

# 基于 ACO 优化 BP 神经网络的变压器热点温度预测

江兵 杨春 杨雨亭 巢一帆  
(南京邮电大学自动化学院 南京 210023)

**摘要:**针对变压器热点温度预测精度问题,提出一种蚁群算法(ant colony algorithm, ACO)结合改进主成分分析法(improved principal component analysis, IPCA)优化 BP 神经网络的热点温度预测模型。首先采用 IPCA 去除数据冗余信息,并解决参数间相关性问题,提高网络泛化能力。为了避免 BP 神经网络容易陷入局部最优和收敛速度慢,利用 ACO 优化网络权值和与阈值,加快算法速率,提高预测精度。通过变压器温度实测数据验证,预测结果中的 mae、mse、mape 指标分别为 0.065 7、0.006 7、0.44%,预测精度和网络性能优于 IEEE、BP、IPCA-BP 模型,从而验证所提模型的有效性和可行性。

**关键词:**热点温度;BP 神经网络;改进 PCA;蚁群算法

**中图分类号:** TN06 **文献标识码:** A **国家标准学科分类代码:** 470.4

## Temperature prediction of transformer hot spot based on BP neural network optimized by ACO

Jiang Bing Yang Chun Yang Yuting Chao Yifan

(College of Automation, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

**Abstract:** Aiming at the prediction accuracy of transformer hot spot temperature, the ant colony algorithm (ACO) combined with improved principal component analysis (IPCA) was proposed to optimize BP neural network model to predict hot spot temperature. Firstly, IPCA is used to remove data redundancy information and solve the correlation between parameters to improve the ability of network generalization. In order to avoid BP neural network that is easily falling into local optimum and slow convergence speed, ACO was used to optimize the weights and thresholds of the network to speed up the algorithm and improve the prediction accuracy. Verified by the measured transformer temperature data, the mae, mse and mape indexes in the predicted results are 0.065 7, 0.006 7 and 0.44%, respectively. The prediction accuracy and network performance are better than those of IEEE, BP and IPCA-BP models, thus verifying the validity and feasibility of the proposed model.

**Keywords:** hot spot temperature; BP neural network; improved PCA; ACO

## 0 引言

随着国民经济发展中电能需求的增加,变压器安全运行显得尤为重要<sup>[1]</sup>。作为电力系统中核心设备之一的变压器一旦因故障停运,将会对电网产生巨大的危害<sup>[2-3]</sup>。其中绕组热点温度过高将会加速绝缘材料的老化,缩短变压器使用寿命<sup>[4]</sup>。据导则 GB/T 1094.7-2008 规定,温度每超过 6 °C,变压器老化速率就会增加一倍<sup>[5]</sup>。

在绕组的线饼中埋覆温度传感器可以直接测得热点

温度,该方法简单直接,但在早期由于技术的限制,人们无法确定热点位置,需要在绕组埋覆较多的温度传感器,这样会影响绕组电场分布,增加电磁干扰,降低绕组绝缘效果,影响变压器运行<sup>[6-7]</sup>。文献[8]利用 ANSYS 软件对变压器进行温度场仿真,获取热点的具体位置信息,并结合光纤光栅测温技术,虽然能很好地监测热点温度数据,但对于投运的变压器进行拆解和安装会导致维护费用增加及安全性能问题。导则计算法作为常用的经验计算公式,实现简单、应用范围广,但该方法将变压器运行时的传热过程进行简化,忽略整个系统的非线性因素,计算结果存在一定误差<sup>[9-10]</sup>。文献[11]在考虑负载下降和环境

中风速作用情况下,引入风速修正因子,对经验公式进行改进,虽比标准经验公式更加准确地计算热点温度,但特性参数和修正因子的选择对结果有较大影响。

人工智能算法可根据变压器历史运行数据构建热点温度与各变量间关系模型,因此被运用于变压器绕组热点温度预测领域<sup>[12-13]</sup>。文献[14]采用 Kalman 滤波算法建立热点温度的状态方程和测量方程,并对热点温度进行实时预估,此方法存在时滞性且未考虑噪声信号和环境因素的影响,因此预测精度有待提高。文献[15]利用最小二乘法优化双支持向量回归机,预测精度和性能优于传统支持向量回归机,但算法存在较大计算复杂度。神经网络结构简单,具有良好的自学习性和自适应性,对热点温度预测有较好效果<sup>[16-17]</sup>。文献[18]采用标准主成分分析法结合神经网络对热点温度预测并取得了较好的效果,但标准主成分分析法未考虑原始参数之间的差异性,同时神经网络容易陷入局部最优的缺陷并未解决,因此该方法需要进一步优化。

基于前人在神经网络领域对热点温度预测研究思路,文中建立 BP 神经网络作为热点温度预测模型,采用改进主成分分析法(IPCA)对原始数据进行处理,消除数据间的相关性,提高网络泛化能力。结合蚁群算法(ACO)全局寻优出网络的最佳权值和阈值,消除其易陷入局部最优的缺陷,进一步提高模型预测精度。文中结合变压器热点温度实测数据,分别与 IPCA-BP、传统 BP 神经网络、IEEE 导则预测模型的结果进行对比,验证了文中算法切实可行,能很好地预测热点温度。

## 1 IEEE 导则计算法

各类油浸式变压器在不同负载率情况下,IEEE 导则法规定变压器热点温度为环境温度、顶层油温升、热点温度相对顶层油温梯度之和<sup>[19-20]</sup>。导则计算公式为:

$$T_{hot} = T_{amb} + T_{top,f} \left[ \frac{1 + RK^2}{1 + R} \right]^x + Hg, K^y \quad (1)$$

式中:  $T_{hot}$  为热点温度;  $T_{amb}$  为环境温度;  $T_{top,f}$  为额定负载率下顶层油温的相对环境温度温升;  $R$  为损耗比;  $K$  为负载率;  $Hg$  为额定负载率下热点温度相对顶层油温的温度梯度;  $x, y$  为与变压器结构和冷却方式相关的指数。

## 2 BP 神经网络

BP 神经网络是一种信号前向传递,误差反向传播的多层前馈网络。根据实际值和预测值之间的误差来不断修正网络权值或阈值,直到输出误差在设定范围内。BP 神经网络具有较强的自学习性和自适应性,特别适合在多因素、不确定、模糊的信息处理领域<sup>[21]</sup>。网络由输入

层、隐含层、输出层 3 层网络构成,每层的神经元数分别为  $N_R, L_R, M_R$ , 结构如图 1 所示。

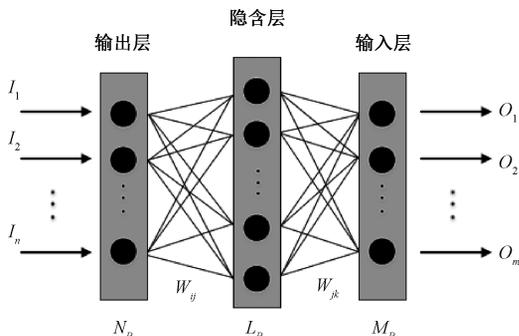


图 1 BP 神经网络结构

Fig. 1 Structure of BP neural network

其中,  $[I_1, I_2, \dots, I_n]$  为输入向量;  $[O_1, O_2, \dots, O_m]$  为输出向量;  $N_R$  为输入层个数;  $L_R$  为隐含层个数;  $M_R$  为输出层个数;  $w_{ij}$  为第  $i$  个输入层到第  $j$  个隐含层之间的连接权值;  $w_{jk}$  为第  $j$  个隐含层到第  $k$  个输出层之间的连接权值。

BP 神经网络的缺点是网络结构不易确定,当输入参数相关性较强时,会使网络泛化能力减弱。此外,BP 神经网络采用梯度下降算法,收敛速度慢,在进行复杂问题优化时,受权值和阈值的影响,网络容易陷入局部最优,影响预测效果。

## 3 ACO-IPCA-BP 神经网络模型

### 3.1 IPCA 算法

主成分分析法(principal components analysis, PCA)在统计领域中有着很好地应用,当研究多元变量时,为了消除变量之间的相关性,通过数据降维操作保留主成分,该方法可以有效地解决数据信息的冗余问题,提高算法效率<sup>[22]</sup>。

标准主成分分析法提取主成分步骤为数据标准化、确定主成分、计算主成分方差贡献率和累计方差贡献率、选取主成分。其中数据标准化使各参数指标方差均为 1,目的是使各指标与主成分的联系趋于相同,该方法未考虑指标具有不同离散程度时对主成分选取的影响。因此,文中采用数据均值化处理,使提取的主成分能更好地覆盖原始数据信息<sup>[23]</sup>。主成分提取步骤如下:

#### 1) 数据均值化

对原始采集的  $m$  维变量  $\mathbf{X} = [X_1 \ X_2 \ \dots \ X_m]$ , 由  $n$  个样本  $\mathbf{x}_i = [x_{i1} \ x_{i2} \ \dots \ x_{im}]$ ,  $i = 1, 2, \dots, n$  ( $n > m$ ) 组成原始观测信息矩阵如下:

$$\mathbf{X} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1m} \\ x_{21} & x_{22} & \cdots & x_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{nm} \end{bmatrix} \quad (2)$$

对原始观测数据进行均值化处理得到均值化矩阵  $\mathbf{Z} = (z_{ij})_{n \times m}$ ,  $z_{ij}$  计算公式如下:

$$z_{ij} = \frac{x_{ij} - \bar{x}_j}{\bar{x}_j} \quad (i = 1, 2, \dots, n; j = 1, 2, \dots, m) \quad (3)$$

式中:  $\bar{x}_j$  为样本中变量的均值。

### 2) 主成分确定

主成分分析法通过线性组合将式(2)中  $m$  个变量形成综合变量  $[F_1, F_2, \dots, F_m]$ , 称为  $[X_1, X_2, \dots, X_m]$  的第 1, 2,  $\dots$ ,  $m$  个主成分, 如式(4)所示, 其中组合系数需满足:  $a_{1i}^2 + a_{2i}^2 + \dots, a_{mi}^2 = 1$ 。

$$\begin{cases} F_1 = a_{11}X_1 + a_{21}X_2 + \dots + a_{m1}X_m \\ F_2 = a_{12}X_1 + a_{22}X_2 + \dots + a_{m2}X_m \\ \vdots \\ F_m = a_{1m}X_1 + a_{2m}X_2 + \dots + a_{mm}X_m \end{cases} \quad (4)$$

组合系数  $a_{ij}(i, j = 1, 2, \dots, m)$  是确定主成分的关键, 根据如下准则来求解:

(1)  $F_i$  与  $F_j$  互不相关, 即  $Cov(F_i, F_j) = 0 (i, j = 1, 2, \dots, m)$ ;

(2) 选取  $F_i (i = 1, 2, \dots, m)$  为  $[X_1, X_2, \dots, X_m]$  中一切线性组合的方差最大项, 方差  $Var(F_i)$  越大则表示  $F_i$  包含的信息越多。

根据以上准则建立均值化矩阵  $\mathbf{Z}$  的相关系数矩阵  $\mathbf{R}$ :

$$\mathbf{R} = \frac{\mathbf{Z}^T \mathbf{Z}}{n - 1} \quad (5)$$

求解相关系数矩阵  $\mathbf{R}$  的特征方程  $|\lambda \mathbf{I} - \mathbf{R}| = 0$  得特征根  $\lambda_i (i = 1, 2, \dots, m)$  及特征向量  $\mathbf{A}_i (i = 1, 2, \dots, m)$ , 因此  $\mathbf{R}$  的第  $i$  特征根所对应的单位特征向量即为第  $i$  个主成分  $F_i$  所对应的组合系数<sup>[24]</sup>。

### 3) 计算方差贡献率和累计方差贡献率

方差贡献率  $G_i$  用来反映所包含信息量的大小, 累计方差贡献率  $G(l)$  可以确定主成分个数  $l$ , 二者计算公式如式(6)所示。

$$\begin{cases} G_i = \lambda_i / \sum_{k=1}^m \lambda_k \\ G(l) = \sum_{k=1}^l \lambda_k / \sum_{k=1}^m \lambda_k \end{cases} \quad (6)$$

结合方差贡献率知, 前  $i$  个累计方差贡献率越大则表示前  $i$  个主成分原始信息观测量就越大。

### 4) 选取主成分

为减少信息损失, 当累计方差贡献率  $G(l) \geq 95\%$  时, 所选取的主成分即可反映原始数据信息, 对应的  $l$  就是抽取的前  $l$  个主成分, 再根据式(4)可获得符合要求的  $l$  个主成分值。

## 3.2 ACO 优化 BP 神经网络

### 1) 蚁群算法原理

蚁群算法是模拟自然界中蚂蚁寻径行为而提出的一种优化算法, 具有较强的全局搜索能力, 其原理为:

将  $m$  只蚂蚁随机放到  $n$  座城市上, 蚂蚁  $k (1 \leq k \leq m)$  根据路径上的信息素和城市之间的距离来选择下一座城市。在  $t$  时刻, 蚂蚁  $k$  从城市  $i$  转移到城市  $j$  的概率为:

$$P_{ij}^k(t) = \begin{cases} \frac{[\tau_{ij}(t)]^a \cdot [\omega_{ij}]^b}{\sum_{k \in J_k(i)} [\tau_{ij}(t)]^a \cdot [\omega_{ij}]^b}, j \in J_k(i) \\ 0, \text{其他} \end{cases} \quad (7)$$

式中:  $\tau_{ij}(t)$  为  $t$  时刻路径上信息素量;  $\omega_{ij}$  为路径的启发信息, 通常反比于路径长度;  $a$  为信息启发式因子;  $b$  为期望启发式因子;  $J_k$  表示第  $k$  只蚂蚁未到过城市。

当蚂蚁遍历完所有城市后, 各路径上的信息素量重新调整为:

$$\begin{cases} \tau_{ij}(t+1) = \eta \tau_{ij}(t) + \Delta \tau_{ij} \\ \Delta \tau_{ij} = \sum_{k=1}^m \Delta \tau_{ij}^k \end{cases} \quad (8)$$

式中:  $\eta$  表示信息素的残留率;  $\Delta \tau_{ij}$  为每次遍历结束后  $m$  只蚂蚁留在路径上的总信息素量;  $\Delta \tau_{ij}^k$  每次遍历蚂蚁  $k$  在路径上留下的信息素量, 其中:

$$\Delta \tau_{ij}^k = \begin{cases} \frac{Q}{L_k}, \text{若蚂蚁从城市 } i \text{ 经过城市 } j \\ 0, \text{其他} \end{cases} \quad (9)$$

式中:  $Q$  为蚂蚁  $k$  能释放总的信息素量, 为常数;  $L_k$  为蚂蚁  $k$  在遍历过程中走过的路径长度。

当所有蚂蚁的路径都为同一条最优时, 或者达到最大的迭代次数, 则蚁群算法终止<sup>[25]</sup>。

### 2) ACO 优化 BP 原理

蚁群算法具备良好的全局寻优能力, 优化 BP 神经网络时, 根据训练样本的输出误差和期望误差对比结果调整蚂蚁寻径时的信息素量和路径选择, 不断重复优化 BP 神经网络的权值和阈值初始值。其基本流程为:

(1) 令 BP 神经网络有  $M$  个待优化的权值和阈值, 每个权值和阈值设为  $n$  个随机非 0 值, 并组成集合  $I_{P_i} (1 \leq i \leq M)$ 。

(2) 初始时刻,  $m$  只蚂蚁中第  $k (1 \leq k \leq m)$  只蚂蚁从集合  $I_{P_i}$  出发, 根据状态转移概率从集合  $I_{P_i}$  中挑选一个元素  $j$ 。当从所有集合中挑选完元素后, 构成 BP 神经网络的一组权值和阈值。

(3) 当  $m$  只蚂蚁全部完成循环, 即可得到  $m$  组初始

权值和阈值,构建 BP 神经网络并进行训练。记录网络训练时误差最小的一组权值和阈值,比较最小误差和期望误差大小,若大于期望误差,则执行步骤(4),否则执行步骤(6)。

(4)对集合  $I_{p_i}(1 \leq i \leq M)$  中每个元素的信息素量进行调整,调整公式为:

$$\begin{cases} \tau_j(t+M) = \eta \cdot \tau_j(I_{p_i})(t) + \tau_j(I_{p_i}) \\ \tau_j(I_{p_i}) = \sum_{k=1}^m \Delta \tau_j^k(I_{p_i}) \end{cases} \quad (10)$$

式中:  $\Delta \tau_j(I_{p_i})$  为每次循环时集合  $I_{p_i}$  中元素  $j$  信息素增量;  $\Delta \tau_j^k(I_{p_i})$  为第  $k$  只蚂蚁在每次循环中留在集合  $I_{p_i}$  元素  $j$  信息素量,公式为:

$$\Delta \tau_j^k(I_{p_i}) = \begin{cases} \frac{Q}{e_k} [\text{循环中经过的路径}(i,j)] \\ 0, \text{其他} \end{cases} \quad (11)$$

式中:  $e_k$  为蚂蚁  $k$  挑选的权值和阈值训练 BP 神经网络得到的网络输出和期望输出间的误差。

(5)重复步骤(2)和(3)直到所有蚂蚁收敛于同一条最优路径或者达到最大迭代次数。

(6)利用蚁群算法筛选出的最优 BP 神经网络初始权值和阈值,进一步训练神经网络,满足训练条件后退出。

### 3) ACO-IPCA-BP 神经网络流程

文中采用改进主成分分析法(IPCA),对网络入口参数进行处理,在保留原始数据信息的前提下,有效地解决参数之间的相关性,通过蚁群算法全局寻优出 BP 神经网络的最佳权值和阈值,从而提高预测精度,实现优化网络的目的。ACO-IPCA-BP 神经网络模型构建流程如图 2 所示。

## 4 模型仿真和结果分析

### 4.1 实验数据

文中采集某变电站 220 KV 油浸式变压器(如图 3)实时监测数据作为算法验证样本集,部分监测数据如图 4 所示,将热点温度作为网络输出,负载率、顶层油温、环境温度作为网络输入,对 ACO-IPCA-BP 网络模型进行实例验证。

### 4.2 IPCA 处理

对 4.1 节中实验数据进行 IPCA 分析,得影响热点温度的各参数之间相关系数矩阵如表 1 所示。

表 1 各参数之间相关系数矩阵

Table 1 Correlation coefficient matrix among parameters

	负载率	顶层油温	环境温度
负载率	1	0.947	0.823
顶层油温	0.947	1	0.862
环境温度	0.823	0.862	1

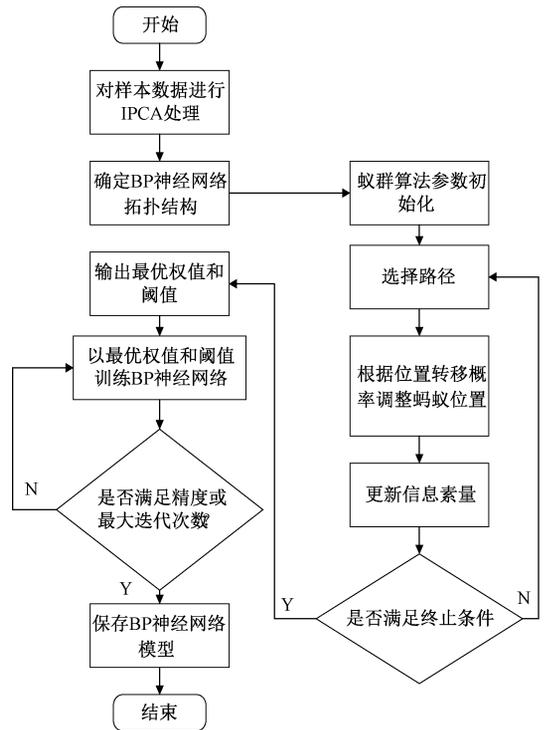


图 2 ACO-IPCA-BP 神经网络模型构建流程

Fig. 2 ACO-IPCA-BP neural network model construction process



图 3 220 KV 油浸式变压器

Fig. 3 220 KV oil-immersed transformer

由表 1 知,各参数之间的相关系数均在 0.8 以上,表明各参数之间相关性较强,会影响 BP 神经网络的泛化能力。对这些参数进一步做 IPCA 提取处理,得各成分方差贡献率和累积方差贡献率,如表 2 所示。

表 2 各成分方差贡献率和累积方差贡献率

Table 2 Variance contribution rate and cumulative variance contribution rate of each component

特征值	方差贡献率/%	累积方差贡献率/%
2.756	91.867	91.867
0.195	6.5	98.367
0.049	1.633	100

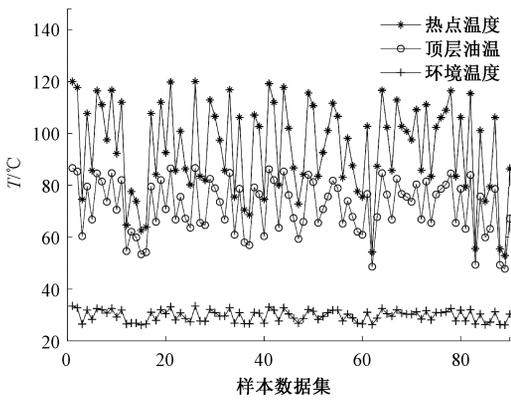


图 4 实测温度数据

Fig. 4 Measured temperature data

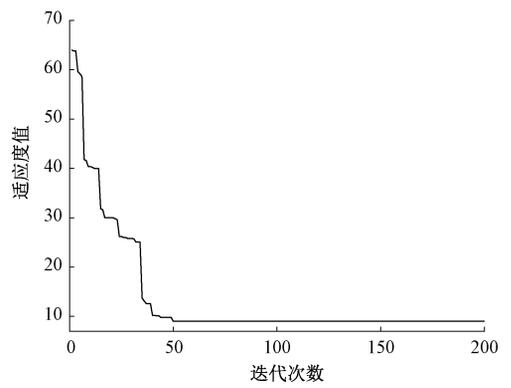


图 5 蚁群算法迭代过程

Fig. 5 Iteration process of ACO

由表 2 知,前两个主成分的累积方差贡献率已超过 98%,包含了原始数据的绝大部分信息,可求得主成分的组合系数如表 3 所示,结合式(4)即可求得所需主成分。

表 3 主成分组合系数

Table 3 Combination coefficients of principal components

主成分 F1 组合系数	主成分 F2 组合系数
0.581	0.505
0.589	0.281
0.561	-0.816

### 4.3 模型预测结果分析

#### 1) 模型参数初始化

文中用 MATLAB 软件作为仿真环境,根据 BP 神经网络参数选择经验,采用 3 层网络结构进行训练,输入层数  $M_R = 2$ ,输出层数  $N_R = 1$ ,隐含层数  $L_R$  根据经验公式(12)选取。设置训练次数为 1 000,最小目标误差为  $10^{-6}$ ,学习速率为 0.01。

$$L_R = \sqrt{M_R + N_R} + A \quad (12)$$

式中: $A$  为  $[1 \sim 10]$  之间的整数。

设置蚂蚁数量  $m = 20$ ;信息素残留率  $\eta = 0.1$ ;蚂蚁位置转移概率  $P_{ij} = 0.2$ ;信息素释放总量  $Q = 1$ ;自变量范围设置为  $[0, 1]$ ;最大迭代次数设置为 200;蚁群算法迭代过程如图 5 所示。

由图 5 知,蚁群算法优化 BP 神经网络的过程中,迭代次数达到 50 次时,就会收敛且变得相对平稳,说明模型初始化参数的设置较为合理。

#### 2) 预测结果及分析

采集 230 组油浸式变压器实时温度数据,将前 200 组数据作为训练样本,后 30 组数据为预测样本。为证明文中算法较优,分别与 BP、IEEE 负载导则、IPCA-BP 等模型预测结果进行对比,采用均方误差 (mse)、平均绝对

误差 (mae)、平均绝对百分比误差 (mape) 3 种评价指标对各模型预测结果进行精度评定。模型训练的网络性能如图 6 和 7 所示,各模型预测结果误差如图 8 和 9 所示,评价指标比较结果如表 4 所示。

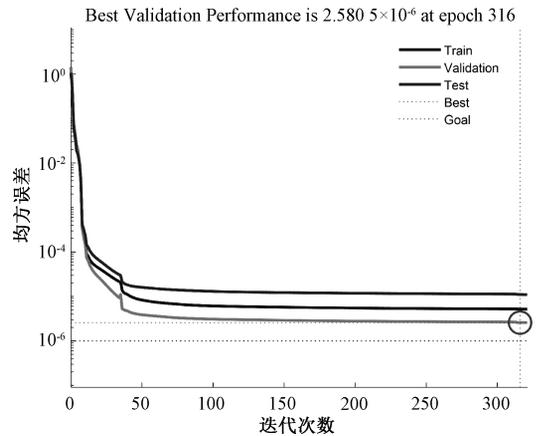


图 6 标准 BP 神经网络训练迭代过程

Fig. 6 Training iteration process of standard BP neural network

表 4 各模型预测结果评价指标

Table 4 Evaluation indexes of prediction results of each model

	平均绝对误差 (mae)	均方误差 (mse)	平均绝对百分比 误差 (mape)/%
IEEE	7.414 1	65.336 6	24.71
BP	1.837 3	5.925 7	6.12
IPCA-BP	1.049 6	1.682 2	3.50
ACO-IPCA-BP	0.065 7	0.006 7	0.44

由图 6 知,标准 BP 神经网络在训练时需要迭代 316 次才能达到算法终止条件,迭代次数较多,算法速率较慢。另由图 7 知,原始数据经过 IPCC 算法处理,再经 ACO 算法优化,模型在训练时所需 66 次迭代即可达到终止条件,网络性能整体较好,算法速率有较大提高。

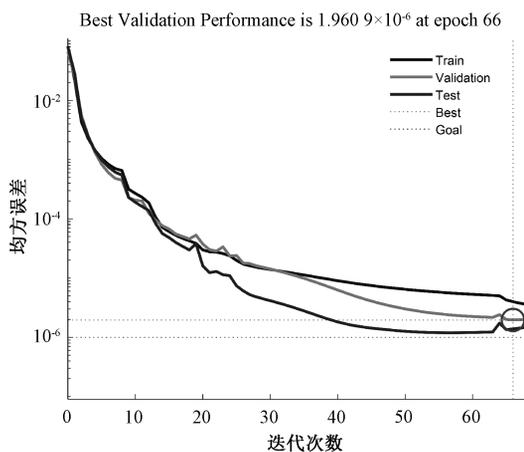


图 7 ACO 优化 IPCA-BP 神经网络训练迭代过程  
Fig. 7 Training iteration process of ACO optimization IPCA-BP neural network

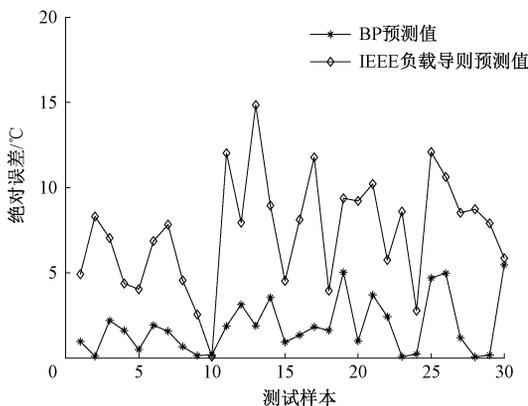


图 8 IEEE 负载导则与 BP 预测绝对误差  
Fig. 8 Absolute error between IEEE load guidelines and BP prediction

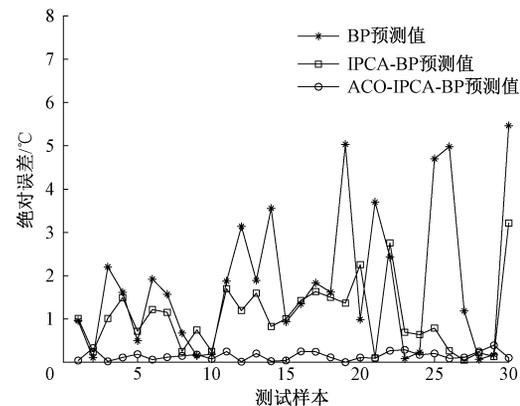


图 9 ACO-IPCA-BP 预测绝对误差  
Fig. 9 Absolute error of ACO-IPCA-BP prediction

误差在文中所有模型为最大值,是由于导则算法没有综合考虑变压器系统的非线性因素,导致预测值与实际值偏差较大。标准 BP 神经网络预测结果误差整体小于 IEEE 负载导则,但综合表 4 中各项评价指标知,该算法指标仍然偏大,需进一步优化。另由图 9 及表 4 知,标准 BP 神经网络经过 IPCA 算法处理模型参数后,网络模型的 mae、mse、mape 分别为 1.049 6、1.682 2、3.5%,算法预测精度和性能优于传统 BP 神经网络。此外,IPCA-BP 算法经过 ACO 算法进一步优化,性能评价指标为 0.065 7、0.006 7、0.44%,模型的预测精度和网络性能整体更好,从而验证了文中所提算法能更好地应用于热点温度预测。

### 5 结 论

为实现对变压器运行时热点温度预测,文中提出一种 ACO-IPCA-BP 网络预测模型。采用 IPCA 算法对输入参数进行处理,在保留原始数据绝大部分信息的基础上,消除网络模型输入参数之间的相关性,提高 BP 神经网络的泛化能力。

针对传统 BP 神经网络容易陷入局部最优的缺点,利用 ACO 算法良好的全局寻优能力,优化 BP 神经网络权值和阈值,提高算法效率,并进一步提高网络模型的预测精度。

文中通过实测数据对网络模型进行训练,并将不同模型的网络性能和预测结果进行对比分析,其中 ACO-IPCA-BP 网络模型的各种综合性能评价指标较 IEEE 负载导则、传统 BP 网络、IPCA-BP 模型有了很大的提升,从而验证了文中算法模型精度高、效率快,能在实际热点温度预测中有着很好的应用。

### 参考文献

[ 1 ] 高国磊,李英娜,段效琛,等. 基于 ACO 优化 LS-SVM 的变压器故障诊断[J]. 电子科技, 2018, 31(6):59-62,74.  
GAO G L, LI Y N, DUAN X CH, et al. A fault diagnosis method for transformer based on least squares support vector machine optimized by ant colony optimization [J]. Electronic Science and Technology, 2018, 31(6):59-62,74.

[ 2 ] 李黄曼,张勇,张瑶. 基于 ISSA 优化 SVM 的变压器故障诊断研究[J]. 电子测量与仪器学报, 2021, 35(3): 123-129.  
LI H M, ZHANG Y, ZHANG Y. Study of transformer fault diagnosis based on improved sparrow search algorithm optimized support vector machine [J]. Journal of Electronic Measurement and Instrumentation, 2021,

由绝对误差图 8 和 9 知,IEEE 负载导则的预测结果

- 35(3):123-129.
- [ 3 ] 刘行谋,薛金鑫,杨永明,等. 变压器铁芯搭接区磁热等效及温升影响研究[J]. 仪器仪表学报, 2020, 41(6):187-196.
- LIU X M, XUE J X, YANG Y M, et al. Research on magnetic heat equivalent and temperature rise of the lap area of transformer core [J]. Chinese Journal of Scientific Instrument, 2020, 41(6):187-196.
- [ 4 ] ALLAHBAKHSI M, AKBARI A. An improved computational approach for thermal modeling of power transformers[J]. International Transactions on Electrical Energy Systems, 2015, 25(7):1319-1332.
- [ 5 ] 李明洋, 张俊双, 李海明, 等. 500 kV 单相变压器直流偏磁下损耗及绕组热点温度的计算分析[J]. 电工电能新技术, 2021, 40(8):51-59.
- LI M Y, ZHANG J SH, LI H M, et al. Calculation and analysis of loss and winding hot spot temperature under DC bias of 500 kV single-phase transformer [J]. Advanced Technology of Electrical Engineering and Energy, 2021, 40(8):51-59.
- [ 6 ] 周爱东. 超高压电力变压器绕组热点温升的解析与在线监测[D]. 北京:华北电力大学, 2014.
- ZHOU AI D. Analysis and online monitoring of temperature rise of hot spot winding of uHV power transformer [D]. Beijing: North China Electric Power University, 2014.
- [ 7 ] SALEH N, AZIS N, JASNI J, et al. Prediction of a transformer's loading and ambient temperature based on SARIMA approach for hot-spot temperature and loss-of-life analyses[C]. 2021 IEEE International Conference on the Properties and Applications of Dielectric Materials (ICPADM). IEEE, 2021: 123-126.
- [ 8 ] 贾丹平, 赵璐, 皇甫丽影. 变压器绕组热点温度监测技术的研究[J]. 计量学报, 2022, 43(2):7:235-241.
- JIA D P, ZHAO L, HUANGFU L Y. Research on hot spot temperature monitoring technology of transformer winding. [J]. Acta Metrologica Sinica 2022, 43(2): 235-241.
- [ 9 ] 朱培勇.《油浸式电力变压器负载导则》讲座(上)[J]. 供用电, 2000(1):52-55.
- ZHU P Y. Lecture on load guidelines of oil immersed power transformer [J]. Distribution & Utilization, 2000(1):52-55.
- [ 10 ] MUKHOPADHYAY P, MITRA G, BANERJEE S, et al. Electricity load forecasting using fuzzy logic: Short term load forecasting factoring weather parameter[C]. 2017 7th International Conference on Power Systems (ICPS). 2017:812-819.
- [ 11 ] 亢银柱, 晋涛, 牛曙, 等. 基于改进经验公式的油浸式变压器热点温度计算[J]. 电测与仪表, 2020(7):1-7.
- KANG Y ZH, JIN T, NIU SH, et al. Calculation of hot spot temperature of oil-immersed transformer based on improved empirical formula [J]. Electrical Measurement and Instrumentation 2020(7):1-7.
- [ 12 ] PENG D, CHEN Y, QIAN Y, et al. Transformer winding temperature soft measurement model based on particle swarm optimization-support vector regression [J]. Transactions of China Electrotechnical Society, 2018, 33(8):1742-1749, 1761.
- [ 13 ] KAZEMI A A, VAKILIAN M, NIAYESH K, et al. Datamining of online diagnosed waveforms for probabilistic condition assessment of SF6 circuit breakers [J]. IEEE Transactions on Power Delivery, 2015, 30(3):1354-1362.
- [ 14 ] 苏小平, 陈伟根, 奚红娟, 等. 采用 Kalman 滤波算法预测变压器绕组热点温度[J]. 高电压技术, 2012, 38(8):1909-1916.
- SU X P, CHEN W G, XI H J, et al. Winding hot-spot temperature prediction for oil-immersed power transformer based on Kalman filter algorithm [J]. High Voltage Engineering, 2012, 38(8):1909-1916.
- [ 15 ] 张磊, 杨廷方, 李炜, 等. 基于 LSTSVR 模型的边缘计算预测变压器平均油温及绕组热点温度[J]. 电力自动化设备, 2020, 40(8):197-203.
- ZHANG L, YANG T F, LI W, et al. Prediction of transformer average oil temperature and winding hot spot temperature by edge computation based on LSTSVR model [J]. Electric Power Automation Equipment, 2020, 40(8):197-203.
- [ 16 ] 廖才波, 阮江军, 蔚超, 等. 变压器热点温度研究方法综述[J]. 高压电器, 2018, 54(7):79-86.
- LIAO C B, RUAN J J, WEI CH, et al. Review of study methods on hot-spot temperature of transformer[J]. High Voltage Apparatus, 2018, 54(7):79-86.
- [ 17 ] LUO X M, RUAN J J, DENG Y Q, et al. T transformer hot-spot temperature inversion based on multi-physics calculation and fuzzy neural network algorithm [J]. High Voltage Engineering, 2020, 46(3):860-866.
- [ 18 ] 奚红娟, 冯浩, 郑贺伟. 一种变压器绕组热点温度预测的神经网络改进方法[C]. 2013 年中国电机工程学会年会论文集, 2013:1479-1484.
- XI H J, FENG H, ZHEN H W. An improved neural network method in predicting the hot spot temperature of transformer winding [C]. 2013 Annual Conference of The Chinese Society of Electrical Engineering, 2013: 1479-1484.

- [19] SONG S J, LI B H. Short-term forecasting method of photovoltaic power based on LSTM [J]. Renewable Energy Resources, 2021, 39(5):9.
- [20] 傅高金. 油浸式电力变压器负载导则指数方程解法应用探讨和对比分析[J]. 变压器, 2021, 58(4):26-30.  
FU G J. Discussion and comparative analysis on application of exponential equation solution in load conductor of oil-immersed power transformer [J]. Transformer, 2021, 58(4):26-30.
- [21] 熊一, 詹智红, 柯方超, 等. 基于改进 BP 神经网络的变电站检修运维成本预测[J]. 电力科学与技术学报, 2021, 36(4):44-52.  
XIONG Y, ZHAN ZH H, KE F CH, et al. Overhaul operation and maintenance cost prediction of substation based on improved BP neural network [J]. Journal of Electric Power Science and Technology, 2021, 36(4):44-52.
- [22] 彭在兴, 王颂, 易林, 等. 基于 SVM 主成分分析的高压断路器分合闸线圈故障诊断研究[J]. 高压电器, 2019, 55(7):39-46.  
PENG Z X, WANG S, YI L, et al. Research on fault diagnosis of high voltage circuit breaker opening/closing coils based on SVM principal component analysis [J]. High Voltage Apparatus, 2019, 55(7):39-46.
- [23] 商立群, 王守鹏. 改进主成分分析法在火电机组综合评价中的应用[J]. 电网技术, 2014, 38(7):1928-1933.  
SHANG L Q, WANG SH P. Application of improved principal component analysis in comprehensive assessment on thermal power generation units [J]. Power System Technology, 2014, 38(7):1928-1933.
- [24] 姜双城, 林培梅, 蔡建堤, 等. 基于 PCA 法的沉积物质量评价模型构建及其应用[J]. 应用海洋学学报, 2020, 39(4):501-510.  
JIANG SH CH, LIN P M, CAI J D, et al. Establishment and application of sediment quality assessment model based on PCA method [J]. Journal of Applied Oceanography, 2020, 39(4):501-510.
- [25] 谢辅雯. 蚁群优化 BP 神经网络的电机故障诊断设计与实现[J]. 制造业自动化, 2012, 34(10):106-108.  
XIE F W. Fault diagnosis for FMS based on BP algorithm and petri net [J]. Manufacturing Automation, 2012, 34(10):106-108.

### 作者简介



江兵(通信作者), 2007 年于中国科学技术大学获博士学位, 现为南京邮电大学副教授, 主要研究方向为智能仪器与测控系统。

E-mail: jiangb@njupt.edu.cn

**Jiang Bing** (Corresponding author), received his Ph. D. degree from University of Science and Technology of China in 2007. Now he is an associate professor at Nanjing University of Posts and Telecommunications. His main research interests include intelligent instruments and measurement and control systems.