

# 基于 BP 神经网络的地铁站厅空调负荷预测

李婷婷<sup>1</sup> 毕海权<sup>1</sup> 王宏林<sup>1</sup> 王晓亮<sup>2</sup> 周远龙<sup>1</sup>

(西南交通大学机械工程学院 成都 610031)<sup>1</sup> (西南民族大学城市规划与建筑学院 成都 610041)<sup>2</sup>

**摘要** 中央空调系统是城市轨道交通系统车站建筑中的重点耗能设备,由于在运营初期其负荷远小于设计负荷、缺乏实时负荷值而无法根据建筑的实际负荷动态调节,导致其目前能耗较大。文中以地铁车站站厅公共区域的空调系统为研究对象,根据空调负荷计算方法,基于 trnsys 系统仿真平台建立负荷计算模型。按照正交试验方法设计的试验方案,采用仿真模拟的方法对显著影响地铁车站站厅空调能耗的因素进行了研究。基于影响因素的显著性大小排序和 BP 神经网络理论建立了空调负荷预测模型。以预测负荷值与实际负荷值误差最小作为目标函数,采用仿真模拟实验数据作为训练样本对模型进行训练。训练过程较为稳定,未出现明显震荡( $R^2=0.99956$ ),预测负荷与模拟负荷的均方根误差变异系数较小(3.6%)。在客流变化、天气变化的情况下对模型进行验证,最大相对误差分别为 9.8257% 和 11.675%。验证结果表明,模型预测精度较高,具有较好的泛化能力,能有效预测地铁车站站厅公共区域空调负荷,可为地铁车站空调控制系统提供依据。

**关键词** 地铁车站, 负荷预测, 方差分析, BP 神经网络

**中图分类号** TP391 **文献标识码** A

## Prediction of Air-conditioning Load in Metro Station Hall Based on BP Neural Network

LI Ting-ting<sup>1</sup> BI Hai-quan<sup>1</sup> WANG Hong-lin<sup>1</sup> WANG Xiao-liang<sup>2</sup> ZHOU Yuan-long<sup>1</sup>

(School of Mechanical Engineering, Southwest Jiaotong University, Chengdu 610031, China)<sup>1</sup>

(Architecture and Urban Planning College, Southwest Minzu University, Chengdu 610041, China)<sup>2</sup>

**Abstract** The central air conditioning system is the emphases energy-consuming equipment in the station building of urban rail transit system. In the initial operational stage, there are many reasons, such as the load of station air conditioning is far less than the designed load, the lack of real-time load value and the inability to dynamically adjust according to the actual load of the building, which lead to the current energy consumption. In this paper, the air conditioning system in public area of metro station hall is taken as the research object. On the basis of the air conditioning load calculation method, load calculation model is established based on TRNSYS system simulation platform. Applying the orthogonal test method to design the test scheme and the simulation method to study the factors that have significant influence on the air conditioning energy consumption of the subway station hall. A load forecasting model for air conditioning system is established based on the significance orders of factors and BP neural network theory. The objective function is to minimize the error between the predicted load and the actual load, and the model is trained by using simulation experimental data as training samples. The training process was relatively stable and there was no obvious shock ( $R^2=0.99956$ ). The variance coefficient of root mean square error between predicted load and simulated load is small (3.6%). The maximum relative errors of the model are 9.8257% and 11.675% respectively when the passenger flow and weather change. The validation results indicate that the model has high prediction accuracy and preferably generalization ability, which is an effective method for air conditioning load forecasting in public area of metro station hall, and can provide basis for air conditioning control system of Metro station.

**Keywords** Metro station, Load forecasting, Variance analysis, BP neutral network

地铁车站通风空调系统复杂,具有“多输入、多输出、强耦合”的特点。城市轨道交通系统车站的空调系统需按预测的远期客流量和最大通过能力进行设计<sup>[1]</sup>,在运营初期客流量远小于设计客流量,由此会造成通风空调系统大量的冷量浪费。

目前,关于地铁车站通风空调系统的节能研究主要集中在 PID 变频控制方面。魏渊诚<sup>[2]</sup>以上海地铁黄陂南路站为例,设定不同模式的站厅温度、湿度、二氧化碳浓度,并根据其

变化运用 PID 控制器实时控制空调箱和风机。尹奎超等<sup>[3]</sup>根据 ASHARE 提出的相对热指标(RWI)计算了对天津地铁站的空调运行控制温度随室外温度的变化趋势,研究发现跟随室外气象条件变化调整室内参数可以保证空调舒适且节能。唐敏<sup>[6]</sup>根据地铁既有的综合监控系统统计出某一时段的客流量及所需新风量,并将其输入 PID 控制器调节所需空调冷负荷及风量。考虑到地铁车站公共区域实际所需冷量受环

本文受国家重点研发计划先进轨道交通专项(2017YFB1201105)资助。

李婷婷(1994-),女,硕士生,主要研究方向为地铁车站空调系统节能;毕海权 男,博士,教授,主要研究方向为建筑节能、高速列车空气动力学、隧道通风及火灾,E-mail: bhquan@163.com(通信作者)。

境温度、客流等多重因素影响,仅根据室内温度或湿度等单个影响因素对空调系统进行调节,存在调控不准确的问题。

人工神经网络基于人体神经网络系统,由 McCulloch 等<sup>[7]</sup>在 1943 年首次提出。神经网络作为一种数学工具,有多种用途:分类、数据挖掘、预测、模式识别、函数优化等<sup>[9]</sup>。国内外运用人工神经网络等智能控制方法对空调系统进行热控制的研究多集中于办公建筑。Abdullatif 等<sup>[10]</sup>将外界 24 h 的温度作为神经网络的输入,将第二天的每小时冷负荷作为输出,并与 ESP-r 软件计算的逐时负荷进行比较,结果表明神经网络用于空调负荷预测领域是可行的。Neto 等<sup>[11]</sup>用 ANN 对巴西圣保罗大学某行政楼的能耗进行预测,并将预测结果与在 EnergyPlus 中建立的物理模型进行对比,结果表明人工神经网络适用于能耗预测。Kang 等<sup>[12]</sup>利用人工神经网络对采用 VRF 系统的韩国首尔某办公楼的制冷负荷进行预测,结果表明通过合理的输入参数可得到较高精度的空调系统制冷负荷预测值。Li 等<sup>[13]</sup>用 ANN(人工神经网络)和 GA-ANFIS(基于遗传算法的自适应网络模糊推理系统)两种模型分别对浙江大学某图书馆的建筑能耗进行预测,结果表明 GA-ANFIS 模型的精度高于 ANN。

为实现对地铁车站站厅公共区域空调冷负荷的实时预测,本文采用 BP 神经网络与方差分析相结合的方法,以 trn-sys 模拟成都某地铁站全年冷负荷数据为基础,对地铁车站站厅空调冷负荷及其影响因素进行研究,旨在为地铁车站空调控制系统提供依据。

## 1 物理模型

在地铁车站通风空调系统中,通常将站台、站厅层公共区通风空调系统称为大系统,设备管理用房通风空调系统称为小系统。大系统空调负荷主要由 6 部分组成(见图 1):人体散热、散湿负荷,围护结构散热、散湿负荷,照明负荷,新风负荷,出入口空气渗透负荷,车站公共区设备发热负荷。其中,照明负荷和设备负荷基本不随时间变化而改变,人员负荷和

新风负荷随客流变化较大。




图 1 车站站厅负荷组成

## 2 负荷预测方法

人工神经网络(ANN)的反向传播(Back Propagation)训练算法是一种迭代梯度算法<sup>[14]</sup>,用于求解前馈网络的实际输出与期望输出的最小均方差值。BP 神经网络是一种反向传递并能修正误差的多层映射网络,具有自学习能力和一定的推广能力,目前被广泛运用于空调负荷预测中。

### 2.1 输入参数

地铁车站大系统负荷可以看成是车站建筑系统在外扰(室外气象条件波动)和内扰(站厅内灯光、人员、设备等发热)综合作用下的系统输出。理论上,任何影响负荷的因素均可作为神经网络的输入因素。一般地,输入信息越多,神经网络非线性映射能力越强,预测准确度越高,但这也将增加计算机的求解时间。本文采用正交试验结合方差分析的方法,根据地铁车站的实际情况选择合理的输入参数。假定 3 个外部环境因素(室外空气温度、室外空气相对湿度、太阳辐射)、3 个室内热扰参数(人员数量、设备发热量、灯光发热量)这 6 个因素相互独立、互不影响,另设一列空白列,故选用 L18(3<sup>7</sup>)型的正交表,共有 18 组试验。室外空气温度、室外空气相对湿度、太阳辐射值均根据各组试验工况选择北京、成都、广州三地的数值,客流变化均根据各组试验工况选择北京地铁 1 号线、5 号线和八通线的人流量数值,表 1 中各项参数的取值均以地名代替。方差分析法所得计算结果如表 2 所列。

表 1 正交试验表

试验号	A 室外空气温度/℃	B 室外空气相对湿度/%	C 太阳辐射强度/(W/m <sup>2</sup> )	D 客流变化/个	E 设备发热量/kW	F 灯光发热量/kW	G 空白	总负荷/kW
1	成都	成都	成都	北京地铁 1 号线	106.29	192.44	1	1656014
2	成都	北京	北京	北京地铁 5 号线	53.15	96.22	2	504033
3	成都	广州	广州	北京地铁八通线	35.43	64.15	3	312828.5
4	北京	成都	成都	北京地铁 5 号线	53.15	64.15	3	863817.1
5	北京	北京	北京	北京地铁八通线	35.43	192.44	1	434942.2
6	北京	广州	广州	北京地铁 1 号线	106.29	96.22	2	1600806
7	广州	成都	北京	北京地铁 1 号线	35.43	96.22	3	2985184
8	广州	北京	广州	北京地铁 5 号线	106.29	64.15	1	1333698
9	广州	广州	成都	北京地铁八通线	53.15	192.44	2	1291330
10	成都	成都	广州	北京地铁八通线	53.15	96.22	1	343090.8
11	成都	北京	成都	北京地铁 1 号线	35.43	64.15	2	836883.9
12	成都	广州	北京	北京地铁 5 号线	106.29	192.44	3	1091727
13	北京	成都	北京	北京地铁八通线	106.29	64.15	2	434805.2
14	北京	北京	广州	北京地铁 1 号线	53.15	192.44	3	1235021
15	北京	广州	成都	北京地铁 5 号线	35.43	96.22	1	818591.5
16	广州	成都	广州	北京地铁 5 号线	35.43	192.44	2	2081431
17	广州	北京	成都	北京地铁八通线	106.29	96.22	3	916011
18	广州	广州	北京	北京地铁 1 号线	53.15	64.15	1	2686422

注:客流变化取值参考王凯<sup>[15]</sup>统计分析的北京轨道交通线路客流时间分布特征图;气象数据采用 trn-sys 中相应地区的天气文件值

从表 2 可知,室外空气温度、客流变化对总负荷影响都较为显著,但其影响程度大小有较大差异。按影响作用的大小排序,依次为:客流变化( $P=0.000713, P<0.05$ )>室

外空气温度( $P=0.000739, P<0.05$ )>室外空气相对湿度( $P=0.00735, P<0.05$ )>太阳辐射强度( $P=0.04, P<0.05$ )。而设备发热量  $P=0.422$ , 灯光发热量  $P=$

0.087,均大于0.05,可见设备发热量、灯光发热量对总负荷不具有显著影响。

表2 方差分析数据结果

因变量:总负荷源	III型平方和	自由度 $df$	均方	$F$	显著性
校正模型	10 191 088 187 729.840 <sup>a</sup>	14	$7.28 \times 10^{11}$	60.961	0.003 001 744
截距	$2.55 \times 10^{13}$	1	$2.55 \times 10^{13}$	2135.972	0.000 022 302
室外空气温度	$4.34 \times 10^{12}$	2	$2.17 \times 10^{12}$	181.894	0.000 739 705
室外空气相对湿度	$9.12 \times 10^{11}$	2	$4.56 \times 10^{11}$	38.167	0.007 353 434
太阳辐射强度	$2.70 \times 10^{11}$	2	$1.35 \times 10^{11}$	11.321	0.040 019 685
客流变化	$4.45 \times 10^{12}$	2	$2.23 \times 10^{12}$	186.398	0.000 713 270
设备发热量	$2.78 \times 10^{10}$	2	$1.39 \times 10^{10}$	1.166	0.422 146 533
灯光发热量	$1.46 \times 10^{11}$	2	$7.29 \times 10^{10}$	6.105	0.087 592 292
空白	$4.00 \times 10^{10}$	2	$2.00 \times 10^{10}$	1.677	0.324 452 360
误差	$3.58 \times 10^{10}$	3	$1.19 \times 10^{10}$		
总计	$3.57 \times 10^{13}$	18			
校正的总计	$1.02 \times 10^{13}$	17			

因此,选取室外空气温度、室外空气相对湿度、人员数量、太阳辐射作为神经网络输入参数。考虑室外温度对系统负荷的延迟作用,通过反复测试模型,选取  $t, t-1, t-2, t-3$  时刻的实测室外空气温度值、相对湿度值同时作为输入。历史数据也可提高神经网络训练的速度和精度,因此附加前一日  $t$  时刻的室外温度值和对应空调冷负荷值作为输入参数。

## 2.2 其他参数的设置

隐含层及其神经元数量的选取对构建神经网络有重要影响,神经元个数太少可能导致 BP 神经网络无法训练,即网络容错性差,无法充分学习,从而影响负荷预测效果,称为“欠拟合”;神经元个数太多可能导致训练时间过长,神经网络结构联想能力降低,称为“过拟合”。本文采用 Kolmogorov 提出的隐含层节点数选取方法( $N=2n+1$ ( $n$  为输入层节点数)),设置隐含层节点数为 25 个。

训练目标是使负荷误差最小,则目标函数为:

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

其中,  $y_i$  为  $i$  时刻的空调负荷预测值,  $\hat{y}_i$  为  $i$  时刻的空调负荷实际值。

传递函数(激励函数)用于神经元基于输入计算输出,可以将多个线性输入转换为非线性的关系。由于预测输出的空调冷负荷可能为 0,因此输出层传递函数不能为 s 型函数,经多次试验确定当隐含层、输出层传递函数都为双极 s 型函数时,预测效果较好。

训练函数和学习函数是基于误差来修改权值和阈值的。通过比较各种训练函数可知,当传递函数、隐含层节点数相同时,采用 Levenberg-Marquardt 算法的均方误差最小。综合考虑训练时间和训练精度,选取  $t_r = 0.01$  作为本次神经网络模型的学习率。

## 3 案例研究

### 3.1 数据获取与预处理

Trnsys 中的 TRNBuild 子程序用于建筑参数输入,本文模型中的建筑参数参照成都地铁某站,该站为采用屏蔽门系统的地下两层标准岛式站台车站。围护结构材料及热物性参数均按说明设定。考虑到模拟的可行性,做如下假设:(1)地铁内部各点温度趋于均匀;(2)忽略地铁内部热容影响。模拟条件如表 3 所列。

表3 模拟条件

项目	输入
模拟软件	Trnsys 16
模拟地点	成都
车站土建尺寸(站厅)/m	长 385,宽 35,高 6.5
空调设备开启时间	6:00-24:00
空调设计条件	温度 29℃,湿度 60%
屏蔽门漏风量/h	0.6761
照明发热量/kw	192.44
设备发热量/kw	106.29

选用宋扬<sup>[10]</sup>“基于人流密度的北京地铁车站节点设计调查研究”一文中对地铁车站人流变化的数据,将 trnsys 能耗模拟软件的时间步长设置为 5 min,即每个数据间隔 5 min。保持人员全天变化规律不变,修改人数多少,将模拟数据导出。共导出 3 种不同人数下车站全年的空调冷负荷,选取空调整节(5-10 月中旬)的运行数据。室外空气干球温度、室外空气相对湿度、太阳辐射数据采用 trnsys 软件气象参数集标准年数据。

由于 trnsys 的气象数据通过插值得到,时间步长太小可能导致数据偏差。某数据与其相邻两组数据及前后两天同时刻数据的相对误差超过 150%时,则视为异常数据。通过对数据进行预处理,剔除异常数据,用该点附近可靠数据插值代替,以消除偏差。为提高神经网络训练速度,删除夜间设备关闭时对应的数据。

### 3.2 训练过程

应用 matlab 编程将剩余 108 807 组数据归一化后作为 BP 神经网络的训练样本,其中 107 807 组数据作为训练样本,1 000 组数据作为测试样本。选用  $R^2$  和 ASHRAE Guideline 14-Measurement of energy savings 中的 CVRMSE(均方根误差变异系数)作为评价神经网络训练结果的指标, $R^2 \geq 0.8$  且  $CVRMSE \leq 30\%$  时认为预测结果可接受。

训练样本部分输入参数的取值范围如表 4 所列。

表4 神经网络训练样本部分输入参数的取值范围

类别	变化范围
室外空气干球温度/℃	1.41~36.01
室外空气相对湿度/%	35~94.87
人员数量/个	64~2978
新风量/(kg/s)	0~19.7
$t-24$ 时刻冷负荷/kW	0~599.49

在仿真过程中发现,去掉输入参数中对冷负荷影响较小

的太阳辐射可提高预测精度,故本案实际训练的神经模型输入参数为室外空气温度、室外空气相对湿度、人员数量、新风量及其历史数据。神经网络模型的结构图如图 2 所示。




图 2 神经网络结构图

利用 matlab 编写程序对样本进行训练。神经网络参数设置为:隐含层节点数为 25,学习率为 0.01,迭代次数为 10000 次,目标误差为 0.0000001。训练界面、误差下降曲线、总体回归曲线如图 3 所示。神经网络经过学习训练后,将预测值反归一化还原为原始值。

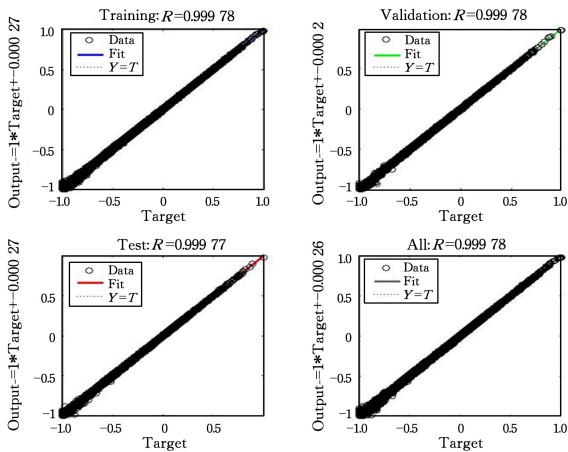


图 3 训练、验证、测试、总体数据回归曲线

由图 3 可见,求解过程较为稳定,未出现明显振荡,实际训练 1122 次,训练、误差为  $4.80 \times 10^{-5}$ ,  $R^2 = 0.99956 > 0.8$ ,已达到仿真所要求的精度。

### 3.3 验证与评价

网格训练结束后对模型进行验证,以判断训练得到的模型是否可用。调用 sim 函数,对 1000 组测试数据进行预测,预测值与实际值的拟合情况如图 4 所示,横坐标为第  $n$  个输入数据,代表某具体时间点,纵坐标为该时间点对应的冷负荷。




图 4 1000 组验证数据的预测值与实际值的拟合情况

从图 4 中看出,实际值与预测值的拟合情况较好,且呈现出与实际值相似的跟随性,说明建立的模型精度较高。

预测负荷与模拟负荷的  $CVRMSE$  值为  $3.6\% < 30\%$ ,说明该神经网络预测模型的效果较好。鉴于地铁站负荷受内外环境变化影响较大,改变环境参数对负荷进行预测以验证负荷预测模型的适应性。

#### 3.3.1 客流变化

保持灯光、设备负荷不变,更改车站人员数量,模拟车站客流发生变化的情况,使用训练好的神经网络对车站 7 月空调冷负荷进行预测(7 月 1 日—7 月 31 日,共 26213 组数据),预测值和实际值的拟合效果如图 5 所示。预测值与实际值的相对误差曲线如图 6 所示。由相对误差曲线可知,最大相对误差不超过  $9.8257\%$ ,绝大多数预测值与实际值的相对误差在  $5\%$  以内。




图 5 更改人数后,预测值与实际值的拟合情况




图 6 更改人数后,预测值与实际值的相对误差

当模拟客流发生变化时,预测值与实际值的差值对应的数据量及相应  $CVRMSE$  值如图 7 所示。 $98\%$  的数据预测值与实际值的差值在  $-5 \sim 10$  kW 之间,且对应的  $CVRMSE$  较小。

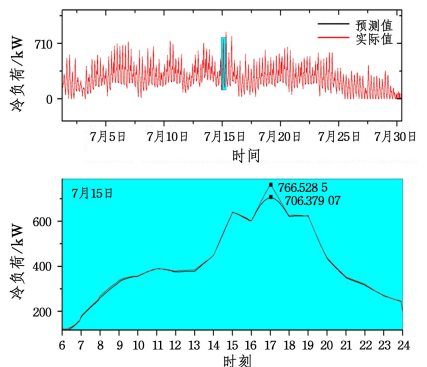


图 7 客流变化时,各误差区间对应的  $CVRMSE$  值

#### 3.3.2 天气变化

保持灯光、设备负荷、车站人员数量不变,更改气象参数(更换为成都地区天气文件数据),模拟车站室外气象环境发生变化的情况。使用训练好的神经网络对车站 7 月的空调冷负荷进行预测,全月预测值和实际值的拟合效果及 7 月 15 日单日的拟合情况如图 8 所示。




图8 更改室外环境参数后,预测值与实际值的拟合情况

通过对7月15单日的负荷预测值与实际值进行分析可知:全天拟合情况较好,仅在17:00出现负荷峰值时,预测值与实际值的差值为60.14988kW,相对误差为7.847%,也在工程可接受范围内。计算全月预测值与实际值相对误差可知,最大相对误差为11.675%,绝大多数预测值与实际值的相对误差在8%以内。




图9 天气变化时,各误差区间对应的CVRMSE值

分析各误差区间对应的CVRMSE值可知:虽然有极少数预测值与实际值的差值大于20kw,但大量预测值与实际值的差值集中在-5~10kw之间,且CVRMSE值均小于30%。较客流发生变化时对应的预测情况而言,室外环境发生变化后,神经网络对冷负荷的预测情况稍显不足。这符合方差分析中,室外空气温度和室外空气相对湿度对空调冷负荷影响较客流变化对其影响更为显著的特征。

**结束语** 目前,地铁地下车站空调系统负荷计算多采用经验公式,本文利用神经网络理论对空调负荷进行预测可在实际工程应用中作为计算负荷的验证。在神经网络输入参数的选取上,引入了数值分析相关方法,以提高常规BP神经网络在地铁车站空调负荷预测中的适配度。

为建立一套地铁车站站厅空调负荷预测模型,本文以实际工程项目为基础,分析选取了对站厅空调冷负荷影响较大的因素作为神经网络的输入参数,利用trnsys能耗软件对该站的站厅空调负荷相关数据进行仿真,利用仿真数据对神经网络进行训练和测试。

(1)对影响地铁车站站厅负荷的因素进行正交实验和方差分析,各因素对车站站厅负荷按影响作用的大小排序依次为:客流变化( $P=0.000713, P<0.05$ )>室外空气温度( $P=0.000739, P<0.05$ )>室外空气相对湿度( $P=0.00735, P<0.05$ )>太阳辐射强度( $P=0.04, P<0.05$ )。而设备发热量、灯光发热量对总负荷不具有显著影响。

(2)测试试验表明,本文的预测模型对地铁车站站厅空调负荷特性的辨识能力较好,训练 $R^2$ 达到0.99956,CVRMSE=3.6%。更换测试条件后,CVRMSE依然小于30%,说明该

预测模型能及时根据外界条件变化跟踪预测所需空调冷负荷,且具有较好的泛化能力。本研究为下一步利用该模型对系统进行预测控制打下基础,对地铁车站公共区域通风空调系统节能控制具有积极作用。

(3)由于缺少实测数据,将能耗软件模拟数据与实际运行数据存在一定差异,若能获得车站实际运行负荷情况及对应的气象数据,能进一步提高预测精度。

## 参考文献

- [1] GB50157-2013 地铁设计规范[M].北京:中国建筑工业出版社,2014.
- [2] 魏渊诚.上海轨交车站机电设备的智能节能控制研究[J].消防界(电子版),2017(9):121-126.
- [3] 尹奎超,由世俊.对天津地铁站空调运行控制温度的探讨[J].山东建筑大学学报,2008,23(5):466-470.
- [4] 梁星,张九根,陈大鹏.变水量系统Smith-模糊PID复合控制方法[J].暖通空调,2018,48(8):101-106.
- [5] ZAKULA T, ARMSTRONG P R, NORFORD L. Modeling environment for model predictive control of buildings[J]. Energy & Buildings, 2014, 85: 549-559.
- [6] 唐敏.基于负荷预测的地铁通风空调系统节能优化方案[J].都市轨道交通,2008,21(4):74-78.
- [7] MCCULLOCH W S, PITTS W. A logical calculus of the ideas immanent in nervous activity. 1943. [J]. Bulletin of Mathematical Biology, 1990, 52(1/2): 99-115.
- [8] 李浩.基于史密斯预估补偿的变风量空调系统性能优化研究[D].西安:西安建筑科技大学,2016.
- [9] BASHEER I A, HAJMEER M. Artificial neural networks: fundamentals, computing, design, and application[J]. Journal of Microbiological Methods, 2000, 43(1): 3-31.
- [10] BEN-NAKHI A E, MAHMOUD M A. Cooling load prediction for buildings using general regression neural networks[J]. Energy Conversion & Management, 2004, 45(13): 2127-2141
- [11] NETO A H, FIORELLI F A S. Comparison between detailed model simulation and artificial neural network for forecasting building energy consumption [J]. Energy & Buildings, 2008, 40(12): 2169-2176.
- [12] KANG I, LEE K H, LEE J H, et al. Artificial Neural Network-Based Control of a Variable Refrigerant Flow System in the Cooling Season[J]. Energy, 2018, 11: 1643.
- [13] LI K, SU H, CHU J. Forecasting building energy consumption using neural networks and hybrid neuro-fuzzy system: A comparative study [J]. Energy & Buildings, 2011, 43 (10): 2893-2899.
- [14] 蔡自兴.人工智能控制[M].北京:化学工业出版社,2005.
- [15] 张伟捷,吴金顺,魏一然,等.基于正交试验法的建筑冷负荷影响因素分析[J].暖通空调,2006,36(11):77-80.
- [16] 王凯.北京地铁客流特征分析[J]. Management Sciences & Engineering, 2014, 3(1): 51-56.
- [17] 全国咨询工程师(投资)职业资格考试参考教材编写委员会.项目决策分析与评价[M].北京:中国计划出版社,2016:440-445
- [18] 赵丹,张九根.基于神经网络预测控制的VAV系统优化控制研究[J].电气应用,2016(12):62-65.
- [19] 宋扬.基于人流密度的北京地铁车站节点设计调查研究[D].北京:北京交通大学,2015.