

doi: 10.12052/gdutxb.170019

基于纵横交叉算法优化BP神经网络的风机齿轮箱故障诊断方法

马留洋, 孟安波, 葛佳菲

(广东工业大学 自动化学院, 广东 广州 510006)

摘要: 风电机组齿轮箱的运行工况比较复杂, 容易发生故障. 针对常规BP(Back Propagation)神经网络故障诊断容易陷入局部最优的问题, 提出一种基于纵横交叉算法(Crisscross Optimization Algorithm, CSO)优化BP神经网络的风电齿轮箱故障诊断新方法. 考虑到风电齿轮箱振动信号的波动性和非线性, 首先从信号中提取故障特征参数, 建立带评价因子的误差分析模型, 然后通过纵横交叉算法优化BP的权值和阈值对神经网络进行训练, 最后用训练好的神经网络对样本进行测试. 经实验仿真并与其他方法的对比, 验证了本文方法用于风电机组故障诊断有效性及优越性.

关键词: 风电机组; 齿轮箱; 纵横交叉算法; BP神经网络; 故障诊断

中图分类号: TM315 文献标志码: A 文章编号: 1007-7162(2018)02-0057-06

A Fault Diagnosis Method of Wind Turbine Gearbox Based on BP Neural Network Optimized by Crisscross Optimization Algorithm

Ma Liu-yang, Meng An-bo, Ge Jia-fei

(School of Automation, Guangdong University of Technology, Guangzhou 510006, China)

Abstract: Wind turbine gearbox has high failure rate in its complex operation. In order to overcome the drawbacks of the conventional BP (Back Propagation) neural network which is easy to trap into local optimal, a new fault diagnosis model of turbine gearbox is presented based on BP neural network optimized by crisscross optimization (CSO) algorithm. Considering the instability and complexity of vibration signal of the wind turbine gearbox. The fault feature for gearbox is first extracted and a new error analysis model is established with assessment factors, CSO is then used to optimize the weights and bias of BP neural network, and finally the trained neural network is used to test the samples. The simulation and comparison with other methods show that the proposed method is effective and efficient in fault diagnosis of wind turbines.

Key words: wind turbine; gearbox; crisscross optimization algorithm; BP neural network; fault diagnosis

作为使用技术最成熟且增长速度最快的可再生能源, 风力发电在近几年倍受世界关注. 我国每年的风电装机容量也在成倍地增长, 但由于风电机组所处的工作环境比较恶劣, 导致发电机组的故障率居高不下. 高故障率是造成风力发电平均可用率低的一个主要原因, 所以降低风电机组故障率是提高运行效益的一个重要途径.

齿轮箱是风电机组的一个重要部件, 其损耗率极高, 故障百分比达到60%以上. 由于机组安装的塔架有数十米高, 因此齿轮箱若出现故障将难以维修,

也可能会导致风电机组停机, 造成巨大经济损失. 近年来, 许多专家学者对风电机组齿轮箱故障诊断做了大量的研究工作. 例如文献[1]中提出基于改进粒子群优化BP(Back Propagation)神经网络, 以发电机组齿轮箱为研究对象, 用傅里叶变换和小波包分析等方法提取出6组故障特征参数, 再用改进粒子群优化的BP神经网络对样本进行训练. 改进粒子群的全局搜索能力一定程度改善了BP神经网络学习的盲目性和无法训练等问题, 但存在陷入局部最优而导致诊断结果欠佳的问题. 文献[2]提出了将最小二乘

支持向量机(Least Squares Support Vector Machine, LSSVM)用于风电机组齿轮箱故障诊断,将最小二乘函数作为损失函数,改善了传统SVM(Support Vector Machine)求解复杂的凸二次规划困难的问题,该方法在故障诊断中得到广泛应用。但由于LSSVM将最小错误率作为目标,它的假设前提是:样本类别平衡和各类误判代价相等,忽略了将故障误判为正常的代价远大于正常误判了故障的问题。而齿轮箱在实际运行中样本获取困难,这样会导致样本类别不平衡而出现误判。文献[3]提出基于粗糙集理论和贝叶斯网络的诊断方法,对粗糙集进行知识简化和故障特征压缩,获取最小诊断规则以建立贝叶斯网络,仿真表明该方法能有效地降低网络结构复杂性和故障特征获取的难度。其他应用于风机齿轮箱故障诊断的方法还包括:多元离群检测方法^[4]、朴素贝叶斯算法和反向传播算法^[5]、模糊集和故障树诊断法^[6]、数据挖掘法^[7]以及其他传统方法的改进算法^[8]。

本文提出一种基于纵横交叉算法优化BP神经网络的风电齿轮箱故障诊断模型,利用横向交叉的全局搜索和纵向交叉的变异寻优能力,弥补BP神经网络收敛速度慢,容易陷入局部最优的缺陷,加快了种群的收敛速度并提高了收敛精度。最后用针对性的误差分析模型对神经网络进行训练,弥补了传统方法诊断准确性低的问题。通过实验仿真和其他方法的分析对比,验证了本文方法的有效性。

1 带评价因子的BP神经网络故障诊断模型

1.1 基本BP神经网络

BP神经网络由输入层、隐含层和输出层组成,它是一种基于误差反向传播的前馈神经网络。其通过对样本数据的不断学习和训练来调整网络的权值和阈值,使得误差达到目标值。BP神经网络的拓扑图如图1所示。由于其有强大的非线性计算能力,因此在复杂的机械故障诊断和预测领域占有重要地位,如风速预测^[9]、负荷预报^[10]、变压器故障诊断^[11]等。然而BP神经网络在训练权值和阈值过程中,存在容易陷入局部最优导致学习失败的缺点,这会严重影响预测和诊断的准确性^[12]。因此本文采用优化算法代替传统神经网络的误差反向传播过程来寻找最佳的权值和阈值,克服BP神经网络收敛速度慢、容易陷入局部最优的缺陷,具体方法将在第2部分介绍。




图1 神经网络结构图

Fig.1 Neural network structure of BP

1.2 带评价因子的BP神经网络诊断模型

本文选取正常状态、磨损状态和断齿状态3种状态进行故障诊断研究,对应目标向量分别为000、010和001。传统误差函数只能对精确性进行判断,由于故障诊断涉及正确率和精确性两个指标,如果神经网络训练只保证和样本的精确性拟合,使误差总体最小达到目标要求,则会忽略部分关键性误差,使训练过程容易陷入局部最优,降低诊断的正确率。因此本文引入评价因子 a 来衡量BP神经网络的诊断效果。假设诊断状态为 F ,实际状态为 R ,用诊断结果绝对误差 $A=|R(i)-F(i)|$ 来评估结果优劣,其中, $F(i)$ 和 $R(i)$ 分别表示第 i 个诊断状态和实际状态。经过多次取值试验分析,不同绝对误差对应的诊断结果和评价因子值如式(1)所示。为有效地评价误差情况,建立如式(2)所示的误差模型。

$$a = \begin{cases} 1 & \text{正确诊断 } A \in [0, 0.25); \\ 1.5 & \text{模糊诊断 } A \in [0.25, 0.4); \\ 2.2 & \text{诊断失效 } A \in [0.4, 0.6); \\ 3 & \text{错误诊断 } A \in [0.6, 1]. \end{cases} \quad (1)$$

$$E = \frac{1}{S} \frac{1}{n} \sum_{j=1}^S \sum_{i=1}^n ((R(i, j) - F(i, j))^2 a_{ij}) \times 100\%. \quad (2)$$

式(2)中 E 表示平均误差函数; S 为训练样本数; n 为输出层节点数,表示目标向量的个数; $R(i, j)$ 为第 j 个训练样本的第 i 个实际状态数; $F(i, j)$ 为第 j 个训练样本的第 i 个输出数, a_{ij} 为评价因子。

实验表明带评价因子的误差函数能有效地提高诊断的正确率,以准确性为第一考虑准则,能避免训练陷入局部最优的情况。同时,也能通过上述误差函数直观地比较出不同诊断方法的好坏。

2 纵横交叉算法优化BP神经网络

2.1 纵横交叉算法

纵横交叉算法^[13]是最近发展起来的新型群体智

能搜索算法.它采用一种双向搜索机制,即横向交叉和纵向交叉,结合一个简单的竞争机制,形成CSO (Crisscross Optimization Algorithm)的基本搜索行为.在每一次迭代过程中,CSO从两个不同的方向对种群进行交叉产生子代,这些子代被称为中庸解.随后,这些新产生的中庸解通过一个贪婪的选择机制和父代进行比较,只有比父代适应度更好的解才能够存活下来,否则就被淘汰.这些在竞争中存活下来的解被称为占优解,作为下一次交叉的父代.很显然,在种群迭代过程中,CSO始终保持个体的最优解,这样的竞争机制无疑会加快求解的收敛速度.

(1) 横向交叉.

横向交叉之前需要对种群中的粒子两两不重复配对,然后对配对粒子的相同维进行算术交叉.假设对粒子 $X(i)$ 和 $X(j)$ 的第 d 维交叉,公式为

$$\begin{cases} MS_{id} = r_1 X_{id} + (1 - r_1) X_{jd} + c_1 (X_{id} - X_{jd}), \\ MS_{jd} = r_2 X_{jd} + (1 - r_2) X_{id} + c_2 (X_{jd} - X_{id}). \end{cases} \quad (3)$$

式(3)中: r_1, r_2 为 $[0,1]$ 上的随机数; c_1, c_2 为 $[-1,1]$ 之间的随机数; X_{id} 和 X_{jd} 分别为粒子 $X(i)$ 和 $X(j)$ 的第 d 维; MS_{id} 和 MS_{jd} 分别为横向交叉后的第 d 维子代.

由式(3)可以观察到横向交叉有两个部分组成:第一部分是内部信息的交换,以较大的概率在父代粒子形成的超立方体内进行搜索;第二部分是外部信息的探索,通过在父代粒子之间施加一个扩展系数,以较小的概率在超立方体的外缘进行搜索.这种搜索机制可以有效地减少搜索盲点,提高CSO的全局搜索能力.

(2) 纵向交叉.

与横向交叉不同的是,纵向交叉是在同一个粒子不同维的交叉,假设对粒子 $X(i)$ 的第 d_1 和 d_2 维执行纵向交叉,公式为

$$MS_{i,d_1} = r X_{i,d_1} + (1 - r) X_{i,d_2} \quad i \in (1, M), \quad d_1, d_2 \in (1, D). \quad (4)$$

式(4)中: M 为粒子的个数; D 为粒子的维数; r 为 $[0,1]$ 上的均匀分布随机数; MS_{i,d_1} 为粒子 $X(i)$ 的第 d_1 维子代.

由于不同维的上下限往往不同,所以纵向交叉之前需要对粒子的各维进行归一化处理,纵向交叉结束后还需要对所产生的中庸解进行反归一化处理.一般算法在迭代过程中某些维容易陷入局部最优而停止更新,但不同的维一般都有差异.纵横交叉算法正是观察到这种现象,使用纵向交叉在不同维进行算术交叉,可以有效地帮助陷入局部最优的维跳出困境,而且每次交叉只产生一个子代,在保持种

群多样性的同时不破坏有可能比较好的维.相比于其他搜索算法^[14-16],纵向交叉是纵横交叉算法的一个明显的特征.

2.2 CSO优化BP神经网络

CSO是一种群体智能搜索算法,能够克服神经网络收敛速度慢容易陷入局部最优的缺陷.横向交叉提高空间搜索能力,纵向交叉能防止陷入维局部最优,纵横交叉相结合则能有效地弥补BP神经网络自身的不足.CSO优化BP神经网络的基本思想是用CSO替代BP神经网络沿梯度反向传播训练,寻找最佳的权值和阈值.

设含有 M 层输入、 H 层隐含层和 N 层输出的一个任意网络,给定 S 个样本,输入层到隐含层权值 W_1 ,隐含层到输出层的权值为 W_2 ,隐含层和输出层的阈值为 b .粒子编码格式如图2所示.其中 W_1, W_2, W_3 分别是 W_1, W_2, W_3 权矩阵中元素展开后的一个排列,则每个粒子的维数 $D=(N+H+M)H+H+N$ ^[16].




图2 粒子参数编码格式

Fig.2 Particle parameter encoding format

CSO优化BP神经网络的流程图如图3所示,具体流程为:




图3 CSO优化BP神经网络流程图

Fig.3 Flow chart of CSO optimization BP neural network

- (1) 建立BP神经网络,设置基本参数和误差函数.
- (2) 初始化种群,设置纵横交叉的基本参数,包括:种群规模,最大迭代次数,惯性权重,纵向交叉概率.
- (3) 设置适应度函数,对群体中每个个体进行适应度评价,本文用式(2)衡量每个粒子的适应度值.
- (4) 横向交叉:将种群内粒子两两配对,每对粒子通过式(3)进行横向交叉,产生一对中庸解保存在矩阵 MS_{hc} 中.然后计算 MS_{hc} 中每个解的适应值,与父代种群进行比较,适应度更好的保留在矩阵 X 中.
- (5) 纵向交叉:对种群所有粒子进行归一化处理,再对同一粒子的所有维进行随机配对,在交叉概率为 P_v 下选取一定数量的维,通过式(4)进行交叉产生子代,反归一化后与横向交叉更新后的 X 进行比较,择优保留在矩阵 X 中.
- (6) 迭代次数加1,判断是否达到结束条件(迭代次数和最小误差要求),如果达到,停止迭代,以适应度最小的解作为神经网络的权值和阈值,否则转移到第4步进行新一轮迭代.

表 1 风电机组齿轮箱故障诊断特征值训练样本
Tab.1 Training samples of fault eigenvalue of turbine gearbox

齿轮状态	功率谱熵	小波熵	峭熵	偏度	关联维度	盒维度	目标向量
正常状态	1.353 7	0.534 0	-0.026 1	1.594 0	4.827 3	1.464 7	0 0 0
磨损状态	1.606 4	1.484 6	-0.596 7	1.466 9	4.966 4	1.449 3	0 1 0
断齿状态	2.324 6	1.821 3	1.266 9	2.191 0	10.482 4	1.514 4	0 0 1

3.2 实验参数设置

本文分别建立CSO-BP、BP、改进PSO-BP 3种故障诊断型进行对比分析,具体参数设置如下.

(1)BP参数设置:输入层、隐含层和输出层的层数分别为6、13、3;目标误差为0.001;学习速率为0.1,最大训练次数为100;隐含层和输出层传递函数分别采用Sigmoid型正切函数tansig和对数函数logsig;训练函数采用trainlm函数.

(2)CSO和改进PSO参数设置:粒子数为30,最大允许迭代次数500,加速常数 $C_1=C_2=2$,最大限制速度 $V_{\max}=1$,最小限制速度 $V_{\min}=-1$,纵向交叉概率设为0.5,改进PSO的搜索扩张系数从1.0线性下降到0.5^[18].

3.3 诊断结果与对比分析

分别用BP、改进PSO-BP和CSO-BP进行训练,训练后对表2的10组测试样本进行诊断,分别进行50次独立实验,测试结果如表3所示, Y_1 、 Y_2 、 Y_3 分别代表目

3 风电机组故障诊断仿真

3.1 风电机组齿轮箱故障特征参数提取

由于风电机组所处的工作环境恶劣,扰动性大,导致信号杂乱无章.因此根据文献[17]的方法能够从风电机组齿轮箱提取出各种不同的特征参数.其中信息熵用来衡量信号源在总体上的不确定性的量度,它包括功率谱熵、小波熵和奇异谱熵.而峭熵和偏度可以反映齿轮箱在发生故障时的冲击能力大小,是作为诊断齿轮箱故障的常用指标.分形维度由关联维度、能量维度以及盒维度组成,用以描述系统耗能的大小.考虑到风电齿轮箱振动信号的非平稳性和不确定性,本文选取功率谱熵、峭熵、偏度、盒维数、小波熵关联维数作为风电机组齿轮箱故障诊断的特征值.采用1.5 MW风电机组为研究对象,选取齿轮正常状态、磨损状态和断齿状态3种状态进行研究分析^[1].采样频率为5 120 Hz,每个样本节点数为8 192点.经处理后得到25组特征数据,随机选取15个样本作为训练数据,10个作为测试数据.部分训练样本如表1所示.

标向量3个不同的元素.

对表3数据分析可得,传统BP神经网络由于容易出现早熟和陷入局部最优的情况,导致诊断效果欠佳,误差较大.而改进PSO-BP是对BP神经网络的改善,有效地提高全局搜索能力和诊断能力,但在磨损状态和断齿状态的3组测试中出现偏差,可见改进PSO-BP仍然会存在陷入局部最优而导致判断不稳定的问题.而CSO-BP有效地结合了横向交叉和纵向交叉两算子间的优点和弥补相互之间的不足,表现出良好的全局寻优能力,克服了维局部最优的现象,体现了CSO-BP良好的正确率和精确性,适用于风电机组齿轮箱故障诊断.

表4为各算法进行50次试验的诊断结果,由诊断误差对比可以看出本文方法明显优于前者,而且在带评价因子的误差模型训练下,CSO-BP表现出更为突出的诊断能力,充分说明该神经网络诊断模型的稳定性、可行性和准确性.

表 2 风电机组齿轮箱故障诊断特征值测试样本
Tab.2 Test sample of fault eigenvalue of turbine gearbox

齿轮状态	功率谱熵	小波熵	峭熵	偏度	关联维度	盒维度	目标向量
正常状态	0.943 8	0.639 4	-0.388 4	1.516 7	4.812 5	1.460 3	0 0 0
	1.131 3	0.636 9	-0.201 7	1.559 2	4.936 6	1.456 0	0 0 0
	1.481 0	1.143 7	-0.201 7	1.559 2	4.945 1	1.456 0	0 0 0
	1.353 7	0.534 0	-0.026 1	1.594 0	4.827 3	1.464 7	0 0 0
磨损状态	1.482 9	1.296 3	-1.713 1	1.433 2	5.514 5	1.490 6	0 1 0
	1.490 6	1.482 9	-0.596 7	1.466 9	5.514 5	1.561 0	0 1 0
	1.542 1	1.440 3	0.160 1	1.638 0	5.286 2	1.498 3	0 1 0
断齿状态	2.324 6	1.821 3	1.266 9	2.191 0	10.482 4	1.514 4	0 0 1
	2.641 4	1.910 4	2.462 9	2.014 0	8.592 7	1.520 1	0 0 1
	2.342 9	1.836 9	4.753 0	2.344 8	10.681 3	1.508 5	0 0 1

表 3 3种诊断方法的结果对比¹⁾
Tab.3 Performance comparison among three algorithms

类别	编号	BP			改进PSO-BP			CSO-BP		
		Y ₁	Y ₂	Y ₃	Y ₁	Y ₂	Y ₃	Y ₁	Y ₂	Y ₃
正常状态(000)	1	0.000 5	0.003 6	0.000 2	0.000 2	0.000 4	0.000 8	0.000 3	0.000 2	0.000 3
	2	0.000 5	0.002 5	0.000 2	0.000 5	0.000 3	0.000 3	0.000 3	0.000 6	0.000 3
	3	0.000 5	0.457 8	0.000 4	0.001 1	0.003 5	0.000 7	0.000 4	0.296 8	0.000 6
	4	0.000 4	0.001 9	0.000 3	0.000 6	0.004 7	0.016 1	0.000 3	0.001 3	0.000 3
磨损状态(010)	5	0.001 5	0.723 8	0.202 1	0.000 4	0.562 8	0.012 1	0.001 2	0.966 9	0.000 1
	6	0.001 2	0.996 6	0.002 2	0.000 1	0.743 6	0.025 9	0.001 1	0.991 6	0.004 0
	7	0.000 4	0.984 9	0.001 8	0.000 2	1.001 6	0.001 7	0.000 3	0.993 6	0.004 0
断齿状态(001)	8	0.000 4	0.002 0	0.000 3	0.000 4	0.000 3	0.999 8	0.000 8	0.001 0	0.999 4
	9	0.000 9	0.001 0	0.993 1	0.000 3	0.003 2	1.001 1	0.000 8	0.007 0	0.999 4
	10	0.000 8	0.000 70	0.999 3	0.000 7	0.263 4	0.748 2	0.000 8	0.000 9	0.999 4

1) 黑色字体为正确判断,绿色字体为模糊判断,黄色字体为判断失效,红色字体为错误判断. 其中判断失效和错误判断均属于错误识别.

表 4 各诊断方法结果分析
Tab. 4 Result analysis of different algorithms %

诊断结果	BP	改进PSO-BP	CSO-BP
模糊诊断	13.1	22.4	12.8
失效诊断	10.4	6.1	2.6
错误诊断	8.6	3.4	1.8
正确诊断	81	90.5	95.8
E	12.360	4.520	0.824

4 结语

风电机组齿轮箱故障诊断对风电的安全稳定运行有着十分重要的意义. 为提高诊断准确性,本文提出基于纵横交叉算法优化BP神经网络的故障诊断模型. 横向交叉能进行全局搜索,增强全局优化能力;纵向交叉能够交叉变异,摆脱维局部最优. 纵横交叉相结合能够通过链式反应持续保持种群更新,表现出比其他算法更强的收敛能力和寻优能力. 用CSO优化BP神经网络能充分弥补BP自身学习能力

的不足,解决诊断过程中过度学习、早熟和陷入局部最优等问题. 而用带评价因子的误差函数,能使诊断模型更科学地进行训练,提高诊断准确性. 经实验表明,本文提出方法的诊断效果,从识别能力和精确度上都有显著的改善,能有效对风电机组齿轮箱的故障进行诊断.

参考文献:

[1] 龙泉,刘永前,杨勇平.基于粒子群优化BP神经网络的风电机组齿轮箱故障诊断方法[J].太阳能报,2012,33(1): 120-125.
LONG Q, LIU Y Q, YANG Y P. Fault diagnosis method of wind turbine gearbox based on BP neural network trained by particle swarm optimization algorithm[J]. Acta Energiae Solaris Sinica, 2012, 33(1): 120-125.
[2] 黎涛,唐明珠,谭欣星. 基于CLSSVM的风电机组齿轮箱故障诊断[J].可再生能源,2015,33(2): 232-237.
LI T, TANG M Z, TAN X X. Fault diagnosis of wind turbine gearbox based on cost-sensitive least squares support vector machine[J]. Renewable Energy Resources, 2015,

- 33(2): 232-237.
- [3] 秦大力, 于德介. 基于本体的机械故障诊断贝叶斯网络[J]. 中国机械工程, 2013, 24(9): 1195-1209.
- QIN D L, YU D J. Ontology-based diagnostic Bayesian networks for mechanical fault diagnosis[J]. China Mechanical Engineering, 2013, 24(9): 1195-1209.
- [4] 顾煜炯, 贾子文, 王瑞, 等. 基于改进的多元离群检测方法的风机齿轮箱早期故障诊断[J]. 中国机械工程, 2016, 27(14): 1905-1910.
- GU Y J, JIA Z W, WANG R, *et al.* Early fault diagnosis for wind turbine gearbox based on improved multivariate outlier detection [J]. China Mechanical Engineering, 2016, 27(14): 1905-1910.
- [5] 张少敏, 毛冬, 王保义. 大数据处理技术在风电机组齿轮箱故障诊断与预警中的应用[J]. 电力系统自动化, 2016, 40(14): 129-134.
- ZHANG S M, MAO D, WANG B Y. Application of big data processing technology in fault diagnosis and early warning of wind turbine gearbox. Automation of Electric Power Systems, 2016, 40(14): 129-134.
- [6] 谷凯凯, 郭江. 紧致融合模糊集和故障树的变压器故障诊断[J]. 高电压技术, 2014, 40(5): 1507-1513.
- GU K K, GUO J. Transformer fault diagnosis method based on compact fusion of fuzzy set and fault tree[J]. High Voltage Engineering, 2014, 40(5): 1507-1513.
- [7] 赵文清. 基于数据挖掘的变压器故障诊断和预测研究[D]. 保定: 华北电力大学(保定)计算机科学与技术学院, 2009.
- [8] 尹玉萍, 刘万军, 魏林. 基于和声蚁群耦合算法的风电机组齿轮箱故障诊断[J]. 计算机工程, 2014, 40(12): 172-181.
- YIN Y P, LIU W J, WEI L. Fault diagnosis of wind turbine gearbox based on harmony search and ant colony algorithm[J]. Computer Engineering, 2014, 40(12): 172-181.
- [9] 戴浪, 黄守道, 黄科元, 等. 风电场风速的神经网络组合预测模型[J]. 电力系统及其自动化学报, 2011, 23(4): 27-31.
- DAI L, HUANG S D, HUANG K Y, *et al.* Combination forecasting model based on neural networks for wind speed in wind farm[J]. Proceedings of the Chinese Society of Universities, 2011, 23(4): 27-31.
- [10] 朱晟, 蒋传文, 侯志俭. 基于气象负荷因子的Elman神经网络短期负荷预测[J]. 电力系统及其自动化学报, 2005, 17(1): 23-26.
- ZHU S, JIANG C W, HOU Z J. Application of a weather component based Elman neural network to short-term load forecasting [J]. Proceedings of the CSU-EPSCA, 2005, 17(1): 23-26.
- [11] 赵文清, 朱永利, 张小奇, 等. 粗糙集理论在电力变压器故障诊断中的应用[J]. 仪器仪表学报, 2006, 27(z2): 1722-1723.
- ZHAO W Q, ZHU Y L, ZHANG X Q, *et al.* Rough set theory based fault diagnosis on power transformers [J]. Chinese Journal of Scientific Instrument, 2006, 27(2): 1722-1723.
- [12] 韩力群. 人工神经网络教程[M]. 北京: 北京邮电大学出版社, 2006.
- [13] MENG A B, CHEN Y C, YIN H, *et al.* Crisscross optimization algorithm and its application [J]. Knowledge-Based Systems, 2014, 67(4): 218-229.
- [14] 杨维, 李歧强. 粒子群优化算法综述[J]. 中国工程科学, 2004, 6(5): 87-92.
- YANG W, LI Q Q. A Survey on particle swarm optimization algorithm [J]. Engineering Science, 2004, 6(5): 87-92.
- [15] 罗萍, 刘伟, 周述波. 自适应混沌变异的万有引力搜索算法[J]. 广东工业大学学报, 2016, 33(1): 57-61.
- LUO P, LIU W, ZHOU S B. Gravitational search algorithm of adaptive chaos mutation[J]. Journal of Guangdong University of Technology, 2016, 33(1): 57-61.
- [16] 吴伟民, 田龙, 林志毅. 基于粒子群优化的混合宇宙大爆炸算法[J]. 广东工业大学学报, 2016, 33(4): 12-17.
- WU W M, TIAN L, LIN Z Y. Hybrid big bang-big crunch algorithm based on particle swarm optimization[J]. Journal of Guangdong University of Technology, 2016, 33(4): 12-17.
- [17] 龙泉. 风电机组齿轮传动系统动态特性及故障诊断方法研究[D]. 北京: 华北电力大学源动力与机械工程学院, 2012.
- [18] 张海, 浦健, 张啸澄. 基于粒子群优化算法的Elman神经网络凝汽器真空模型[J]. 热力发电, 2010, 39(4): 7-11.
- ZHANG H, PU J, ZHANG X C. A model for predicting vacuum in the condenser based on Elman neural network by using particle swarm optimization algorithm[J]. Thermal Power Generation, 2010, 39(4): 7-11.