

# 基于 CNN-SVM 卷积神经网络煤矿机电 设备安全评价方法

Safety Evaluation Method for Coal Mine Electromechanical Equipment Based on  
CNN-SVM Convolutional Neural Network

兰德兴(煤炭工业石家庄设计研究院有限公司贵州分公司, 贵州 贵阳 550001)

**摘要:**煤矿机电设备是直接影响煤炭产出效率的重要因素,为准确预测煤矿机电设备安全评价等级,提出了三个主要影响因素,分别为企业组织管理因素、煤矿井下环境因素与机电设备状态因素,并建立了四个安全评价等级指标,构建了 CNN-SVM 模型对具有多向量的煤矿机电设备因素特征值进行分类预测。结果表明:CNN-SVM 模型与 CNN-GRU 模型、CNN-BiLSTM 模型的训练及预测结果相似,均为安全等级Ⅲ的预测准确率略低,但该模型的安全等级Ⅲ的预测准确率要高于上述两种模型,特别是在测试集预测结果中,安全等级Ⅲ的预测准确率为 96.3%,远低于 CNN-GRU 模型、CNN-BiLSTM 模型的 77.8%、88.9%,CNN-SVM 模型对煤矿机电安全评价等级的整体预测准确率要高于其他两种模型,模型预测结果与实际评价结果基本吻合。

**关键词:** CNN-SVM 卷积神经网络; 煤矿机电设备; 安全评价

中图分类号: TD529

文献标志码: A

文章编号: 1672-609X(2025)02-0015-05

**Abstract:** Coal mine electromechanical equipment is an important factor that directly affects coal production efficiency. In order to accurately predict the safety evaluation level of coal mine electromechanical equipment, three main influencing factors are proposed, namely enterprise organizational management factors, coal mine underground environmental factors, and electromechanical equipment status factors. Four safety evaluation level indicators are established, and a CNN-SVM model is constructed to classify and predict the characteristic values of coal mine electromechanical equipment factors with multiple vectors. The results showed that the training and prediction results of CNN-SVM model were similar to those of CNN-GRU model and CNN BiLSTM model, both of which had slightly lower prediction accuracy for safety level III. However, the prediction accuracy of this model for safety level III was higher than the above two models. Especially in the test set prediction results, the prediction accuracy of safety level III was 96.3%, far lower than the 77.8% and 88.9% of CNN-GRU model and CNN BiLSTM model. The overall prediction accuracy of CNN-SVM model for coal mine electromechanical safety evaluation level was higher than the other two models, and the model prediction results were basically consistent with the actual evaluation results.

**Key words:** CNN-SVM convolutional neural network; coal mine electromechanical equipment; safety evaluation

## 1 前言

煤矿机电安全评价方法是保证煤矿安全高效生产的重要环节之一<sup>[1-3]</sup>。对于煤矿企业,煤矿机电设备是直接影响煤炭产出效率的最重要因素之一,煤炭企业在保证煤炭生产达标的同时,也需要保证煤矿机电设备的安全可靠性。然而,在实际煤炭生产过程中,煤矿机电设备安全运行受多方面因素影响,煤矿企业的人员管理水平对煤炭生产效率、能力等有重要影响,此外,煤矿井下条件复杂,煤矿机电

设备的长时间运行可能导致煤矿设备的意外故障发生,煤矿设备发生故障直接影响到煤炭的生产效率,严重可能导致煤矿发生事故,因此,煤矿环境因素及机电设备运行状况也是影响煤矿机电设备安全的重要因素。目前,国内外学者对煤矿机电设备的安全评价方法进行了诸多研究,其中,常用的评价方法为数学方法及神经网络分类预测方法,采用数学方法评价时,其影响因素的选取、权重的确定是影响最终评价结果的重要指标,但实际计算最终的分类指标时,各影响因素及权重的选取与最终的分类指标值有非常明显的线性关系,然而,煤矿机电设备运行时,各影响因素与煤矿机电安全分类间是显著的非线性关系,因此,采集大量数据,通过构建算法建立神经网络预测模型具有较高的分类精度。吴少杰采用了多种神经网络评价模型对煤矿机电设备进行分

[作者简介] 兰德兴(1983—), 贵州桐梓人, 本科, 工程师, 从事机电管理方面相关工作。

[基金项目] 贵州省科技计划项目(黔科合成果[2020]2Y019)

[引用格式] 兰德兴. 基于 CNN-SVM 卷积神经网络煤矿机电设备安全评价方法[J]. 中国矿山工程, 2025, 54(2): 15-19.

类预测,对现有模型进行分析得出了模型的不足,构建了双 MapReduce 预测模型<sup>[4]</sup>。邢志刚等针对以往对煤矿机电安全设备评价方法的权重难确定、影响因素少及构建的预测模型算法单一、精度较低的问题,构建了 AHP-TOPSIS 预测模型,该模型能有效分类预测煤矿机电设备的安全等级,模型精度高,符合煤矿现场机电设备的实际运行情况<sup>[5]</sup>。王辉针对现有煤矿机电设备数据量大,部分数据存在噪点降低了预测效率的问题,利用了 Hadoop 平台完成数据高效管理,并提出了具有时间序列特征的 BP 预测模型,并实践于实际工程矿井,结果表明模型精度高且具有较高的泛化能力<sup>[6]</sup>。

本文为准确预测出煤矿机电设备的安全状态,以煤炭企业组织管理、煤矿设备的运行环境及机电设备运行状态为影响因素,并构建 CNN-LSTM 卷积神经网络安全评价模型,从而实现煤矿机电设备的安全评价。

## 2 构建评价模型

确定合理的评价因素是准确评价煤矿机电设备安全状态的重要因素之一,基于前人的研究成果,总结出了三个主要影响因素,分别为企业组织管理因素、煤矿井下环境因素与机电设备状态因素,企业管

理是影响机电设备安全状态的重要影响因素之一,好的企业管理水平能直接影响到机电设备的运行状态,且对于机电设备发生异常故障后,企业管理的重视程度等也是影响机电设备安全状态的重要因素之一。对于煤矿机电设备,多数设备均位于煤矿井下,然而,多数煤矿井下环境较差,巷道中长时间存在大量灰尘或存在高湿度空气等,这些因素直接影响了机电设备的使用寿命,从而造成机电设备的故障异常。此外,机电设备本身状态是机电设备能否安全运行最重要因素,包括了机电设备本身质量、设备使用时长、设备使用频率、设备检修水平四个次要因素。因此,根据上述三个主要因素共划分了 12 个次要因素,从而构建出了煤矿机电安全评价指标体系,具体如图 1 所示。确定影响煤矿机电安全状态的影响因素后,需要构建安全评价等级指标以确定机电设备的安全运行状态,本文构建了四个安全评价等级,分别为危险 I、较危险 II、较安全 III 与安 IV 全四个等级,其中等级 I 评分为 0~60,等级 II 评分为 60~70,等级 III 评分为 70~85 分,等级 IV 评分为 85~100,此外,需要确认划出的 12 个次要因素特征值,即邀请专家对该 12 个次要因素特征赋值。

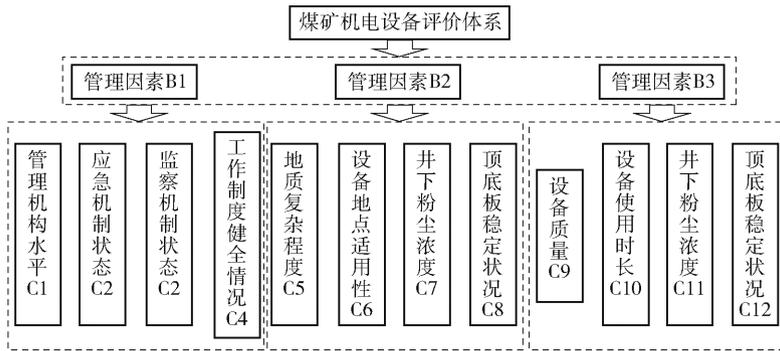


图 1 煤矿机电设备安全评价指标体系图

## 3 CNN-SVM 卷积神经网络

### 3.1 CNN-SVM 卷积神经网络预测原理

采用 CNN-SVM 卷积神经网络预测煤矿机电设备运行状态安全评价的原理为首先需要提出各影响因素的特征指标值,利用 CNN 神经网络中的卷积层降低数据维度,得到准确的煤矿机电设备的运行状态训练结果数据,最后通过经典支持向量机(SVM)分类器处理输出得到的训练结果数据,对该数据进行分类处理,即评价该机电设备的安全运行状态,得到其风险评价等级。

### 3.2 构建 CNN-SVM 评价模型

由于传统的 CNN 模型具有较强的数据特征提

取能力,但在处理较为复杂的数据时的分类效果较差,特别是在处理较为非线性数据时常出现过拟合现象,而 SVM 模型在处理高维度的数据时具有较好的泛化能力,但在处理大量的数据时会出现维数灾难问题,因此,本文结合 CNN 模型与 SVM 模型的优点,构建出 CNN-SVM 模型,对具有多向量的煤矿机电设备因素特征值进行分类预测。

本文对影响煤矿机电的三个主要因素分成了十二个次要影响因素,因此,在确定该机电设备的安全评价等级时,需要将通过专家评分得到的 12 个特征值进行特征提取,作为输入数据,CNN 是一种人工神经网络,利用卷积运算达到数据非线性变化的目

的。在 CNN 结构中,嵌入层作为一个矩阵,能够实现数据状态向量的排序;卷积层通过运算可获得很多种特征映射,再传输到池化层减少数据维度;池化层最后与全连接层相连,输出训练好的机电设备运行状态结果数据,通过全连接层输出数据后导入至 SVM 模型中,最终得到安全评价等级。

SVM 分类器是线性模型分类器,当采用 SVM 分类非线性数据时,SVM 分类器将非线性数据映射到高维空间中使不可分的非线性数据成为线性可分,假设存在线性可分数据  $T = \{(x_a, y_a)\}, a = 1, 2, 3, \dots, N$ , 其中  $x_a$  是样本矩阵,  $y_a$  是样本标签, 而线性 SVM 分类器通过构建一个超平面  $\omega x + b = 0$ , 其中  $\omega$  为该超平面的法向量,  $b$  为偏置, 则支持向量回归优化模型的表达式为

$$\begin{aligned} \min & \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^m (\xi_a + \xi_a^*) \\ \text{s. t.} & \begin{cases} y_i - \omega^T \cdot x_a - b \leq \varepsilon + \xi_a \\ \omega^T \cdot x_a + b - y_i \leq \varepsilon + \xi_a^* \\ \xi_a \geq 0, \xi_a^* \geq 0 \end{cases} \end{aligned} \quad (1)$$

式中:  $C$  为惩罚参数;  $\xi_i$  和  $\xi_i^*$  为松弛变量;  $\varepsilon$  为损失函数参数。

线性模型的表达式为

$$f(x) = \text{sign}(\omega \cdot x + b) \quad (2)$$

式中:  $\text{sign}(\cdot)$  代表符号函数。

然而,煤矿机电设备的安全评价数据呈现出明显的非线性特征,对于非线性数据,SVM 分类器通过一个非线性映射  $\varphi(x)$ , 将输入的非线性数据映射到一个高维特征空间,是非线性数据在该空间中是线性可分的,因此,SVM 分类器非线性模型处理数据的表达式为

$$f(x) = \text{sign}(\omega \cdot \varphi(x) + b) \quad (3)$$

但通过引入的非线性映射将原本的非线性数据处理为线性可分时,原本的线性数据只需要一个超平面将数据分类,然而在高维特征空间中,特别是非线性数据具有非常明显的高特征维度,对该非线性数据进行分类时需要多个超平面,因此,计算该数据会产生大量复杂的计算,为避免该情况的发生,本文引入了高斯核函数(径向基函数核)来降低计算资源,高斯核函数的表达式为

$$K(x, y) = \exp\left(-\frac{\|x - y\|^2}{2\sigma^2}\right) \quad (4)$$

式中:  $\sigma > 0$  是高斯核的带宽参数。

采用高斯核函数处理非线性数据时,其优点为不计算高特征维度中的线性数据,通过计算原始

非线性数据空间中的向量距离得出高维空间中的内积,即不需要计算在高维空间中  $\varphi(x)$  与  $\varphi(y)$  的具体值,从而大幅降低了计算资源,提高了计算效率。

上述为 SVM 分类器的特征,可明显看出 SVM 分类器对非线性数据的分类具有良好效果,但当原始数据量过大,且无法分辨原始数据中出现的异常数据,从而导致 SVM 分类器在处理数据时会出现过拟合或泛化能力差的现象。因此,结合 CNN 模型的数据特征提取能力,首先对非线性数据进行归一化处理,使数据具有相似的尺度,然后通过提取数据的局部特征,初步提高处理异常数据时的效率,并通过池化层降低处理的数据量,增加数据处理效率,同时保证数据处理的准确性,最终输出处理后的数据经过 SVM 分类器进行分类,保证了数据模型的预测效果。采用 MATLAB 对 CNN-SVM 模型进行编程, CNN-SVM 模型计算结构图如图 2 所示。

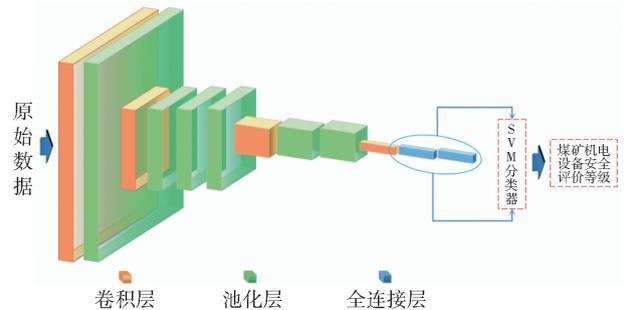


图2 煤矿机电设备安全评价 CNN-SVM 模型示意图

## 4 数据集验证

选用了 357 组来自不同煤矿的各因素评分,该 357 组数据已经过安全等级划分,在 357 组数据中包括了 89 组数据评价为危险等级 I, 89 组数据评价为危险等级 II, 89 组数据评价为危险等级 III, 90 组数据评价为危险等级 IV, 其中训练集数据占 70%, 测试集数据占 30%, 此外,为验证 CNN-SVM 模型的准确性,将本文模型与 CNN-GRU 模型、CNN-BiLSTM 模型计算结果进行对比。

图 3、图 4 所示分别 CNN-GRU 模型、CNN-BiLSTM 模型与 CNN-SVM 模型训练集与测试集计算结果。由图 3 可知,三种模型的训练集训练结果相差较小,训练集训练结果最佳模型为 CNN-BiLSTM 模型,模型准确率为 98.39%, 其次为 CNN-SVM 模型,模型准确率为 97.99%, 最后为 CNN-GRU 模型,模型准确率为 96.79%。对于 CNN-GRU 模型,模型的绝大部分数据预测结果与实际结果一

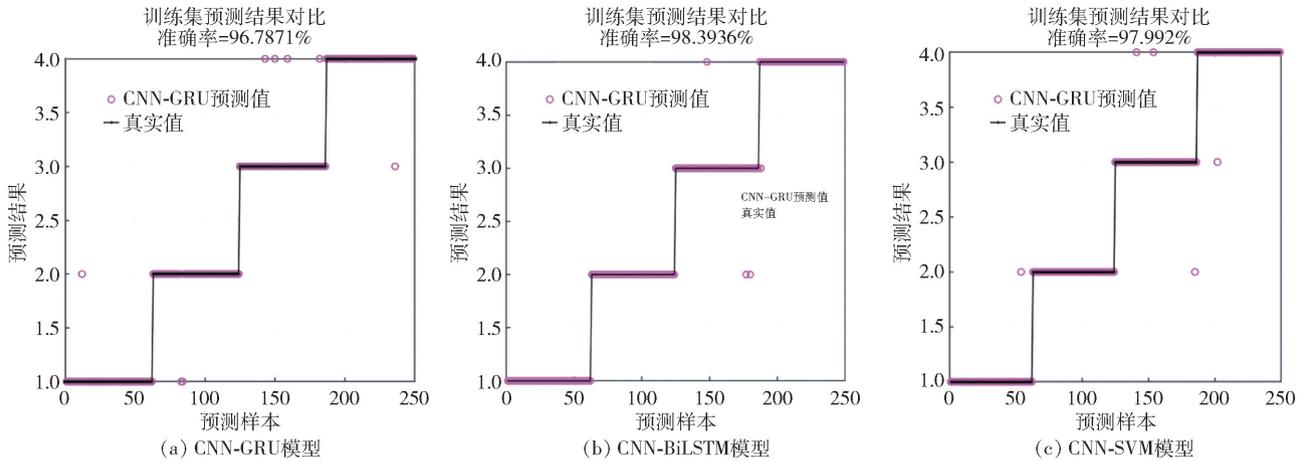


图3 训练集验证结果

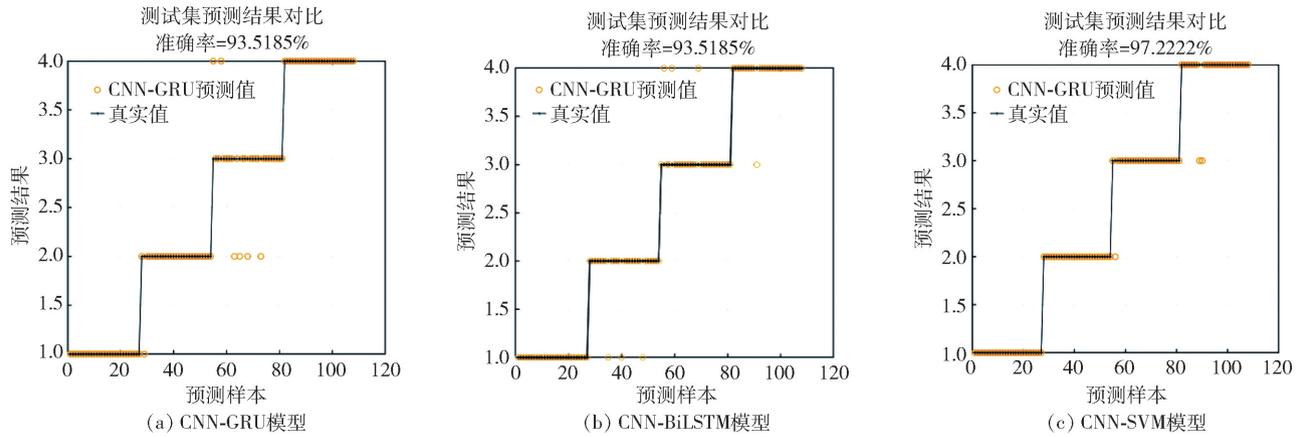


图4 测试集验证结果

致,但该模型在三种等级分类预测中均出现了部分数据异常,其中,安全等级 I、II、III 中少量数据预测错误,在安全等级 IV 中出现了较多的数据预测错误。对于 CNN-BiLSTM 模型,仅在安全等级 II 和 IV 中出现了预测错误,对于 CNN-SVM 模型,在安全等级 II、III 和 IV 中出现了预测错误,整体来说,三种模型在训练集数据的预测结果相近,且预测准确率均高于 96%,表明三种模型训练时均具有较高的可靠性。然而,从图 4 可看出,不同于训练集数据的预测结果,三种模型的测试集预测结果相差较大,特别是 CNN-GRU 模型与 CNN-BiLSTM 模型,两种模型的准确率均为 93.52% 左右,模型准确率较低,而 CNN-SVM 模型的测试集预测结果为 97.22% 左右,要高于前两种模型,对于 CNN-GRU 模型与 CNN-BiLSTM 模型,在四个安全评价等级中出现了部分数据预测错误,而 CNN-SVM 模型仅在安全评价等级 II 和 III 中出现了预测错误。图 5、图 6 所示为三种模型下混淆矩阵图,混淆矩阵可以明显看出模型对各个等

级分析与真实数据间的匹配情况,如图 5(a)、图 6(a)中 CNN-GRU 模型所示,该模型训练集对安全评价等级 I、II、IV 的预测准确率较高,安全等级 III 的预测准确率略低,为 93.5%,其中对安全等级 III 的预测中,58 组数据预测正确,4 组数据预测错误,将安全等级 III 的数据预测成了安全等级 IV,而对于测试集结果,均为对安全等级 III 的预测结果较差,其中有 21 组数据正确预测为安全等级 III,有 4 组数据预测成了安全等级 II,2 组数据预测成了安全等级 IV。由图 5(b)、图 6(b)可知,CNN-BiLSTM 模型对安全等级 I、II 的预测准确率为 100%,所有数据均准确预测,但在训练集训练结果中,等级 III 的预测准确率较差,预测准确率为 95.2%,有三组安全等级 III 的数据错误预测成了安全等级 II 与 IV,而在测试集的预测结果中,安全等级 II 与 III 均出现了少量数据预测错误,预测准确率仅为 88.9%,安全等级 IV 的预测结果较高,仅出现一组数据预测错误,准确率为 96.3%,而安全等级 I 的预测准确率最高,为

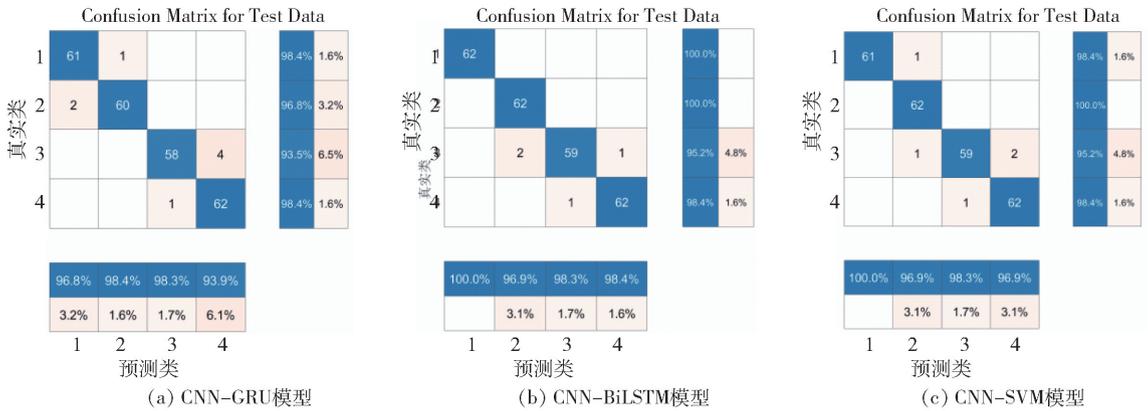


图5 训练集混淆矩阵

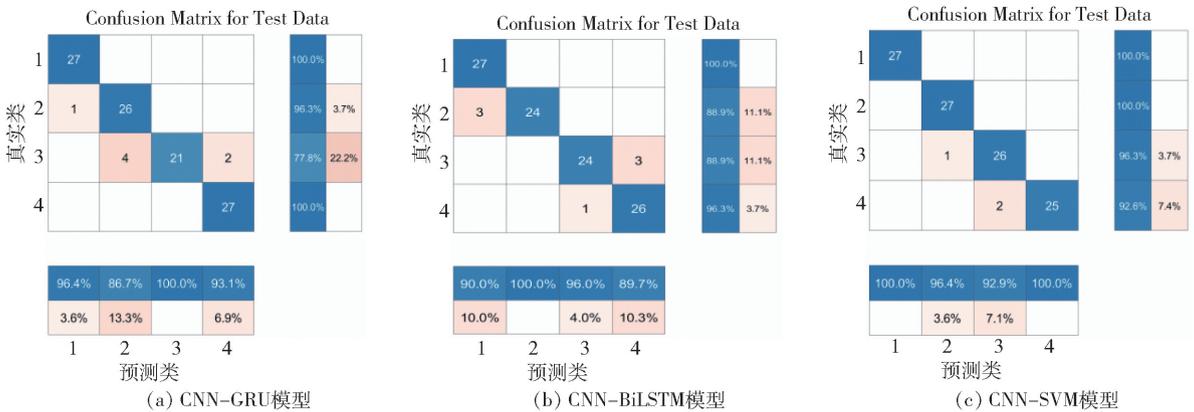


图6 测试集混淆矩阵

100%。对于 CNN-SVM 模型,与上述两种模型训练及预测结果相似,均为安全等级Ⅲ的预测准确率略低,但该模型的安全等级Ⅲ的预测准确率要高于上述两种模型,特别是在测试集预测结果中,安全等级Ⅲ的预测准确率为 96.3%,远低于 CNN-GRU 模型、CNN-BiLSTM 模型的 77.8%、88.9%,但 CNN-SVM 模型测试集对安全等级Ⅳ训练效果准确率要低,为 92.6%,此外,该模型在训练集与测试集对安全等级Ⅰ、Ⅱ的预测结果中的准确率均要高于其他两种模型,因此,CNN-SVM 模型对煤矿机电安全评价等级的整体预测准确率要高于其他两种模型,表明该模型的煤矿机电的预警效果更好。

### 5 结论

(1)总结出了三个主要影响因素,分别为企业组织管理因素、煤矿井下环境因素与机电设备状态因素,并建立了四个安全评价等级,构建了 CNN-SVM 模型,并与 CNN-GRU 模型、CNN-BiLSTM 模型计算结果进行对比,计算结果表明 CNN-SVM 模型对煤矿机电安全评价等级的整体预测准确率要高于其他两种模型,模型预测结果与实际评价结果基本

吻合。

(2)采用 CNN-SVM 模型对煤矿机电安全状态进行评价,客观准确地分析了各评价指标,消除以往评价方法存在的局限性,得到煤矿机电安全等级并通过实例进行验证,评价结果可为煤矿机电设备管理工作提供一定参考。

### [参考文献]

[1] 张培森,李复兴,朱慧聪,等. 2008—2020 年煤矿事故统计分析及其防范对策[J]. 矿业安全与环保,2022,49(1):128-134.

[2] 刘振华,徐绪堪. 基于物联网的煤矿机电设备智能管理平台设计[J]. 工矿自动化,2019,45(4):101-104+108.

[3] 刘媛媛. 煤矿机电设备智能化维护研究现状与发展趋势[J]. 工矿自动化,2021,47(7):79-84.

[4] 吴少杰. 基于数据挖掘的煤矿机电设备运行状态预测方法研究[D]. 西安:西安科技大学,2019.

[5] 邢志刚. 基于 AHP-TOPSIS 的煤矿机电安全评价模型及应用[J]. 煤炭技术,2021,40(4):142-145.

[6] 王辉. 基于大数据平台的煤矿机电设备数据综合管理系统[D]. 徐州:中国矿业大学,2021.