

杨健锋, 雒可, 柴敬, 等. 基于XGBoost-LSTM的光纤监测巷道变形预测[J]. 辽宁工程技术大学学报(自然科学版), 2026, 45(1): 17-24. DOI: 10.11956/j.issn.1008-0562.20250378
YANG Jianfeng, LUO Ke, CHAI Jing, et al. XGBoost-LSTM based prediction of tunnel deformation from optical fiber monitoring[J]. Journal of Liaoning Technical University(Natural Science), 2026, 45(1): 17-24. DOI: 10.11956/j.issn.1008-0562.20250378

基于XGBoost-LSTM的光纤监测巷道变形预测

杨健锋^{1,2}, 雒可¹, 柴敬^{1,2}, 张丁丁^{1,2}, 景超¹, 刘永亮³

(1. 西安科技大学 能源与矿业工程学院, 陕西 西安 710054; 2. 西安科技大学 西部矿井开采及灾害防治教育部重点实验室, 陕西 西安 710054; 3. 华北科技学院 矿山安全学院, 河北 廊坊 065201)

摘要: 针对近距离煤层开采过程中, 遗留煤柱下区段煤柱变形导致巷道稳定性差的问题, 采用分布式光纤植入区段煤柱内部的监测方式, 对5个监测孔位的多时段实测应变数据进行系统化与归一化处理。采用滑动窗口构建训练样本, 并结合网格搜索方法调优超参数, 搭建一种结合极端梯度提升(XGBoost)与长短期记忆网络(LSTM)的矿压显现集成预测模型。研究表明: 该模型在多个监测点上的决定系数 R^2 达到0.922, 均方根误差降至4.215, 平均绝对误差降至2.135, 显著优于单一模型(XGBoost、LSTM、随机森林)的预测精度、稳健性与泛化能力。研究结论揭示了二次采动条件下煤柱的水平应变分布规律, 为区段煤柱变形预测提供参考。

关键词: 分布式光纤; 煤柱内部变形; 集成预测; 超参数优化; 误差分析

中图分类号: TD32

文献标志码: A

文章编号: 1008-0562(2026)01-0017-08

XGBoost-LSTM based prediction of tunnel deformation from optical fiber monitoring

YANG Jianfeng^{1,2}, LUO Ke¹, CHAI Jing^{1,2}, ZHANG Dingding^{1,2}, JING Chao¹, LIU Yongliang³

(1. College of Energy and Mining Engineering, Xi'an University of Science and Technology, Xi'an 710054, China; 2. Key Laboratory of Western Mine Exploitation and Hazard Prevention, Ministry of Education, Xi'an University of Science and Technology, Xi'an 710054, China; 3. School of Mine Safety, North China Institute of Science and Technology, Langfang 065201, China)

Abstract: To address the problem of roadway instability caused by deformation of sectional coal pillars beneath remnant pillars during close-distance coal seam mining, a distributed optical fiber sensing method was employed by embedding fibers inside the coal pillars. Strain data from five monitoring boreholes were systematically processed and normalized. A training dataset was constructed using a sliding-window approach, and hyperparameters were optimized via grid search to develop an integrated mine pressure prediction model combining XGBoost (Extreme Gradient Boosting) and LSTM (Long Short-Term Memory) algorithms. The results show that the proposed model achieves a coefficient of determination (R^2) of 0.922, with the root mean square error (RMSE) reduced to 4.215 and the mean absolute error (MAE) lowered to 2.135, demonstrating superior prediction accuracy, robustness, and generalization compared with single models such as XGBoost, LSTM, and random forest (RF). The research conclusion reveals the horizontal strain distribution law of coal pillar under the condition of secondary mining, and provides reference for the deformation prediction of section coal pillar.

Keywords: distributed optical fiber; internal deformation of coal pillars; ensemble prediction; hyperparameter optimization; error analysis

收稿日期: 2025-09-03 修回日期: 2025-10-08 接受日期: 2025-10-18 责任编辑: 张雯

基金项目: 国家自然科学基金青年科学基金项目(52004203); 廊坊市科学技术研究与发展计划项目(2024013023); 中央高校基本科研业务费资助项目(3142024012)

作者简介: 杨健锋(1992-), 男, 黑龙江七台河人, 博士, 副教授, 主要从事矿山压力与岩层控制方面的研究。E-mail: yangjianfeng@xust.edu.cn

0 引言

近距离煤层的多层次联合开采是煤矿高效开采的重要途径^[1-2]。但该模式使下伏煤层受上覆遗留煤柱应力影响,区段煤柱变形与失稳风险显著增加,易引发巷道围岩破坏^[3]、支架失稳^[4]和顶板垮落^[5]等强矿压现象,威胁井下安全与通风系统稳定。如何实现对区段煤柱变形的高时效、高分辨率监测与精准预测,成为灾害防控的关键。

分布式光纤监测技术(BOTDR)具有全分布、长距离、高灵敏、抗干扰等优势^[6-7],被广泛应用于煤柱和巷道围岩变形监测^[8-10]。通过将光纤传感器埋设于煤柱内部,可获得应变分布特征,揭示煤柱在采动扰动下的变形规律及其对巷道稳定性的影响^[11-13]。然而,在非稳态扰动条件下,光纤监测数据常受信噪比低、波动大等因素影响,限制了其预警精度。近年来,机器学习与深度神经网络在矿压预测中展现出较高潜力^[14]。研究者将XGBoost(Extreme Gradient Boosting)算法与光纤监测相结合,建立了矿压时序预测模型^[15];利用LSTM网络分析了支架阻力与周期来压规律^[16];并基于光纤频移数据构建了工作面来压位置预测模型^[17]。但在复杂工况和高噪声数据条件下仍存在预测精度不足和稳定性欠佳的问题。传统人工神经网络(ANN)依赖梯度下降法训练,XGBoost虽能刻画非线性关系,但难以捕捉时间序列的动态特征;LSTM具备时序建模能力,却在缺乏特征提取辅助时表现不稳。

综上,现有研究在煤柱及巷道围岩变形预测方面取得了一定进展,但仍存在以下问题。一方面,多数模型依赖理想化或实验室条件下的数据,难以充分反映井下复杂应力环境与扰动特征;另一方面,针对区段煤柱内部多点应变的动态响应规律研究仍较有限,尚缺乏能够兼顾空间分布特征与时序演化规律的预测模型。此外,受限于监测点布设条件及信号质量,如何在低信噪比、数据波动明显的情况下实现稳定建模,仍是技术难题。基于此,以大柳塔煤矿活鸡兔井典型近距离煤层工作面为工程背景,聚焦上覆遗留煤柱扰动下区段煤柱的内部应变特征,构建XGBoost-LSTM集成模型。通过Stacking框架融合XGBoost的特征表达优势与LSTM的时序建模能力,依托BOTDR分布式光纤技术获取高时空分辨率的连续监测数据,搭建适用于井下监测点位有限、数据波动剧

烈及信噪比不稳定等复杂工况下的XGBoost-LSTM的矿压显现集成预测模型。

1 煤柱变形光纤监测系统

1.1 分布式光纤监测传感原理

基于分布式光纤监测技术(BOTDR)^[6]构建矿压监测系统,其核心结构见图1。测试设备(AV6419)的技术指标见表1。




图1 BOTDR传感系统结构

Fig.1 BOTDR sensing system structure

表1 测试设备技术指标
Tab.1 technical indicators of testing equipment

光学指标	取值
工作波长	(1 550±5) nm
光纤类型	单模
最高采样分辨率	0.05 m
频率扫描间隔	1 MHz、2 MHz、55 MHz、10 MHz、20 MHz、50 MHz
应变测试精度	±50×10 ⁻⁶ (10~20 ns)
应变测试范围	-15×10 ⁻³ ~15×10 ⁻³

激光器输出角频率为 $\nu_B(0)$ 的连续光信号,经光纤调制器调制为探测脉冲光后,射入传感光纤。当外部应变或温度变化时,光纤内产生频率为 $\nu_B(0)+\nu_B(\varepsilon,t,z)$ 的自发布里渊散射。其中, $\nu_B(0)$ 为光纤在无应变时的初始布里渊频移; $\nu_B(\varepsilon,t,z)$ 为温度 t 下、光纤距离 z 处产生应变 ε 时的布里渊频移。

散射光沿光纤传播并返回信号检测系统。信号检测系统对不同时间点接收到的布里渊散射信号进行洛伦兹拟合,提取出光纤轴向距离 X_1 至 X_2 之间的布里渊频移信息。光纤中布里渊频移为

$$\nu_B = \pm \frac{2n\nu_a}{\lambda_p}, \quad (1)$$

式中: n 为光纤的折射率; ν_a 为声波的传播速度; λ_p 为入射光的波长。

布里渊频移与光纤温度及应变呈线性关系,即

$$\nu_B(\varepsilon,t) = \nu_B(0,t_0) + C_s\varepsilon(z) + C_t(t-t_0), \quad (2)$$

式中: $\nu_B(0,t_0)$ 为温度 t_0 下光纤在无应变时的初始布里渊频移; C_t 为温度系数,表示单位温度变化

引起的频移变化量; t 为环境温度; t_0 为初始温度; ε 为光纤应变; $\varepsilon(z)$ 为光纤距离 z 处的应变; C_s 为光纤产生单位应变时引起的布里渊频移的变化量, 计算式为

$$C_s = \frac{\Delta\nu_B}{\Delta\varepsilon} \quad (3)$$

监测位置温度变化较小, 所以忽略温度对监测系统的影响, 式 (2) 可简化为

$$\nu_B(\varepsilon) = \nu_B(0) + C_s \varepsilon(z) \quad (4)$$




图2 22208工作面平面位置

Fig.2 plan position of the 22208 working surface

22208工作面区段煤柱位于上覆采空区和遗留煤柱下, 其结构见图3。5-1#煤柱位于遗留煤柱下, 5-2#和6#煤柱位于采空区下。分布式光纤布设在22208回顺与22206运顺之间的5-1#区段煤柱内, 分别设置5-1-1#至5-1-5#钻孔监测区段煤柱变形特征。

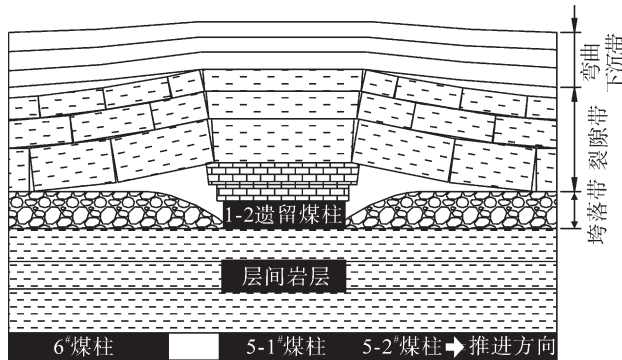


图3 工作面上方覆岩结构

Fig.3 overburden structure above the working face

为研究22208工作面位于遗留煤柱下的区段煤柱变形问题, 采用钻孔植入的方法将分布式光纤传感器植入到22206主运平巷和22208回风平巷之间的区段煤柱中, 光纤测孔编号及布置方式见图4。将金属加强型索状光缆沿PVC管两侧径向布设, 保持光纤平直, 并以扎带每隔1m进行固定。在5#煤柱上施工钻孔后, 将预先绑扎好的PVC管植入孔内, 随后采用全孔注浆工艺, 实现光纤与煤柱

1.2 工程概况及光纤监测系统布设

陕西大柳塔煤矿22208工作面开采2-2煤层, 工作面上覆岩层厚度为82~139m, 工作面总推进长度为2370m, 设计采高为4m, 合计回采煤量为298.3万t, 22208工作面位置距上覆采空区平均层间距为30m。受上覆煤层开采影响, 22206运输顺槽和22208工作面回风顺槽及其煤柱部分与上覆煤柱位置重叠, 见图2。以遗留煤柱下的5#区段煤柱为研究对象, 该煤柱与22208工作面斜交11°。

体的充分耦合。最后, 将分布式光纤连接至BOTDR设备, 构建在线监测系统。




图4 区段煤柱分布式光纤布置

Fig.4 distributed optical fiber arrangement of section coal pillar

1.3 数据处理及监测结果

测量初期, 22208工作面(二次采动)与1号测孔的距离为-39m(正值表示远离钻孔, 负值表示接近钻孔)。1~5号测孔沿15m煤柱宽度的应变分布见图5。煤柱宽度0m处为22206工作面侧, 15m处为22208工作面侧。随着采动工作面的持续推进, 煤柱受扰动程度不断增强, 当工作面推进至测孔位置时, 应变骤然升高, 煤柱稳定性显著降低。二次采动的应变曲线总体呈双峰状分布,

说明在开采过程中,煤柱两侧靠近工作面区域的应变集中现象要明显大于煤柱中部区域。

工作面由1号测孔推进至5号测孔期间,以位于煤柱中心的3号测孔为参考,将推进过程划分为3个阶段:工作面距3号测孔-33~-11 m为进遗留煤柱阶段,-11~11 m为过遗留煤柱阶段,11~33 m为出遗留煤柱阶段。由监测数据可知,进遗留煤

柱阶段煤柱内部变形较小,应变趋于稳定,波动范围为 $\pm 100 \times 10^{-6}$;过遗留煤柱阶段,开采侧水平应变增加,波动范围为 $\pm 270 \times 10^{-6}$;在出煤柱阶段,煤柱两侧水平应变出现明显变化,波动范围为 $\pm 550 \times 10^{-6}$ 。出煤柱阶段应变变化最剧烈,所以选择出煤柱阶段的应变进行预测。应变统计分析结果见表2。

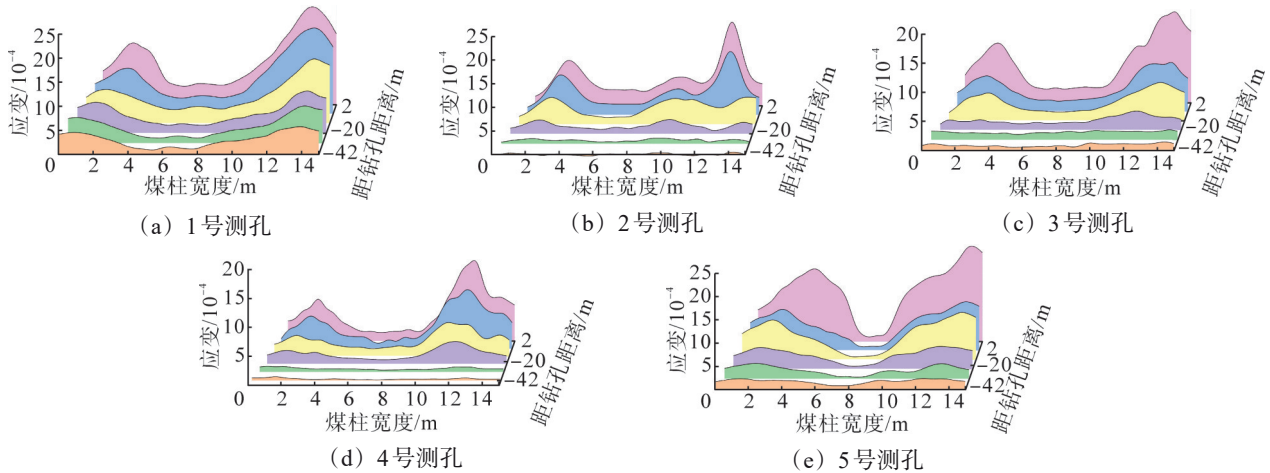


图5 分布式光纤监测的煤柱水平应变

Fig.5 horizontal strain of coal pillar monitored by distributed optical fiber

表2 应变统计分析结果

Tab.2 statistical analysis of strain datas

测孔	平均值 / 10^{-6}	标准误差 / 10^{-6}	中位数 / 10^{-6}	众数 / 10^{-6}	最小值 / 10^{-6}	最大值 / 10^{-6}
1	524.01	36.14	327.61	129.74	28.81	2 310.09
2	619.58	34.90	466.66	408.33	70.00	2 298.33
3	315.37	24.98	228.93	0	-35.22	2 201.26
4	333.25	24.65	198.33	151.66	46.66	1 808.33
5	270.29	21.69	169.78	160.48	5.58	1 635.87

由表2可知,2号测孔的应变平均值最大,表明其长期处于较强压缩状态,4号测孔的应变平均值相对较小,显示出较高稳定性。分析表明,2号和5号测孔的标准误差波动幅度较大,稳定性较差,1号和3号波动较小。中位数与平均值接近,说明数据分布大致对称,极值分析则揭示了2号和5号测孔的受力范围最广,可能存在局部异常或极端波动。

2 预测模型构建

XGBoost能够有效应对煤柱内部应变与多种监测特征间存在的高度非线性关系,具备较强的特征提取与泛化能力。LSTM能够捕捉应变随采动过程变化的动态依赖特征。将两者结合,不仅充分利用了XGBoost在非线性特征建模方面的稳定性,

而且发挥了LSTM在时序趋势刻画中的优势,使模型既能反映煤柱内部复杂的空间特征,又能准确描述随时间演化的变形规律,提升预测的可靠性与精度。

2.1 XGboost模型构建

XGBoost通过不断迭代生成新决策树来拟合前一轮的残差,并引入二阶梯度信息和正则化项,提高预测精度与防止过拟合。模型的目标函数为

$$Q = \sum_{i=1}^n l(y_i, \hat{y}_i^{(x)}) + \sum_{k=1}^x M(f_k), \quad (5)$$

式中: $l(\cdot)$ 为损失函数; y_i 为真实值; $\hat{y}_i^{(x)}$ 为前 $x-1$ 轮的预测值; $M(f_k)$ 为正则化项; n 为样本数。

节点分裂依据增益 G 选择最优特征划分,表示为

$$G = \frac{1}{2} \left[\frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{(G_L + G_R)^2}{H_L + H_R + \lambda} \right] - \gamma, \quad (6)$$

式中: G_L 、 G_R 为左、右子节点的一阶梯度和; H_L 、 H_R 为左、右子节点的二阶梯度和; λ 为 ℓ_2 正则化系数; γ 为最小分裂损失(节点分裂阈值)。

构建的XGBoost模型采用基于梯度提升的集成学习框架,通过迭代训练多个决策树(CART),逐步优化预测精度,算法流程如下:①初始化矿

压预测模型, 设定学习率、迭代次数等超参数; ②计算应变梯度与二阶变化量, 用于指导最优分裂; ③依据支承压力增益构建决策树, 提取煤柱监测数据的关键特征; ④更新预测结果, 叠加新树输出修正模型; ⑤若预测精度已满足终止条件, 则输出最终模型, 否则继续迭代。

2.2 LSTM 模型构建

长短期记忆网络 (LSTM) 是一种改进型循环神经网络。其核心结构由遗忘门、输入门、输出门和记忆单元组成, 能够有效捕捉矿压随时间的动态变化, 避免梯度消失问题。LSTM 的关键信息更新过程为

$$f_t = \sigma(\mathbf{W}_f \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_f), \quad (7)$$

$$\mathbf{C}_t = f_t \odot \mathbf{C}_{t-1} + \mathbf{i}_t \odot \tilde{\mathbf{C}}_t, \quad (8)$$

式 (7)、式 (8) 中: f_t 为遗忘门的门控值, 控制旧信息保留比例; \mathbf{C}_t 为当前时刻记忆单元状态向量; \mathbf{i}_t 为输入门向量; \mathbf{C}_{t-1} 为前一时刻记忆单元状态向量; \mathbf{h}_{t-1} 为前一时刻隐藏状态; \mathbf{W}_f 为权重矩阵; \mathbf{b}_f 为偏置项; $\sigma(\cdot)$ 为激活函数; \mathbf{x}_t 为当前时刻输入向量; $\tilde{\mathbf{C}}_t$ 为当前时刻候选记忆单元状态向量。

通过滑动窗口输入煤柱应变序列, LSTM 能学习时序特征并输出未来矿压变化趋势, 为短期预测和预警提供支持。LSTM 算法流程如下: ①输入与初始化。采用滑动窗口方法对煤柱应变监测序列进行切分, 每个输入样本由连续 20 个时间步的应变数据组成 (窗口长度为 20), 窗口每次滑动 1 个时间步 (步长为 1), 形成新的输入样本。预测目标为窗口结束后下一个时间点的应变值 (预测步长为 1)。②遗忘门更新。根据矿压变化特征, 判断保留多少历史信息。③输入门与记忆单元更新。写入新的应变变化信息, 形成当前时刻的记忆状态。④输出门生成预测。结合当前记忆和隐藏状态, 输出下一时刻矿压预测值。⑤迭代优化。循环处理全部时间步并更新参数, 直至预测精度满足要求。

2.3 集成模型的构建

堆叠集成 (Stacking) 是一种集成学习方法, 通过组合多个不同的基学习器并引入元学习器 (meta-learner), 对基学习器的输出结果进行再学

习, 以提升整体预测性能。第一级 (Level-0) 模型训练多个基学习器, 分别得到预测结果; 第二级 (Level-1) 模型以第一级模型的预测结果作为输入特征, 训练元学习器进行最终预测。假设有 K 个基学习器 $h_k(\mathbf{x})$, 则 Stacking 模型最终集成预测结果为

$$\hat{y} = g(h_1(\mathbf{x}), h_2(\mathbf{x}), \dots, h_K(\mathbf{x})), \quad (9)$$

式中: $g(\cdot)$ 为元学习器, 常用模型包括 Logistic 回归、线性回归、SVM、简单神经网络等。

采用两层 Stacking 框架, 整体计算流程如下: ①基学习器训练 (Level-0 层) 使用原始数据分别训练 XGBoost 和 LSTM 模型, 在验证集上输出各基学习器的预测结果; ②构造二级特征, 将一级模型的预测结果拼接成新的特征向量 \mathbf{Z} ; ③元学习器训练 (Level-1 层) 以 \mathbf{Z} 作为输入特征, 使用元学习器 $g(\cdot)$ 进行训练, 得到最终集成预测模型; ④测试与预测, 在测试集上, 先用基学习器生成预测结果, 再输入元学习器, 输出最终预测值。

3 预测结果与讨论

3.1 数据归一化

在模型训练前对数据进行归一化处理。归一化后的特征值为

$$a' = \frac{a - a_{\min}}{a_{\max} - a_{\min}}, \quad (10)$$

式中: a 为原始特征值; a_{\max} 、 a_{\min} 分别为该特征在数据集中的最大值和最小值。

归一化操作仅基于训练集的统计信息计算 a_{\min} 和 a_{\max} , 并将同样的归一化比例应用到测试集上, 避免因测试集信息泄露带来的评估偏差。共使用 17 组监测数据, 其中前 12 组作为训练集, 后 5 组作为测试集。


3.2 模型参数设置

分别优化 XGBoost 模型、LSTM 模型及 Stacking 集成模型的主要参数。调整 XGBoost 模型的最大树深、学习率、弱学习器数量、子样本比例, 以提升树模型的特征建模能力。优化 LSTM, 以更好捕捉时间序列特征。Stacking 模型采用 XGBoost 与 LSTM 的预测输出构建二级特征矩阵, 并以线性回归作为元学习器。参数设置见表 3。


表3 模型参数设置
Tab.3 model parameter settings

模型	参数	取值
XGboost	最大树深	20
	学习率	0.08
	弱学习器数量	100
	子样本比例	0.8
	最小分裂损失	0
LSTM	隐藏单元数	100
	学习率	0.001
	批次大小	32
	最大迭代次数	200

XGBoost模型和LSTM模型的适应度曲线见图6。初始阶段,2种模型适应度均提升较快,在前50次迭代中,平均适应度和最优适应度迅速下降,快速逼近最优解。50次迭代后,曲线趋于平稳,说明模型已收敛并保持稳定,验证了所设参数下模型的有效性与收敛性。采用泰勒图展示均方根误差(RMSE)、标准差(STD)、相关系数 r 之间的关系,见图7。



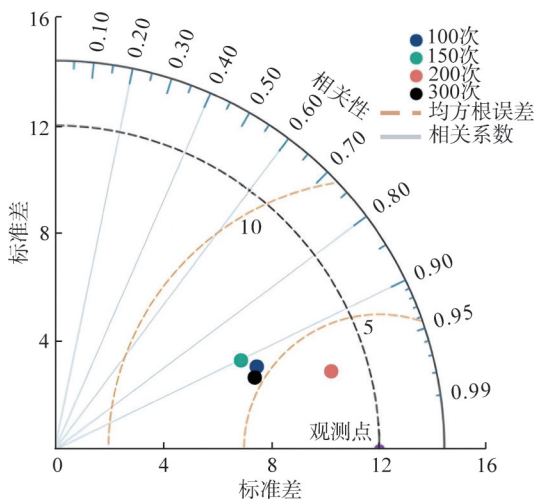
(a) XGBoost模型



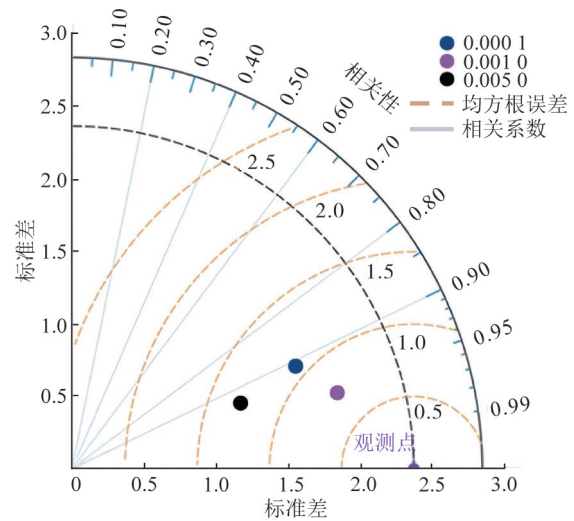
(b) LSTM模型

图6 适应度曲线

Fig.6 fitness curve



(a) 不同迭代次数



(b) 不同学习率

图7 泰勒分析图

Fig.7 Taylor diagram

泰勒图里的散点分别代表不同的指标组合预测值。由图7(a)可知,当迭代次数增加至200次时,模型在相关系数、标准差和均方根误差上的综合表现最优,接近观测值点。由图7(b)可知,当学习率为0.001时,模型的相关系数最高,标准

差最接近观测值,预测性能最为理想。

3.3 模型预测结果及对比分析

为验证集成模型的有效性,选取随机森林(RF)模型和支持向量回归(SVR)模型与集成模型进行性能对比分析,选取决定系数 R^2 、均方根

误差 (RMSE) 和平均绝对误差 (MAE) 作为评价指标。模型预测结果对比见图 8。

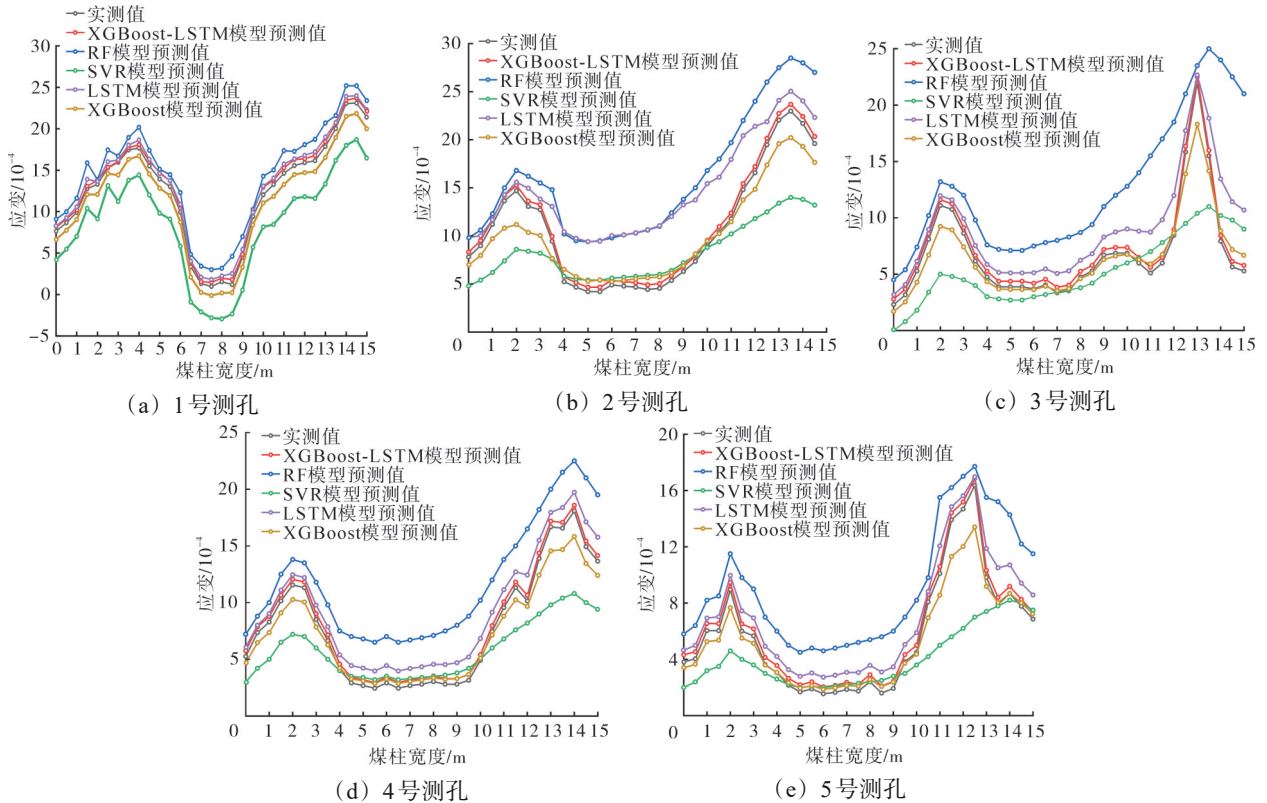


图 8 模型预测结果对比

Fig.8 comparison of model prediction results

XGBoost-LSTM 模型显著提升了预测性能, 相较于最优 LSTM 模型 R^2 提升至 0.922, 提升了 0.029, RMSE 降低至 4.215×10^{-6} , 误差降低了约 0.661×10^{-6} , 表现出更强的泛化能力和拟合精度, 模型性能对比见表 4。

表 4 不同模型应变预测性能对比
Tab.4 comparison of strain prediction performance metrics among different models

模型	R^2	RMSE/ 10^{-6}	MAE/ 10^{-6}
XGBoost	0.871	5.124	3.045
LSTM	0.893	4.876	2.832
RF	0.785	6.103	3.682
SVR	0.812	5.947	3.498
XGBoost-LSTM	0.922	4.215	2.135

XGBoost-LSTM 模型在监测区域上能够较好地拟合实际应变曲线, 预测曲线与真实曲线基本一致, 尤其在煤柱中部监测孔处于相对稳定的受力环境, 应变演化较为平缓, 模型预测效果较好。在靠近采动工作面的煤柱边部区域受超前支承压力影响, 应力集中显著, 应变变化突发且幅度大, 导致模型在该区域的拟合精度下降。

4 结论

(1) 二次采动作用下, 煤柱水平应变分布表现出明显的“双峰型”空间特征, 边部应变显著高于中部区域。随着工作面的持续推进, 超前支承压力的周期性扰动使煤柱内部逐步产生累积性损伤, 受损区域在后续采动阶段对矿压变化更加敏感, 形变幅度明显增大。

(2) 揭示了二次采动条件下煤柱内部弹性区与塑性区的时空演化规律, 确定弹性区主要分布于距煤柱边界 3~12 m 内。结果表明, 分布式光纤传感技术能够精准反映煤柱在采动扰动下的变形演化特征, 验证了其在实现煤柱分布式、长距离、高精度与实时监测方面的显著优势。

(3) 基于煤柱应变实测数据, 构建了融合 XGBoost 与 LSTM 的 Stacking 集成预测模型, 实现了多源特征与时序信息的有效融合。该模型在 R^2 、RMSE 和 MAE 等评价指标上均优于单一模型, 能准确刻画煤柱在平稳与波动阶段的变形趋势。验证了该模型在区段煤柱短期变形预测与灾害预警中的科学性与实用性。

参考文献(References):

- [1] 汪北方, 蒋嘉祺, 张学朋, 等. 浅埋临空下工作面开采强矿压显现诱因及支护载荷研究[J]. 采矿与安全工程学报, 2025, 42(5): 1064-1075.
WANG Beifang, JIANG Jiaqi, ZHANG Xuepeng, et al. Study on strong mining pressure manifestation cause and support load of shallow-buried working face under goaf[J]. Journal of Mining & Safety Engineering, 2025, 42(5): 1064-1075.
- [2] 张宏伟, 赵象卓, 韩军, 等. 极近距离煤层重复采动矿压显现规律[J]. 辽宁工程技术大学学报(自然科学版), 2018, 37(2): 225-231.
ZHANG Hongwei, ZHAO Xiangzhuo, HAN Jun, et al. Strata behavior characteristics of extra contiguous seams with repeated mining[J]. Journal of Liaoning Technical University (Natural Science), 2018, 37(2): 225-231.
- [3] 丁自伟, 李帅, 张杰, 等. 近距离煤层回采巷道非对称破坏机理及其控制[J]. 采矿与安全工程学报, 2024, 41(2): 242-254.
DING Ziwei, LI Shuai, ZHANG Jie, et al. Asymmetric failure mechanism and control of entries in short-distance coal seam[J]. Journal of Mining & Safety Engineering, 2024, 41(2): 242-254.
- [4] 许猛堂, 徐佑林, 金志远. 房式采空区下近距离煤层开采支架工作阻力研究[J]. 煤炭科学技术, 2020, 48(8): 63-69.
XU Mengtang, XU Youlin, JIN Zhiyuan. Research on support resistance of contiguous coal seam mining under room-and-pillar gob[J]. Coal Science and Technology, 2020, 48(8): 63-69.
- [5] 李亮, 何富连, 许旭辉, 等. 近距离煤层应力拱形态与支承压分布演化研究[J]. 采矿与安全工程学报, 2023, 40(2): 295-303.
LI Liang, HE Fulian, XU Xuhui, et al. Study on the evolution of stress arch shape and abutment pressure distribution in close distance coal seams[J]. Journal of Mining & Safety Engineering, 2023, 40(2): 295-303.
- [6] 张旭苹, 张益昕, 王亮, 等. 分布式光纤传感技术研究和应用的现状及未来[J]. 光学学报, 2024, 44(1): 0106001.
ZHANG Xuping, ZHANG Yixin, WANG Liang, et al. Current status and future of research and applications for distributed fiber optic sensing technology[J]. Acta Optica Sinica, 2024, 44(1): 0106001.
- [7] 程刚, 王振雪, 施斌, 等. DFOS 在矿山工程安全开采监测中的研究进展[J]. 煤炭学报, 2022, 47(8): 2923-2949.
CHENG Gang, WANG Zhenxue, SHI Bin, et al. Research progress of DFOS in safety mining monitoring of mines[J]. Journal of China Coal Society, 2022, 47(8): 2923-2949.
- [8] TANG B, CHENG H. Application of distributed optical fiber sensing technology in surrounding rock deformation control of TBM-excavated coal mine roadway[J]. Journal of Sensors, 2018, 2018(1): 8010746.
- [9] CHAI J, DU W G, YUAN Q, et al. Analysis of test method for physical model test of mining based on optical fiber sensing technology detection[J]. Optical Fiber Technology, 2019, 48: 84-94.
- [10] XU S A, ZHANG P S, ZHANG D, et al. Simulation study of fiber optic monitoring technology of surrounding rock deformation under deep mining conditions[J]. Journal of Civil Structural Health Monitoring, 2015, 5(5): 563-571.
- [11] 杨健锋, 刘泽宇, 柴敬, 等. 区段煤柱内部变形光纤监测应用研究[J]. 采矿与岩层控制工程学报, 2025, 7(2): 224-237.
YANG Jianfeng, LIU Zeyu, CHAI Jing, et al. Applied research on fiber optic monitoring of internal deformation of coal columns in sections[J]. Journal of Mining and Strata Control Engineering, 2025, 7(2): 224-237.
- [12] 柴敬, 郝鸿儒, 杨健锋, 等. 基于BOTDR的区段煤柱水平变形监测[J]. 煤田地质与勘探, 2024, 52(5): 46-55.
CHAI Jing, HAO Hongru, YANG Jianfeng, et al. BOTDR-based horizontal deformation monitoring of section coal pillars[J]. Coal Geology & Exploration, 2024, 52(5): 46-55.
- [13] 杜文刚, 柴敬, 张丁丁, 等. 采动覆岩导水裂隙发育光纤感测与表征模型试验研究[J]. 煤炭学报, 2021, 46(5): 1565-1575.
DU Wengang, CHAI Jing, ZHANG Dingding, et al. Optical fiber sensing and characterization of water flowing fracture development in mining overburden[J]. Journal of China Coal Society, 2021, 46(5): 1565-1575.
- [14] 张晨思, 王茂宁, 钟羽中, 等. 高干扰环境下基于分布式光纤声波传感的微弱语音信号检测[J]. 工程科学与技术, 2025(2): 29-39.
ZHANG Chensi, WANG Maoning, ZHONG Yuzhong, et al. Weak speech signal detection in high interference environment based on distributed acoustic sensing[J]. Advanced Engineering Sciences, 2025(2): 29-39.
- [15] 柴敬, 王润沛, 杜文刚, 等. 基于XGBoost的光纤监测矿压时序预测研究[J]. 采矿与岩层控制工程学报, 2020, 2(4): 60-67.
CHAI Jing, WANG Runpei, DU Wengang, et al. Study on time series prediction of rock pressure by XGBoost in optical fiber monitoring[J]. Journal of Mining and Strata Control Engineering, 2020, 2(4): 60-67.
- [16] 赵毅鑫, 杨志良, 马斌杰, 等. 基于深度学习的大采高工作面矿压预测分析及模型泛化[J]. 煤炭学报, 2020, 45(1): 54-65.
ZHAO Yixin, YANG Zhiliang, MA Binjie, et al. Deep learning prediction and model generalization of ground pressure for deep longwall face with large mining height[J]. Journal of China Coal Society, 2020, 45(1): 54-65.
- [17] 冀汶莉, 田忠, 张丁丁, 等. 基于遗传算法-深度神经网络的分布式光纤监测工作面矿压预测[J]. 科学技术与工程, 2022, 22(24): 10485-10492.
JI Wenli, TIAN Zhong, ZHANG Dingding, et al. Mine pressure prediction by genetic algorithm-deep neural network based on distributed optical fiber monitoring[J]. Science Technology and Engineering, 2022, 22(24): 10485-10492.