

基于 KPCA-WOA-KELM 的岩爆烈度预测

郭廷华,赵 帅

(河北工程大学 土木工程学院,河北 邯郸 056038)

摘要: 岩爆是隧道开挖中常见的工程地质灾害,为准确预测岩爆烈度,提出基于 KPCA-WOA-KELM 的岩爆烈度预测模型。首先,根据岩爆烈度影响因素确定岩爆评判指标,并采用核主成分分析(KPCA)对岩爆数据做特征提取,简化模型输入参数的同时充分保留数据特征信息;其次,使用核极限学习机(KELM)拟合评判指标与岩爆烈度间的非线性映射关系,并采用鲸鱼优化算法(WOA)优化 KELM 的参数,避免人工设置参数对模型预测效果的影响;然后,使用准确率、精确率、召回率、 F 值等指标综合评估模型的预测性能;最后,利用秦岭终南山公路隧道岩爆实例验证该模型的可行性。研究表明,KPCA-WOA-KELM 能有效地简化数据结构,避免局部最优解,提高岩爆烈度预测的准确率。

关键词: 岩爆;核主成分分析;鲸鱼优化算法;核极限学习机

中图分类号: TU45

文献标识码: A

Classified Prediction Model of Rockburst Using KPCA-WOA-KELM

GUO Yanhua,ZHAO Shuai

(School of Civil Engineering,Hebei University of Engineering, Handan,Hebei 056038,China)

Abstract: Rockburst is a common engineering geological disaster in deep rock excavation. In order to predict rockburst intensity grade accurately, this paper proposes a rockburst intensity prediction model based on KPCA-WOA-KELM. Firstly, rockburst evaluation indexes are determined according to the influencing factors of rockburst intensity, and the kernel principal component analysis (KPCA) is used to perform feature compression on rockburst data, so as to simplify the input data structure of the model and fully retain the data feature information. Secondly, the kernel-based extreme learning machine (KELM) was used to fit the nonlinear mapping relationship between the evaluation index and rockburst intensity, and the whale optimization algorithm (WOA) is used to optimize the parameters of KELM to reduce the impact of manual setting parameters on the model prediction effect. Then, the accuracy, precision, recall, F -measure and other indicators are used to evaluate the prediction performance of the model. Finally, the prediction of rock burst intensity of Zhongnanshan highway tunnel in Qinling Mountains is made to verify the feasibility and applicability of the model. The results show that KPCA-WOA-KELM can simplify the data structure more effectively, effectively avoid the local optimal solution, and improve the accuracy of rockburst intensity prediction.

Key words: rockburst; kernel principal component analysis; Whale Optimization Algorithm; kernel-based extreme learning machine

岩爆是隧道开挖时,因岩体受到扰动,其中聚集的弹性能突然释放,导致岩体脱落、爆裂、弹射的动力失稳现象,严重时可能造成重大财产损失和

人员伤亡^[1]。随着我国经济的快速发展,对地下深部资源开采和地下工程建设的需求愈发强烈,对岩爆预测与防治的研究也愈发重要。

收稿日期:2021-02-27

基金项目:河北省自然科学基金资助项目(E2014402099)

作者简介:郭廷华(1972-),男,黑龙江齐齐哈尔人,硕士,副教授,主要从事煤矿安全、地下工程等方面的教学和研究工作。

在岩爆烈度预测方面,国内外学者进行了大量的研究^[2-3],神经网络^[4]、功效系数法^[5]、模糊数学^[6]、灰色理论^[7]、支持向量机^[8]、数据挖掘^[9]、PCA-PNN 法^[10]、PCA-OPF 法^[11]等数学模型与智能算法被提出。但上述预测方法一般基于少量岩爆案例的小样本岩爆数据,而岩爆数据的数量与质量往往影响岩爆预测的准确性和可靠性^[12],所以由此建立的预测模型的可靠性与泛化性较差。此外上述方法的预设参数往往由人工经验设置,预测结果受人主观因素影响较大,或仅对岩爆数据作线性降维,未考虑数据间的非线性关系,从而未充分保留岩爆数据的特征信息。因此在岩爆预测方面需要进一步研究,并提出经济可靠的岩爆预测方法。

核极限学习机(Kernel Based Extreme Learning Machine, KELM)是一种分类预测算法,该算法将核函数与极限学习机(Extreme Learning Machine, ELM)相结合,以提高 ELM 算法的预测性能。故本文岩爆烈度预测将基于 KELM 实现,同时为解决因人工设置参数而影响 KELM 预测效果的问题,使用鲸鱼优化算法(Whale Optimization Algorithm, WOA)寻优 KELM 的惩罚系数 C 和核函数参数 s 以提高其预测性能。此外,考虑到岩爆评价指标之间的多维交叉冗余性,使用核主成分分析(Kernel Principal Component Analysis, KPCA)对岩爆数据集做特征压缩,相比于传统的主成分分析(Principal Component Analysis, PCA),KPCA 能对数据集做非线性降维,从而能更加充分地保留特征信息,以提高 KELM 的训练速度和预测速度,故本文建立 KPCA-WOA-KELM 的岩爆烈度预测模型。

1 模型原理与建立

1.1 KPCA 理论基础

PCA 是对数据做线性降维的传统降维算法,而对具有非线性关系的数据做特征提取时,却无法充分保留数据的特征信息。KPCA 在其基础上结合核函数,将数据映射至高维空间中做数据压缩。KPCA 能在充分保留数据特征信息的基础上做数据压缩^[13]。

1.1.1 KPCA 基础理论

设 n 个 m 维数据样本,建立数据样本矩阵 $X'_{n \times m}$,归一化后得到样本矩阵 $X_{n \times m}$ 。

使用函数 φ 将样本映射至高维特征空间 R^F ,映射值为 $\varphi(x_1), \varphi(x_2), \dots, \varphi(x_n)$ 并使用 PCA 方

法得到协方差矩阵为:

$$C = \frac{1}{n} \sum_{i=1}^n \varphi(x_i) \varphi(x_i)^T \quad (1)$$

其特征方程为:

$$C\nu = \lambda\nu \quad (2)$$

式中, λ 为协方差矩阵的特征值, ν 为特征向量,由式(1)、式(2)可得 ν :

$$\nu = \sum_{i=1}^n \varphi(x_i) \frac{\varphi(x_i)^T \nu}{\lambda n} = \sum_{i=1}^n \varphi(x_i) \alpha_i \quad (3)$$

式中, $\alpha_i = \frac{\varphi(x_i)^T \nu}{\lambda n}$ 。通常映射 φ 不是显式的,对于 ν 的计算较困难,因此引入核函数:

$$k(x_i, x_j) = \phi(x_i)^T \phi(x_j) \quad (4)$$

对于式(2),任意的 $k = 1, 2, \dots, n$, 有:

$$\varphi(x_k) C \nu = \lambda \varphi(x_k) \nu \quad (5)$$

分别将式(1)、式(3)与式(4)带入式(5)可得:

$$K\alpha = \lambda n \alpha \quad (6)$$

式中, K 为 k 对应的核矩阵, $K = k(x_i, x_j)$, $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_n)$ 。

通过式(6),求得特征值 $\lambda_1 \geq \lambda_2 \geq \dots \lambda_n$ 及其对应特征向量 $\alpha_1, \alpha_2, \dots, \alpha_n$ 。选取 p ($p \leq n$) 个特征值,满足累计贡献率 $\geq 85\%$ 。新样本 $\varphi(x_j)$ 投影后的第 j ($j = 1, 2, \dots, p$) 维坐标为:

$$y_i = \sum_{i=1}^n \alpha_i^j (\varphi(x_i)^T \varphi(x_j)) = \sum_{i=1}^n \alpha_i^j k(x_i, x_j) \quad (7)$$

式中, α_i 已经规范化, α_i^j 是 α_i 的第 j 个分量,规范化需满足:

$$\alpha_i^T \alpha_i = \frac{1}{\lambda_i} \quad (8)$$

1.1.2 核函数的选择

核函数的类别一般分为局部核函数和全局核函数,而核函数的选择往往影响 KPCA 数据降维的效果。为更加充分地保留数据特征信息,本文将两类核函数加权组合从而建立新的核函数。其中核函数参数通过多重实验的方法得出,组合核函数比例系数采用网格搜索法选取最优组合系数,使其贡献率达到最大值。核函数选用高斯核函数(局部核函数)和多项式核函数(全局核函数):

$$k(x, x') = \exp\left(-\frac{\|x - x'\|^2}{2\sigma^2}\right) \quad (9)$$

$$k(x, x') = (\gamma(x, x') + c)^d \quad (10)$$

式中, σ 为高斯核函数的待定参数, γ, c, d 为多项式核函数的待定参数。

将式(9)与式(10)加权组合得:

$$k(x, x') = \eta_1 \times \exp\left(-\frac{\|x - x'\|^2}{2\sigma^2}\right) + \eta_2 \times (\gamma(x, x') + c)^d \quad (11)$$

式中, η_1, η_2 为组合核函数的比例系数。

1.2 WOA 理论基础

WOA^[14-15] 是受座头鲸捕食行为的启发而提出的一种群智能算法。座头鲸在发现猎物后, 会下潜并旋绕, 对猎物进行泡泡网攻击, 如图 1 所示。该过程主要经历三个阶段: 随机捕猎、环绕猎物以及捕食猎物。




图 1 座头鲸泡泡网攻击捕猎行为示意

Fig. 1 Humpback whale bubble net attack and hunting behavior

1.2.1 随机捕猎

模拟鲸鱼群随机捕猎的方式求可行解, 数学模型如下:

$$D = |C \cdot X^*(t) - X(t)| \quad (12)$$

$$X(t+1) = X^*(t) - A \cdot D \quad (13)$$

式中, X^* 为当前最优位置向量, t 为当前迭代数, D 为位置衡量参数, X 为位置向量, A 和 C 为控制参数向量, 可通过下式计算:

$$A = 2a \cdot r - a \quad (14)$$

$$C = 2 \cdot r \quad (15)$$

$$a = 2 - 2 \cdot \frac{t}{t_{\text{MaxIter}}} \quad (16)$$

式中: r 为任意向量, t_{MaxIter} 为最大迭代数, a 随迭代次数的增加由 2 减少至 0, 从而实现收缩环绕机制。

1.2.2 环绕猎物

环绕更新位置通过螺旋方程来表示:

$$D' = |X^*(t) - X(t)| \quad (17)$$

$$X(t+1) = D' \cdot e^{bl} \cdot \cos(2\pi l) + X^*(t) \quad (18)$$

式中: D' 为最佳位置距当前位置的距离, l 为 $[-1, -2]$ 中任意数; b 为对数螺旋形状的常数, 通过公

式(19)计算。

$$b = -1 - \frac{t}{t_{\text{MaxIter}}} \quad (19)$$

求解时收缩环绕和螺旋更新同时进行, 各赋予两种方式 1/2 的概率执行:

$$X(t+1) = \begin{cases} X^*(t) - A \cdot D, & p < 0.5 \\ D' \cdot e^{bl} \cdot \cos(2\pi l) + X^*(t), & p \geq 0.5 \end{cases} \quad (20)$$

式中: p 为 $[0, 1]$ 的随机数。

1.2.3 捕食猎物

探索过程中, 通过全局搜索更新最佳位置以达到最优, 数学描述为:

$$D = |C \cdot X_{\text{rand}} - X| \quad (21)$$

$$X(t+1) = X_{\text{rand}} - A \cdot D \quad (22)$$

式中: X_{rand} 是当前一代中的随机位置向量。其中 $|A| < 1$ 时, 使用收缩环绕局部寻优; $|A| \geq 1$ 时, 使用探索全局寻优。

1.3 KELM 理论基础

ELM^[16] 是一种单隐层前馈神经网络, 其学习目标函数 $F(x)$ 可用矩阵表示为:

$$F(x) = h(x) \times \beta = H \times \beta = L \quad (23)$$

$$\beta = H^* \cdot L \quad (24)$$

式中: x 为输入向量, $h(x)$ 、 H 为隐层节点输出, β 为输出权重, L 为期望输出, H^* 为 H 的广义逆矩阵。

引入惩罚系数 C 和单位矩阵 I 增强神经网络的稳定性, 则输出权值的最小二乘解为:

$$\beta = H^T \left(HH^T + \frac{I}{C} \right)^{-1} L \quad (25)$$

引入核函数到 ELM 中, 核矩阵为:

$$\Omega_{\text{ELM}} = HH^T = h(x_i)h(x_j) = K(x_i, x_j) \quad (26)$$

式中: x_i, x_j 为试验输入向量, 则可将式(23)表达为:

$$F(x) = \begin{bmatrix} K(x, x_1) \\ \vdots \\ K(x, x_n) \end{bmatrix} \left(\frac{I}{C} + \Omega_{\text{ELM}} \right)^{-1} L \quad (27)$$

式中: (x_1, x_2, \dots, x_n) 为给定训练样本, n 为样本数量。核函数选用高斯核函数即:

$$K(x, x_i) = \exp\left(-\frac{\|x - x_i\|^2}{2s^2}\right) \quad (28)$$

惩罚系数 C 和核函数参数 s 的设置在一定程度上影响 KELM^[17] 的预测性能。

1.4 KPCA-WOA-KELM 模型构建

本文岩爆案例基于 Zhou 等收集的国内外地下工程和矿山中 245 组岩爆案例^[18]。去除部分埋深数据缺失案例后,选取岩爆烈度判别指标并随机将数据集分为训练集 174 例与测试集 30 例。

首先利用 KPCA 对岩爆数据做特征提取,然后将训练集输入 KELM 进行训练,并使用 WOA 对其参数优化,最后利用测试集测试该预测模型的准确性。基于 KPCA-WOA-KELM 的岩爆烈度预测模型的流程如图 2 所示:

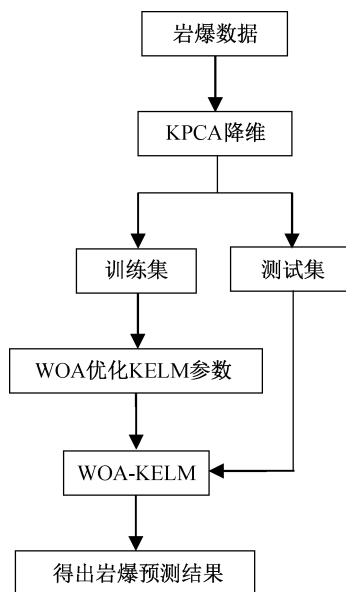


图 2 岩爆烈度预测模型流程

Fig. 2 The process of rockburst intensity prediction model

2 岩爆烈度仿真实验与分析

2.1 岩爆烈度预测指标选取

影响岩爆的因素具有显著的突发性、随机性与复杂性的特点,其主要包括岩性、地质条件、开挖方式、围岩初始应力状态、隧道断面型式等。

目前国内外学者对岩爆预测指标的选取通常基于岩石力学参数或岩爆判据。一般来说,选取岩爆预测指标应符合易于获取、代表性与可操作性强的特点,能从多个方面反映岩爆的特征信息。

根据岩爆的影响因素、特点及成因,本文选取岩爆埋深 D , 围岩最大切应力 σ_θ , 单轴抗压强度 σ_c , 单轴抗拉强度 σ_t , 应力集中系数 SCF(最大切向应力比单轴抗压强度), 脆性系数(单轴抗压强度比单轴抗拉强度 B_1 和单轴抗压、抗拉强度之差与两者之和的比值 B_2), 弹性能量指数 W_{et} 作为岩爆烈度的主要评判指标。将岩爆分为 4 级: 无岩爆、轻微岩爆、中等岩爆、强烈岩爆, 其级别分别对应 I 级、II 级、III 级、IV 级, 表 1 为不同理论判据下岩爆烈度分类标准表^[19]。

2.2 KPCA 特征提取

KPCA 特征提取步骤为:

- (1) 选取岩爆数据。
- (2) 归一化初始数据矩阵。
- (3) 使用核技巧将样本空间映射至高维空间构建核矩阵 $K_{n \times n}$ 。
- (4) 核矩阵中心化, 即:

$$\bar{K} = K - I_n \times K - K \times I_n + I_n \times K \times I_n \quad (29)$$

其中, I_n 为元素均为 $1/n$ 的矩阵。

(5) 求解核矩阵的特征值 λ , 排序特征向量 α 。选取出 $p(p \leq n)$ 个特征向量, 并根据式(8)规范化。

(6) 通过特征值和特征向量得出主成分, 样本 x_j 在特征向量 α^k 上的投影为:

$$r_{jk} = \sum_{j=1}^n \alpha_j^k \phi(x_j)^T \phi(x) = \sum_{j=1}^n \alpha_j^k K(x_j, x) \quad (30)$$

$$k = 1, 2, \dots, p$$

表 1 不同理论判据的岩爆烈度分类标准

Tab. 1 Classification standards of rockburst intensity based on different theoretical criteria

理论判据	评价指标	分类标准			
		I	II	III	IV
Russenes 判据	SCF	<0.2	0.2~0.3	0.3~0.55	>0.55
二郎山判据	SCF	<0.3	0.3~0.5	0.5~0.7	>0.7
张文乐等	D/m	<50	50~200	200~700	>700
张文乐等	σ_c / MPa	<80	80~120	120~180	>180
J. J. Zhang	B_1	<15	15~18	18~22	>22
彭祝等	B_1	>40	26.7~40	14.5~26.7	<14.5
Neyman 判据	W_{et}	<2.0	2.0~3.5	3.5~5.0	>5.0

表2 不同核函数特征提取结果对比

Tab.2 Comparison of feature extraction results of different kernel functions

高斯核函数			多项式核函数			组合核函数		
特征值	贡献率	累计贡献率	特征值	贡献率	累计贡献率	特征值	贡献率	累计贡献率
1.220 44	0.177 5	0.177 5	9 851.633	0.474	0.474	795 522.7	0.704 3	0.704 3
1.003 141	0.145 9	0.323 4	4 209.618	0.202 5	0.676 5	114 385.5	0.101 3	0.805 6
1.000 579	0.145 5	0.468 9	2 537.763	0.122 1	0.798 6	94 387.02	0.083 6	0.889 2
0.998 289	0.145 2	0.614 1	1 938.019	0.093 2	0.891 8	58 315.93	0.051 6	0.940 8
0.994 416	0.144 6	0.758 7	1 225.013	0.058 9	0.950 7	38 410.66	0.034	0.974 8
0.964 003	0.140 2	0.898 9	722.887 9	0.034 8	0.985 5	15 570.06	0.013 8	0.988 6
0.694 64	0.101 1	1	301.157 6	0.014 5	1	12 851.93	0.011 4	1
0	0	1	0	0	1	0	0	1

构造特征提取后的矩阵 $R_{n \times p}$ 。

分别通过组合核函数、高斯核函数和多项式核函数实现 KPCA 特征提取,其中高斯核函数参数 $\sigma = 1.81$,多项式核函数中 $d = 3, \gamma = c = 1$,组合系数 $\eta_1 = 0.7, \eta_2 = 0.3$ 。

表2为通过不同核函数分别得到的特征值,贡献率和累计贡献率。可以看出,组合核 KPCA 得到 70.43% 的第一主成分贡献率,远大于高斯核、多项式核 KPCA,说明相比于单一核 KPCA,组合核 KPCA 具有更好的特征提取能力。

2.3 WOA 优化 KELM 模型

由于 KELM 对其核函数参数的敏感性,直接使用 KELM 建模,往往导致预测结果产生较大误差。因此,为提高 KELM 的预测性能,使用 WOA 算法对 KELM 的惩罚系数 C 和核函数参数 s 进行全局寻优。具体步骤如下:

(1) 归一化 KPCA 降维后的数据集。

(2) 参数设置:变量数 $\dim = 2$ 、鲸鱼数量 $\text{SearchAgents_no} = 30$ 、最大迭代次数 $t_{\text{MaxIter}} = 150$,变量下限 $\text{lb} = [30, 0.2]$,变量上限 $\text{ub} = [500, 0.7]$ 。

(3) 种群初始化:令 $n = \text{SearchAgents_no}$,鲸鱼位置为:

$$X = \begin{pmatrix} x_{1,1} & \cdots & x_{1,\dim} \\ \vdots & \ddots & \vdots \\ x_{n,1} & \cdots & x_{n,\dim} \end{pmatrix} \quad (31)$$

通过下式计算鲸鱼初始随机种群位置 X_0 ,迭代数 $t = 1$:

$$X_0(i,j) = (\text{ub}(i) - \text{lb}(i)) \times \text{rand}(i,j) + \text{lb}(i) \quad (32)$$

式中: $X_0(i,j)$ 为式(31)第 i 行第 j 列的值, $\text{lb}(i)$ 和 $\text{ub}(i)$ 为第 i 个座头鲸的下限和上限, $\text{rand}(i,j)$ 为

$[0,1]$ 内的随机数。

(4) 定义适应度函数:惩罚系数 C 和核函数参数 s 用鲸鱼位置表示,即 $X(i,1)$ 和 $X(i,2)$ 。将 $X(i,1)$ 和 $X(i,2)$ 代入 KELM,并预测岩爆烈度,将预测值 y'_i 和真实值 y_i 通过交叉验证获得适应度值。

(5) 利用 WOA 寻优得到最优 C_{best} 和 s_{best} 如表3所示。

(6) 将 C_{best} 和 s_{best} 代入 KELM 得到 KPCA-WOA-KELM 的岩爆烈度等级预测模型。

表3 不同核 KPCA 下 KELM 最优参数

Tab.3 KELM optimal parameters base on different KPCA

KELM 参数	组合核	高斯核	多项式核
C_{best}	33.51	10.54	271.06
s_{best}	0.22	0.26	0.80

2.4 KPCA-WOA-KELM 模型实测

将 30 例测试数据输入模型中,结果如图3所示。

该模型相关评估指标如表4所示。分别采用 F 值、准确率 (Accuracy)、精确率 (Precision)、召回率 (Recall) 量化 KPCA-WOA-KELM 的预测性能。其中 Accuracy 可量化模型整体的预测性能,其余指标则反映模型对 4 类岩爆等级中单独的某一级的预测能力。

组合核、高斯核和多项式核的 KPCA-WOA-KELM 的准确率分别为 90%、86.66%、83.33%,精确率分别为 87.05%、83.92%、84.37%,召回率分别为 95%、93.18%、87.62%, F 值分别为 90.06%、86.69%、83.3%,说明该模型有较高的预测性能。其中,组合核 KPCA-WOA-KELM 预测能力最优,对 4 类岩爆等级分类精确率分别为 85.71%~100%, 85.71%~100%, 87.5%~100%, 召回率分别为




图3 不同核 KPCA-WOA-KELM 岩爆烈度预测结果
Fig. 3 KPCA-WOA-KELM rockburst intensity prediction results for different core

80%~100%, 72.73%~100%, 72.73%~100%, F 值分别为 85.71%~93.33%, 76.92%~93.33%, 66.67%~100%。其中 I 级岩爆与 II 级岩爆的 F 值均大于 III 级岩爆与 IV 级岩爆的 F 值,说明该模型对 I 级岩爆与 II 级岩爆的预测性能较强,而对于 III 级岩爆与 IV 级岩爆的预测性能较弱。

综上所述,综合考虑该模型的准确率及相关评价指标,组合核 KPCA-WOA-KELM 具有较好的预测性能。

3 工程实践

3.1 工程概况

秦岭终南山公路隧道全程 18.02 km,最大纵

表4 不同核 KPCA-WOA-KELM 性能评价

Tab. 4 Performance evaluation of different core KPCA-WOA-KELM

岩爆等级	评估指标/%	KPCA-WOA-KELM		
		组合核	高斯核	多项式核
I	Precision	85.71	85.71	100
	Rcall	100	100	100
	F	92.31	92.31	100
II	Precision	85.5	87.5	100
	Rcall	100	100	72.73
	F	93.33	93.33	84.21
III	Precision	75	62.5	50
	Rcall	100	100	100
	F	85.71	76.92	66.67
IV	Precision	100	100	87.5
	Rcall	80	72.73	77.78
	F	88.89	84.21	82.35
平均	Precision	87.05	83.92	84.37
	Rcall	95	93.18	87.62
	F	90.06	86.69	83.3
	Accuracy	90	86.66	83.33

坡 11%。该工程采用双洞双线设计,净宽 10.5 m、限高 5 m,安全等级一级,结构设计基准期 100 a。该隧道深埋地段的最大水平主应力达到 21.04 MPa,地应力水平较高,岩爆发生概率较大^[20]。

3.2 模型应用

将 KPCA-WOA-KELM 模型应用于秦岭终南山隧道工程岩爆烈度的预测。该工程岩爆相关指标如表 5 所示,预测结果与实际情况基本一致。表明 KPCA-WOA-KELM 在实际工程中有一定的可靠性,为实际工程提供一定的参考价值。

4 结论

1) 在确定岩爆烈度主要评判指标后,使用 KPCA 对岩爆数据做非线性降维,相比于 PCA, KPCA 能更充分保留特征信息,简化 KELM 模型的输入参数,同时借助 WOA 优化 KELM 的惩罚系数 C 和核函数参数 s 使其达到最优,从而提高模型的训练速度与预测精度。

2) 对局部核函数和全局核函数采用加权方式构造组合核 KPCA,并与 WOA 优化的 KELM 相结合,建立组合核 KPCA-WOA-KELM 模型。使用 204 例岩爆案例对模型进行训练与测试,并用准确

表5 终南山隧道岩爆实测数据与预测结果

Tab. 5 Measured data and prediction results of rockburst in Zhongnanshan Tunnel

埋深/m	σ_{θ} /MPa	σ_c /MPa	σ_t /MPa	SCF	B_1	B_2	W_{et}	实际烈度	预测烈度
119	43.1	122	5.38	0.35	22.68	0.92	3.31	II	II
283	87.5	121	8.73	0.72	13.86	0.87	9.05	IV	IV
316	79.1	124	8.64	0.63	14.35	0.87	7.74	IV	IV
467	56.2	119	7.21	0.47	16.50	0.89	5.52	III	III
659	62.8	120	6.45	0.52	18.60	0.90	4.16	III	III

率、精确率、召回率、 F 值等指标综合评价 KPCA-WOA-KELM 的预测性能。结果表明,组合核 KPCA-WOA-KELM 相较于单一核 KPCA-WOA-KELM 有更高的预测性能。

3)为检验该模型的预测性能,将其应用于终南山公路隧道中对岩爆等级进行预测,结果表明与实际岩爆等级基本一致,说明该模型具有一定的工程应用价值。

参考文献:

- [1]冯夏庭,肖亚勋,丰光亮,等.岩爆孕育过程研究[J].岩石力学与工程学报,2019,38(4):649-673.
- [2]吕庆,孙红月,尚岳全,等.深埋特长公路隧道岩爆预测综合研究[J].岩石力学与工程学报,2005,24(16):2982-2988.
- [3]张镜剑,傅冰骏.岩爆及其判据和防治[J].岩石力学与工程学报,2008,27(10):2034-2042.
- [4]陈海军,郇能惠,聂德新,等.岩爆预测的人工神经网络模型[J].岩土工程学报,2002,24(2):229-232.
- [5]王迎超,尚岳全,孙红月,等.基于功效系数法的岩爆烈度分级预测研究[J].岩土力学,2010,31(2):529-534.
- [6]王元汉,李卧东,李启光,等.岩爆预测的模糊数学综合评判方法[J].岩石力学与工程学报,1998,17(5):493-501.
- [7]刘春,易俊,姜德义,等.基于灰色关联分析理论的岩爆烈度预测研究[J].中国矿业,2007,16(12):100-103.
- [8]祝云华,刘新荣,周军平.基于v-SVR算法的岩爆预测分析[J].煤炭学报,2008,33(3):277-281.
- [9]葛启发,冯夏庭.基于AdaBoost组合学习方法的岩爆分类预测研究[J].岩土力学,2008,29(4):943-948.
- [10]吴顺川,张晨曦,成子桥.基于PCA-PNN原理的岩爆

烈度分级预测方法[J].煤炭学报,2019,44(9):2767-2776.

- [11]赵国彦,刘雷磊,王剑波,等.岩爆等级预测的PCA-OPF模型[J].矿冶工程,2019,39(4):1-5.
- [12]LIN JIMENEZ R, FENG X D. The Influence of Bayesian Networks Structure on Rock Burst Hazard Prediction with Incomplete Data [J]. Procedia Engineer, 2017, 191: 206-214.
- [13]董雪,张德平.基于组合核主成分分析的潜艇威胁度评估模型[J].计算机工程,2018,44(11):40-45.
- [14]SEYEDALI Mirjalili, ANDREW Lewis. The Whale Optimization Algorithm [J]. Advances in Engineering Software, 2016, 95: 51-67.
- [15]刘怀远.基于WOA-LSSVM的锅炉NO_x排放量预测模型[J].华北电力大学学报,2019,46(4):1007-2691.
- [16]HUANG Guangbin, ZHOU Hongming, DING Xiaojian, et al. Extreme Learning Machine for Regression and Multiclass Classification [J]. IEEE Transactions on Cybernetics, 2012, 42(2): 513-29.
- [17]邵良杉,周玉.基于MIV-MA-KELM模型的岩爆烈度等级预测[J].中国安全科学学报,2018,28(02):34-39.
- [18]ZHOU J, LI X B, MITRI H S. Classification of Rockburst Inunder Ground Projects: Comparison of Ten Supervised Learning Methods [J]. Journal of Computing in Civil Engineering, 2016, 30(5): 1-19.
- [19]汤志立,徐千军.基于9种机器学习算法的岩爆预测研究[J].岩石力学与工程学报,2020,39(04):773-781.
- [20]王羽,许强,柴贺军,等.工程岩爆灾害判别的RBF-AR耦合模型[J].吉林大学学报:地球科学版,2013,43(6):1944-1949.

(责任编辑 王利君)