

改进 PSO 优化 RBF 智能电能表端子 温度检测方法

樊友杰¹, 邓祥东², 高云鹏², 汤振华¹, 祝君剑¹, 朱 亮¹

1. 国网江西省电力有限公司供电服务管理中心, 江西 南昌 330032; 2. 湖南大学电气与信息工程学院, 湖南 长沙 410082)

摘 要: 针对智能电表前端接线端子温度难以直接检测的问题, 提出一种改进粒子群优化径向基神经网络的智能电能表温度端子检测方法。首先基于 RBF 神经网络建立电能表端子温度与其影响因素映射关系式, 通过 K-Means++ 算法获取合适网络核函数的中心位置; 然后利用递推最小二乘法求解网络核函数连接权值; 最后通过改进粒子群优化 RBF 神经网络宽度系数和模型训练, 推导优化温度映射表达式, 据此实现智能电能表端子温度检测。仿真实验结果表明: 提出的多种群共生改进粒子群优化径向基神经网络算法计算准确度高、搜索能力强、收敛速度快, 温度检测相对误差小于 0.17%, 相比于现有检测方法具有更高的准确度。

关 键 词: RBF 神经网络; 改进 PSO; 温度检测; 智能电能表; 接线端子

DOI:10.19781/j.issn.1673-9140.2022.05.023 中图分类号: TM930 文章编号: 1673-9140(2022)05-0207-08

Terminal temperature detection method for smart meter based on RBF neural network optimized by improved PSO

FAN Youjie¹, DENG Xiangdong², GAO Yunpeng²,
TANG Zhenhua¹, ZHU Junjian¹, ZHU Liang¹

(1. Power Supply Service Management Center of State Grid Jiangxi Electric Power Co., Ltd., Nanchang 330032, China;

2. College of Electrical and Information Engineering, Hunan University, Changsha 410082, China)

Abstract: Aiming at the problem that it is difficult to directly detect the temperature of the front-end terminal of the smart meter, this paper proposes an improved particle swarm optimization radial basis function neural network for the detection of the temperature terminal of the smart meter. First, the mapping relationship between the terminal temperature of the electric energy meter and its influencing factors based on the RBF neural network is established. The central position of the appropriate network core function is selected through the K-Means++ algorithm, and the recursive least square method is used to obtain the network core function connection weight. The improved particle swarm algorithm is used to optimize the width coefficient of RBF neural network and model training, and the optimized temperature mapping expression is derived. Then the terminal temperature detection of the smart electric energy meter is realized. The simulation results show that the improved particle swarm hybrid optimization radial basis function neural network algorithm proposed in this paper has high calculation accuracy, strong search ability, fast

收稿日期: 2021-04-29; 修回日期: 2021-09-11

基金项目: 国家电网有限公司科技项目(52185220000A); 国家自然科学基金(51777061)

通信作者: 高云鹏(1978—), 男, 教授, 博士, 博士生导师, 主要从事电能计量、智能信息处理研究; E-mail: gfront@126.com

convergence speed, and the relative error of temperature detection is less than 0.17%. Compared with the existing detection methods, the proposed method has higher accuracy.

Key words: RBF neural network; improved PSO; temperature check; smart energy meter; terminals

智能传感技术作为电网信息获取的重要手段,其已成为当前智能配电网数字化、物联网化、大数据和智能化发展的重要基础^[1-2]。各类智能传感器作为电网运行的神经末梢,多维度感知数据支撑整个电网生产指挥决策体系,成为电网稳定运行重要保障^[3]。智能电能表作为当前电力物联网感知层末端重要传感设备,具有高准确互动计量、数据处理、远程/本地通信、实时数据交互、多种电价计费、电能质量监测和用户互动等功能^[4-5]。在泛在电力物联网环境业务要求下,提升自身感知与环境安全状态检测能力,需全面提升智能电能表的感知技术研究。而当前智能电能表尚无法监测接线端子温度功能,实现实时告知接线失效与短路故障,造成用户用电安全隐患。因此,开展智能电能表端子温度检测技术研究具有重要的应用价值与现实意义。

为实现接线点与端子温度准确检测,国内外对此技术展开大量研究。其中,遗传算法^[6]、粒子群优化算法(particle swarm optimization, PSO)^[7-8]、支持向量机(SVR)^[9]和神经网络^[10-11]等智能方法应用于其中。文献[10]提出BP神经网络检测开关柜端子温度,但其非线性映射能力不强,模型需进一步优化提升;文献[12]提出PSO优化HKELM检测变压器顶层油温预测法,其网络结构复杂、计算量大;文献[13]构建PSO优化SVM检测太阳能电池温度模型,SVM计算需耗费大量内存和运行时间;文献[14]提出QPSO优化SVR检测排气温度方法,SVR计算效率有待提高。相较于现有机器学习方法,径向基神经网络(radial basis function neural network, RBFNN)作为一种学习效率高、泛化能力强的学习方法^[15-16],具有结构简单、鲁棒性且非线性映射能力强等优点^[17-18]。因此,文献[19]建立基于PSO优化RBF神经网络间隙传感器温度补偿模型,可提高间隙传感器补偿精度,但PSO算法易陷入局部最优且后期收敛速度慢,检测准确度需进一步提高。

为实现智能电能表前端接线端子温度的准确检测,本文提出一种改进粒子群优化RBF神经网络智能电能表接线端子温度检测算法。首先通过K-Means++选择合适RBF神经网络的中心位置,利用递推最小二乘法和改进PSO优化算法分别对RBF神经网络中心参数、宽度系数进行优化和模型训练,推导接线点端子温度的映射函数式,最后通过仿真实验对本文提出方法的准确性和有效性进行验证与分析。

1 径向基神经网络与粒子群算法

1.1 径向基神经网络

RBFNN是一种三层神经网络的局部逼近网络,分为输入层、隐含层和输出层,其特征值从输入层输入,经线性变换形成隐含层,隐含层通过线性叠加形成输出层。多输入单输出的网络模型结构如图1所示。

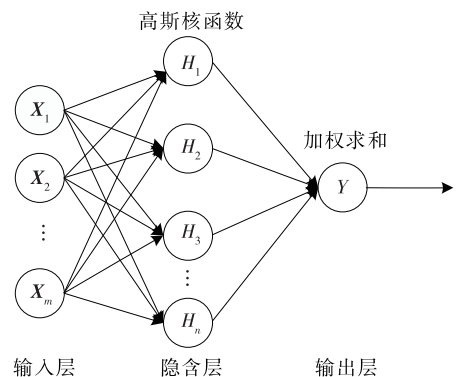


图1 RBF神经网络模型结构

Figure 1 RBF neural network model structure diagram

由图1可知,输入层特征值个数为 m ,中间隐含层的隐藏节点个数为 n ,隐含层激活函数为高斯核函数,对应输出只有一个节点,其RBFNN输出函数为

$$\bar{y} = \sum_{i=1}^n \omega_i \varphi_i(\mathbf{x}) = \sum_{i=1}^n \omega_i e^{-\frac{\|\mathbf{x}-\boldsymbol{\mu}_i\|^2}{2\sigma_i^2}} \quad (1)$$

式中 \bar{y} 为RBFNN网络输出; \mathbf{x} 为RBFNN网络

输入变量,由向量 $\{\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_m\}$ 组成; $\phi_i(x)$ 为隐含层第 i 个神经元函数; ω_i 为隐含层第 i 个节点的连接权重; $\boldsymbol{\mu}_i$ 为第 i 个核函数 $\phi_i(x)$ 的中心向量; σ_i 为第 i 个核函数的宽度参数。

1.2 PSO 优化

PSO 优化算法因其收敛速度快且全局优化能力强^[8],在许多工程领域的优化方面取得了很好的效果^[12]。粒子群优化算法表达式为

$$\begin{aligned} v_i(t+1) = & \omega(t) \cdot v_i(t) + c_1 \cdot \text{rand} \cdot (P_{\text{best},i}(t) - p_i(t)) + c_2 \cdot \text{rand} \cdot (G_{\text{best}}(t) - p_i(t)) \\ p_i(t+1) = & p_i(t) + \omega(t) \cdot v_i(t+1) \end{aligned} \quad (2)$$

式(2)、(3)中 $v_i(t)$ 和 $p_i(t)$ 分别为 i 号粒子第 t 次更新的速度和位置; $\omega(t)$ 为惯性权重;rand 为随机数在 0~1 之间; c_1 、 c_2 为学习因子; $P_{\text{best},i}(t)$ 和 G_{best} 分别为局部最优位置和全局最优位置。

为提升粒子群的全局搜索能力,可产生变动的惯性权重 $\omega(t)$ 和学习因子 c_1 、 c_2 , $\omega(t)$ 原本为 0~1 的常数,即将 $\omega(t)$ 改为 0~1 随机函数,或改为一个随迭代次数 t 递减的函数。

学习因子 c_1 、 c_2 采用递增和递减的变化因子代替恒定的加速因子,即

$$\begin{cases} c_1(t+1) = c_{1,s} - (c_{1,s} - c_{1,e}) \frac{t}{T} \\ c_2(t+1) = c_{2,s} - (c_{2,s} - c_{2,e}) \frac{t}{T} \end{cases} \quad (4)$$

式中 $c_{1,s}$ 、 $c_{2,s}$ 和 $c_{1,e}$ 、 $c_{2,e}$ 分别对应学习因子 c_1 、 c_2 的初始值和终止值; t 为当前的迭代次数; T 为最大的迭代数。通常 $c_{1,s} > c_{1,e}$, $c_{2,s} < c_{2,e}$, c_1 随 t 递减, c_2 随 t 递增。

2 改进 PSO 优化的 RBF 智能电能表温度检测方法

2.1 PSO 改进与重构

粒子群算法因参数少、计算速度快等优点被广泛用于神经网络参数优化,但粒子群算法易于陷入局部最优^[14]。为避免粒子群算法陷入局部最优,本文在粒子群算法中引进共生生物搜索算法,提出多

种群互生粒子群(symbiosis particle swarm optimization, SOPSO)优化 RBF 神经网络算法。

粒子位置向量表示当前的可行解,粒子速度向量表示当前的移动步长。与传统 PSO 粒子速度更新式不同,SOPSO 算法速度向量在原有基础上增加种群间相同位置的相互作差,形成种群间相互促进相互监督的作用。改进后 PSO 速度更新表达式为

$$\begin{aligned} v_{1,i}(t+1) = & \omega_1(t) \cdot v_{1,i}(t) + c_1 \cdot \text{rand} \cdot (P_{1,\text{best},i}(t) - p_{1,i}(t)) + c_2 \cdot \text{rand} \cdot (G_{1,\text{best}}(t) - p_{1,i}(t)) + c_3 \cdot \text{rand} \cdot (p_{2,i}(t) - p_{1,i}(t)) \\ v_{2,i}(t+1) = & \omega_2(t) \cdot v_{2,i}(t) + c_1 \cdot \text{rand} \cdot (P_{2,\text{best},i}(t) - p_{2,i}(t)) + c_2 \cdot \text{rand} \cdot (G_{2,\text{best}}(t) - p_{2,i}(t)) + c_3 \cdot \text{rand} \cdot (p_{1,i}(t) - p_{2,i}(t)) \end{aligned} \quad (5)$$

式中 $v_{1,i}(t)$ 和 $p_{1,i}(t)$ 分别为更新 t 次种群 1 第 i 个粒子的速度和位置; $\omega_1(t)$ 和 $\omega_2(t)$ 为惯性权重; c_1 、 c_2 、 c_3 均为学习因子; $P_{1,\text{best},i}(t)$ 为种群 1 的局部最优位置; $G_{1,\text{best}}$ 为种群 1 的全局最优位置; $v_{2,i}(t)$ 、 $p_{2,i}(t)$ 、 $P_{2,\text{best},i}(t)$ 和 $G_{2,\text{best}}$ 分别为种群 2 的粒子速度、位置、局部最优位置和全局最优位置。种群 1 的惯性权重 ω_1 按传统方式设置,种群 2 的惯性权重 $\omega_2(t)$ 按振动方式设置,提高种群 2 的全局最优值,并利用 2 种群形成的 2 种模式,通过式(5)实现 2 种群相互互补,提高种群的局部和全局最优位置。

式(5)中 $\omega_1(t)$ 为常数 0.618, $\omega_2(t)$ 通过振荡的式给振荡定惯性权重,以增大种群 2 的变化性和全局最优性,振荡惯性权重为

$$\omega_2(t) = 0.618 + 0.99^t \frac{\text{rands}(1)}{2} \quad (6)$$

式中 $\text{rands}(1)$ 为 -1~1 的随机变量值; t 为迭代次数。

求得 $v_{1,i}(t+1)$ 后,与 v_{max} 和 v_{min} 进行比较,即

$$v_{1,i}(t+1) = \begin{cases} v_{\text{min}}, & v_{1,i}(t+1) < v_{\text{min}} \\ v_{1,i}(t+1), & v_{\text{min}} < v_{1,i}(t+1) < v_{\text{max}} \\ v_{\text{max}}, & v_{1,i}(t+1) > v_{\text{max}} \end{cases} \quad (7)$$

式中 v_{min} 为速度允许的最小值; v_{max} 为速度允许的最大值,用于规范粒子的速度范围。根据粒子的速度和惯性权重更新粒子位置,有

$$\begin{cases} p_{1,i}(t+1) = p_{1,i}(t) + \omega_1(t) \cdot v_{1,i}(t+1) \\ p_{2,i}(t+1) = p_{2,i}(t) + \omega_2(t) \cdot v_{2,i}(t+1) \end{cases} \quad (8)$$

式中 $p_{1,i}(t+1)$ 、 $p_{2,i}(t+1)$ 分别为种群 1、2 更新的粒子位置。

2.2 RBF 模型训练与参数优化

RBFNN 结构和参数优化程度对 RBFNN 非线性映射能力有很大影响,文献[19]提出 PSO 混合梯度下降法优化 RBFNN 的参数,但 RBFNN 参数繁多,且类型不一,导致 PSO 产生优化速度慢和容易陷入局部最优的问题。

为提高检测准确度,本文针对 RBF 三类参数采用不同优化方式,K-Means++ 因以最小的误差将数据划分为预定的类数,具有良好分类能力,可用于中心位置 μ 优化;递推最小二乘法(RLS)通过最小误差的平方和求解,既快又准确,可用于连接权重 ω 优化;改进 PSO 算法快速寻优的能力,可用于优化宽度系数和模型训练,改进 PSO 算法避免 PSO 早期陷入局部最优的问题,同时因参数减少而大大加快参数的优化速度。

RBF 神经网络的参数优化和训练首先利用 K-Means++ 聚类出合适的中心位置,之后通过改进 PSO 算法与 RLS 进行宽度系数和连接权值的优化和训练,可得 RLS 递推式为

$$\begin{cases} K(k) = \frac{\lambda^{-1} \mathbf{A}(k-1) f(k)}{1 + \lambda^{-1} f'(k) \mathbf{A}(k-1) f(k)} \\ \xi(k) = y(k) - \omega'(k-1) f(k) \\ \omega(k) = \omega(k-1) + K(k) \xi(k) \\ \mathbf{A}(k) = \lambda^{-1} \mathbf{A}(k-1) - \lambda^{-1} K(k) f'(k) \mathbf{A}(k-1) \end{cases} \quad (9)$$

式中 λ 为遗忘因子,取值介于 0.9~1.0 之间, λ 越接近 1.0,辨识精度越高,但跟踪能力会减弱, λ 越小跟踪能力越强,但辨识收敛过程将波动剧烈,为兼顾跟踪能力和辨识准确度,本文取值为 0.98; $f(k)$ 为第 k 次输入特征集,输入特征集由式(1)激活函数 ϕ 组成; f' 为 f 的转置; $\omega(k)$ 为递推第 k 次连接权重的估计值; ω' 为 ω 的转置; $y(k)$ 为期望的输出真值; $K(k)$ 为递推第 k 次误差修正系数; $\xi(k)$ 为递推第 k 次预测误差值; $\mathbf{A}(k)$ 为递推第 k 次协方差矩阵, $\mathbf{A}(0)$ 为 $n \times n$ 单位矩阵与正值 δ 的乘积, δ 取值

为 10^6 ,用于迭代求解最优 ω 值。

改进 PSO 算法粒子位置向量 \mathbf{p} 由径向基神经网络的宽度系数 σ_1 、 σ_2 和 σ_n 组成,即

$$\mathbf{p} = \{\sigma_1, \sigma_2, \dots, \sigma_n\} \quad (10)$$

$\Delta f(\cdot)$ 为改进 PSO 算法适应度函数,由输出值与实际值的均方误差 M_{SE} 表示适应度函数,则

$$\Delta f(p_i(t)) = M_{SE} = \frac{\sum_{i=1}^k (\bar{y}'_i - y'_i)^2}{k} \quad (11)$$

式中 \bar{y}'_i 、 y'_i 分别为迭代到第 t 次时径向基神经网络输出预测值与实际输出真值; k 为样本个数。

对比 $t+1$ 时刻更新的位置和 t 时刻的个体最优位置和全局最优位置的适应度,更新个体最优和全局最优的位置,个体最优粒子 $P_{best,i}(t)$ 和全局最优粒子 $G_{best}(t)$ 的更新规则为

$$P_{best,i}(t+1) = \begin{cases} P_{best,i}(t), \Delta f(p_i(t+1)) \geq \Delta f(P_{best,i}(t)) \\ p_i(t+1), \Delta f(p_i(t+1)) < \Delta f(P_{best,i}(t)) \end{cases} \quad (12)$$

$$G_{best}(t+1) = \underset{P_{best,i}}{\operatorname{argmin}}(\Delta f(P_{best}(t+1))) \quad (13)$$

式中 $P_{best}(t+1)$ 为 $P_{best,i}(t+1)$ 中 $i=1,2,\dots,n$ 的集合,式(12)、(13)分别应用于种群的局部最优位置和全局最优位置的优化。

为进一步提高检测算法的全局性,加强种群 2 间互动性,将 2 种群通过全局最优位置的适应度关联,其中种群 1 最优位置的适应度为 $\Delta f(G_{1,best}(t))$,种群 2 最优位置的适应度为 $\Delta f(G_{2,best}(t))$,某时刻种群粒子 i 迭代结束后,随机选取粒子 j ($j \neq i$),比较 2 个适应度,最佳适应度大的种群向最佳适应度小的种群学习,按其速度算式运动,具体的更新规则为

$$\begin{cases} p_{1,j}(t+1) = p_{1,j}(t) + \omega_2(t) \cdot v_{2,j}(t+1), \\ \quad \Delta f(G_{2,best}(t)) \geq \Delta f(G_{1,best}(t)) \\ p_{2,j}(t+1) = p_{2,j}(t) + \omega_1 \cdot v_{1,j}(t+1) \\ \quad \Delta f(G_{2,best}(t)) < \Delta f(G_{1,best}(t)) \end{cases} \quad (14)$$

2.3 算法实现流程

本文提出的改进粒子群优化 RBF 神经网络智

能电能表端子温度检测算法流程如图 2 所示。

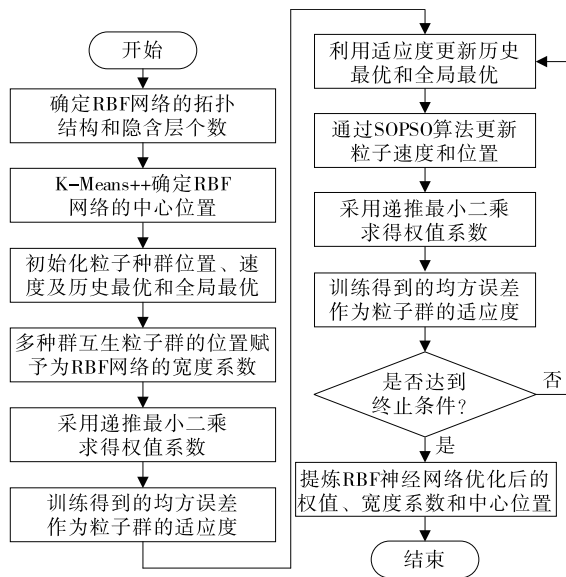


图 2 SOPSO-RBF 算法

Figure 2 SOPSO-RBF algorithm flow chart

1) 采用蒙特卡洛随机优化 K-Means++ 的初试值, 选取 RBF 神经网络最佳的核函数个数和聚类中心向量。

2) 对粒子群进行初始化, 设置 2 个种群, 以 RBF 神经网络核函数的宽度系数 σ 为种群维度, 确定种群规模, 设置各粒子群的初始速度、初始位置、局部最优位置和全局最优位置。

3) 利用改进 PSO 算法寻优算式, 通过式(5)更新粒子速度, 将其更新结果代入式(6)规范粒子速度的范围, 最后由式(8)递推获得新粒子位置, 该粒子位置即为核函数宽度系数。

4) 基于中心位置和宽度系数, 应用迭代最小二乘法, 即式(9)求解输出层的权值参数。

5) 将式(11)作为改进 PSO 算法适应度, 通过式(12)、(13)更新个体最优和全局最优位置, 并由式(14)实现 2 种群间的交叉交流优化全局最优效果, 最后利用步骤 5) 多次迭代步骤 3)、4), 训练求得最优宽度系数和权值参数。

3 仿真实验与分析

3.1 参数设定与模型训练

为验证本文提出的改进 PSO 优化 RBF 智能电

表端子温度检测方法的有效性和准确性, 针对 XG-ZT264 热电堆温度传感器的实测数据进行实验验证, 将 XGZT264 安装于 PCB 电路板正下方靠近端子边沿处, 使其在接线铜柱下方最近位置垂直对准接线铜柱。实验总共有 10 201 组温度实测数据, 随机挑选 4 080 组作为训练数据, 6 121 组作为测试数据。实验基本参数设置如下: 粒子维度 $n=20$, 粒子种群粒子个数设置为 40, 惯性系数 $\omega_1(t)=0.618$, 学习因子 $c_1=2$ 、 $c_2=2.1$ 和 $c_3=2$, 最大迭代次数为 500。采用预测输出值的均方误差 M_{SE} 作为模型适应度函数, M_{SE} 越小说明预测准确度越高, 模型优化效果越优。为证明 SOPSO-RBF 搜索能力和收敛性, 将 SOPSO-RBF 与 PSO-RBF 算法 MSE 收敛曲线对比, 2 种算法 MSE 收敛曲线如图 3 所示。

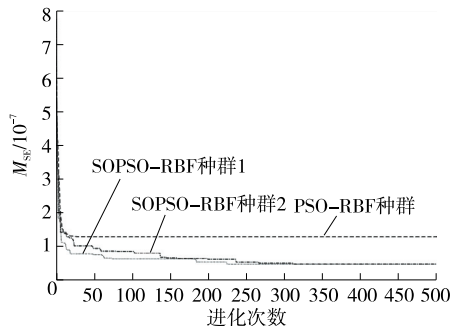


图 3 SOPSO 与 PSO 算法 MSE 收敛曲线

Figure 3 MSE convergence curve of SOPSO and PSO algorithm

由图 3 可知, PSO-RBF 算法适应度在前 30 次左右明显下降, 但立刻陷入局部最优, 本文提出的 SOPSO-RBF 算法在前 50 次迭代优化中急剧下降, 下降速度比 PSO-RBF 下降速度更快、更显著, 且 2 种群在迭代 150 次后依然会相互交替下降, 交替至 300 次才趋于平稳, 可有效地避免粒子群算法陷入局部最优。可见, 本文提出 SOPSO-RBF 算法的搜索能力更强、收敛速度更快。

3.2 仿真结果分析与比较

采用三维立方图描绘 XGZT264 热电堆温度传感器的实测数据, 构建感应电压、环境温度与实际温度的映射关系如图 4 所示。

图 4 中, x 轴和 y 轴分别为热电堆的感应电压和环境温度, z 轴为温度实际输出值。由图 4 可知, 当实测温度相同时, 环境温度越高, 感应电压越小; 当环境温度相同时, 感应电压随实测温度升高而增

大。因此,感应电压随实测温度增大而增大,呈非线性正相关,而环境温度影响感应电压,进一步影响端子温度检测的准确度。




图4 实际温度的映射关系

Figure 4 Map of actual temperature

将训练集样本分别输入传统 RBF 神经网络、PSO-RBF 神经网络和 SOPSO-RBF 神经网络中,得到 3 种测模型,将测试集数据输入,得到各自的预测结果,并与实测温度对比求得温度预测的相对误差。传统 RBF 神经网络、PSO-RBF 神经网络和本文 SOPSO-RBF 神经网络的温度检测相对误差分别如图 5~7 所示。




图5 传统 RBF 算法拟合的相对误差

Figure 5 Relative error of traditional RBF algorithm fitting




图6 PSO-RBF 算法拟合的相对误差

Figure 6 Relative error of PSO-RBF algorithm fitting




图7 SOPSO-RBF 算法拟合的相对误差

Figure 7 Relative error of SOPSO-RBF algorithm fitting

由图 5~7 可知,传统 RBF 神经网络检测温度的最大相对误差为 6.59%,且相对误差普遍偏大,PSO-RBF 算法检测结果的相对误差最大值为 1.54%,本文 SOPSO-RBF 算法检测结果的相对误差最大值为 1.08%。将图 5~7 对比发现,传统 RBF 神经网络的相对误差远大于 PSO-RBF 算法和 SOPSO-RBF 算法的相对误差,PSO-RBF 算法相对误差的凸起明显大于 SOPSO-RBF 算法相对误差的凸起,本文 SOPSO-RBF 算法具有更好的拟合精度和泛化能力。因此,本文 SOPSO 算法相对 PSO 具有更强搜索能力,对 RBF 神经网络参数优化有显著效果,使温度测量准确度得到进一步提高且泛化能力有效提升。

传统 RBF 神经网络、PSO-RBF 神经网络和本文 SOPSO-RBF 神经网络对测试样本的均方根误差和平均相对误差如表 1 所示。

由表 1 可知,SOPSO-RBF 算法平均相对误差 M_{RE} 为 0.17%,分别为 PSO-RBF 算法和传统神经网络算法的 54.84% 和 4.97%;均方误差 M_{SE} 为 4.32×10^{-4} ,分别为 PSO-RBF 神经网络和传统神经网络的 36% 和 0.567%。由此,本文 SOPSO-RBF 算法的检测准确度远高于 PSO-RBF 和传统 RBF 算法。

表1 现有检测方法温度测量误差结果对比

Table 1 Comparison of temperature measurement error results of existing detection methods

方法	M_{RE} 值/%	M_{SE} 值
RBF	3.42	0.076 200 00
PSO-RBF	0.31	0.001 200 00
SOPSO-RBF	0.17	0.000 432 43

4 结语

针对智能电表前端接线端子温度难以直接检测问题,本文提出了一种改进粒子群优化的 RBF 神经网络优化算法,实现了智能电能表端子温度的准确检测。实验结果表明:该方法可有效地实现非接触检测电能表端子温度,且具有较高的准确度,解决了当前电能表端子温度难以直接准确检测的问题。相比于现有检测方法,本文提出方法的检测精度更高,避免了粒子群算法产生早熟收敛和陷入局部最小值问题,增强了算法的全局搜索能力,使获得的 RBF 神经网络逼近与泛化能力更强、结构更紧凑,提出方法可为当前智能电表温度检测与故障预测提供新的解决方案。

参考文献:

- [1] ALBU M M, SĂNDULEAC M, STĂNESCU C. Syncretic use of smart meters for power quality monitoring in emerging networks[J]. IEEE Transactions on Smart Grid, 2017, 8(1): 485-492.
- [2] 陈伟根, 张知先, 李剑, 等. 电气设备状态参量智能传感技术[J]. 中国电机工程学报, 2020, 40(S1): 323-342.
CHEN Weigen, ZHANG Zhixian, LI Jian, et al. Intelligent sensing technology for power equipment state parameters[J]. Proceedings of the CSEE, 2020, 40(S1): 323-342.
- [3] 李鹏, 毕建刚, 于浩, 等. 变电设备智能传感与状态感知技术及应用[J]. 高电压技术, 2020, 46(9): 3097-3113.
LI Peng, BI Jiangan, YU Hao, et al. Technology and application of intelligent sensing and state sensing for transformation equipment[J]. High Voltage Engineering, 2020, 46(9): 3097-3113.
- [4] ALAHAKOON D., YU X. Smart electricity meter data intelligence for future energy systems: a survey[J]. IEEE Transactions on Industrial Informatics, 2016, 12(1): 425-436.
- [5] 张振宇, 程诺, 罗翔, 等. 10 kV 配电网高温超导电缆电热耦合模型仿真分析[J]. 高压电器, 2020, 56(11): 203-209.
ZHANG Zhenyu, CHENG Nuo, LUO Xiang, et al. Electrical-thermal coupling model analysis of high temperature superconducting power cable utilized in 10 kV power distribution system[J]. High Voltage Apparatus, 2020, 56(11): 203-209.
- [6] CHONG S, RUI S, JIE L, et al. Temperature drift modeling of MEMS gyroscope based on genetic-Elman neural network[J]. Mechanical Systems and Signal Processing, 2016, 72: 897-905.
- [7] 刘浩然, 周凯, 王昱皓, 等. 基于电磁耦合注入的电力电缆局部缺陷在线定位方法[J]. 中国电力, 2021, 54(12): 177-185+194.
LIU Haoran, ZHOU Kai, WANG Yuhao, et al. An online location method for local defects in power cables based on electromagnetic coupling injection[J]. Electric Power, 2021, 54(12): 177-185+194.
- [8] 蔡卫江, 李雪峰, 赵士正. 基于粒子群算法的 SVC 抑制阻尼系统振荡控制器设计[J]. 电力科学与技术学报, 2020, 35(5): 60-65.
CAI Weijiang, LI Xuefeng, ZHAO Shizheng. Design of oscillation controller for SVC damping system based on particle swarm algorithm[J]. Journal of Electric Power Science and Technology, 2020, 35(5): 60-65.
- [9] 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 Lei, YANG Tingfang, LI Wei, 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.
- [10] LI J, SUN Y, DONG N. A novel contact temperature calculation algorithm in distribution switchgears for condition assessment[J]. IEEE Transactions on Components, Packaging and Manufacturing Technology, 2019, 9(2): 279-287.
- [11] 周敬嵩, 俞京锋, 唐圣丰, 等. 基于移动式红外测温的变电站设备温度预警系统[J]. 电力科学与技术学报, 2020, 35(1): 163-168.
ZHOU Jingsong, YU Jingfeng, TANG Shengfeng, et al. Research on temperature early warning system for substation equipments based on mobile infrared temperature measurement[J]. Journal of Electric Power Science and Technology, 2020, 35(1): 163-168.
- [12] 白静芬, 卢达, 徐励, 等. 智能电能表自动化检定流水线的温度参比条件影响分析[J]. 电测与仪表, 2020, 57(11): 121-127.

- BAI Jingfen, LU Da, XU Li, et al. Analysis of temperature condition influence of automatic calibrating conveyor line in smart electricity meter[J]. *Electrical Measurement & Instrumentation*, 2020, 57(11): 121-127.
- [13] 刘煜, 王俊江, 焦青, 等. 基于量子行为粒子群算法的含分布式电源的配电网故障定位[J]. *智慧电力*, 2020, 48(8): 51-55.
- LIU Yu, WANG Junjiang, JIAO Qing, et al. Fault location of distribution network with distributed power supply based on quantum behavior particle swarm optimization algorithm[J]. *Smart Power*, 2020, 48(8): 51-55.
- [14] 皮骏, 黄江博, 黄磊, 等. 基于改进 QPSO-SVR 的航空发动机排气温度预测[J]. *振动. 测试与诊断*, 2019, 39(2): 267-272+440.
- PI Jun, HUANG Jiangbo, HUANG Lei, et al. Aero-engine exhaust gas temperature prediction based on QPSO-SVR [J]. *Journal of Vibration, Measurement & Diagnosis*, 2019, 39(2): 267-272+440.
- [15] FERRARI S, BELLOCCHIO F, PURI V, et al. A hierarchical RBF online learning algorithm for real-time 3-D scanner[J]. *IEEE Transactions on Neural Networks*, 2010, 21(2): 275-285.
- [16] KOKSHENEV I, BRAGA A P. An efficient multi-objective learning algorithm for RBF neural network [J]. *Neurocomputing*, 2010, 73(16): 2799-2808.
- [17] 汉京善, 吕海平, 李丹煜, 等. 基于 GA-BP 神经网络算法的输电线路舞动预警方法[J]. *电网与清洁能源*, 2021, 37(4): 1-7+14.
- HAN Jingshan, LÜ Haiping, LI Danyu, et al. Prediction of transmission line galloping using improved bp neural network based on genetic algorithm[J]. *Power System and Clean Energy*, 2021, 37(4): 1-7+14.
- [18] 关鹏, 焦玉勇, 段新胜. 基于 RBF 神经网络的土体导热系数非线性预测[J]. *太阳能学报*, 2021, 42(3): 171-178.
- GUAN Peng, JIAO Yuyong, DUAN Xinsheng. Non-linear prediction of soil thermal conductivity based on RBF neural network [J]. *Acta Energetica Sinica*, 2021, 42(3): 171-178.
- [19] 王海宝, 王峥, 周娴姊, 等. 基于脉冲转换温度传感方法的电力设备温度监测系统研究[J]. *电力系统保护与控制*, 2020, 48(24): 180-187.
- WANG Haibao, WANG Zheng, ZHOU Xianzi, et al. Temperature monitoring system for distribution network equipment using a pulseconversion temperature sensing method[J]. *Power System Protection and Control*, 2020, 48(24): 180-187.