

DOI:10.13296/j.1001-1609.hva.2026.08.005

基于GA优化BP神经网络预测开关柜内部设备温度

桑仲庆^{1,2}, 袁会生^{1,2}, 游一民^{1,2}, 戴冬云^{1,2}, 周顺雄^{1,2},
廖权昌^{1,2}, 姜维云^{1,2}

(1. 厦门理工学院电气工程与自动化学院, 福建 厦门 361024; 2. 厦门市高端电力装备及智能控制重点实验室,
福建 厦门 361006)

摘要: 由于开关柜通入电流后,内部设备会产生热量,当温度长期超出阈值,会造成设备损坏无法保证安全,因此需要对开关柜内部温度进行监测,提前对柜内设备的温度进行预测,方便对设备进行维护。为了能够准确预测开关柜内部设备温度,基于BP神经网络,采用GA算法对BP神经网络优化,提出GA-BP神经网络开关柜内部设备温度预测模型。首先分析影响开关柜温度上升的影响因素,并将其作为预测模型的输入数据;再通过预测模型的训练与测试;最后通过衡量指标来评价网络模型的优劣。测试结果表明,该方法能够有效预测开关柜内部设备的温度值,为变电站内设备进行维护提供了便利。

关键词: 开关柜; 预测; 温度; BP神经网络; GA算法

Prediction of Temperature Inside Switchgear Cabinet Based on GA Optimized BP Neural Network

SANG Zhongqing^{1,2}, YUAN Huisheng^{1,2}, YOU Yimin^{1,2}, DAI Dongyun^{1,2},
ZHOU Shunxiong^{1,2}, LIAO Quanchang^{1,2}, JIANG Weiyun^{1,2}

(1. School of Electrical Engineering and Automation, Xiamen University of Technology, Fujian Xiamen 361024, China; 2. Xiamen Key Laboratory of Frontier Electric Power Equipment and Intelligent Control, Fujian Xiamen 361006, China)

Abstract: When current flows through the switchgear cabinet, its internal components generate heat. Prolonged exposure to temperature above the threshold can damage the equipment and pose safety risk. Therefore, internal temperature monitoring and advance temperature prediction are required to enable timely maintenance. In order to accurately predict the temperature of the internal components within the switchgear cabinet a temperature prediction model for internal components of the switchgear cabinet based on the BP neural network is proposed, where the GA algorithm is used to optimize the BP neural network. First, the influencing factors affecting the temperature rise of the switchgear cabinet are analyzed and used as the input data of the prediction model. Then, the prediction model is trained and tested. Finally, the pros and cons of the network model are evaluated through measurement indicators. The test results show that this method can effectively predict the temperature value of the components within the switchgear cabinet, providing convenience for the maintenance of equipment in the substation.

Key words: switchgear cabinet; prediction; temperature; BP neural networks; GA algorithm

0 引言

进入新时代,生产力得到了解放,随着国民经

济的提升,用户对电力系统的要求更加严格,从对供电量的需求转变成对供电质量的需求^[1-4]。由此电网不断发展并且用电负荷也日益增加,开关柜被大

量应用于电力系统中,成为用户供电的核心设备^[5-8]。它主要有控制保护的作用负担着限制系统短路电流,提高系统可靠性的重大任务,因此开关设备运行的可靠性和稳定性至关重要^[9-13]。由于变电站通常处在偏僻地区,开关柜长期处在比较恶劣的环境下,且长期运行在高压的环境中,其内部容易因老化、积灰、连接松动等引起设备发热,而温度可以直接表明开关柜运行的健康状态,因此需要对开关柜内部设备进行温度监测与高温预警,能够及时发现开关柜的安全隐患,并及时采取相关的应对措施,避免开关柜事故发生,保障用户及时安全用电。

随着计算机技术大力发展,人工智能也得到了快速发展,同时被应用于很多行业之中,例如金融、电力、医疗等多个领域。针对于温度预测的研究也逐渐完善,通常的预测方法可分为:基于模型的预测、基于知识的预测和基于数据驱动的预测^[14-17]。

基于数据驱动的常见预测方法有:支持向量机、BP神经网络、循环神经网络等。文[18]提出利用主成分分析(PCA)优化BP神经网络的模型,在减少数据丢失的同时消除数据的冗余信息,保证数据的可靠性,并将该模型应用于股票价格预测当中,取得了有效的预测结果。该方法适合输入与输出关联清晰或者线性关系的预测,但是不适合复杂的非线性关系模型。文[19]提出基于序列理论的电网用户用电负荷预测模型,以历史电网用户用电数据为基础,得出未来某个时间节点的用电负荷预测值。该方法计算得出的MAE和MAPE指标数值更小,预测的精度更高,误差更小,但是该模型无法有效长期预测。

BP神经网络的数据信号是正向传播,误差信号是逆向传播,可以通过逆向传播自动优化模型的权值。由此,BP神经网络实现了从输入到输出的映射,并且数学理论上已经证明了它具有实现复杂非线性映射的能力,这使得它特别适合于求解内部机制复杂的问题。但是,BP神经网络因过早收敛容易陷入局部最优解^[20],不能够解决复杂非线性全局极值问题,容易陷入局部极值。而遗传算法通过变异机制避免了陷入局部极值,逐步逼近最优解或者全局极值,且可拓性强,易于与其他算法进行结合。

针对BP神经网络与遗传算法的特性,文中将遗传算法与BP神经网络相结合,利用遗传算法具备全局寻优的能力,优化了BP神经网络权值、阈值的更新与选择^[21],避免陷入到局部极值,提高模型的预测精准性。

1 相关理论

1.1 BP神经网络介绍

BP(back propagation)神经网络是1986年由Rumelhart和McClelland为首的科学家提出的概念,是一种根据误差逆向传播的多层前馈神经网络^[22],该网络的特点是输入信号前向传递,根据误差反向更新权值与阈值。在输入信号向前传播过程中,信号由输入层输入经隐含层逐层进行计算,直至输出层。若输出层得到的结果与真实值之间存在较大误差,则网络进行反向传播,根据预测值与真实值之间的误差更新网络各层的权值与阈值,从而提高BP神经网络的预测精度,使预测值与真实值之间无限逼近。BP神经网络的基本结构见图1。




图1 BP神经网络结构图

Fig. 1 BP neural network structure diagram

由图1的BP神经网络结构图可知,BP神经网络由3层结构组成,分别是输入层、隐含层和输出层。图1中,输入层是数据输入节点,原始数据通过输入层的神经元节点输入到网络当中,经过隐含层单个或者多个神经元节点计算,将计算结果不断向后传递输出和训练处理,最后基于输出层神经元节点输出结果。BP神经网络根据网络输出的误差进行逆向传递,利用非线性可微分函数作为训练函数,通过大量的数据样本模拟训练,对各层之间神经元的权值与阈值进行不断更新调整,最终得到预测模型^[23]。BP神经网络计算的流程图见图2。

1.1.1 网络初始化

在网络初始化阶段需要对网络的参数进行设置,输入层节点的个数 n ,隐含层节点个数 l ,输出层节点个数 m ,输入层到隐含层的权重 w_{ij} ,输入层到隐含层的偏置 a_i ,隐含层到输出层的偏置 b_k ,以及神经网络的学习速率 η 和激励函数 $g(x)$ 。其中激励函数 $g(x)$ 取sigmoid函数,公式为

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




图2 BP神经网络计算流程图

Fig. 2 BP neural network calculation flow chart

1.1.2 计算隐含层输出

隐含层的输出为 H_j

$$H_j = g\left(\sum_{i=1}^n w_{ij}x_i + a_j\right) \quad (2)$$

1.1.3 计算输出层输出

输出层的输出为 O_k

$$O_k = \sum_{j=1}^l H_j w_{jk} + b_k \quad (3)$$

1.1.4 计算误差

取误差 E 公式为

$$E = \frac{1}{2} \sum_{k=1}^m (Y_k - O_k)^2 \quad (4)$$

式(4)中, Y_k 为期望输出。记 $Y_k - O_k = e_k$, 则 E 可以表示为

$$E = \frac{1}{2} \sum_{k=1}^m e_k^2 \quad (5)$$

1.1.5 更新权值

权值更新公式为

$$\begin{cases} w_{ij} = w_{ij} + \eta H_j (1 - H_j) x_i \sum_{k=1}^m w_{jk} e_k \\ w_{jk} = w_{jk} + \eta H_j e_k \end{cases} \quad (6)$$

BP神经网络的误差是反向传播的^[24], 目的是使得误差函数计算的值达到最小值, 即 $\min E$, 使用梯度下降法有输出层向输入层逐层更新权值。

隐含层到输出层的权值更新

$$\frac{\partial E}{\partial w_{jk}} = \sum_{k=1}^m (Y_k - O_k) \left(-\frac{\partial O_k}{\partial w_{jk}}\right) = (Y_k - O_k)(-H_j) = -e_k H_j \quad (7)$$

则权重的更新式为

$$w_{jk} = w_{jk} + \eta H_j e_k \quad (8)$$

输入层到隐含层的权重更新

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial H_j} \cdot \frac{\partial H_j}{\partial w_{ij}} \quad (9)$$

式(9)中:

$$\frac{\partial E}{\partial H_j} = -\sum_{k=1}^m w_{jk} e_k \quad (10)$$

$$\frac{\partial E}{\partial H_j} = H_j(1 - H_j)x_i \quad (11)$$

则权重的更新式为

$$w_{ij} = w_{ij} + \eta H_j (1 - H_j) x_i \sum_{k=1}^m w_{jk} e_k \quad (12)$$

1.1.6 偏置的更新

偏置的更新式为

$$\begin{cases} a_j = a_j + \eta H_j (1 - H_j) \sum_{k=1}^m w_{jk} e_k \\ b_k = b_k + \eta e_k \end{cases} \quad (13)$$

隐含层到输出层的偏置更新

$$\frac{\partial E}{\partial b_k} = (Y_k - O_k) \left(-\frac{\partial O_k}{\partial b_k}\right) = -e_k \quad (14)$$

则偏置的更新式为

$$b_k = b_k + \eta e_k \quad (15)$$

输入层到隐含层的偏置更新

$$\frac{\partial E}{\partial a_j} = \frac{\partial E}{\partial H_j} \cdot \frac{\partial H_j}{\partial a_j} \quad (16)$$

式(16)中:

$$\frac{\partial H_j}{\partial a_j} = H_j(1 - H_j) \quad (17)$$

$$\frac{\partial E}{\partial H_j} = -\sum_{k=1}^m w_{jk} e_k \quad (18)$$

则偏置的更新式为

$$a_k = a_k + \eta H_j (1 - H_j) \sum_{k=1}^m w_{jk} e_k \quad (19)$$

1.1.7 判断算法迭代是否结束

有很多的方法可以判断算法是否已经收敛, 常见的有指定迭代的代数, 判断相邻的两次误差之间的差别是否小于指定的值等等。

1.2 遗传算法介绍

遗传算法(genetic algorithm, GA)最早是由美国的 John holland 于 20 世纪 70 年代提出, 该算法是根据大自然中生物体进化规律而设计提出的。依据达尔文自然进化论, 模拟其中的自然选择和遗传学

机理,构建数据计算模型,搜索最优解^[25-26]。该算法利用数学的方式与计算机仿真运算,将问题的求解过程转换成生物遗传中的染色体基因的交叉、变异等过程。遗传算法已被人们广泛地应用于组合优化、机器学习、信号处理、自适应控制和人工生命等领域。

它是模仿自然界生物进化机制发展起来的随机全局搜索和优化方法,其本质是一种高效、并行、全局搜索的方法,能在搜索过程中自动获取和积累有关搜索空间的知识,并自适应地控制搜索过程求得最佳解^[27]。

常规的优化算法,如解析法,通常只能得到局部最优解而非全局最优解,且要求目标函数连续光滑及可微;枚举法克服了这些缺点,但是计算效率太低,往往对于搜索空间太大导致考虑方面不够全面;动态规划法解决不了中等规模和适应度复杂性的问题。

相比于其他的优化算法,遗传算法具有以下的特点:

- 1)遗传算法是将参数进行编码,并不是对参数本身操作。
- 2)遗传算法采取多点并行的方式,不局限于一点,有效防止搜索过程中收敛于局部最优解。
- 3)遗传算法通过目标函数计算适配值,降低对问题的依赖性。
- 4)遗传算法的寻优是由概率决定的,没有确定性。
- 5)遗传算法具有并行计算的优点,可以提高计算速度。
- 6)遗传算法适合大规模复杂问题的优化。
- 7)遗传算法计算简单,功能强大。

遗传算法以一种群体中的所有个体为对象,并利用随机化技术指导对一个被编码的参数空间进行高效搜索。其中,选择、交叉和变异构成了遗传算法的遗传操作;参数编码、初始群体的设定、适应度函数的设计、遗传操作设计、控制参数设定5个要素组成了遗传算法的核心内容。遗传算法的工作示意图见图3。

2 GA 优化 BP 神经网络模型设计

BP神经网络是目前最常用的仿生算法,利用问题本身的一些特征量,来解决较为复杂或者非线性问题^[28]。文中采用遗传算法优化BP神经网络对中压开关柜内部设备温度预测,利用遗传算法避免BP神经网络陷入局部最优解,基于BP神经网络的结构,通过训练误差的逆向传播机制,不断的输入训练,形成多层前馈神经网络^[29]。GA-BP神经网络流程见图4。




图3 遗传算法工作示意图

Fig. 3 Genetic algorithm working diagram




图4 GA-BP神经网络流程图

Fig. 4 GA-BP neural network flow chart

遗传算法改进优化BP神经网络具体步骤如下:

1)初始化网络。确定网络的输入节点 i 、隐含节点 j 、输出节点 k ,从而确定整个BP神经网络的拓扑结构。

2)生成初始权值与阈值。根据BP神经网络的拓扑结构,生成输入层到隐含层的权值矩阵 W ,隐含层的阈值矩阵 y ,隐含层到输出层的权值矩阵 V ,输出层的阈值矩阵 h 。

3)GA对初始值进行编码。考虑输入结点为 i 、隐含结点为 j 、输出结点为 k 的神经网络,其中输入

层到隐含层的权值矩阵为 $\mathbf{W}$, 隐含层的阈值矩阵为 $\mathbf{y}$, 隐含层到输出层的权值矩阵为 $\mathbf{V}$, 输出层的阈值矩阵为 $\mathbf{h}$ 。但是在BP神经网络当中权值矩阵是二维的, 而染色体是一维的; 并且权值与阈值是多个, 但是一个染色体只有一条; 这就导致需要对权值与阈值进行编码, 将二维的权值矩阵映射成一维, 并且将多个权值与阈值拼接形成染色体。

4) 建立适应度函数。适应度函数 $fitness$ 定义为

$$fitness = \frac{1}{\sum_{k=1}^{N_n} \sum_{i=1}^{N_o} |y_k^i - a_k^i|} \quad (20)$$

式(20)中: y_k^i 为第 k 个训练样本通过神经网络得到的第 i 个预测输出; a_k^i 为相应的实际输出; N_n 为训练集样本个数; N_o 为输出节点的个数。

5) 选择操作。采用轮盘赌选择法对群体的染色体进行选择, 产生规模同样为 N 的种群。选出的个体平均适应度较高, 但是会有重复的个体, 而重复的个体交叉是没有意义的, 因此在选择的过程中需要筛选重复的个体。

6) 交叉操作。将长度为 l 的染色体 A 和 B , 采用实数交叉法对染色体进行交叉:

$$a'_k = (1-r)a_k + rb_k \quad (21)$$

$$b'_k = rb_k + (1-r)a_k \quad (22)$$

式(21)、(22)中: r 为 $[0, 1]$ 之间的随机数; $k=1, 2, 3, \dots, l$ 。

7) 变异操作。当变异算子以一定概率对某个个体 A 的第 k 个基因发生变异时, 变异操作为

$$a'_k = \begin{cases} a_k + (a_{\max} - a_k)r_1(1 - \frac{G}{G_{\max}})^2 & r_2 > 0.5 \\ a_k + (a_{\min} - a_k)r_1(1 - \frac{G}{G_{\max}})^2 & r_2 \leq 0.5 \end{cases} \quad (23)$$

式(23)中: $a_{\max}$ 和 $a_{\min}$ 分别为基因值上下界; G 为当前迭代次数; $G_{\max}$ 为最大迭代次数; r_1 和 r_2 为 $[0, 1]$ 之间的随机数。

8) 种群更新。在进行完遗传变异之后, 根据适应度函数对新的染色体进行验证, 如果函数判定它们的适应度足够, 那么就会用它们从总体中替代掉那些适应度不够的染色体。

9) 判断是否满足终止条件。适应度值 $fitness$ 是否达到期望值或者是否达到最大进化次数, 若达到则进化完毕, 否则返回到5)。

10) 将最佳权值与阈值带入BP神经网络。

11) 计算误差。通过BP神经网络将输入信号正向传播, 计算正向传播得到的值与真实值之间的差值。

12) 权值与阈值更新。通过BP神经网络的逆向

传播机制, 更新隐含层到输出层的权值与阈值和输入层到隐含层的权值与阈值。

13) 判断是否满足终止条件。预测的平均误差是否达到期望值或者是否达到最大进化次数, 若达到则迭代结束, 否则返回到10)。

3 实验分析

3.1 实验条件

文中以某电厂 12 kV 中压开关柜内断路器设备为例, 验证文中所提模型的有效性。利用文中提出的 GA-BP 神经网络温度预测模型对中压开关柜内断路器的温度进行预测, 此次实验环境为: 仿真实验平台为 windows10, 计算机 CPU 为 intel CORE i7, 程序设计语言为 Python 3.7.4, 集成开发环境为 Pycharm Community Edition。

3.2 基于 GA-BP 神经网络开关柜设备温度建模

3.2.1 特征变量的选取

由于电厂位置偏远, 环境复杂, 影响开关柜温度的因素众多, 文中实验数据来源于福建省某电厂, 开关柜的负载电流 I_A (A)、开关柜内断路器 A 相上触臂的温度 T_A (℃)、环境温度 T_e (℃) 作为影响预测结果的因素, 利用皮尔逊相关系数对各因素与下一时刻的温度预测值 T_p (℃) 进行求解, 分析各个变量之间的相关性, 确定 GA-BP 神经网络的输入量。

根据表 1 皮尔逊相关系数评价表, 由表 2 可知, I_A 与 T_p 、 T_A 与 T_p 、 T_e 与 T_p 的皮尔逊相关系数均大于 0.9, 属于极强相关。因此, 选择开关柜的负载电流 I_A (A)、开关柜内断路器 A 相上触臂的温度 T_A (℃)、环境温度 T_e (℃) 作为文中预测模型的输入量。

表 1 皮尔逊相关系数的评价标准

Table 1 Pearson correlation coefficient evaluation criteria

$ r_{pq} $ 的取值范围	相关联的程度
$ r_{pq} \in [0.0, 0.2)$	极弱相关或无相关
$ r_{pq} \in [0.2, 0.4)$	弱相关
$ r_{pq} \in [0.4, 0.6)$	中等程度相关
$ r_{pq} \in [0.6, 0.8)$	强相关
$ r_{pq} \in [0.8, 1.0]$	极强相关

表 2 特征变量与目标变量皮尔逊相关性求解结果

Table 2 The result of solving Pearson correlation between feature variable and target variable

变量	I_A	T_A	T_e	T_p
I_A	1.000 000	0.994 723	0.984 301	0.994 962
T_A	0.994 723	1.000 000	0.921 420	0.998 679
T_e	0.984 301	0.921 420	1.000 000	0.951 839
T_p	0.994 962	0.998 679	0.951 839	1.000 000

3.2.2 网络模型相关参数设定

根据上述提到的特征变量选取, 构建GA-BP神经网络温度预测模型, 主要参数设置如下。

遗传算法参数设置: ①种群规模 $popsiz=100$; ②最大迭代次数 $G_{max}=500$; ③交叉概率 $p_c=0.8$; ④变异概率 $p_m=0.1$; ⑤染色体基因值上限 $a_{max}=15$; ⑥染色体基因值下限 $a_{min}=-15$ 。

BP神经网络参数设置: ①输入神经元 $inputnum=3$; ②隐含层神经元 $hiddennum=30$; ③输出神经元 $outputnum=1$; ④训练步长 $step=1$; ⑤最大迭代次数 $iternum_{max}=2\ 000$; ⑥平均绝对误差 $Everage=0.01$ 。

3.2.3 数据预处理

文中实验数据来源于某电厂 12 kV 中压开关柜, 上文分析可知, 选取的输入量为 I_A 、 T_A 、 T_e 。由此, 选取该地 2023 年 2 月 8 日到 2 月 10 日的历史数据, 共计 180 组数据, 部分样本数据集见表 3。其中选取前 94 组作为训练数据集, 后 86 组作为测试数据集。

表 3 部分样本数据

Table 3 Partial sample data

序号	时刻	A 相上触臂 电流 I_A/A	A 相上触臂 温度 $T_A/^\circ C$	环境温 度 $T_e/^\circ C$
1	12:30:00	271.14	24.40	20.5
2	13:00:00	272.75	25.37	20.9
3	13:30:00	294.09	25.70	21.6
4	14:00:00	317.75	26.23	21.7
5	14:30:00	322.17	26.77	22.1
6	14:43:51	329.92	27.23	22.5
7	15:00:00	348.02	27.80	22.0

BP神经网络训练模型包含两个阶段, 一个是信号的正向传播, 即将输入数据输入到网络当中, 从输入层到输出层逐层传递变换; 另一个是误差逆向传播, 即根据预测值与真实值之间的误差从后往前逐层修改权值。通常输入数据在各个字段的数值范围上不可避免地存在差异, 当数值差别很大甚至存在量级的差别时, 网络受到各种特征的影响不一, 数值大的特征输入将更多地影响网络的学习, 导致网络学习速度变慢甚至不能收敛。因此, 需要对输入数据做数据预处理, 即训练数据的归一化或者规格化处理, 以消除数据间的影响, 提高网络的学习效率和预测准确性。

归一化处理是将数据映射到指定范围之内, 如把数据映射到 0~1 或 -1~1 范围之内处理。归一化将有量纲表达式变为无量纲表达式, 便于不同单位或量级的指标能够进行比较和加权。经过归一化后, 将有量纲的数据集变成纯量, 还可以达到简化计算的作用。

文中使用 Min-Max 归一化, 将其数据映射到 0~1 范围之内, 其表达式为

$$x_{new} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (24)$$

式(24)中: x 为原始数据样本; x_{min} 为原始数据集中的最小值; x_{max} 为原始数据集中的最大值。

3.2.4 模型性能评价

针对提出的BP神经网络模型, 可以通过量化指标来衡量BP神经网络的预测效果, 其中包括均方误差、均方根误差、平均绝对误差、平均百分比误差和 R^2 等。

1)MSE(均方误差)。预测值与实际值之差平方的期望值, 取值越小, 模型准确度越高。

2)RMSE(均方根误差)。为 MSE 的平方根, 取值越小, 模型准确度越高。

3)MAE(平均绝对误差)。绝对误差的平均值, 能反映预测值误差的实际情况, 取值越小, 模型准确度越高。

4)MAPE(平均绝对百分比误差)。是 MAE 的变形, 它是一个百分值, 取值越小, 模型准确度越高。

5) R^2 (R-Square)。将预测值跟只使用均值的情况下相比, 结果越接近 1, 模型准确度越高。

3.3 结果及分析

根据文中设计的GA-BP神经网络模型进行开关柜温度预测, 为了验证GA-BP神经网络的有效性, 采用相同的数据集, 使用传统BP神经网络温度预测模型作为对比实验, 均使用python实现。

GA-BP神经网络预测值与真实值之间的对比, 见图 5。GA-BP神经网络预测值与真实值误差结果, 见图 6。由图 5、6 可以看出GA-BP神经网络的预测结果与实际测量得到的温度趋势基本吻合, 且最大误差为 2 $^\circ C$, 所以文中提出的GA-BP神经网络预测模型可以准确预测开关柜内温度。




图 5 GA-BP神经网络模型预测结果对比

Fig. 5 Comparison of prediction results of GA-BP neural network model




图6 GA-BP神经网络模型预测误差结果

Fig. 6 GA-BP neural network model predicts error results

为了衡量网络预测模型的训练效果,文中使用训练loss值对训练效果进行说明,文中提出的GA-BP神经网络预测模型的loss曲线见图7。




图7 GA-BP神经网络预测模型loss曲线

Fig. 7 GA-BP neural network prediction model loss curve

由图7可以看出,GA-BP神经网络预测模型的loss曲线呈现逐渐下降趋势,网络训练loss值逐渐减小,500次迭代之后逐渐收敛于0.1,证明网络模型朝着最优的方向进行调整训练,网络模型训练效果较好。

传统BP神经网络预测模型的结果对比和预测误差见图8、9。可以从图8、9中看出,传统BP神经网络的预测结果在整体趋势上与开关柜内断路器A相上触臂温度趋势一致,在其上下波动,但是预测值与实际测量值的最大误差在3.7℃,且整体误差偏高。

文中实验选用均方误差MSE、均方根误差RMSE、平均绝对误差MAE、平均绝对百分比误差MAPE以及决定系数 R^2 (R-Square)等相关指标进行综合对比,衡量GA-BP神经网络温度预测模型的优劣,GA-BP神经网络预测热模型与传统BP神经网络预测模型的相关指标对比见表4。




图8 BP神经网络预测结果对比

Fig. 8 Comparison of BP neural network prediction results




图9 BP神经网络模型预测结果误差

Fig. 9 Prediction error of BP neural network model

表4 GA-BP与BP模型相关指标对比

Table 4 Comparison of relevant indicators between GA-BP and BP models

神经网络	$e_{MSE}/^{\circ}\text{C}^2$	$e_{RMSE}/^{\circ}\text{C}$	$e_{MAE}/^{\circ}\text{C}$	$e_{MAPE}/\%$	R^2
BP	2.914 3	1.707 1	1.408 4	0.097 5	0.889 4
GA-BP	2.018 6	1.420 8	1.095 7	0.088 1	0.997 6

由表4可以看出,对于GA-BP神经网络温度预测模型的MSE、RMSE、MAE、MAPE、 R^2 值可以看出,GA-BP神经网络温度预测模型误差小且拟合能力好,相关系数大,吻合度好。因此,相比较于传统BP神经网络预测模型和GA-BP神经网络温度预测模型,文中提出的GA-BP神经网络温度预测模型预测值与实际测量值之间误差较小,模型预测精度比较高,效果优于传统BP神经网络温度预测模型。

4 结语

文中提出了一种基于GA-BP神经网络的开关柜温度预测模型,提高了开关柜温度预测的精确度。以某电厂12 kV开关柜内断路器A相上触臂温度预测为例,将GA-BP神经网络温度预测模型与传统BP神经网络温度预测模型进行对比,从对比结果可以看出:GA-BP神经网络温度预测模型精确度较高。该模型也可以应用于开关柜内其他设备的温

度预测,为电力系统的安全稳定运行提供保障。

参考文献:

- [1] 黎才添. 变电站设备无线温度监测系统的应用[D]. 广州: 华南理工大学, 2015.
Li Caitian. Research and application of wireless temperature monitoring system for substation equipment[D]. Guangzhou: South China University of Technology, 2015.
- [2] 阮江军, 黎 鹏, 黄道春, 等. 中压开关柜内部短路燃弧热—力效应研究综述[J]. 高电压技术, 2018, 44(10): 3340-3351.
Ruan Jiangjun, Li Peng, Huang Daochun, et al. Review on thermal-mechanical effects research of MV switchgear due to internal short circuit arcing[J]. High Voltage Engineering, 2018, 44(10): 3340-3351.
- [3] 田超华, 赵 欢, 黄鸿基, 等. 基于深度学习的配电网开关柜电晕放电检测设计[J]. 电子设计工程, 2025, 33(1): 51-54.
Tian Chaohua, Zhao Huan, Huang Hongji, et al. Design of corona discharge detection for distribution network switchgear based on deep learning[J]. Electronic Design Engineering, 2025, 33(1): 51-54.
- [4] 李刚毅. 基于多传感信息融合的开关柜局放类型诊断研究[J]. 电器与能效管理技术, 2025(1): 23-27.
Li Gangyi. Research on partial discharge type diagnosis of switchgear based on multi-sensor information fusion[J]. Electrical Appliances and Energy Efficiency Management Technology, 2025 (1): 23-27.
- [5] 王文华. 高压开关柜局部放电故障诊断分析方法[J]. 无损检测, 2018, 40(11): 75-79.
Wang Wenhua. Analytical method in partial discharge fault diagnosis of high-voltage switchgear[J]. Non-Destructive Testing, 2018, 40(11): 75-79.
- [6] 王 真, 刘子全, 路永玲, 等. 基于RFID传感器和深度学习的开关柜故障诊断研究[J]. 电力科学与技术学报, 2025, 40(2): 179-185.
Wang Zhen, Liu Ziquan, Lu Yongling, et al. Fault detection in switchgear based on RFID sensors and deep learning[J]. Journal of Electric Power Science and Technology, 2025, 40(2): 179-185.
- [7] 方江华, 谢堪恒, 贺 平, 等. 基于多传感器融合与机器学习的开关柜潜伏性故障检测方法[J]. 电子设计工程, 2025, 33(18): 26-30.
Fang Jianghua, Xie Kanheng, He Ping, et al. Latent fault detection method for switchgear based on multi-sensor fusion and machine learning[J]. Electronic Design Engineering, 2025, 33(18): 26-30.
- [8] 盛连军, 周超杰, 陈 侃, 等. 基于I-GWO改进RF的开关柜状态诊断算法[J]. 智慧电力, 2025, 53(1): 38-44.
Sheng Lianjun, Zhou Chaojie, Chen Kan, et al. Switchgear condition diagnosis algorithm based on I-GWO improved random forest[J]. Smart Power, 2025, 53(1): 38-44.
- [9] 陈凯彬, 耿 新, 郭营生, 等. 基于ZigBee和CAN总线的高压开关柜温度在线监测预警系统设计[J]. 科技风, 2020(10): 3.
Chen Kaibin, Geng Xin, Guo Yingsheng, et al. Design of on-line temperature monitoring and early warning system for high voltage switchgear based on ZigBee and CAN bus[J]. Technology Wind, 2020(10): 3.
- [10] 王 浩, 白 张, 吴劲松, 等. 高海拔地区中压充气式开关柜温升特性研究[J]. 电测与仪表, 2025, 62(11): 88-94.
Wang Hao, Bai Zhang, Wu Jinsong, et al. Research on temperature rise characteristics of medium voltage gas-filled switchgear in high altitude areas[J]. Electrical Measurement & Instrumentation, 2025, 62(11): 88-94.
- [11] 吴小忠, 甘 星, 严亚兵, 等. 基于过热故障仿真的高压开关柜测温点优化方法[J]. 西安工程大学学报, 2025, 39(6): 128-138.
Wu Xiaozhong, Gan Xing, Yan Yabing, et al. Optimization method of high-voltage switchgear temperature measurement points based on overheating fault simulation[J]. Journal of Xi'an Polytechnic University, 2025, 39(6): 128-138.
- [12] 康 晶, 任召田, 刘振笃, 等. 环保气体绝缘开关柜电场仿真与优化[J]. 电器与能效管理技术, 2025(1): 56-60.
Kang Jing, Ren Zhaotian, Liu Zhendu, et al. Simulation and optimization on electric field of environment-friendly gas insulated switchgear[J]. Electrical Appliances and Energy Efficiency Management Technology, 2025(1): 56-60.
- [13] 林奕夫, 叶兆平, 陈 雪, 等. 基于二阶电路的开关柜局部放电检测方法[J]. 浙江电力, 2024, 43(8): 113-120.
Lin Yifu, Ye Zhaoping, Chen Xue, et al. A partial discharge detection method for switch cabinets based on a second-order circuit[J]. Zhejiang Electric Power, 2024, 43(8): 113-120.
- [14] 薛禹胜, 郁 琛, 赵俊华, 等. 关于短期及超短期风电功率预测的评述[J]. 电力系统自动化, 2015(6): 141-151.
Xue Yusheng, Yu Chen, Zhao Junhua, et al. A review on short-term and ultra-short-term wind power prediction[J]. Automation of Electric Power Systems, 2015(6): 141-151.
- [15] 杨 茂, 张罗宾. 基于数据驱动的超短期风电功率预测综述[J]. 电力系统保护与控制, 2019, 47(13): 171-186.
Yang Mao, Zhang Luobin. Review on ultra-short term wind power forecasting based on data-driven approach[J]. Power System Protection and Control, 2019, 47(13): 171-186.
- [16] 王晓丹. 基于深度学习的风力发电机故障预测研究[D]. 重庆: 重庆工商大学, 2019.
Wang Xiaodan. Research on wind turbine fault prediction based on deep learning[D]. Chongqing: Chongqing Technology and Business University, 2019.
- [17] Bai X, An Z, Hou Y, et al. Health assessment and management of wind turbine blade based on the fatigue test data[J]. Microelectronics Reliability, 2017(75): 205-214.
- [18] 于春蕾, 李梦悦, 尹伟石. 基于PCA-BP组合模型的股价预测分析[J]. 长春理工大学学报(自然科学版), 2021, 44(4): 125-130.
Yu Chunlei, Li Mengyue, Yin Weishi. Analysis of stock price forecast based on PCA-BP combination model[J]. Journal of Changchun University of Science and Technology(Natural Science Edition), 2021, 44(4): 125-130.
- [19] 冯 波, 张 瑞, 孙 冲, 等. 基于序列理论的电网用户用电负荷自动预测研究[J]. 自动化技术与应用, 2023, 42(2): 17-20.
Feng Bo, Zhang Rui, Sun Chong, et al. Research on automatic power load prediction of power grid users based on sequence theory

- [J]. Techniques of Automation and Applications, 2023, 42(2): 17-20.
- [20] 马创涛,邵景峰.烟花算法改进BP神经网络预测模型及其应用[J].控制工程,2020,27(8):1324-1331.
Ma Chuangtao, Shao Jingfeng. Fireworks algorithm improved BP neural network forecasting model and its application[J]. Journal of Control Engineering, 2020, 27(8): 1324-1331.
- [21] 王英立,陶 帅,候晓晓,等.基于MIV分析的GA-BP神经网络光伏短期发电预测[J].太阳能学报,2020,41(8):236-242.
Wang Yingli, Tao Shuai, Hou Xiaoxiao, et al. GA - BP neural network photovoltaic power generation short-term forecast based on MIV analysis[J]. Acta Energaie Solaris Sinica, 2020, 41(8): 236-242.
- [22] 游佳凝,高 玲,王 庆.基于GA-BP神经网络的颗粒阻尼器减振特性预测[J].福建师范大学学报(自然科学版),2023,39(3): 106-115.
You Jianing, Gao Ling, Wang Qing. Prediction of vibration damping characteristics with particle dampers based on GA - BP neural network[J]. Journal of Fujian Normal University(Natural Science Edition), 2023, 39(3): 106-115.
- [23] 黄杨森.基于BP神经网络的转子振动预警方法研究[J].发电设备,2023,37(3):186-191.
Huang Yangsen. Research on early warning method for rotor vibration based on BP neural network[J]. Power Equipment, 2023, 37(3): 186-191.
- [24] 李 忻,吴金额,苏慧敏,等.基于BP神经网络的手部尺寸预测模型构建[J].丝绸,2023,60(5):59-65.
Li Xin, Wu Jinying, Su Huimin, et al. Construction of hand size prediction models based on BP neural network[J]. Silk, 2023, 60 (5): 59-65.
- [25] 黄敬尧,程 煜,李雅恬.基于DCM-PCA和GA-BP的逆变器故障诊断[J].电力科学与技术学报,2024,39(1):260-271.
Huang Jingyao, Cheng Yu, Li Yatian. Fault diagnosis of inverter based on DCM - PCA and GA - BP neural network[J]. Journal of Electric Power Science and Technology, 2024, 39(1): 260-271.
- [26] 墨 蒙,赵龙章,龚媛雯,等.基于遗传算法优化的BP神经网络研究应用[J].现代电子技术,2018,41(9):41-44.
Mo Meng, Zhao Longzhang, Gong Aiwen, et al. Research and application of BP neural network based on genetic algorithm optimization[J]. Modern Electronics Technique, 2018, 41(9): 41-44.
- [27] 邹春玲,熊 静,刘 超,等.基于遗传算法优化BP神经网络的飞机油耗预测方法[J].智能计算机与应用,2023,13(3):226-230.
Zou Chunling, Xiong Jing, Liu Chao, et al. Aircraft fuel consumption prediction method based on BP neural network optimized by genetic algorithm[J]. Intelligent Computer and Applications, 2023, 13(3): 226-230.
- [28] 王团结,赵 赛,郑思嘉.应用BP神经网络的人脸识别系统[J].福建电脑,2020,36(7):27-29.
Wang Tuanjie, Zhao Sai, Zheng Sijia. Face recognition system based on BP neural network[J]. Fujian Computer, 2020, 36(7): 27-29.
- [29] 何汶静,赵 毅.电气光纤光栅测温火灾预警技术[J].消防科学与技术,2011,30(8):711-714.
He Wenjing, Zhao Yi. Bragg fiber gratings temperature monitoring system for warning of electric fire[J]. Fire Science and Technology, 2011, 30(8): 711-714.
- 桑仲庆(1977—),男,高级工程师,研究生导师,主要从事电气设备一二次融合研究(E-mail:1668422809@qq.com)。
袁会生(1996—),男,硕士研究生,主要从事高压电器在线监测及故障诊断研究(通信作者)(E-mail:1010917287@qq.com)。