

本文引用格式: 吴健超,郑昊岳.基于 PSO-BP 的阀冷却系统阀门开度分类预测模型[J].自动化与信息工程,2024,45(5):14-19;31.  
WU Jianchao, ZHENG Haoyue. Valve opening classification and prediction model based on PSO-BP for valve cooling system[J]. Automation & Information Engineering, 2024,45(5):14-19;31.

# 基于 PSO-BP 的阀冷却系统阀门开度分类预测模型

吴健超 郑昊岳

(广州高澜节能技术股份有限公司, 广东 广州 510705)

**摘要:** 针对阀冷却系统内部的复杂性与外部环境的多变性,准确预测阀门开度以适应不同工况需求的问题,提出一种基于 PSO-BP 的阀冷却系统阀门开度分类预测模型。利用粒子群优化(PSO)算法优化反向传播(BP)神经网络的初始权重和偏置,改善 BP 神经网络易陷入局部最优解和收敛速度慢的情况。采用工业现场收集的阀冷却系统实测数据对 PSO-BP 预测模型进行训练和验证,并与传统的 BP 预测模型进行仿真对比分析。仿真结果表明,PSO-BP 预测模型对阀门开度的分类预测准确率达到 100%,且具有良好的学习和泛化能力,为阀冷却系统的智能控制提供了一种新的解决方案。

**关键词:** 阀冷却系统; 反向传播神经网络; 粒子群优化算法; 阀门开度分类预测

中图分类号: TH185

文献标志码: A

文章编号: 1674-2605(2024)05-0003-07

DOI: 10.3969/j.issn.1674-2605.2024.05.003

开放获取

## Valve Opening Classification and Prediction Model Based on PSO-BP for Valve Cooling System

WU Jianchao ZHENG Haoyue

(Guangzhou Goaland Energy Conservation Tech. Co., Ltd., Guangzhou 510705, China)

**Abstract:** Valve opening classification and prediction model based on PSO-BP for valve cooling system is proposed to address the complexity of the internal system and the variability of the external environment, in order to accurately predict valve opening to meet different operating conditions. Using particle swarm optimization (PSO) algorithm to optimize the initial weights and biases of backpropagation (BP) neural network, improving the situation where BP neural network is prone to getting stuck in local optima and has slow convergence speed. Train and validate the PSO-BP prediction model using measured data from valve cooling systems collected on industrial sites, and compare and analyze it with traditional BP prediction models through simulation. The simulation results show that the PSO-BP prediction model has a classification accuracy of 100% for valve opening, and has good learning and generalization abilities, providing a new solution for intelligent control of valve cooling systems.

**Keywords:** valve cooling system; back propagation neural network; particle swarm optimization algorithm; valve opening classification and prediction

## 0 引言

在现代工业生产中,阀冷却系统是确保设备稳定运行的关键环节,直接影响生产的效率和安全性。工艺上通常要求阀冷却系统在一定的温度范围内工作,以保持阀门的热状态平衡,进而保证阀门的使用寿命和操作可靠性<sup>[1]</sup>。通过精确控制阀门开度,可有效调

节冷却介质的流量和温度,从而维持阀门的最佳工作状态。

然而,阀冷却系统受多种因素(冷却介质的流量和温度、阀门材料特性和环境温度等)的影响,阀门的热状态存在一定的不确定性和不稳定性;且这些因素相互作用,使阀门的热状态难以通过传统的经验方

法进行精确控制。现场工人通常难以判断合适的阀门开度，错误的设置可能导致阀冷却系统过热或过冷，影响系统性能，甚至引发安全事故，造成资源浪费和生产中断。因此，设计一种高效、准确的阀门开度预测模型对提高阀冷却系统的性能，确保工业生产的连续性和稳定性具有重要意义。

目前，阀门开度分类预测模型的相关研究较少。FENG 等<sup>[2]</sup>针对变风量末端多变量、强耦合、高度非线性的特性，建立了基于反向传播（back propagation, BP）神经网络的阀门开度预测模型；与传统的反馈调节方法相比，该模型可以直接输出阀门开度，实现快速变风量控制；但该模型关注于连续值预测，未能充分考虑阀门开度的分类特性。在实际应用中，连续预测值可能需要进一步解析才能转化为具体的操作指令，特别是在快速决策和响应的情况下，增加了操作的复杂性和潜在的错误风险。

本文针对阀冷却系统中阀门开度的动态变化特性，构建基于 PSO-BP 的阀冷却系统阀门开度分类预测模型（以下简称 PSO-BP 预测模型）。其中，粒子群优化（particle swarm optimization, PSO）算法用于优化 BP 神经网络的初始权重和偏置<sup>[3]</sup>，以避免网络陷入局部最优解，并加速权重和偏置的收敛过程。PSO-BP 预测模型能够根据实际工况将阀门开度分为不同的类别，有效提高了阀门开度分类预测的准确性和泛化能力。

## 1 基于 PSO-BP 的阀门开度分类预测

### 1.1 BP 神经网络

BP 神经网络是一种多层前馈神经网络，其通过 BP 神经网络来训练网络的权重，广泛应用于模式识别、图像处理、语音识别以及各种预测和分类任务<sup>[4]</sup>。

BP 神经网络由输入层、隐藏层和输出层组成，每层包含多个神经元。这些神经元通过权重连接，并通过激活函数引入非线性，使网络能够学习和模拟复杂的函数映射。BP 神经网络的拓扑结构如图 1 所示<sup>[5]</sup>。

BP 神经网络算法流程图如图 2 所示。

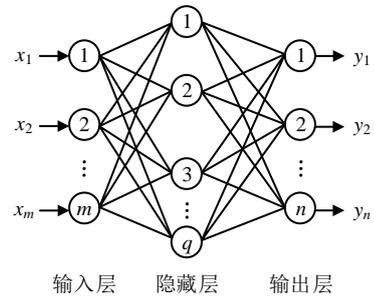


图 1 BP 神经网络的拓扑结构

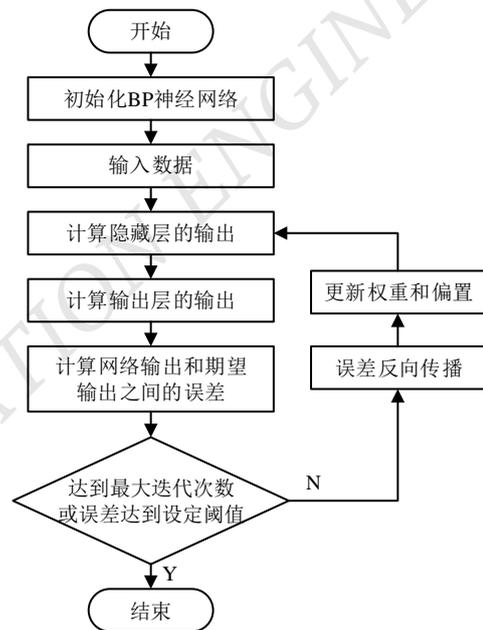


图 2 BP 神经网络算法流程图

设输入层的输入向量为  $\mathbf{X} = (x_1, x_2, \dots, x_m)$ ；第  $l$  层隐藏层向量为  $\mathbf{H}^l = (h_1^l, h_2^l, \dots, h_{q_l}^l)$ ；输出层的输出向量为  $\mathbf{Y} = (y_1, y_2, \dots, y_m)$ ，则 BP 神经网络的训练过程如下：

- 1) 在开始训练前，初始化 BP 神经网络的权重和偏置（阈值）；
- 2) 将输入数据送入 BP 神经网络的输入层；
- 3) 输入数据通过每一层的神经元计算其加权和，并利用激活函数来生成输出，可表示为

$$z_j^l = \sum_{i=1}^{q_{l-1}} w_{ij}^l + b_j^l \quad (1)$$

$$h_j^l = f(z_j^l) \quad (2)$$

式中： $z_j^l$ 为第 $l$ 层第 $j$ 个神经元的输入， $w_{ij}^l$ 为第 $l-1$ 层第 $i$ 个神经元和第 $l$ 层第 $j$ 个神经元之间的连接权重， $b_j^l$ 为第 $l$ 层第 $j$ 个神经元的偏置； $f(\cdot)$ 为激活函数，如 Sigmoid 函数为

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

4) 输出层通过损失函数来衡量预测值与实际值之间的差异；常见的损失函数包括均方误差和交叉熵损失，分别用于回归和分类任务；

均方误差的计算公式为

$$L_{MAE} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (4)$$

式中： $N$ 为训练样本的个数， $y_i$ 为第 $i$ 个样本的实际值， $\hat{y}_i$ 为第 $i$ 个样本的预测值；

交叉熵损失的计算公式为

$$L_{CEL} = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^M y_{i,c} \log(\hat{y}_{i,c}) \quad (5)$$

式中： $M$ 为类别数量； $y_{i,c}$ 为第 $i$ 个样本属于第 $c$ 个类别的 One-Hot 编码值，如果属于该类别则为 1，否则为 0； $\hat{y}_{i,c}$ 为模型预测第 $i$ 个样本属于第 $c$ 个类别的概率；

5) BP 算法利用链式法则计算每个权重对损失的贡献，即梯度；这个过程从输出层开始，逆向通过网络的每一层，更新权重和偏置，以减少损失：

$$\frac{\partial L}{\partial w_{ij}^l} = \frac{\partial L}{\partial z_j^l} \cdot h_i^{l-1} \quad (6)$$

$$\frac{\partial L}{\partial b_j^l} = \frac{\partial L}{\partial z_j^l} \quad (7)$$

6) 使用梯度下降法或其变体来更新权重和偏置，更新公式为

$$w_{ij}^l = w_{ij}^l - \eta \frac{\partial L}{\partial w_{ij}^l} \quad (8)$$

$$b_j^l = b_j^l - \eta \frac{\partial L}{\partial b_j^l} \quad (9)$$

式中： $\eta \in (0,1)$ 为学习率，用于控制权重更新的步长；

7) 重复步骤 3) ~6)，直到满足停止条件，如达到最大迭代次数或误差降低到设定的阈值以下。

## 1.2 PSO 算法

PSO 算法是一种基于群体智能的优化算法，它通过模拟鸟群觅食行为来寻找最优解。在 PSO 算法中，每个解被视为搜索空间中的一个粒子，每个粒子代表问题的潜在解，并具有速度和位置 2 种属性。粒子在搜索空间中飞行，通过跟踪个体极值 ( $p_{Best}$ ) 和全局极值 ( $g_{Best}$ )，来更新其速度和位置，从而不断地接近最优解<sup>[6]</sup>。PSO 算法流程图如图 3 所示。

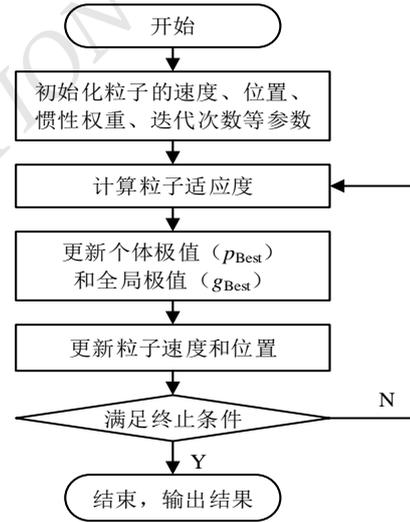


图 3 PSO 算法流程图

PSO 算法的基本实现过程如下：

- 1) 随机初始化一群粒子的速度 $v_i$ 和位置 $x_i$ ，以及 PSO 算法所需的其他参数；
- 2) 计算每个粒子的适应度 $f(x_i)$ ；
- 3) 对于每个粒子，如果当前位置的适应度优于之前记录的个体极值 $p_i$ ，则更新个体极值 $p_i = x_i$ ；
- 4) 如果粒子的个体极值优于当前记录的全局极值 $p_g$ ，则更新全局极值 $p_g = p_i$ ；
- 5) 对于每个粒子，其速度和位置的更新公式分别表示为

$$v_i(t+1) = w \cdot v_i(t) + c_1 \cdot r_1 \cdot (p_i - x_i(t)) + c_2 \cdot r_2 \cdot (p_g - x_i(t)) \quad (10)$$

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (11)$$

式中： $v_i(t+1)$ 、 $x_i(t+1)$  分别为第  $i$  个粒子在第  $(t+1)$  代的速度、位置； $w$  为惯性权重，用于平衡探索和开发； $c_1$ 、 $c_2$  为学习因子，用于控制粒子向个体极值、全局极值的移动强度； $r_1$ 、 $r_2$  为  $[0,1]$  区间内均匀分布的随机数；

惯性权重  $w$  是 PSO 算法的一个重要参数。当  $w$  较大时，算法的全局搜索能力较强，粒子更倾向于探索新的空间区域，有助于算法跳出局部最优解，但可能导致算法收敛速度变慢；当  $w$  较小时，算法的局部搜索能力较强，粒子更倾向于在其历史最佳位置附近进行搜索，有助于算法快速收敛，但增加了陷入局部最优解的风险。线性调整策略是一种常用的惯性权重调整方法，其根据迭代次数线性地减小  $w$  值，从而在算法的不同阶段平衡全局和局部的搜索能力<sup>[7]</sup>。线性调整策略可表示为

$$w = w_{\max} - (w_{\max} - w_{\min}) \cdot t/T \quad (12)$$

式中： $w_{\max}$ 、 $w_{\min}$  分别为最大和最小惯性权重， $t$  为当前迭代次数， $T$  为算法的总迭代次数；

6) 重复步骤 2)~5)，直到满足停止条件，如达到最大迭代次数或解的质量达到设定的阈值；

7) 输出全局极值  $p_g$  作为问题的最优解。

## 2 PSO-BP 预测模型

BP 神经网络在分类预测问题上虽然具有强大的非线性映射能力，但也存在一些明显的弊端，如易陷入局部最优解，导致全局性能下降<sup>[8]</sup>。本文利用 PSO 算法对 BP 神经网络的参数进行优化，可有效避免 BP 神经网络的局部最小问题，加快收敛速度，提高网络性能。PSO 算法优化 BP 神经网络 (PSO-BP 预测模型) 的流程如图 4 所示。

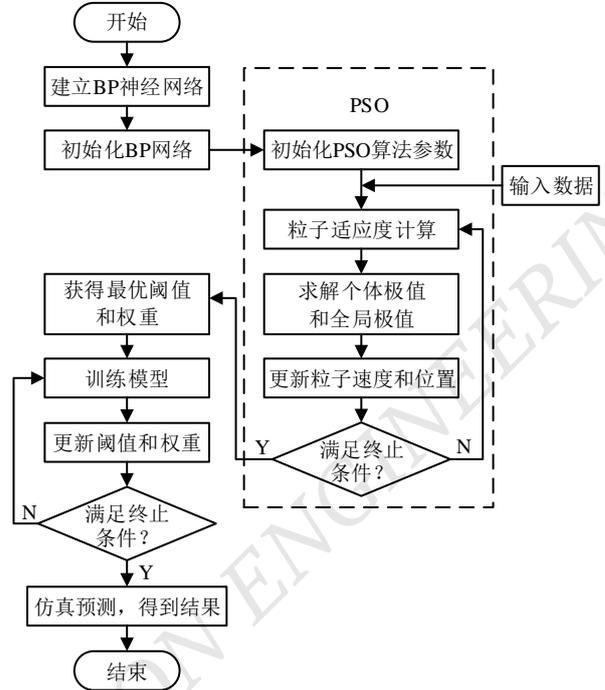


图 4 PSO-BP 预测模型流程图

PSO 算法优化 BP 神经网络的具体步骤如下<sup>[9]</sup>：

1) 构建一个 BP 神经网络，初始化相应的权重和偏置；根据输入和输出参数的数量，确定 BP 神经网络的输入和输出节点数；隐藏层节点数通常先通过经验公式来估计一个初始值，再通过实际训练网络及观察其性能来逐步调整，直至找到使网络预测效果最佳的配置，隐藏层节点数常见的经验公式为<sup>[10]</sup>

$$q = \sqrt{(m+n)} + r \quad (13)$$

式中： $q$  为隐藏层节点数， $m$  为输入层节点数， $n$  为输出层节点数， $r$  为区间  $[0,10]$  内的常数；

2) 初始化 PSO 算法所需的参数，包括粒子群的大小、粒子的速度、位置、惯性权重、学习因子等；

3) 利用神经网络输出值的均方误差 (mean square error, MSE) 生成目标函数，其倒数作为适应度函数，均方误差越小，对应粒子的性能越好<sup>[11]</sup>，目标函数计算公式为

$$M_{\text{MSE}} = \frac{1}{nN} \sum_{i=1}^p \sum_{j=1}^m (d_{ij} - y_{ij}) \quad (14)$$

式中： $n$  为输出层节点数， $d_{ij}$  为网络输出层的预

测值,  $y_{ij}$  为网络输出层的实际值;

4) 利用 PSO 算法更新粒子的速度和位置, 以搜索权重和偏置的最优解;

5) 重复步骤 3)~4), 直至获得具有最优适应度的个体, 即最优的阈值和权重。这些参数将 BP 神经网络调整为最佳初始状态, 通过训练, 形成 PSO-BP 预测模型。

### 3 模型评价与对比

#### 3.1 实验数据

根据流体力学原理和对现场工艺流程的深入分析, 确定了冷却水进阀温度、冷却水出阀温度、外风冷冷却器出水温度、膨胀罐液位为影响阀门开度的关键参数。为此, 选择以上 4 个参数作为 PSO-BP 预测模型的输入数据。本文的实验数据源自于某直流中心三站阀冷却系统的 3 个月 (2、6、8 月) 实测数据。阀门开度分为 3 个类别: 2 月的阀门开度约为 88%, 为类别 1; 6 月的阀门开度约为 80%, 为类别 2; 8 月的阀门开度约为 75%, 为类别 3。部分实测数据如表 1 所示。

表 1 某直流中心三站阀冷却系统的部分实测数据

序号	冷却水进阀温度/°C	冷却水出阀温度/°C	外风冷冷却器出水温度/°C	膨胀罐液位/mm	阀门开度/%	阀门开度类别
1	31.9	42.7	36.4	800.6	88.0	1
...	...	...	...	...	...	...
96	25.6	31.3	30.9	702.2	88.0	1
97	30.0	35.9	29.1	729.9	79.5	2
...	...	...	...	...	...	...
192	32.9	39.4	32.8	753.1	79.4	2
193	31.3	36.4	31.2	714.1	75.8	3
...	...	...	...	...	...	...
288	36.2	41.7	35.3	754.1	75.6	3

将 2、6、8 月的实测数据进行预处理, 包括缺失值和异常值处理、移除不相关或冗余变量、特征编码、归一化等。每个类别分别选取 4 天的数据进行实验。涉及的变量包括冷却水进阀温度、冷却水出阀温度、外风冷冷却器出水温度、膨胀罐液位、阀门开度的类

别标签。其中, 选取每个类别 3 天的数据作为训练集, 用于建立和训练 PSO-BP 预测模型; 剩余的 1 天数据作为测试集, 用于评估 PSO-BP 模型的预测性能。

#### 3.2 参数设置

BP 神经网络的输入层节点数为 4; 输出分类为阀门开度 75%、80%、88%, 即输出层节点数为 3。通过经验公式(13)和试错法确定最优隐藏层节点数为 9, 故本文实验采用的 BP 神经网络结构为 4-9-3 型结构。

设置 BP 神经网络的最大迭代次数为 1000, 误差目标值为  $10^{-5}$ , 学习率为 0.01。设置 PSO 算法的学习因子为 2, 最大迭代次数为 50, 粒子数量为 30, 惯性权重的最大值和最小值分别为 0.9 和 0.4, 粒子的速度范围为  $[-1, 1]$ , 粒子的位置范围为  $[-5, 5]$ 。

#### 3.3 实验环境

本实验在 MATLAB R2021b 下进行, 使用了 MATLAB 的神经网络工具箱和优化工具箱。利用 newff 函数构建 BP 神经网络, 隐藏层节点的转移函数选用 logsig, 输出层节点的转移函数选用 purelin。先通过 PSO 算法优化 BP 神经网络的初始权重和偏置, 再使用 trainlm 算法进行权值微调。

#### 3.4 实验仿真结果

为了验证 PSO-BP 预测模型的有效性, 采用相同的数据集对传统的 BP 预测模型和 PSO-BP 预测模型进行仿真对比测试, 分类预测结果和混淆矩阵分别如图 5~8 所示。PSO-BP 预测模型和传统的 BP 预测模型对阀门开度的分类预测准确率如表 2 所示。

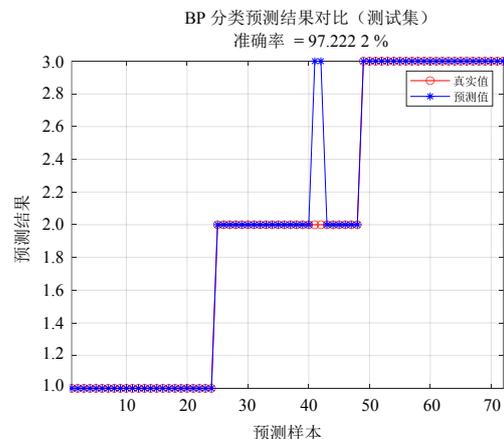


图 5 BP 预测模型分类预测结果

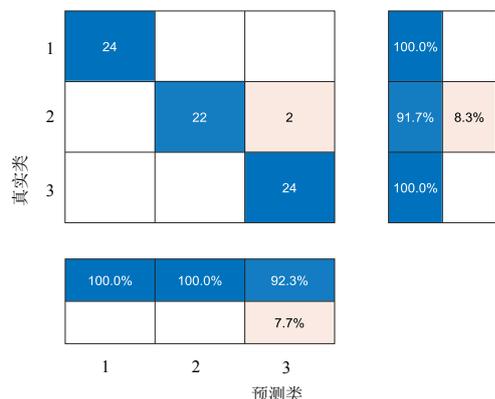


图 6 BP 预测模型分类预测结果混淆矩阵

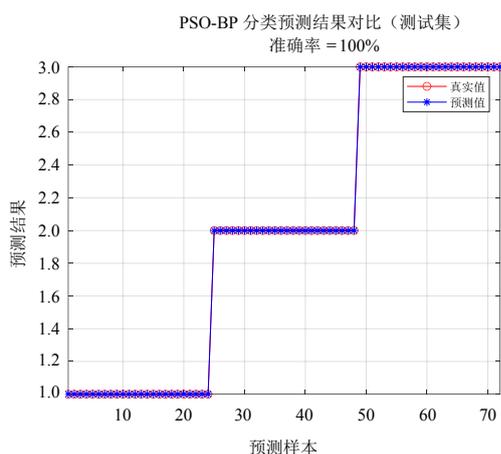


图 7 PSO-BP 预测模型分类预测结果

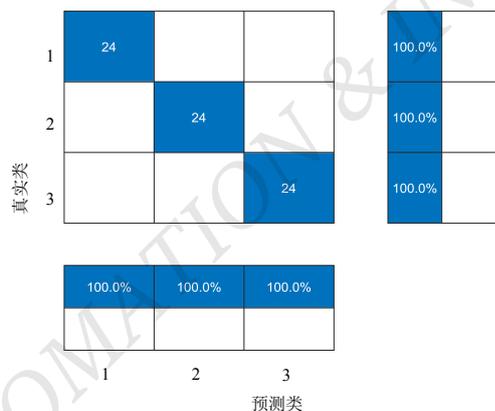


图 8 PSO-BP 预测模型分类预测结果混淆矩阵

表 2 BP 和 PSO-BP 预测模型实验结果对比

预测模型	分类预测准确率/%		
	类别 1	类别 2	类别 3
BP	100	92.3	100
PSO-BP	100	100	100

由表 2 可知：PSO-BP 预测模型的阀门开度的平均分类预测准确率均达到 100%；而 BP 预测模型的平均分类预测准确率约为 97%，且类别 2 的分类预测准确率仅为 92.3%，说明 PSO 算法能够有效调整 BP 神经网络的结构，提高模型的分类预测性能。

#### 4 结论

本文针对阀门开度的动态变化特性，提出一种基于 PSO-BP 的阀冷却系统阀门开度分类预测模型。利用 PSO 算法的全局优化搜索和 BP 神经网络的局部优化搜索性能较好的特点，改善了模型易陷入局部最优解的问题，提高了阀门开度分类预测的准确性和泛化能力。该模型不仅能为阀冷却系统的智能控制提供决策支持，而且有助于提高系统的运行效率和稳定性，减少因阀门开度不当导致的能源浪费和设备损耗。未来将探索自适应学习率策略，以动态调整 PSO 算法和 BP 算法的学习参数，进一步提高模型的收敛速度和分类预测精度。

©The author(s) 2024. This is an open access article under the CC BY-NC-ND 4.0 License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>)

#### 参考文献

- [1] 武小芳,刘甲森,马超洋.换流阀冷却系统频繁补气排气的原因分析及解决措施建议[J].自动化应用,2023,64(1):63-65.
- [2] FENG G, LEI S, Gu X, et al. Predictive control model for variable air volume terminal valve opening based on backpropagation neural network[J]. Building and Environment, 2021, 188:107485.
- [3] 陈刚,徐敏锐,穆小星,等.基于改进神经网络算法的互感器在线监测和故障诊断技术[J].电测与仪表,2020,57(11):49-54; 62.
- [4] 朱志均,周华英,罗坤豪,等.基于机器嗅觉结合 BP 神经网络的砂仁气味鉴别方法[J].自动化与信息工程,2018,39(4):45-48.
- [5] 宋海声,陈召,徐大诚,等.GA-BP 神经网络结合 EDXRF 技术实现对中低合金钢中 Cr、Mn 和 Ni 元素含量的预测[J].激光与光电子学进展,2022,59(12):544-550.
- [6] 黄艺航,蔡凯武,黄晓智,等.基于机器学习的通信电缆故障检测与定位方法[J].自动化与信息工程,2024,45(1):35-41;60.

(下转第 31 页)