

基于 WNN-GNN-SVM 组合算法的变压器油色谱时间序列预测模型

张施令, 姚 强

(国网重庆市电力公司电力科学研究院, 重庆 401123)

摘要:分析了小波神经网络(WNN)、灰色神经网络(GNN)、支持向量机(SVM)预测方法的原理,利用粒子群优化(PSO)算法对这3种基本预测方法进行了结构参数优化。将WNN、GNN、SVM与PSO-BP算法进行组合,推导得出了组合预测模型最优权系数的计算方法,并优化了组合预测模型拓扑结构参数。算例分析结果表明:经过PSO算法优化后,WNN、GNN、SVM预测模型的预测精度得到了提高,其组合模型较单一模型有更高的预测精度。

关键词:电力变压器;DGA;PSO-BP算法;组合预测模型

中图分类号:TM 41

文献标识码:A

DOI:10.16081/j.issn.1006-6047.2018.09.023

0 引言

电力变压器是电力系统中的重要设备,其运行状态直接关系到电网的安全稳定运行,而电力变压器本体内部油中溶解气体的体积分数及其变化规律与变压器的故障模式关系密切,因此油中溶解气体分析DGA(Dissolved Gas Analysis)技术的应用较为广泛^[1-5]。而电力变压器油中溶解气体体积分数随时间的变化关系实际上为多维时间序列,该序列以相同时间间隔或不同时间间隔排列,包含了电力变压器所处外界环境、运行状况与油中溶解气体体积分数的内在关系,因此可通过该时间序列的预测揭示电力变压器的运行状况,并以此为基础对电力变压器故障类型进行判定^[6]。

文献[7]将一种新的贝叶斯组合神经网络模型应用于短期交通流量的预测,其中贝叶斯组合神经网络由反向传播神经网络和径向基函数(RBF)神经网络构成,该组合模型具有较高预测精度且预测稳定。文献[8]将阶梯遗传算法和BP神经网络联合应用于铁路客运量时间序列预测,预测效果优于单一BP神经网络预测模型。文献[9]提出利用思维进化算法优化BP神经网络、粒子群优化(PSO)算法优化支持向量机(SVM)和基于单隐层前馈网络极限学习机组合进行预测的综合预测体系,其用于微电网的短期负荷预测时具有较高预测精度。以上研究表明时间序列预测应用较为广泛,依据已获取历史时间序列进行数值拟合并在一定时间域内进行预测

具有较大实际应用价值。

目前较多文献均应用单一时间序列预测方法,例如BP神经网络和径向基神经网络等^[10-11],这些单一预测方法通过对网络权值与阈值进行修正可得到具有一定精度的预测效果。为进一步提高预测精度,学者提出了组合预测模型,即将各种单一预测模型按照一定规则进行组合^[12-13],综合利用单一预测模型的优势达到提高预测精度的目的。

另一方面,电力变压器是电力系统中最重要设备之一,若电力变压器发生故障,则可能引起电网大停电。为及时发现电力变压器故障,国际电工委员会推荐将DGA作为油浸式变压器故障诊断方法。目前已有文献将DGA数据与BP神经网络、粗糙集技术以及SVM等结合对变压器故障进行有效诊断^[14-16]。本文将小波神经网络(WNN)、灰色神经网络(GNN)和SVM进行结合,并通过粒子群优化算法优化BP神经网络(PSO-BP)算法对以上WNN、GNN、SVM进行优化,对电力变压器DGA历史时间序列进行短期预测。

本文首先介绍了WNN、GNN、SVM的原理,分别选取了其拓扑结构优化变量,并利用PSO算法对这3种单一预测方法进行结构参数优化,提出了基于PSO-BP算法的时间序列组合预测模型,并推导得出了组合预测模型最优权系数的计算方法。本文研究结果对于电力变压器DGA数据预测,并以此为基础对电力变压器故障类型进行判定均具有一定的指导意义。

1 单一时间序列预测方法理论分析

1.1 基于WNN的时间序列预测

小波函数由1个母小波函数经过平移与尺寸伸缩得到,小波分析即把信号分解为一系列小波函数的叠加。小波变换是指把某一基本小波函数 $\varphi(t)$

收稿日期:2017-07-11;修回日期:2018-07-13

基金项目:重庆市基础科学与前沿技术研究项目(cstc2017-jcyjAX0461);重庆市电力公司科技项目(2018渝电科技4#)
Project supported by the Research on Basic Science and Frontier Technology in Chongqing(cstc2017jcyjAX0461)and the Science and Technology Project of Chongqing Electric Power Company (2018 Chongqing Electric Power Company Technology 4#)

平移 τ 后,再在不同尺度 γ 下与待分析的信号 $x(t)$ 做内积:

$$f_x(\gamma, \tau) = \frac{1}{\sqrt{\gamma}} \int_{-\infty}^{\infty} x(t) \varphi\left(\frac{t-\tau}{\gamma}\right) dt \quad \gamma > 0 \quad (1)$$

对式(1)进行等效拉普拉斯变换得:

$$f_x(\gamma, \tau) = \frac{1}{\sqrt{\gamma}} \int_{-\infty}^{\infty} x(\omega) \varphi(\gamma\omega) e^{j\omega\tau} d\omega \quad \gamma > 0 \quad (2)$$

WNN 是在 BP 神经网络基础上以小波基函数作为隐含层传递函数,其拓扑结构如图 1 所示。图 1 中, $X_1, X_2, \dots, X_M$ 为 WNN 的输入; $Y_1, Y_2, \dots, Y_N$ 为 WNN 的输出; ω_{ij} 和 ω_{jl} 为 WNN 权值, $i=1, 2, \dots, M, j=1, 2, \dots, J$ (J 为小波基函数数量), $l=1, 2, \dots, N$ 。当输入向量 $[X_1, X_2, \dots, X_M]$ 输入小波基函数时,其中一小波基函数的输出可表示为:

$$h(j) = h_j \frac{\sum_{i=1}^M \omega_{ij} X_i - \tau_j}{\gamma_j} \quad j=1, 2, \dots, J \quad (3)$$

其中, $h(j)$ 为隐含层第 j 个节点输出值; γ_j, τ_j 分别为第 j 个小波基函数的尺度和平移。




图 1 WNN 拓扑结构

Fig.1 Topology of WNN

1.2 基于 GNN 的时间序列预测

灰色模型可对灰色不确定系统行为特征值的发展进行预测,将序列 $x_t^{(0)} (t=0, 1, 2, \dots, K-1)$ 进行累加生成后得到数列 $x_t^{(1)}$,若 $x_t^{(1)}$ 呈现指数增长规律,则可利用微分方程进行数据预测。以下假设原始时间序列为 $x(t)$,一次累加生成后的数列为 $y(t)$,预测结果为 $z(t)$,则 n 个参数的 GNN 模型的微分方程为:

$$\frac{dy_1}{dt} + a_1 y_1 = b_1 y_2 + b_2 y_3 + \dots + b_{n-1} y_n \quad (4)$$

其中, $y_2, \dots, y_n$ 为 GNN 的输入参数; y_1 为 GNN 输出; $a_1, b_1, b_2, \dots, b_{n-1}$ 为微分方程的系数。令 $b_1 y_2 + b_2 y_3 + \dots + b_{n-1} y_n = u$,则式(4)的通解为:

$$y_1 = -\frac{k}{a_1} e^{-a_1 t} + \frac{u}{a_1} \quad (5)$$

其中, k 为待定常数。

将式(5)映射到 BP 神经网络中即为 n 输入、1 输出的 GNN,其拓扑结构如图 2 所示。图中, t 为输

入参数序号; GNN 分为 A、B、C、D 4 层,网络权值为: $\omega_{11} = a_1, \omega_{21} = -y_1(0), \omega_{2i} = 2b_{i-1}/a_1 (i=2, 3, \dots, n), \omega_{3i} = 1 + e^{-a_1 t} (i=2, 3, \dots, n)$ 。




图 2 GNN 拓扑结构

Fig.2 Topology of GNN

1.3 基于 SVM 的时间序列预测

SVM 与 BP 神经网络拓扑结构类似, SVM 中间节点的线性组合构成输出,其中每个支持向量与中间节点对应,结构如图 3 所示。SVM 用于回归拟合预测的基本思想是寻求一个最优分类面,目标是使训练样本距最优分类面误差最小。设有 L 个训练样本 $\{(\mathbf{x}_i, y_i)\}$,其中 $i=1, 2, \dots, L$; y_i 为对应的输出值。建立线性回归函数如式(6)所示。

$$f(\mathbf{x}) = \mathbf{w} \Phi(\mathbf{x}) + b \quad (6)$$




图 3 SVM 拓扑结构

Fig.3 Topology of SVM

现引入变量 ξ_i, ξ_i^* ,则求解 $\mathbf{w}, b$ 的问题转化为:

$$\begin{cases} \min \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^L (\xi_i + \xi_i^*) \\ \text{s.t.} & y_i - \mathbf{w} \Phi(\mathbf{x}_i) - b \leq \varepsilon + \xi_i \\ & -y_i + \mathbf{w} \Phi(\mathbf{x}_i) + b \leq \varepsilon + \xi_i^* \quad i=1, 2, \dots, L \\ & \xi_i \geq 0, \xi_i^* \geq 0 \end{cases}$$

引入 Lagrange 函数,并转换为对偶形式后可得回归函数为:

$$f(\mathbf{x}) = \mathbf{w}^* \Phi(\mathbf{x}) + b^* = \sum_{i=1}^L (\alpha_i - \alpha_i^*) K(\mathbf{x}_i, \mathbf{x}) + b^* \quad (7)$$

其中, C 为权重系数; α_i 和 α_i^* 为 Lagrange 因子; $K(\mathbf{x}_i, \mathbf{x}) = \Phi(\mathbf{x}_i) \Phi(\mathbf{x})$ 为核函数,可选用高斯径向基核函数,如式(8)所示。

$$K(\mathbf{x}_i, \mathbf{x}) = e^{-\frac{\|\mathbf{x}_i - \mathbf{x}\|^2}{2\sigma^2}} = e^{-g \|\mathbf{x}_i - \mathbf{x}\|^2} \quad (8)$$

因此 SVM 主要涉及的参数包括权重系数 C 和

核函数参数 g 。

2 WNN-GNN-SVM 组合算法的实现

单纯基于一种方法进行时间序列预测具有片面性和不稳定性,假设历史时间序列 $x_1, x_2, \dots, x_n$, WNN、GNN、SVM 对该历史时间序列的预测值为 $x_{i1}, x_{i2}, \dots, x_{in}$ (i 取 1、2、3 时分别对应 WNN、GNN、SVM 的预测值),预测误差矩阵 E 为^[1]:

$$E = [(e_{it})_{3 \times n}] [(e_{it})_{3 \times n}]^T \quad i=1, 2, 3 \quad (9)$$

其中, i 取 1、2、3 时分别对应 WNN、GNN、SVM; $e_{it} = P(t) - P_i(t)$, 为第 t 时刻的预测误差, $P_i(t)$ 为预测时间序列。传统组合预测模型为:

$$P'(t) = w_1 P_1(t) + w_2 P_2(t) + w_3 P_3(t) \quad (10)$$

其中, $w_1 + w_2 + w_3 = 1$ 。令 $W = [w_1 \ w_2 \ w_3]$ 为预测模型线性组合的加权系数。线性组合预测误差平方和为:

$$S = \sum_{i=1}^n \left(\sum_{j=1}^3 w_j e_{ij} \right)^2 = W^T E W \quad (11)$$

为求得组合预测模型的最优权系数 W , 可将上式转换为二次规划问题:

$$\begin{cases} \min S = W^T E W \\ \text{s.t. } R^T = \mathbf{1}, R^T = (1 \ 1 \ 1) \end{cases} \quad (12)$$

继续引入 Lagrange 算子 $2\lambda(R^T W - 1)$, 分别对 W 和 λ 求导得:

$$\begin{aligned} \frac{d[W^T E W - 2\lambda(R^T W - 1)]}{dW} &= 0 \Rightarrow E W - \lambda R = 0 \Rightarrow \\ W &= \lambda E^{-1} R \end{aligned} \quad (13)$$

$$\begin{aligned} \frac{d[W^T E W - 2\lambda(R^T W - 1)]}{d\lambda} &= 0 \Rightarrow R^T \lambda E^{-1} R = 1 \Rightarrow \\ \lambda &= (R^T E^{-1} R)^{-1} \end{aligned} \quad (14)$$

因此最优权系数 $W = E^{-1} R / (R^T E^{-1} R)$ 。

在此基础上,提出一种基于 BP 神经网络的时间序列组合预测模型,可有效利用各种预测方法的优势,提高时间序列预测的精度和可靠性。组合模型的基本建模思路为:

- 利用 WNN、GNN、SVM 分别对时间序列进行预测,并通过 PSO 算法优化其拓扑结构优化变量;
- 基于以上 3 种单一模型的预测结果,结合最优权系数计算方法,获得权系数组合模型预测结果;
- 将预测得到的 4 组灰色预测结果作为 BP 神经网络的输入向量,以原始历史时间序列作为 BP 神经网络输出向量,建立基于 BP 神经网络的组合模型并应用 PSO 算法进行优化,其拓扑结构如图 4 所示。

3 预测实例计算与分析

3.1 原始数据的选取与预处理

变压器油在过热或者放电故障条件下将分解生




图4 基于 PSO-BP 算法的时间序列组合预测模型

Fig.4 Combined forecasting model of time series based on PSO-BP algorithm

成特征气体,气体主要包括氢气(H_2)、二氧化碳(CO_2)、甲烷(CH_4)、乙烷(C_2H_6)、乙烯(C_2H_4)、乙炔(C_2H_2) 6 种故障气体,气体含量及比例对于故障类型的判断具有参考价值^[17-19]。对某变压器进行周期性变压器 DGA 时,发现其总烃超过了注意值,随后进行了跟踪试验,发现各种气体的体积分数均快速升高,以氢气、甲烷 2 种气体的体积分数为例验证本文所提组合预测方法的准确性。

WNN、GNN 和 SVM 的输出向量为氢气或甲烷的含量,输入向量为除输入向量外另外 5 种气体的含量。组合预测模型期望达到的目标是输入已知的 5 种气体含量,输出目标是对应时间点处氢气或甲烷的含量。文中仿真建模平台为 MATLAB (R2009b),运行环境为 Intel Core i5-3230,4 G 内存,500 G 硬盘,通过 MATLAB 自带函数 mapminmax,结合 apply 和 reverse 命令满足 WNN、GNN 和 SVM 的输入需要^[20-21]。

3.1.1 SVM 预测模型

采用高斯径向基核函数作为 SVM 核函数,涉及的优化参数包括权重系数 C 和核函数参数 g ,基于交叉验证原理,通过 PSO 算法对 SVM 模型进行参数寻优,提高 SVM 模型的预测效果^[22]。PSO 算法参数设置:学习因子 $c_1 = 1.5$ 、 $c_2 = 1.7$,算法进化代数 300,粒子种群的最大数量为 20。SVM 的权重系数 $C \in [0.1, 100]$,核函数参数 $g \in [0.01, 1000]$,SVM Cross Validation 参数的初始值设定为 3。对氢气体积分数的时间序列进行预测时,SVM 的最佳参数设置为 $C = 5.66$ 、 $g = 0.25$;对甲烷体积分数的时间序列进行预测时,SVM 的最佳参数设置为 $C = 1.41$ 、 $g = 0.18$ 。

PSO 算法对 SVM 的优化效果见图 5,SVM 对氢气、甲烷体积分数的时间序列预测结果见图 6。

3.1.2 WNN 预测模型

WNN 参数设置为:5 个输入节点和 1 个输出节点,10 个隐含层节点;参数学习率为 0.01,学习迭代次数为 200 次;网络神经元间权值初始值应用




图 5 PSO 算法优化 SVM 效果

Fig.5 Optimizing effect of PSO algorithm on SVM




图 6 SVM 对氢气和甲烷的时间序列预测结果

Fig.6 Prediction results of time series of H_2 and CH_4 volume fractions by SVM

randn 函数随机赋值;在学习过程中采用 Morlet 母小波基函数。应用 PSO 算法对 WNN 进行网络权值和神经元阈值的优化过程中,PSO 算法的参数设定与 SVM 一致,WNN 在对氢气、甲烷体积分数时间序列预测误差变化趋势如图 7 所示。由图 7 可见,在 PSO 算法优化 WNN 的过程中,随着迭代次数的增加,适应度函数值在前几次迭代过程中收敛较快,然后趋于平稳,这表明 PSO 算法对 WNN 的权值、神经元阈值的优化过程逐渐趋于收敛,优化效果良好。




图 7 WNN 预测误差收敛情况

Fig.7 Prediction error convergence of WNN

WNN 对氢气、甲烷体积分数时间序列的预测结果如图 8 所示。由图可见,经过 PSO 算法优化后,WNN 的预测结果更加接近时间序列真实值,且前 15 个时间序列点预测精度较高,然后预测序列逐渐发散,精度降低趋势。

3.1.3 WNN 预测模型

GNN 需对网络初始化参数 a 、 b_{n-1} 进行初始化,通过 rand 函数随机赋值,其中灰色神经网络的优化参数包括 a_1 、 b_1 、 b_2 、 b_3 、 b_4 、 b_5 、 b_6 ,在优化过程中 PSO 算法的参数设定与 4.1.2 节中一致。GNN 模型首先对特征气体体积分数的原始时间序列进行一次累




图 8 WNN 对氢气和甲烷体积分数时间序列的预测结果

Fig.8 Prediction results of time series of H_2 and CH_4 volume fractions by WNN

加,累加后的时间序列呈现准指数变化规律,然后通过一阶微分方程对其进行拟合。经过 PSO 算法优化后的 GNN 预测模型适应度函数值随迭代次数的变化如图 9 所示。由图可见,适应度函数值逐渐减小而趋于稳定,证明了 PSO 算法优化 GNN 的稳定性。




图 9 适应度函数值随迭代次数变化关系

Fig.9 Relationship between fitness function and iteration number

GNN 对氢气、甲烷体积分数时间序列的预测结果如图 10 所示,由图可见经过 PSO 算法优化后,GNN 的预测精度提高,但 GNN 对前 10 个时间序列点的预测精度较低,出现了预测时间序列点跳变的情况。




图 10 GNN 对氢气、甲烷体积分数时间序列的预测结果

Fig.10 Prediction results of time series of H_2 and CH_4 volume fractions by GNN

3.2 组合模型修正预测时间序列

限于篇幅,后文以甲烷体积分数时间序列为例对组合预测模型进行讨论。依据 SVM-PSO 预测模型、WNN-PSO 预测模型、GNN-PSO 预测模型的预测值与真实时间序列得到预测误差矩阵 $e^{[1,3]}$,限于篇幅略去矩阵中部分元素。

$$e = \begin{bmatrix} -0.345 & 0.062 & -0.13 \\ -0.351 & -0.016 & -0.579 \\ 0.286 & 0.038 & 4.232 \\ -0.340 & 0.284 & 17.812 \\ 0.531 & -0.162 & -0.279 \\ \vdots & \vdots & \vdots \\ 1.334 & 2.396 & 0.398 \\ 2.723 & 1.081 & 5.573 \\ -0.781 & -2.615 & -0.469 \\ 1.138 & 1.273 & 1.696 \\ -0.108 & -1.247 & -1.423 \end{bmatrix} \quad (24)$$

SVM-PSO WNN-PSO GNN-PSO

相应的预测误差矩阵 E 为:

$$E = [(e_{it})_{3 \times n}] [(e_{it})_{3 \times n}]^T = \begin{bmatrix} 20.151 & 17.426 & 26.914 \\ 17.426 & 30.288 & 33.630 \\ 26.914 & 33.630 & 474.833 \end{bmatrix} \quad (25)$$

将预测误差矩阵 E 代入 $W = E^{-1}R / (R^T E^{-1}R)$ 中得到组合预测模型的最优权系数 W :

$$W = [0.832 \ 0.186 \ -0.019] \quad (26)$$

因此传统组合预测模型为:

$$P'(t) = 0.832 \ 8P_1(t) + 0.186 \ 5P_2(t) - 0.019 \ 3P_3(t) \quad (27)$$

将传统组合预测模型预测结果与真实时间序列进行对比,结果如图 11 所示。




图 11 传统组合预测模型预测结果

Fig.11 Prediction result of traditional combination model

图 11 表明应用权系数修正的传统组合预测模型可将甲烷体积分数的时间序列预测精度进一步提升,前 15 个时间序列点的预测值基本和时间序列真实值一致,在后 10 个时间点处出现了预测偏差。

3.3 基于 PSO-BP 算法的组合预测模型

文中提出的组合预测模型基于 SVM-PSO、WNN-PSO、GNN-PSO 和传统组合预测模型的预测结果,因此将 BP 神经网络的输入层设置为 4 个,输出层设置为 1 个,用于组合预测模型输出的时间序列;中间层神经元个数设定为 6 个;PSO 算法用于优化 BP 神经网络的权值和神经元阈值。BP 神经网络组合预测模型的预测结果如图 12 所示。




图 12 PSO-BP 组合预测模型预测效果

Fig.12 Prediction result of PSO-BP combination model

图 12 表明 BP 神经网络组合预测模型的预测值与时间序列真实值基本吻合,经过 PSO 算法优化后,BP 神经网络组合预测模型表现出较强的非线性拟合能力和预测性能。

4 讨论

利用 SVM、WNN、GNN、SVM-PSO、WNN-PSO、GNN-PSO、传统组合模型、基于 PSO-BP 算法的组合预测模型对甲烷体积分数的时间序列真实值与预测值分别计算绝对平均误差 E_1 、均方根误差 E_2 、最大绝对误差 E_3 和序列相关度系数 E_4 4 个指标来评定各个预测模型的预测精度,如图 13 所示。图中,预测算法序号 1—8 分别对应 SVM、PSO-SVM、WNN、PSO-WNN、GNN、PSO-GNN 预测模型、传统组合模型、基于 PSO-BP 算法的组合预测模型。




图 13 预测模型预测效果对比

Fig.13 Comparison among predicting models

图 13 表明 SVM、WNN、GNN 经过 PSO 算法优

化后,平均误差 E_1 、均方根误差 E_2 、最大绝对误差 E_3 均显著降低,序列相关度系数 E_4 增大,这说明时间序列预测精确度提高。传统组合模型和基于 PSO-BP 算法的组合预测模型的 4 个评价指标均优于其他 6 种预测模型,表明了组合预测模型的优势,且基于 PSO-BP 算法的组合预测模型的 E_1 、 E_2 、 E_3 更低,具有更好的预测精度。

5 结论

本文分析了 WNN、GNN、SVM 的原理,并应用 PSO 算法对上述 3 种基本预测方法进行结构参数优化,提出了基于 PSO-BP 算法的组合预测模型,PSO 算法通过优化 WNN、GNN、SVM 预测模型的拓扑结构参数可提高其预测精度,将 WNN、GNN、SVM 预测模型与 PSO-BP 算法进行组合,并应用 PSO 算法优化组合预测模型的拓扑结构参数,组合模型较单一模型有更高的预测精度。本文提出的预测方法适用于变压器油色谱的时间序列预测,也可用于电力系统其他时间序列的预测。

参考文献:

- [1] 杨廷方,刘沛,李浙,等. 应用新型多方法组合预测模型估计变压器油中溶解气体浓度[J]. 中国电机工程学报,2008,28(31):108-113.
YANG Tingfang, LIU Pei, LI Zhe, et al. A new combination forecasting model for concentration prediction of dissolved gases in transformer oil[J]. Proceedings of the CSEE, 2008, 28(31):108-113.
- [2] 雷亚国,陈昊,李乃鹏,等. 自适应多核组合相关向量机预测方法及其在机械设备剩余寿命预测中的应用[J]. 机械工程学,2016,52(1):87-93.
LEI Yaguo, CHEN Wu, LI Naipeng, et al. A relevance vector machine prediction method based on adaptive multi-kernel combination and its application to remaining useful life prediction of machinery[J]. Journal of Mechanical Engineering, 2016, 52(1):87-93.
- [3] 梁永亮,李可军,赵建国,等. 变压器油色谱在线监测周期动态调整策略研究[J]. 中国电机工程学报,2014,34(9):1446-1453.
LIANG Yongliang, LI Kejun, ZHAO Jianguo, et al. Research on the dynamic monitoring cycle adjustment strategy of transformer chromatography on-line monitoring devices[J]. Proceedings of the CSEE, 2014, 34(9):1446-1453.
- [4] 程加堂,段志梅,熊燕,等. 基于 DGA 的 QPSO-BP 模型变压器故障诊断方法研究[J]. 高压电器,2016,52(2):57-61.
CHENG Jiatang, DUAN Zhimei, XIONG Yan, et al. Dissolved gas analysis based QPSO-BP model for transformer fault diagnosis[J]. High Voltage Apparatus, 2016, 52(2):57-61.
- [5] 欧阳庭辉,查晓明,秦亮,等. 含核函数切换的风电功率短期预测新方法[J]. 电力自动化设备,2016,36(9):80-86.
OUYANG Tinghui, ZHA Xiaoming, QIN Liang, et al. Short-term wind power prediction based on kernel function switching[J]. Electric Power Automation Equipment, 2016, 36(9):80-86.
- [6] 任韧,徐进,朱世华. 最小二乘支持向量域的混沌时间序列预测[J]. 物理学报,2006,55(2):555-563.
REN Ren, XU Jin, ZHU Shihua. Prediction of chaotic time sequence using least squares support vector domain[J]. Acta Physica Sinica, 2006, 55(2):555-563.
- [7] 祖向荣,田敏,白焰. 基于模糊聚类与函数小波核回归的短期负荷预测方法[J]. 电力自动化设备,2016,36(10):134-140.
ZU Xiangrong, TIAN Min, BAI Yan. Short-term load forecasting based on fuzzy clustering and functional wavelet-kernel regression[J]. Electric Power Automation Equipment, 2016, 36(10):134-140.
- [8] 周辉仁,郑丕谔. 基于递阶遗传算法和 BP 网络的时间序列预测[J]. 系统仿真学报,2007,19(21):5055-5058.
ZHOU Hui ren, ZHENG Pie. Time series forecasting based on hierarchical genetic algorithm and BP neural network[J]. Journal of System Simulation, 2007, 19(21):5055-5058.
- [9] 单英浩,付青,耿炫,等. 基于改进 BP-SVM-ELM 与粒子化 SOM-LSF 的微电网光伏发电组合预测方法[J]. 中国电机工程学报,2016,36(12):3334-3342.
SHAN Yinghao, FU Qing, GENG Xuan, et al. Combined forecasting of photovoltaic power generation in microgrid based on the improved BP-SVM-ELM and SOM-LSF with particleization[J]. Proceedings of the CSEE, 2016, 36(12):3334-3342.
- [10] 杨金芳,瞿永杰,王东风,等. 基于支持向量回归的时间序列预测[J]. 中国电机工程学报,2005,25(17):110-114.
YANG Jinfang, ZHAI Yongjie, WANG Dongfeng, et al. Time series prediction based on support vector regression[J]. Proceedings of the CSEE, 2005, 25(17):110-114.
- [11] 王德文,雷倩. 基于贝叶斯正则化深度信念网络的电力变压器故障诊断方法[J]. 电力自动化设备,2018,38(5):129-135.
WANG Dewen, LEI Qian. Fault diagnosis of power transformer based on BR-DBN[J]. Electric Power Automation Equipment, 2018, 38(5):129-135.
- [12] 张学清,梁军,张熙,等. 基于样本熵和极端学习机的超短期风电功率组合预测模型[J]. 中国电机工程学报,2013,33(25):33-40.
ZHANG Xueqing, LIANG Jun, ZHANG Xi, et al. Combined model for ultra short-term wind power prediction based on sample entropy and extreme learning machine[J]. Proceedings of the CSEE, 2013, 33(25):33-40.
- [13] 阮旻,谢齐家,高胜友,等. 人工神经网络和信息融合技术在变压器状态评估中的应用[J]. 高电压技术,2014,40(3):822-828.
RUAN Ling, XIE Qijia, GAO Shengyou, et al. Application of artificial neural network and information fusion technology in power transformer condition assessment[J]. High Voltage Engineering, 2014, 40(3):822-828.
- [14] 熊浩,孙才新,李小虎,等. 基于克隆选择分类算法的电力变压器故障诊断[J]. 电网技术,2006,30(4):65-73.
XIONG Hao, SUN Caixin, LI Xiaohu, et al. Power transformer fault diagnosis based on clonal selection classification algorithm[J]. Power System Technology, 2006, 30(4):65-73.
- [15] 牛哲文,余泽远,李波,等. 基于深度门控循环单元神经网络的短期风电功率预测模型[J]. 电力自动化设备,2018,38(5):36-42.
NIU Zhewen, YU Zeyuan, LI Bo, et al. Short-term wind power forecasting model based on deep gated recurrent unit neural network[J]. Electric Power Automation Equipment, 2018, 38(5):36-42.
- [16] 熊浩,孙才新,李小虎,等. 基于克隆选择分类算法的电力变压器故障诊断[J]. 电网技术,2006,30(4):65-73.
XIONG Hao, SUN Caixin, LI Xiaohu, et al. Power transformer fault diagnosis based on clonal selection classification algorithm[J].

- Power System Technology, 2006, 30(4): 65-73.
- [17] 杨廷方, 周力行, 李景禄, 等. 基于最优权值的组合模型诊断变压器故障[J]. 电网技术, 2013, 37(1): 190-194.
YANG Tingfang, ZHOU Lixing, LI Jinglu, et al. Power transformer fault diagnosis based on optimal weights combined model [J]. Power System Technology, 2013, 37(1): 190-194.
- [18] 刘亚南, 范立新, 徐钢, 等. 基于非负矩阵分解与改进极端学习机的变压器油中溶解气体浓度预测模型[J]. 高压电器, 2016, 52(1): 162-169.
LIU Yanan, FAN Lixin, XU Gang, et al. Concentration prediction model of dissolved gases in transformer oil based on NMF and improved ELM[J]. High Voltage Apparatus, 2016, 52(1): 162-169.
- [19] 马福民, 逯瑞强, 张腾飞. 基于局部密度自适应度量的粗糙 K-means 聚类算法[J]. 计算机工程与科学, 2018, 40(1): 184-190.
MA Fumin, LU Ruiqiang, ZHANG Tengfei. Rough K-means clustering based on local density adaptive measure [J]. Computer Engineering & Science, 2018, 40(1): 184-190.
- [20] 高佳程, 曹雁庆, 朱永利, 等. 基于 KELM-VPMD 方法的未知局部放电类型的模式识别[J]. 电力自动化设备, 2018, 38(5): 141-147.
GAO Jiacheng, CAO Yanqing, ZHU Yongli, et al. Pattern recognition of unknown PD types based on KELM-VPMD [J]. Electric Power Automation Equipment, 2018, 38(5): 141-147.
- [21] 程启明, 陈路, 程尹曼, 等. 基于 EEMD 和 LS-SVM 模型的风电功率短期预测方法[J]. 电力自动化设备, 2018, 38(5): 27-35.
CHENG Qiming, CHEN Lu, CHENG Yinman, et al. Short-term wind power forecasting method based on EEMD and LS-SVM model [J]. Electric Power Automation Equipment, 2018, 38(5): 27-35.
- [22] 王继东, 冉冉, 宋智林. 基于改进深度受限玻尔兹曼机算法的光伏发电短期功率概率预测[J]. 电力自动化设备, 2018, 38(5): 43-49.
WANG Jidong, RAN Ran, SONG Zhilin. Probability forecast of short-term photovoltaic power generation based on improved depth restricted Boltzmann machine algorithm [J]. Electric Power Automation Equipment, 2018, 38(5): 43-49.

作者简介:



张施令(1986—),男,重庆人,高级工程师,博士,从事超/特高压绝缘结构的优化设计和 SF₆ 设备故障诊断与寿命评估 (E-mail: 526793305@qq.com)。

Predicting model of transformer DGA time series based on WNN-GNN-SVM combined algorithm

ZHANG Shiling, YAO Qiang

(Chongqing Electric Power Research Institute of State Grid Chongqing Electric Power Company, Chongqing 401123, China)

Abstract: The principle of prediction methods based on WNN (Wavelet Neural Network), GNN (Gray Neural Network) and SVM (Support Vector Machine) is analyzed. The structure parameters of the above three basic predicting methods are optimized based on PSO (Particle Swarm Optimization) algorithm. The WNN-based, GNN-based and SVM-based predicting models are combined with PSO-BP algorithm and the calculation method of the optimal weight coefficient of the combined forecasting model is deduced. Case study results show that the accuracy of WNN-based, GNN-based and SVM-based predicting models is improved by optimizing the topological structure parameters with PSO algorithm, and the combined predicting model has higher accuracy than single models.

Key words: power transformers; DGA; PSO-BP algorithm; combination predicting model