

文章编号: 1671-6612 (2022) 03-337-09

# PSO 优化 BP 神经网络 对露点间接蒸发冷却空调机组性能预测研究

陈 梦 黄 翔 屈悦滢

(西安工程大学城市规划与市政工程学院 西安 710048)

**【摘 要】** 针对传统机组在设计时的实际运行、优化设计、成本投入等问题, 基于神经网络理论建模的研究方法, 分别建立了 BP 神经网络和 PSO-BP 神经网络两种预测模型, 通过实际工程的测试得到了相关数据, 最后采取理论建模与实测数据相结合的研究手段, 得出了 PSO-BP 神经网络更适合用于解决露点间接蒸发冷却空调机组的性能预测问题的结论, 在同一时刻, BP 神经网络预测的相对误差为 9.6% 时, PSO-BP 神经网络预测的相对误差为 2.21%, 精度提高了 7.39%。

**【关键词】** 露点间接蒸发冷却空调机组; BP 神经网络; PSO 优化 BP 神经网络; 性能预测; 灰色关联分析  
中图分类号 TP183/TU831 文献标识码 A

## Study on Performance Prediction of Dew Point Indirect Evaporative Cooling Air Conditioning Unit Based on BP Neural Network Optimized by PSO

Chen Meng Huang Xiang Qu Yueying

(School of Urban Planning and Municipal Engineering, Xi'an Polytechnic University, Xi'an, 710048)

**【Abstract】** Aiming at the actual operation of traditional unit when the design, optimization design, the problem such as costs, based on the theory of neural network modeling methods, respectively, set up the BP neural network and PSO - BP neural network two prediction model, the relevant data is obtained by actual engineering test, finally take theory modeling and measured data of the combination of research methods, it is concluded that PSO-BP neural network is more suitable to solve the performance prediction problem of dew point indirect evaporative cooling air conditioning units. At the same time, when the relative error of BP neural network prediction is 9.6%, the relative error of PSO-BP neural network prediction is 2.21%, and the accuracy is improved by 7.39%.

**【Keywords】** Dew point indirect evaporative cooling air conditioning unit; BP neural network; PSO optimization BP neural network; Performance prediction; Grey Relation Analysis

基金项目: 2022 年度西安工程大学研究生创新基金项目 (编号: chx2022031)

作者简介: 陈 梦 (1998-), 女, 在读硕士研究生, E-mail: 1348313387@qq.com

通讯作者: 黄 翔 (1962-), 男, 教授, E-mail: huangx@xpu.edu.cn

收稿日期: 2021-08-20

## 0 引言

蒸发冷却空调技术以水作为制冷剂, 最大限度地利用了我国干燥地区丰富的干空气能源, 能有效减少温室气体排放、节约能源<sup>[1]</sup>。作为我国暖通空调行业绿色、环保、节能的关键技术之一, 目前蒸发冷却空调技术已日益成熟并实现了产业化, 已用

于工业建筑、公共建筑、住宅建筑、轨道交通、农业建筑的空调系统中, 可以大大减少峰值的电力消耗和电力需求<sup>[2]</sup>。

露点间接蒸发冷却技术利用一次空气干球温度和露点温度的差值为驱动势, 能有效提高蒸发冷却空调设备的温降。由于其显著的优势, 成为目前

国际上许多专家和学者研究的热点。关于露点间接蒸发冷却性能预测方面还鲜有研究,如何寻找一种简单、快速、高效的性能预测模型已成为研究重点之一。采用神经网络方法的优势在于可以充分模拟预测、规避产品缺陷;降低机组的研发成本、缩短机组研发的周期、增强机组的核心竞争力<sup>[3]</sup>。

### 1 露点间接蒸发冷却空调机组 BP 神经网络分析样本测试数据采集

#### 1.1 中等湿度地区某露点间接蒸发冷却空调机组实测数据采集



图 1 露点间接蒸发冷却机组实物图

Fig.1 Physical map of dew point indirect evaporative cooling air conditioning unit

本项目用的露点间接蒸发冷却空调机组位于陕西省榆林市锦界镇,机组实物图如图 1 所示,机组测点布置图如图 3 所示,测点分别布置在机组的

进风口、排风口、送风口处。其中 1 台机组应用于中控室,面积约 50m<sup>2</sup>/间;2 台应用于电子间,面积约 60m<sup>2</sup>/间,机组风量均为 20000m<sup>3</sup>/h。室内还装有三台机械制冷柜机,作为辅助冷源使用。

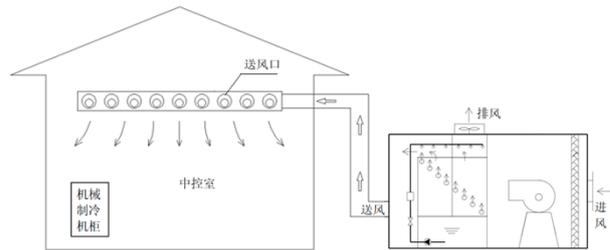


图 2 露点间接蒸发冷却空调系统平面图

Fig.2 Dew point indirect evaporative cooling air conditioning unit system plan

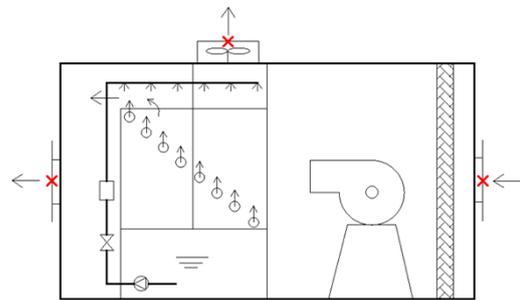


图 3 露点间接蒸发冷却机组测点布置示意图

Fig.3 Dew point indirect evaporative cooling unit measurement point arrangement diagram

表 1 20000m<sup>3</sup>/h 风量机组测试数据 (部分数据)

Table 1 Test data of 20000m<sup>3</sup>/h air volume unit (partial data)

室外环境		进风参数			排风参数		出风参数		温降 °C	湿球效率 %
温度°C	相对湿度%	温度°C	相对湿度%	湿球温度°C	温度°C	相对湿度%	温度°C	相对湿度%		
28.9	41	28.1	41.1	19.1	25.5	67.9	19.7	83.3	8.4	93.33
29.1	38.9	28.3	40.1	19.1	25.3	70.6	19.9	82.6	8.4	91.3
28.7	39	28.1	39.6	18.8	25	71.2	19.9	81	8.2	88.17
28.7	38.7	28.1	40.4	19	24.9	72	19.8	81.1	8.3	91.21
28.8	39.6	28.4	39.7	19.1	25.4	67.1	19.8	81.4	8.6	92.47
28.7	39.2	28.4	39.8	19.1	25.1	72.1	19.9	81.4	8.5	91.4
28.6	38.6	28.4	38.7	18.9	25.1	70	19.8	81	8.6	90.53
28.4	37.7	28.3	38.7	18.8	24.9	69.9	19.7	80.4	8.6	90.53
28.3	37.6	28	37.9	18.4	24.6	69.6	19.4	80.3	8.6	89.58
28.1	39.3	27.8	39.2	18.5	24.7	67.5	19.3	81.2	8.5	91.4

### 1.2 高湿度地区某露点间接蒸发冷却空调机组实测数据采集

本项目用的是在福州地区某公司实验室安装的露点机组<sup>[4]</sup>, 机组实物图如图4所示, 机组测点布置图同样如图3所示, 测点分别布置在机组的进风口、排风口、送风口处。该机组额定风量15000m<sup>3</sup>/h, 对上述机组进行测试, 机组的风口截面积不变, 实测的机组进风迎面平均风速为5.5m/s, 二/一次风量为0.6, 一次风量为6375m<sup>3</sup>/h, 二次风量为3825m<sup>3</sup>/h。部分测试数据如表2所示。



图4 机组实物图

Fig.4 Physical map of the unit

表2 15000m<sup>3</sup>/h风量机组测试数据(部分数据)Table 2 Test data of 15000m<sup>3</sup>/h air volume unit (partial data)

序号	进风干球温度 °C	进风相对湿度 %	总风量 m <sup>3</sup> /h	迎面风速 m/s	一次风量 m <sup>3</sup> /h	二次风量 m <sup>3</sup> /h	二/一次风量比 /	蒸发效率 %
1	31.40	70.42	15000	5.5	6375	3825	0.6	107
2	32.50	69.27	15000	5.5	6375	3825	0.6	116
3	33.60	68.72	15000	5.5	6375	3825	0.6	124
4	34.60	64.92	15000	5.5	6375	3825	0.6	115
5	33.90	61.87	15000	5.5	6375	3825	0.6	102
6	34.60	60.75	15000	5.5	6375	3825	0.6	101
7	35.70	59.43	15000	5.5	6375	3825	0.6	110
8	36.40	58.41	15000	5.5	6375	3825	0.6	107
9	36.30	58.34	15000	5.5	6375	3825	0.6	105
10	36.40	59.87	15000	5.5	6375	3825	0.6	111

### 1.3 干燥地区某露点间接蒸发冷却空调机组实测数据采集

本工程为机场扩建工程子项目, 主要范围为敦煌机场航空配餐中心。总建筑面积2880m<sup>2</sup>, 共2层, 层高4.2m, 机组实物图如图5所示, 共有6台机组<sup>[5,6]</sup>, 机组测点布置图同样如图3所示, 测点分别布置在机组的进风口、排风口、送风口处。该机组额定风量分别为20000m<sup>3</sup>/h、10000m<sup>3</sup>/h, 对上述机组进行测试, 机组的风口截面积不变, 实测的机组进风迎面平均风速分别为6.1m/s、4.7m/s, 二/一次风量比分别为0.56、0.62, 一次风量分别为

11804m<sup>3</sup>/h、4320m<sup>3</sup>/h, 二次风量分别为6610m<sup>3</sup>/h、2680m<sup>3</sup>/h。部分测试数据如表3所示。



图5 机组实物图

Fig.5 Physical map of the unit

表3 10000m<sup>3</sup>/h和20000m<sup>3</sup>/h风量机组测试数据(部分数据)Table 3 Test data of 10000m<sup>3</sup>/h and 20000m<sup>3</sup>/h air volume unit (partial data)

序号	进风干球温度 °C	进风相对湿度 %	总风量 m <sup>3</sup> /h	迎面风速 m/s	一次风量 m <sup>3</sup> /h	二次风量 m <sup>3</sup> /h	二/一次风量比 /	蒸发效率 %
1	36.50	16.20	20000	6.10	11804	6610	0.56	105.00
2	35.80	17.50	20000	6.10	11804	6610	0.56	104.50

续表 3 10000m<sup>3</sup>/h 和 20000m<sup>3</sup>/h 风量机组测试数据 (部分数据)

序号	进风 干球温度 °C	进风 相对湿度 %	总风量 m <sup>3</sup> /h	迎面 风速 m/s	一次风量 m <sup>3</sup> /h	二次风量 m <sup>3</sup> /h	二/一次 风量比 /	蒸发 效率 %
3	36.00	17.60	20000	6.10	11804	6610	0.56	105.93
4	36.20	17.50	20000	6.10	11804	6610	0.56	106.98
5	35.90	17.10	20000	6.10	11804	6610	0.56	103.55
6	23.90	31.20	10000	4.70	4320	2680	0.62	97.06
7	24.70	31.80	10000	4.70	4320	2680	0.62	107.77
8	24.30	31.60	10000	4.70	4320	2680	0.62	107.84
9	24.30	31.50	10000	4.70	4320	2680	0.62	109.80
10	24.20	31.70	10000	4.70	4320	2680	0.62	112.00

## 2 露点间接蒸发冷却空调机组 BP 神经网络性能预测模型研究

### 2.1 BP 神经网络理论基础

#### 2.1.1 BP 神经网络算法介绍

BP 算法包括样本正向、误差反向传播两部分。如图 6 所示, 算法结构分为三部分<sup>[7]</sup>。当网络的结构被确定后, 根据输入、输出数据对网络进行训练, 找到两者之间的关系, 修正隐含层的阈值。

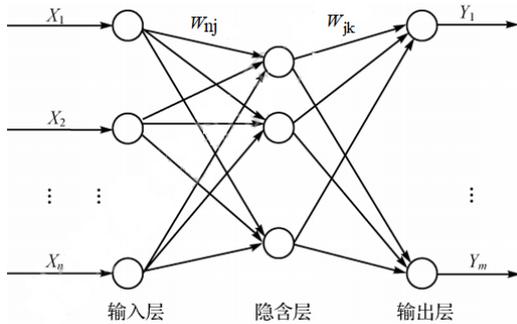


图 6 BP 神经网络拓扑结构图

Fig.6 BP Neural network topology structure diagram

#### 2.1.2 BP 神经网络研究方法

##### (1) 训练样本的选取

训练样本: 本文所研究的机组功能段核心为露点间接段。由于影响机组冷却效率的因素对机组性能产生的影响是非线性的, 同时需要较多的测试数据进行训练, 才能更好地寻找两者之间的规律。因此, 采用机组实测数据作为网络的训练样本, 利用 Matlab 软件建立预测露点蒸发冷却空调机组性能的神经网络模型, 从而利用训练好的神经网络实现对露点蒸发冷却空调机组的蒸发效率进行预测。

##### (2) 输入/输出样本设计

影响露点间接蒸发冷却效率的影响因素很多, 本课题主要研究在机组其他条件不变的情况下, 主要考虑机组进风口干球温度、相对湿度、总风量、迎面风速、一次风量、二次风量、二/一次风量比对机组性能 (蒸发效率) 的影响。为了更有效地进行网络训练, 对训练数据归一化<sup>[8]</sup>, 对网络输出数据进行反归一化。

##### (3) 神经网络的结构设计

输入层包括机组进风口的空气状态参数 (干球温度、相对湿度)、总风量、迎面风速、一次风量、二次风量、二/一次风量比 7 个重要的参数, 由于考虑到多输出参数导致的神经网络参数权重以及参数之间共用最优解的问题, 因此输出层有蒸发效率 1 个参数。网络采用一个隐含层, 隐含层的神经元个数按 Mr. Kawashima 提出的方法选择, 即神经元个数为  $7 \times 2 + 2 = 16$ , 即隐含层神经元个数初始值取 16 个, 通过程序运行过程中采用试凑法得出最佳的隐含层神经元个数为 14。

##### (4) 网络传递及训练函数

隐含层神经元采用对数 S 型正切函数 Tansig, 输出层神经元采用 purelin 函数。为避免 BP 神经网络算法的预测结果陷入局部最优的问题, 学习和训练函数采用 LM 算法的 trainlm 函数。同时还需要设置训练次数 1000 次, 训练误差  $10^{-9}$ , 学习率 0.1。

## 2.2 中等湿度地区某露点间接蒸发冷却空调机组 BP 神经网络性能预测结果分析

本小节对中等湿度地区 (陕西榆林) 露点间接蒸发冷却空调机组性能预测, 测试时间为 2019 年

8 月 1—6 日、每天 9:00—18:00 的实际机组运行的测试数据, 每小时记录一次, 每天 10 组, 共有 60 组测试数据。以 2019 年 8 月 1—5 日每天 9:00—18:00 的测试数据为训练数据, 设置 2019 年 8 月 6 日 9:00—18:00 的数据为预测数据。

由图 7 和图 8, BP 网络对机组蒸发效率的预测值与实测值的变化趋势整体上基本一致。但存在个别数据误差较大的问题, 其中, 在测试样本号为 7 的相对误差较大, 接近 10%。通过对预测结果进行检验与验证, 得到该预测模型蒸发效率的 RMSE 为 3.1367, 决定系数  $r^2$  为 0.9659。

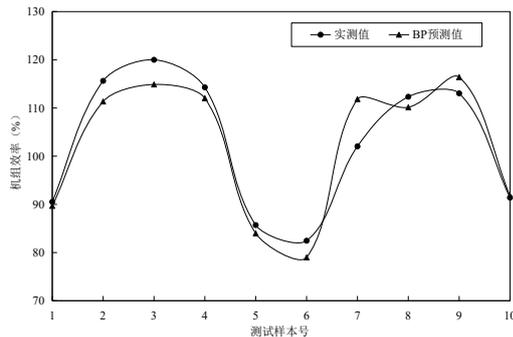


图 7 BP 神经网络对机组蒸发效率的预测结果

Fig.7 BP Neural Network's Forecast Results of Unit

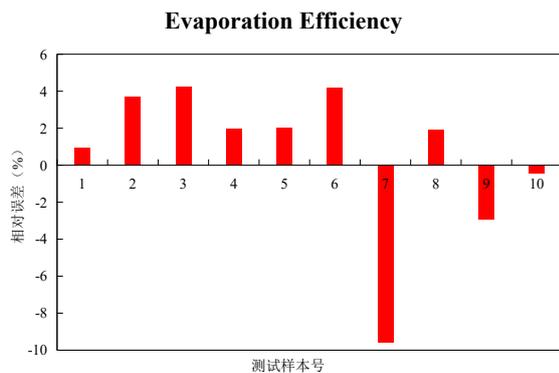


图 8 BP 神经网络对机组蒸发效率的预测相对误差

Fig.8 BP neural network predicts relative error of unit evaporation efficiency

### 2.3 高湿度地区某露点间接蒸发冷却空调机组 BP 神经网络性能预测结果分析

本小节对高湿度地区(福建福州)机组的性能预测方法同上, 并且机组结构相同, 机组测试时间为 2017 年 6 月 23 日、27—30 日, 通过对数据的整理, 选择每天 9:00—18:00 的机组运行的测试数据, 每 30 分钟记录一次, 每天 20 组, 共有 100 组测试数据。以 2017 年 6 月 23 日、27—29 日每天 9:00—18:00 的测试数据为训练数据, 设置 2017 年

6 月 30 日 9:00—18:00 的数据为预测数据。

由图 9 和图 10, BP 网络对机组蒸发效率的预测值与实测值的变化趋势整体上基本一致。但存在个别数据误差较大的问题, 其中, 在测试样本号为 3、10、16 的相对误差较大, 最大的相对误差接近 10%。通过对预测结果进行检验与验证, 得到该预测模型蒸发效率的 RMSE 为 4.6170, 决定系数  $r^2$  为 0.9581。因此可认为, BP 网络能够预测出蒸发效率及其变化趋势。

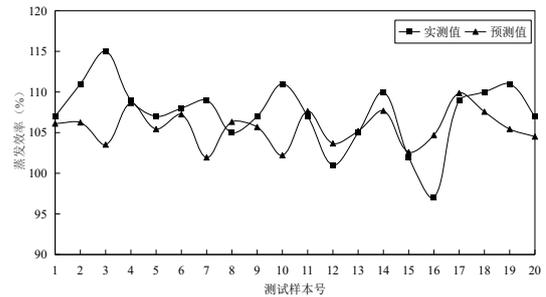


图 9 BP 神经网络对机组蒸发效率的预测结果

Fig.9 BP Neural Network's Forecast Results of Unit Evaporation Efficiency

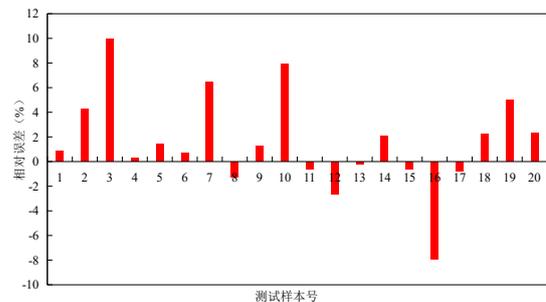


图 10 BP 神经网络对机组蒸发效率的预测相对误差

Fig.10 BP neural network predicts relative error of unit evaporation efficiency

### 2.4 干燥地区某露点间接蒸发冷却空调机组 BP 神经网络性能预测结果分析

本小节对干燥地区(敦煌机场)机组性能预测方法同上, 并且机组结构相同, 机组测试时间为 2018 年 8 月 19—23 日, 通过对数据的整理, 选择每天 9:00—18:00 的机组运行的测试数据, 每 30 分钟记录一次, 每天 20 组, 共有 100 组测试数据。以 2018 年 8 月 19—22 日每天 9:00—18:00 的测试数据为训练数据, 设置 2018 年 8 月 23 日 9:00—18:00 的数据为预测数据。

由图 11 和图 12, BP 网络对机组蒸发效率的预测值与实测值的变化趋势整体上也基本一致。但

同时存在个别数据误差较大的问题，其中，在测试样本号为 4 的相对误差较大，接近 14%。通过对预测结果进行检验与验证，得到该预测模型蒸发效率的 RMSE 为 3.4934，决定系数  $r^2$  为 0.9673。因此可认为，BP 网络能够准确的预测出蒸发效率及其变化趋势。

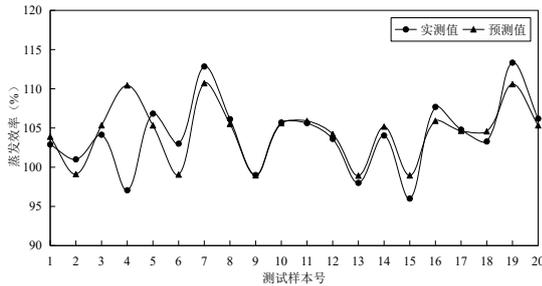


图 11 BP 神经网络对机组蒸发效率的预测结果  
Fig.11 BP Neural Network's Forecast Results of Unit Evaporation Efficiency

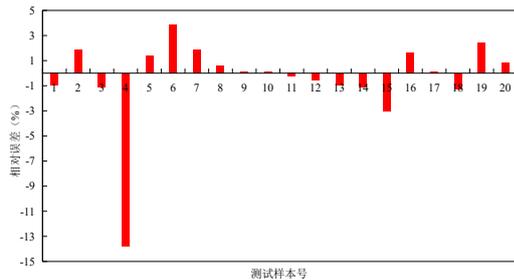


图 12 BP 神经网络对机组蒸发效率的预测相对误差  
Fig.12 BP neural network predicts relative error of unit evaporation efficiency

### 2.5 不同气象条件下露点间接蒸发冷却空调机组 BP 神经网络性能预测结果分析

本文 2.2-2.4 节分别是对不同地区露点间接蒸发冷却空调机组的性能预测，本节神经网络输入输出样本为三个地区的 260 组数据，设置陕西地区 2019 年 8 月 1—2 日 9:00—18:00 的数据为预测值，其他数据均为模型的训练值。

由图 13 和图 14，BP 网络对机组蒸发效率的预测值与实测值的变化趋势整体上是基本一致的。同样存在个别数据误差较大的问题，其中，在测试样本号为 11、12 的相对误差较大，接近 13%。通过对预测结果进行检验与验证，得到该预测模型蒸发效率的 RMSE 为 6.4157，决定系数  $r^2$  为 0.9381。因此可认为，BP 网络能够准确的预测出机组蒸发

效率及其变化趋势。

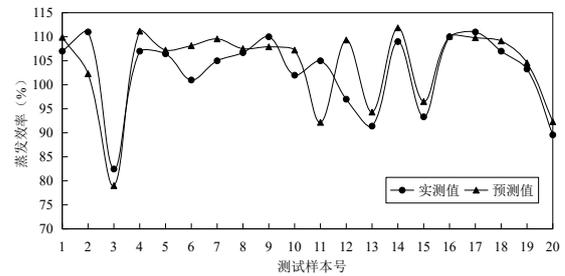


图 13 BP 神经网络对机组蒸发效率的预测结果  
Fig.13 BP Neural Network's Forecast Results of Unit Evaporation Efficiency

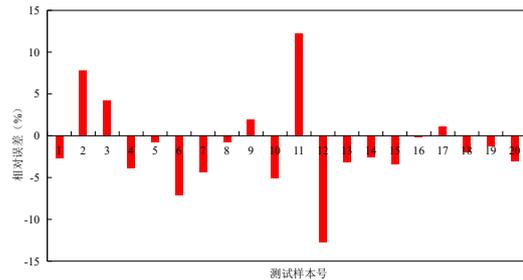


图 14 BP 神经网络对机组蒸发效率的预测相对误差  
Fig.14 BP neural network predicts relative error of unit evaporation efficiency

由表 4 可得，对于 BP 神经网络在不同气象条件下露点间接蒸发冷却空调机组的预测，决定系数  $r^2$  均在 0.9 以上，表明所搭建的模型具有一定的稳定性。均方根误差 RMSE 平均为 4.4157。

表 4 BP 神经网络对不同气象条件露点间接蒸发冷却空调机组蒸发效率的预测结果对比

Table 4 Comparison of prediction results of BP neural network on the evaporation efficiency of indirect evaporative cooling air conditioning units with dew point in different meteorological conditions

地区	决定系数 $r^2$	均方根误差 RMSE
中等湿度地区	0.9659	3.1367
高湿度地区	0.9581	4.6170
干燥地区	0.9673	3.4934
不同气象条件	0.9381	6.4157

### 2.6 输入变量对输出变量影响程度分析

#### 2.6.1 灰色关联分析方法理论基础

灰色关联分析是一种多因素统计方法，衡量各个因素间的关联度，适用于动态过程分析<sup>[9]</sup>，可以弥补数理统计方法的不足，具有很强的适用性。该

方法通过对数据进行量化, 计算量小, 非常方便, 因此灰色关联分析的结果不会与定性结果矛盾。本文采用该方法来实现多个因素对结果影响程度的分析。

### 2.6.2 输入变量对输出变量影响程度结果分析

采用 Matlab 来实现输入变量与输出变量之间的关联度分析。得到的关联度如表 5 和图 15 所示,

表 5 关联度的计算结果

Table 5 Calculation result of relevance

比较数列 X	进风干球温度 °C	进风相对湿度 %	总风量 m <sup>3</sup> /h	迎面风速 m/s	一次风量 m <sup>3</sup> /h	二次风量 m <sup>3</sup> /h	二/一次风量比 /
关联度 <i>r</i>	0.7687	0.5885	0.6879	0.7717	0.5605	0.5657	0.8258

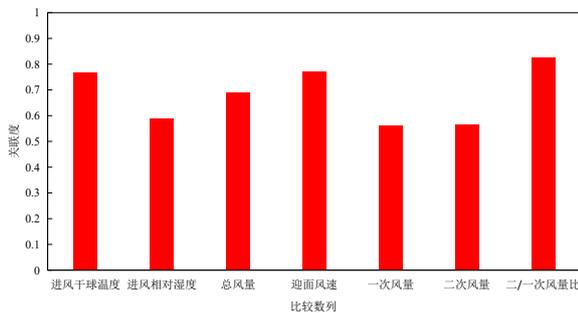


图 15 关联度结果图

Fig.15 Relevance result graph

通过比较 7 个输入变量与输出变量关联度的大小可以看出: 二/一次风量比>迎面风速>进风温度>总风量>相对湿度>二次风量>一次风量。

因此得出结论: 输出变量蒸发效率受到输入变量二/一次风量比的影响最大。二次风量的影响虽然是最小的, 但是关联度为 0.5657>0.5, 因此也是重要的参数。

型的输入层神经元数为 7、隐含层神经元数为 14、输出层神经元数为 1, 因此可得  $D=127$ 。

### (2) 确定粒子种群规模 $N$

$N$  与该算法的计算量和全局寻优能力有很大关系,  $N$  越大, 参与搜索的粒子数越多, 所以算法全局寻优能力越强。  $N$  过大也会导致其计算时间呈现指数式增长。  $N$  过少会使全局信息减少从而易陷入局部最优。  $N$  的增长不与搜索能力成正比<sup>[10]</sup>。一般来说, 经验参数值多在 [20, 80]。 综上,  $N$  取 50。

## 3 露点间接蒸发冷却空调机组 PSO 优化 BP 神经网络性能预测模型研究

### 3.1 PSO-BP 模型的构建

由于第 2 节所建立的 BP 神经网络模型预测效果具有较好的稳定性, 在不同气象条件下(陕西、福建、甘肃)的预测效果差别不大, 因此本节将建立的 PSO-BP 神经网络预测模型仅应用在陕西榆林, 即本节采用的数据为第 1.2 节露点间接蒸发冷却空调机组的实测数据。训练数据和预测数据的设置同 2.2 节。

PSO 优化 BP 神经网络模型是对网络的阈值、权值进行不断更新的一个过程, 通过构建合适的网络结构来对机组的蒸发效率进行预测。网络的结构设计同 2.1 节。优化算法的流程图如图 16 所示。

#### (1) 确定粒子的维度

$$D = m \times n + n \times l + n + l \quad (1)$$

式中:  $m$  为输入层神经元数;  $n$  为隐含层神经元数;  $l$  为输出层神经元数。

根据公式 (1), 由 2.1 节可知 BP 神经网络模

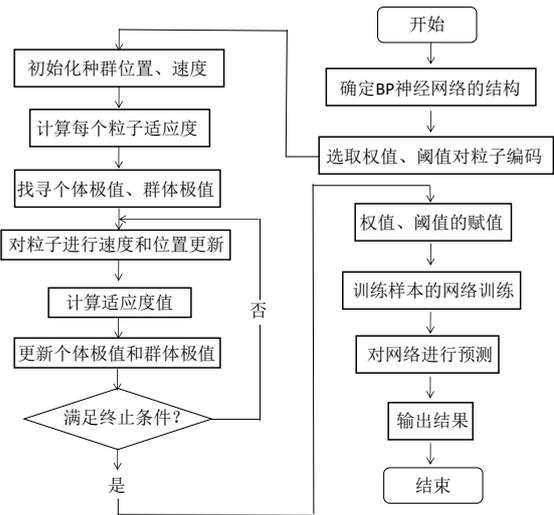


图 16 PSO 优化 BP 神经网络模型的流程图

Fig.16 Flow chart of PSO optimized BP neural network model

#### (3) 确定学习因子 $C_1$ 和 $C_2$

一般情况下  $C_1$  和  $C_2$  为非负常数。 PSO 算法的两个学习因子代表的是单个粒子的认知能力与整个群体的信息交换能力,  $C_1$  和  $C_2$  可以确定粒子在

整体信息扩展和自我认知学习之间的关系, 决定粒子的搜索轨迹。 $C_1$  和  $C_2$  越大越容易让算法快速达到最优解范围, 若  $C_1$  和  $C_2$  过大, 解会在最优解中徘徊, 不能获取最优; 过小则会导致算法缓慢, 得不到最优解。一般经验取值在 $[0, 4]$ 。

因此本节在建立 PSO 优化 BP 神经网络算法时, 设定  $C_1=C_2=2$ 。

(4) 确定惯性权重  $\omega$

$\omega$  表示粒子在每次迭代前的惯性, 不断寻找最优解。 $\omega$  越大粒子移动速度越大, 搜索速度变快, 在全局的寻优能力越强, 有时候会使算法无法收敛, 因此就需要进行合理的取值。 $\omega$  越小粒子的移动速度越慢, 可能会导致算法的局部收敛。可以分为固定和时变两类, 前者的值是固定的, 而后者可以针对实际情况自动进行及时的调整, 在一定程度上能够提高算法准确性。由于其弊端是在高维度粒子群里, 运行速度减慢。因此本节选用固定权重。一般经验取值  $\omega$  范围为 $[0.8, 1.2]$ , 所以取  $\omega=1$ 。

(5) 确定粒子的搜索范围和速度范围

粒子的搜索能力与速度范围、搜索范围相关。搜索范围越大, 算法的精度越高, 但是运行速度会越低。搜索范围越小, 运行速度加快, 陷入局部最小解。由于 BP 神经网络的权值、阈值的范围为 $[0, 1]$ , 所以设置 PSO 的搜索范围和速度范围也为 $[0, 1]$ 。

(6) PSO-BP 模型输入参数的确定

根据对影响蒸发效率的影响因素考虑, 本节依然选取机组进风口干球温度、相对湿度、总风量、迎面风速、一次风量、二次风量、二/一次风量比这 7 个参数作为 PSO-BP 神经网络的输入变量, 神经网络的输出变量为机组的蒸发效率。

3.2 PSO-BP 神经网络模型预测结果分析

3.2.1 PSO-BP 神经网络模型预测结果

利用采集并处理过的测试数据对优化后的网络进行训练和测试分析, 以此来验证优化后网络的预测效果。图 17、图 18 分别为两者的预测结果、相对误差, 可以看出, PSO-BP 神经网络对机组蒸发效率的预测值与测试变化趋势基本一致, 且两者的数据较为接近, 不存在个别数据误差较大的问题, 最大相对误差 2.48%。

通过对该 PSO-BP 神经网络的预测结果进行检验与验证, 得到该预测模型蒸发效率的 RMSE

为 1.102, 决定系数  $r^2$  为 0.9745。因此可认为, 本节所建立的 PSO-BP 神经网络模型精度相对较高, 该 PSO-BP 神经网络能够准确预测蒸发效率及其变化趋势。

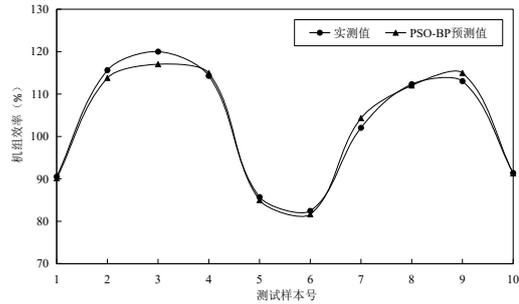


图 17 PSO-BP 神经网络的预测结果图

Fig.17 PSO-BP neural network prediction result map

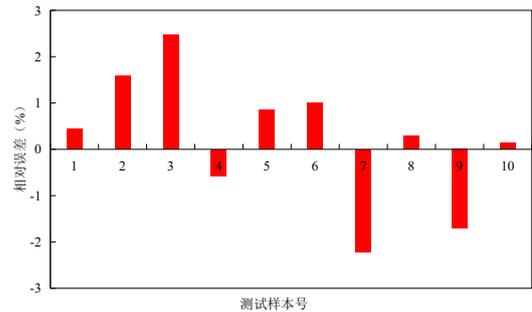


图 18 PSO-BP 神经网络预测相对误差

Fig.18 PSO-BP Neural network predicts relative error

3.2.2 BP、PSO-BP 神经网络模型预测结果对比分析

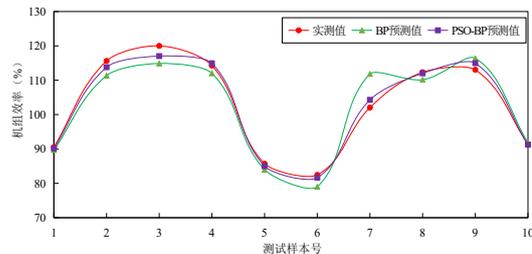


图 19 BP、PSO-BP 神经网络的预测结果对比图

Fig.19 Comparison chart of prediction results of BP and PSO-BP neural network

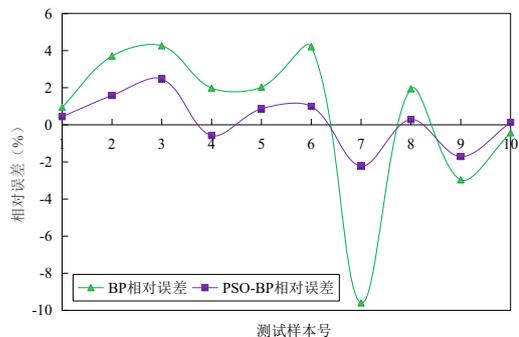


图 20 BP、PSO-BP 神经网络预测相对误差对比

**Fig.20 Comparison of relative error of BP and PSO-BP neural network prediction**

图 19 为 BP 神经网络和优化后的 PSO-BP 神经网络预测露点间接蒸发冷却空调机组蒸发效率的结果对比图,可以看出,优化后的模型预测曲线与实测值更接近,没有出现太大的误差波动点,预测精度明显要比 BP 神经网络好。

从图 20 和表 6 可以明显看出,优化后模型的相对误差整体较优化前的 BP 神经网络小,因此可以用于预测露点间接蒸发冷却空调机组的蒸发效率。且在同一时刻,优化前的 BP 神经网络相对误差为 9.6%,优化后仅为 2.21%,准确度有效提高了 7.39%。

表 6 BP、PSO-BP 神经网络预测结果对比

Table 6 Comparison of prediction results of BP and PSO-BP neural network

序号	测试时间 h	实测值 %	BP 预测值 %	PSO-BP 预测值 %	BP 相对误差 %	PSO-BP 相对误差 %
1	9:00	90.53	89.68	90.13	0.94	0.44
2	10:00	115.63	111.34	113.8	3.71	1.58
3	11:00	120	114.89	117.03	4.26	2.48
4	12:00	114.29	112.03	114.95	1.98	-0.58
5	13:00	85.71	83.97	84.97	2.03	0.86
6	14:00	82.46	78.99	81.64	4.21	0.99
7	15:00	102.04	111.84	104.3	-9.60	-2.21
8	16:00	112.33	110.15	112.01	1.94	0.28
9	17:00	113.04	116.39	114.97	-2.96	-1.71
10	18:00	91.4	91.79	91.28	-0.43	0.13

#### 4 结论

(1) 数据的采集:从三个不同地区整理的测试数据来看,机组送风参数均满足室内送风要求,说明应用露点间接蒸发冷却空调机组能保证室内空气调节要求。采集到了可供分析应用的基础数据,为神经网络预测和对比奠定基础。

(2) 参数的选取:在机组其他条件不变的情况下,仅考虑机组进风参数干球温度、进风相对湿度、总风量、迎面风速、一次风量、二次风量、二/一次风量比 7 个重要参数对机组蒸发效率的影响。采用灰色关联分析方法,得出蒸发效率受到二/一次风量比的影响最大,受到二次风量的影响最小,但关联度为  $0.5657 > 0.5$ ,因此也是重要的参数。

(3) 模型的研究:虽然 BP 神经网络对机组蒸发效率的预测结果在可接受的范围内,预测结果与实测数据虽然规律相近,但是有个别点存在误差过大的问题,因此必须对该模型进行改进。

(4) 模型的优化:实验表明 PSO 算法优化后的 BP 神经网络预测模型在预测准确度和精度上都优于 BP 神经网络预测模型。在同一时刻, BP

神经网络预测的相对误差为 9.6%时, PSO-BP 神经网络预测的相对误差为 2.21%,精度提高了 7.39%。

#### 参考文献:

- [1] 武俊梅.蒸发冷却空调技术在节能减排中的重要作用[J].制冷与空调,2008,(4):17-20.
- [2] 黄翔.蒸发冷却空调理论与应用[M].北京:中国建筑工业出版社,2010.
- [3] 黄童毅,何林,郭庆,等.基于BP神经网络的空调性能预测研究[J].环境技术,2019,37(4):100-103,114.
- [4] 王文博.露点蒸发冷却空调机组在干燥地区的优化设计及应用研究[D].西安:西安工程大学,2018.
- [5] 黄凯新,黄翔,严政,等.复合式露点间接蒸发冷却空调机组在敦煌机场某食堂的应用[J].制冷与空调,2019,19(3):46-50.
- [6] 黄凯新.蒸发冷却空调系统在机场的节能应用研究[D].西安:西安工程大学,2019.
- [7] 高玉明.基于GA-PSO算法优化BP网络的短期电力负荷预测[D].贵阳:贵州师范大学,2014.
- [8] 贾广政.公共建筑空调负荷预测及制冷站控制策略研究[D].北京:北京建筑大学,2019.

[9] 施晓琳.LG煤矿水源热泵空调系统改造工程综合评价研究[D].青岛:山东科技大学,2017.

[10] 付亮.地铁车站中央空调系统负荷预测与节能优化[D].西安:西安建筑科技大学,2019.