

1-18-2021

Cold Load Prediction Model Based on Improved PSO-BP Algorithm

Junqi Yu

1. School of Construction Equipment and Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China; ;

Wenqiang Jing

1. School of Construction Equipment and Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China; ;

Anjun Zhao

1. School of Construction Equipment and Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China; ;2. Xi'an University of Architecture and Technology Engineering Co., Ltd., Xi'an 710055, China; ;

Yanhuan Ren

1. School of Construction Equipment and Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China; ;

See next page for additional authors

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.

Cold Load Prediction Model Based on Improved PSO-BP Algorithm

Abstract

Abstract: Aiming at the low correlation between input and output data and the error of prediction model in PSO-BP neural network prediction model, a combined prediction method based on JMP, PSO-BP neural network and Markov chain is proposed. *The method first uses JMP data processing software to process the input data and eliminating the low coupling degree samples, then conducts PSO-BP neural network training to obtain the cold load prediction results, and finally uses markov chain to eliminate the random errors generated by the system to obtain the final prediction results.* The results show that the combined prediction method has higher prediction accuracy, and the prediction result conforms to the change rule of the shopping mall load, and meets the actual application requirements.

Keywords

air conditioning cooling load, PSO-BP neural, prediction algorithms, markov chain

Authors

Junqi Yu, Wenqiang Jing, Anjun Zhao, Yanhuan Ren, Zhou Meng, Xinle Huang, and Yang Xue

Recommended Citation

Yu Junqi, Jing Wenqiang, Zhao Anjun, Ren Yanhuan, Zhou Meng, Huang Xinle, Yang Xue. Cold Load Prediction Model Based on Improved PSO-BP Algorithm[J]. Journal of System Simulation, 2021, 33(1): 54-61.

基于改进 PSO-BP 算法的冷负荷预测模型

于军琪¹, 井文强¹, 赵安军^{1,2}, 任延欢¹, 周梦², 黄馨乐¹, 杨雪³

(1. 西安建筑科技大学 建筑设备与工程学院, 陕西 西安 710055; 2. 西安建筑科大工程技术有限公司, 陕西 西安 710055;
3. 大唐移动通信设备有限公司, 陕西 西安 710055)

摘要: 针对 PSO-BP(Particle Swarm Optimization-Back Propagation)神经网络预测模型在冰蓄冷空调冷负荷预测中存在输入输出数据关联度低和预测模型存在误差的情况, 提出了一种基于 JMP 数据处理软件、PSO-BP 神经网络和马尔可夫链的组合预测方法。利用 JMP 处理输入数据, 剔除耦合度低的样本, 进行 PSO-BP 神经网络训练, 得到冷负荷预测结果, 利用马尔可夫链消除系统产生的随机误差得到最终预测结果。结果表明: 该组合预测方法对比传统 PSO-BP 算法其预测精度更高, 预测结果符合商场冷负荷的变化规律, 满足实际的应用需求。

关键词: 空调冷负荷; PSO-BP 神经网络; 预测算法; 马尔可夫链

中图分类号: TU831; TP391 文献标志码: A 文章编号: 1004-731X (2021) 01-0054-08
DOI: 10.16182/j.issn1004731x.joss.19-0223

Cold Load Prediction Model Based on Improved PSO-BP Algorithm

Yu Junqi¹, Jing Wenqiang¹, Zhao Anjun^{1,2}, Ren Yanhuan¹, Zhou Meng², Huang Xinle¹, Yang Xue³

(1. School of Construction Equipment and Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China;
2. Xi'an University of Architecture and Technology Engineering Co., Ltd., Xi'an 710055, China;
3. Datang Mobile Communications Equipment Co., Ltd., Xi'an 710055, China)

Abstract: Aiming at the low correlation between input and output data and the error of prediction model in PSO-BP neural network prediction model, a combined prediction method based on JMP, PSO-BP neural network and Markov chain is proposed. *The method first uses JMP data processing software to process the input data and eliminating the low coupling degree samples, then conducts PSO-BP neural network training to obtain the cold load prediction results, and finally uses markov chain to eliminate the random errors generated by the system to obtain the final prediction results.* The results show that the combined prediction method has higher prediction accuracy, and the prediction result conforms to the change rule of the shopping mall load, and meets the actual application requirements.

Keywords: air conditioning cooling load; PSO-BP neural; prediction algorithms; markov chain

引言

目前空调能耗在建筑能耗中的占比越来越大^[1], 其巨大的用电量加剧了电网的压力, 有研究者采用冰蓄冷空调解决这一问题^[2]。冰蓄冷空调的运行, 需要合理匹配电价的波峰波谷时间内冷机和冰槽应提供的冷量, 首先对次日建筑物内各个时刻

的冷负荷量进行预测, 然后根据预测结果来进行冷量的划分。因此冷负荷的动态预测是冰蓄冷空调的核心内容。

目前针对空调冷负荷预测, 多数研究者采用数据驱动的方法^[3], 主要包括支持向量机(Support Vector Machine, SVM)、统计回归、决策树、遗传算法、神经网络算法。SVM 是一种常用的人工智

收稿日期: 2019-05-23

修回日期: 2019-11-15

基金项目: 陕西省重点研发计划(2017zdcx1-sf-03-02), 陕西省教育厅产业化培育项目(17JF016), 陕西省科技厅专项科研项目(2017JM6106), 校基础研究基金(JC1706)

作者简介: 于军琪(1969-), 男, 博士, 教授, 研究方向为建筑智能与节能技术。E-mail: junqiyu@126.com

能方法^[4], 具有将非线性关系转化的处理能力, 但是其处理数据耗时太久^[5-6]。统计回归是一种简单易行的预测方法, 但是其预测能力低于 SVM, 且统计回归方法的预测器难以选择^[7]。决策树是一种使用树状图将数据分为组的技术, 易于理解, 但其预测结果经常会与实际结果有很大的偏差^[8], 且不能很好的处理时间序列和非线性数据^[9]。遗传算法是处理复杂模型问题^[10]的优化处理算法, 当输入数据量大且复杂时, 该算法可以根据客观函数或主观判断得到合适的解, 但是其存在非唯一结果和计算时间大的问题^[11-12]。神经网络作为一种预测算法广泛应用于各个领域^[13], 其中 BP(Back Propagation)神经网络以其强大的非线性映射、自学习、泛化、容错能力得到的广泛应用, 但是其也存在局部极小化和收敛速度慢的问题。有研究者采用粒子群算法 PSO(Particle Swarm Optimization)^[14]对 BP 神经网络进行初始阈值和权值的优化, 提高了 BP 神经网络收敛速度和精度。但是由于输入数据与输出数据存在匹配度低, 以及组合模型存在过程误差, 导致预测结果达不到理想需求。

本文在传统的人工神经网络的基础上, 加入 JMP 数据分析, 对系统的输入输出变量进行关联度分析, 增加数据的关联度, 采用 Markov 链对人工神经网络的预测结果进行误差修正。研究表明, 该改进模型相对于传统的人工神经网络预测方法在预测精度和模型的收敛速度均有提高, 更符合工程的实际应用。

1 空调冷负荷动态预测方法思路

冷负荷预测的难点和重点是提高预测准确度和时效性, 传统的商场空调冷负荷预测没有考虑到商场运行特性点, 未区分周内和周末用能情况的不同^[15], 所以需要根据商场的特点对数据进行重新分析整合后再进行预测, 具体的预测思路如图 1 所示。

利用 JMP 数据分析软件对输入数据进行关联度分析可以对神经网络进行改进, 利用关联度分析法能够剔除相关性低的输入变量, 弥补由于输入输出变量关联度低导致神经网络训练速度慢和预测

精度低的弱点, 提高其预测准确度, 因此可将其应用于商场建筑空调冷负荷的动态预测, 考虑到组合模型预测结果会存在一些相对误差, 因此采用 Markov 链对预测结果作进一步修正来提高精度。

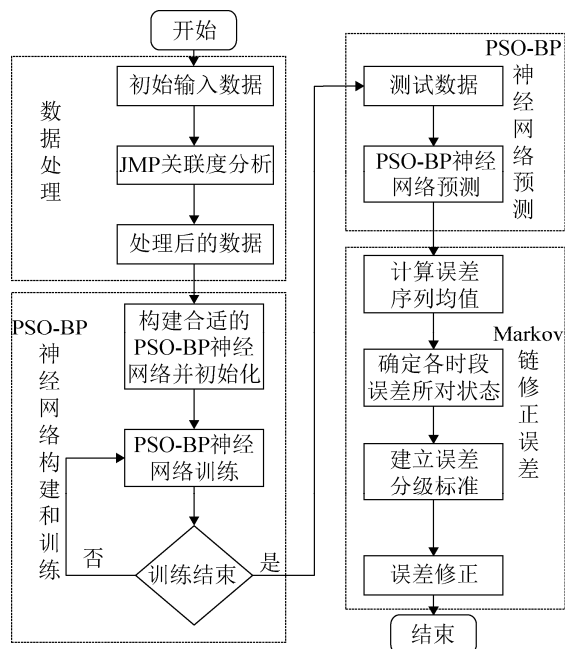


图 1 冷负荷动态预测方法思路的流程

Fig. 1 Flow of dynamic prediction method for cooling load

2 改进 PSO-BP 大型商场筑冷负荷动态预测模型构建

2.1 PSO-BP 神经网络预测模型

利用 PSO-BP 神经网络对商场空调冷负荷预测, 实际是利用 PSO 算法对 BP 神经网络的权重和阈值进行迭代优化, 得到适应度最好的权重和阈值, 用于 BP 神经网络进行预测。

为预测商场空调冷负荷, 本文采用 3 层网络架构。冰蓄冷空调冷负荷预测常用的输入数据包含当前和前一时刻的室外干球温度 $T, T-1$, 当前和前一时刻以及前两时刻的太阳辐射量 $R, R-1, R-2$, 当前时刻室外湿度 H , 当前时刻室外风速 W 、前一时刻和前两时刻以及前四时刻的冷负荷 $C-1, C-2, C-4$, 以当前时刻冷负荷 C 作为输出, 输入层神经元数为 10, 输出层为 M 时刻的冷负荷, 神经网络隐含层的节点可有经验式(1)得到为 21。

$$A = 2B + 1 \tag{1}$$

式中： A 为隐含层神经元个数； B 为输入层神经元个数。

(1) 确定粒子的适应度。通过采集的与预测相关的数据和 PSO 算法处理的得到的数据来确定粒子的适应度数值，如式(2)所示：

$$f = \sum_{i=1}^N |y_i - \bar{y}_i| \tag{2}$$

式中： N 为样本个数； y_i 为样本 i 的观测值； \bar{y}_i 为样本 i 的预测值。

(2) 粒子适应度的选取，选取当前粒子的适应度 P_{see} 和历史最优适应度 P_{best} 中最好的，做为当前粒子的适应度；选取当前粒子的历史最优适应度和全局最优适应度 g_{best} 中最好的，做为当前粒子的历史最优适应度。

(3) 利用式(3)~(4)对粒子位置及速度进行更新。

$$V_{ab}(t+1) = V_{ab}(t) + l_1 \times r_1 \times (P_{ab}(t) - X_{ab}(t)) + l_2 \times r_1 \times (P_{gb}(t) - X_{ab}(t)) \tag{3}$$

$$X_{ab}(t+1) = X_{ab}(t) + V_{ab}(t+1) \tag{4}$$

式中： $a=1,2,\dots,n$ ， $b=1,2,\dots,n$ ， l_1 为粒子个体最优步长； l_2 为粒子的群体最优步长； r_1 和 r_2 为 0~1 之间随机数； X_{ab} 为第 a 个粒子的位置； V_{ab} 为第 a 个粒子的速度。

设置粒子速度最大区间为 $[0, V_{max}]$ ，当粒子速度 $> V_{max}$ ，则该粒子此时的速度改为 V_{max} 。

(4) 比较当前迭代次数 $CurIte$ 与最大迭代次数 $maxIte$ ：若 $CurIte \geq maxIte$ ，则停止迭代；若 $CurIte < maxIte$ ，则返回步骤(1)。

2.2 基于 JMP, Markov 链改进的 PSO-BP 神经网络

虽然 PSO-BP 神经网络的预测精度优于之前的一些神经网络，但是还达不到工程实际的理想状态，主要是因为输入数据的冗杂性和组合预测存在一些偏差，因此需要利用 JMP^[16]对输入数据进行处理，利用 Markov 链对预测误差进行修正。

考虑到上述数据中存在部分输入数据与输出

数据关联度较低，所以利用 JMP 进行相关性分析，并通过 Pearson 相关性显著性进行检验，其中 $[0, 0.3]$ 认定为相关性较弱， $[0.3, 0.5]$ 认为相关性中等， $[0.5, 0.7]$ 认为相关性较强， $[0.7, 1.0]$ 认为相关性很强。关联度分析后的结果如表 1 所示。

表 1 各输入参数与 T 时刻冷负荷的关联度
Tab. 1 Correlation between input parameters and cooling load at time T

输入参数	数据关联度	输入参数	数据关联度
T	0.751 3	H	0.896 3
$T-1$	0.794 8	W	0.017 6
R	0.798 3	$C-1$	0.934 2
$R-1$	0.823 2	$C-2$	0.875 3
$R-2$	0.692 3	$C-4$	0.609 7

结合前述及表 1 的分析结果，可以剔除 $R-2$ ， W ， $C-4$ 共 3 个输入参数，以 T ， $T-1$ ， R ， $R-1$ ， H ， $C-1$ ， $C-2$ 共 7 个变量作为 PSO-BP 神经网络预测模型的输入变量，以参数 C 作为输出变量，结合式(1)得到大型公共建筑冷负荷预测模型结构为：7-15-1，即 7 个输入层节点 15 个隐含层节点和 1 个输出层节点。

Markov 链是一种具有无后效性的随机过程^[17]，根据某一已知时刻条件下求出下一时刻的概率分布，得到下一时刻的状态而与其他时刻无关。Markov 链适用于对存在波动性的预测问题进行修正描述^[18]。

神经网络模型的预测值的 Markov 误差修正过程步骤如下：

step 1: 根据前述 PSO-BP 神经网络所得的预测值矩阵 $\hat{A}(t)$ 与实测值矩阵 $A(t)$ 求出误差值矩阵 $\bar{A}(t)$ ，利用式(5)~(6)求出 $\bar{A}(t)$ 的均值 \bar{X} 与标准差 S ，得到误差状态区间。

$$\bar{X} = \frac{1}{n} \sum_{t=1}^n \bar{A}(t) \tag{5}$$

$$S = \sqrt{\frac{1}{n-1} \sum_{t=1}^n (\bar{A}(t) - \bar{X})^2} \tag{6}$$

step 2: 按照式(7)以及统计法，根据 step 1 的误差状态区间，得到转移概率矩阵。

$$P_{ij}^{(t)} = n_{ij}^{(t)} / N_i \quad (7)$$

式中: $P_{ij}^{(t)}$ 为概率转移矩阵; N_i 为状态为 i 的误差出现的总次数; $n_{ij}^{(t)}$ 为状态为 i 的误差经过 t 步转移到状态 j 的次数。

step 3: 利用式(8)得到 t 步所处的状态向量, 来判断 t 步所处的状态区间。

$$P(t) = P^{(0)} \times P^{(t)} = P^{(0)} \times (P^{(1)})^t \quad (8)$$

式中: $P^{(0)}$ 为初始向量矩阵; $P^{(1)}$ 为一步概率转移矩阵如式(9)所示。

$$P^{(1)} = \begin{bmatrix} P_{11} & P_{12} & \cdots & P_{1x} \\ P_{21} & P_{22} & \cdots & P_{2x} \\ \vdots & \vdots & & \vdots \\ P_{y1} & P_{y2} & \cdots & P_{yx} \end{bmatrix} \quad (9)$$

step 4: 根据 step 2 所得概率转移矩阵和 step 3 所得状态向量, 求出修正后的值。

3 商场建筑冷负荷预测仿真实验分析

3.1 冷负荷变化机理研究分析

根据冷负荷的变换趋势具有周期性和相似性, 推测商场建筑冷负荷的变化规律也应该具有类似的特征。以西安市某商业中心为例, 分别对周内和周末的冷负荷数据进行了分析。一周之中的周一~周五的冷负荷信息具有相似性, 但是和周末不太相同, 将该商业中心为取样对象, 分析周内和周末冷负荷变化图, 如图 2 所示。




图 2 冷负荷变化图

Fig. 2 Cooling load variation diagram

图 2 可以看出周内和周末冷负荷变化存在差异, 因此在之后的实验仿真中分别对周内和周末进行实验, 进行分析。

3.2 实例验证分析

本实验利用西安市某商业中心实际数据, 该商业中心共有 10 层, 高度为 40.6 m, 面积达 25 万 m^2 , 其中建筑空调面积约占 18.76 万 m^2 , 该商场夏季供冷部分采用冰蓄冷空调供冷方式。

本实验采用当前和前一时刻的室外干球温度 $T, T-1$, 当前和前一时刻太阳辐射量 $R, R-1$, 当前时刻室外湿度 H , 前一时刻和前两时刻冷负荷 $C-1, C-2$ 7 个变量作为 PSO-BP 神经网络的输入变量, 以当前时刻冷负荷 C 作为神经网络的输出变量。考虑到商业中心的工作特点, 实验以商场的 6 月和 7 月 60 天中前 50 天每天早 8 点至晚上 10 点的输入变量做为训练数据, 7 月份的 26-29 日的的数据作为验证分析数据。

利用测试数据进行仿真, 检验网络的预测能力。图 3 中模型 1 为未区分周内和周末数据进行预测, 模型 2 为区分周内和周末数据但是未剔除关联度低的输入数据进行的预测, 模型 3 为既区分了周内和周末数据也剔除了关联度低的输入数据后进行的预测。图 4 展示的是 3 种模型的预测误差情况, 由图 3 和图 4 中可以看出剔除关联度低的输入数据进行预测的效果更好。




图 3 预测结果对比图

Fig. 3 Comparison of prediction results




图 4 预测误差对比图
Fig. 4 Comparison of prediction errors

通过图 4 可以发现模型 3 的预测误差优于模型 1 和 2，但还存在尖峰误差，因此需要利用 Markov 链对其进行修正提升模型预测精度。

3.3 Markov 链修正

基于 Markov 链修正的 PSO-BP 神经网络的建模过程，首先是根据上述得到的相对误差的大小进行值域的区间划分，区间划分采取的方法是均值-方差法^[19-20]。然后根据划分好的区间，对误差进行分类，根据分类结果构建概率转移矩阵，利用初始向量所处的状态以及概率转移矩阵，计算出预测时间段所处的状态，根据预测时间段的状态来计算得到预测时间段的修正值。

根据上述分析的相对误差情况分别得出周内误差均值 $\bar{X}_1 = 5.937$ ，均值方差 $S_1 = 6.352$ ；周末误差均值 $\bar{X}_2 = -0.694$ ，均值方差 $S_2 = 10.421$ 。经过计算划分周内和周末 Markov 链的状态区间如表 2 所示。

表 2 Markov 链的状态区间
Tab. 2 State interval of the Markov chain

周内 Markov 链的状态区间	周末 Markov 链的状态区间
$E_1 = [-24.112, -11.111]$	$E_1 = [-5.475, -3.206]$
$E_2 = [-11.111, -5.900]$	$E_2 = [-3.206, 1.895]$
$E_3 = [-5.900, 4.521]$	$E_3 = [1.895, 9.113]$
$E_4 = [4.521, 9.370]$	$E_4 = [9.113, 12.289]$
$E_5 = [9.370, 33.799]$	$E_5 = [12.289, 19.687]$

根据划分的状态区间依次对 PSO-BP 模型预测周内和周末的误差值进行状态划分，划分结果如表 3 所示。

表 3 PSO-BP 神经网络预测误差分类结果
Tab. 3 PSO-BP neural network prediction error classification results

时间	7 月 26 日(周末)		时间	7 月 27 日(周末)	
	误差/%	状态		误差/%	状态
8	15.843	E_5	8	10.132	E_5
9	33.799	E_5	9	-17.486	E_1
10	-12.314	E_1	10	-7.983	E_2
11	14.492	E_5	11	-2.809	E_3
12	7.951	E_4	12	0.116	E_3
13	-8.171	E_2	13	0.167	E_3
14	3.333	E_3	14	-0.860	E_3
15	-2.819	E_3	15	-0.966	E_3
16	-1.233	E_3	16	-0.352	E_3
17	1.223	E_3	17	-1.222	E_3
18	-1.015	E_3	18	-2.479	E_3
19	-1.018	E_3	19	-7.976	E_3
20	-4.204	E_3	20	-6.261	E_2
21	-4.323	E_3	21	-4.817	E_3
22	-24.112	E_1	22	4.557	E_4
时间	7 月 28 日(周内)		时间	7 月 29 日(周内)	
	误差/%	状态		误差/%	状态
8	16.218	E_2	8	19.687	E_5
9	-2.426	E_4	9	7.364	E_3
10	8.938	E_4	10	13.364	E_4
11	12.275	E_4	11	14.016	E_4
12	8.062	E_4	12	14.018	E_3
13	5.157	E_3	13	0.849	E_3
14	-0.432	E_4	14	2.841	E_3
15	6.032	E_4	15	5.103	E_4
16	7.031	E_3	16	6.302	E_3
17	3.094	E_3	17	-0.318	E_3
18	5.896	E_3	18	10.296	E_3
19	-5.473	E_3	19	0.853	E_3
20	0.420	E_1	20	-4.835	E_1
21	12.708	E_1	21	2.865	E_1
22	9.335	E_2	22	-1.122	E_2

根据表 3 的误差状态分别确定周内和周末的 Markov 链一步转移概率矩阵 P_1 ， P_2 为：

$$P_1 = \begin{bmatrix} 0 & 1/3 & 0 & 0 & 2/3 \\ 0 & 0 & 1 & 0 & 0 \\ 1/18 & 1/18 & 5/18 & 1/18 & 0 \\ 0 & 1/2 & 0 & 0 & 1/2 \\ 1/2 & 0 & 0 & 1/4 & 1/4 \end{bmatrix}$$

$$P_2 = \begin{bmatrix} 1/2 & 1/2 & 0 & 0 & 0 \\ 0 & 1/3 & 0 & 1/3 & 1/3 \\ 2/13 & 0 & 8/13 & 3/13 & 0 \\ 0 & 0 & 4/9 & 5/9 & 0 \\ 0 & 0 & 1 & 0 & 0 \end{bmatrix}$$

根据表 3 的误差状态来确定各时间段的状态向量, 根据状态转移向量和概率转移矩阵来解出经

Markov 链修正后的 PSO-BP 神经网络预测模型的预测值。

将修正后的预测值(模型 4)与前述的没有区分周内和周末数据进行预测(模型 1)、区分周内和周末但是没有对输入数据进行处理来进行预测(模型 2)、即区分了周内和周末数据又对输入数据进行处理来进行预测的预测结果(模型 3)进行对比, 结果如图 5 所示。

利用 RMSPE(Root Mean Square Percentage Error)均方根误差来评价 4 种预测模型误差, 处理结果如表 4 所示。

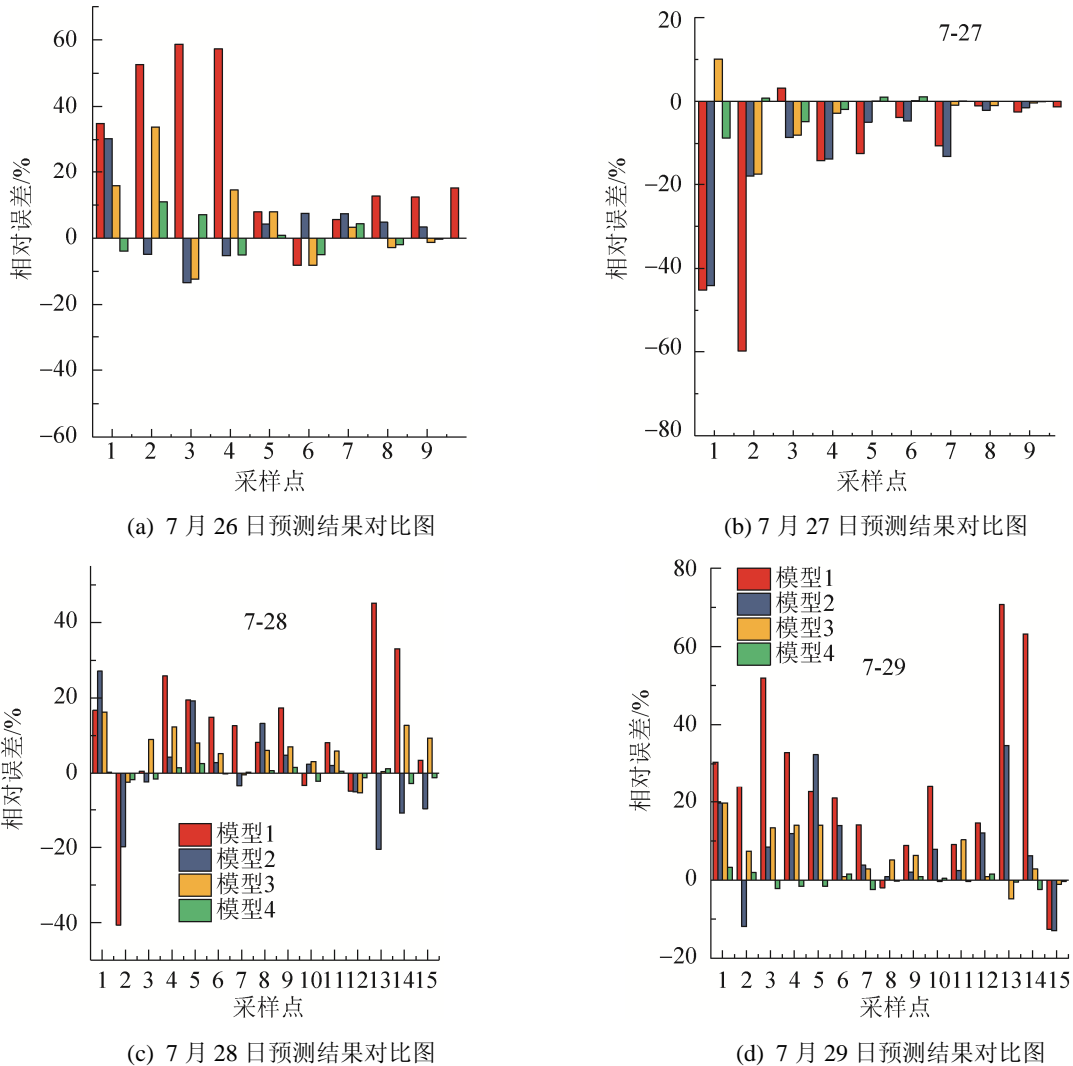


图 5 结果比较图
Fig. 5 Comparison results

表 4 预测模型均方根误差

Tab. 4 Prediction model root mean square error

采用方法	RMSPE/%
预测模型 1	26.14
预测模型 2	20.15
预测模型 3	9.15
预测模型 4	3.06

实验结果表明, 进行改进 PSO-BP 神经网络 Marko 链组合预测时, 最大迭代次数设置为 2 000 次, 该预测模型达到预测精度仅为 409 步, 提升了预测结果的有效性。从图 5 和表 4 的结果可以看出 Markov 修正 PSO-BP 神经网络的预测精度更高, 更能达到实际工程应用的要求。

4 结论

针对商城冰蓄冷空调的冷负荷预测问题, 文中提出改进 PSO-BP 神经网络的预测模型, 并利用 Markov 链对误差进行修正的预测方法; 利用 JMP 数据分析软件对输入输出数据间的关联度进行分析, 利用 PSO-BP 神经网络对冰蓄冷空调冷负荷进行初步预测, 利用 Markov 链对预测结果进行误差修正。将预测模型应用于实际的商场, 得出以下结论:

(1) 该商场冰蓄冷空调的 T 时刻输出冷负荷与以 T 时刻室外温度、 $T-1$ 时刻室外温度、 T 时刻太阳辐射量、 $T-1$ 时刻太阳辐射量、 T 时刻相对湿度、 $T-1$ 时刻冷负荷、 $T-2$ 时刻冷负荷这 7 个输入量相关性高。

(2) 考虑到商场周内和周末因为客流量变化会导致商场空调冷负荷需求不同, 因此在进行商城空调冷负荷预测时需要对周内和周末的情况进行区分, 分别建立实验模型。

(3) 经过改进的模型与未改进的模型针对预测值和实际值的最大相对误差从 33.799% 减小到了 10.967%, 预测模型的均方根误差 $RMSPE$ 从 26.14% 减小到了 3.06%。

(4) 预测结果表明, 本文所述方法能够提高预

测精度, 更适合工程实际的应用。

参考文献:

- [1] 刘静纨, 魏东, 朱为明. 神经网络模糊预测优化控制在 VAV 系统中的应用[J]. 系统仿真学报, 2010, 22(12): 2909-2914.
Liu Jingwan, Wei Dong, Zhu Weiming. Application of Neural Network Fuzzy Predictive Optimal Control in VAV System [J]. Journal of System Simulation, 2010, 22(12): 2909-2914.
- [2] 于军琪, 王胤钧, 陈旭, 等. 基于粒子群算法的冰蓄冷空调系统运行优化研究[J]. 西安建筑科技大学学报(自然科学版), 2018, 50(1): 148-154.
Yu Junqi, Wang Yinjun, Chen Xu, et al. Study on Operation Optimization of Ice Storage Air Conditioning System Based on Particle Swarm Optimization [J]. Journal of Xi'an University of Architecture and Technology (Natural Science Edition), 2018, 50(1): 148-154.
- [3] Wei Y X, Zhang X X. A Review of Data-Driven Approaches for Prediction and Classification of Building Energy Consumption[J]. Renewable and Sustainable Energy Reviews (S1364-0321), 2018, 82: 1027-1047.
- [4] Li Q, Meng Q L, Cai J J, et al. Applying Support Vector Machine to Predict Hourly Cooling Load in the Building[J]. Appl Energy (S0306-2619), 2009, 86(10): 2249-2256.
- [5] Zhao H X, Magoulès F. Parallel Support Vector Machines Applied to the Prediction of Multiple Buildings Energy Consumption[J]. J Algorithms Comput Technol (S0196-6774), 2010, 4(2): 231-250.
- [6] Li Q, Meng Q, Cai J, et al. Predicting Hourly Cooling Load in the Building: A Comparison of Support Vector Machine and Different Artificial Neural Networks[J]. Energy Convers Manag (S0196-8904), 2009, 50(1): 90-96.
- [7] Swan L G, Ugursal V I. Modeling of End-use Energy Consumption in the Residential Sector: a Review of Modeling Techniques[J]. Renew Sustain Energy Rev (S1364-0321), 2009, 13(8): 1819-1835.
- [8] Yu Z, Haghghat F, Fung B C M, et al. A Decision Tree Method for Building Energy Demand Modeling[J]. Energy Build (S0378-7788), 2010, 42(10): 1637-1646.
- [9] Tso G K F, Yau K K W. Predicting Electricity Energy Consumption: A Comparison of Regression Analysis, Decision Tree and Neural Networks[J]. Energy (S0360-5442), 2007, 32(9): 1761-1768.

- [10] Beyer H G. Evolutionary Algorithms in Noisy Environments: Theoretical Issues and Guidelines for Practice[J]. *Comput Methods Appl Mech Eng* (S0045-7825), 2000, 186(2/3/4): 239-267.
- [11] Azadeh A, Ghaderi S F, Tarverdian S, et al. Integration of Artificial Neural Networks and Genetic Algorithm to Predict Electrical Energy Consumption[J]. *Appl Math Comput* (S0096-3003), 2007, 186(2): 1731-1741.
- [12] Li K, Su H. Forecasting Building Energy Consumption with Hybrid Genetic Algorithm-Hierarchical Adaptive Network-Based Fuzzy Inference System[J]. *Energy Build* (S0378-7788), 2010, 42(11): 2070-2076.
- [13] Li K J, Su H Y, Chu J. Forecasting Building Energy Consumption Using Neural Networks and Hybrid Neuro-Fuzzy System: A Comparative Study[J]. *Energy Build* (S0378-7788), 2011, 43(10): 2893-2899.
- [14] Huang J F, He L L. Application of Improved PSO-BP Neural Network in Customer Churn Warning[J]. *Procedia Computer Science* (S1877-0599), 2018, 131: 1238-1246.
- [15] 郭晨露. 西安某商城冰蓄冷空调负荷预测与多目标优化运行研究[D]. 西安: 西安建筑科技大学, 2018.
Guo Chenlu. Research on load Prediction and Multi-objective Optimization Operation of Ice Storage Air conditioning in a shopping mall in Xi'an [D]. Xi'an: Xi'an University of Architecture and Technology, 2018.
- [16] 赵新玥, 赵文, 陈华. pH 测定检验能力验证及评价新方法的应用[J]. *药物分析杂志*, 2018, 38(3): 545-550.
Zhao Xinyue, Zhao Wen, Chen Hua. Application of a New Method to Test the Ability of pH Determination and Evaluation [J]. *Journal of Pharmaceutical Analysis*, 2018, 38(3): 545-550.
- [17] 刘义才, 刘斌, 石安伟. 区间化随机时延的网络控制系统建模与控制[J]. *系统仿真学报*, 2018, 30(2): 654-663.
Liu Yicai, Liu Bin, Shi Anwei. Modeling and Control of Network Control System with Interval Random Delay [J]. *Journal of System Simulation*, 2018, 30(2): 654-663.
- [18] 陆欣, 沈艳霞, 陈杰, 等. 考虑风力发电随机性的超短期风电功率区间预测研究[J]. *太阳能学报*, 2017, 38(5): 1307-1315.
Lu Xin, Shen Yanxia, Chen Jie, et al. Study on Ultra-Short Term Wind Power Interval Prediction Considering Wind Power Generation Randomness [J]. *Acta Solar Energy Sinica*, 2017, 38(5): 1307-1315.
- [19] 黄银华, 彭建春, 李常春, 等. 马尔科夫理论在中长期负荷预测中的应用[J]. *电力系统及其自动化学报*, 2011, 23(5): 131-136.
Huang Yinhua, Peng Jianchun, Li Changchun, et al. Application of Markov Theory in Medium and Long-term Load Forecasting [J]. *Journal of Power System Automation*, 2011, 23(5): 131-136.
- [20] 景亚平, 张鑫, 罗艳. 基于修正组合模型的青海省城市需水量预测[J]. *自然资源学报*, 2012, 27(6): 1013-1021.
Jing Yaping, Zhang Xin, Luo Yan. Prediction of Urban Water Demand in Qinghai Province Based on Modified Combined Model [J]. *Journal of Natural Resources*, 2012, 27(6): 1013-1021.