

文章编号:1671-251X(2021)08-0090-06

DOI:10.13272/j.issn.1671-251x.17694

# 基于时序数据的工作面设备故障预测研究

郑磊

(国能信息技术有限公司,北京 100011)



扫码移动阅读

**摘要:**煤矿工作面设备通常由多个复杂系统模块组成,各模块间具有强耦合性,且设备故障机理复杂,在进行设备故障预测时需对设备的运行状态、环境数据、操作数据等进行实时监测,从而获取电气、机械、热工类多参数时序数据。提出一种基于时序数据对工作面设备进行故障预测的方法:首先,采用时序对齐算法将采集的设备监测数据对齐,即对监测数据的时间列重新排序,以时间列为关键值,各监测数据作为标签值填入,空缺值以前值填充;然后,根据故障表征现象和发生机理选取故障相关因素,通过 Pearson 相关系数分析法计算相关因素间的相关性,由此确定故障预测因素集;最后,采用长短期记忆(LSTM)网络建立工作面设备故障预测模型,以归一化的故障预测因素集作为 LSTM 预测模型的输入、故障作为输出,将迟滞时间段引入 LSTM 预测模型,实现了迟滞性故障的超前预测。以采煤机过热跳闸故障为例进行试验,通过分析得出故障预测因素集为{滚筒温度,滚筒电流,滚筒启停,牵引温度,变压器温度,摇臂温度},当 LSTM 网络细胞层数为 10、隐藏细胞数为 10、学习率为 0.001、迭代次数为 1 500、1 次读取样本个数为 120 时,采煤机过热跳闸故障的迟滞时间为 30 min,采用测试集进行故障预测时可实现超前 26 min 预测,与迟滞时间相差 4 min,表明采用 LSTM 网络可基于时序数据有效实现工作面设备故障的超前预测。

**关键词:**工作面设备;故障预测;迟滞性故障;时序数据;时序对齐;相关系数分析;长短期记忆网络  
中图分类号:TD67 文献标志码:A

Research on fault prediction of working face equipment based on time series data

ZHENG Lei

(CHN Energy Information Technology Co., Ltd., Beijing 100011, China)

**Abstract:** Coal mine working face equipment are usually consists of several complex system modules that have strong coupling among each other. Moreover, the equipment fault mechanism is complex. Therefore, when the equipment fault prediction is carried out, it is necessary to conduct real-time monitoring of equipment operation status, environmental data and operation data so as to obtain time series data of electrical, mechanical, thermal and other parameters. A method for fault prediction of working face equipment based on time series data is proposed. Firstly, the time series alignment algorithm is used to align the collected equipment monitoring data. The time columns of monitoring data are reordered, and the time columns are the key values. Each monitoring data is filled in as the label value, and the previous value is filled in the vacant value. Secondly, the fault-related factors are selected according to the fault characterization phenomenon and the occurrence mechanism. And the correlation between the relevant factors is calculated by Pearson correlation coefficient analysis method, thereby determining the fault prediction factor set. Finally, the long short-term memory(LSTM) network is used to establish a fault

收稿日期:2021-03-19;修回日期:2021-08-15;责任编辑:李明。

基金项目:国家重点研发计划项目(2017YFC0804307)。

作者简介:郑磊(1980—),男,河北赵县人,高级经济师,硕士,长期从事煤矿安全、信息化及经济管理方面的工作,E-mail:lei.zheng.c@chnenergy.com.cn。

引用格式:郑磊.基于时序数据的工作面设备故障预测研究[J].工矿自动化,2021,47(8):90-95.

ZHENG Lei. Research on fault prediction of working face equipment based on time series data[J]. Industry and Mine Automation, 2021,47(8):90-95.

prediction model for working face equipment. The normalized set of fault prediction factor set is used as the input and the fault is used as the output of the LSTM prediction model. The delay time period is introduced into the LSTM prediction model to realize advanced prediction of delay faults. The test is carried out by taking the shearer overheating trip fault as an example. Through analysis, it is found that the fault prediction factor set is {drum temperature, drum current, drum start and stop, traction temperature, transformer temperature, rocker arm temperature}. When the number of LSTM network cell layers is 10, the number of hidden cells is 10, the learning rate is 0.001, the number of iterations is 1 500, and the number of samples read per time is 120, the delay time of shearer overheating trip fault is 30 min. When the test set is used for fault prediction, the advanced prediction time is 26 min, which is 4 min shorter than the delay time, indicating that the LSTM network can effectively achieve advanced fault prediction of working face equipment based on time series data.

**Key words:** working face equipment; fault prediction; delay time fault; time series data; time series alignment; correlation coefficient analysis; long short-term memory network

## 0 引言

煤矿工作面设备(采煤机、液压支架、刮板输送机)突发故障造成的非计划性停机会影响煤矿正常生产,同时会缩短设备使用寿命,增加生产成本<sup>[1]</sup>。实现工作面设备故障预测及预防性检修,提高设备的可靠性已成为热点研究课题<sup>[2-3]</sup>。

时间序列(时序)分析是一种根据时序数据预测未来发展趋势的方法。时序数据是同一指标按时间顺序记录的数据列,与设备运行相关的时序数据是在设备运行阶段随时间获取的一系列观测数据<sup>[4-5]</sup>。时序分析通常通过数据预处理、建模、预测3个步骤实现趋势预测,在多个领域得到研究和应用。如E. Erdem等<sup>[6]</sup>基于时序数据,采用自回归移动平均值预测风速和风向;蔺茜等<sup>[7]</sup>采用长短期记忆(Long Short-Term Memory, LSTM)网络,根据电力变压器监测时序数据,实现了电力变压器运行状态预测;王超等<sup>[8]</sup>通过分析齿轮箱轴承温度相关的特征时序数据,采用LSTM网络对齿轮箱轴承温度进行预测,并通过滑动窗口对预测残差进行合理

分析,实现了对齿轮箱轴承故障的有效预测。但鲜有时序分析在煤矿工作面设备故障预测中应用的报道。

本文提出基于时序数据对工作面设备进行故障预测。煤矿工作面设备通常由多个复杂系统模块组成,各模块间具有强耦合性,且设备故障机理复杂,因此在进行故障预测时需对设备的运行状态、环境参数、操作数据等进行实时监测,获取电气、机械、热工类多参数时序数据。本文以国家能源集团神东煤炭集团公司上湾煤矿8.8 m大采高综采工作面设备为研究对象,采集设备的多状态时序数据,采用时序数据处理中常用的LSTM网络建立故障预测模型,实现了设备故障的有效预测。

## 1 工作面设备时序数据预处理

上湾煤矿工作面设备各监测点数据均为单序列变化时序数据,根据数据变化记录时间戳,采样时间无规则。以某采煤机4个监测点数据为例,部分时序数据见表1。可看出各组数据对应的时间戳均不相同,形成独特的时序。为便于采用LSTM网络处理数据,需对原始数据进行预处理。

表1 采煤机部分时序数据

Table 1 Part time series data of shearer

时间	破碎臂电流/A	时间	破碎臂温度/℃	时间	牵引速度/(dm·s <sup>-1</sup> )	时间	变压器温度/℃
18:05:12	27.284 040 45	18:05:07	23.289 299 01	18:05:19	7.302 922 058	18:05:44	77.967 796 33
18:05:16	27.031 410 22	18:05:17	24.329 732 89	18:05:26	14.605 844 120	18:05:59	77.772 384 64
18:05:19	26.526 149 75	18:05:19	23.289 299 01	18:05:38	0	18:06:02	78.358 612 06
18:05:29	27.031 410 22	18:05:22	22.248 924 26	18:06:29	14.937 794 490	18:06:05	78.163 200 38
18:05:31	27.536 670 68	18:05:26	23.289 299 01	18:06:35	16.265 599 060	18:06:17	77.967 796 33
18:05:33	27.789 300 92	18:05:43	22.248 924 26	18:06:50	0	18:06:21	77.772 384 64
18:05:52	27.031 410 22	18:05:45	23.289 299 01	18:07:11	0.331 950 998	18:06:37	77.381 568 91
18:05:59	27.536 670 68	18:05:55	22.248 924 26	18:07:15	12.282 186 890	18:06:41	77.576 972 96
18:06:02	27.031 410 22	18:06:04	23.289 299 01	18:07:21	12.946 089 170	18:06:47	77.967 796 33
18:06:05	27.284 040 45	18:06:14	22.248 924 26	18:09:12	0	18:07:01	77.381 568 91
18:06:11	27.536 670 68	18:06:20	24.329 732 89	18:09:28	4.315 362 930	18:07:03	77.576 972 96
18:06:13	27.284 040 45	18:06:24	23.289 299 01	18:09:31	4.979 264 832	18:07:21	77.967 796 33
18:06:33	26.526 149 75	18:06:33	22.248 924 26	18:09:57	7.302 922 058	18:07:32	77.576 972 96

根据表 1 数据,基于时序对齐算法将时序数据对齐并进行前值填充,具体方法:对监测数据的时间列重新排序,以时间列为关键值,各监测数据作为标

签值填入,对某一时刻空缺值以前值进行填充。对齐后的时序数据见表 2。

表 2 对齐后的采煤机部分时序数据

Table 2 Part aligned time series data of shearer

时间	破碎臂电流/A	破碎臂温度/℃	牵引速度/(dm · s <sup>-1</sup> )	变压器温度/℃
18:05:07	—	23.289 299 01	—	—
18:05:12	27.284 040 45	23.289 299 01	—	—
18:05:16	27.031 410 22	23.289 299 01	—	—
18:05:17	27.031 410 22	24.329 732 89	—	—
18:05:19	26.526 149 75	23.289 299 01	7.302 922 058	—
18:05:22	26.526 149 75	22.248 924 26	7.302 922 058	—
18:05:26	26.526 149 75	23.289 299 01	14.605 844 120	—
18:05:29	27.031 410 22	23.289 299 01	14.605 844 120	—
18:05:31	27.536 670 68	23.289 299 01	14.605 844 120	—
18:05:33	27.789 300 92	23.289 299 01	14.605 844 120	—
18:05:38	27.789 300 92	23.289 299 01	0	—
18:05:43	27.789 300 92	22.248 924 26	0	—
18:05:44	27.789 300 92	22.248 924 26	0	77.967 796 33
18:05:45	27.789 300 92	23.289 299 01	0	77.967 796 33
18:05:52	27.031 410 22	23.289 299 01	0	77.967 796 33
18:05:55	27.031 410 22	22.248 924 26	0	77.967 796 33
18:05:59	27.536 670 68	22.248 924 26	0	77.772 384 64
18:06:02	27.031 410 22	22.248 924 26	0	78.358 612 06
18:06:04	27.031 410 22	23.289 299 01	0	78.358 612 06
18:06:05	27.284 040 45	23.289 299 01	0	78.163 200 38
18:06:11	27.536 670 68	23.289 299 01	0	78.163 200 38
18:06:13	27.284 040 45	23.289 299 01	0	78.163 200 38
18:06:14	27.284 040 45	22.248 924 26	0	78.163 200 38
18:06:17	27.284 040 45	22.248 924 26	0	77.967 796 33
18:06:20	27.284 040 45	24.329 732 89	0	77.967 796 33
18:06:21	27.284 040 45	24.329 732 89	0	77.772 384 64
18:06:24	27.284 040 45	23.289 299 01	0	77.772 384 64
18:06:29	27.284 040 45	23.289 299 01	14.937 794 490	77.772 384 64
18:06:33	26.526 149 75	22.248 924 26	14.937 794 490	77.772 384 64
18:06:35	26.526 149 75	22.248 924 26	16.265 599 060	77.772 384 64
18:06:37	26.526 149 75	22.248 924 26	16.265 599 060	77.381 568 91
18:06:41	26.526 149 75	22.248 924 26	16.265 599 060	77.576 972 96
18:06:47	26.526 149 75	22.248 924 26	16.265 599 060	77.967 796 33

## 2 故障预测因素集选取

煤矿工作面设备故障种类多,各故障发生机理不同;单一设备监测点多(可达 120 个),监测数据量大<sup>[9-12]</sup>。针对某一故障选取最合理有效的相关因素是实现故障预测的关键环节。本文以采煤机过热跳闸故障为例进行说明。

通过分析采煤机过热跳闸故障表征现象和发生机理,得出引发过热跳闸故障的相关因素集为{滚筒

温度,滚筒电流,滚筒启停,变频器跳闸状态,牵引温度,变频器设定速度,变压器温度,摇臂温度}。采用 Pearson 相关系数分析法<sup>[13]</sup>对相关因素集进行相关性分析。相关系数为


$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (1)$$

式中: $n$  为采样点数; $x_i, y_i$  分别为 2 种因素在第  $i$  个

采样点的值; $\bar{x}, \bar{y}$  分别为 2 种因素采样值的平均值。

$r$  取值范围为 $[-1, 1]$ ,  $r > 0$  表示存在正相关关系,  $r < 0$  表示存在负相关关系,  $|r| \leq 0.3$  表示不存在线性相关关系,  $0.3 < |r| \leq 0.5$  表示存在低度线性相关关系,  $0.5 < |r| \leq 0.8$  表示存在显著线性相关关系,  $0.8 < |r| < 1$  表示存在高度线性相关关系,  $|r| = 1$  表示存在完全线性相关关系。

根据监测数据, 采煤机过热跳闸故障相关因素间相关系数如图 1 所示。可看出变频器跳闸状态和变频器设定速度与其他因素间相关系数较小, 因此将这 2 个因素舍弃, 将{滚筒温度, 滚筒电流, 滚筒启停, 牵引温度, 变频器设定速度, 变压器温度, 摇臂温度}作为过热跳闸故障预测因素集。



1-滚筒温度; 2-滚筒电流; 3-滚筒启停; 4-变频器跳闸状态;  
5-牵引温度; 6-变频器设定速度; 7-变压器温度;  
8-摇臂温度; 9-过热跳闸。

图 1 采煤机过热跳闸故障相关因素间相关系数

Fig. 1 Correlation coefficients among correlation factors for overheating trip fault of shearer

### 3 基于 LSTM 网络的多状态时序数据预测方法

采用 LSTM 网络对采煤机过热跳闸故障进行预测。以故障预测因素集作为 LSTM 网络输入, 过热跳闸故障作为 LSTM 网络输出。LSTM 网络由递归神经网络发展而来, 其细胞结构如图 2 所示。

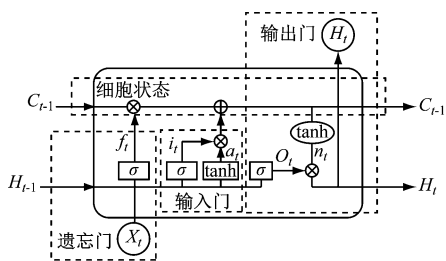


图 2 LSTM 网络细胞结构

Fig. 2 Cell structure of LSTM network

细胞状态为 LSTM 网络的关键要素, 是整个 LSTM 网络的记忆空间。信息是否记忆由控制门控制, 包括遗忘门、输入门和输出门。

遗忘门控制信息是否遗忘, 即以一定的概率控

制是否遗忘上一层的隐藏细胞状态。图 2 中 LSTM 网络细胞单元输入为上一层隐藏细胞状态  $H_{t-1}$  ( $t$  为当前细胞层数) 和本层时序数据  $X_t$ , 通过 sigmoid 激活函数 ( $\sigma$ ) 得到遗忘门输出  $f_t$ 。  $f_t$  在  $[0, 1]$  之间, 其代表遗忘上一层隐藏细胞状态的概率。

输入门负责处理本层细胞的输入, 包括 2 个部分: 第 1 部分使用 sigmoid 激活函数, 输出  $i_t$ ; 第 2 部分使用 tanh 激活函数, 输出  $a_t$ 。

本层细胞状态  $C_t$  由 2 个部分组成: 第 1 部分为上一层细胞状态  $C_{t-1}$  和本层细胞遗忘门输出  $f_t$  的乘积; 第 2 部分为本层细胞输入门的  $i_t$  和  $a_t$  乘积。

本层隐藏细胞状态  $H_t$  的更新由 2 个部分组成: 第 1 部分为由上一层隐藏细胞状态  $H_{t-1}$  和本层时序数据  $X_t$  通过 sigmoid 激活函数得到的  $O_t$ ; 第 2 部分由本层细胞状态  $C_t$  通过 tanh 激活函数得到的  $n_t$ 。二者相乘得到  $H_t$ 。

LSTM 网络训练中要求历史时序与输出时序具有对应关系, 在同一时间段内的时间点保证上下衔接或对等, 即

$$F_k = [T_k, P_k]; F'_k \quad (2)$$

式中:  $F_k$  为数据训练时对应时间段  $k$  的输入与输出间关系;  $T_k$  为输入的故障预测因素集;  $P_k$  为输出故障数据;  $F'_k$  为预测阶段对应时间段  $k$  的输入与输出间关系。

在实际生产中, 迟滞性故障与其相关因素间存在时间累积效应, 即相关因素经过一段迟滞时间后才引发故障。因此故障数据与故障发生前一段时间的相关因素相关。在 LSTM 网络训练阶段引入迟滞时间  $h$ , 将输入的故障预测因素集通过  $h$  与输出故障数据建立联系, 即

$$F_k = [T_k, P_{k+h}]; F'_{k+h} \quad (3)$$

式中:  $P_{k+h}$  为延时  $h$  后的输出故障数据;  $F'_{k+h}$  为预测阶段对应时间段  $k$  延时  $h$  后的输入与输出间关系。

式(3)表明, 预测阶段的输出具有时间段  $h$  的滞后性, 因此确定迟滞时间段  $h$  成为研究重点。

### 4 试验及结果分析

根据采煤机过热跳闸故障预测因素集, 选取实际生产中的 9 000 组数据为训练集, 3 000 组数据为测试集, 正常数据与故障数据比为 10:1。

对数据进行归一化处理, 把数据转换至  $[-1, 1]$  区间, 将各数据绝对值变成相对值, 其实质是一种线性变换, 不会导致数据失效, 反而能提高数据表现。归一化公式如下。

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (4)$$

式中： $x^*$  为归一化时序数据； $x$  为原始时序数据； $x_{max}$ 、 $x_{min}$  分别为原始时序数据最大值、最小值。

示启动,0 表示停止;过热跳闸故障以 0 表示正常,1 表示故障。

部分归一化时序数据见表 3。滚筒启停以 1 表

表 3 部分归一化时序数据  
Table 3 Part normalized time series data

序列	时间	滚筒温度	滚筒启停	滚筒电流	牵引温度	摇臂温度	变压器温度	过热跳闸
1	18:05:07	0.855 012	1	0.285 393	0.971 287	0.748 053	0.618 072	0
2	18:05:16	0.983 311	1	0.221 180	0.881 188	0.677 934	0.619 084	0
3	18:05:26	0.808 008	1	0.137 430	0.886 138	0.277 681	0.617 349	0
4	18:06:19	0.928 589	1	0.157 717	0.866 336	0.438 581	0.617 349	0
5	18:06:22	0.828 589	1	0.110 410	0.906 534	0.485 665	0.623 132	0
6	18:06:27	0.832 362	1	0.151 341	0.831 683	0.510 504	0.622 168	0
7	18:06:57	0.828 589	0	0.173 284	0.831 683	0.563 797	0.619 277	1
8	18:07:10	0.825 759	1	0.101 933	0.838 283	0.390 830	0.623 710	0
9	18:07:34	0.811 610	1	0.100 656	0.830 033	0.537 197	0.623 710	1
10	18:07:44	0.019 534	1	0.113 921	0.815 181	0.056 012	0.623 493	0

设置 LSTM 网络细胞层数为 10,隐藏细胞数为 10,学习率为 0.001,一次读取样本个数为 120。以均方根误差为指标,确定迟滞时间为 60 min。则不同迭代次数下 LSTM 网络迭代损失如图 3 所示。从图 3 可看出,随着迭代次数增加,LSTM 网络迭代损失表现出持续性递减,1 500 次迭代后损失减小速度较小,验证了 LSTM 网络在时序数据下表现出良好的计算性能。确定迭代次数为 1 500,以迟滞时间为变量对 LSTM 网络迭代损失进行计算,结果如图 4 所示。可看出迭代损失最小时迟滞时间为 30 min。




图 4 不同迟滞时间下 LSTM 网络迭代损失  
Fig. 4 Iteration loss of LSTM network under different delay times

数为 1 500,迟滞时间为 30 min,采用测试集进行故障预测,结果如图 5 所示。预测值为[0,1],当预测值有明显上升趋势或达 0.5 以上时,表明实现了故障预测。从图 5 可看出,实际值在 72 min 左右达到 1(发生故障),预测值从 46 min 开始持续上升至 0.5,实现了故障超前 26 min 预测,与设定的故障迟滞时间相差 4 min,验证了模型具有良好的预测效果。




图 5 故障预测结果  
Fig. 5 Fault prediction results




图 3 不同迭代次数下 LSTM 网络迭代损失  
Fig. 3 Iteration loss of LSTM network under different iterations

根据上述结果确定 LSTM 网络训练的迭代次

### 5 结论

(1) 提出采用时序对齐算法对采集的煤矿工作面设备原始时序数据进行对齐及前值填充,形成了完备的基础数据集。

(2) 采用相关性分析验证了故障与其影响因素间的相关性,选取了故障预测因素集。

(3) 建立了工作面设备故障的 LSTM 网络预测模型,根据工作面迟滞性故障与其相关因素间存在时间累积效应的特点,将迟滞时间段引入预测模型,通过试验确定了迟滞时间段,并验证了采用时序数据进行工作面设备故障预测的有效性。

#### 参考文献(References):

- [1] 赵津. 采煤机潜在故障预测和可靠性分析[D]. 太原: 太原理工大学, 2016.  
ZHAO Jin. The potential failure prediction and reliability analysis of drum shearer [D]. Taiyuan: Taiyuan University of Technology, 2016.
- [2] 马昆. 综采工作面“三机”故障诊断系统与信息化控制技术的研究及其应用[J]. 中国煤炭, 2019, 45(4): 82-85.  
MA Kun. Research and application on three-machine fault diagnosis system and information control technology for fully mechanized mining face[J]. China Coal, 2019, 45(4): 82-85.
- [3] 杨一晴, 马宏伟, 樊红卫, 等. 煤矿旋转机械在线故障诊断及预警系统设计[J]. 工矿自动化, 2019, 45(10): 104-108.  
YANG Yiqing, MA Hongwei, FAN Hongwei, et al. Design of online fault diagnosis and early warning system for coal mine rotating machinery[J]. Industry and Mine Automation, 2019, 45(10): 104-108.
- [4] 张天宇. 基于时间序列分析的瓦斯涌出异常识别方法研究[D]. 青岛: 山东科技大学, 2020.  
ZHANG Tianyu. Research on identification method of gas emission anomalies based on time series analysis [D]. Qingdao: Shandong University of Science and Technology, 2020.
- [5] 施龙青, 王雅茹, 邱梅, 等. 时间序列模型在工作面涌水量预测中的应用[J]. 煤田地质与勘探, 2020, 48(3): 108-115.  
SHI Longqing, WANG Yaru, QIU Mei, et al. Application of time series model in water inflow prediction of working face [J]. Coal Geology & Exploration, 2020, 48(3): 108-115.
- [6] ERDEM E, SHI Jing. Arma based approaches for forecasting the tuple of wind speed and direction[J]. Applied Energy, 2010, 88(4): 1405-1414.
- [7] 蔺茜, 陶卿墨, 张清辉. 基于 LSTM 神经网络的电力变压器故障预测模型研究[C]//中国系统仿真与虚拟现实技术高层论坛论文集, 北京, 2020: 60-65.  
LIN Qian, TAO Qingzhao, ZHANG Qinghui. Research on fault prediction model of power transformer based on LSTM neural network [C]// Proceedings of China High Level Forum of System Simulation and Virtual Reality, Beijing, 2020: 60-65.
- [8] 王超, 李大中. 基于 LSTM 网络的风机齿轮箱轴承故障预警[J]. 电力科学与工程, 2020, 36(9): 40-45.  
WANG Chao, LI Dazhong. Fault early warning of fan gearbox bearing based on LSTM network [J]. Electric Power Science and Engineering, 2020, 36(9): 40-45.
- [9] 王国法, 范京道, 徐亚军, 等. 煤炭智能化开采关键技术创新进展与展望[J]. 工矿自动化, 2018, 44(2): 5-12.  
WANG Guofa, FAN Jingdao, XU Yajun, et al. Innovation progress and prospect on key technologies of intelligent coal mining [J]. Industry and Mine Automation, 2018, 44(2): 5-12.
- [10] 智有明. 煤矿机电设备安全故障诊断及维修技术分析[J]. 内蒙古煤炭经济, 2020(3): 119.  
ZHI Youming. Safety fault diagnosis and maintenance technologies of coal mine electromechanical equipment [J]. Inner Mongolia Coal Economy, 2020(3): 119.
- [11] 闫亚恒. 基于 FTA 的煤矿工作面供电系统故障分析[J]. 陕西煤炭, 2019, 38(6): 95-98.  
YAN Yaheng. Failure analysis of power supply system in coal mine workface based on FTA [J]. Shaanxi Coal, 2019, 38(6): 95-98.
- [12] 冯耀东. 羊场湾煤矿进口和国产大采高综采工作面主要设备的故障分析及改进建议[J]. 中国煤炭, 2012, 38(3): 74-76.  
FENG Yaodong. Failures analysis and improvement proposals on imported and domestic main equipments in fully mechanized faces with large cutting height in Yangchangwan Coal Mine [J]. China Coal, 2012, 38(3): 74-76.
- [13] 宋立远, 谭平, 沈德明, 等. 自变量关联性对故障诊断相关特征的影响分析[J]. 电站系统工程, 2021, 37(4): 22-24.  
SONG Liyuan, TAN Ping, SHEN Deming, et al. Influence of correlation of independent variables on the correlation features of fault diagnosis [J]. Power System Engineering, 2021, 37(4): 22-24.