

文章编号:1671-251X(2021)03-0079-05

DOI:10.13272/j.issn.1671-251x.17688

矿用设备智能安全监测与预知维护系统

徐畅¹, 王道元², 李敬兆², 陈梓华²

(1. 淮北职业技术学院 计算机科学技术系, 安徽 淮北 235025;

2. 安徽理工大学 电气与信息工程学院, 安徽 淮南 232001)



扫码移动阅读

摘要:针对现有矿用设备监测数据精度不高、数据分析能力弱、智能化程度不高等问题,提出了一种矿用设备智能安全监测与预知维护系统。该系统通过基于模拟退火算法的智能数据预选模型对矿用设备安全监测数据进行预处理,筛选出阈值范围内的数据,以剔除数据中的异常值;利用基于卷积神经网络的智能安全预知维护模型,使用不同大小的卷积核进行双通道卷积,多样化提取筛选后的数据特征,并与矿用设备历史状态样本数据进行对比,从而判断矿用设备运行状态,进而提供相应的设备预知维护方案。实验结果表明,该系统在矿用设备运行状态判断及预知维护方面具有较高精度。

关键词:矿用设备监测;安全监测;预知维护;模拟退火算法;卷积神经网络

中图分类号:TD67 文献标志码:A

Intelligent safety monitoring and predictive maintenance system for mining equipment

XU Chang¹, WANG Daoyuan², LI Jingzhao², CHEN Zihua²

(1. Department of Computer Science and Technology, Huaibei Vocational and Technical College,

Huaibei 235025, China; 2. School of Electrical and Information Engineering,

Anhui University of Science and Technology, Huainan 232001, China)

Abstract: In order to solve the problems of low accuracy of monitoring data, weak data analysis capabilities, and low intelligence of existing mining equipment, an intelligent safety monitoring and predictive maintenance system for mining equipment is proposed. The system preprocesses mining equipment safety monitoring data through an intelligent data pre-selection model based on the simulated annealing algorithm, filters out the data within the threshold range so as to eliminate outliers in the data. The intelligent safety predictive maintenance model based on convolutional neural network is used to perform dual-channel convolution using convolutional kernels of different sizes to diversify the extracted filtered data characteristics. By comparing them with the mining equipment historical status sample data, it is able to judge the mining equipment operation status and then provide corresponding equipment predictive maintenance solutions. The experimental results show that the system has high accuracy in judging the operation status and predictive maintenance of mining equipment.

Key words: mining equipment monitoring; safety monitoring; predictive maintenance; simulated annealing algorithm; convolutional neural networks

0 引言

煤矿开采过程中大多数安全事故的发生是由于

矿用设备安全监测不及时且未进行预知维护^[1-3]。传统的矿用设备安全监测大多依靠人工检查矿用设备^[4-5],并将检测结果记录在纸质档案中,该方式存

收稿日期:2020-12-01;修回日期:2021-03-19;责任编辑:盛男。

基金项目:国家自然科学基金资助项目(51874010);北京理工大学高精尖机器人开放性研究项目(2018IRS16);物联网关键技术研究创新团队项目(201950ZX003)。

作者简介:徐畅(1978-),女,安徽淮南人,讲师,硕士,主要研究方向为智慧矿山,E-mail:1579221994@qq.com。

引用格式:徐畅,王道元,李敬兆,等.矿用设备智能安全监测与预知维护系统[J].工矿自动化,2021,47(3):79-82.

XU Chang, WANG Daoyuan, LI Jingzhao, et al. Intelligent safety monitoring and predictive maintenance system for mining equipment [J]. Industry and Mine Automation, 2021, 47(3): 79-82.

在数据繁杂、误差较大等问题,且使用纸质档案易导致数据遗失。目前,部分煤矿企业采用安全监控系统监测矿用设备^[6-7],但只对监测数据简单存储,未进行深度数据处理与分析,无法提前预知矿用设备运行状态。因此,研发一种矿用设备运行数据实时监测、运行状态智能预测的系统,是亟待解决的问题。

陈晓勇^[8]提出了一种基于单片机的矿用设备电动机运行安全综合监测系统,对矿用电动机的电压等参数进行实时监测,并通过各参数偏差值来实现数据异常报警,但监测数据精度不高、数据分析能力弱,实际适用范围小。赵淑芳^[9]采用 BP 神经网络建立矿用设备安全预警系统,对矿用设备安全的关键指标数据进行异常状态趋势预测,但未能针对矿用设备维护提供有效措施,且智能化程度不高。本文通过构建基于模拟退火算法(Simulated Annealing, SA)的智能数据预选模型和基于卷积神经网络(Convolutional Neural Networks, CNN)的智能安全预知维护模型,设计了一种矿用设备智能安全监测与预知维护系统。该系统具有矿用设备安全监测数据预选、运行状态特征提取等功能,可实现矿用设备运行状态的精准判断和维护方案的智能预知。

1 系统架构

矿用设备智能安全监测与预知维护系统分为数据采集层、智能模型层、数据处理层和人机交互层,如图 1 所示。

数据采集层主要采集矿用设备安全监测数据,数据采集方式包括感知设备自动上传和人工录入,采集的安全监测数据、矿用设备历史状态样本数据与设备维护方案均以数据表的形式通过服务器存储至数据库。

智能模型层是系统的核心,通过推理引擎对采集的矿用设备安全监测数据进行计算模拟与模型训练,经过反馈调整获取最优的模型权值,从而构建基于 SA^[10]的智能数据预选模型和基于 CNN 的智能安全预知维护模型。

数据处理层采用智能数据预选模型对矿用设备安全监测数据进行筛选,以剔除数据中的异常值;利用智能安全预知维护模型对预选的数据进行处理,以提取矿用设备运行状态特征,并通过映射到矿用设备历史状态样本数据表,判断矿用设备运行状态。

人机交互层主要实现矿用设备安全监测数据实时可视化,方便安全人员对矿用设备运行状态实时监测,获取矿用设备相应维护方案。

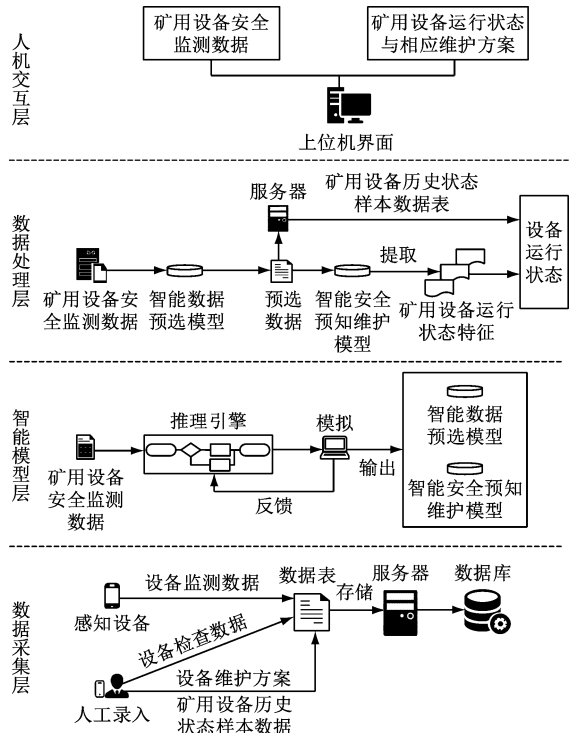


图 1 矿用设备智能安全监测与预知维护系统架构
Fig. 1 Architecture of intelligent safety monitoring and predictive maintenance system for mining equipment

2 基于 SA 的智能数据预选模型

基于 SA 的智能数据预选模型原理如图 2 所示。初始遍历矿用设备某监测项的安全监测数据,设定数据预选的最大阈值、最小阈值及迭代次数,采用 Metropolis 准则获取概率阈值。随机选出监测项中某个数据项作为初始节点(携带邻近节点值的信息记录表),从初始节点向周围的邻近节点发散,随机选择 1 个邻近节点作为下一跳节点,计算初始节点与该节点的能量差。若能量差小于 0,则跳转至该节点;否则,通过 Metropolis 准则计算从初始节点到其他邻近节点的概率。若概率大于概率阈值,则选取最大概率对应的邻近节点跳转,温度衰减,判断该节点值是否在数据预选阈值范围内,若是则将该节点值记录至数据表中,继续从该节点向邻近节点发散;若概率小于概率阈值,则停留在初始节点,重新选择下一跳节点。当温度衰减至 0 或达到迭代次数时,数据预选过程结束并记录终点节点值至数据表。

基于 SA 的智能数据预选模型构建步骤如下。

(1) 设矿用设备某监测项的数据规模大小为 g , 随机选定某一数据项作为初始节点 w_0 , 设初始温度为 T_0 , 则第 $l(l=1, 2, \dots, n, n$ 为迭代次数) 次迭代的温度为

$$T_l = T_{l-1} + \exp\left(\frac{\Delta E_l}{kT_{l-1}}\right) \quad (1)$$

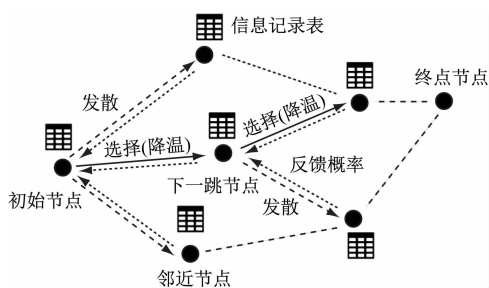


图2 基于SA的智能数据预选模型原理

Fig. 2 Principle of intelligent data preselection model based on SA

式中: ΔE_l 为第 l 次迭代的能量差; k 为玻尔兹曼常数。

(2) 设第 $l-1$ 次迭代的当前节点 w_{l-1} 随机发散到达的某个邻近节点为 w_l , 计算第 l 次迭代的能量差:

$$\Delta E_l = f(w_l) - f(w_{l-1}) \quad (2)$$

式中 $f(w_l)$ 为第 l 次迭代节点值。

(3) 若 $\Delta E_l < 0$, 接受 w_l 作为新的当前节点; 否则通过 Metropolis 准则计算 w_{l-1} 到其他邻近节点的概率 $P = \exp\left(-\frac{f(w_{l-1}) - f(w_l)}{NT_l}\right)$ (N 取 1.5)。




图3 基于CNN的智能安全预知维护模型原理

Fig. 3 Principle of intelligent security predictive maintenance model based on CNN

基于CNN的智能安全预知维护模型构建步骤如下。

(1) 随机从经过智能数据预选模型预选后的矿用设备安全监测数据中选出 64 个数据, 构造 8×8 的输入矩阵。使用 3×3 和 5×5 的卷积核进行双通道卷积运算, 多样化提取数据特征, 将双通道卷积输出矩阵通过 $\max()$ 函数融合, 即取矩阵对应位置元素的最大值, 得到卷积层输出。

$$\begin{cases} S_{i,j}^1 = \text{Relu}\left(\sum_{a=1}^m \sum_{i=0}^7 \sum_{j=0}^7 \sigma_{a,i,j}^1 p_{a,i,j} + d_1\right) \\ S_{i,j}^2 = \text{Relu}\left(\sum_{a=1}^m \sum_{i=0}^7 \sum_{j=0}^7 \sigma_{a,i,j}^2 p_{a,i,j} + d_2\right) \\ S_{i,j} = \max(S_{i,j}^1, S_{i,j}^2) \end{cases} \quad (3)$$

式中: $S_{i,j}^1, S_{i,j}^2$ 为双通道卷积输出矩阵, (i, j) 为输入矩阵中存储数据的坐标; $\text{Relu}(\cdot)$ 为激活函数; $\sigma_{a,i,j}^1, \sigma_{a,i,j}^2$ 分别为第 α ($\alpha=1, 2, \dots, m$, m 为矿用设备数量) 个矿用设备数据项在不同卷积核尺寸卷积下的权重; $p_{a,i,j}$ 为第 α 个矿用设备的输入矩阵元素; d_1, d_2 分别为不同卷积核尺寸的卷积偏移量; $S_{i,j}$ 为

若 $P > r$ (r 为 $(0, 1)$ 上均匀分布的随机数), 则接受对应的邻近节点作为当前节点 w_l , 并判断当前节点值 $f(w_l)$ 是否在数据预选的阈值范围内, 若是则输出第 l 次迭代节点值 $f(w_l)$, 温度 T_l 以 $\exp\left(\frac{\Delta E_l}{kT_{l-1}}\right)$ 的速率衰减, 返回步骤 (2), 直至温度衰减至 0 或达到迭代次数, 迭代结束。

3 基于CNN的智能安全预知维护模型

基于CNN的智能安全预知维护模型原理如图3所示。首先, 将通过智能数据预选模型预选后的矿用设备安全监测数据(噪声、功率、温度、振动、电流、电压、湿度、转速)转换为输入矩阵。然后, 通过具有不同大小卷积核的卷积层^[11-13]对输入矩阵进行数据特征提取。接着, 利用池化层进行数据降维, 缩减数据的特征项, 再经过全连接得到矿用设备运行状态预测数据。最后, 将矿用设备运行状态预测数据与历史状态数据进行对比, 判断矿用设备状态是否异常。

融合后的卷积层输出矩阵。

(2) 融合后的卷积层输出矩阵 $S_{i,j}$ 进入池化层, 采用平均池化^[14]方式降低特征量。

(3) 经过多次卷积池化后, 进行全连接处理, 得到第 α 个矿用设备运行状态的预测数据(维度为 1×8)。

(4) 将矿用设备运行状态预测数据与历史状态数据进行对比, 判断矿用设备运行状态, 从而获取相应矿用设备安全预知维护方案。

4 实验验证

为验证矿用设备智能安全监测与预知维护系统的可靠性, 与基于BP神经网络的矿用设备安全预警系统^[9]进行了实验对比。实验采用淮北矿业(集团)有限责任公司某矿 16 台矿用设备共 45 000 个安全监测数据项, 检索时间为 90 min。实验平台配置: 32 GB 内存; Intel Core i7 中央处理器; Python 3.6; 8 核 GPU; TensorFlow 深度学习框架^[15]。CNN 参数设置: 学习率为 0.1, 初始学习率为 0.02,

动量系数为 0.8。实验结果见表 1 和表 2,可看出本文系统在矿用设备运行状态判断及预知维护方面具有较高精度。

表 1 矿用设备运行状态判断效果对比

Table 1 Comparison of operation state judgment effect of mining equipment

系统	检索数据总条数	实际检索到的数据条数	准确判断设备发生故障或待检修的数据条数	准确率/%
基于 BP 神经网络的矿用设备预警系统	8 000	7 540	6 288	83.4
本文系统	8 000	7 631	6 968	91.3

表 2 矿用设备预知维护效果对比

Table 2 Comparison of predictive maintenance effect of mining equipment

系统	检索数据总条数	实际检索到的数据条数	准确预知设备维护的数据条数	准确率/%
基于 BP 神经网络的矿用设备预警系统	8 000	7 540	6 012	79.7
本文系统	8 000	7 631	6 792	89.0

5 结语

提出了一种矿用设备智能安全监测与预知维护系统。该系统通过基于 SA 的智能数据预选模型对矿用设备安全监测数据进行筛选,以剔除数据中的异常值;利用基于 CNN 的智能安全预知维护模型对筛选后的数据进行特征提取,并与矿用设备历史状态样本数据进行对比,实现矿用设备运行状态动态预知与设备维护的智能决策。实验结果表明,该系统在矿用设备运行状态判断及预知维护方面具有较高精度。

参考文献 (References):

[1] 陈兆波,雷煜斌,曾建潮,等. 煤矿安全事故人因的灰色关联分析[J]. 煤炭工程,2015,47(4):145-148.
CHEN Zhaobo, LEI Yubin, ZENG Jianchao, et al. Grey correlation analysis of human factors in mining accidents[J]. Coal Engineering,2015,47(4):145-148.

[2] 李博杨,李贤功,吴利高,等. 基于熵权法和集对分析的煤矿安全事故人因失误分析[J]. 矿业安全与环保,2017,44(1):111-114.
LI Boyang, LI Xiangong, WU Ligao, et al. Analysis of human error factors in coal mine safety accidents based on entropy weight and set pair analysis[J].

Mining Safety and Environmental Protection,2017,44(1):111-114.

[3] 张旭辉,张雨萌,王妙云,等. 基于混合现实的矿用设备维修指导系统[J]. 工矿自动化,2019,45(6):27-31.
ZHANG Xuhui, ZHANG Yumeng, WANG Miaoyun, et al. Maintenance guidance system of mine-used equipments based on mixed reality[J]. Industry and Mine Automation,2019,45(6):27-31.

[4] 焦洋,孙家兰,温慧明. 煤矿设备管理系统设计[J]. 煤炭科学技术,2013,41(增刊 2):323-324.
JIAO Yang, SUN Jialan, WEN Huiming. Design of equipment management system in coal mine[J]. Coal Science and Technology,2013,41(S2):323-324.

[5] 丁恩杰,金雷,陈迪. 互联网+感知矿山安全监控系统研究[J]. 煤炭科学技术,2017,45(1):129-134.
DING Enjie, JIN Lei, CHEN Di. Study on safety monitoring and control system of internet + perception mine[J]. Coal Science and Technology,2017,45(1):129-134.

[6] 赵淑芳,陈立潮. 基于 WEB 的煤矿矿用设备安全监测管理系统的设计与实现[J]. 微计算机信息,2011,27(3):54-56.
ZHAO Shufang, CHEN Lichao. The safe monitor management of colliery mineral product equipment that based on the WEB[J]. Control and Automation,2011,27(3):54-56.

[7] 崔博文. 监测监控技术在煤矿安全生产中的应用[J]. 内蒙古煤炭经济,2016(7):93-94.
CUI Bowen. Application of monitoring and control technology in coal mine safety production[J]. Inner Mongolia Coal Economy,2016(7):93-94.

[8] 陈晓勇. 矿用设备电机运行安全综合监测系统[J]. 露天采矿技术,2019,34(1):115-117.
CHEN Xiaoyong. Integrated monitoring system for mine equipment motor operation safety[J]. Opencast Mining Technology,2019,34(1):115-117.

[9] 赵淑芳. 基于 BP 神经网络的煤矿矿用设备安全监测研究[J]. 太原理工大学学报,2013,44(5):619-622.
ZHAO Shufang. The study of coal mine safety monitoring equipment based on BP neural network [J]. Journal of Taiyuan University of Technology,2013,44(5):619-622.

[10] 傅文渊,凌朝东. 布朗运动模拟退火算法[J]. 计算机学报,2014,37(6):1301-1308.
FU Wenyuan, LING Chaodong. Brownian motion based simulated annealing algorithm [J]. Chinese Journal of Computers,2014,37(6):1301-1308.

[11] 周飞燕,金林鹏,董军. 卷积神经网络研究综述[J]. 计

- 计算机学报,2017,40(6):1229-1251.
- ZHOU Feiyan, JIN Linpeng, DONG Jun. Review of convolutional neural network[J]. Chinese Journal of Computers,2017,40(6):1229-1251.
- [12] 李旭冬,叶茂,李涛. 基于卷积神经网络的目标检测研究综述[J]. 计算机应用研究,2017,34(10):2881-2886.
- LI Xudong, YE Mao, LI Tao. Review of object detection based on convolutional neural networks[J]. Application Research of Computers,2017,34(10):2881-2886.
- [13] 杨宏志,庞宇,王慧倩. 基于改进 Faster R-CNN 的自然场景文字检测算法[J]. 重庆邮电大学学报(自然科学版),2019,31(6):876-884.
- YANG Hongzhi, PANG Yu, WANG Huiqian. Natural scene text detection algorithm based on improved Faster R-CNN[J]. Journal of Chongqing University of Posts and Telecommunications (Natural Science Edition),2019,31(6):876-884.
- [14] 刘万军,梁雪剑,曲海成. 不同池化模型的卷积神经网络学习性能研究[J]. 中国图象图形学报,2016,21(9):1178-1190.
- LIU Wanjun, LIANG Xuejian, QU Haicheng. Learning performance of convolutional neural networks with different pooling models[J]. Journal of Image and Graphics,2016,21(9):1178-1190.
- [15] 仝卫国,李敏霞,张一可. 深度学习优化算法研究[J]. 计算机科学,2018,45(增刊2):155-159.
- TONG Weiguo, LI Minxia, ZHANG Yike. Research on optimization algorithm of deep learning [J]. Computer Science,2018,45(S2):155-159.