

DOI: 10.13382/j.jemi.B2104135

风力发电机齿轮箱优化逐层故障诊断方法*

何怡刚 鲁力 阮义 袁伟博

(合肥工业大学电气与自动化工程学院 合肥 230009)

摘要:风力发电机齿轮箱的故障诊断在风力发电机组正常运行中起着重要作用,除了识别故障类型外,故障的严重程度对风机的维护也具有指导意义,因此,一种优化堆叠诊断结构(OSDS)被提出以识别故障类型和严重性。首先对原始振动信号进行压缩采样,然后将压缩样本分别输入第1层和第2层深度信任网络(DBN),对故障类型和严重性进行识别,同时采用混沌量子粒子群优化算法(CQPSO)对每个DBN进行优化。通过两组实验得到的结果表明,故障类型诊断准确率分别达到99.24%和97.21%,故障严重程度诊断准确率达到99.06%,同时诊断时间仅为1.493和2.176 s。

关键词:风力发电机;齿轮箱;故障诊断;逐层诊断网络

中图分类号: TN919;TP274 **文献标识码:** A **国家标准学科分类代码:** 510.4030

Optimized hierarchical diagnostic approach for wind turbine gearbox

He Yigang Lu Li Ruan Yi Yuan Weibo

(School of Electrical Engineering and Automation, Hefei University of Technology, Hefei 230009, China)

Abstract: Fault diagnosis for gearbox of wind turbine plays an important role in the normal operation of WT. Current studies commonly focus on diagnosis of fault types, nevertheless, in addition to identifying the fault type, the severity of the fault is also instructive for maintenance and repair for wind turbine. Thus, a novel optimized stacked diagnosis structure (OSDS) is proposed for identification of fault type and severity. Compressed sensing is adopted to implement compressed sampling of original vibration signals. Then, compressed samples are input into first and second layer deep belief networks (DBNs) for identification of fault type and severity, separately. In addition, every single DBN in the OSDS is optimized with chaotic quantum particle swarm optimization (CQPSO) algorithm. Comparison experiments based on bench mark gearbox fault data and working planetary gearbox show that the fault type diagnosis accuracy of this method reaches 99.24% and 97.21%, while the fault severity accuracy reaches 99.06%. Meanwhile, the testing times are only 1.493 and 2.176 s.

Keywords: wind turbine; gearbox; fault diagnosis; hierarchical diagnostic network

0 引言

随着风力发电的高速发展,其在能源结构中所占比重也日益增大。然而,逐渐增大的风电机组装机数量和单机容量也同时导致了内部结构更加复杂,各部件之间耦合愈发密切,细微故障会给整个系统带来连锁反应等问题。基于此种情况,对风力发电机组进行高效的在线监测对保障安全高效的工业生产起到了至关重要的作

用。在风力发电机组传动系统中,齿轮箱对风力发电机组的正常运行起着至关重要的作用,其故障将严重影响风力发电机组的正常出力,使经济效益急剧下降。因此,尽可能准确地对齿轮箱故障进行早期诊断具有重要意义。

在现有的研究中,提出了许多应用于风力发电机齿轮箱的故障诊断方法^[1-3],其中机器学习方法的应用越来越受到重视^[4-6]。目前,故障诊断的研究一般只集中在故障类型的诊断上,但是除了故障的类型外,确定当前故障

收稿日期:2021-04-06 Received Date:2021-04-06

* 基金项目:国家自然科学基金(51577046)、国家自然科学基金(51977161)、国家自然科学基金(51977153)、国家自然科学基金重点项目(51637001)、国家重点研发计划“重大科学仪器设备开发”项目(2016YFF0102200)、装备预先研究重点项目(41402040301)资助

的严重程度,对于识别故障的严重性以便采取措施加以预防和消除也具有重要意义。因此,本文提出了一种能同时诊断故障类型和故障严重程度的深度结构。这一结构被称为优化堆叠诊断结构(optimized stacked diagnosis structure, OSDS),它由深度信念网络(deep belief network, DBN)^[7]、混沌量子粒子群优化(chaotic quantum particle swarm optimization, CQPSO)算法^[8]和压缩感知(compressed sensing, CS)^[9]组成。DBN 由受限玻耳兹曼机(restricted Boltzmann machine, RBM)构成^[10],通过预训练和逐层微调对原始信号逐层进行非线性表征,得到有效提取输入数据特征的结构。DBN 的结构设置对其特征提取表现十分重要,传统粒子群优化(particle swarm optimization, PSO)算法^[11]、量子粒子群优化(quantum particle swarm optimization, QPSO)算法^[12]和量子遗传算法(quantum genetic algorithm, QGA)^[13],都可能陷入局部最优,同时也存在收敛速度慢、收敛失败等问题,因此在优化中利用混沌来保持粒子的多样性的 CQPSO 算法被采用。与传统快速傅里叶变换(fast Fourier transform, FFT)^[14]、小波变换(wavelet transform, WT)^[15]、小波包变换(wavelet packet transform, WPT)^[16]和经验模式分解(empirical mode decomposition, EMD)^[17]等信号处理方法相比,风机齿轮箱振动信号的稀疏性保证了可以采用 CS 得到包含原始信号特征的压缩采样。

在 OSDS 中,每一层都由 DBN 组成,用于识别输入数据的类型。近年来,这种分级诊断网络在故障诊断领域取得了一些优秀的成果^[18-20]。在此基础上,采用 CQPSO 算法对每个 DBN 层进行优化,能够获得最佳的分类性能。另外,对原始信号进行压缩采样,可以有效减少故障诊断所需的时间和内存,同时保证故障诊断的准确性。在 OSDS 中,第 1 层 DBN 对故障类型进行分类,第 2 层 DBN 则分别识别不同故障类型数据的故障严重程度,可以根据故障严重程度的诊断结果直接判断齿轮箱的损伤程度。

综上所述,通过与已有的同类研究相对比,本文提出的 OSDS 方法在对风机齿轮箱进行故障诊断时所取得的诊断准确性、所需测试时间和所需存储空间方面都具有优势,取得了优异表现。

1 深度信念网络结构

DBN 是由多个 RBM 的隐藏层组成的堆叠结构,具有预训练过程和微调过程,其结构如图 1 所示。

原始数据被输入到第 1 层 RBM 中,并且第 1 个隐藏层提取的特征被用作下一 RBM 的输入,在下一个隐藏层中继续提取出特征。最后一个隐藏层中储存了最终提取的特征,将这些特征作为 Softmax 分类器的输入来识别别

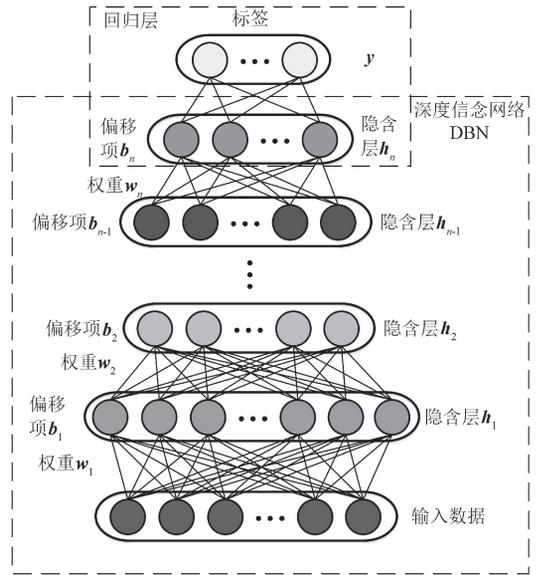


图 1 DBN 结构

Fig. 1 DBN structure

入数据的模式,并将分类得到的输入数据类别标签与预设的输入数据类别标签进行比较,以便使用反向传播机制更新每个 RBM 的参数^[7]。

每个 RBM 包括可见层 $\mathbf{v} = \{0, 1\}^D$ 和隐藏层 $\mathbf{h} = \{0, 1\}^K$,其能量函数如下^[10]:

$$E(\mathbf{v}, \mathbf{h}) = - \sum_{p=1}^D \sum_{q=1}^K v_p w_{pq} h_q - \sum_{p=1}^D c_p v_p - \sum_{q=1}^K b_q h_q \quad (1)$$

式中: D 表示可见层 \mathbf{v} 中的神经元数量; K 表示隐藏层 \mathbf{h} 中的神经元数量; v_p ($p=1, 2, 3, \dots, D$) 表示可见层 \mathbf{v} 中的神经元状态; h_q ($q=1, 2, 3, \dots, K$) 表示隐藏层 \mathbf{h} 中的神经元状态; w_{pq} 表示 \mathbf{v} 和 \mathbf{h} 之间的权重; c_p 表示可见层 \mathbf{v} 的偏移项; b_q 表示隐藏层 \mathbf{h} 的偏移项。

其权重的更新符合以下公式:

$$\Delta w_{pq} = \varepsilon (v_p h_{qorigin} - v_p h_{qreconstruct}) \quad (2)$$

式中: ε 是学习率。通过 CQPSO 算法设置合适的学习率 ε 和隐含层 \mathbf{h} 结构,DBN 可以实现可靠的故障诊断性能。

2 混沌量子粒子群算法优化过程

CQPSO 算法在迭代过程中采用混沌策略进行策略决策,与传统的 QPSO 算法相比降低了早熟收敛的可能性^[21]。常规 QPSO^[21] 的更新方程如下:

$$\begin{cases} m_{best} = \frac{1}{M} \sum_{i=1}^M P_i \\ P_{c_{ij}} = \varphi P_{ij} + (1 - \varphi) P_{gj} \\ X_{ij}(t+1) = P_{c_{ij}} \pm \alpha | m_{bestj} - X_{ij}(t) | \ln\left(\frac{1}{u}\right) \end{cases} \quad (3)$$

式中： m_{best} 是所有粒子的当前最佳位置的中心； m_{bestj} 是在 j 维的最佳位置的中心； P_i 是最优位置， X_{ij} 是在 j 维的当前位置； t 是迭代次数； M 是粒子群大小； P_{cij} 是介于 P_{ij} 和 P_{gj} 之间的随机位置； $\phi \in (0, 1)$ ， $u \in (0, 1)$ ； α 是控制因子^[22]。

$$\alpha = 0.5 + 0.5 \times (T_{\max} - t) / T_{\max} \quad (4)$$

式中： T_{\max} 是迭代停止的次数。

为了提高混沌特性的效果，保持种群多样性，在 CQPSO 优化过程中采用了具有优良混沌分布特性的 Cat 映射函数^[23]。相关公式如下：

$$\begin{cases} x_{n+1} = (x_n + y_n) \text{bmod}1 \\ y_{n+1} = (x_n + 2y_n) \text{bmod}1 \end{cases} \quad (5)$$

式中： $x \text{mod}1 = x - [x]$ 。

本文将根均方误差 (root mean square error, RMSE) 作为适应度函数进行了研究。全局最优位置 P_g 是能够达到最小适应度函数值的最优位置 P_i 。

优化过程如如图 2 所示。

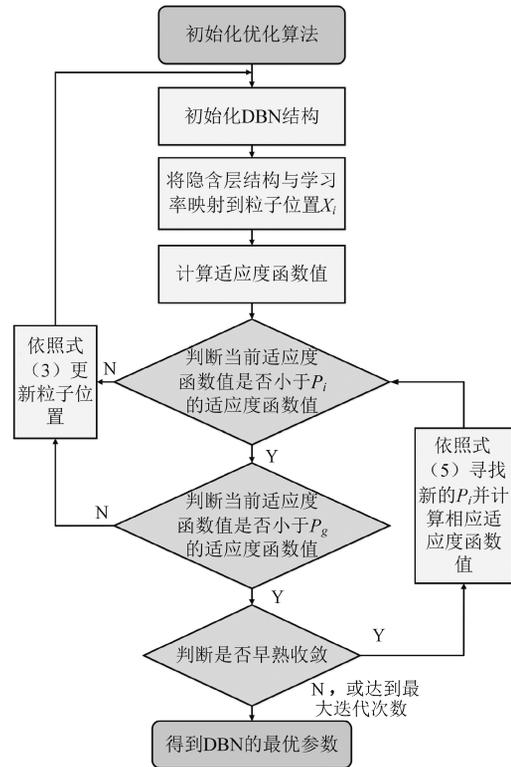


图2 CQPSO 算法优化流程

Fig. 2 Optimization flowchart of CQPSO

其优化步骤如下：

1) 初始化优化算法为一组随机粒子，其中粒子位置 X_i 表示将要被优化的参数，即隐层节点数和学习速率。

2) 计算每个粒子的 RMSE。然后，得到每个粒子的 P_i ，并选择 P_g 。

3) 计算 m_{best} ，然后用式(3)更新整个粒子的位置，并计算所有粒子的 RMSE。此外，还对每个粒子的更新后位置的 RMSE 和 P_i 进行了比较。如果更新后的位置可以得到较小的 RMSE，则用它替换 P_i ，否则 P_i 将保持不变。

4) 再次比较现有 P_i 和 P_g 的 RMSE，如果现有 P_i 可以得到较小的 RMSE，则用它替换 P_g ，否则 P_g 保持不变。

5) 如果需要更新 P_g ，则需要判断当前结果是否过早收敛。在预设标准值 δ 的前提下，根据以下公式的计算结果进行判断：

$$\hat{\delta} = \frac{1}{M} \sum_{i=1}^M \left(\frac{f_i - f_{mean}}{f} \right)^2 \quad (6)$$

式中： f_i 是现有粒子的适应度函数 RMSE， f_{mean} 是整个现有粒子群 RMSE 的平均值。如果小于 δ ，则判断为早熟收敛。在这种情况下，根据式(5)搜索新的 P_i 。

6) 当达到预设的最大迭代次数时，采集 P_g 的参数。或者，迭代步骤 1)~5)，直到满足迭代停止的条件。

3 压缩感知采样方法

CS 理论利用了稀疏信号的可压缩性，在最小化约束的前提下^[24]，能够以较少的信号采集量再现原始信号。利用 $M \times N$ 阶的测量矩阵 Φ 从 N 维原始信号 x 中收集维度远小于 N 的 M 维线性采样 y ，式(7)为基本的无噪模式。

$$y = \Phi x \quad (7)$$

为了表示压缩采样信号相对于初始信号的压缩程度，引入了压缩比 (compression ratio, CR)，其表达式如下：

$$CR = \frac{N - M}{N} \times 100\% \quad (8)$$

在压缩采集的实现中，合适的测量矩阵 Φ 起着重要的作用。测量矩阵 Φ 的选择关系到能否采集到包含原始信号所有特征的稀疏信号，以及能否根据压缩采样重构原始信号。限制等距条件 (restricted isometry property, RIP) 已经被证明是压缩信号和 K 稀疏信号能够完全重构的一个充分条件。以下公式说明了 RIP：

$$1 - \delta \leq \frac{\|\Phi x\|_2^2}{\|x\|_2^2} \leq 1 + \delta \quad (9)$$

式中： $\delta \in (0, 1)$ 是 RIP 常数。

在现有的 CS 应用研究中，随机高斯矩阵^[24] 被广泛应用，因为它被证明具有满足 RIP 的最大概率。然而，它占用的存储空间太大，运行时间太长，限制了它的实际应用。因此在本研究中，随机伯努利矩阵^[25] 被用作压缩和收集信号的测量矩阵。由于随机伯努利矩阵的所有元素都是随机的 +1 或 -1，因此与随机高斯矩阵相比，采用随

机伯努利矩阵所占用的运算时间和存储空间大大减少。

4 优化堆叠诊断结构

本文所提出的 OSDS 是一种综合了上述 DBN、CQPSO 和 CS 理论的逐层故障诊断模型,既能识别故障类型又能判断故障严重程度。其故障诊断流程如图 3 所示。

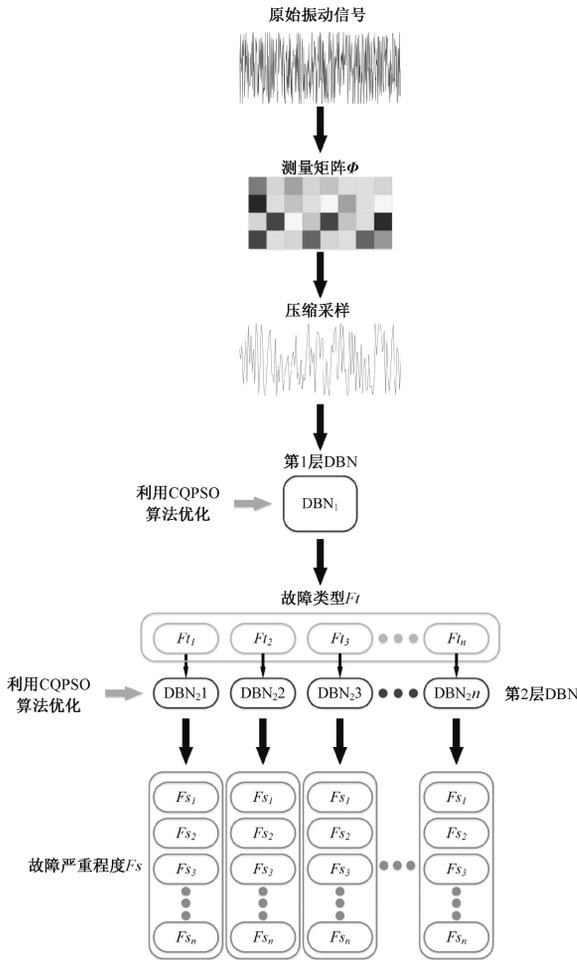


Fig. 3 Fault diagnosis flowchart of OSDS

首先,利用测量矩阵 Φ 得到原始振动信号的压缩样本。然后,基于从压缩样本中划分出的训练数据集,采用 CQPSO 算法对第 1 层 DBN 进行优化。利用第 1 层 DBN₁ 识别从压缩样本中划分出来的测试数据集的故障类型 F_t 。按照故障类型的分类结果,将采样分为 $F_{t_1}, F_{t_2}, F_{t_3}, \dots, F_{t_n}$ 。然后对每种类型的样本,将分类后的样本输入到第 2 层 DBN 中,并用 CQPSO 算法对其进行优化,识别出每个样本的故障严重程度 F_s 。例如,将分类样本 F_{t_1} 输入到 DBN_{2,1} 中,以识别每个样本的 F_s ,然后将 F_{t_1} 的每个

样本划分为不同的 F_s 分类, $F_{s_1}, F_{s_2}, F_{s_3}, \dots, F_{s_n}$ 。

基于这一故障诊断流程,输入的原 始 齿 轮 箱 故 障 数 据 能 够 被 高 效 的 识 别 出 不 同 故 障 类 型 F_t , 以 及 与 之 相 对 应 的 故 障 严 重 程 度 F_s 。

5 实验结果与分析

本文实验分为两部分对所提出的方法进行验证,其中第 1 部分采用一组由美国康涅狄格大学唐炯教授团队分享的^[26],从基准齿轮箱采集的故障信号对所提出的方法进行了测试。本组齿轮箱故障信号包括 5 种故障类型,其中第 5 种故障类型有 5 种不同的故障严重程度,表 1 为故障信号的详细数据。

表 1 基准齿轮箱故障详细信息

Table 1 Fault details of benchmark gearbox

故障代码	故障类型	故障严重程度	原始采样/压缩采样 维度 (CR=70%)
F_{t_1}	健康	/	3 600/1 080
F_{t_2}	缺齿	/	3 600/1 080
F_{t_3}	齿根裂纹	/	3 600/1 080
F_{t_4}	剥落	/	3 600/1 080
F_{t_5}	尖端缺失	$F_{s_1}/F_{s_2}/F_{s_3}/F_{s_4}/F_{s_5}$	3 600/1 080

5 种不同故障类型的信号以 $F_{t_1}, F_{t_2}, F_{t_3}, F_{t_4}$ 和 F_{t_5} 代称。5 种不同故障严重程度的信号以 $F_{s_1}, F_{s_2}, F_{s_3}, F_{s_4}$ 和 F_{s_5} , 代称。采样频率为 20 kHz, 每一条原始信号包含 3 600 个数据点, 每种不同故障类型和故障严重程度的信号分别有 104 条原始信号。

实验的第 2 部分采用宣城龙湖风电场数年间行星齿轮箱故障数据组成的数据集对所提出方法进行测试。风电机组装机容量为 2.1 MW, 齿轮箱传动结构为 1 级行星齿轮和 2 级平行齿轮, 总传动比为 1 : 118.1。该测试齿轮箱如图 4 所示, 详细故障信息如表 2 所示。

表 2 行星齿轮箱故障详细信息

Table 2 Fault details of planetary gearbox

故障代码	故障类型	故障特性	原始采样/压缩采样 维度 (CR=70%)
F_{p_1}	健康	/	2 000/600
F_{p_2}	太阳轮故障	齿轮磨损	2 000/600
F_{p_3}	行星轮故障	齿轮磨损	2 000/600
F_{p_4}	齿圈故障	未知	2 000/600

本组故障数据仅对故障类型进行诊断, 4 种不同故障类型的信号以 $F_{p_1}, F_{p_2}, F_{p_3}$ 和 F_{p_4} 代称。每一条原始信号为从连续采样中截取出一段含有 2 000 个数据点的片段, 在每种故障类型的数据中分别有 50 条此类片段信号。



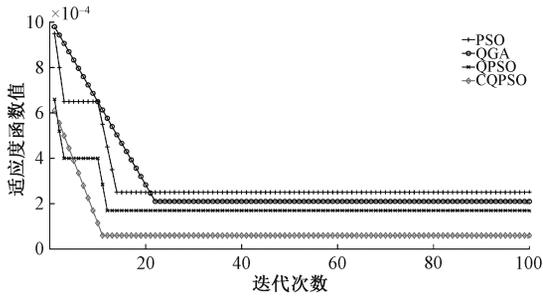
图 4 测试行星齿轮箱

Fig. 4 Tested planetary gearbox

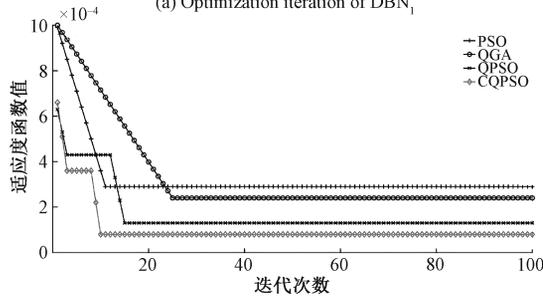
在两部分实验中,每一故障类型的训练数据均由该类故障总数据中随机抽取出的 1/4 组成,并由这些训练数据组成训练集,剩余数据则组成测试集。在故障诊断之前,先以 70% 的 CR 进行压缩采样,并以训练集数据为基准对全部数据进行归一化处理。

5.1 算法优化实验

在用 OSDS 进行故障诊断之前,需要将其中包含的 DBN 隐含层结构和学习率设定为合适的值。为了验证 CQPSO 算法的优化性能,将广泛采用的 PSO、QGA 和 QPSO 算法作为对照组进行实验,该优化实验使用第 1 部分中的训练集数据进行,图 5 所示为实验中第 1 层 DBN₁ 和第 2 层 DBN₂ 的适应度函数的收敛过程。



(a) 第 1 层 DBN₁ 优化迭代
(a) Optimization iteration of DBN₁



(b) 第 2 层 DBN₂ 优化迭代
(b) Optimization iteration of DBN₂

图 5 适应度函数收敛过程

Fig. 5 Convergence process of fitness function

从图 5 可以看出,无论是第 1 层 DBN₁ 的图 5(a),还是第 2 层 DBN₂ 的图 5(b),CQPSO 算法在迭代结束时都达到了最小适应度函数值。同时,从图 5(b) 可以看出,CQPSO 算法一度陷入局部最优解,但经过 5 次迭代后,很快就解决了这个问题。表 3 和 4 分别阐明了优化过后两层 DBN 的参数。

5.2 故障诊断实验

合适的 CR 在故障诊断中起着重要的作用,因此采用不同的 CR 对第 1 部分的训练集数据进行压缩采样以测试故障诊断结果,不同 CR 的测试结果如图 6 所示。

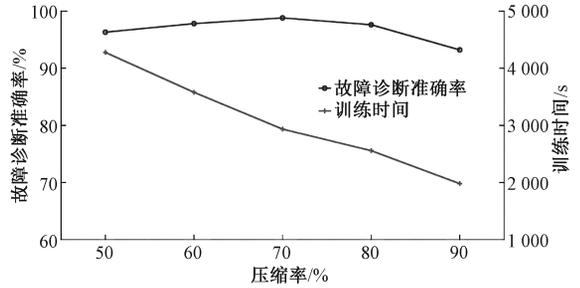


图 6 不同 CR 下的故障诊断准确率和训练时间

Fig. 6 Fault diagnosis accuracy and testing time under different CRs

从图 6 可以看出,训练时间随着压缩比的增加而减少,因为压缩比越大,压缩后的采样维数越小。当关注诊断准确率时,随着 CR 增加 80% 以上,诊断准确率明显下降。当 CR 为 70% 时,诊断准确率达到最大值,训练时间明显小于 60%。因此,本研究采用 70% 作为 CR。

表 3 第 1 层 DBN₁ 优化参数

Table 3 Optimized parameters of DBN₁

优化算法	隐含层结构	学习率	训练诊断准确率/%	测试诊断准确率/%	训练时间/s
PSO	500-800-240	0.20	93.7	74.8	3 249
QGA	850-691-683	0.29	96.6	83.2	3 722
QPSO	893-865-797	0.48	98.4	89.1	3 403
CQPSO	984-827-859	0.41	99.3	95.7	3 516

表 4 第 2 层 DBN₂ 优化参数

Table 4 Optimized parameters of DBN₂

优化算法	隐含层结构	学习率	训练诊断准确率/%	测试诊断准确率/%	训练时间/s
PSO	400-630-200	0.34	87.3	63.6	2 510
QGA	528-665-281	0.41	88.1	69.5	2 694
QPSO	613-746-373	0.55	91.6	74.7	2 572
CQPSO	788-849-500	0.48	98.7	92.9	2 638

为了验证本文所提出方法的故障诊断性能,构建了 3 种相似的逐层结构进行对照。这些结构由传统的反向

传播神经网络 (backpropagation neural network, BPNN)、支持向量机 (support vector machine, SVM) 和卷积神经网络 (convolutional neural network, CNN) 构成。

在第 1 部分实验中,针对每种故障类型和故障严重程度,随机选取 104 个样本中的 26 个样本作为训练数据。每个原始信号的维度为 3 600,压缩采样的维度为 1 080。在进行 20 次试验后,实验结果的平均值如表 5 所示。

表 5 第 1 部分故障诊断结果对比

Table 5 First part fault diagnosis results comparison

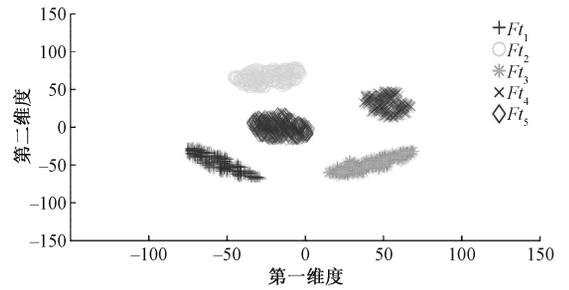
诊断方法	DBN ₁ 诊断	DBN ₂ 诊断	诊断误差率/%	测试时间/s
	准确率/%	准确率 I/II/%		
BPNN	72.93	68.64/77.02	8.38	5.051
SVM	79.30	80.26/85.57	5.31	4.339
CNN	93.55	94.17/97.92	3.75	2.214
本文方法	99.24	99.06/99.70	0.64	1.493

首先,由于基准数据中只有 F_{t_5} 区分了故障的严重性,因此只有对 F_{t_5} 的 F_s 进行诊断。表 5 中第 1 层 DBN₁ 诊断准确率是各方法在故障类型诊断时所取得的表现,而第 2 层 DBN₂ 诊断准确率 I/II 分别代表对 F_{t_5} 的严重程度以第 1 层 DBN 分类结果进行故障严重程度识别的结果,以及在故障类型 100% 诊断正确的条件下对故障严重程度进行识别的结果。同时,这二者之间的差值即为表中的诊断误差率。

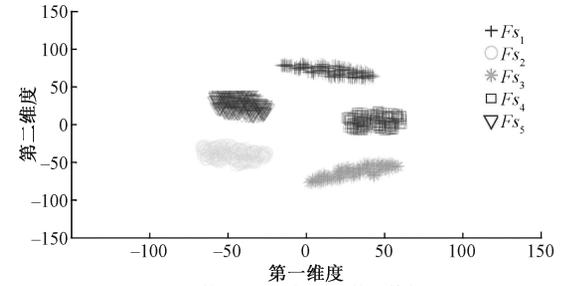
从表 5 可以看出,在故障诊断实验中,本文提出的方法在 4 种方法中取得了最好的表现。在对故障类型进行识别时,传统 CNN 方法与本文方法均取得了优秀的表现,其中 CNN 方法的诊断率为 93.55%,而本文方法的诊断率达到了 99.24%。而在对故障严重程度进行诊断时,诊断率 I 受到对故障类型误诊断的影响,本文方法仍然取得了 99.06% 的优异表现。同时,本文方法所取得的诊断率 II 高达 99.70%。本文方法在这 3 项故障诊断的准确率上,均取得了最优异的表现,同时还取得了仅为 0.64% 的最低诊断误差率。在测试时间方面,本文方法所需花费的时间也是最短的 1.493 s。

作为对总精度的补充,利用 t-SNE^[27] 分别生成由第 1 层 DBN₁ 和第 2 层 DBN₂ 提取的特征的二维图像。故障类型 F_t 和故障严重性 F_s 测试的可视化结果如图 7 所示。

如图 7(a) 所示, DBN₁ 很好地区分了 $F_{t_1}, F_{t_2}, \dots, F_{t_5}$ 等 5 种信号的特征。同类型信号的特征聚类效果较好。更重要的是,不同类型信号的特征分类非常明显。同样的效果如图 7(b) 所示,它以图形的方式演示了为什么 DBN₂ 可以很好地对故障严重性 $F_{s_1}, F_{s_2}, \dots, F_{s_5}$ 进行分类。



(a) 第 1 层 DBN₁ 提取出的 F_t 特征
(a) F_t feature extracted by DBN₁



(b) 第 2 层 DBN₂ 提取出的 F_s 特征
(b) F_s feature extracted by DBN₂

图 7 特征提取结果二维图像

Fig. 7 2D image of feature extraction results

表 6 第 1 部分故障类型测试诊断混淆矩阵

Table 6 First part fault type testing diagnosis confusion matrix

类型	诊断类型					
	F_{t_1}	F_{t_2}	F_{t_3}	F_{t_4}	F_{t_5}	
实际类型	F_{t_1}	78	0	0	0	0
	F_{t_2}	1	76	0	0	1
	F_{t_3}	0	0	76	1	1
	F_{t_4}	0	0	1	77	0
	F_{t_5}	0	1	5	2	382

表 7 第 1 部分故障严重程度测试诊断混淆矩阵

Table 7 First part fault severity testing diagnosis confusion matrix

类型	诊断类型					
	F_{s_1}	F_{s_2}	F_{s_3}	F_{s_4}	F_{s_5}	
实际类型	F_{s_1}	77	1	0	0	0
	F_{s_2}	0	77	1	0	0
	F_{s_3}	0	1	77	0	0
	F_{s_4}	0	0	2	76	0
	F_{s_5}	0	0	0	0	78

表 6 和 7 分别为第 1 部分故障诊断实验 20 次测试实验,其中 1 次故障类型和故障严重程度诊断结果的混淆矩阵。从表 6 可以看出,在 78 例故障数据中, F_{t_1} 类数据在本次实验中全部诊断正确, F_{t_4} 有 1 例诊断错误,而 F_{t_2} 和 F_{t_3} 则有 2 诊断错误,而在 390 例故障数据中 F_{t_5}

有 8 例诊断错误。从表 7 可以看出,在 78 例故障数据中, F_{s_5} 类数据在本次实验中全部诊断正确, F_{s_1} 、 F_{s_2} 和 F_{s_3} 都有 1 例诊断错误,而 F_{s_4} 则有 2 例诊断错误。

在第 2 部分实验中,针对每种故障类型,随机选取 50 个样本中的 13 个样本作为训练集。每个原始信号维度为 2 000,压缩采样后的维度为 600。在进行 20 次实验之后,实验结果的平均值如表 8 所示。

表 8 第 2 部分故障诊断结果对比

Table 8 Second part fault diagnosis results comparison

诊断方法	DBN ₁ 训练诊断	DBN ₁ 测试诊断	训练时 间/s	测试时 间/s
	准确率/%	准确率/%		
BPNN	80.59	67.39	4 682	6.237
SVM	87.17	81.77	3 724	4.849
CNN	97.88	91.46	5 651	2.851
本文方法	98.55	97.21	4 457	2.176

在第 2 部分实验中,采用该部分故障数据重新对 OSDS 进行训练后再进行故障类型的诊断实验。从表 8 可以看出,本文所提出的方法与 CNN 方法在训练时都取得了优异的故障诊断表现,而在采用测试集数据进行故障诊断测试时,本文方法仍然取得了 97.21% 的准确率,与 CNN 方法及其他传统方法相对比优势明显。同时,在测试时间上本方法所花费时间也是最短的 2.176 s。

表 9 第 2 部分测试诊断混淆矩阵

Table 9 Second part testing diagnosis confusion matrix

类型	诊断类型				
	F_{p_1}	F_{p_2}	F_{p_3}	F_{p_4}	
实际类型	F_{p_1}	37	0	0	0
	F_{p_2}	0	36	0	1
	F_{p_3}	1	0	35	1
	F_{p_4}	1	0	0	36

表 9 为第 2 部分故障诊断实验 20 次测试实验其中一次诊断结果的混淆矩阵,可以看出在 37 例测试样本中 F_{p_1} 类数据在本次实验中全部诊断正确, F_{p_2} 和 F_{p_4} 都有 1 例诊断错误,而 F_{p_3} 则有 2 例诊断错误。

综合以上两部分实验结果,本文方法不仅可以实现传统故障诊断方法无法实现的故障严重性识别,而且在由传统诊断方法构成的相似逐层诊断结构中,其总体诊断性能也是最好的。

6 结论

本文提出了一种新的逐层故障诊断结构,用以识别风机齿轮箱故障类型和严重程度。将 CS 理论应用于信号处理,然后将压缩后的样本输入到第 1 层 DBN₁ 中,用 CQPSO 算法进行优化,识别故障类型 F_t ;将每一类样本输入到第 2 层 DBN₂ 中,用 CPQSO 算法进行优化,识别故障严重程度 F_s 。CQPSO 算法保证了每个 DBN 的最佳特

征提取性能。

在实验中,本文提出的方法在 4 种相似方法中取得最好的表现,第 1 部分故障类型诊断准确率达到 99.24%,故障严重程度诊断准确率为 99.06%,误差为 0.64%,第 2 部分故障类型诊断准确率达到 97.21%。在故障类型 F_t 和严重程度 F_s 的识别中,本文方法以最短的测试时间获得了最佳的诊断性能。

参考文献

- [1] 李刚,齐莹,李银强,等. 风力发电机组故障诊断与状态预测的研究进展[J]. 电力系统自动化, 2015, 45(4):180-191.
LI G, QI Y, LI Y Q, et al. Research progress on fault diagnosis and state prediction of wind turbine [J]. Automation of Electric Power Systems, 2015, 45(4):180-191.
- [2] WANG T, HAN Q, CHU F, et al. Vibration based condition monitoring and fault diagnosis of wind turbine planetary gearbox: A review [J]. Mechanical Systems and Signal Processing, 2019, 126:662-685.
- [3] SALAMEH J P, CAUET S, ETIEN E, et al. Gearbox condition monitoring in wind turbines: A review [J]. Mechanical Systems and Signal Processing, 2018, 111:251-264.
- [4] 狄豪,孙文磊,武玉柱. EEMD 结合概率神经网络的风力机轴承故障诊断研究[J]. 机械设计与制造, 2020(6):105-108.
DI H, SUN W L, WU Y ZH. Reaearch on fault diagnosis for wind turbine based on EEMD and PNN [J]. Machinery Design & Manufacture, 2020(6):105-108.
- [5] LI H, ZHANG Q, QIN X R, et al. K-SVD-based WVD enhancement algorithm for planetary gearbox fault diagnosis under a CNN framework [J]. Measurement Science and Technology, 2020, 31(2):025003.
- [6] TENG W, DING X, ZHANG X, et al. Multi-fault detection and failure analysis of wind turbine gearbox using complex wavelet transform[J]. Renewable Energy, 2016, 93:591-598.
- [7] QIN Y, YI X, ZOU J Q. The optimized deep belief networks with improved logistic sigmoid units and their application in fault diagnosis for planetary gearboxes of wind turbines [J]. IEEE Transactions on Industrial Electronics, 2019, 66(5):3814-3824.
- [8] HUANG M L. Hybridization of chaotic quantum particle swarm optimization with SVR in electric demand forecasting[J]. Energies, 2016, 9(6):426.
- [9] DONOHO D L. Compressed sensing [J]. IEEE Transactions on Information Theory, 2006, 52(4):1289-

- 1306.
- [10] 赵光权,葛强强,刘小勇,等.基于 DBN 的故障特征提取及诊断方法研究[J]. 仪器仪表学报,2016,37(9):1946-1953.
ZHAO G Q, GE Q Q, LIU X Y, et al. Fault feature extraction and diagnosis method based on deep belief network [J]. Chinese Journal of Scientific Instrument, 2016,37(9):1946-1953.
- [11] XUE Z, DU P, SU H. Harmonic analysis for hyperspectral image classification integrated with PSO optimized SVM[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 7(6):2131-2146.
- [12] 张朝龙,何怡刚,邓芳明,等.一种基于 QPSO-RVM 的模拟电路故障预测方法[J]. 仪器仪表学报,2014, 35(8):1751-1757.
ZHANG CH L, HE Y G, DENG F M, et al. An approach for analog circuit fault prognostics based on QPSO-RVM [J]. Chinese Journal of Scientific Instrument, 2014,35(8):1751-1757.
- [13] 王波,刘树林,蒋超,等.基于量子遗传算法优化 RVM 的滚动轴承智能故障诊断[J]. 振动与冲击,2015, 34(17):207-212.
WANG B, LIU SH L, JIANG CH, et al. Rolling bearings' intelligent fault diagnosis based on RVM optimized with quantum genetic algorithm [J]. Journal of Vibration and Shock, 2015,34(17):207-212.
- [14] GONZALEZ E, LLOBET E, ROMERO A, et al. A new approach to NO₂ gas sensing based on pulsed UV light and FFT analysis using MOX sensors [J]. IEEE Sensors Journal, 2020, 20(1):397-404.
- [15] FENG L, XIAO E R. Wavelet-based diffusion approaches for signal denoising [J]. Signal Processing, 2007, 87(5):1138-1146.
- [16] RAFIEE J, ARVANI F, HARIFI A, et al. Intelligent condition monitoring of a gearbox using artificial neural network [J]. Mechanical Systems & Signal Processing, 2007, 21(4):1746-1754.
- [17] DU L, WANG B, LI Y, et al. Robust classification scheme for airplane targets with low resolution radar based on EMD-CLEAN feature extraction method [J]. IEEE Sensors Journal, 2013, 13(12):4648-4662.
- [18] MENG G, CONG W, ZHU C. Construction of hierarchical diagnosis network based on deep learning and its application in the fault pattern recognition of rolling element bearings [J]. Mechanical Systems & Signal Processing, 2016, 72-73:92-104.
- [19] WANG F, JIANG H K, SHAO H D, et al. An adaptive deep convolutional neural network for rolling bearing fault diagnosis [J]. Measurement Science and Technology, 2017, 28:095005.
- [20] SAUCEDO-DORANTES J J, DELGADO-PRIETO M, OSORNIO-RIOS R A, et al. Multifault diagnosis method applied to an electric machine based on high-dimensional feature reduction [J]. IEEE Transactions on Industry Applications, 2017, 53(3):3086-3097.
- [21] PASSERINI A, PONTIL M, RASCONI P F. New results on error correcting output codes of kernel machines [J]. IEEE Transactions on Neural Networks, 2004, 15(1):45-54.
- [22] 何怡刚,白月皎,鲁力.基于 DE-QPSO 算法的 MKRVM 对电容式 RF-MEMS 开关的寿命预测方法[J]. 电子测量与仪器学报,2020,34(12):66-75.
HE Y G, BAI Y J, LU L. MKRVM prediction of capacitive RF-MEMS switching life based on DE-QPSO algorithm [J]. Journal of Electronic Measurement and Instrumentation, 2020,34(12):66-75.
- [23] CHEN G, MAO Y, CHUI C K. A symmetric image encryption scheme based on 3D chaotic cat maps [J]. Chaos, Solitons & Fractals, 2004, 21(3):749-761.
- [24] CANDES E, ROMBERG J, TAO T. Robust uncertainty principles: Exact signal reconstruction from highly incomplete frequency information [J]. IEEE Transactions on Information Theory, 2006, 52(2):489-509.
- [25] BARANIUK R, DAVENPORT M, DEVORE R, et al. A simple proof of the restricted isometry property for random matrices [J]. Constructive Approximation, 2008, 28(3):253-263.
- [26] CAO P, ZHANG S, TANG J. Preprocessing-free gear fault diagnosis using small datasets with deep convolutional neural network-based transfer learning [J]. IEEE Access, 2018, 6:26241-26253.
- [27] 何怡刚,汪涛,施天成,等.基于 RFID 传感器标签与深度学习的变压器状态检测方法研究[J]. 电子测量与仪器学报,2018,32(9):72-79.
HE Y G, WANG T, SHI T CH, et al. Research on monitoring technology of transformer based on RFID sensor tag and deep learning [J]. Journal of Electronic Measurement and Instrumentation, 2018,32(9):72-79.

作者简介

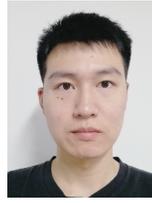


何怡刚(通信作者),1992 年于湖南大学获得硕士学位,1996 年于西安交通大学获得博士学位,现任合肥工业大学电气与自动化工程学院院长。主要研究方向包括电路理论及其应用、模拟与混合信号电路测试与故障诊断、电信号检测、智能电网、卫星通

信监测和智能信号处理。

E-mail:18655136887@163.com

He Yigang (Corresponding author) received his M. Sc. degree from Hunan University in 1992 and Ph. D. degree from Xi'an Jiaotong University in 1996. He currently works as the Head of School of Electrical Engineering and Automation, Hefei University of Technology. His main research interests include power electronic circuit theory and its applications, testing and fault diagnosis of analog and mixed-signal circuits, electrical signal detection, smart grid, satellite communication monitoring, and intelligent signal processing.



鲁力,2015 年于华北电力大学(北京)获得学士学位,现为合肥工业大学博士研究生,主要研究方向为电力设备状态监测、射频识别、信号处理。

E-mail:moon298@sina.com

Lu Li received the B. Sc. degree from North China Electric Power University(Beijing) in 2015. He is now a Ph. D. candidate at Hefei University of Technology. His main research interests include condition monitoring of electrical equipment, radio frequency and signal processing.