

文章编号:1671-251X(2021)07-0021-08

DOI:10.13272/j.issn.1671-251x.2020110032

采煤机运行状态数据分布式实时预测模型

张俭让^{1,2}, 刘睿卿^{1,2}, 李学文^{1,2}, 王智鹏^{1,2}, 史振东^{1,2}

(1. 西安科技大学 安全科学与工程学院, 陕西 西安 710054;
2. 教育部西部矿井开采及灾害防治重点实验室, 陕西 西安 710054)



扫码移动阅读

摘要:针对采煤机大量运行状态数据不能得到及时处理的问题,研究了基于 Storm 的采煤机运行状态数据分布式实时预测模型。结合采煤机实际运行状态数据,通过 Hadoop 分布式存储数据库模拟采煤机运行状态实时数据流;通过 Storm 分布式实时大数据处理框架处理大量采煤机运行状态时间序列数据,采用门控循环单元(GRU)作为预测模型,实现对采煤机运行状态数据的实时预测;结合各类数据的阈值设定,实现故障预警。以某矿综采工作面 MG400930-WD 电牵引采煤机的数据为例,取截割部电动机电流、截割部电动机温度、牵引部电动机电流、牵引部电动机转速、调高泵工作压力、调高泵工作转速、冷却水压、变频器电流 8 种监测数据作为实验数据,对预测模型进行训练和测试,结果表明:预测模型收敛速度较快,且拟合优度达到 0.9 以上;除冷却水压外,其余数据的预警准确率均达到 95% 以上;处理速度快,整个预警过程共 10 s 左右,可满足应用要求。

关键词:采煤机;运行状态数据;时间序列数据;状态预测;预警;Storm;门控循环单元;Hadoop
中图分类号:TD632 文献标志码:A

Distributed real time prediction model of shearer operating state data

ZHANG Jianrang^{1,2}, LIU Ruiqing^{1,2}, LI Xuewen^{1,2}, WANG Zhipeng^{1,2}, SHI Zhendong^{1,2}

(1. College of Safety Science and Engineering, Xi'an University of Science and Technology, Xi'an 710054, China; 2. Key Laboratory of West Mines Exploitation and Hazard Prevention of Ministry of Education, Xi'an 710054, China)

Abstract:In order to solve the problem that a large amount of shearer operating state data cannot be processed in time, the distributed real-time prediction model of shearer operating state data based on Storm is proposed. Combined with the actual operating state data of the shearer, the Hadoop distributed storage database is used to simulate the real-time data flow of the operating state of the shearer. The Storm distributed real-time big data processing framework is used to process a large number of time series data of the operating state of the shearer. And Gate Recurrent Unit (GRU) is adopted as the prediction model to achieve real-time prediction of shearer operating state data. Combined with the threshold setting of various data, the model can realize fault warning. Taking the data of MG400930-WD electric traction shearer in fully mechanized working face as an example, eight kinds of monitoring data are used as experimental data to train and test the prediction model. The data include cutting part motor current, cutting part motor temperature, traction part motor current, traction part motor speed, height adjustment pump working pressure, height adjustment pump working speed, cooling water pressure and inverter current. The results show that the prediction model converges quickly, and the goodness of fit is above 0.9. Except for the cooling water pressure, the early warning accuracy rate of the remaining data is above 95%. The

收稿日期:2020-11-16;修回日期:2021-06-29;责任编辑:胡娴。
基金项目:陕西省自然科学基金基础研究计划项目(2019JLZ-08)。
作者简介:张俭让(1963—),男,陕西岐山人,教授,主要从事矿山灾害防治的教学与科研工作,E-mail:zhaangjr@sohu.com。
引用格式:张俭让,刘睿卿,李学文,等.采煤机运行状态数据分布式实时预测模型[J].工矿自动化,2021,47(7):21-28.

ZHANG Jianrang, LIU Ruiqing, LI Xuewen, et al. Distributed real time prediction model of shearer operating state data[J]. Industry and Mine Automation, 2021, 47(7): 21-28.

processing speed is fast and the whole early warning process is about 10 s in total, which can meet the application requirements.

Key words: shearer; operating state data; time series data; state prediction; early warning; Storm; gate recurrent unit; Hadoop

0 引言

随着煤矿智能化的发展,数据量的增长异常迅猛。采煤机是综采“三机”之一,其工作环境复杂,自身安装有多个传感器,采样频率高,数据量大^[1-2]。采煤机运行状态数据属于动态的时间序列数据,可用于采煤机运行状态的实时分析判断及预测。对采煤机运行状态数据进行实时采集与分析处理,可一定程度上保障采煤机及人员安全,对采煤机智能化运行具有重要意义^[3]。

目前机械设备的状态预测方法仍然大量使用传统机器学习方法,如自回归模型^[4]、隐马尔科夫模型^[5]、BP 神经网络预测模型^[6]等。这些模型在预测少量数据时取得了不错的效果,但面对大量数据应用时往往效果不理想。

Storm 是一种开源的分布式实时大数据处理框架,具有适用场景广泛、可伸缩性高、无数据丢失的特点,适用于大量时间序列流数据的实时处理^[7-8]。因此,本文在 Storm 框架基础上进行采煤机运行状态预测。循环神经网络在处理与时间序列相关的数据方面取得了良好效果,但在反向传播过程中,随着层数增多,会出现梯度消失或者爆炸现象,对模型的拟合程度有较大影响。门控循环单元 (Gate Recurrent Unit, GRU) 是循环神经网络的一种变体,其解决了长距离时序数据预测中容易出现的梯度爆炸和消失问题,应用于金融时间序列预测^[9]、电力负荷预测^[10]等领域时取得了良好效果。因此,本文采用 GRU 预测采煤机的时序数据,结合 Storm 框架和 GRU 实现采煤机运行状态预测。

1 Storm 数据流模型

Storm 的核心组件主要包括主控节点 (Nimbus) 和从节点 (Supervisor)。Nimbus 节点主要负责资源分配和任务调度,Supervisor 节点负责接收 Nimbus 分配的任务,管理和启动所有的工作 (Worker)。1 个 Supervisor 对应 4 个 Worker,1 个 Worker 对应 1 个拓扑 (Topology),Topology 由 Stream、Spout 和 Bolt 组成。Stream 即数据流; Spout 充当采集器的角色,实现与数据源的连接; Bolt 为业务逻辑运算节点,订阅多个 Spout,实现业务处理、连接运算等操作。Storm 数据流模型基本

结构如图 1 所示。




图 1 Storm 数据流模型基本结构
Fig. 1 Basic structure of Storm data flow model

2 GRU 结构及原理

GRU 结构如图 2 所示。其中 x_t 为 t 时刻的输入值, c_t 为记忆细胞, h_t 为 t 时刻隐藏单元的历史信息, a_t 为重写的记忆细胞的候选值, o_t 为 t 时刻的输出值, r_t 为重置门, u_t 为更新门。GRU 通过记忆细胞 c_t 将历史数据信息保存下来,用于数据预测。当 t 时刻实际数据 x_t 到达时,结合隐藏单元历史信息 h_{t-1} ,通过更新门和重置门控制上一个单元有多少信息可以保留,当前单元有多少信息可以添加到记忆细胞 c_t 并传递给下一个单元,通过激活函数输出当前时刻的预测值 o_t 。常用的激活函数为 $\tanh$, K 类别分类问题可以选用 softmax 作为激活函数。为了简化描述,设置输出的激活函数为 softmax 函数,隐藏层的激活函数为 $\tanh$ 函数。




图 2 GRU 结构
Fig. 2 GRU structure

更新门 u_t 用于确定上一隐藏层中的记忆信息,重置门 r_t 用于确定上一隐藏层中的遗忘信息,记忆细胞候选值 a_t 用于确定当前的记忆内容,记忆细胞 c_t 用于确定当前要保留的信息,其计算公式分别为

$$u_t = \sigma(w_u[c_{t-1}, x_t] + b_u) \tag{1}$$

$$r_t = \sigma(w_r[c_{t-1}, x_t] + b_r) \tag{2}$$

$$a_t = \tanh(w_h[r_t c_{t-1}, x_t] + b_c) \tag{3}$$

$$c_t = u_t a_t + (1 - u_t) c_{t-1} \tag{4}$$

式中: σ 为 sigmoid 函数; w_u, w_r, w_h 分别为更新门 u_t 、重置门 r_t 和记忆细胞候选值 a_t 的更新权值; b_u, b_r, b_c 分别为更新门 u_t 、重置门 r_t 和记忆细胞候选值 a_t 的偏差值。

3 基于 Storm 的采煤机运行状态数据分布式实时预测模型

3.1 预测模型原理

基于 Storm 的采煤机运行状态数据分布式实




图 3 基于 Storm 的采煤机运行状态数据分布式实时预测模型

Fig. 3 Distributed real time prediction model of shearer operating state data based on Storm

3.2 Hadoop 分布式存储数据库

为方便管理海量的采煤机运行状态数据,基于 Hadoop^[12]设计数据存储结构,包括 1 张索引表和多张数据表^[13]。索引表包括监测点位置、预测模型、预警阈值上界 TUB_n (n 为监测点数)和下界 TLB_n ,见表 1。数据表通过行增长的方式模拟时间序列,每一列代表某个监测点所采集的时间序列数据,见表 2,其中 m 为时间点数, $Data_{nm}$ 为监测数据。在实际生产中,各个测点的实时运行数据会以固定时间间隔存入 Hadoop 中,经主控节点 Nimbus 的调配传入 Spout 中进行处理。

表 1 索引表

Table 1 Index table

位置	预测模型	预警上界	预警下界
监测点 1	GRU	TUB_1	TLB_1
监测点 2	GRU	TUB_2	TLB_2
$\vdots$	$\vdots$	$\vdots$	$\vdots$
监测点 n	GRU	TUB_n	TLB_n

表 2 数据表

Table 2 Data table

时间	监测数据			
时间点 1	$Data_{11}$	$Data_{21}$	$\cdots$	$Data_{n1}$
时间点 2	$Data_{12}$	$Data_{22}$	$\cdots$	$Data_{n2}$
$\vdots$	$\vdots$	$\vdots$	$\cdots$	$\vdots$
时间点 m	$Data_{1m}$	$Data_{2m}$	$\cdots$	$Data_{nm}$

3.3 Spout 设计

Spout 通过调用 `nextTuple()` 方法从 Hadoop 中提取相应监测点的信息,将信息封装后传递给 Bolt,具体步骤如下:

时预测模型如图 3 所示。采煤机运行状态数据是以固定时间间隔源源不断地产生,本文结合在煤矿收集的采煤机运行状态数据,在 Hadoop 分布式存储数据库中通过 `crontab` 编写定时读取数据的脚本,用来模拟采煤机的实时数据流。将流数据传送到不同的消息队列 Spout 中,Spout 将数据以元组流的形式发送给相应 Bolt,通过多个 Bolt 实现对数据的预处理、预测、误差计算及存储,最终实现对采煤机运行状态数据的实时预测^[11]。

(1) 连接 Hadoop,从相应监测点的数据表中读取 n 个数据。

(2) 判断数据序列长度是否达到预测的历史数据样本容量 N ,达到则进行步骤(4),否则进行步骤(3)。

(3) 从数据库读取新数据,将新数据添加到序列末尾,跳回步骤(2)。

(4) 将数据封装成元组形式发送到预处理 Bolt。

3.4 Bolt 设计

Bolt 接收 Spout 传递的元组,通过多个 Bolt 调用 `execute()` 方法,分别实现数据的预处理、预测、误差计算和存储,具体步骤^[14]如下:

(1) 预处理 Bolt 接收从 Spout 传递来的元组,解析对应监测点的 N 个数据;导入 python 包处理异常值,并将数据标准化,以元组形式发送到 GRU 预测 Bolt。

(2) 预测 Bolt 接收预处理 Bolt 传递的标准化后的数据,导入训练好的 GRU 模型,预测下一时刻的数据,并等待该时刻实际数据,将预测数据和实际数据一起发送到预警 Bolt。

(3) 预警 Bolt 根据设定的阈值判断是否要预警,将预测结果和预警信息发送到存储 Bolt。

(4) 存储 Bolt 接收数据并存储。

4 实验分析

4.1 实验环境及过程

选用 3 台配置相同的计算机搭建 Storm 分布式

集群环境,每台机器部署 1 台虚拟机。3 台虚拟机的操作系统为 CentOS6.8,其中 1 台作为 Master 布置 Nimbus 节点,另外 2 台布置 Supervisor 节点。主控节点 Nimbus 为双核单处理器,4 GB 内存,40 GB 硬盘;从节点 Supervisor 为单核单处理器,2 GB 内存,20 GB 硬盘。Nimbus 节点接收 Storm 集群的任务后,通过 Zookeeper 实现对 Supervisor 的资源分配。

以某矿综采工作面 MG400930-WD 电牵引采煤机的数据为例,取采煤机中的截割部电动机电流、截割部电动机温度、牵引部电动机电流、牵引部电动机转速、调高泵工作压力、调高泵工作转速、冷却水压、变频器电流 8 种监测数据(依次用 a—h 表示)各 1 000 条作为实验数据。

首先进行 GRU 模型训练。对原始数据中的缺失值、异常值及噪声进行预处理,将预处理后的数据作为输入数据。将输入数据以 7:3 的比例分为训练集和测试集。隐藏层针对训练集进行训练,通过优化函数 Adam、损失函数 MSE 调节模型的超参数,以损失值最小作为调优准则对模型进行优化。

通过训练找到 GRU 的最优参数,在 Hadoop 上模拟实时数据流,设置基本时间窗口为 1 min。在 主控节点 Nimbus 调控下,将 8 种测试集数据并行

输入 8 个 Worker 中,在各自的拓扑中完成对数据的预测和预警。


4.2 实验结果

GRU 超参数寻优结果见表 3,其中 C_1 — C_7 分别为寻优训练次数、学习率、神经元数量、权重衰减、时间步数、每次训练样本数、隐藏层数。从表 3 可看出,8 种监测数据在 GRU 模型中收敛的训练次数不同,但均小于 500 次,收敛速度较快。


表 3 GRU 超参数寻优结果
Table 3 GRU hyperparameter optimization results

数据类型	C_1	C_2	C_3	C_4	C_5	C_6	C_7
a	489	0.01	64	0.001	8	256	1
b	341	0.01	64	0.001	8	256	1
c	418	0.01	64	0.001	8	256	1
d	325	0.01	64	0.001	8	256	1
e	455	0.01	64	0.001	8	256	1
f	481	0.01	64	0.001	8	256	1
g	364	0.01	64	0.001	8	256	1
h	478	0.01	64	0.001	8	256	1


将训练好的 GRU 导入 Bolt 中,用测试集模拟实时数据流,各测试集中 300 个点的真实值和预测结果对比如图 4 所示。




(a) 截割部电动机电流




(b) 截割部电动机温度




(c) 牵引部电动机电流



(d) 牵引部电动机转速



(e) 调高泵工作压力



(f) 调高泵工作转速




图 4 真实值和预测结果对比

Fig. 4 Comparison of real values and predicted results

4.3 结果分析

4.3.1 GRU 预测结果评价

采用平均绝对误差 (MAE)、均方根误差 (RMSE) 及拟合优度 (R^2) 作为 GRU 拟合程度的评价指标,其计算公式分别为

$$MAE = \frac{1}{p} \sum_{i=1}^p |\hat{y}_i - y_i| \tag{5}$$

$$RMSE = \sqrt{\frac{1}{p} \sum_{i=1}^p (\hat{y}_i - y_i)^2} \tag{6}$$

$$R^2 = 1 - \frac{\sum_{i=1}^p (y_i - \hat{y}_i)^2}{\sum_{i=1}^p (y_i - \bar{y})^2} \tag{7}$$

式中: p 为数据量; $\hat{y}_i$ 为预测值; y_i 为真实值; $\bar{y}$ 为所有真实数据的平均值。

GRU 预测结果评价指标对比见表 4。

表 4 评价指标对比

Table 4 Comparison of evaluation indexes			
数据类型	MAE	RMSE	R^2
a	0.738	0.911	0.941
b	0.808	1.049	0.943
c	0.938	1.204	0.928
d	3.346	4.168	0.930
e	0.105	0.134	0.955
f	2.727	3.398	0.943
g	0.019	0.025	0.911
h	1.208	1.486	0.937

拟合优度 R^2 的值越接近 1,MAE 和 RMSE 的值越接近 0,效果越好。由表 4 可知,因为原始数据较大,数据类型 d 和 f 的 MAE 和 RMSE 的值相对较大,而其余类型的原始数据较小,误差也相对较小。8 种数据的 MAE 和 RMSE 均接近 0,初步判断 GRU 可作为预测模型。8 种数据的 R^2 均达到 0.9 以上,说明基于 Storm 的分布式时间序列实时

预测模型适用于采煤机运行状态数据的预测。

4.3.2 预警的准确性

根据经验和误差要求,设定各类实验数据的阈值,见表 5,其中 I_{e_1} 、 I_{e_2} 分别截割部电动机、牵引部电动机的额定电流, $I_{e_1}=87\text{ A}$ 、 $I_{e_2}=105\text{ A}$ 。

表 5 数据阈值设定

Table 5 Data thresholds setting		
参数	注意值	故障阈值
截割部电动机电流	$0.9I_{e_1}$	$1.1I_{e_1}$
截割部电动机温度/ $^{\circ}\text{C}$	135	155
牵引部电动机电流	$0.9I_{e_2}$	$1.1I_{e_2}$
牵引部电动机转速/ $(\text{r}\cdot\text{min}^{-1})$	1 470	1 550
调高泵工作压力/MPa	20	23
调高泵工作转速/ $(\text{r}\cdot\text{min}^{-1})$	1 470	1 550
冷却水压/MPa	1.5	2
变频器电流/A	97	150

根据阈值设定,将各类数据的状态分为正常、注意和故障 3 种。当采煤机运行时,若数据未达到注意值,则状态为正常,工作性能稳定,无需采取措施;若数据达到注意值而未达到故障阈值,则状态为注意;若数据达到故障阈值,则状态为故障。预测 Bolt 在得到预测数据而实际数据未到时,对数据状态进行预测并作出相应预警^[15]。测试集的各数据预测状态与实际状态的对比结果如图 5 所示,其中纵坐标 1,2,3 分别表示正常、注意和故障 3 种状态。各类数据的预警准确率见表 6。

从表 6 可看出,除冷却水压外,其余数据的预警准确率均达到 95% 以上,满足实际应用要求。由于冷却水压数据值较小,注意值和故障阈值间隔很小,预测时误差偏大,但也达到 85% 以上,准确率较高,具有一定的实用价值。

4.3.3 处理时间

实验模拟从传感器得到数据并传入 Hadoop




图 5 数据状态对比
Fig. 5 Data state comparison

表 6 预警准确率
Table 6 Early warning accuracy

数据类型	准确率/%	数据类型	准确率/%
a	96.0	e	98.7
b	96.7	f	95.7
c	96.0	g	88.7
d	96.0	h	95.7

中,Storm 从 Hadoop 中读取数据,主控节点 Nimbus 通过 Zookeeper 监控和分配任务,通过 Supervisor 节点将具体的处理逻辑交由 Worker 完成。分别测量将流数据传入 Spout 中所需要的时间,Spout 将数据分发给 Bolt 所需要的时间,预处理 Bolt、预测 Bolt、预警 Bolt 和存储 Bolt 所需要的总时间,结果见表 7。

表 7 预测模型处理时间

Table 7 Processing time of prediction model

数据类型	数据库处理 时间/ms	Spout 处理 时间/ms	Bolt 处理 时间/ms
a	5 450	4 426	0.956
b	5 412	4 516	0.962
c	5 469	4 484	0.944
d	5 510	4 534	0.972
e	5 562	4 415	1.056
f	5 593	4 580	1.182
g	5 410	4 532	1.132
h	5 435	4 520	1.152
均值	5 480.125	4 500.875	1.044 5

从表 7 可看出,数据库、Worker 中 Spout 和各 Bolt 针对流数据的处理速度较快,整个预警过程共 10 s 左右,远低于测点数据采集间隔(1 min),因此,可满足应用要求。

5 结论

(1) 提出基于 Storm 的采煤机运行状态数据分布式实时预测模型,结合 Hadoop 数据库,模拟实际生产中采煤机时间序列运行数据,采用深度学习中的 GRU 对数据进行处理,实现对采煤机运行状态数据的预测和预警。

(2) 实验结果表明:GRU 收敛速度较快,且拟合优度达到 0.9 以上;各种数据状态预测的准确率均达到 85%以上,整个预警过程仅需 10 s 左右,远低于测点数据采集间隔(1 min),模型的预警准确率和效率均能满足要求。

(3) Storm 框架仍需进行包括负载均衡、集群调优等优化,以更好地满足应用要求,下一步将对此进行研究。

参考文献(References):

[1] 王国法,赵国瑞,任怀伟.智慧煤矿与智能化开采关键核心技术分析[J].煤炭学报,2019,44(1):34-41.
WANG Guofa, ZHAO Guorui, REN Huaiwei. Analysis on key technologies of intelligent coal mine and intelligent mining [J]. Journal of China Coal Society,2019,44(1):34-41.

[2] 谭章禄,马营营.煤炭大数据研究及发展方向[J].工矿自动化,2018,44(3):49-52.
TAN Zhanglu, MA Yingying. Research on coal big

data and its developing direction [J]. Industry and Mine Automation,2018,44(3):49-52.

[3] 王国法,杜毅博.智慧煤矿与智能化开采技术的发展方向[J].煤炭科学技术,2019,47(1):1-10.
WANG Guofa, DU Yibo. Development direction of intelligent coal mine and intelligent mining technology [J]. Coal Science and Technology,2019,47(1):1-10.

[4] 李永耀,韩捷,陈磊,等.基于 AR-Kalman 的机械设
备状态趋势预测方法研究[J].制造业自动化,2014,
36(12):95-96.
LI Yongyao, HAN Jie, CHEN Lei, et al. Research on
condition trend prediction method of mechanical
equipment based on AR-Kalman [J]. Manufacturing
Automation,2014,36(12):95-96.

[5] 季云,王恒,朱龙彪,等.基于 HMM 的机械设备运行
状态评估与故障预测研究综述[J].机械强度,2017,
39(3):511-517.
JI Yun, WANG Heng, ZHU Longbiao, et al. Review
on operation state assessment and prognostics for
mechanical equipment based on hidden Markov model
[J]. Journal of Mechanical Strength, 2017, 39 (3):
511-517.

[6] 马宏伟,吴少杰,曹现刚,等.煤矿综采设备运行状态
大数据清洗建模[J].工矿自动化,2018,44(11):
80-83.
MA Hongwei, WU Shaojie, CAO Xiangang, et al. Big
data cleaning modeling of operation status of coal
mine fully-mechanized coal mining equipment [J].
Industry and Mine Automation,2018,44(11):80-83.

[7] 曹现刚,姜韦光,张国祯.采煤机运行状态数据实时清
洗技术研究[J].煤炭工程,2020,52(3):127-131.
CAO Xiangang, JIANG Weiguang, ZHANG
Guozhen. Real-time data cleaning of coal mining
machine operating status[J]. Coal Engineering,2020,
52(3):127-131.

[8] 杨丽,吴雨茜,王俊丽,等.循环神经网络研究综述
[J].计算机应用,2018,38(增刊 2):1-6.
YANG Li, WU Yuxi, WANG Junli, et al. Research on
recurrent neural network [J]. Journal of Computer
Applications,2018,38(S2):1-6.

[9] 张金磊,罗玉玲,付强.基于门控循环单元神经网络的
金融时间序列预测[J].广西师范大学学报(自然科学
版),2019,37(2):82-89.
ZHANG Jinlei, LUO Yuling, FU Qiang. Predicting
financial time series based on gated recurrent unit
neural network [J]. Journal of Guangxi Normal
University (Natural Science Edition), 2019, 37 (2):

82-89.

[10] 王增平,赵兵,纪维佳,等. 基于 GRU-NN 模型的短期负荷预测方法[J]. 电力系统自动化,2019,43(5): 53-58.

WANG Zengping,ZHAO Bing,JI Weijia,et al. Short-term load forecasting method based on GRU-NN model[J]. Automation of Electric Power Systems, 2019,43(5):53-58.

[11] 翁小松,张征. 基于 Storm 的流媒体实时传输系统[J]. 计算机系统应用,2020,29(6):64-72.

WENG Xiaosong,ZHANG Zheng. Real-time streaming media transmission system based on Storm [J]. Computer Systems & Applications,2020,29(6): 64-72.

[12] 陈红. 基于 Hadoop 的分布式 SQL 数据库索引设计与实践[J]. 舰船电子工程,2018,38(4):73-77.

CHEN Hong. Design and practice of distributed SQL database index based on Hadoop[J]. Ship Electronic Engineering,2018,38(4):73-77.

[13] 王远,陶烨,袁军,等. 一种基于 HBase 的智能电网时序大数据处理方法[J]. 系统仿真学报,2016,28(3): 559-568.

WANG Yuan,TAO Ye,YUAN Jun,et al. Approach to process smart grid time-serial big data based on HBase [J]. Journal of System Simulation, 2016, 28(3):559-568.

[14] 寇元宝,汪崇建,俞瑞光. 采煤机运行数据预处理算法研究[J]. 煤矿机械,2020,41(10):41-43.

KOU Yuanbao,WANG Chongjian,YUN Ruiguang. Research on preprocessing algorithm of shearer operation data [J]. Coal Mine Machinery, 2020, 41(10):41-43.

[15] 曹现刚,李彦川,雷卓,等. 采煤机健康状态智能评估方法研究[J]. 工矿自动化,2020,46(6):41-47.

CAO Xiangang,LI Yanchuan,LEI Zhuo,et al. Research on intelligent evaluation method of health state of shearer[J]. Industry and Mine Automation, 2020,46(6):41-47.