

http://bhxb.buaa.edu.cn jbuua@buaa.edu.cn

DOI: 10.13700/j.bh.1001-5965.2021.0581

基于 AE-BN 的发电机滚动轴承故障诊断

王进花^{1, 2, 3, *}, 高媛¹, 曹洁^{1, 4}, 马佳林⁵

- (1. 兰州理工大学 电气工程与信息工程学院, 兰州 730050; 2. 兰州理工大学 甘肃工业过程先进控制重点实验室, 兰州 730050;
3. 兰州理工大学 电气与控制工程国家实验教学中心, 兰州 730050; 4. 甘肃省制造信息工程研究中心, 兰州 730050;
5. 兰州理工大学 计算机与通信学院, 兰州 730050)

摘 要: 为解决风力发电机在复杂工况及耦合性、不确定性条件下故障识别的准确性问题, 提出了一种基于自动编码器 (AE) 与贝叶斯网络 (BN) 的 AE-BN 故障诊断方法。采用 AE 对电流信号进行特征提取, 得到能够高度表征信号的特征分量; 基于故障与特征之间的因果关系, 建立由故障位置、故障状态和故障特征搭建的三层 BN; 将 AE 的特征分量与 BN 的拓扑结构相结合建立风力发电机故障诊断模型, 解决故障诊断中的不确定性问题, 提高多故障诊断的准确性。实验结果表明: 所提方法能够对故障特征信号进行分析及诊断, 精确辨识不同故障类型, 相比 K 近邻算法等具有明显优势。

关键词: 故障诊断; 自动编码器; 贝叶斯网络; 结构学习; 特征提取

中图分类号: TP277

文献标志码: A

文章编号: 1001-5965(2023)08-1896-08

大型风电机组的结构与电磁系统等部件耦合紧密, 故障之间的映射关系复杂, 使得维修成本高且诊断难度大^[1]。由于数据提取方式及处理方法的不同, 风电机组的故障诊断可分为基于解析模型的方法和基于数据驱动的方法。基于解析模型的方法可利用信号分析技术对比特征间的差异来实现故障诊断。文献[2]选取不同的信号处理技术对设备进行可靠性分析与故障诊断, 如变分模态分解 (variational mode decomposition, VMD) 和小波变换 (wavelet transform, WT) 等方法。不同信号处理方法能够应对不同情况, 针对故障特征提取困难的问题, 文献[3]提出参数优化的 VMD 方法对轴承早期故障进行诊断, 通过分析信号包络谱来判断轴承的故障类型。文献[4]结合 WT 与自组织映射 (self-organizing feature map, SOM) 对轴承失效问题提出了一种故障预测方法, 使用 WT 提取特征, 采取 SOM 对轴承故障进行预测。数据驱动方法不依赖

监测对象的机理模型, 因此在大型工业过程的故障诊断领域具有普遍适用性。由于非平稳特征及故障样本难获取等问题, 可选择机器学习算法处理数据。文献[5]提出基于经验模态分解 (empirical mode decomposition, EMD) 与支持向量机 (support vector machine, SVM) 的齿轮故障诊断方法, 从 IMF 分量中提出能量特征并输入 SVM 中判断齿轮的工作状态和故障类型。文献[6]将 SVM 算法应用于非线性的田纳西-伊斯曼过程, 在非线性过程的故障分类中取得了良好效果。当数据量过大无法处理时, 使用深度学习 (deep learning, DL) 能够快速处理数据属性类别, 提取故障特征并提升分类的准确性。文献[7]提出一种深度学习框架加速神经网络的训练, 通过迁移学习实现高精度设备的故障诊断, 提高了齿轮箱故障测试的精度与诊断速度。机械设备的运行工况复杂多变, 文献[8]采用深度自编码器特征学习方法对旋转机械的振动信号进行特征

收稿日期: 2021-09-30; 录用日期: 2021-12-27; 网络出版时间: 2022-01-26 14:21

网络出版地址: kns.cnki.net/kcms/detail/11.2625.V.20220125.1916.002.html

基金项目: 国家自然科学基金 (62063020, 61763028); 甘肃省自然科学基金 (20JR5RA463)

*通信作者. E-mail: wjh0615@lut.edu.cn

引用格式: 王进花, 高媛, 曹洁, 等. 基于 AE-BN 的发电机滚动轴承故障诊断 [J]. 北京航空航天大学学报, 2023, 49 (8): 1896-1903.

WANG J H, GAO Y, CAO J, et al. Fault diagnosis of generator rolling bearing based on AE-BN [J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49 (8): 1896-1903 (in Chinese).

学习, 增强特征学习能力并应用于齿轮箱和滚动轴承中进行故障诊断。

对机械设备进行诊断分析时, 深度学习无法提供结果的可解释性且对故障溯源具有不确定性, 而属于机器学习算法的贝叶斯网络 (Bayesian network, BN) 可以解决。BN 适合于描述复杂工业过程中的因果关系^[9], 其表达能力、模型更新能力及解释性等特点使其更加适合处理故障诊断问题^[10]。针对不确定性的推理, 文献 [11] 提出基于变步长粒子群的 VMD 与 BN 结合的滚动轴承故障诊断模型, 实现对故障特征的提取和对不确定性信息的推理估计, 提高滚动轴承故障诊断的准确率。文献 [12] 针对多故障耦合问题提出基于 BN 模型的故障诊断方法, 利用有向无环图 (directed acyclic graph, DAG) 描述耦合关系并结合概率对故障进行推理, 有效解耦多故障之间的关联性从而得到更加精确的诊断结果。

基于以上分析, 依据 BN 在故障诊断领域的可描述性与处理不确定性问题的有效性, 本文将 BN 与特征提取方法结合来解决故障分类问题: ①选取自动编码器 (auto-encoder, AE) 完成特征提取, 并对特征数据进行离散化处理, 提高对多故障的特征表征能力; ②对故障特征数据使用爬山搜索 (hill-climbing, HC) 算法构建贝叶斯拓扑结构; ③根据搭建的 DAG 完成 BN 故障诊断模型, 实现故障类型的有效识别, 提高诊断速度与诊断精度。

1 自动编码器

在工程问题上, 对采集的原始信号直接进行故障诊断会出现数据杂乱、特征模糊等问题, 而大多学者均选取时频域等特征提取方法, 其提取不充分和计算速度慢等缺陷降低了故障诊断的效率。作为对称性结构的神经网络学习模型, AE 是一种尽可能复现输入信号的神经网络, 其结构包含输入层、隐藏层和输出层。若输出层能够很好地重建输入层, 则隐藏层可作为表达输入信号的特征^[13]。因此, 本文选择 AE 进行特征提取, 其结构如图 1 所示, 包括编码器 (encode) 与解码器 (decode) 2 个部分, 编码器将输入信号变换成编码信号, 解码器将编码变换为输出信号。

AE 的输入与输出维度相同, 即将输入向量组 $X = (x_1, x_2, \dots, x_n)$ 进行编码后得到隐藏层 $H = (h_1, h_2, \dots, h_n)$, 再进行反编码转换为 $Y = (y_1, y_2, \dots, y_n)$ 。X 与 Y 之间的差距越小, 证明 H 很好地重构了 X, 即有效描述了 X 的特征。

给定训练样本 $X = (x_1, x_2, \dots, x_n)$, 对样本使用




图 1 自动编码器结构

Fig. 1 Structure of AE

1×3 卷积核的分段聚合方式提取特征向量 $Z = (z_1, z_2, \dots, z_m)$, 提取特征向量的方式如下:

$$Z = \sigma(W * X + b) \tag{1}$$

式中: W 、 b 为网络中的权重; σ 为非线性激活函数; $*$ 为卷积。

从 Z 到 H 的映射通过全连接层表示, 如下:

$$H = \sigma(W * Z + b) \tag{2}$$

解码器是对编码的逆操作, 训练 AE 时的损失函数代表 X 与 Y 之间的距离, 如下:

$$L^{AE} = \sum_{i=1}^n \left(\frac{1}{2} \|y_i - x_i\|^2 \right) \tag{3}$$

训练好 AE 网络的编码器, 可用作信号非线性特征的提取。本文通过 AE 编码器提取电流信号的特征, 之后搭建 BN 模型对风电机组滚动轴承进行故障诊断。

2 贝叶斯网络

BN 由节点、有向连线和条件概率表 (conditional probability table, CPT) 组成, 表示为二元组 $BN = (G, \theta)$ 及 $G = (X, E)$, 其中, G 表示 DAG, DAG 由节点集合 X 与有向边 E 构成, 节点表示模型的随机变量, 有向边 E 表示节点间的因果关系, θ 表示网络中所有条件概率分布的参数集合^[14], 所有条件概率构成 CPT^[15]。

给定变量集合 $X = (X_1, X_2, \dots, X_n)$, 故障集合 $F = (F_1, F_2, F_3, F_4, F_5, F_6)$, 构造含 n 个节点的 BN, 其联合概率分布公式为

$$P(X) = P(X_1 X_2 \dots X_n) \prod_{i=1}^n P(X_i | P_{arc}(X_i)) \tag{4}$$

式中: $P_{arc}(X_i)$ 为所有变量 X_i 的父节点集合。根据条件独立性可知, 若已得父节点, 则该节点与其所有

非后代的节点 (non-descendants) 条件独立。

网络中故障 F 的条件概率计算公式为

$$P(X_1, X_2, \dots, X_n | F_k) = \prod_{i=1}^n P(X_i | F_k) \quad (5)$$

联合贝叶斯公式与式 (4)、式 (5) 可计算节点的后验概率, 如下:

$$P(F_k | X_1, X_2, \dots, X_n) = \frac{P(F_k) \prod_{i=1}^n P(X_i | F_k)}{P(X_1, X_2, \dots, X_n)} \quad (6)$$

式中: $P(X_1, X_2, \dots, X_n)$ 为 X 的先验概率; $P(F_k)$ 为 F_k 的先验概率; $\prod_{i=1}^n P(X_i | F_k)$ 为 F_k 的条件概率 (即后验概率), 通过计算最大后验概率值判断结果。

3 基于 AE-BN 的故障诊断模型

3.1 贝叶斯网络结构搭建

BN 进行故障诊断的流程主要包括结构学习、参数学习、推理分析和故障识别。以设备运行产生的数据为基础, 首先确定节点个数, 然后建立节点之间关系并得出网络结构, 最后根据结构计算概率并诊断故障。BN 结构通常分为 2 层, 本文添加运行状态作为第 3 层, 从而提高网络诊断性能。

发电机故障类型多样, 选取滚动轴承为研究对象, 考虑故障发生位置、故障类型及故障特征, 依据轴承损伤数据建立网络模型并确定因果关系。3 层网络结构包含 15 个节点, 第 1 层故障位置层确定故障发生位置, 表示为父节点合集 $C = (C_1, C_2, C_3)$, 第 2 层故障类型层确定故障类别, 由 6 种故障类型集合表示为中间节点合集 $F = (F_1, F_2, F_3, F_4, F_5, F_6)$, 第 3 层故障特征层确定由 AE 提取出隐藏表征作为故障特征, 表示为子节点合集 $S = (S_1, S_2, S_3, S_4, S_5, S_6)$ 。网络中任一节点所含信息均可经过有向边进行传播, 同时更新节点的概率。初步根据专家知识与网络结构建立故障诊断模型, 如图 2 所示。

S_6) 作为观测节点, 对节点数据信息作离散化处理, 以便后续对结构进行概率计算。

为获得结构中有向边的信息传输方向, 优化故障诊断模型的有效性, 对初步搭建的 BN 进行结构学习。结构学习旨在从数据中分析出节点间的依赖关系, 在可能的结构空间中搜索最优结构。BN 结构学习分为基于分数的方法、基于约束的方法及混合结构估计的方法^[16], 分别从 3 类中选取具有代表性的 3 种方法进行结构搭建, 得到与滚动轴承最拟合的网络结构。3 类结构搭建方法分别选取贝叶斯搜索方法^[17]、贪婪厚细化方法^[18]及爬山搜索算法^[19]。选取评分函数 BDeu、K2^[20]及 BIC 计算所得结构分数并进行对比, 对比结果如表 1 所示。

根据表 1 中评分结果可知, 3 种结构搭建方法中, 依据爬山搜索算法建立的结构所得评分最高, 因此选取爬山搜索算法对本文实验数据集搭建基于 BN 的故障诊断模型。

将滚动轴承故障数据输入图 2 所示的初始模型中, 并使用爬山搜索算法进行结构训练及优化。为提高模型在故障诊断时对故障数据推理分析的准确度, 对 DAG 中的有向边进行筛选, 得到与滚动轴承电流信号拟合度较高的 BN 结构, 如图 3 所示。

表 1 结构评分对比

Table 1 Comparison of structure scores

结构搭建方法	BDeu/10 ⁴	K2/10 ⁴	BIC/10 ⁴
贝叶斯搜索方法	-3.232 9	-3.241 7	-3.238 4
贪婪厚细化方法	-3.088 2	-3.099 3	-3.101 8
爬山搜索算法	-2.235 8	-2.275 4	-2.769 2




图 3 滚动轴承故障诊断的贝叶斯网络模型

Fig. 3 Bayesian network model for fault diagnosis of rolling bearings

3.2 AE-BN 故障诊断方法流程

为解决故障特征难提取和诊断精度不足的问题, 本文将 AE 与 BN 结合来搭建故障诊断模型。AE 能够完整表达故障特征, 可提高对原始数据的高效利用; BN 能够完成故障特征和原因之间的因果关系, 推理实现故障类别诊断。基于经验知识和数据驱动故障诊断流程如图 4 所示。




图 2 贝叶斯网络结构

Fig. 2 Structure of BN

为提高故障诊断模型的有效性, 依据滚动轴承故障的设备信息确定故障位置 (C_1, C_2, C_3)、故障类型 ($F_1, F_2, F_3, F_4, F_5, F_6$) 及故障特征 ($S_1, S_2, S_3, S_4, S_5,$

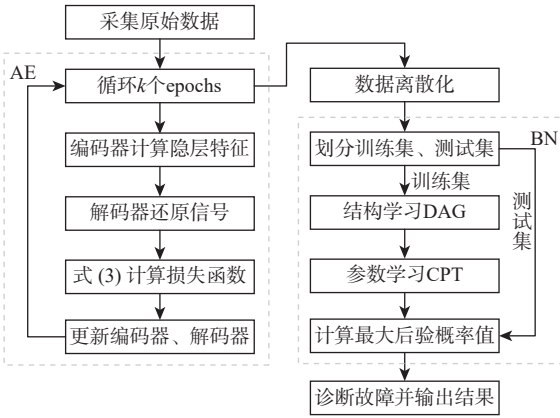


图 4 故障诊断方法流程

Fig. 4 Fault diagnosis algorithm flow chart

故障诊断流程主要包括以下步骤:

步骤 1 数据集准备。针对设备的原始故障数据及机械原理,对采集数据进行预处理,包括数据清洗、数据筛选及缺失数据处理,标记数据对应的故障类型。

步骤 2 特征提取。采用 AE 提取隐藏表征 $H = (h_1, h_2, \dots, h_6)$, 将其作为能反映故障类别的敏感特征集合 $(S_1, S_2, S_3, S_4, S_5, S_6)$ 输入到 BN 中进行诊断, 处理后的数据划分为训练集与测试集, 以便后续对模型进行测试验证。BN 普遍适用于分析离散数据, 因此对特征数据采取 K-Bins 算法完成离散化处理。

步骤 3 模型结构学习。综合专家知识与数据驱动的方法, 从训练集中学习 BN 结构, 由专家知识得到故障位置与故障类型之间的有向关系并以节点的形式作为结构的第 1 层, 根据爬山搜索算法^[21]学习到故障类型与故障特征之间的因果关系, 进而确定网络的 DAG, 完成 3 层 BN 结构搭建。

步骤 4 故障诊断模型的建立。BN 建立分为结构学习、参数学习和诊断分析。在学习结构后, 采用贝叶斯参数估计方法进行参数学习, 对节点进行概率推理并得出相应的 CPT。

步骤 5 模型验证。将步骤 2 划分好的测试集输入模型中进行测试验证, 针对特征数据计算最大后验概率值, 并得出对应的故障类别与精度。

4 实验验证

4.1 数据预处理

本文实验数据采用德国 Paderborn 大学机械工程学院轴承数据中心^[22]的公开数据集, 共包含 32 个实验轴承, 分为健康、人为损坏和实际损坏 3 种类型, 数据采样频率为 64 kHz。滚动轴承实验台如图 5 所示, 由测试电机、扭矩测量轴、滚动轴承模块、飞轮和负载电机组成。除电动机电流和振动信号外, 该平台还支持其他测量数据, 如速度、转

矩、温度和径向负载, 根据不同运行条件将数据集分为 4 种工况, 具体内容如表 2 所示。

选取人为损坏轴承数据, 采集 12 个滚动轴承的运行数据, 根据 3 种损坏方式及 2 种损毁程度将故障分为 5 种类型 (其中每种运行工况下的数据提取均在相同故障种类下进行处理), 3 种损坏方式为电放电加工 (electrical discharge machining, EDM)、钻孔 (drilling) 和手动电雕刻 (manual electric engraving)。选取 6 个健康轴承的健康数据作为参考, 并将其列为一种特殊的故障 (标签 3) 放入所有故障类型中进行对比, 具体故障类型及对应标签如表 3 所示。其中, IR(inner ring) 表示内圈位置且对应标签为 C_1 , 正常条件对应标签为 C_2 , OR(outer ring) 表示外圈位置且对应标签为 C_3 。




图 5 滚动轴承状况监测实验台

Fig. 5 Rolling bearing condition monitoring test bench

表 2 不同的运行条件

Table 2 Different operating conditions

运行工况	转速/(r·min ⁻¹)	径向力/N	负载转矩/(N·m)
K0	1 500	1 000	0.7
K1	1 500	1 000	0.1
K2	900	1 000	0.7
K3	1 500	400	0.7

表 3 故障类型与状态标签

Table 3 Fault types and status labels

故障位置	故障类型	轴承代码	标签
C_1	IR-EDM	KI01	1
C_1	IR-manual electric engraver	KI05	2
C_2	Normal	K002	3
C_3	OR-drilling	KA07	4
C_3	OR-EDM	KA01	5
C_3	OR-manual electric engraver	KA05	6

注: Normal 表示正常数据, 将其作为一种特殊的故障与其余 5 种故障一起进行故障分类的研究。

选取 K3 运行工况下的数据进行故障诊断模型搭建, 验证方法可行性后选取其他 3 种工况进行对比实验。将负载 K3 下的两相电流信号 (CS1 与 CS2) 作为原始数据处理, 连续选取 2 000 个采样点为一个样本, 经过特征提取及数据处理后所得最终数据集包含 12 274 组训练样本与 3 128 组测试样本, 在所得特征矩阵中最后一列添加标签列以区分

不同故障类别。图6提供了滚动轴承6种故障的电流信号采集,6种故障分别为:正常状态(Normal)、内圈放电加工故障(IR-EDM)、内圈电雕刻故障(IR-manual electric engraver)、外圈钻孔故障(OR-drilling)、外圈放电加工故障(OR-EDM)、外圈电雕刻故障(OR-manual electric engraver)。可从中看出,不同电流信号在时域分析图中的差异十分细微,导致电流信号较难进行故障诊断,根据德国Paderborn大学机械工程学院轴承数据中心实验^[22]可知,相同条件下采集的数据中电流信号诊断精度明显低于振动信号。本文提出的AE-BN故障诊断模型能够对差异较小的电流信号进行深层次的提取特征,提高对电流信号的诊断效果。

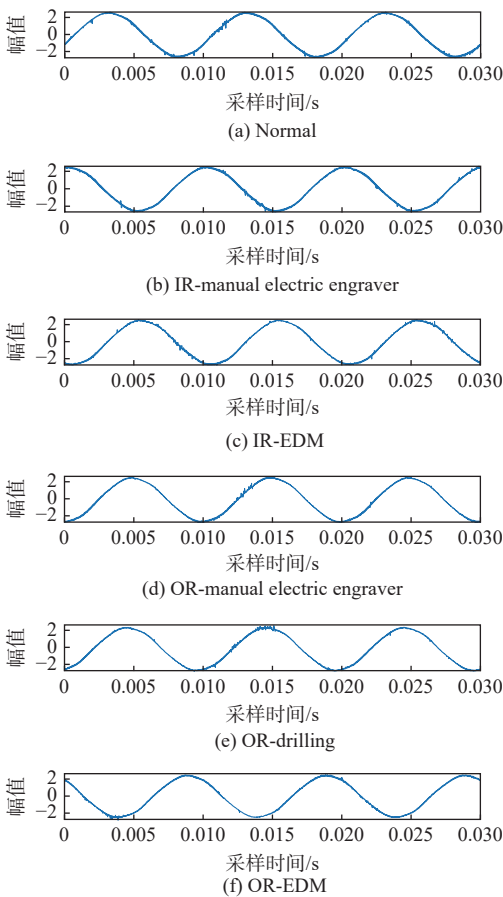


图6 6种故障电流信号时域波形

Fig. 6 Time domain waveform of six types of fault current signals

选取流行学习方法可视化故障样本数据,分析AE特征提取能力。选取部分测试集的故障特征样本通过t-分布随机近邻嵌入(t-distributed stochastic neighbor embedding, t-SNE)方法^[23]进行降维,可视化前3个分量绘制散点图,如图7所示。可知,经提取后的数据均形成聚集,易于区分不同类别的特征样本,表明特征提取能力较好,各类别均完成分类且未出现混叠现象。

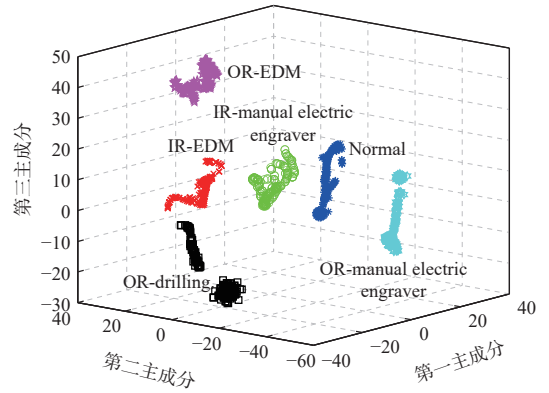


图7 特征提取散点图

Fig. 7 Feature extraction scatter plot

4.2 实验结果分析

针对已搭建的AE-BN故障诊断模型,随机选取1200组故障特征样本来分析不同特征对故障类别的影响。选取Pandas中的RadViz绘制雷达图,如图8所示。雷达图是一种可视化多变量数据的方法,以表征故障的特征变量 $F_1, F_2, F_3, F_4, F_5, F_6$ 在平面设置单位圆,根据图8中样本分布可知,变量 F_2 与 F_3 对故障类型判别的影响较大。




图8 RadViz雷达图

Fig. 8 RadViz radar map

经训练得到模型拓扑结构后,使用节点条件概率参数表示节点之间的依赖关系,即BN的参数学习。因为数据集完备且节点离散,所以采用贝叶斯参数估计方法推理分析节点并得出相应的CPT。根据图3所得BN结构进行推理,以滚动轴承的3种故障发生位置作为父节点、不同损伤故障类型作为中间节点、反映故障征兆的特征作为子节点,将训练集导入模型中计算条件概率并更新模型,选取中间层节点描述CPT,如表4所示。

得到故障类型层各节点的条件概率后,使用测试集验证分析。在计算精度时,分别选取VMD与AE方法对比,将K近邻(KNN)算法与所提模型对比精度,详细准确率对比如表5所示。

本文选取德国Paderborn大学机械工程学院轴承数据中心滚动轴承数据集的4种负载条件,并根据不同负载数据完成AE-BN方法的消融实验,确保了本文方法的优越性。由表5所得结果可知,在

相同故障诊断 KNN 算法下, 采取 AE 提取特征所得样本在进行诊断时精度远高于 VMD 算法, 在相同特征提取方法 AE 条件下, 使用 BN 分析故障类别的精度高于 KNN 算法。

本文提出的 AE-BN 故障诊断模型在对滚动轴承多种故障进行诊断时具有较高准确率, 为展现不同故障类别精度及分类错误的占比, 将测试集输入混淆矩阵中展示具体情况, 如图 9 所示。混淆矩阵的横轴表示轴承故障预测种类, 纵轴表示真实故障种类, 对角线数值表示模型对每类故障的诊断精

度, 非对角线数值表示模型对每类故障的诊断错误率。

由图 9 可知, 在对故障标签为“1”、“4”和“6”进行诊断时精确度可达 100%, 其余类别故障诊断精度为 99.8%, 滚动轴承故障诊断整体的正确识别精度达到 99.9%, 表明 AE-BN 故障诊断模型在针对轴承电流信号诊断时具有良好的分类效果。

5 结 论

1) 本文结合 AE 与 BN 对发电机轴承进行故障诊断分析, 能够有效提取轴承故障特征, 分析电流信号并使用 AE 提取特征, 完成对多故障的高效表征。

2) 使用 BN 实现故障类别的推理。根据故障位置、故障状态和故障特征组成的 3 层 BN 结构来确定拓扑结构及节点, 完成 BN 建模。

3) 经德国 Paderborn 大学机械工程学院轴承数据中心数据集验证可知, 模型能够有效辨识轴承的故障类别, 减少冗余数据的影响, 提升了故障识别的准确率。

BN 建模较于其他智能算法难度较大, 在需要大量数据支撑的同时还需要考虑节点参数概率随着结构改变而修正等复杂因素, 目前 BN 在故障诊断领域的应用并不广泛, 对其模型算法和计算还有待投入更多的研究。

参考文献 (References)

[1] 曾军, 陈艳峰, 杨苹, 等. 大型风力发电机组故障诊断综述[J]. 电网技术, 2018, 42(3): 849-860.
ZENG J, CHEN Y F, YANG P, et al. Review of fault diagnosis methods of large-scale wind turbines[J]. Power System Technology, 2018, 42(3): 849-860(in Chinese).

[2] 陈是扞, 彭志科, 周鹏. 信号分解及其在机械故障诊断中的应用研究综述[J]. 机械工程学报, 2020, 56(17): 91-107.
CHEN S Q, PENG Z K, ZHOU P. Review of signal decomposition theory and its applications in machine fault diagnosis[J]. Journal of Mechanical Engineering, 2020, 56(17): 91-107(in Chinese).

[3] 唐贵基, 王晓龙. 参数优化变分模态分解方法在滚动轴承早期故障诊断中的应用[J]. 西安交通大学学报, 2015, 49(5): 73-81.
TANG G J, WANG X L. Parameter optimized variational mode decomposition method with application to incipient fault diagnosis of rolling bearing[J]. Journal of Xi'an Jiaotong University, 2015, 49(5): 73-81(in Chinese).

[4] ZHONG J, YANG K. Failure prediction for linear ball bearings based on wavelet transformation and self-organizing map[C]//2018 IEEE 4th Information Technology and Mechatronics Engineering Conference (ITOEC). Piscataway: IEEE Press, 2018: 34-38.

[5] 张超, 陈建军, 郭迅. 基于EMD能量熵和支持向量机的齿轮故障诊断方法[J]. 振动与冲击, 2010, 29(10): 216-220.
ZHANG C, CHEN J J, GUO X. A gear fault diagnosis method

表 4 贝叶斯网络子节点条件概率

Table 4 Conditional probability of subnodes of Bayesian network

节点	节点取值	父节点取值	条件概率
F ₁	0	0	0.480 7
F ₂	0	0,1	0.511 1
F ₂	0	1,0	0.496 2
F ₂	0	1,1	0.512 8
F ₃	0	0,0	0.306 8
F ₃	0	0,1	0.603 1
F ₃	0	1,0	0.520 4
F ₃	0	1,1	0.375 3
F ₄	0		0.305 0
F ₅	0		0.403 3
F ₆	0	0,1	0.492 9
F ₆	0	1,0	0.487 2

表 5 4 种工况下不同故障诊断模型的分类精度对比

Table 5 Comparison of classification accuracy of different fault diagnosis models under four types of working conditions

运行工况	VMD-KNN	AE-KNN	AE-BN
K0	0.712 4	0.873 3	0.998 3
K1	0.632 4	0.891 4	0.977 2
K2	0.723 1	0.893 2	0.995 5
K3	0.737 7	0.871 5	0.998 1

实际种类	1	2	3	4	5	6	精度
1	520 16.6%	1 0%	0 0%	0 0%	0 0%	0 0%	99.8% 0.2%
2	0 0%	519 16.6%	0 0%	0 0%	0 0%	0 0%	100% 0%
3	0 0%	0 0%	521 16.7%	0 0%	1 0%	0 0%	99.8% 0.2%
4	0 0%	0 0%	0 0%	522 16.7%	0 0%	0 0%	100% 0%
5	0 0%	0 0%	1 0%	0 0%	521 16.7%	0 0%	99.8% 0.2%
6	0 0%	0 0%	0 0%	0 0%	0 0%	522 16.7%	100% 0%
	100% 0%	99.8% 0.2%	99.8% 0.2%	100% 0%	99.8% 0.2%	100% 0%	99.9% 0.1%
	1	2	3	4	5	6	

图 9 轴承故障分类混淆矩阵

Fig. 9 Confusion matrix of bearing fault classification

- based on EMD energy entropy and SVM[J]. *Journal of Vibration and Shock*, 2010, 29(10): 216-220(in Chinese).
- [6] CHIANG L H, KOTANCHEK M E, KORDON A K, et al. Fault diagnosis based on Fisher discriminant analysis and support vector machines[J]. *Computers & Chemical Engineering*, 2004, 28(8): 1389-1401.
- [7] SHAO S, MCALEER S, YAN R, et al. Highly accurate machine fault diagnosis using deep transfer learning[J]. *IEEE Transactions on Industrial Informatics*, 2019, 15(4): 2446-2455.
- [8] SHAO H, JIANG H, ZHAO H, et al. A novel deep autoencoder feature learning method for rotating machinery fault diagnosis[J]. *Mechanical Systems and Signal Processing*, 2017, 95: 187-204.
- [9] 陈东超. 基于贝叶斯网络的汽轮发电机组故障诊断方法及应用研究[D]. 北京: 华北电力大学(北京), 2018.
- CHEN D C. Research on methods and application of fault diagnosis for turbo-generator unit based on bayesian network[D]. Beijing: North China Electric Power University (Beijing), 2018(in Chinese).
- [10] 王双成, 张立, 郑飞. 异步动态贝叶斯网络分类器研究[J]. *计算机学报*, 2020, 43(9): 1737-1754.
- WANG S C, ZHANG L, ZHENG F. Asynchronous dynamic Bayesian network classifiers[J]. *Chinese Journal of Computers*, 2020, 43(9): 1737-1754(in Chinese).
- [11] 全兆景, 芦彤, 秦紫霓. 基于PSO-VMD与贝叶斯网络的滚动轴承故障诊断[J]. *河南理工大学学报(自然科学版)*, 2021, 40(1): 95-104.
- TONG Z J, LU T, QIN Z N. Fault diagnosis of rolling bearing based on PSO-VMD and Bayesian network[J]. *Journal of Henan Polytechnic University (Natural Science)*, 2021, 40(1): 95-104(in Chinese).
- [12] 王金鑫, 王忠巍, 马修真, 等. 基于贝叶斯网络的柴油机润滑系统多故障诊断[J]. *控制与决策*, 2019, 34(6): 1187-1194.
- WANG J X, WANG Z W, MA X Z, et al. Diagnosis of multiple faults of diesel engine lubrication system based on Bayesian networks[J]. *Control and Decision*, 2019, 34(6): 1187-1194(in Chinese).
- [13] 尹爱军, 王昱, 戴宗贤, 等. 基于变分自编码器的轴承健康状态评估[J]. *振动、测试与诊断*, 2020, 40(5): 1011-1016.
- YIN A J, WANG Y, DAI Z X, et al. Evaluation method of bearing health state based on variational auto-encoder[J]. *Journal of Vibration, Measurement & Diagnosis*, 2020, 40(5): 1011-1016(in Chinese).
- [14] 孙叶, 王钢, 魏东. 贝叶斯网络在智能电网研究中的应用[J]. *自动化应用*, 2020(7): 108-109.
- SUN Y, WANG G, WEI D. The application of Bayesian network in the research of smart grid[J]. *Automation Application*, 2020(7): 108-109(in Chinese).
- [15] CAI B, HUANG L, XIE M. Bayesian networks in fault diagnosis[J]. *IEEE Transactions on Industrial Informatics*, 2017, 13(5): 2227-2240.
- [16] 李硕豪, 张军. 贝叶斯网络结构学习综述[J]. *计算机应用研究*, 2015, 32(3): 641-646.
- LI S H, ZHANG J. Review of Bayesian networks structure learning [J]. *Application Research of Computers*, 2015, 32(3): 641-646(in Chinese).
- [17] WEN Z, KVETON B, ERIKSSON B, et al. Sequential Bayesian search[C]//*Proceedings of the 30th International Conference on Machine Learning*. New York: ACM, 2013: 226-234.
- [18] CHENG J, BELL D A, LIU W. An algorithm for Bayesian belief network construction from data[C]//*Proceedings of the 6th International Workshop on Artificial Intelligence and Statistics*. Amsterdam: Elsevier, 1997: 83-90.
- [19] CONSTANTINO A C, LIU Y, CHOBTHAM K, et al. Large-scale empirical validation of Bayesian network structure learning algorithms with noisy data[J]. *International Journal of Approximate Reasoning*, 2021, 131: 151-188.
- [20] BEHJATI S, BEIGY H. Improved K2 algorithm for Bayesian network structure learning[J]. *Engineering Applications of Artificial Intelligence*, 2020, 91: 103617.
- [21] 刘浩然, 王念太, 王毅, 等. 基于V-结构&对数似然函数定向与禁忌爬山的贝叶斯网络结构算法[J]. *电子与信息学报*, 2021, 43(11): 3272-3281.
- LIU H R, WANG N T, WANG Y, et al. Bayesian network structure algorithm based on V-structure & Log-likelihood orientation and tabu hill climbing[J]. *Journal of Electronics & Information Technology*, 2021, 43(11): 3272-3281(in Chinese).
- [22] LESSMEIER C, KIMOTH O J K, ZIMMER D, et al. Condition monitoring of bearing damage in electromechanical drive systems by using motor current signals of electric motors: A benchmark data set for data-driven classification[C]//*European Conference of the Prognostics and Health Management Society*, 2016: 1-17.
- [23] VAN DER MAATEN L, HINTON G. Visualizing data using t-SNE[J]. *Journal of Machine Learning Research*, 2008, 9: 2579-2605.

Fault diagnosis of generator rolling bearing based on AE-BN

WANG Jinhua^{1, 2, 3, *}, GAO Yuan¹, CAO Jie^{1, 4}, MA Jialin⁵

(1. College of Electrical & Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China;

2. Key Laboratory of Gansu Advanced Control for Industrial Processes, Lanzhou University of Technology, Lanzhou 730050, China;

3. National Experimental Teaching Center of Electrical and Control Engineering, Lanzhou University of Technology, Lanzhou 730050, China;

4. Engineering Research Center of Manufacturing Information of Gansu Province, Lanzhou 730050, China;

5. College of Computer and Communication, Lanzhou University of Technology, Lanzhou 730050, China)

Abstract: To solve the accuracy of fault identification of wind turbines under complex working conditions, coupling, and uncertainty, an AE-BN fault diagnosis method based on a auto-encoder (AE) and Bayesian network (BN) is proposed. AE is used to extract the characteristics of the current signal, and the characteristic component that can highly characterize the signal is obtained; based on the causal relationship between fault and feature, a three-layer BN composed of fault location, fault state, and fault feature is established; The wind turbine fault diagnostic model is then established, the uncertainty problem in fault diagnosis is solved, and the precision of multi fault diagnosis is enhanced by combining the characteristic component of AE with the topology of BN. Experimental results show that the proposed method can analyze and diagnose fault characteristic signals and accurately identify different fault types, which has obvious advantages over other algorithms.

Keywords: fault diagnosis; auto-encoder; Bayesian network; structure learning; feature extraction

Received: 2021-09-30; **Accepted:** 2021-12-27; **Published Online:** 2022-01-26 14:21

URL: kns.cnki.net/kcms/detail/11.2625.V.20220125.1916.002.html

Foundation items: National Natural Science Foundation of China (62063020,61763028); Natural Science Foundation of Gansu Province, China (20JR5RA463)

* **Corresponding author.** E-mail: wjh0615@lut.edu.cn