

6-2-2020

Fault Diagnosis Algorithm of Permanent Magnet Synchronous Motor Based on Improved ELM

Wang Xin

Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China;

Wang Yan

Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China;

Zhicheng Ji

Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Fault Diagnosis Algorithm of Permanent Magnet Synchronous Motor Based on Improved ELM

Abstract

Abstract: In order to address the common problems of lacking of phase and interturn short circuit fault, after analyzing the basic and corresponding fault model of permanent magnet synchronous motor(PMSM), *an improved extreme learning machine (IELM) algorithm was proposed based on self-adaptive second-order particle swarm optimization (SaSECPSO). SaSECPSO employed adaptive inertia weight and cognitive coefficient with linear variation to improve the convergence rate and accuracy of second-order particle swarm optimization (SECPSO). In addition, the recognition rate of extreme learning machine (ELM) when solving the fault model of PMSM could be significantly improved by using SaSECPSO to simultaneously optimize input weights and hidden layer threshold.* The extensive experiment was carried out by taking motor speed and phase current as multi-source sample, and the results validate that IELM has a higher diagnostic accuracy than other algorithms.

Keywords

permanent magnet synchronous motor, fault model, Improved Extreme Learning Machine, fault diagnosis

Recommended Citation

Wang Xin, Wang Yan, Ji Zhicheng. Fault Diagnosis Algorithm of Permanent Magnet Synchronous Motor Based on Improved ELM[J]. Journal of System Simulation, 2017, 29(3): 646-653.

基于改进 ELM 的永磁同步电机故障诊断算法

汪鑫, 王艳, 纪志成

(江南大学教育部物联网技术应用工程中心, 江苏 无锡 214122)

摘要: 针对永磁同步电机(Permanent Magnet Synchronous Motor, PMSM)常见的缺相及匝间短路故障,分析了PMSM的基本模型及相应的故障模型,提出一种基于自适应二阶粒子群算法(*self-adaptive second-order particle swarm optimization, SaSECP*)的改进极限学习机(*improved extreme learning machine, IELM*)算法。该 SaSECP 算法采用自适应惯性权重策略及线性变化认知系数方法,提高二阶粒子群算法 (*second-order particle swarm optimization, SECP*)的收敛速度和收敛精度。运用 SaSECP 算法同时优化 ELM 的输入权值和隐含层阈值参数,提高 ELM 算法在 PMSM 故障中的识别率。以电机转速和 ABC 相电流作为多源样本,实验证明 IELM 算法相对于其他算法具有较高的诊断精度。

关键词: 永磁同步电机; 故障模型; 改进极限学习机; 故障诊断

中图分类号: TP391.9

文献标识码: A

文章编号: 1004-731X (2017) 03-0646-09

DOI: 10.16182/j.issn1004731x.joss.201703024

Fault Diagnosis Algorithm of Permanent Magnet Synchronous Motor Based on Improved ELM

Wang Xin, Wang Yan, Ji Zhicheng

(Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China)

Abstract: In order to address the common problems of lacking of phase and interturn short circuit fault, after analyzing the basic and corresponding fault model of permanent magnet synchronous motor(PMSM), an improved extreme learning machine (IELM) algorithm was proposed based on self-adaptive second-order particle swarm optimization (SaSECP). SaSECP employed adaptive inertia weight and cognitive coefficient with linear variation to improve the convergence rate and accuracy of second-order particle swarm optimization (SECP). In addition, the recognition rate of extreme learning machine (ELM) when solving the fault model of PMSM could be significantly improved by using SaSECP to simultaneously optimize input weights and hidden layer threshold. The extensive experiment was carried out by taking motor speed and phase current as multi-source sample, and the results validate that IELM has a higher diagnostic accuracy than other algorithms.

Keywords: permanent magnet synchronous motor; fault model; Improved Extreme Learning Machine; fault diagnosis

引言

永磁同步电机具有可控性强,噪声低,效率高



收稿日期: 2016-07-22 修回日期: 2016-09-09;
基金项目: 国家自然科学基金(61572238), 江苏省杰出青年基金(BK20160001);
作者简介: 汪鑫(1992-), 男, 安徽黄山, 硕士生, 研究方向为电机故障诊断; 王艳(1978-), 女, 江苏无锡, 博士, 教授, 博导, 研究方向为网络控制优化、电机智能控制。

等优点,因此被广泛用于各行各业。然而电机在使用的过程中会出现一些常见的故障,如电机匝间故障、缺相故障等,若未能及时发现排除则会造成更严重的损害。因此,及时发现电机故障并正确诊断故障显得极为重要。

2006年,新加坡南洋理工大学教授在提出前馈神经网络极限学习概念的基础上提出了极限学习机(Extreme Learning Machine, ELM)的概念^[1-2]。相对

<http://www.china-simulation.com>

于其他神经网络, 该算法训练速度比传统的网络、BP 网络^[3-4]、支持向量机(SVM)^[5]等学习速度提高了数千倍。但由于极限学习机中输入权值和隐含层阈值是随机产生的, 从而在训练的过程中容易出现拟合现象, 影响极限学习机的精度。

近年来, 提出了许多对极限学习机的改进方法。主成分分析结合法(PCA-IELM)^[6]将高数据进行降低维度处理, 降低输入信号的复杂度, 从而提高了 ELM 模型精度。文献[7]采用 Fibonacci 序列对 ELM 隐含层节点与偏置进行改进。文献[8]通过自适应感应机制来改进极限学习机。文献[9]将隐含层分解成多个进行训练, 再将训练结果进行输出。以上几种改进方法过程复杂且没有明显改善算法性能。传统粒子群算法(PSO)^[10]具有结构简单易于实现, 然而存在精度不高、易陷入局部最优解的问题, 标准二阶粒子群收敛速度快但精度略差于标准粒子群。

本文针对极限学习机存在的不足, 提出自适应二阶粒子群算法(self-adaptive second-order particle swarm optimization, SaSECP SO)改进极限学习机(Improved extreme learning machine, IELM), 是基于二阶粒子群算法的自适应惯性权重策略及线性调整认知系数, 再对极限学习机的输入权值和隐含层阈值同时优化。该方法结构简单易于实现, 解决粒子群算法收敛速度慢及二阶粒子群精度不高的问题, 以此提高极限学习机的训练精度及测试精度。将 IELM 算法用于永磁同步电机故障诊断中, 文章最后通过多组仿真实验论证 IELM 算法在永磁同步电机故障诊断中有较高的准确性。

1 永磁同步电机数学模型

1.1 静态状态永磁同步电机数学模型

永磁同步电机的定子电压方程式如(1)所示:

$$\begin{cases} u_A = R_S i_A + \frac{d\psi_A}{dt} \\ u_B = R_S i_B + \frac{d\psi_B}{dt} \\ u_C = R_S i_C + \frac{d\psi_C}{dt} \end{cases} \quad (1)$$

电机的磁链方程如(2)所示:

$$\begin{bmatrix} \psi_A \\ \psi_B \\ \psi_C \end{bmatrix} = \begin{bmatrix} L_{AA} & M_{AB} & M_{AC} \\ M_{BA} & L_{BB} & M_{BC} \\ M_{CA} & M_{CB} & L_{CC} \end{bmatrix} \begin{bmatrix} i_A \\ i_B \\ i_C \end{bmatrix} + \begin{bmatrix} \psi_f \cos \theta \\ \psi_f \cos(\theta - \frac{2\pi}{3}) \\ \psi_f \cos(\theta + \frac{2\pi}{3}) \end{bmatrix} \quad (2)$$

其中: ψ_f 为电机产生的磁链; θ 为转子旋转的电角度; L_{AA} , L_{BB} , L_{CC} 为各定子绕组间的自感系数; M_{AB} , M_{AC} , M_{BA} , M_{BC} , M_{CA} , M_{CB} 为各定子绕组间的互感系数。

将式(1), (2)结合, 则定子电压方程如(3)所示:

$$\begin{bmatrix} u_A \\ u_B \\ u_C \end{bmatrix} = \begin{bmatrix} R_S + pL_{AA} & pM_{AB} & pM_{AC} \\ pM_{BA} & R_S + pL_{BB} & pM_{BC} \\ pM_{CA} & pM_{CB} & R_S + pL_{CC} \end{bmatrix} \begin{bmatrix} i_A \\ i_B \\ i_C \end{bmatrix} + p \begin{bmatrix} \psi_f \cos \theta \\ \psi_f \cos(\theta - \frac{2\pi}{3}) \\ \psi_f \cos(\theta + \frac{2\pi}{3}) \end{bmatrix} \quad (3)$$

永磁同步电机转子机械运动方程如(4)所示:

$$T_e = T_L + \frac{J}{n_p} \frac{dw_e}{dt} + \frac{1}{n_p} B w_e \quad (4)$$

其中: T_e 为电磁转矩; T_L 为负载转矩; B 为粘滞摩擦系数; J 为转动惯量; w_e 为电机转速。

1.2 dq 旋转轴下数学模型

通过 Clark 和 Park 变换, 电机模型从静止坐标系转化到旋转坐标系下。从而得到 dq 坐标系下的定子电压方程式(5)所示:

$$\begin{cases} u_d = R_S i_d + p\psi_d - w_s \psi_q \\ u_q = R_S i_q + p\psi_q + w_s \psi_d \end{cases} \quad (5)$$

其中: u_d , u_q 分别是 d q 轴上的电压分量; i_d , i_q 分别是 d q 轴上的电流分量; ψ_d , ψ_q 为 d q 轴的定子磁链分量。

电机的磁链方程可表示为式(6)所示:

$$\begin{cases} \psi_d = \psi_f + L_d i_d \\ \psi_q = L_q i_q \end{cases} \quad (6)$$

其中: L_d, L_q 为 dq 轴电感分量; ψ_f 为电机产生的磁链。

电机的转矩方程为式(7)所示:

$$T_e = \frac{3}{2} n_p (\psi_d i_q - \psi_q i_d) \quad (7)$$

1.3 匝间短路故障状态下电机模型

假设 A 相发生绕组匝间短路故障, 故障匝数为 n , 总匝数为 N , 则 A 相绕组故障率 $\eta = n/N$ 。图 1 为三相永磁同步电机 A 相发生绕组匝间短路示意图, 则 A 相绕组故障电阻 R_1 、电感 L_1 、互感 M_{12} 可如式(8) (9)所示:

$$\begin{cases} R_1 = \eta R_s \\ L_1 = \eta^2 L_{AA} \\ M_{12} = \eta(1-\eta)L_{AA} \end{cases} \quad (8)$$

$$\begin{cases} L_1 + L_2 + 2M_{12} = L_{AA} \\ R_1 + R_2 = R_s \\ U_1 + U_2 = U_A \end{cases} \quad (9)$$

电机电压方程短路表达式如(10)所示:

$$\begin{bmatrix} u_A \\ u_B \\ u_C \\ 0 \end{bmatrix} = \begin{bmatrix} R_a & 0 & 0 & -R_1 \\ 0 & R_b & 0 & 0 \\ 0 & 0 & R_c & 0 \\ -R_1 & 0 & 0 & R_1 + R_f \end{bmatrix} \begin{bmatrix} i_A \\ i_B \\ i_C \\ i_f \end{bmatrix} + p \begin{bmatrix} \psi_2 \\ \psi_B \\ \psi_C \\ \psi_1 \end{bmatrix} \quad (10)$$

其中: ψ_1 为 A 相故障绕组上产生的磁链; R_f 为 A 相电机短路电阻。

磁链方程表达式为(11)所示:

$$\begin{bmatrix} \psi_2 \\ \psi_B \\ \psi_C \\ \psi_1 \end{bmatrix} = \begin{bmatrix} L_{AA} & M_{AB} & M_{AC} & -\eta L_{AA} \\ M_{AB} & L_{BB} & M_{BC} & -M_{1B} \\ M_{AC} & M_{BC} & L_{CC} & -M_{1C} \\ -\eta L_{AA} & -M_{1B} & -M_{1C} & L_1 \end{bmatrix} \begin{bmatrix} i_A \\ i_B \\ i_C \\ i_f \end{bmatrix} + \begin{bmatrix} \psi_{fA} \\ \psi_{fB} \\ \psi_{fC} \\ \psi_{f1} \end{bmatrix} \quad (11)$$

其中: L, M 为自感、互感; 下标表示绕组各相。

电机电磁转矩方程式为(12)所示:

$$T_e = \frac{u_A i_a + u_B i_b + u_C i_c - u_f i_f}{\Omega} \quad (12)$$

其中: Ω 是机械角速度。

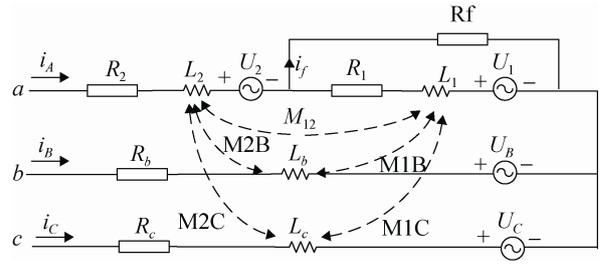


图 1 A 相匝间短路故障示意图

Fig. 1 The schematic diagram of A-phase interturn short circuit fault

1.4 缺相故障状态下电机模型

假设 A 相发生开路故障时, A 相电流传感器会出现电流偏差, 导致 i_A 电流不为 0 而是 i_Δ , 即三相各相电流如式(13)所示:

$$\begin{cases} i_A + i_B + i_C = i_\Delta \\ i_B + i_C = 0 \end{cases} \quad (13)$$

电机电压方程如式(14)所示:

$$\begin{bmatrix} u_A \\ u_B \\ u_C \end{bmatrix} = \begin{bmatrix} R_a & 0 & 0 \\ 0 & R_b & 0 \\ 0 & 0 & R_c \end{bmatrix} \begin{bmatrix} i_\Delta \\ i_B \\ i_C \end{bmatrix} + p \begin{bmatrix} \psi_A \\ \psi_B \\ \psi_C \end{bmatrix} \quad (14)$$

电机磁链方程如(15)所示:

$$\begin{bmatrix} \psi_A \\ \psi_B \\ \psi_C \end{bmatrix} = \begin{bmatrix} L_{AA} & M_{AB} & M_{AC} \\ M_{BA} & L_{BB} & M_{BC} \\ M_{CA} & M_{CB} & L_{CC} \end{bmatrix} \begin{bmatrix} i_\Delta \\ i_B \\ i_C \end{bmatrix} + \begin{bmatrix} \psi_f \cos \theta \\ \psi_f \cos(\theta - \frac{2\pi}{3}) \\ \psi_f \cos(\theta + \frac{2\pi}{3}) \end{bmatrix} \quad (15)$$

2 粒子群算法及极限学习机

ELM 具有学习速度快的同时还具有良好的泛化性能, 然而极限学习机中输入权值和隐含层阈值随机产生, 影响算法精度。粒子群算法(PSO)作为一种智能算法, 相对于传统优化算法, PSO 算法具有全局搜索能力及增加粒子间学习和竞争。粒子群算法及极限学习机算法如下。

2.1 粒子群算法原理

粒子群算法的速度和位置的进化方程如方程

式(16)、(17)所示:

$$v_j(t+1) = wv_j(t) + c_1r_1(p_j(t) - x_j(t)) + c_2r_2(p_g(t) - x_j(t)) \quad (16)$$

$$x_j(t+1) = x_j(t) + v_j(t+1) \quad (17)$$

其中: t 为迭代次数; $v_j(t)$ 为粒子 j 在 t 代的速度; w 为惯性权重; c_1, c_2 为认知系数; r_1, r_2 是均匀分布的随机数; $p_j(t)$ 为粒子 j 个体的历史最优位置; $p_g(t)$ 为群体历史最优位置; $x_j(t)$ 为粒子 j 在 t 代的位置。

2.2 二阶粒子群算法

粒子群算法中粒子个体最佳位置及粒子全局最佳位置确定后, 仅对粒子最佳位置考虑时, 则粒子的速度变化率应为公式(18)所示:

$$v_j(t+1) - v_j(t) = p_j - 2x_j(t) + x_j(t-1) \quad (18)$$

而仅对粒子的全局最佳位置考虑时, 则粒子的速度变化率应为公式(19)所示:

$$v_j(t+1) - v_j(t) = p_g - 2x_j(t) + x_j(t-1) \quad (19)$$

当同时考虑粒子最佳位置考虑和粒子全局最佳位置时, 粒子的变化率应当是以上两种情况的线性随机加权, 则粒子的速度变化率为公式(20)所示:

$$v_j(t+1) - v_j(t) = c_1r_1(p_j - 2x_j(t) + x_j(t-1)) + c_2r_2(p_g - 2x_j(t) + x_j(t-1)) \quad (20)$$

即 $v_j(t+1)$ 可以由公式(21)表示:

$$v_j(t+1) = v_j(t) + c_1r_1(p_j - 2x_j(t) + x_j(t-1)) + c_2r_2(p_g - 2x_j(t) + x_j(t-1)) \quad (21)$$

为了使算法更好地提高局部搜索能力和全局搜索能力, 引入惯性权重 w , 从而改善算法性能。故二阶粒子群算法如公式(22)、(23)所示:

$$v_j(t+1) = wv_j(t) + c_1r_1(p_j - 2x_j(t) + x_j(t-1)) + c_2r_2(p_g - 2x_j(t) + x_j(t-1)) \quad (22)$$

$$x_j(t+1) = x_j(t) + v_j(t+1) \quad (23)$$

2.3 极限学习机原理

极限学习机的网络模型采用的是前向单隐层结构。设该网络输入层、隐含层节点数、输出层数分别为 N, L, M 。其中输入样本为 $(x_j, t_j) j \in (0, 1, \dots, N)$, 其中 x_j 是网络的输入向量, t_j 是目标输出向量。 $G(X)$ 是隐含层激活函数, b_j 为阈值。与

传统的神经网络相比, ELM 算法的输入层的输入权值和隐含层阈值随机产生。可以用数学表达式(24)表示极限学习机的网络模型:

$$\sum_{j=1}^N \beta_j G_j(x_j) = \sum_{j=1}^N \beta_j G(w_j \cdot x_j + b_j) = t_j \quad (24)$$

其中: w_i 为隐含层第 j 个节点与输入层的连接权值向量; b_j 为隐含层第 j 个节点与输入层的阈值; β 为隐含层与输出层的连接权值矩阵; β_j 为第 j 个隐含层单元与输出层的连接权, $\beta_j = [\beta_{j1}, \beta_{j2}, \dots, \beta_{jL}]$, $T = [t_1, t_2, \dots, t_M]$; T 为神经网络的期望输出值。

可以将式(24)变换成矩形式(25)所示:

$$H\beta = T \quad (25)$$

式中: $H(w_1, w_2, \dots, w_L; b_1, b_2, \dots, b_L; x_1, x_2, \dots, x_N) =$

$$\begin{bmatrix} G(w_1x_1 + b_1) & \dots & G(w_Lx_1 + b_L) \\ G(w_1x_2 + b_1) & \dots & G(w_Lx_2 + b_L) \\ \dots & \dots & \dots \\ G(w_1x_N + b_1) & \dots & G(w_Lx_N + b_L) \end{bmatrix}_{N \times L},$$

$$\beta = [\beta_1^T, \beta_2^T, \dots, \beta_L^T]_{L \times M}^T,$$

$$T = [T_1^T, T_2^T, \dots, T_M^T]_{L \times M}^T.$$

极限学习机模型的误差函数可表示为:

$$E(\beta) = \sum_{i=1}^M \|y_i - t_i\| \quad (26)$$

由文献[11]得出的结论可知, 极限学习机训练的最终目的是得到最优的参数 β , 从而最终使得训练输出的值 y_j 与训练样本的期望值 t_j 二者之间的差值 E 最小, 即公式(27)所示:

$$\min_{\beta} E(\beta) = \min_{\beta} \|Y - T\| =$$

$$\min_{\beta} \|H(w_1, w_2, \dots, w_L; b_1, b_2, \dots, b_L; x_1, x_2, \dots, x_N) \beta - T\| \quad (27)$$

根据文献[12]可知: 在实际情况中, 由于训练样本数 n 规模较大, 为了降低计算量, 隐含层节点数通常会小于 n , 因此隐含层输出矩阵 H 不是方阵, 所以不存在 $w_i, b_i, \beta_i (i=1, 2, \dots, n)$ 使得 $H\beta = T$ 等式成立, 但是可以以最小范数最小二乘解 β^1 来代替这个线性系统的解, 故可以使用 β^1 代替 β , 则方程组(27)的最小二乘解可以转换为式(28)所示:

$$\beta^1 = H^+ T \quad (28)$$

其中： H^+ 称为隐含层输出矩阵 H 的Moore-Penrose广义逆。

由于极限学习机中输入权值和隐含层阈值的随机选择性，在一定程度上影响了算法的精确性。为了达到理想的误差精度，往往需要大量的隐含层节点，有时在训练的过程中容易出现过拟合现象，从而影响算法性能。对极限学习机中输入权值和隐含层阈值优化不仅可以增加算法的精度，而且不需要大量的隐含层节点，同时降低了过拟合现象，因此优化输入权值及隐含层阈值十分必要。

3 改进极限学习机

自适应二阶粒子群算法主要是在二阶粒子群算法的基础上，使粒子能均匀分布整个空间和更快地找到最优值，对粒子初始种群初始化方式优化及优化惯性权值和认知系数，以此提高粒子群算法的收敛速度和诊断精度。以极限学习机中的输入权值和隐含层阈值作为自适应二阶粒子群算法中的元素，将极限学习机中的样本期望输出和实际输出的均方差(RMSE)作为自适应粒子群算法中的适应度，以此提高ELM算法的分类精度。

3.1 自适应二阶粒子群算法

标准粒子群算法(PSO)中粒子的飞行速度仅仅是粒子当前位置的函数，而二阶粒子群算法中粒子飞行速度的变化与粒子位置有关，避免了由粒子速度项引起的粒子发散而导致后期收敛速度变慢的问题。

3.1.1 二阶粒子群初始化

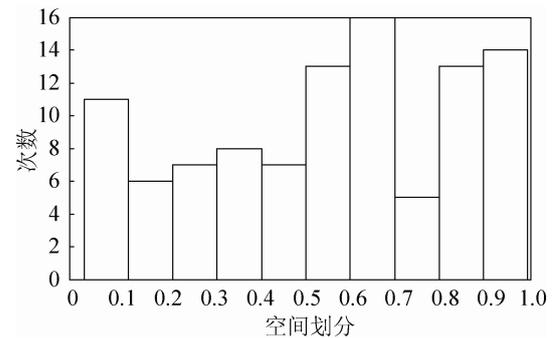
粒子群具有易操作及搜索速度快等优点，但是很容易陷入最优解求解复杂多峰优化问题、算法迭代后期收敛速度慢等问题，在一定程度上限制了算法性能。

在粒子群算法中初始种群是随机产生，为保证初始种群中粒子能均匀分布在空间，提高算法的全局搜索能力，采用式(29)对种群粒子初始化。

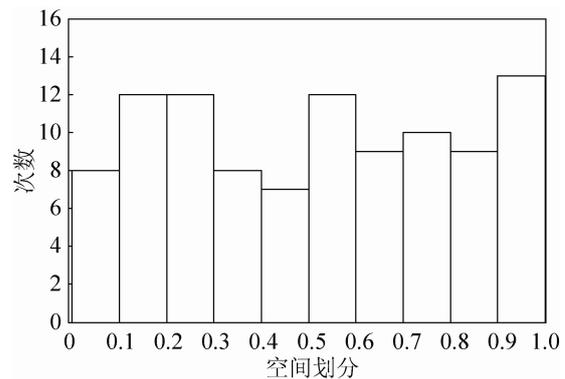
$$Z = \begin{cases} Z_n / 0.3 & 0 < Z_n \leq 0.3 \\ (Z_n - 0.3) / 0.4 & 0.3 < Z_n \leq 0.7 \\ (1 - Z_n) / 0.3 & 0.7 < Z_n < 1 \end{cases} \quad (29)$$

其中： Z 是粒子种群； Z_n 是第 n 个粒子种群值。

粒子数为100的两种初始化粒子仿真图形分别如图2(a)、图2(b)所示，从图2可以看出，采用公式(29)的初始化粒子分布图2(b)具有更好的均匀分布，故本文采用公式(29)对粒子初始化。



(a) 随机产生粒子空间分布



(b) 本文提出的粒子空间分布

图2 两种粒子空间分布

Fig. 2 The spatial distribution between two kinds of particles

3.1.2 二阶粒子群参数优化

在二阶粒子群算法中，惯性权重 w 是非常重要的参数，当 w 值较大时对算法具有较强的全局搜索能力，当 w 值较小时对算法具有较强的局部搜索能力。

本文采用文献[13]提出的自适应权重改变策略，惯性权重随着迭代次数的增加可以自行地调整权重的大小，这样有利于算法的收敛速度的提高，具有避免早熟的效果，其表达式如公式(30)所示：

$$w = \begin{cases} w_{\min} + \frac{(w_{\max} - w_{\min})(f - f_{\min})}{(f_{\text{avg}} - f_{\min})}, & f \leq f_{\text{avg}} \\ w_{\max} & , f > f_{\text{avg}} \end{cases} \quad (30)$$

其中: f 表示当前粒子目标函数适应度值; f_{avg} 和 f_{\min} 分别表示当前粒子平均目标函数适应度值和最小目标函数适应度值。

然而不仅惯性权重 w , 而且认知系数 c_1 、 c_2 对算法的局部搜索及全局搜索也有很大的影响。当粒子的认知系数 c_1 较大时, 算法具有较强的全局搜索能力; 当粒子的认知系数 c_2 较大时, 算法具有较强的局部搜索能力。故认知系数 c_1 、 c_2 相应地递增或递减变化, 通过两者之间的相互作用来平衡算法的全局及局部搜索能力, 能更好地引导粒子进行优化搜索。

文献[14]证明了要使得粒子群算法具有收敛性, 则惯性权重 w 及认知系数 c_1 、 c_2 必须满足公式(31)。

$$\begin{cases} 0 < w < 1 \\ 0 < c_1 r_1 + c_2 r_2 < 4 \\ c_1 r_1 + c_2 r_2 < 2(w+1) \end{cases} \quad (31)$$

从公式(31)可以看出, 当目标函数适应度较大时, 算法需要具有较强的全局搜索能力, 因此惯性权重 w 及认知系数 c_1 的值都较大时能满足要求。同理, 当目标函数适应度较小时, 算法需要具有较强的局部搜索能力, 因此惯性权重 w 值较小及认知系数 c_2 的值较大时能满足要求。

为了满足以上条件, 本文将认知系数 c_1 、 c_2 大小设置如公式(32)所示:

$$\begin{cases} c_1 = 1.5w + 0.5 \\ c_2 = \min(4, 2(w_{\min} + 1)) - c_1 - \frac{w}{1000} \end{cases} \quad (32)$$

3.2 改进的极限学习机算法

给定一训练样本集 $(x_j, t_j) \quad j \in (1, \dots, N)$, 激活函数为 $G(X)$, 输出训练学习误差为 ε 。以极限学习机中的输入权值和隐含层阈值作为自适应二阶粒子群算法中的元素, 将极限学习机中的样本期望输出和实际输出的均方差(RMSE)作为粒子群算法中的适应度, 改进后的极限学习机步骤如下:

(1) 给一训练样本集, 包括输入向量和期望输出向量, 并且预先将训练样本数据进行 0-1 归一化处理。

(2) 初始 ELM 网络结构, 输入层、隐层、输出层神经元初始个数和相应的激活函数。

(3) 产生种群, 设置粒子数 Z 、迭代数、最小误差。由公式(29)随机产生初始种群。初始化粒子群算法认知系数、惯性权重等。

(4) 采用极限学习机的实际输出和期望输出误差 ε 作为粒子群算法适应度值。

(5) 根据公式(30)(32)更新惯性权重 w 及认知系数 c_1 、 c_2 。

(6) 根据公式(22)、(23)更新粒子的速度和位置, 得到个体极值和群体极值。

(7) 判断是否达到终止条件, 若否, 则转到步骤(4)继续迭代。若是, 则结束。

3.3 实验流程

改进后 ELM 算法流程图如图 3 所示。

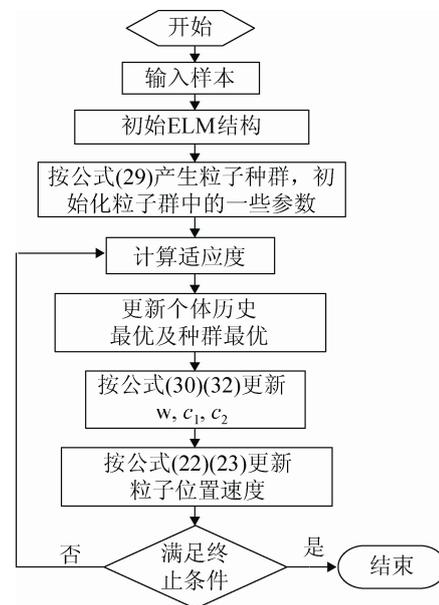
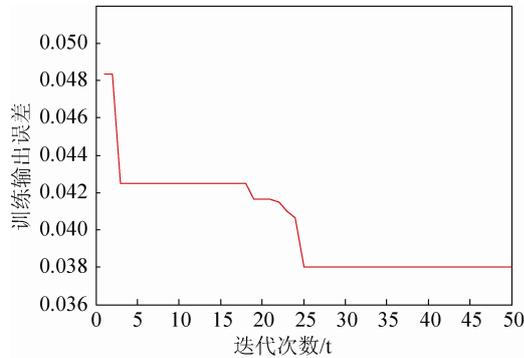


图 3 改进 ELM 流程图

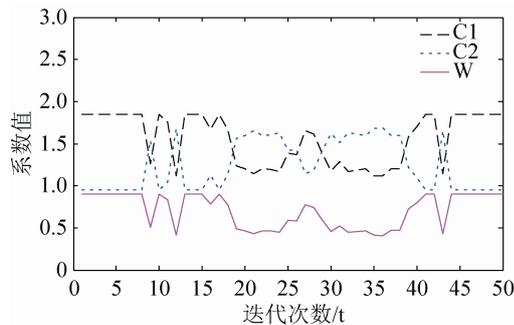
Fig. 3 The improved ELM flow chart

根据以上算法, 迭代 50 次得到的适应度曲线图及各参数曲线图如图 4 所示。从图 4(a)中可以看出改进极限学习机算法的输出误差在 25 代左右达

到最小训练误差,同时误差值为 0.038 左右,具有较快的收敛速度和较高的精度。从图 4(b)可以看出,当算法达到最小误差后, c_1 、 c_2 的值会不断波动,最终 c_1 值增大 c_2 值减小,可以避免算法陷入局部最优,有利于寻找全局最优。



(a) 训练误差曲线图



(b) 参数变化曲线图

图 4 ELM 输出误差及参数变化曲线

Fig. 4 The curve of ELM output error and parameter variation

4 实验及结果分析

本文采用永磁同步电机正常数学模型和故障数学模型分别在 MATLAB 中进行仿真实验。文中永磁同步电机模型参数如表 1 所示。

表 1 电机模型参数
Tab. 1 Motor parameters

序号	仿真参数	参数值	单位
1	定子电阻 R_s	2.87	Ω
2	定子电感 L_d	0.008 5	H
3	定子电感 L_q	0.008 5	H
4	极对数 n_p	2	对
5	转速	1 500	$r \times \text{min}^{-1}$
6	转动惯量 J	0.008	$\text{Kg} \times \text{m}^2$

本文分别对前文提出的开路故障、匝间故障、正常模型仿真,对各运行状态过程中的电机转速信号值及 ABC 相电流信号值进行提取,再进行 0-1 归一化处理,处理后的数据作为对应的训练样本及测试样本。

ELM 模型中采用的是 sigmoid 作为激励函数,以永磁同步电机的速度、ABC 相电流作为样本数据,ELM 模型针对不同样本的结果如表 2 所示。样本 1 的数据为电机完整周期的速度、ABC 相电流数据,样本 2 是各个故障时的速度、ABC 相电流数据,可以看出样本 2 得到的实验结果不论在速度上还是在精确度上都优于样本 1 的数据。

表 2 不同样本下 ELM 模型诊断效果对比

Tab. 2 The effect contrast of ELM model diagnosis under different samples

样本	训练时间/s	诊断时间/s	训练精度/%	测试精度/%
1	0.078 0	0.006 2	92.55	91.84
2	0.031 2	0.002 8	93.64	93.77

为了验证 SaSECPSO 算法优化 ELM 的性能效果优于其他算法。表 3 列举了 ELM 算法及 PSO 算法、SECPSO 算法、SaSECPSO 算法对 ELM 算法优化后的诊断效果性能对比。训练样本和测试样本为样本 2 的数据,本文采用的训练样本数和测试样本数分别为 1 000 和 200,由于输入变量为 4 个故障输入层节点数为 4,隐含层数由经验确定为 20。粒子种群规模为 20,最大迭代次数是 100 次,表 3 中数据是每组算法做 20 次重复实验的平均值。虽然利用 SaSECPSO 算法优化 ELM 算法耗时略慢于其他 3 个算法,但是在可接受的范围内。从表中可以看出,利用 SaSECPSO 算法对 ELM 算法优化后,在训练精度、测试精度及训练方差方面都明显优于其他 3 种算法。

表 3 不同算法优化 ELM 的性能对比

Tab. 3 The comparison of performance among different ELM-optimizing algorithms

算法	训练精度/%	测试精度/%	训练方差
ELM	92.41	92.37	9.194×10^{-5}
SECPSO	95.02	94.92	4.348×10^{-6}
PSO	95.57	95.39	4.516×10^{-6}
SaSECPSO	96.11	96.08	3.384×10^{-6}

图 5 是 SECPSOELM, PSOELM 及 IELM 算法迭代 300 次得到的分类训练误差率对比图, 从图中可以看出, 本文提出的 IELM 算法在迭代 30 次左右时达最小误差, 误差率为 3.85% 左右, 而 SECPSO 及 PSO 优化算法分别需要迭代 40 和 75 次左右时才能达到最小误差。相对于其他两种算法, IELM 收敛速度更快, 分类精度更高。因此 IELM 算法具有较好的诊断效果。

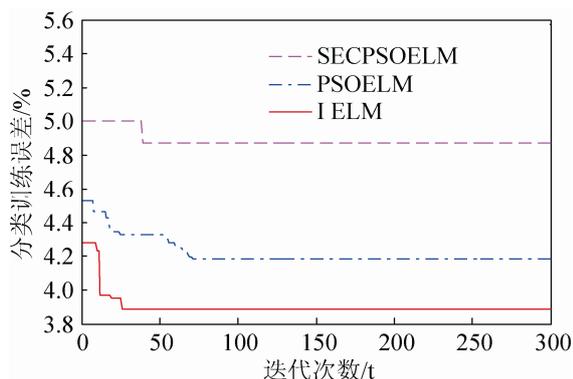


图 5 ELM 训练图
Fig. 5 ELM training figure

5 结论

本文首先分析永磁同步电机正常数学模型及故障状态下的数学模型。提出了利用自适应二阶粒子群算法对极限学习机模型中输入权值及隐含层阈值优化。采用永磁同步电机缺相故障、匝间短路故障仿真实验得到样本数据, 利用优化后的极限学习机对永磁同步电机进行故障诊断, 最后通过和其他几种粒子群算法对比分析可以看出自适应二阶粒子群优化算法具有更高的训练精度和测试精度及更快地收敛速度, 在永磁同步电机中具有较好的诊断效果。

参考文献:

[1] Huang G B, Chen L, Siew C K. Universal approximation using incremental constructive feedforward networks with random hidden nodes [J]. IEEE Transactions on Neural Networks (S1045-9227), 2006, 17(4): 879-892.
[2] Huang G B, Chen L. Enhanced random search based incremental extreme learning machine [J]. Neurocomputing

(S0925-2312), 2008, 71 (16/18): 3460-3468.
[3] 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 Fuwen. Fault diagnosis for FMS based on BP algorithm and petri net [J]. Manufacturing Automation, 2012, 34(10): 106-108.)
[4] 吉哲, 王修敏, 张松涛. 基于 BP 神经网络的舰船电机故障诊断 [J]. 电机与控制应用, 2013, 40(7): 58-60. (Ji Zhe, Wang Xiumin, Zhang Songtao. Fault Diagnosis for Ship Motor Based on BP Neural Network. [J]. Electric Machines & Control Application, 2013, 40(7): 58-60.)
[5] 刘国海, 董蓓蓓, 滕成龙, 等. 基于支持向量机广义逆的永磁同步电机模型参考自适应控制 [J]. 东南大学学报: 自然科学版, 2010, 40(增 1): 13-18. (Liu Guohai, Dong Beibei, Teng Chenglong, et al. Model reference adaptive control of PMSM based support vector machines generalized inverse [J]. Journal of Southeast University (Natural Science Edition) | J Southeast Univ (Nat Sci Ed), 2010, 40(S1): 13-18.)
[6] 贺彦林, 王晓, 朱群雄. 基于主成分分析改进的极限学习机方法的精对苯二甲酸醋酸含量软测量 [J]. 控制理论与应用, 2015, 32(1): 80-85. (He Yanlin, Wang Xiao, Zhu Qunxiong. Modeling of acetic acid content in purified terephthalic acid solvent column using principal component analysis based improved extreme learning machine [J]. Control Theory and Applications, 2015, 32(1): 80-85.)
[7] 陆慧娟, 魏莎莎, 宋夫华. 一种 Fibonacci 优化理论的改进 ELM 分类方法 [J]. 小型微型计算机系统, 2015, 36(12): 2745-2748. (Lu Huijuan, Wei Shasha, Song Fuhua, et al. ELM Algorithm Based on Fibonacci Method Optimization Algorithm [J]. Journal of Chinese Mini-Micro Computer Systems, 2015, 36(12): 2745-2748.)
[8] 尹刚, 张英堂, 李志宁, 等. 自适应集成极限学习机在故障诊断中的应用 [J]. 振动、测试与诊断, 2013, 33(5): 897-901. (Yin Gang, Zhang Ying Tang, Li Zhining, et al. Adaptive integration extreme learning machine application in fault diagnosis [J]. Journal of Vibration, Measurement & Diagnosis, 2013, 33(5): 897-901.)
[9] Yang Y, Wu Q M. Extreme Learning Machine With Subnetwork Hidden Nodes for Regression and Classification [J]. Cybernetics IEEE Transactionson (S2168-2267), 2015, 210(3): 1-14.
[10] J Kennedy, R Eberhart. Particle swarm optimization [J]. IEEE International Conference on Neural Networks (S1098-7576), 1995 (4): 1942-1948.

(下转第 668 页)