通空调系统的能耗占 50% 以上^[8], 若能对其进行准确、及时的预测, 将对空调系统的节能与优化控制具有重要意义。

目前, 空调系统能耗预测的主要方法包括线性回归、支持向量机、决策树和人工神经网络^[9]。线性回归是一种统计分析方法, 建模速度快, 但不能解决非线性问题。支持向量机是一种人工智能方法, 可以向高维空间进行映射, 但其受缺失数据的影响较大^[10]。决策树是一种分类方法, 易于理解和实现, 但其预测结果会偏向于数值占比大的特征, 且不能很好的处理非线性数据^[11]。与上述方法相比, 人工神经网络具有强大的非线性拟合和逼近能力, 更适用于空调系统能耗预测。其中, BPNN 以其强大的非线性映射、容错能力得到广泛应用, 但是其也存在收敛速度慢和局部极小化等缺陷。有研究者使用 PSO 算法对 BPNN 的参数进行优化^[12], 提高了 BPNN 的预测精度和收敛速度。但由于 PSO 算法容易陷入局部最优, 导致预测结果的精度和收敛速度还是不能达到理

想需求。此外, 有效挖掘预测模型的输入、输出变量之间的相关性更有利于提高预测精度。

本文针对动态热环境控制的空调系统能耗预测问题, 设计了以 $|PMV| \leq 0.5$ 为指标的动态温度调控策略, 通过 EnergyPlus 仿真办公建筑变风量空调系统逐时能耗数据集。并集成聚类、分类和关联度分析方法挖掘空调系统能耗模式、确定系统能耗的关键影响因素作为预测模型的输入变量。在此基础上, 提出 IPSO 算法, 建立了 IPSO-BPNN 模型预测空调系统逐时能耗。实验结果表明, 所设计的 IPSO-BPNN 模型在收敛速度和预测精度方面均有提高。

1 动态温度调控的空调系统能耗模拟

1.1 动态温度调控策略及舒适性检验

在公共建筑暖通空调设计中, 用户的热舒适度作为重要指标被 ASHRAE 和 ISO 列为行业标准。经典舒适理论表明, 在自然环境和空调环境中, 人体可接受的热舒适温度范围分别是 $27^{\circ}\text{C} \sim 30^{\circ}\text{C}$ 和 $25^{\circ}\text{C} \sim 27^{\circ}\text{C}$ ^[13-14]。借鉴清华大学罗茂辉和山东大学李慧、段培永等学者在这方面的研究成果^[15-16], 本研究针对西安地区典型气象年夏季工况工作日设计动态温度调控策略, 如式(1)所示, 条件是室外最高温超过 27°C 的工作时段, 调控范围取 $26^{\circ}\text{C} \sim 28^{\circ}\text{C}$ 。经试验得知, 满足条件可进行动态温度调控的时间点共有 741 组。

$$g(t) = \begin{cases} t'_{\max} - \frac{t'_{\max} - t'_{\min}}{t_{\max} - t_{\min}} |t - t_{\min}|, & t \in (-\infty, t'_{\min}) \\ t, & t \in [t'_{\min}, t'_{\max}] \\ t'_{\min} + \frac{t'_{\max} - t'_{\min}}{t_{\max} - t_{\min}} |t - t_{\max}|, & t \in (t'_{\max}, +\infty) \end{cases} \quad (1)$$

式中: t'_{\max}, t'_{\min} 分别为温度调控范围的最大和最小值; t 是当前时刻室外温度; t_{\max}, t_{\min} 分别为工作时段室外温度的最大值和最小值, 单位为 $^{\circ}\text{C}$ 。

为检验动态温度调控策略下的人体热舒适度，本文采用 Fanger 提出的 PMV-PPD 指标对热舒适度进行评价^[17]。由于办公环境中人员大都静坐或仅做轻微活动，参考 ASHRAE 标准的相关参数设定值，做出以下假设：①人体对外做功取 0 W/m^2 ；②新陈代谢率取 62.5 W/m^2 ；③室内风速取 0.3 m/s ；④服装热阻取 0.5 clo ；⑤平均辐射温度取室内空气温度。

通过对室内逐时段的 PMV-PPD 进行计算检验，结果如图 1 所示。由图可知动态温度调控策略下的室内环境满足人体的热舒适性要求，即 $|PMV| \leq 0.5$ ， $PPD \leq 10\%$ 。




图1 PMV-PPD 模型检验结果
Fig. 1 PMV-PPD model test results

1.2 变风量空调系统能耗模拟

本文建立了西安地区某空调办公建筑模型，应用 EnergyPlus 软件模拟基于动态温度调控策略的变风量空调系统逐时能耗。该建筑共 12 层，窗墙比为 0.4，总面积为 $19\,296.12 \text{ m}^2$ ，表 1 为建筑的基本概况，图 2 为建筑的几何视图。空调系统中分别设置冷却塔 1 台、冷水机组 1 台、建筑各层均设置一套空气处理机组 (air handling unit, AHU)，空调末端采用变风量形式。空调系统的运行基于动态温度调控策略，运行时间为 08:00—20:00。系统详细信息如表 2 所示。室内负荷中的人员密度为 $4 \text{ m}^2/\text{人}$ 、照明功率为 11 W/m^2 和设备功率为 20 W/m^2 。文中的建筑设计参数均参考

DBJ T6161-60-2011 《公共建筑节能设计标准》^[18]。

表 1 建筑的基本概况
Table 1 Basic overview of building

城市	气候	体形系数	传热系数/(W/(m ² ·K))			
			外墙	外窗	内墙	屋顶 地板
西安	寒冷地区	0.120	0.442	2.353	1.630	0.191 0.191




图 2 建筑的几何视图
Fig. 2 Geometric view of building

表 2 建筑的变风量空调系统信息表
Table 2 Information table of VAV air conditioning system for building

项目	详情	
冷水机组	效率	5.0
	静压值/ Pa	600
风机	效率/%	70
	工作时间	工作日 08:00—20:00 基于动态温度调控策略运行,其余时间不运行
制冷温度	工作日 08:00—20:00 进行动态温度设定,其余时间不工作	
末端布置	每层有 9 个空调系统,即 9 个 AHU 和 9 个 ATU	

通过 EnergyPlus 模拟夏季工况 6~8 月的变风量空调系统逐时能耗，分别得到稳态和动态 2 种不同温度调控策略的空调系统逐时能耗，其总能耗分别为 $2.63 \times 10^4 \text{ kW}\cdot\text{h}$ 和 $2.42 \times 10^4 \text{ kW}\cdot\text{h}$ ，动态温度调控的空调系统可节约能耗 7.68%。图 3 为 2 种温度控制的空调逐时能耗对比图。由此可见，基于动态温度调控的空调系统既能满足人体热舒适又能实现系统节能。




图3 两种温度控制的空调逐时能耗对比图
Fig. 3 Hourly energy consumption comparison chart of two temperature-controlled air conditioners

2 空调系统能耗分析的集成方法设计

确定能耗的关键影响因素对准确建立能耗预测模型至关重要。本文集成聚类、分类和关联度分析 3 种方法对 6~8 月的 2 208 组逐时能耗数据挖掘空调系统的能耗模式。首先对能耗数据进行聚类分析得到能耗模式的划分; 其次添加能耗模式和时间类别属性进行决策树分类, 得到能耗模式依据时间类别判定的决策树; 最后运用关联度分析确定影响能耗的关键因素作为预测模型的输入变量。

2.1 能耗模式的划分

由于空调系统在不同时段的能耗量差异较大, 本文采用 K-Means 聚类算法对逐时能耗数据进行聚类, 划分出不同时刻所对应的能耗模式。聚类包括 5 个步骤:

step 1: 从能耗数据集中随机选取 a 个样本点作为初始聚类中心 $m_i (i = 1, 2, \dots, a)$, 本文采用手肘法判定最佳 a 值为 4, 误差平方和 (sum of the squared errors, SSE) 随聚类数的变化趋势如图 4 所示。

$$SSE = \sum_{i=1}^a \sum_{p_x \in C_i} |p_x - m_i|^2$$

step 2: 在第 j 次迭代中, 对任意一个样本点 $p_x (x = 1, 2, \dots, n)$ 求其到 a 个聚类中心的欧氏距离。

$$E_d(x, i) = \sqrt{(p_x - m_i)^2}$$

step 3: 将样本数据点划分至最近的聚类中心所在的簇中。

step 4: 采用式(2)计算样本点 p_x 的均值, 更新各簇 n_i 的聚类中心值。

$$m_i = \frac{1}{n_i} \sum_{x=1}^{n_i} p_x, i = 1, 2, \dots, a \quad (2)$$

step 5: 重复 step 2~step 4, 直至各簇的聚类中心不再变化。




图4 SSE随聚类数的变化趋势
Fig. 4 Change trend of SSE with cluster number

聚类分析结果如图 5 所示, 分别对聚类结果的 4 类数据簇添加零能耗、低能耗、中能耗和高能耗 4 种模式标签。




图5 能耗的聚类结果图
Fig. 5 Clustering result graph of energy consumption

2.2 能耗模式判别决策树的构建

在划分空调系统存在的能耗模式之后，为便于分析能耗模式的判别条件，选取是否工作日、是否加班时间、是否上班时间作为能耗模式的特征属性对不同的能耗模式进行分类。添加特征属性的部分能耗数据如表 3 所示。

表 3 添加特征属性的部分能耗数据
Table 3 Partial energy consumption data with added feature attributes

日期	时刻	时间类别			能耗/ (kW·h)	能耗模 式标签
		工作日	加班	上班		
06.01	1:00	否	否	否	0	零能耗
06.01	2:00	否	否	否	0	零能耗
06.01	3:00	否	否	否	0	零能耗
					
07.24	8:00	是	否	是	32.27	中能耗
07.24	9:00	是	否	是	38.72	高能耗
07.24	10:00	是	否	是	34.19	中能耗
					
08.31	18:00	是	否	是	32.87	中能耗
08.31	19:00	是	是	否	23.31	低能耗
08.31	20:00	是	是	否	23.46	低能耗

随机选取数据集的 80% 作为训练集，剩余 20% 作为测试集，采用分类回归决策树算法 (classification and regression tree, CART) 构建能耗模式判别决策树。包括以下 3 个步骤：

step 1: 计算数据集 S 中特征属性的基尼系数

$$Gini(S, A) = \frac{|S_1|}{|S|} Gini(S_1) + \frac{|S_2|}{|S|} Gini(S_2)$$

式中：A 是 S 的任意一个特征属性；S₁ 和 S₂ 是集合 S 被 A 分裂的子集；|S|、|S₁| 和 |S₂| 分别是 S、S₁ 和 S₂ 的样本个数。

step 2: 选择基尼系数最大的特征属性进行划分，基尼系数最小的特征属性及其对应的切分点作为最优特征与最优切分点。

step 3: 对当前生成的 2 个子结点重复 step 1 和 step 2，直至所有的特征属性分析完毕，生成决策树。

通过计算基尼系数得知是否工作日作为决策树的根节点，“是否加班时间”和“是否上班时间”分别作为内部结点，能耗模式为叶子节点，建立的能耗模式判别决策树如图 6 所示。从决策树中可以看出，4 种能耗模式可根据不同时间类别属性进行分类。

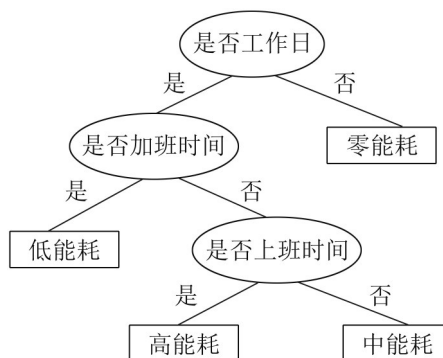


图 6 能耗模式判别决策树
Fig. 6 Energy consumption mode discrimination decision tree

2.3 能耗影响因素的确定

空调系统能耗受到的影响因素包括外扰和内扰因素，外扰因素包括室内外空气温度、相对湿度、太阳辐照度、风速等，内扰因素包括室内照明、设备和人员负荷密度等^[9]。本文选用 R 时刻室外温度、R-1 时刻室外温度、R-1 时刻室外相对湿度、R-1 时刻室外风速、R-1 时刻太阳直射辐射、R-1 时刻太阳散射辐射、R 时刻空调温度设定值和 R 时刻空调系统能耗模式为关联因子，应用灰色关联度分析判断 R 时刻能耗的重要影响因素。基于上述对 R 时刻能耗分类的结果，由于零能耗模式可根据分类规则直接估计出，因此从 2 208 组数据集中将所对应的样本序列剔除，选用剔除后的 741 组样本计算 R 时刻能耗数据与其关联因子的关联度。计算包括 3 个步骤：

step 1: 对逐时能耗数列 X₀ 和各关联因子数列 X_k 进行均值化处理。

step 2: 计算关联系数 L_{0k}(θ)，分辨率 ρ 取 0.5。

$$L_{ok}(\theta) = \frac{\min_k \min_{\theta} |x_0(\theta) - x_k(\theta)| + \rho \max_k \max_{\theta} |x_0(\theta) - x_k(\theta)|}{|x_0(\theta) - x_k(\theta)| + \rho \max_k \max_{\theta} |x_0(\theta) - x_k(\theta)|}$$

step 3: 计算关联度 r_{ok} , b 为样本个数。 r_{ok} 值在 0~1 之间, 越接近 1 说明关联性越大。

$$r_{ok} = \frac{1}{b} \sum_{\theta=1}^b L_{ok}(\theta)$$

关联度计算结果如表 4 所示, 本文确定关联因子高于 0.6 的 8 项影响因素作为预测模型的输入项。

表 4 各影响因子与 R 时刻空调能耗的关联度
Table 4 Correlation degree between each influence factor and air conditioning energy consumption at time R

变量	关联度
R 时刻室外温度	0.923 21
$R-1$ 时刻室外温度	0.917 59
$R-1$ 时刻室外相对湿度	0.893 89
$R-1$ 时刻室外风速	0.803 01
$R-1$ 时刻太阳直射辐射	0.648 06
$R-1$ 时刻太阳散射辐射	0.765 04
R 时刻空调温度设定值	0.936 18
R 时刻空调系统能耗模式	0.897 12

3 能耗预测模型的建立

目前, 线性回归、支持向量机和决策树预测算法会因缺失数据等原因, 导致不能有效解决非线性问题, 并出现预测结果偏向于数值占比大的特征^[9]。与上述方法相比, BPNN 具有强大的非线性映射和容错能力等优势, 同时也存在收敛速度慢和局部极小化等缺陷。为了克服 BPNN 模型收敛速度慢、易陷入局部最优等缺点, 本文引入 PSO 算法, 采用非线性变化策略调整 PSO 算法的惯性权重和加速度因子, 设计了 IPSO 算法, 从而提高了 PSO 算法的全局搜索能力。在此基础上, 利用 IPSO 对 BPNN 的权值和阈值进行优化, 使得收敛速度和全局求解能力均提高, 充分发挥 BPNN 较强的非线性映射能力。

3.1 粒子群算法的改进

标准 PSO 算法首先初始化一组随机粒子, 然

后通过跟踪当前的最优粒子来搜索最优解。假设在 D 维搜索空间中, 一个群体包含 N 个粒子, 每个粒子根据式(3)进行速度和位置的更新。

$$\begin{aligned} v_{\tau}^{l+1} &= \omega v_{\tau}^l + c_1 r_1 (pbest_{\tau}^l - h_{\tau}^l) + \\ & c_2 r_2 (gbest_{\tau}^l - h_{\tau}^l) \\ h_{\tau}^{l+1} &= h_{\tau}^l + v_{\tau}^{l+1} \end{aligned} \quad (3)$$

式中: ω 为惯性权重; c_1 和 c_2 为加速度因子; r_1 和 r_2 表示在 $[0,1]$ 之间的随机数; v_{τ}^l 和 h_{τ}^l 分别为第 τ 个粒子在第 l 次迭代时的速度和位置; $pbest_{\tau}$ 为第 τ 个粒子的个体极值; $gbest_{\tau}$ 为群体的全局极值。

标准 PSO 算法容易过早收敛, 且算法后期易在全局最优解附近产生振荡的现象, 本文引入非线性变化策略对惯性权重和加速度因子进行调整, 即构建式(4)所示的参数更新模型。

$$\begin{cases} \omega = \omega_{\max} - [(\omega_{\max} - \omega_{\min}) / it_{\max}^2] it_{\tau}^2 \\ c_1 = (c_{1f} - c_{1cr}) [(it_{\max} - it_{\tau}) / it_{\max}] + c_{1f} \\ c_2 = (c_{2f} - c_{2cr}) [(it_{\max} - it_{\tau}) / it_{\max}] + c_{2f} \end{cases} \quad (4)$$

式中: ω_{\max} 和 ω_{\min} 为权重的最大和最小值; c_{1f} 和 c_{2f} 为加速因子 c_1 和 c_2 的初始值; c_{1cr} 和 c_{2cr} 为加速因子 c_1 和 c_2 的最终值; it_{\max} 和 it_{τ} 分别为迭代次数的最大值和当前迭代次数。

算法迭代前期惯性权重取值较大, 进行全局搜索, 此时加速因子 c_1 大、 c_2 小, 有助于个体进行全局搜索。到了后期惯性权重取值较小, 进行局部搜索, 此时 c_1 小、 c_2 大, 有助于局部搜索时群体的学习。其中, 惯性权重和加速度因子随着迭代次数的变化非线性增大或减小, 使得各参数的大小配合达到最佳, 提高了算法的全局搜索性能和收敛速度。

3.2 IPSO-BPNN 预测模型的建立

从 741 组空调系统逐时能耗数据集中随机选取 80% 作为网络的训练集, 剩余 20% 作为测试集。将 R 时刻室外温度、 $R-1$ 时刻室外温度、 $R-$

1时刻室外相对湿度、R-1时刻室外风速、R-1时刻太阳直射辐射、R-1时刻太阳散射辐射、R时刻空调温度设定值和R时刻空调系统能耗模式作为模型的输入项，R时刻能耗数据作为模型的输出项，依据经验式(5)^[20]和试错法，最终确定隐含层节点数为13。故网络结构为8-13-1，如图7所示。

$$\lambda = \sqrt{\alpha + \beta} + \gamma \tag{5}$$

式中： γ 为0~10的常数； α, β, λ 分别为输入层、输出层和隐含层的节点数。

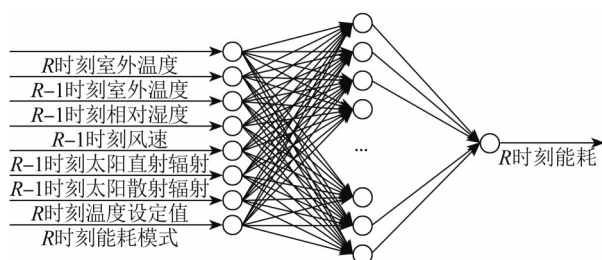


图 7 BPNN 结构图
Fig. 7 BPNN structure

本文采用 Sigmoid 为输入层到隐含层的传递函数，Purelin 为隐含层到输出层的传递函数，建立 IPSO-BPNN 模型，用 IPSO 算法优化 BPNN，其具体步骤如下：

step 1: 建立 BPNN 模型，随机生成粒子群 T_μ 作为神经网络的初始解。

$$T_\mu = (w_{\mu 1}, w_{\mu 2}, \dots, w_{\mu d})^T, \mu = 1, 2, \dots, z$$

$$d = \alpha \cdot \gamma + \gamma \cdot \beta + \gamma + \beta$$

式中： d 为搜索空间维数； z 为种群粒子数。

step 2: 将 step 1 中的粒子 T_μ 赋值于 BPNN 的权值和阈值进行网络训练，根据式(6)计算种群 T 中个体 T_μ 的适应度

$$fitness_z = \sum_{z=1}^g \frac{Y_o(z) - C_o(z)}{C_o(z)}, z = 1, 2, \dots, g \tag{6}$$

式中： $C_o(z)$ 和 $Y_o(z)$ 分别为第 z 个样本节点 O 的训练输出值和实际值； g 为训练集样本数。

step 3: 更新粒子群体个体极值与全局极值。

step 4: 由式(3)更新粒子速度和位置，再次计

算适应度值、新粒子群体个体极值和全局极值，然后按照 step 2 对粒子群更新，不断循环迭代，直到满足迭代次数。

step 5: 将种群最优粒子赋值于 BPNN 的权值与阈值进行训练，直到满足迭代次数，输出结果。

3.3 性能评价指标

采用平均绝对百分比误差(MAPE)、平均绝对误差(MAE)和均方根误差(RMSE)来评价预测精度，表达式如式(7)~(9)所示。

$$MAPE = \frac{1}{e} \sum_{\varepsilon=1}^e \left| \frac{Y_\varepsilon - \hat{Y}_\varepsilon}{Y_\varepsilon} \right| \times 100\% \tag{7}$$

$$MAE = \frac{1}{e} \sum_{\varepsilon=1}^e |Y_\varepsilon - \hat{Y}_\varepsilon| \tag{8}$$

$$RMSE = \sqrt{\frac{1}{e} \sum_{\varepsilon=1}^e (Y_\varepsilon - \hat{Y}_\varepsilon)^2} \tag{9}$$

式中： $\hat{Y}_\varepsilon (\varepsilon = 1, 2, \dots, e)$ 和 $Y_\varepsilon (\varepsilon = 1, 2, \dots, e)$ 分别为预测值和实际值数列； e 为样本数目。

4 预测结果分析

使用相同的数据集分别对传统单一的 BPNN 模型和在采用集成方法分析能耗的基础上建立的 BPNN 模型、PSO-BPNN 模型、IPSO-BPNN 模型进行训练。BPNN 模型的最大迭代次数为 100，目标误差为 0.001，学习率为 0.01；PSO-BPNN 模型和 IPSO-BPNN 模型的进化代数 200，种群规模为 100，粒子的速度范围为[-1, 1]，位置范围为[-5, 5]。PSO-BPNN 模型中加速度因子 c_1 和 c_2 都为 2，惯性权重为 0.7；IPSO-BPNN 模型中加速度因子 c_1 和 c_2 的动态调整范围分别为[0.5, 2.4]和[2.4, 0.5]，惯性权重 ω 的动态调整范围为[0.4, 0.8]。IPSO-BPNN 模型和 PSO-BPNN 模型的迭代收敛情况如图 8 所示，可以看出 PSO-BPNN 模型需要迭代 92 步达到收敛，而 IPSO-BPNN 模型只需要迭代 27 步就已经收敛，收敛速度较快。(图 9 是 4 种模型的预测值与实际值对比图。)




图8 训练收敛结果对比图

Fig. 8 Comparison graph of training convergence results

能评价指标对预测模型的精度进行评价, 数值越小精度就越高。可以看出, 在采用集成方法对能耗进行分析的基础上建立的BPNN模型、PSO-BPNN模型、IPSO-BPNN模型均比传统单一的BPNN模型预测精度高, MAPE减少了3.4%。

表5 误差指标分析
Table 5 Error indicator analysis

分析-模型	MAPE/%	MAE/ (kW·h)	RMSE/ (kW·h)
BPNN	8.24	2.816 9	4.179 5
集成-BPNN	6.13	2.110 9	2.715 9
集成-PSO-BPNN	5.59	1.910 8	2.561 7
集成-IPSO-BPNN	4.87	1.684 1	2.299 2

在表5中, 结合MAPE、MAE和RMSE 3种性




图9 4种模型的预测值与实际值对比图

Fig. 9 Predicted and actual values of four models are compared

5 结论

本研究针对西安地区夏季工况工作日设计了空调环境动态温度调控策略, 并采用EnergyPlus软件模拟某办公建筑变风量空调系统逐时能耗。结果表明, 基于动态温度调控的空调系统既可满足人体热舒适又可有效降低系统能耗。与此同时,

针对动态温度调控的空调系统能耗预测问题, 在采用集成方法分析能耗的基础上建立IPSO-BPNN模型, 并对空调系统逐时能耗进行预测。将所建立的IPSO-BPNN模型与BPNN模型、PSO-BPNN模型及传统单一的BPNN模型进行对比分析, 结果表明, 在采用集成方法对能耗进行分析的基础

上建立的 BPNN 模型、PSO-BPNN 模型、IPSO-BPNN 模型和传统单一的 BPNN 模型所对应的 *MAPE* 分别为 6.13%，5.59%，4.87% 和 8.24%。可以看出，在采用集成方法分析能耗的基础上建立的神经网络模型均比传统单一的 BPNN 模型精度高，且 IPSO 算法可以更好地弥补 BPNN 和 PSO-BPNN 存在的局部极小值陷阱和收敛速度慢等缺点。因此，所设计的预测方法合理、有效，对系统降耗增效具有重要的指导意义。

参考文献

- [1] Thach T Q, Mahirah D, Dunleavy G, et al. Prevalence of Sick Building Syndrome and Its Association with Perceived Indoor Environmental Quality in an Asian Multi-ethnic Working Population [J]. *Building and Environment*(S0360-1323), 2019, 166(c): 106420.
- [2] Vellei M, Le Dréau J. A Novel Model for Evaluating Dynamic Thermal Comfort under Demand Response Events [J]. *Building and Environment*(S0360-1323), 2019, 160(8): 106215.
- [3] 白燕, 冯壮壮, 张玮. 基于动态模糊推理的舒适温度在线预测 [J]. *计算机测量与控制*, 2020, 28(7): 74-80.
Bai Yan, Feng Zhuangzhuang, Zhang wei. Online Prediction of Comfort Temperature based on Dynamic Fuzzy Reasoning[J]. *Computer Measurement and Control*, 2020, 28(7): 74-80.
- [4] 孙淑凤, 赵荣义, 许为全, 等. 动态空调策略研究 [J]. *制冷与空调*, 2003, 3(6): 27-32.
Sun Shufeng, Zhao Rongyi, Xu Weiquan, et al. Research on Dynamic Air Conditioning Strategies [J]. *Refrigeration and Conditioning*, 2003, 3(6): 27-32.
- [5] Zhang , Zhao . Relationship Between Thermal Sensation and Comfort in Non-uniform and Dynamic Environments [J]. *Building and Environment*(S0360-1323), 2009, 44(7): 1386-1391.
- [6] Zhu Y, Ouyang Q, Cao B, et al. Dynamic Thermal Environment and Thermal Comfort [J]. *Indoor Air* (S0905-6947), 2016, 26(1): 125-137.
- [7] 刘争敏. 集中空调动态温度调控策略及能耗分析研究 [D]. 西安: 西安建筑科技大学, 2019.
Liu Zhengmin. Dynamic Temperature Control Strategy and Energy Consumption Analysis of central Air-conditioning [D]. Xi 'an: Xi 'an University of Architecture and Technology, 2019.
- [8] Yang S, Wan M P, Chen W, et al. Model Predictive Control with Adaptive Machine-learning-based Model for Building Energy Efficiency and Comfort Optimization [J]. *Applied Energy*(S0306-2619), 2020, 271(c): 115147.
- [9] Amasyali K, El-Gohary N M. A Review of Data-Driven Building Energy Consumption Prediction Studies[J]. *Renewable and Sustainable Energy Reviews*(S1364-0321), 2018, 8(1): 1192-1205.
- [10] Shao M, Wang X, Bu Z, et al. Prediction of Energy Consumption in Hotel Buildings via Support Vector Machines[J]. *Sustainable Cities and Society*(S2210-6707), 2020, 57(4): 102128.
- [11] Zhang B, Ren J, Cheng Y, et al. Health Data Driven on Continuous Blood Pressure Prediction based on Gradient Boosting Decision Tree Algorithm [J]. *IEEE Access* (S2169-3536), 2019, 7(9): 32423-32433.
- [12] 杨熊, 于军琪, 郭晨露, 等. 基于改进 PSO-BP 神经网络的冰蓄冷空调冷负荷动态预测模型 [J]. *土木与环境工程学报*, 2019, 41(01): 168-174.
Yang Xiong, Yu Junqi, Guo Chenlu, et al. Dynamic Prediction Model of Ice Storage Air Conditioning Cooling Load based on Improved PSO-BP Neural Network [J]. *Journal of Civil and Environmental Engineering*, 2019, 41(1): 168-174.
- [13] Xu X, Liu W, Lian Z. Dynamic Indoor Comfort Temperature Settings based on the Variation in Clothing Insulation and its Energy-saving Potential for an Air-conditioning System [J]. *Energy and Buildings*(S0378-7788), 2020, 220(c): 110086.
- [14] Ryu J, Kim J, Hong W, et al. Quantifying Householder Tolerance of Thermal Discomfort before Turning on Air-conditioner[J]. *Energy and Buildings*(S0378-7788), 2020, 211(15): 109797.
- [15] 罗茂辉, 余娟, 杨月婷, 等. 等温工况下分体空调送风动态化与人体热舒适实验研究 [J]. *暖通空调*, 2014, 44(5): 130-134.
Luo Maohui, Yu Juan, Yang Yueting, et al. Experimental Study on dynamic State of Separable Air Supply and Human Thermal Comfort under Isothermal Condition[J]. *HVAC*, 2014, 44(5): 130-134.
- [16] 李慧, 张庆范, 段培永. 基于用户学习的智能动态热舒适控制系统 [J]. *四川大学学报(工程科学版)*, 2011, 43(2): 128-135.
Li Hui, Zhang Qingfan, Duan Peiyong. Intelligent Dynamic Thermal comfort Control System based on User Learning [J]. *Journal of Sichuan University (Engineering Science Edition)*, 2011, 43(2): 128-135.
- [17] Fanger P O. Thermal Comfort. Analysis and Applications in Environmental Engineering [J]. *Thermal Comfort. Analysis and Applications in Environmental Engineering*

- (S0003-6870), 1970, 3(3):181.
- [18] 西安市城乡建设委员会. 公共建筑节能设计标准: DBJ T6161-60-2011 [S]. 陕西省住房和城乡建设厅, 陕西省质量技术监督局, 2011: 7-35.
- Xi'an Urban-Rural Construction Committee. Energy-saving Design Standards for Public Buildings: DBJ T6161-60-2011 [S]. Shaanxi Provincial Department of Housing and Urban-Rural Construction, Shaanxi Provincial Bureau of Quality and Technical Supervision, 2011: 7-35.
- [19] Ma Z, Song J, Zhang J. Energy Consumption Prediction of Air-Conditioning Systems in Buildings by Selecting Similar Days based on Combined Weights [J]. Energy and Buildings(S0378-7788), 2017, 151(9): 157-166.
- [20] Jiang Q, Huang R, Huang Y, et al. Application of BP Neural Network Based on Genetic Algorithm Optimization in Evaluation of Power Grid Investment Risk [J]. IEEE Access(S2169-3536), 2019, 7(9): 154827-154835 .