

文章编号:1671-251X(2024)S2-0167-06

基于粗糙集-径向基神经网络的采煤机滚筒 智能调高决策模型

吴文前¹, 甄葳棋¹, 门少斌², 赵龙龙²

(1. 延安车村煤业(集团)有限责任公司, 陕西 延安 717300;

2. 延安市禾草沟二号煤矿有限公司, 陕西 延安 717300)

摘要:针对传统的采煤机记忆截割方法难以实现对采煤机滚筒高度自适应控制,以及响应速度慢和跟踪性能差等问题,提出了一种基于粗糙集-径向基(RBF)神经网络的采煤机滚筒智能调高决策模型。首先,采用粗糙集理论对采煤机运行状态特征参数进行约简,并建立采煤机滚筒调高决策规则库。然后,设计一种基于属性重要度的采煤机滚筒智能调高决策规则选择算法,获取采煤机调高的决策规则。最后,以选择的决策规则为数据集,采用 RBF 神经网络构建采煤机智能调高决策模型,实现采煤机滚筒高度调整的智能决策。利用某矿 1123 智能综采工作面采煤机实际运行数据,对该模型的调高性能进行分析,结果表明:粗糙集-RBF 神经网络模型的采煤机滚筒调高决策准确率为 81.67%,与支持向量机(SVM)、极限学习机(ELM)和梯度提升决策树(GBDT)模型相比,准确率分别提升了 11.6%、17.1%和 9.1%。

关键词:煤炭开采;采煤机;滚筒调高;粗糙集;RBF 神经网络

中图分类号:TD632.1 文献标志码:A

Decision model of shearer drum intelligent height adjustment based on rough set-RBF neural network

WU Wenqian¹, ZHEN Weiqi¹, MEN Shaobin², ZHAO Longlong²

(1. Yan'an Checun Coal Industry (Group) Co., Ltd., Yan'an 717300, China;

2. Yan'an Hecaogou No.2 Coal Mine Co., Ltd., Yan'an 717300, China)

0 引言

煤矿智能化是煤炭工业高质量发展的核心技术支撑,是煤炭工业技术革命和升级发展的必然方向,而综采智能化是煤矿智能化的核心。采煤机作为综采工作面的核心装备,其智能高效截割是实现综采智能化的基础保障^[1-2]。煤矿井下地质条件十分复杂,煤层赋存状态多变,顶底板高度起伏变化的不确定性,给煤矿井下采煤机滚筒高度的自适应调节造成了极大困扰^[3-4]。为解决采煤机滚筒智能调高问题,学者们采用煤岩识别技术,如 γ 射线探测技术^[5]、雷达探测技术^[6]、图像识别^[7]及多源信息融合^[8]等,感知煤层赋存状态,为采煤机滚筒调高提供决策依据。然而,综采工作面地质条件复杂且煤岩属性多变,导致这些技术的实用性不强,未获得良好的工程应用。为解决此问题,研究者提出记忆截割

这一间接方法实现采煤机滚筒自动调高。Li Wei 等^[9]提出利用灰色马尔可夫组合模型的采煤机自适应记忆截割策略,显著提升了采煤机自动化水平。陈伟华等^[10]提出了基于深度学习的采煤机截割轨迹预测方法,提升了采煤机滚筒的截割轨迹预测精度。王雅东等^[11]提出了一种基于深度确定性策略梯度算法的采煤机滚筒自适应调高控制策略,并验证了该控制策略的可行性。记忆截割技术虽然在一定程度上减少了井下施工人员、提高了采煤机自动化程度,但由于综采工作面复杂环境及煤岩界面的剧烈变化等原因,导致传统记忆截割的记忆路径出现失效问题,依赖人工干预,存在截割精度低的缺点。

本文考虑采煤机工作状态和环境的不确定性,以及调高控制过程的非线性,将粗糙集与径向基函数(Radial Basis Function, RBF)神经网络相结合,

收稿日期:2023-07-13;责任编辑:盛男。

基金项目:陕西省厅市联动重点项目(2022GD-TSLD-63, 2022GD-TSLD-64)。

作者简介:吴文前(1966—),男,陕西安塞人,高级工程师,主要从事煤矿开采技术研究工作, E-mail:1279490327@qq.com。

构建基于数据驱动的采煤机滚筒智能调高模型。对采煤机运行特征参数进行优选,采用决策规则约简算法提取滚筒调高决策规则,进而将决策规则用于 RBF 神经网络训练,构建高精度的采煤机滚筒调高决策模型,实现采煤机滚筒智能调高。

1 采煤机滚筒智能调高技术框架

采煤机滚筒智能调高技术框架如图 1 所示。以实现采煤机滚筒精确调高为目标,采用粗糙集理论与 RBF 神经网络结合的数据驱动方法,分析采煤机截割电流、电压、温度、牵引速度及采煤机机身位置等与采煤机滚筒高度相关的运行特征参数信息,构建采煤机滚筒调高决策数据库与决策规则提取算法,通过 RBF 神经网络对选择的决策规则进行训练学习,实现规则前件与规则后件间的非线性映射,进一步实现采煤机滚筒高度预测。




图 1 采煤机滚筒智能调高技术框架

2 基于粗糙集-RBF 神经网络的采煤机滚筒智能调高决策模型

2.1 属性约简

基于属性的重要性^[12],依次计算各条件属性的依赖度和重要性,为后续决策规则的优选提供依据。实现采煤机滚筒调高状态参数属性约简过程如下:

1) 将采煤机及滚筒状态属性域 U 进行等价类划分,本研究采用基于重要度的属性约简算法对属性集 C 与滚筒调高决策 D 划分,得等价类 $\text{ind}(C) = \{c_1, c_2, \dots, c_n\}$, $\text{ind}(D) = \{d_1, d_2, \dots, d_m\}$ 。

2) 计算滚筒调高决策 D 关于条件属性集 C 的依赖度。

$$r(C, D) = \frac{|\text{POS}_C(D)|}{|U|} \quad (1)$$

3) 计算去除某一属性 c_i 的条件属性 C 对滚筒决策高度 D 的重要度。

$$r(C - c_i, D) = \frac{|\text{POS}_{C - \{c_i\}}(D)|}{|U|} \quad (2)$$

4) 计算条件属性 c_i 的对于决策属性 D 的重要度。

$$\text{sig}(c_i, C, D) = r(C, D) - r(C - c_i, D) \quad (3)$$

式(3)表示去掉条件属性 c_i 后,单一因素 c_i 影响采煤机滚筒调高决策的程度,即 c_i 对决策属性 D 的重要度。计算条件属性集 C 相对于决策属性 D 的核 $\text{CORE}_D(C)$,令 $B = \text{CORE}_D(C)$ 。

5) 计算条件 c_i 对 B 对于决策属性 D 的分类能力的影响。

$$\text{sig}(c_i, B, D) = r(B, D) - r(B - c_i, D) \quad (4)$$

$\text{sig}(c_i, B, D)$ 表示去掉条件属性 c_i 不影响条件属性集 B 对决策属性 D 的分类能力,即条件属性 c_i 为一个冗余属性。 $\text{sig}(c_i, B, D)$ 的值越大说明条件属性 c_i 越重要, c_i 对于 B 对 D 的分类效果影响越大。

2.2 决策规则提取算法

属性约简后,通过值约简生成决策规则库,决策规则提取算法根据采煤机运行状态的历史数据从规则库中选择部分规则。选取合适的决策规则对建立采煤机滚筒调高决策模型至关重要。由于不同条件属性对决策规则的选择影响不同,所以在进行采煤机滚筒调高决策时,需要考虑决策规则表中各属性的权重,弥补传统采煤机滚筒调高决策方法对属性重要性考虑的不足。采用式(5)选择采煤机滚筒调高的决策规则:

$$\text{dist}(M(t), r) = \sqrt{\sum_{c \in \text{RED}} w_c (M(c, t) - r(c))^2} \quad (5)$$

式中: c 为条件属性集 RED 中的属性; w_c 为决策规则表中 c 属性的权重,该权重可以用条件属性集 DEP 中属性 c 的判别来表示; $M(c, t)$ 为在 t 时刻采集的实时数据 $M(t)$ 中 c 属性的值; $r(c)$ 为规则 r 中 c 属性的值。

对于属性 c ,其判别定义为

$$d_{\text{DEP}}(c) = \frac{|U/\text{DEP}| - |U/(\text{DEP} - \{c\})|}{|U/\text{DEP}|} \quad (6)$$

式中 $|U/\text{DEP}|$ 为属性集 DEP 上等价类的个数, $U/\text{DEP} = U/\text{ind}(\text{DEP}) = \{c_1, c_2, \dots, c_n\}$ 。

属性 c 的权重为

$$w(c) = d_{\text{DEP}}(c) / \sum_{c \in \text{DEP}} d_{\text{DEP}}(c) \quad (7)$$

采煤机滚筒调高决策规则选择算法描述如下。

步骤 1: 基于属性重要度计算加权距离 $\text{dist}(M(t), r)$ 。

步骤 2: 选择满足 $\text{dist}(M(t), r) < \text{dist}_t$ 条件的采煤机滚筒调高规则 r ,若小于给定规则数量阈值,则增加阈值 $\text{dist}_t = \text{dist}_t + \text{inc}$,若被选择规则过多,大于给定规则数量阈值 rule_m ,则 $\text{dist}_t = \text{dist}_t - \text{inc}$ 。

步骤 3: 计算所选决策规则中 3 个决策属性的规则数,选择规则数最多的决策属性作为最终决策

结果。

为建立准确的采煤机滚筒智能调高决策模型,通过调整加权距离阈值 dist_i 、数量阈值 rulem_i 和决策因子 inc ,对约简生成的初始决策规则库进行决策规则筛选。通过决策规则选择算法,将筛选得到的决策规则集的条件属性作为 RBF 神经网络的输入,采煤机滚筒高度调整模式作为 RBF 神经网络的输出,训练并得到采煤机滚筒智能调高决策模型。

2.3 采煤机滚筒调高决策模型

RBF 神经网络是一种典型的 3 层前馈神经网络,具有良好的非线性逼近能力,且结构简单,适合采煤机滚筒高度调节的非线性映射^[13]。多输入单输出 RBF 神经网络结构如图 2 所示。




图 2 多输入单输出 RBF 神经网络结构

RBF 神经网络包括输入层、隐层和输出层,其输入 $X=(x_1, x_2, \cdots, x_n)$,输出 $Y=(y_1, y_2, \cdots, y_m)$ 。RBF 神经网络输出层的第 k 个神经元输出可定义为

$$\hat{y}_k = \sum_{i=1}^h \omega_{ik} \varphi_j(x) \tag{8}$$

式中: h 为隐层神经元个数; ω_{ik} 为第 k 个输出层与第 i 个隐层神经元之间的连接权值,一般采用 Gauss 函数为隐层激活函数。

$$\varphi_i(x) = \exp\left(-\frac{|x-\mu_i|}{2\sigma_i^2}\right) \tag{9}$$

式中: x 为 n 维输入样本; μ_i 为第 i 个 Gauss 函数的中心; σ_i 为第 i 个 Gauss 函数的宽度,表示以 μ_i 为中心点的基函数的宽度。

在采煤机滚筒高度调节决策中,RBF 神经网络的输入对应决策规则选择算法挑选出的决策规则的前件,即条件属性,表示采煤机运行状态;RBF 神经网络的输出对应决策规则的后件,即决策属性,表示采煤机滚筒高度的调节模式。基于粗糙集-RBF 神经网络的采煤机滚筒调高决策模型结构如图 3 所示。

3 实验验证

3.1 初始特征参数确定

实验数据集来自于陕西延安禾草沟煤业有限公




图 3 基于粗糙集-RBF 神经网络的采煤机滚筒调高决策模型结构

司 1123 综采工作面,工作面长度为 260 m,煤层平均厚度为 1.6 m,倾斜度为 $0\sim 3^\circ$,属于薄煤层综采工作面。综采工作面设备配套:液压支架采用 ZZ4000/6.5/13D 四柱掩护式,采煤机采用 MG200/468-WD 型,刮板输送机选择 SGZ630/264 型。数据采集时间为 2022 年 11 月 7 日—23 日,采样周期为 1.0 s。采煤机运行状态监测参数包括电流、温度、速度等传感数据,且数据类型多样。综采工作面集中监控系统能够方便地采集和存储数据。原始数据集包括 10 组条件属性和 1 组决策属性,样本总数为 16 860。采煤机运行状态监测参数见表 1。

表 1 采煤机状态监测参数

特征标志	特征名称	特征值类型	单位
c_1	采煤机机身位置	数值	m
c_2	俯仰角	数值	°
c_3	牵引温度	数值	℃
c_4	牵引电流	数值	℃
c_5	牵引方向	布尔型	左/右
c_6	牵引速度	数值	m/min
c_7	截割电机温度	数值	℃
c_8	截割电机电流	数值	A
c_9	滚筒高度	数值	m
c_{10}	横滚角	数值	°
D	滚筒高度变化	数值	m

在表 1 中,采煤机俯仰角和滚筒横滚角 2 个特征变量反映了工作面底板的波动变化,采煤机机身位置反映了采煤机实时机身位置,这 3 个特征属性在一定程度上反映了采煤机的空间位置状态。采煤机滚筒的高度反映了工作面顶板的起伏。因此,表 1 不仅描述了采煤机的运行条件,而且在一定程度上描述了工作面的环境条件。

3.2 数据预处理

原始样本数据中有部分数据缺失、异常。对于一维数据缺失的样本,本文使用拉格朗日插值对缺失值进行插补,而对于一个采样点存在多属性缺失

或异常,为保障准确性,会删除该样本。由于电气故障或传感器故障,遇到一些异常值是不可避免的。根据这些异常数据的实际特点,将其作为缺失值处理或使用平均值进行修正,并删除一部分。

经过上述处理后,数据样本消除了采样点存在的属性值缺失、异常。滚筒调高数据集包含的数据大小为 10 935,由属性集 $\{c_1-c_{10},D\}$ 构成的数据集为初始决策规则表。

3.3 属性约简及决策规则库建立

通过 K-means 法将初始化决策规则库每个特征参数离散化。利用特征约简方法对离散后的初始化决策规则表约简。各条件属性约简结果见表 2、表 3。

表 2 条件属性 c 相对决策属性 D 的分类能力					
属性	c_1	c_2	c_3	c_4	c_5
$\text{sig}(c_i,C,D)$	0.471	0.174	0	0.264	0.026
属性	c_6	c_7	c_8	c_9	c_{10}
$\text{sig}(c_i,C,D)$	0.216	0.083	0	0.274	0.151

表 3 条件属性 c 相对核属性 B 影响决策属性 D 的分类能力					
属性	c_1	c_2	c_4	c_5	
$\text{sig}(c_i,B,D)$	0.470	0.091	0.233	0	
属性	c_6	c_7	c_9	c_{10}	
$\text{sig}(c_i,B,D)$	0.116	0	0.237	0.062	

由表 2 可知,经过离散化后的初始化决策规则表条件属性 c_3,c_7 对于决策属性 D 的重要度为 0,因此滚筒条件属性 C 相对于决策属性 D 的核为 $\{c_1,c_2,c_4,c_5,c_6,c_7,c_9,c_{10}\}$ 。

由表 3 可知,从核属性集 B 中删除条件属性 c_5,c_{12} 并不影响 B 对于 D 的分类能力,因此左滚筒条件属性集最终属性约简结果为 $P_l=\{c_1,c_2,c_4,c_6,c_9,c_{10}\}$ 。

通过属性约简的初始化决策表,合并相似决策规则,共获取 6 648 条采煤机调高决策规则,生成决策规则库,见表 4。

由表 4 可知,通过不同的条件属性的值,如采煤机机身位置、俯仰角、牵引电流等,可对应得出采煤机滚筒调高决策——上升、下降或不变。

3.4 结果分析

整个样本数据(决策规则)按 9:1 比例被分为训练集和测试集。使用 Matlab R2018b 进行程序开发,在 Intel(R)Core(TM)i5-6500CPU@ 3.20 GHz, 16.0 GiB RAM 硬件平台和 Windows10 64 位操作系统上执行相关实验。采用准确率(Accuracy)、精确率(Precision)、召回率(Recall)对采煤机滚筒调

表 4 采煤机滚筒调高决策规则库	
序号	采煤机滚筒调高决策规则库
1	$c_1(6) \text{ AND } c_2(3) \text{ AND } c_4(7) \text{ AND } c_6(1) \text{ AND } c_9(1) \text{ AND } c_{10}(9) = D(0)$
2	$c_1(4) \text{ AND } c_2(8) \text{ AND } c_4(4) \text{ AND } c_6(7) \text{ AND } c_9(3) \text{ AND } c_{10}(9) = D(0)$
3	$c_1(1) \text{ AND } c_2(1) \text{ AND } c_4(9) \text{ AND } c_6(5) \text{ AND } c_9(1) \text{ AND } c_{10}(6) = D(0)$
4	$c_1(4) \text{ AND } c_2(1) \text{ AND } c_4(4) \text{ AND } c_6(7) \text{ AND } c_9(8) \text{ AND } c_{10}(3) = D(0)$
$\vdots$	$\vdots$
2 897	$c_1(2) \text{ AND } c_2(4) \text{ AND } c_4(1) \text{ AND } c_6(2) \text{ AND } c_9(8) \text{ AND } c_{10}(4) = D(1)$
2 898	$c_1(8) \text{ AND } c_2(1) \text{ AND } c_4(1) \text{ AND } c_6(6) \text{ AND } c_9(8) \text{ AND } c_{10}(1) = D(1)$
2 899	$c_1(2) \text{ AND } c_2(4) \text{ AND } c_4(3) \text{ AND } c_6(8) \text{ AND } c_9(4) \text{ AND } c_{10}(5) = D(1)$
2 900	$c_1(2) \text{ AND } c_2(3) \text{ AND } c_4(3) \text{ AND } c_6(5) \text{ AND } c_9(2) \text{ AND } c_{10}(5) = D(1)$
$\vdots$	$\vdots$
6 645	$c_1(1) \text{ AND } c_2(4) \text{ AND } c_4(3) \text{ AND } c_6(1) \text{ AND } c_9(6) \text{ AND } c_{10}(5) = D(-1)$
6 646	$c_1(6) \text{ AND } c_2(5) \text{ AND } c_4(3) \text{ AND } c_6(2) \text{ AND } c_9(7) \text{ AND } c_{10}(5) = D(-1)$
6 647	$c_1(2) \text{ AND } c_2(4) \text{ AND } c_4(2) \text{ AND } c_6(11) \text{ AND } c_9(8) \text{ AND } c_{10}(3) = D(-1)$
6 648	$c_1(3) \text{ AND } c_2(4) \text{ AND } c_4(1) \text{ AND } c_6(11) \text{ AND } c_9(8) \text{ AND } c_{10}(5) = D(-1)$

高决策分类性能进行评价,采用平均绝对误差(MAE)、平均绝对百分误差(MAPE)、均方根误差(RMSE)对采煤机滚筒高度预测精度进行评价^[14]。

采用对比实验验证基于粗糙集-RBF 神经网络的采煤机滚筒调高智能决策模型的有效性和可行性。将采煤机滚筒的调高决策过程视为模式分类过程,采煤机调高模式见表 5。

表 5 采煤机调高模式			
输出	模式 1	模式 2	模式 3
1	滚筒上调	—	—
0	—	滚筒保持	—
-1	—	—	滚筒下调

将支持向量机(Support Vector Machine, SVM)、极限学习机(Extreme Learning Machine, ELM)和梯度提升决策树(Gradient Boosting Decision Tree,GBDT)3 种采煤智能调高分类模型

与本文的粗糙集-RBF 神经网络模型进行对比实验。通过反复实验,确定核函数为高斯核函数,惩罚系数 $C=151$ 、核参数 $g=0.18$ 作为 SVM 的训练参数;采用 Sin 函数确定 ELM 的隐层节点数为 368;GBDT 的子树数量越高,其精度越高,但训练子树个数过多容易导致过拟合,最终确定 GBDT 最佳训练树个数为 29。按照上述参数设置,得到 4 种模型下采煤机滚筒调高决策分类结果,见表 6。

表 6 4 种模型的采煤机滚筒决策分类性能对比 %				
评价指标	SVM	ELM	GBDT	粗糙集-RBF 神经网络
准确率	73.19	69.75	74.87	81.67
精确率	72.88	66.91	76.45	82.17
召回率	75.51	67.36	78.21	77.32

从表 6 可看出,粗糙集-RBF 神经网络模型对采煤机滚筒调高决策分类的准确率最高,为 81.67%。与 SVM、ELM 和 GBDT 模型相比,粗糙集-RBF 神经网络模型对采煤机滚筒调高决策分类的准确率分别提升了 11.6%,17.1%,9.1%。

采用基于粗糙集-RBF 神经网络的采煤机滚筒智能调高模型进行模式分类的结果如图 4 所示。可

看出,在用于测试的 120 个样本点中,粗糙集-RBF 神经网络模型对采煤机滚筒调高决策分类基本正确。对于采煤机滚筒上升阶段的 54 个样本点,共有 45 个正确预测分类点;对于采煤机滚筒不调整阶段的 30 个样本点,共有 23 个正确预测分类点;对于采煤机滚筒下降阶段的 36 个样本点,共有 29 个正确预测分类点。对采煤机滚筒调高决策分类的正确率为 80.8%。




图 4 采煤机滚筒调高决策分类结果

基于上述 4 个模型的模式分类结果,拟合采煤机滚筒高度曲线,得到采煤机滚筒高度预测曲线,如图 5 所示。总体来看,粗糙集-RBF 神经网络模型对采煤机滚筒高度的预测曲线与人工调整滚筒高度曲线较为拟合,对于采煤机滚筒调高决策的预测误差小于 0.05 m。




图 5 4 种采煤机滚筒调高模型预测结果

4 结论

- 1) 采用粗糙集属性约简方法,从采煤机运行状态监测参数中选择能够反映采煤机滚筒调高的关键特征参数,进而建立了采煤机滚筒调高决策规则库。
- 2) 提出了一种加权属性重要度的采煤机滚筒

- 调高决策规则优选算法,该算法依据历史数据选择出采煤机滚筒调高最优决策规则,为建立采煤机滚筒调高决策模型提供了数据支撑。
- 3) 设计了基于粗糙集-RBF 神经网络的采煤机滚筒调高模型,该模型以最优规则集为训练数据集。实验结果表明:与 SVM、ELM 和 GBDT 模型

相比,提出的模型预测决策分类精度更高,达 81.67%,能较好地预测采煤机滚筒的调高决策分类。

参考文献:

[1] 刘峰,曹文君,张建明.持续推进煤矿智能化促进我国煤炭工业高质量发展[J].中国煤炭,2019,45(12):32-36.

[2] 王国法,刘峰,庞义辉,等.煤矿智能化——煤炭工业高质量发展的核心技术支撑[J].煤炭学报,2019,44(2):349-357.

[3] 赵丽娟,王雅东,张美晨,等.复杂煤层条件下采煤机自适应截割控制策略[J].煤炭学报,2022,47(1):541-563.

[4] 徐志鹏,王忠宾,米金鹏.采煤机自适应记忆切割[J].重庆大学学报,2011,34(4):134-140.

[5] BESSINGER S L,NELSON M G.Remnant roof coal thickness measurement with passive gamma ray instruments in coal mines[J].IEEE Transactions on Industry Applications,1993,29(3):562-565.

[6] BAUSOV I Y,STOLARCZYK G L,STOLARCZYK L G,et al.Look-ahead radar and horizon sensing for coal cutting drums [C].The 4 th International Workshop on Advanced Ground Penetrating Radar,Aula Magna Partenope,2007:208-211.

[7] 孙继平,余杰.基于小波的煤岩图像特征抽取与识别[J].煤炭学报,2013,38(10):1900-1904.

[8] 王海舰,黄梦蝶,高兴宇,等.考虑截齿损耗的多传感信息融合煤岩界面感知识别[J].煤炭学报,2021,46(6):1995-2008.

[9] LI Wei,LUO Chengming,YANG Hai,et al.Memory cutting of adjacent coal seams based on a hidden Markov model[J].Arabian Journal of Geosciences,2014,7(12):5051-5060.

[10] 陈伟华,南鹏飞,闫孝姮,等.基于深度学习的采煤机截割轨迹预测及模型优化[J].煤炭学报,2020,45(12):4209-4215.

[11] 王雅东,赵丽娟,张美晨.采煤机自适应调高控制策略[J].煤炭学报,2022,47(9):3505-3522.

[12] PAWLAK Z.Rough sets[J].International Journal of Computer and Information Science,1982,11:341-356.

[13] 王晓卫,魏向向,侯雅晓,等.基于小波去噪与改进 RBF 神经网络的小电流接地系统故障选线方法[J].工矿自动化,2014,40(4):46-50.

[14] SUN Lin,YIN Tengyu,DING Weiping,et al.Feature selection with missing labels using multilabel fuzzy neighborhood rough sets and maximum relevance minimum redundancy [J].IEEE Transactions on Fuzzy Systems,2022,30(5):1197-1211.

(上接第 160 页)

[33] 杨延栋,陈馈,李凤远,等.盘形滚刀磨损预测模型[J].煤炭学报,2015,40(6):1290-1296.

[34] 曾锋,苏华友,宋天田.复合地层中盾构机滚刀寿命预测研究[J].地下空间与工程学报,2016,12(增刊 2):755-759.

[35] 孙汝继,王水生,王海舰.掘进机截齿磨损程度分析及识别方法[J].工矿自动化,2016,42(12):68-71.

[36] 刘吉洋.全断面岩石掘进机盘形滚刀寿命预测及管理软件开发[D].北京:华北电力大学,2009.