

文章编号:1671-251X(2020)04-0081-05

DOI:10.13272/j.issn.1671-251x.2019120001

一种带式输送机故障诊断方法

张喆^{1,2}, 陶云春^{1,2}, 梁睿^{1,2}, 迟鹏^{1,2}

(1. 中国矿业大学 电气与动力工程学院, 江苏 徐州 221116;
2. 中国矿业大学 江苏省煤矿电气与自动化工程实验室, 江苏 徐州 221116)



扫码移动阅读

摘要:针对传统浅层神经网络用于带式输送机故障诊断时存在故障状态样本数据不足、准确率不高等问题,提出了一种基于合成少数类过采样技术(SMOTE)和深度置信网络(DBN)的带式输送机故障诊断方法。该方法利用SMOTE生成带式输送机故障状态样本数据,克服样本数据分布不平衡现象;将样本数据输入DBN,利用无监督逐层训练方式提取数据中的故障特征,并通过有监督微调来优化故障诊断能力,实现带式输送机故障精确诊断。仿真结果表明,该方法提高了带式输送机故障诊断准确率。

关键词:带式输送机; 故障诊断; 合成少数类过采样技术; 深度置信网络

中图分类号:TD634.1 文献标志码:A

A fault diagnosis method of belt conveyor

ZHANG Zhe^{1,2}, TAO Yunchun^{1,2}, LIANG Rui^{1,2}, CHI Peng^{1,2}

(1. School of Electrical and Power Engineering, China University of Mining and Technology, Xuzhou 221116, China; 2. Jiangsu Province Laboratory of Mining Electric and Automation, China University of Mining and Technology, Xuzhou 221116, China)

Abstract: Aiming at problems of insufficient fault state sample data and low accuracy in fault diagnosis of belt conveyor by traditional shallow neural network, a fault diagnosis method of belt conveyor based on synthetic minority oversampling technique (SMOTE) and deep belief network (DBN) was proposed. Fault state sample data of belt conveyor is generated by SMOTE to overcome imbalance distribution of the sample data. The sample data is input into DBN, fault features in the data are extracted by means of unsupervised layer-by-layer training, and fault diagnosis ability is optimized by means of supervised fine-tuning to achieve accurate fault diagnosis of belt conveyor. The simulation results show that the method improves fault diagnosis accuracy of belt conveyor.

Key words: belt conveyor; fault diagnosis; synthetic minority oversampling technique; deep belief network

0 引言

带式输送机作为煤矿井下运输煤炭的核心设备,一旦发生故障会严重影响煤矿安全生产和工作效率,造成巨大经济损失。因此,对煤矿带式输送机进行故障诊断尤为重要^[1-2]。目前,广义回归神经网络(General Regression Neural Network, GRNN)、概率神经网络(Probabilistic Neural Network,

PNN)、极限学习机(Extreme Learning Machine, ELM)等传统浅层神经网络在故障诊断中取得了一定成果^[3-5],但它们均属于浅层学习的算法结构,要在一到两层的模型结构中完成函数拟合,没有充分挖掘数据内部隐含的特征,泛化能力不强,易出现局部极值,故障诊断准确率不高,且诊断精度依赖于样本数据的分布,由于煤矿现场实际采集的故障样本数据较少,当样本数据分布不平衡时,会导致过拟合

收稿日期:2019-12-02;修回日期:2020-04-16;责任编辑:盛男。

基金项目:国家重点研发计划资助项目(2017YFC0804400)。

作者简介:张喆(1995—),男,安徽濉溪人,硕士研究生,主要研究方向为电气设备状态感知与诊断,E-mail:969103110@qq.com。

引用格式:张喆,陶云春,梁睿,等.一种带式输送机故障诊断方法[J].工矿自动化,2020,46(4):81-84.

ZHANG Zhe, TAO Yunchun, LIANG Rui, et al. A fault diagnosis method of belt conveyor[J]. Industry and Mine Automation, 2020, 46(4): 81-84.

问题。鉴此,本文提出了一种基于合成少数类过采样技术(Synthetic Minority Oversampling Technique,SMOTE)和深度置信网络(Deep Belief Network,DBN)的带式输送机故障诊断方法。该方法利用 SMOTE 对采集的带式输送机状态数据进行预处理,通过 DBN 提取数据中隐含的故障特征,可有效提高带式输送机故障诊断准确率。

1 相关原理

1.1 SMOTE

SMOTE 基本思想是对少数类样本进行分析,在原始少数类样本的邻域空间中生成大量具有一定策略的新样本,以平衡样本数据分布^[6-7]。

SMOTE 生成新样本过程如图 1 所示。首先,在少数类样本中选择一个主样本 x_i ($i=1,2,\dots,N$, N 为少数类样本个数),然后在 x_i 的 k 近邻中随机选择 M 个样本 x_j ($j=1,2,\dots,M, j \neq i$),最后在连接主样本 x_i 及其主要近邻样本 x_j 的直线的随机位置生成一个新样本^[8]:

$$x_{\text{new}}(i,j) = x_i + \text{rand}(0,1)(x_j - x_i) \quad (1)$$

式中 $\text{rand}(0,1)$ 表示 0~1 之间的随机数。

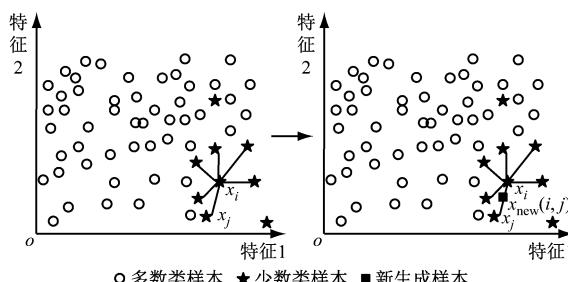


图 1 SMOTE 生成新样本过程

Fig. 1 Process of generating new sample by SMOTE

1.2 DBN

DBN 由多个堆叠的受限玻尔兹曼机(Restricted Boltzmann Machine,RBM)和在最后一个 RBM 上增加的输出层组成^[9-10]。以具有 3 层隐藏层结构的 DBN(图 2)为例,网络由 3 个 RBM 堆叠而成,每个 RBM 有两层,上层为隐藏层,下层为可见层。DBN 训练过程包括预训练和微调 2 个阶段。在预训练阶段,采用逐层贪婪方法训练 RBM,当前 RBM 训练完成,将其隐藏层作为下一个 RBM 的可见层,以此类推,直到最后一个 RBM 训练完成。每个 RBM 通过最大化其输入数据的概率来训练,利用对比散度(Contrastive Divergence,CD)算法更新参数。在预训练之后,将输出层添加到最后一个隐藏层,采用 BP 算法将误差从最后一层逐层传递到输入层,对 DBN 参数进行微调^[11-13],从而使 DBN 参数达到最优。

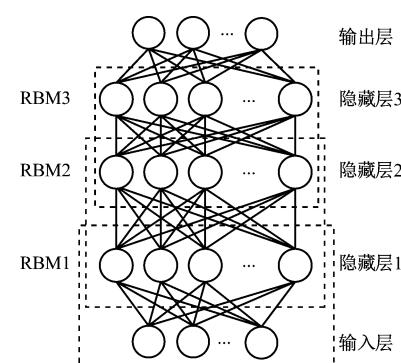


图 2 DBN 结构

Fig. 2 DBN structure

2 基于 SMOTE 和 DBN 的带式输送机故障诊断

基于 SMOTE 和 DBN 的带式输送机故障诊断流程如图 3 所示,主要步骤如下。

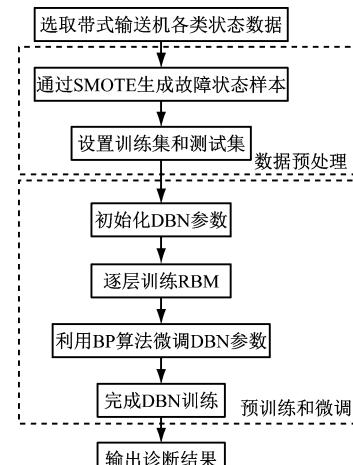


图 3 基于 SMOTE 和 DBN 的带式输送机故障诊断流程

Fig. 3 Fault diagnosis flow of belt conveyor based on SMOTE and DBN

(1) 获取带式输送机不同运行工况状态数据,通过 SMOTE 生成故障状态样本,平衡样本数据分布。

(2) 确定训练集和测试集。

(3) 初始化 DBN 相关参数,包括损失函数、RBM 学习率、RBM 迭代次数、网络层数、各层节点数、动量参数等,其中输入层节点数由带式输送机故障特征数量确定,输出层节点数由带式输送机状态数量确定。

(4) 将训练样本作为 DBN 输入,以无监督方式逐层训练 RBM,即将前一个 RBM 的隐藏层作为下一个 RBM 的可见层,直到完成所有 RBM 的训练。

(5) 通过有监督方式的 BP 算法反向微调 DBN 参数。

(6) 利用训练好的 DBN 进行带式输送机故障诊断。

3 仿真验证

3.1 数据来源

仿真使用的数据全部来自山西某煤矿现场实际采集的数据。本文选择六类典型的带式输送机故障状态(打滑、撕裂、跑偏、过载、火灾事故、电动机故障)和带式输送机正常状态进行仿真研究。选取某一段时间内该煤矿带式输送机在线监测系统采集的状态特征量,见表1。当带式输送机发生打滑故障时,电动机功率减小,改向滚筒温度明显升高,输送

带张力减小;当带式输送机发生撕裂故障时,输送带张力增大,输送带速度减小,输送带偏移量增大;当带式输送机发生跑偏故障时,输送带偏移量增大,输送带速度略有增大,输送带张力和电动机功率增大;当带式输送机发生过载故障时,输送带速度明显减小,电动机功率明显增大,输送带张力增大,改向滚筒温度升高;当带式输送机发生火灾事故时,烟雾浓度明显增大;当带式输送机发生电动机故障时,电动机功率和输送带速度减小,电动机和改向滚筒温度均降低。

表1 不同带式输送机工况下状态特征量

Table 1 State characteristics quantity under different belt conveyor working conditions

| 特征量 | 正常 | 打滑 | 撕裂 | 跑偏 | 过载 | 火灾事故 | 电动机故障 |
|----------------------------|--------|--------|--------|--------|--------|--------|-------|
| 电动机功率/kW | 316.53 | 281.46 | 318.50 | 334.44 | 458.44 | 324.68 | 0 |
| 电动机温度/℃ | 34.9 | 34.3 | 33.3 | 33.6 | 55.1 | 34.3 | 20.3 |
| 输送带速度/(m·s ⁻²) | 4.3 | 4.3 | 3.1 | 4.4 | 2.8 | 4.2 | 0 |
| 改向滚筒温度/℃ | 55.97 | 94.38 | 57.35 | 58.70 | 75.05 | 56.26 | 41.97 |
| 输送带偏移量/cm | 0 | 0 | 52 | 23 | 0 | 0 | 0 |
| 烟雾浓度/(mg·m ⁻³) | 0.14 | 0.13 | 0.13 | 0.14 | 0.14 | 0.51 | 0.13 |
| 输送带张力/kN | 20.4 | 18.1 | 22.5 | 22.9 | 22.3 | 20.0 | 20.3 |

将采集的410个原始样本数据经过SMOTE预处理,共获得650个样本数据,其分布见表2。选取正常状态样本中280个样本和各类故障状态样本中40个样本构成训练集,剩余样本构成测试集。

表2 带式输送机样本数据分布

Table 2 Sample data distribution of belt conveyor

| 带式输送机工况类型 | 原始样本数/个 | 预处理后样本数/个 | 训练样本数/个 | 测试样本数/个 |
|-----------|---------|-----------|---------|---------|
| 正常 | 350 | 350 | 280 | 70 |
| 打滑 | 12 | 50 | 40 | 10 |
| 撕裂 | 11 | 50 | 40 | 10 |
| 跑偏 | 7 | 50 | 40 | 10 |
| 过载 | 7 | 50 | 40 | 10 |
| 火灾事故 | 9 | 50 | 40 | 10 |
| 电动机故障 | 14 | 50 | 40 | 10 |

3.2 参数设置

在Intel Core i7-9750H处理器、16 GB内存、64位操作系统的个人计算机上,使用Python进行仿真。

DBN输入层神经元个数为7,隐藏层神经元个数为200,输出层神经元个数为7,损失函数为均方误差函数,动量参数为0.8,RBM最大迭代次数为65,学习率为0.001,隐藏层激活函数为Sigmoid函数,输出层激活函数为Softmax函数。DBN迭代次数和隐藏层数通过实验调试来确定。

3.3 结果分析

隐藏层数设置为3时,均方误差和故障诊断准确率随迭代次数变化曲线如图4所示。可看出均方误差随着迭代次数的增加逐渐降低,训练集和测试集准确率均随着迭代次数的增加逐渐提高,因此要得到较高的故障诊断准确率,需要增大迭代次数,但会延长迭代时间;当迭代次数达到500后,均方误差和训练集、测试集准确率波动幅度较小,趋于平稳。为了缩短网络训练时间,本文选取DBN迭代次数为500。

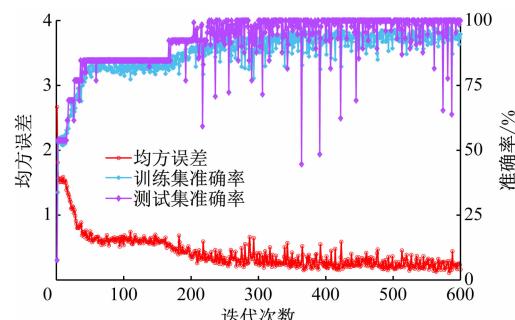


图4 均方误差和故障诊断准确率随迭代次数变化曲线

Fig. 4 Curves of mean square error and fault diagnosis

accuracy vary with iterations

分别构建含有1,2,3,4,5层隐藏层的DBN,迭代次数设置为500,采用相同的训练集和测试集进行仿真,故障诊断准确率随隐藏层数变化曲线如图5所示。可看出隐藏层数为3时,故障诊断准确率最高;当隐藏层数继续增加,故障诊断准确率反而

下降。因此本文选取隐藏层数为 3, 即 DBN 采用 5 层结构, 由 3 个 RBM 组成。

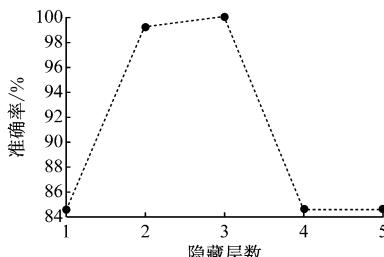


图 5 故障诊断准确率随隐藏层数变化曲线

Fig. 5 Curve of fault diagnosis accuracy varies with hidden layers

为验证 DBN 在带式输送机故障诊断方面的优势, 与 GRNN, ELM, PNN 进行对比。GRNN 和 PNN 的 SPREAD 参数均设置为 0.4, ELM 的激活函数为 Sigmoid 函数。4 种神经网络均采用相同的训练集和测试集, 对训练集和测试集进行随机排序, 4 种网络在训练集和测试集上的诊断结果见表 3。

表 3 准确率对比

Table 3 Accuracy comparison %

| 神经网络 | 训练集准确率 | 测试集准确率 |
|------|--------|--------|
| GRNN | 89.42 | 82.31 |
| ELM | 92.11 | 89.23 |
| PNN | 99.23 | 92.31 |
| DBN | 98.11 | 100.00 |

从表 3 可看出, DBN 在训练集和测试集上的准确率均较高; PNN 在训练集上的故障诊断效果很好,但在测试集上的准确率明显下降; GRNN 和 ELM 在训练集和测试集上的准确率均低于 DBN。

4 结语

提出了一种基于 SMOTE 和 DBN 的带式输送机故障诊断方法。该方法利用 SMOTE 生成更多的带式输送机故障状态样本数据, 克服了样本数据分布不平衡现象; 将样本数据输入 DBN, 利用无监督逐层训练方式提取带式输送机运行状态数据中的故障特征, 并通过有监督微调来优化故障诊断能力, 避免了局部极值, 提高了网络泛化能力。由于 DBN 结构复杂、参数较多, 为进一步提高故障诊断准确率, 缩短训练时间, 还需要对 DBN 中各参数设置进行更加深入的研究。

参考文献(References):

[1] 方宇. 基于支持向量机的皮带机故障诊断与预测研究 [D]. 徐州: 中国矿业大学, 2019.

FANG Yu. Research on fault diagnosis and prediction

of belt conveyor based on support vector machine [D]. Xuzhou: China University of Mining and Technology, 2019.

- [2] 马宏伟, 毛清华, 张旭辉. 矿用强力带式输送机智能监控技术研究进展[J]. 振动、测试与诊断, 2016, 36(2): 213-219.
MA Hongwei, MAO Qinghua, ZHANG Xuhui. Intelligent monitoring technology study process for steel cord conveyor belt in coal mine[J]. Journal of Vibration, Measurement & Diagnosis, 2016, 36 (2): 213-219.
- [3] 杨清翔, 向秀华, 孟斌, 等. 一种煤矿带式输送机故障诊断方法[J]. 工矿自动化, 2017, 43(12): 48-52.
YANG Qingxiang, XIANG Xiuhua, MENG Bin, et al. A fault diagnosis method of coal mine belt conveyor [J]. Industry and Mine Automation, 2017, 43 (12): 48-52.
- [4] 李榕, 吴宗泽, 曹琰. 一种基于 PNN 的刮板输送机故障诊断方法 [201710695799.4[P]]. 2017-11-24.
LI Rong, WU Zongze, CAO Yan. A fault diagnosis method of scraper conveyor based on PNN: 201710695799.4[P]. 2017-11-24.
- [5] 崔陈辰. 矿用胶带运输机故障诊断研究[D]. 西安: 西安科技大学, 2019.
CUI Chenchen. Study on fault diagnosis of coal belt conveyor[D]. Xi'an: Xi'an University of Science and Technology, 2019.
- [6] 龙周, 陈松坤, 王德禹. 基于 SMOTE 算法的船舶结构可靠性优化设计[J]. 上海交通大学学报, 2019, 53(1): 26-34.
LONG Zhou, CHEN Songkun, WANG Deyu. Reliability-based design optimization of ship structures based on SMOTE algorithm[J]. Journal of Shanghai Jiaotong University, 2019, 53(1): 26-34.
- [7] 张阳, 张涛, 陈锦, 等. 基于 SMOTE 和机器学习的网络入侵检测[J]. 北京理工大学学报, 2019, 39 (12): 1258-1262.
ZHANG Yang, ZHANG Tao, CHEN Jin, et al. Research on network intrusion detection based on SMOTE algorithm and machine learning [J]. Transactions of Beijing Institute of Technology, 2019, 39(12): 1258-1262.
- [8] BLAGUS R, LUSA L. Evaluation of SMOTE for high-dimensional class-imbalanced microarray data [C]//International Conference on Machine Learning & Applications, Boca Raton, 2013: 89-94.
- [9] HAN Dongying, ZHAO Na, SHI Peiming. A new fault diagnosis method based on deep belief network and support vector machine with Teager-Kaiser energy operator for bearings [J]. Advances in Mechanical Engineering, 2017, 9(12): 1-11.
- [10] 郑小霞, 陈广宁, 任浩翰, 等. 基于改进 VMD 和深度

置信网络的风机易损部件故障预警[J].振动与冲击,2019,38(8):153-160.

ZHENG Xiaoxia, CHEN Guangning, REN Haohan, et al. Fault detection of vulnerable units of wind turbine based on improved VMD and DBN[J]. Journal of Vibration and Shock, 2019, 38(8):153-160.

[11] 李梦诗,余达,陈子明,等.基于深度置信网络的风力发电机故障诊断方法[J].电机与控制学报,2019,23(2):114-122.

LI Mengshi, YU Da, CHEN Ziming, et al. Fault diagnosis and isolation method for wind turbines based on deep belief network[J]. Electric Machines and Control, 2019, 23(2):114-122.

[12] 刘文泽,张俊,邓焱.基于深度置信网络和多维信息融

合的变压器故障诊断方法[J].电力工程技术,2019,38(6):16-23.

LIU Wenze, ZHANG Jun, DENG Yan. Transformer fault diagnosis method based on deep learning and multi-dimensional information fusion [J]. Electric Power Engineering Technology, 2019, 38(6):16-23.

[13] 鲁春燕,李炜.基于深度置信网络的炼化空压机故障诊断方法[J].化工学报,2019,70(2):757-763.

LU Chunyan, LI Wei. Fault diagnosis method of petrochemical air compressor based on deep belief network[J]. CIESC Journal, 2019, 70(2):757-763.