

基于深度学习的井筒变形预测模型与应用

刘 辉^{1,2}, 李国强^{1,2}, 朱晓峻^{1,2}, 张鹏飞^{1,2}, 程 桦^{1,2}, 王金正³, 李培帅³

(1. 安徽大学 资源与环境工程学院, 安徽 合肥 230601; 2. 安徽省矿山生态修复工程研究中心, 安徽 合肥 230601; 3. 山东能源集团鲁西矿业有限公司 郭屯煤矿, 山东 菏泽 274000)

摘要:近年来我国东部矿区发生了多起立井井筒倾斜变形及破损失害,严重影响了矿井安全与生产。针对厚含水松散层深立井倾斜破损失害,以鲁南某矿深立井井筒(800 m)为研究对象,开展了井筒倾斜监测,研究了井筒倾斜时空变化特征,分析了井筒倾斜主要影响因素;在此基础上,基于深度学习理论,综合采用循环神经网络(RNN)、长短期记忆网络(LSTM)、门控循环单元(GRU)、一维卷积神经网络(1DCNN)四种经典深度学习方法,构建了井筒倾斜变形预测模型,并将预测结果与实测值进行对比,分析了井筒变形预测模型精度,研究了井筒整体和关键区域预测效果,验证了模型可靠性,并开展了工程应用。研究表明:①井筒倾斜主要发生在松散层,倾斜值由浅到深线性减小、并偏向采空区一侧,最大为352 mm,基岩层变形较小,最大为88 mm;开采引起厚松散层变形传播范围增大、底部含水层沿井壁渗流疏水及地下水渗流场的变化是导致井筒倾斜变形的主要原因。②模型与实测值 Spearman 相关系数最大为 0.978,最小为 0.867,4 种模型与现场实测偏移量的最大差值为 0.043 m,平均绝对误差 E_{MA} 在 0.003~0.009 m 内,均方根误差 E_{RMS} 在 0.004~0.011 m 内,整体预测效果以 1 DCNN 模型最优,主要倾斜方向(偏向采空区一侧的东西方向)预测精度略低于变形量较小的方向(南北方向),且均能够满足工程需要。③井筒整体预测曲线与实际倾斜方向一致,井口、松散层基岩交界面 E_{MA} 与 E_{RMS} 平均值均为 0.005 m、0.006 m,井底精度略低,其对应值为 0.012、0.013 m,井筒特征区域与整体预测效果均表现良好,表明基于深度学习的井筒变形预测模型具有良好的预测能力,研究成果在井筒注浆修复治理工程中得到了有效应用,为井筒安全管理提供了技术参考和数据支撑,为类似工程提供了工程实践经验。

关键词:煤矿立井; 倾斜变形; 深度学习; 井筒预测; 神经网络

中图分类号: TD262; TP18 **文献标志码:** A **文章编号:** 0253-9993(2025)02-0732-16

Exploration and application of deep learning based wellbore deformation forecasting model

LIU Hui^{1,2}, LI Guoqiang^{1,2}, ZHU Xiaojun^{1,2}, ZHANG Pengfei^{1,2}, CHENG Hua^{1,2}, WANG Jinzheng³, LI Peishuai³

(1. College of Resource and Environmental Engineering, Anhui University, Hefei 230601, China; 2. Anhui Province Engineering Research Center for Mine Ecological Remediation, Hefei 230601, China; 3. Guotun Coal Mine, Shandong Energy Group Luxi Mining Company Limited, Heze 274000, China)

Abstract: In recent years, a number of vertical shaft tilt deformation and breakage disasters have occurred in the eastern mining areas of China, which have seriously affected mine safety and production. In response to the tilting and damage

收稿日期: 2024-04-25 策划编辑: 郭晓炜 责任编辑: 钱小静 DOI: 10.13225/j.cnki.jccs.2024.0069

基金项目: 国家自然科学基金资助项目(52174156, 51804001); 安徽省高校协同创新资助项目(GXXT-2020-055)

作者简介: 刘 辉(1982—), 男, 山东肥城人, 教授, 博士生导师, 博士。E-mail: lhui99@aliyun.com

通讯作者: 朱晓峻(1989—), 男, 江苏盐城人, 教授, 硕士生导师, 博士。E-mail: zhuxiaojunahu@126.com

引用格式: 刘辉, 李国强, 朱晓峻, 等. 基于深度学习的井筒变形预测模型与应用[J]. 煤炭学报, 2025, 50(2): 732–747.

LIU Hui, LI Guoqiang, ZHU Xiaojun, et al. Exploration and application of deep learning based wellbore deformation forecasting model[J]. Journal of China Coal Society, 2025, 50(2): 732–747.



移动阅读

disasters of deep vertical shafts in thick water-bearing loose layers, the tilting and deformation monitoring of shafts was carried out by taking the deep vertical shaft (800 m) of a mine in Lunan as the research object, studying the spatial and temporal change characteristics of shaft tilting, and analyzing the main influencing factors of shaft tilting; based on this, based on the deep learning theory, four types of deep learning method, namely, recurrent neural network (RNN), long and short-term memory network (LSTM), gated recurrent unit (GRU), and one-dimensional convolutional neural network (1DCNN), were used. unit (GRU), and one-dimensional convolutional neural network (1DCNN) to construct a wellbore tilt deformation prediction model, and compare the prediction results with the measured values to analyze the accuracy of the wellbore deformation prediction model, validate the reliability of the model, studied overall wellbore and critical area prediction effects, and carry out engineering applications. The study shows that: ① The wellbore tilt mainly occurs in the loose layer, the tilt value decreases linearly from shallow to deep, and is biased towards the side of the extraction zone, with a maximum of 352 mm, and the deformation of the bedrock layer is smaller, with a maximum of 88 mm; the increase in the range of deformation propagation in the thick loose layer caused by the mining, and the change of seepage hydrophobicity of the aquifer at the bottom along the wall of the well and the seepage field of the groundwater are the main causes of the tilted deformation of the wellbore. ② The Spearman correlation coefficient between the model and the measured value is 0.978 at the maximum and 0.867 at the minimum; the maximum difference between the four models and the field measured offsets is 0.043 m, the mean absolute error E_{MA} is within 0.003–0.009 m, and the root mean square error E_{RMS} is within 0.004–0.011 m. The overall prediction is optimized by the 1DCNN model, and the main tilting direction (The prediction accuracy of the main inclined direction (east-west direction, which is inclined to the side of the mining area) is slightly lower than that of the direction with smaller deformation amount (north-south direction), and all of them can meet the engineering needs. ③ The overall prediction curve of the wellbore is consistent with the actual tilt direction, and the average values of E_{MA} and E_{RMS} of the wellhead and loose bedrock interface are 0.005 m and 0.006 m. The accuracy of the wellbore bottoming is a little bit lower, with the corresponding values of 0.012 m and 0.013 m. The wellbore characteristic area and overall prediction effect are good, indicating that the wellbore deformation prediction model based on deep learning has good prediction ability. The research results have been effectively applied in the wellbore grouting repair and management project, which provides technical reference and data support for the safe management of wellbore, and provides engineering practical experience for similar projects.

Key words: mine vertical shaft; deflection deformation; deep learning; wellbore forecasting; neural network

0 引言

我国东部矿区煤炭资源赋存具有煤层埋藏深、松散层厚且潜水位高等地域特征^[1]。随着我国东部矿区开采深度逐年增加,由于矿区活动、地质采矿条件及井筒构造等众多因素,导致多地矿区井筒出现不同程度的变形破坏^[2],其中以厚松散层薄基岩富含水地质条件尤为突出。立井井筒作为地下矿山的咽喉要道,其安全状态在煤矿生产中至关重要,一旦井筒发生变形或破损,将直接影响井筒正常提升,还可能导致井壁破损,严重危及矿井安全。如2015年山东菏泽某煤矿主、副井最大偏斜量分别高达359 mm和322 mm,导致井筒无法正常提升,并对井壁安全造成了巨大威胁^[3]。

目前,矿区井筒变形预测方法主要可分为3种:
①基于力学机理的理论分析法。该方法通常采用弹塑性理论,根据工程条件计算预测井筒变形位移。如

徐晓峰等^[4]推出了井筒竖向附加力的解析解,对后续井壁变形预测给予根据。独知行等^[5]建立了井筒变形的数学模型以便了解预测井筒变形规律。李文平^[6]建立了弹塑性分析模型用来计算井壁附加竖直位移。杨维好等^[7]根据弹塑性力学模型,推导了井筒应力与位移解析解。②基于经验参数的模型预测法。该类方法通过建立包含概率积分法、时间函数法等在内的数学模型,或按试验模拟及数值模拟方法建立矿区井筒模型,进行实际开采过程及受力模拟,分析其受力和位移的变化规律,推断出实际工程过程中的变化以此进行后续变形的预测。如HAN等^[8]通过概率积分法和Knothe时间函数建立了井筒动态预测模型,程桦^[9]通过建立地层移动三维时空模型反演计算井筒倾斜变形位移,高杰、郭洛、徐勇等^[10-12]采用FLAC^{3D}软件对立井井筒及周围地层变形规律进行模拟预测研究。③基于数据分析的机器学习法。该方法主要基于计算机理论、非线性理论及数学思想,在计算机

的辅助下,探究变形特征的学习及运算,不受常规地质采矿条件及水文等复杂物理参数的限制,其原理中的回归思想与时序预测任务紧密关联。如王坚^[13]提出了采用自适应 GM(1,1) 模型进行地表沉降预测,彭涛^[14]将 BP 神经网络与灰色系统联合,建立沉降预测模型进行分析,唐艳梅^[15]采用支持向量机模型建立井筒变形-时间关系模型用于井筒灾害预测,胡安峰、YUAN 等^[16-17]基于深度学习 LSTM 模型对实测沉降数据和矿区地表沉陷进行处理与预测,LIU 等^[18]建立灰色-马尔可夫模型对矿区地表沉降进行预测研究。

上述方法主要关注于煤层开采活动下井筒及地表整体变形破坏规律,一般是从井筒与地层相互作用的角度,开展基于数理统计或物理机制等预测模型的研究,对于解决井筒地表沉降及岩层区域移动变形预测方面研究起到了积极作用。但相关研究大多没考虑厚松散层薄基岩富含水条件下井筒深部区域变形情况,或提出的变形预测模型相对复杂、应用范围有限,无法精准预测不同介质条件下井筒各位置的变形。近年来,随着深度学习在矿山开采沉陷变形领域的广泛应用,与传统方法相比,深度学习能够在时间纬度上捕获、储存更多的有效信息,可以迅速准确的拟合出输入与输出间的关系,学习数据内在的逻辑并将其运用在预测任务上。

笔者以鲁南某矿立井井筒为研究对象,针对厚松散层薄基岩富含水地质条件,分析了立井井筒倾斜变形时空特征及主要原因,在此基础上,基于深度学习中循环神经网络(RNN)、长短期记忆网络(LSTM)、门控循环单元(GRU)、一维卷积神经网络(1DCNN)四种经典神经网络,构建了井筒变形预测模型,并将预测结果与实测值进行对比,研究了井筒整体与局部

特征区域的预测效果,验证了井筒预测模型的可靠性,并开展了工程应用,研究成果为井筒注浆治理修复提供预警作用,从而获取准确可靠的井筒变形预期信息,为井筒修复治理、安全管理提供重要参考价值。

1 研究区概况

1.1 地质采矿条件

鲁南矿区巨野煤田具有煤层赋存深(≥ 1000 m),地层富水性强(3个以上含水层),松散层较厚(400~800 m),松散层与基岩厚度比较小(0.1~0.5)等特点。研究区域位于巨野煤田中北部,为第四系覆盖的全隐伏式井田,受区域构造及沉积环境因素影响,松散层厚度由东向西逐渐增大,东西方向厚度差异显著,其中上覆新生界松散层厚度为530~580 m,大多以黏土、砂质黏土、砂岩为主,基岩平均厚度为260 m,大多以泥岩、粉砂岩为主,属于典型的厚松散层薄基岩地质条件。根据松散层岩土类型及富水特性,新生界松散层自上而下依次划分为3个含水层和2个隔水层,基岩段划分为2个含水层和2个隔水层。其中,松散层第四系上部主要为砂质黏土含水层(一含),下部为强隔水的砂质黏土层(一隔);新近系地层上部是以细砂、粉砂和黏土质粉砂为主的含水层(二含),中部为平均厚度157 m的砂质、粉砂质黏土隔水层(二隔),下部为平均厚度40 m的第3含水层(底含),具体情况见表1^[19]。矿井设计生产能力2.4 Mt/a,主、副立井井筒均建于工业广场中央,其净直径分别为5.0、6.5 m,井筒深度分别为853.0、882.0 m,2个立井井筒穿越的新生界地层与基岩风化带部位均采用冻结法施工,基岩段正常普通施工,井筒与井壁结构特征与参数见表2。

表1 含、隔水层(组、段)划分
Table 1 Division of aquifer and aquifuge

地层	含隔水层	底板深度/m		厚度/m	
		检1孔(主)	检2孔(副)	检1孔(主)	检2孔(副)
第四系	含水层	85.60	85.20	45.75	37.17
	隔水层	136.10	138.30	45.70	48.20
上第三系	上部含水层	333.60	334.30	74.70	78.10
	中部隔水层	542.00	546.60	149.86	159.70
	下部含水层	587.40	586.22	37.00	25.50
上石盒子组	风氧化带上隔	609.80	613.10	22.06	26.46
	风氧化带中含	660.20	666.20	36.35	37.22
	风氧化带下隔	674.00	680.39	13.60	13.88
	风氧化带下含	上 697.40	698.10	18.12	17.53
		下 874.77	883.48	49.12	68.14

表 2 主、副井井筒特征

井筒	垂深/m	净径/m	冻结深度/m	松散层厚度/m	基岩段井壁结构		冻结段井壁结构
主井	853	5.0	702	587.4	C50单层素混凝土井壁, 厚度1 300 mm	双层钢筋混凝土井壁，内壁1 000 mm，外壁1 150 mm， 内外壁之间铺设2层1.5 mm塑料夹层	
副井	882	6.5	702	586.2	C50单层素混凝土井壁, 厚度1 300 mm	双层钢筋混凝土井壁，内壁1 200 mm，外壁1 200 mm， 内外壁之间铺设2层1.5 mm塑料夹层	

经现场监测,该矿于2015年发现:①主、副井筒预留的竖向可压缩性接头发生压缩闭合,井筒罐道梁发生竖向弯曲;②主、副井罐笼与井壁或其他装备的安全距离不符合《煤矿安全规程》要求,罐道出现倾斜;③井壁破裂部位主要发生在新进系松散层底部含水层段,也有深入到其下的基岩强风化带内0.5~2.0 m内,一般破坏段高度在1~15 m内;④破裂形态大都呈现水平环状,破裂处出现渗水、涌水,井壁松散层段拉开处发生不同程度破坏,存在固结水泥浆液,如图1a所示;井壁基岩段在彼此接头相连处沿环向部分拉开,拉开间距不等,如图1b所示^[20]。



(a) 素十段

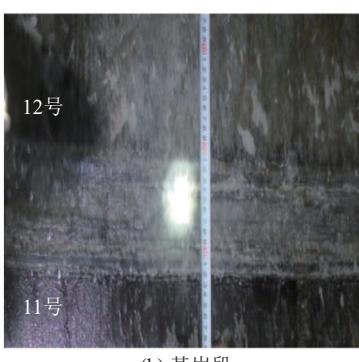


图 1 井筒区域破坏

Fig 1 Wellbore area damage

1.2 井筒倾斜监测

为保证矿区井筒安全生产,于2015年8月—2023年2月开展了井筒变形监测,以2015年8月为第1期,每间隔3个月监测1次,截止2023年2月累计监测30期。

1.2.1 监测方法

针对主、副立井井筒复杂环境,为提高监测效率,

笔者自主研制了专用的井壁测量装置,该装置包括卡槽、卡槽支脚、主体金属骨架与手持式激光测距仪,卡槽用于固定两侧钢丝,卡槽支脚用于构造特殊导线角,激光测距仪用于测量其到井壁点距离,具体结构如图2所示。

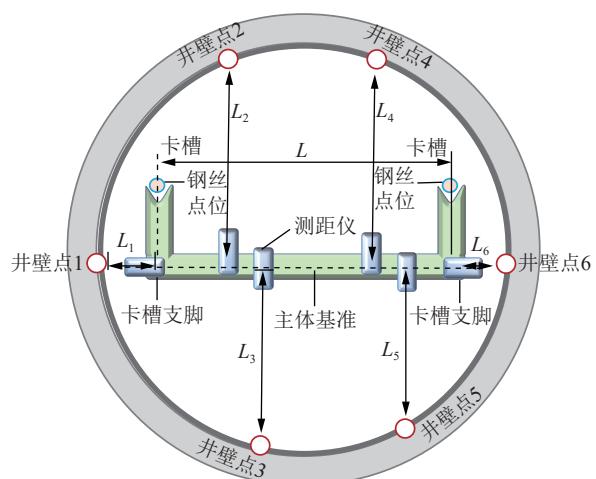


图 2 井筒平面测量装置

Fig.2 Wellbore plane measuring device

基于矿井生产现状,采用双垂线基准法结合特制监测装置,开展矿区井筒变形监测,具体步骤如下:

(1) 在不干扰提升设施及便于保护的前提下,在井筒两内侧分别设置两条钢丝至井筒底部,确定其铅垂平稳后,将钢丝固定形成双垂线基准,旨在提供井筒变形监测的基准。

(2) 在监测装置主体基准线上两端各选取一监测点(井壁点1、6),两侧法线方向上分别选取等间距4个监测点(井壁点2~5),通过对近井控制点导线测量计算2根钢丝平面坐标,进而计算6个井壁监测点坐标,点位如图2所示。

(3) 在罐笼内部搭建监测作业平台,进入平台后先将竖井中已固定好的钢丝嵌入卡槽钢丝点位,随后将整个监测装置固定水平,选取 $15\sim20$ m 为 1 个测量间隔,下放罐笼等间距测量测距仪中心到井壁点距离,监测示意如图 3 所示。

(4) 监测作业时应注意: 装置监测要求主体基准线平直有刚度, 且与测距仪光束垂直, 主体基准线须平

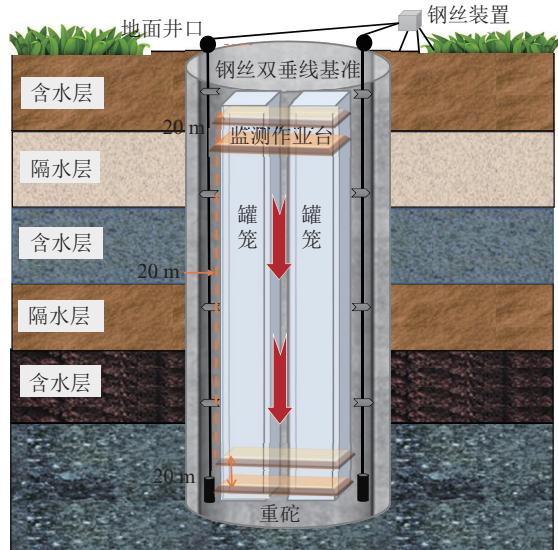


图 3 井筒监测示意

Fig.3 Schematic diagram of wellbore monitoring

行两卡槽连线;两卡槽间距等于钢丝双垂线间距;数据采集时应保证点位完整照射在井壁上,避免井筒内部构筑物抵挡。

1.2.2 数据处理

如图 4 所示, L_1, L_2, \dots, L_6 为骨架中心线上各点到井壁内侧的水平距离; r_1, r_2, \dots, r_6 为骨架中心线与测距方向的水平夹角; S_1, S_7 分别为钢丝 A 到 1 号测距仪、钢丝 B 到 6 号测距仪的距离, S_2, S_3, \dots, S_6 分别为各测距仪之间的距离。

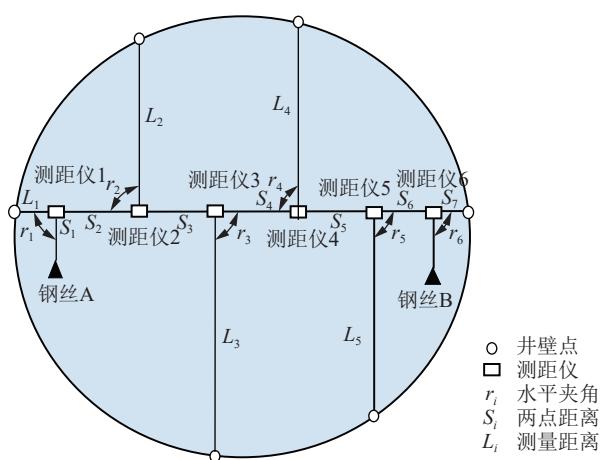


图 4 井筒变形测量原理

Fig.4 Measurement principle diagram of s丈量 device

以 A、B 钢丝平面位置为已知点,按照导线进行解算,得到各井壁点平面坐标。利用每个断面上的 6 个测点坐标,计算出每个断面的圆心坐标 (x, y) 及半径 R ,进而得到井筒整体变形情况。其计算原理如下:以井壁某一断面上各测点坐标为 (x_i, y_i) ,其中, $i=1, 2, \dots, 6$; 截面中心坐标为 (x, y) , 截面半径为 R ,则:

$$\begin{cases} (x - x_1)^2 + (y - y_1)^2 = R^2 \\ (x - x_2)^2 + (y - y_2)^2 = R^2 \\ \dots \\ (x - x_6)^2 + (y - y_6)^2 = R^2 \end{cases} \quad (1)$$

以

$$x_0 = \sum_{i=1}^6 x_i / 6, y_0 = \sum_{i=1}^6 y_i / 6, R_0 = \sqrt{(x_0 - x_1)^2 + (y_0 - y_1)^2}$$

为初值将式(1)线性化,得到误差方程式(式(2)、(3))为

$$X_{3 \times 1} = \begin{bmatrix} \delta x \\ \delta y \\ \delta R \end{bmatrix}, A_{6 \times 3} = \begin{bmatrix} (x - x_1) / R_0 & (y - y_1) / R_0 & -1 \\ (x - x_2) / R_0 & (y - y_2) / R_0 & -1 \\ \vdots & \vdots & \vdots \\ (x - x_6) / R_0 & (y - y_6) / R_0 & -1 \end{bmatrix} \quad (2)$$

$$L_{6 \times 1} = \begin{bmatrix} R_0 - \sqrt{(x_0 - x_1)^2 + (y_0 - y_1)^2} \\ R_0 - \sqrt{(x_0 - x_2)^2 + (y_0 - y_2)^2} \\ \vdots \\ R_0 - \sqrt{(x_0 - x_6)^2 + (y_0 - y_6)^2} \end{bmatrix} \quad (3)$$

然后通过 Matlab 软件,采用经典最小二乘法求解得到井壁断面中心坐标及半径。选取井底拟合圆心为基准,对比各监测断面圆心坐标与基准坐标偏差,计算井筒各层平面上沿南北、东西方向上倾斜量,结合井筒对应断面高度,可较为直观的了解井筒整体倾斜变形情况^[21-23]。

1.3 井筒变形特征

监测发现,井筒自上而下发生不同程度的倾斜变形,选取第 13~16 期的监测数据,绘制了井筒倾斜变形,如图 5 所示。

随着井筒空间高度上升,主、副井倾斜变形呈现以下特征:

(1) 整体变形特征: 在东西方向上,副井在基岩层整体倾斜相对平稳,主要倾斜量在 20 mm 以内,主井在基岩层倾斜较大,变化显著,至松散层区域内,主、副井整体倾斜值线性增加,并偏向西方向采空区一侧,在井口附近达到最大值 352、282 mm; 在南北方向上,主、副井整体倾斜变化较小,整体向北缓慢倾斜,在靠近井口处倾斜较为明显,其最大值分别为 54、95 mm。

(2) 局部变形特征: 在井筒底部,井筒整体倾斜波动较小均在 30 mm 以内,仅在主井沿西方向倾斜量线性增长,最大值达到 88 mm; 在松散层基岩交界面,主井沿西方向倾斜量减小,由 88 mm 减至最低值 0,沿北方向倾斜局部增长至最大值 50 mm,副井整体在

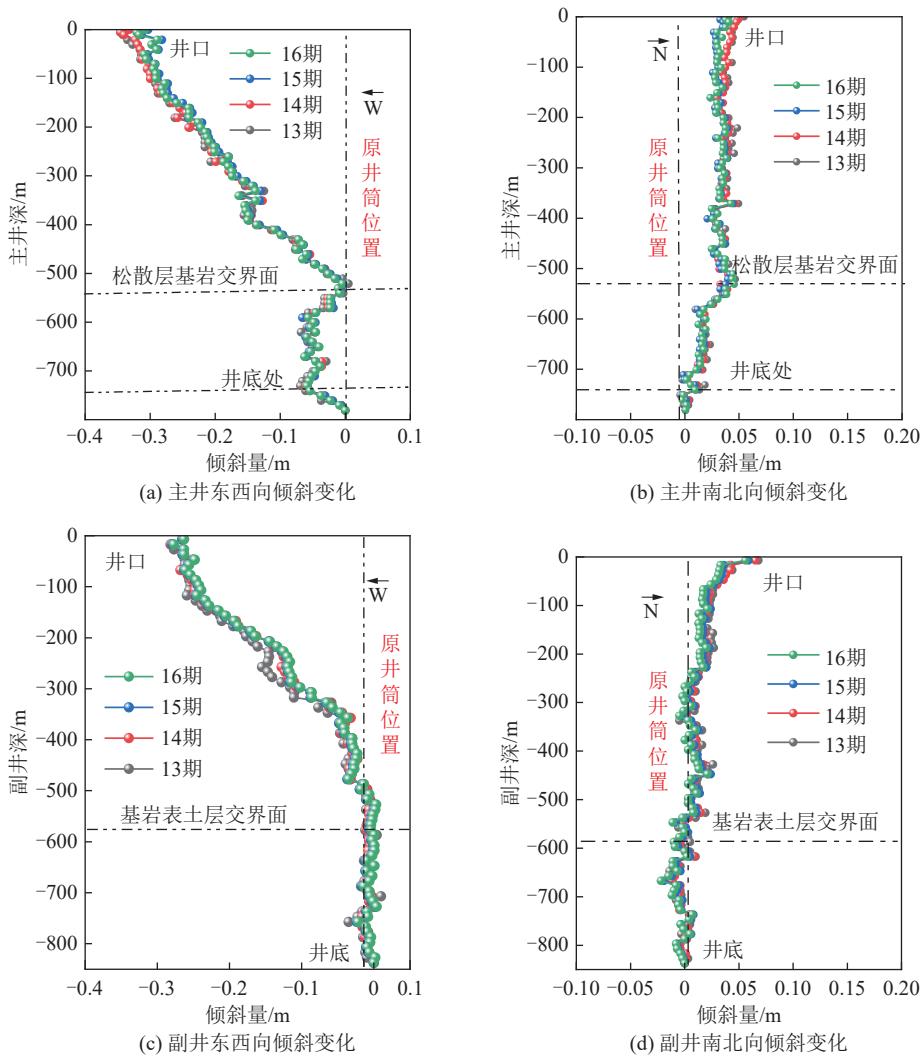


图5 主、副井13~16期倾斜变化

Fig.5 Inclination change of main and secondary wells from 13th to 16th period

基岩交界面变化不受影响;在井筒井口,主、副井倾斜速率较快,且在此处倾斜值增长至最大。

(3) 倾斜差异简析:在松散层内,主井井筒倾斜值由浅到深线性减小,至松散层基岩交界面减小为0,而在进入基岩层后,倾斜量沿西方向继续增加。由于开采工作面均位于工业广场西侧,其中该矿1301、1302工作面终采线与主井直线距离分别为858、1000 m,前期受主要活跃采空区影响较大,井筒发生向采空区一侧倾斜,即在厚松散层内,井筒发生连续水平位移变形,且随松散层厚度加深,沿西方向移动阻力增大,位移逐渐减小;当主井进入松散层基岩交界面,松散层土体密度和凝聚力进一步增加,致使井筒在该区域内移动量趋近于0;当主井深入至基岩层,由于松散层与基岩层物理性质不同,岩层存在较大差异,上覆厚松散层整体发生连续变形,在上部地层巨大推动力作用下,致使原先稳定的基岩层发生向西方向相对滑移,岩层土体在滑移一定距离后,在主井底部重新趋近

于0。

综上可知,井筒倾斜主要发生在松散层内,倾斜值由浅到深线性减小、并偏向西北(采空区)一侧,而基岩层内变形较小。

1.4 井筒倾斜原因分析

1.4.1 厚松散层地质条件的影响

当在厚松散层薄基岩下开采且采用垮落法管理顶板,上覆基岩受厚松散层自重应力影响,在较短时间内自下而上形成垮落带、裂缝带和弯曲带的“上三带”分布模式,其中裂缝带迅速发展至岩层表面,造成采空区上覆岩层大范围内发生垂直于层理面的裂缝或断裂,进而导致上覆岩层、松散层及致地表发生较大弯曲变形。相较于常规地质采矿条件(松散层较薄或无松散层的浅埋煤层)移动变形整体时间较短,而厚松散层矿区地表变形表现为持续时间更长、下沉系数更大、影响范围更广等特点。如:该矿1303工作面停采后7个月内仍未进入衰退期,地表最大下沉值为

2 541 mm, 下沉系数达 0.92。

按现行《建筑物、水体、铁路及主要井巷煤柱留设与压煤开采规范》, 该矿区工业广场保护煤柱留设综合移动角取 $52^\circ \sim 55^\circ$ 。由于对松散层土体移动变形缺乏深入研究, 移动角取值过大, 当开采深度达 700 m 以上时, 地表移动盆地主要影响半径超过 1 400 m^[24-26], 按现行规范设计井筒保护煤柱尺寸过小, 致使井筒仍处于地表沉陷影响范围内。因井筒细长, 侧向抗弯能力弱, 难以抵御厚松散层移动变形, 故在非对称开采条件下易发生向采空区一侧倾斜。现场监测发现, 井口处向采空区一侧最大水平移动值在 300 mm 以上, 在松散层内由浅到深线性减小, 在进入新近系地层后(垂深 440~586 m), 土体强度较上部地层明显提升, 阻力增大, 井筒移动量趋近于 0。在基岩层内, 因岩性强度较大, 且采空区上覆岩层移动未波及井筒, 故井筒在基岩层内倾斜变形较小。

已有研究表明该段井筒横向最大挠度为 0.348 m, 井筒转动惯量为 337.3 m^2 , 垂直应力小于屈服强度, 上部压力通过预留设的可压缩性接头被释放后出现变形闭合, 故井壁在垂直方向目前暂处于安全状态^[27]。同时考虑到松散层段井筒发生竖向压缩变形, 而该压缩变形导致接头处井筒强度变弱, 纵向应力集中, 抗弯能力变弱, 一旦发生横向拉伸, 极易引起或加剧井筒倾斜。

1.4.2 地下水渗流场的影响

矿区东北和西南两侧地层相对较厚, 松散层土体内共有 3 个含水层。其中, 底部含水层直接覆盖于基岩面上部, 无厚隔水层阻隔。经井筒检测孔发现, 基岩面下风化带段发育垂向张性裂隙 11 条, 未探明的基岩地层中可能存在更多裂缝, 同时在地壳抬升过程中, 含水层裂隙发育良好, 为地下水的径流和储存创造了条件。

立井井筒松散层及部分基岩段采用冻结法施工, 当井筒周边地层完全解冻后, 底含水体通过上述发育的纵向裂隙, 经过井下构筑物、井筒井壁进行疏水, 矿井涌水疏放量由建井初期 $50 \text{ m}^3/\text{h}$ 增长为煤层开采影响后的 $500 \sim 600 \text{ m}^3/\text{h}$, 疏放水量提高近 10 倍^[28], 矿区底含水位大幅降低。其中, 井筒基岩段以上含水层水位下降, 对应水压降低, 对上部松散层支撑力减小, 进一步加剧了岩土体变形。

在后期开采过程中, 地下水流通过地层发育裂隙、断层进行沟通, 开采区域内原地下水渗流场受到显著干扰。一方面, 开采导致底部含水层内地下水不断通过岩层裂隙流向采空区, 另一方面, 地下水通过破损井筒持续渗漏, 地层因含水层水位下降不同、地层厚

度与性质不一、含水层水流方向等因素, 导致工业广场地表的不均匀沉降进一步增大, 进而加剧井筒倾斜变形。同时, 含水层水流持续性冲击井筒井壁及流过井壁后产生的真空负压, 亦会导致井筒产生不同程度的倾斜^[29]。

2 基于深度学习的井筒变形预测模型

2.1 预测方法

上述研究表明, 井筒倾斜已对矿区安全生产造成了严重威胁, 亟需实时获取井筒变形动态信息, 并准确预测井筒变形量, 为井筒安全预警提供数据依据。传统方法难以捕捉非线性数据间的时空相关性, 预测效果不佳, 而深度学习方法具有优异的数据处理能力和良好的时空序列预测效果, 本文选用深度学习方法进行预测。

2.1.1 技术路线

结合井筒倾斜变形中单变量短时序的数据特征, 采用 4 种深度学习神经网络, 构建了井筒变形预测模型。研究整体可由数据输入、神经网络构建、网络训练、网络预测、数据输出 5 个阶段组成, 如图 6 所示。首先, 对井筒变形数据进行预处理以满足网络输入要求; 然后选取循环神经网络(RNN)、长短记忆网络(LSTM)、门控循环单元(GRU)、一维卷积神经网络(IDCNN)四种神经网络进行构建; 其中, 网络训练采用 Adam 优化算法; 然后采用迭代方法逐点进行预测; 最终输出变形预测结果。

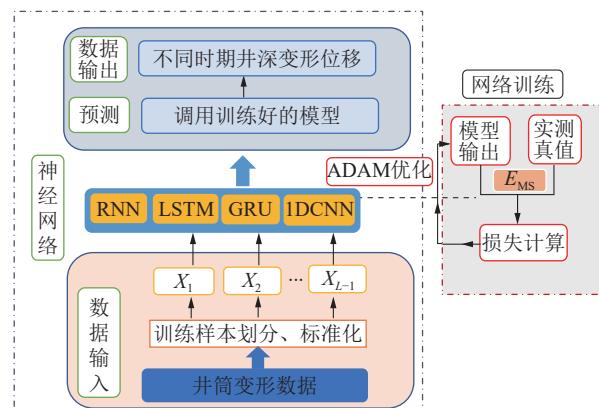


图 6 井筒变形预测研究技术路线

Fig. 6 Technical route of wellbore deformation prediction research

2.1.2 数据预处理

首先采用上述双垂线基准法结合特制监测装置, 进行井筒变形监测, 自上而下每隔 $10 \sim 20 \text{ m}$ 观测一次, 总共测量 65 处, 分别测量各监测点至 6 个井壁点的水平距离(图 2), 按照式(1)~式(3)逐步计算得到

井筒各监测点处的中心坐标及半径, 获取井筒东西方向、南北方向(每方向80组数据, 单期合计160组)各期倾斜值。

其次, 为获取高质量训练样本, 对原始工程数据进行预处理, 选取副井井筒2015年8月—2023年2月共30期实测数据为样本, 以井筒垂深-7 m处实测值为例, 见表3(期间1~8、18~27两个时间段内井

筒监测数据变化较小, 故省略)。将井筒变形数据按不同时期分为X个样本数据和Y个检验数据, 将X个样本数据用作训练数据输入模型, 且应满足相应约束条件。考虑到变形时序的数量级对模型训练效果影响, 对每个样本数据进行标准化处理, 且定义输出序列长度为1, 通过前($t-1$)个时刻变形信息预测第t时刻变形。

表3 主、副井各期倾斜实测值(垂深-7 m处)

Table 3 Measured values of inclination in each phase of the auxiliary well (at a vertical depth of -7 m)

监测期数	1期	8期	9期	13期	14期	15期	16期	17期	18期	27期	28期	29期	30期
副井/ mm	南北 方向	0.081	0.09	0.061	0.068	0.065	0.059	0.056	0.05	0.046	0.044	0.042	0.040
	东西 方向	-0.292	-0.289	-0.259 9	-0.266	-0.264	-0.265	-0.263	-0.26	-0.263	-0.262	-0.267	-0.263
主井/ mm	南北 方向	-0.03	-0.066	-0.051	-0.054	-0.051	-0.035	-0.04	-0.039	-0.037	-0.039	-0.036	-0.035
	东西 方向	-0.348	-0.353	-0.316	-0.335	-0.332	-0.303	-0.308	-0.305	-0.305	-0.310	-0.314	-0.306

经现场监测发现, 主、副井筒在进行注浆修复治理后, 其倾斜变形逐渐减缓并趋于稳定, 后期东西方向倾斜值分别为305、260 mm, 南北方向倾斜值分别为40、35 mm, 井筒整体倾斜有效减缓。为此模型选取时, 为更好地判别井筒倾斜变形关键信息, 探究输入序列的内在联系, 提高模型预测的效率与精度, 本文选取的4种经典深度学习网络模型, 其时序预测性能表现优异, 且模型结构简洁, 均能够满足研究需要。

2.1.3 网络训练与预测

该模型整体框架在python3.8的环境下创建, 使用深度学习框架PyTorch V1.12.1, 网络训练采用Adam优化算法以及 E_{MS} 损失函数进行迭代优化参数和梯度更新, 网络预测则采用迭代的方法逐点进行预测。

为探寻最优的学习率, 在网络训练环节, 设定初始学习率分别为0.1、0.01、0.001、0.0001, 结果表明, 当学习率为0.001时预测值与实测值方差最小(0.003 m^2), 且模型中的Adam优化器自身可自适应调整学习率变化, 无需设定学习率衰减值, 故最终设定初始学习率为0.001。

同时考虑到训练数据量相对较少, 为防止训练过程中出现过拟合, 首先应尽可能减少模型的参数数量, 使得各个模型网络层数在1~2层以内, 每层神经元个数相应减少至64; 其次采用早停法, 损失超过3轮不再下降时停止训练, 避免损失出现较大波动; 另外训练时每100轮保存一次模型权重, 最大训练轮数为500, 训练结束后共保存多个模型权重, 并采用十折交

叉验证法评估每个权重的泛化性能, 选择泛化性能最优权重作为最终模型权重。

2.2 深度学习网络模型

2.2.1 循环神经网络(RNN)

循环神经网络(RNN)是一种用来建模序列化数据的主流深度学习模型, 其优点在于能够处理任意长度的输入, 捕捉时间序列中的依赖关系。其中, 在t时刻, 隐藏单元S接收网络前一时刻的隐藏单元值 S_{t-1} 和当前输入数据 X_t , 并通过隐藏单元值计算当前时刻输出^[30-31], 如图7所示。基于上述原理构建了相应的RNN模型, 该模型主要由一层RNN层和一层全连接层组成, RNN层中隐藏层数量为2, 且每个隐藏层由64个神经元组成。

2.2.2 长短期记忆网络(LSTM)

长短期记忆网络(LSTM)为传统循环神经网络(RNN)的一种流行变体, 可解决RNN训练过程中的梯度消失与爆炸问题, 其隐藏层作为整个LSTM网络的核心, 由多个LSTM细胞单元组成, 其结构如图8所示^[32]。图中为一层隐藏层中的3个细胞单元, X_t 为样本t时刻输入值, h_t 为相应细胞单元的隐含状态输出, 在每个细胞单元中依次进行数据输入、信息遗忘、细胞状态更新以及隐含状态输出^[33]。基于上述原理构建了相应的LSTM模型, 该模型主要由1层LSTM层和1层全连接层组成, LSTM层中隐藏层数量为2, 且每个隐藏层由64个神经元组成。

2.2.3 门控循环单元(GRU)

门控循环单元(GRU)是LSTM的优秀变体, 由

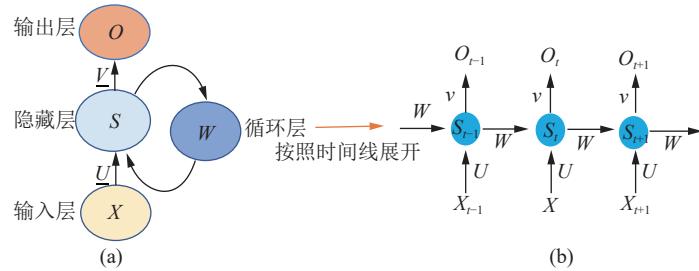


图 7 循环神经网络 (RNN) 网络结构

Fig.7 Network structure of recurrent neural network prediction

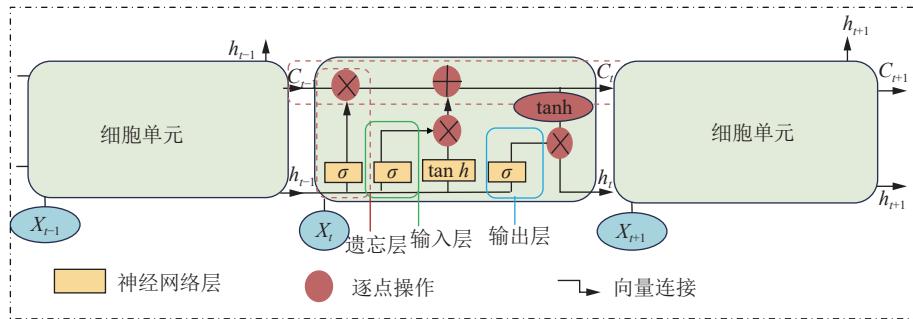


图 8 LSTM 隐藏层单元结构

Fig.8 Unit structure of LSTM hidden layer

更新门和重置门 2 部分组成,相较于 LSTM 参数更少,网络结构更简单,更容易训练和缓解过拟合问题,其内部结构如图 9 所示^[34]。GRU 中更新门确定上一隐藏层状态中记忆信息,重置门确定上一时刻隐藏层中遗忘信息,再确定当前记忆内容与当前时刻隐藏层保留的信息。基于上述原理构建了相应的 GRU 模型,该模型主要由一层 GRU 层和一层全连接层组成,GRU 层中隐藏层数量为 2,且每个隐藏层由 64 个神经元组成。

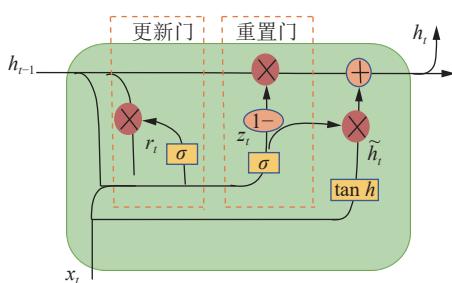


图 9 模型 GRU 内部结构

Fig.9 Model GRU internal structure diagram

2.2.4 一维卷积神经网络 (1DCNN)

一维卷积神经网络 (1DCNN) 主要用于处理一维序列数据,其优势在于能够自动提取数据特征,更好地处理序列数据中的局部关系,其基本结构由输入层、一维卷积层、一维池化层和全连接层组成。1DCNN 先通过可训练的卷积核对输入数据进行特征提取,使用激活函数对特征图进行非

线性变换,再将卷积层输出进行降维,在一系列卷积和池化操作下,特征图被展平为一维向量,最终输入到全连接层中进行变形预测^[35]。为此,基于上述原理构建了相应的 1DCNN 模型,该模型主要由 3 层 1DCNN 层和 2 层全连接层组成,其中第 1~3 层卷积核数量分别为 32、64、128,卷积核大小、步幅均为 1,且均采用 ReLu 激活函数进行非线性变换。

3 模型对比与精度评价

为对比研究深度学习中网络模型的应用效果,以第 1~26 期东西方向和南北方向上井筒变形实测数据为样本,将井筒变形时序数据输入模型层中进行特征学习,采用构建的 4 种深度学习预测模型,预测第 27~30 期井筒变形数据,并与井筒实测数据进行对比,计算预测值与实测值间的相关系数,评价预测模型精度指标,研究模型整体与关键区域预测效果,验证深度学习网络模型在井筒变形预测方面的可靠性。

3.1 相关性分析

为明确深度学习网络模型整体预测效果的可行性,以井筒第 27~30 期实测值为基础,进行各模型预测值与实测值间的相关性分析。考虑到井筒倾斜变形值不符合正态分布且为非线性关系,为此采用 Spearman 相关系数计算各模型间的相应系数,对比分析了井筒东西方向、南北方向上各模型预测效果,具体情况见表 4。

从表 4 可知,模型预测结果中相关系数最低值为

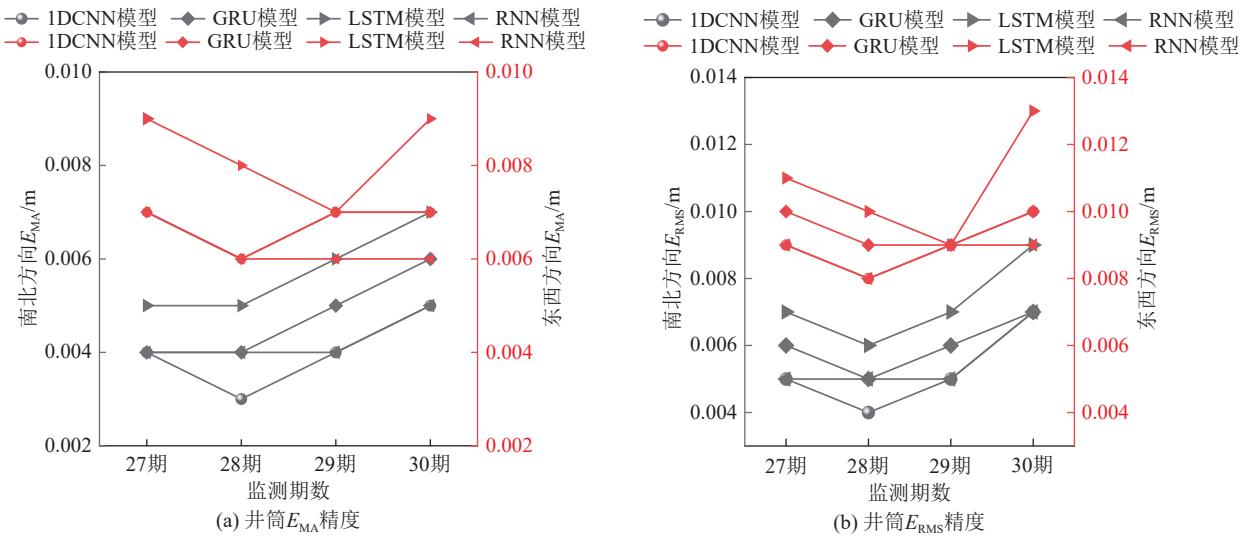
表4 Spearman 相关系数
Table 4 Spearman's correlation coefficient table

预测期数	27期				28期				29期				30期				
	网络模型	RNN	LSTM	GRU	1DCNN												
相关	南北方向	0.927	0.918	0.919	0.933	0.947	0.924	0.943	0.946	0.952	0.926	0.953	0.962	0.899	0.893	0.867	0.899
系数	东西方向	0.917	0.895	0.919	0.927	0.943	0.912	0.942	0.970	0.976	0.970	0.970	0.972	0.973	0.959	0.975	0.979

0.867, 最高值为 0.978, 其中南北方向上相关系数平均值为 0.868, 略低于东西方向上平均值 0.949, 4 种模型预测平均值为 0.909, 整体呈现高度显著相关。其中, 模型相关系数大小排序为 1DCNN > RNN≈GRU > LSTM, 以模型 1DCNN 效果最优, 相关系数平均值为 0.948, RNN 和 GRU 两者接近, LSTM 模型效果较弱。表明 4 种井筒变形预测模型效果良好, 相关系数高度显著相关, 能够满足变形预测的需求。

3.2 精度分析

为评估深度学习各个网络模型预测精度, 研究使用 2 种精度评价指标, 分别是均方根误差 E_{RMS} (Root Mean Square Error) 和平均绝对误差 E_{MA} (Mean Absolute Error), 以此分析模型预测精度。



注: 黑色为南北方向; 红色为东西方向。

图 10 井筒预测模型评价指标

Fig.10 Evaluation metrics for wellbore forecasting models

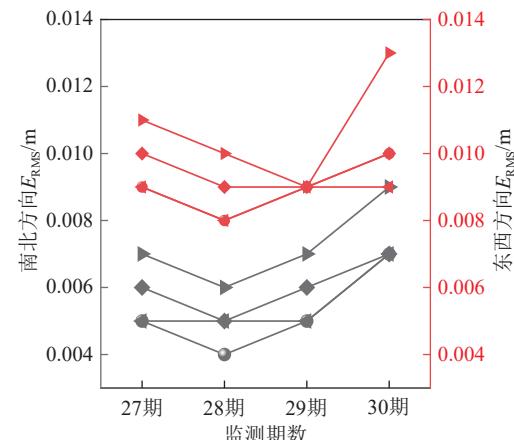
由图 10 可知, 4 种模型中, E_{MA} 最小值为 0.003 m, 最大值为 0.009 m, 模型整体平均值为 0.005 m, 其中东西方向 E_{MA} 平均为 0.007 m, 略高于南北方向平均值 0.005 m; E_{RMS} 最小值为 0.004 m, 最大值为 0.013 m, 模型整体平均值为 0.007 m, 其中东西方向 E_{RMS} 平均值为 0.010 m, 高于南北方向平均值 0.005 m 两倍。由于井筒偏向采空区一侧, 以东西方向倾斜为主, 其倾斜量在 0~350 mm 以内, 而南北方向倾斜量在 0~88 mm 以内, 两者变形量整体相差较大。东西方向上

$$E_{\text{RMS}} = \sqrt{\sum_{i=1}^N (y_i - \tilde{y}_i)^2 / N} \quad (4)$$

$$E_{\text{MA}} = \frac{1}{N} \sum_{i=1}^N |y_i - \tilde{y}_i| \quad (5)$$

其中, y_i 和 \tilde{y}_i 分别为对应时刻的变形观测值和预测值, N 为测试数据集的个数。 E_{RMS} 与 E_{MA} 范围为 $[0, +\infty)$, 当指标 < 0.1 时, 模型预测效果优良, 其能够准确反映真实数据的规律; 当指标在 0.1~1 间, 模型预测效果良好, 能够较好反映真实数据的规律; 当指标 > 1 时, 模型预测效果差, 即误差越大, 指标越大。通过对井筒变形预测模型进行第 27~30 期精度评价, 评价指标如图 10 所示。

—●— 1DCNN 模型 —◆— GRU 模型 —▲— LSTM 模型 —◀— RNN 模型
—●— 1DCNN 模型 —◆— GRU 模型 —▲— LSTM 模型 —◀— RNN 模型



(b) 井筒E_RMS精度

E_{MA} 、 E_{RMS} 分别高于南北方向上 0.002、0.005 m, 当东西方向上指标增大, 对应精度减小, 其略低于南北方向, 同时 4 种模型整体预测精度排序为 1DCNN > RNN > GRU > LSTM, 以 1DCNN 效果最优, 上述表明 4 种预测模型指标评价表现良好, 模型整体预测精度高。

3.3 预测结果分析

调用训练好的预测模型, 输出不同时期井筒变形值, 将井筒东西方向、南北方向第 27~30 期预测值与

实测值进行纵向剖面对比,分析井筒整体预测效果,如图11所示。

由图11可知,4种模型整体预测曲线高度相似,与井筒实际倾斜量接近一致。其中,在南北方向上,模型整体倾斜程度较小,监测点位最大误差仅为

0.024 m,整体误差小,曲线非线性拟合良好,且在井筒井口关键区域预测准确,可有效表示井筒空间变化趋势;在东西方向上,井筒底部出现相对偏差,偏差程度随预测期数增加而逐渐减小,当井筒高度上升,4种模型预测曲线之间差异逐渐减小且趋近于实测值,在井

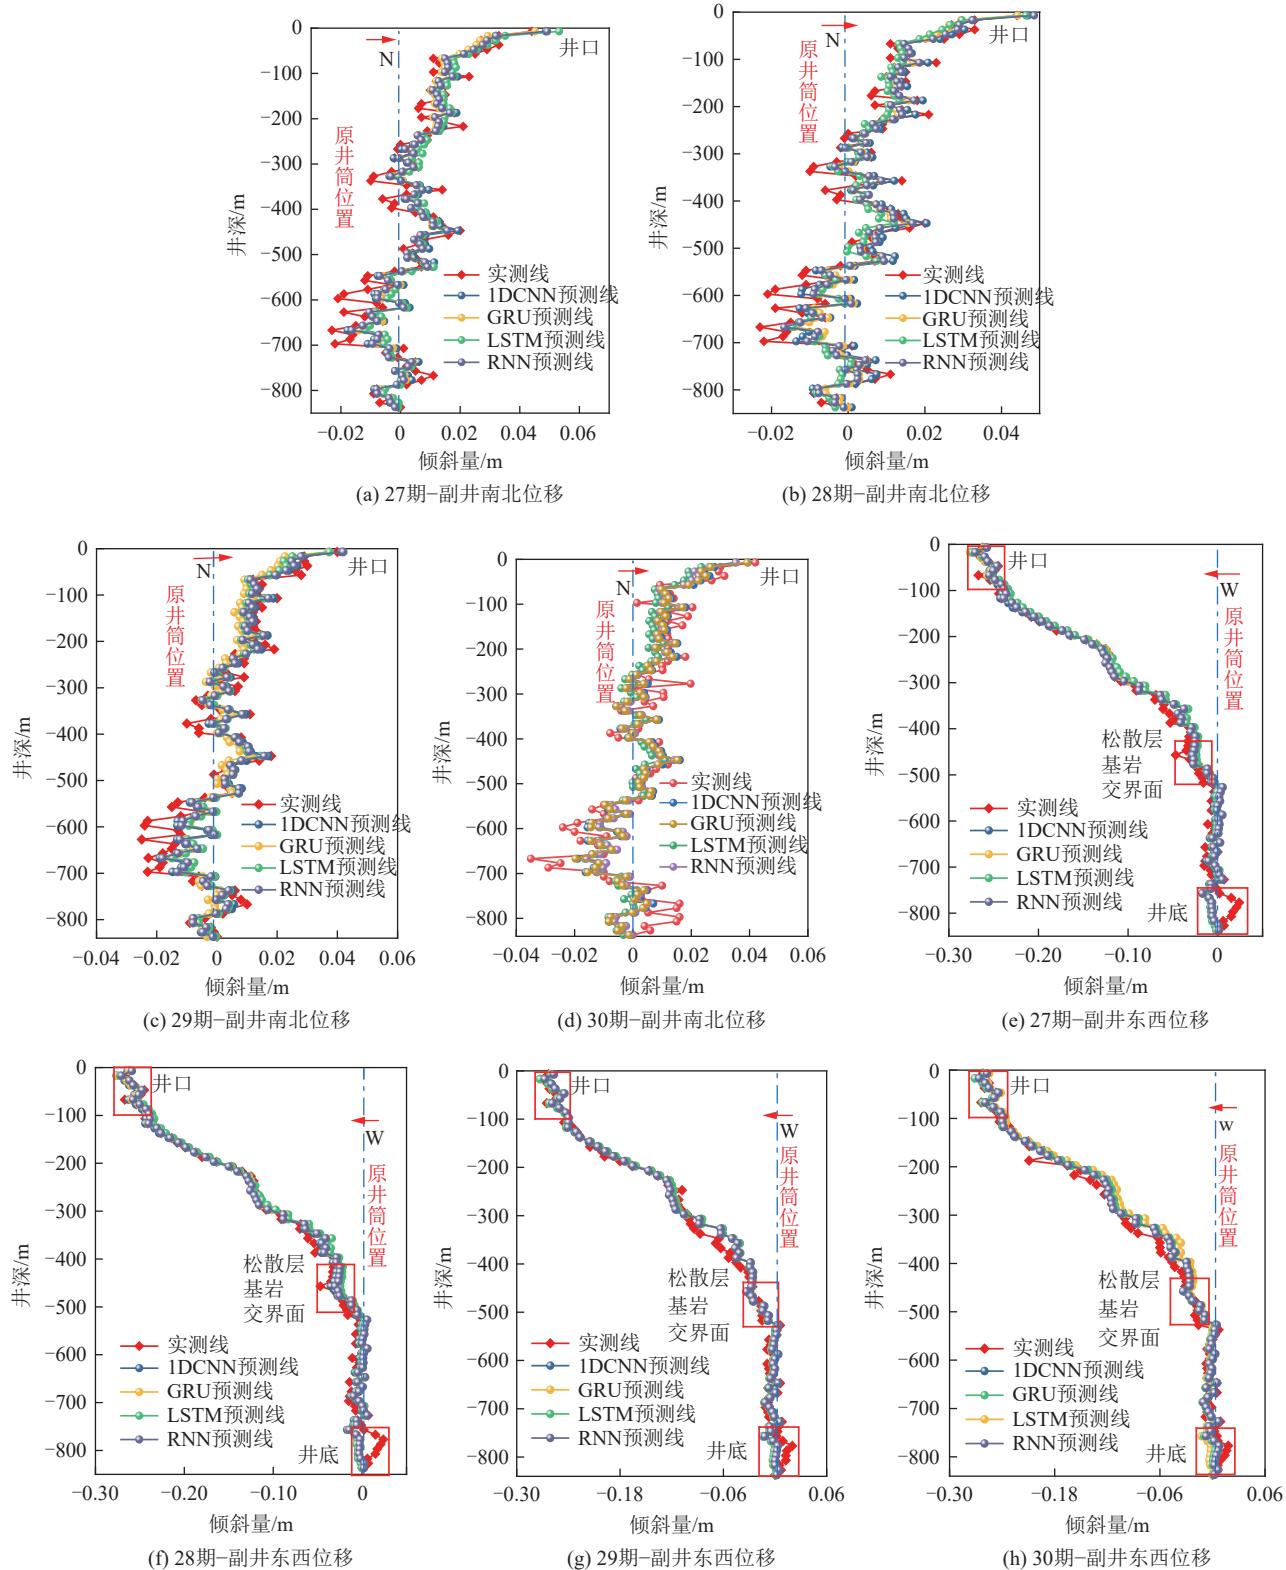


图11 模型预测效果对比

Fig.11 Comparison chart of model prediction effect

筒埋深(0~−500 m)内接近吻合。其中,井筒主要倾斜区域(厚松散层和井筒井口)预测曲线高度重合,预测效果表现良好,以1DCNN模型效果最优,表明4种深度学习预测模型均能有效呈现预期时间厚松散层立井井筒空间变形特征,验证了深度学习在井筒预测方面的良好性能。

为进一步研究模型在井筒关键区域的预测效果,选取井口、松散层与基岩交界处、井底3个区域位置(上下间距100 m,如图11中红色矩形),结合井筒横向变形特征(以第27期为例,如图12所示),对比主要倾斜方向(东西方向)上的预测模型误差,并给出了4种模型的精度评价指标,见表5。

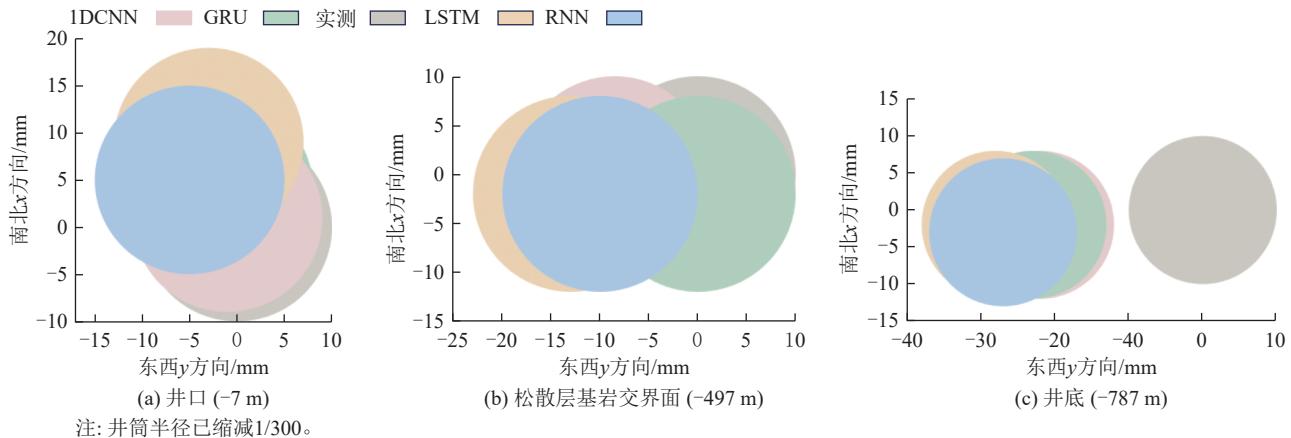


图12 井筒横向变形对比图(27期)

Fig.12 Comparison of transverse deformation of wellbore(27 period)

表5 特征区域精度评价

Table 5 Characterization area accuracy evaluation table

预测模型及期数	RNN				LSTM				GRU				1DCNN				
	27	28	29	30	27	28	29	30	27	28	29	30	27	28	29	30	
E_{MA}/m	井口	0.004	0.005	0.004	0.005	0.006	0.007	0.003	0.002	0.004	0.004	0.003	0.001	0.004	0.003	0.004	
	交界处	0.005	0.007	0.004	0.005	0.004	0.007	0.004	0.001	0.004	0.007	0.004	0.001	0.004	0.005	0.004	0.001
	井底	0.015	0.013	0.009	0.008	0.016	0.014	0.011	0.010	0.016	0.013	0.011	0.003	0.017	0.015	0.011	0.003
E_{RMS}/m	井口	0.005	0.006	0.005	0.004	0.008	0.008	0.004	0.003	0.005	0.005	0.004	0.001	0.004	0.003	0.005	0.003
	交界处	0.007	0.008	0.005	0.005	0.005	0.008	0.004	0.001	0.006	0.008	0.004	0.001	0.004	0.006	0.004	0.002
	井底	0.018	0.015	0.010	0.010	0.019	0.017	0.013	0.003	0.019	0.016	0.013	0.003	0.020	0.017	0.012	0.003

由表5和图12可知:①井口和松散层基岩交界面处 E_{MA} 、 E_{RMS} 平均值分别为0.005 m、0.006 m,预测精度较高;②井底处 E_{MA} 、 E_{RMS} 平均值分别为0.012 m、0.013 m,精度略低;③4种模型整体预测精度排序为:1DCNN≈GRU>RNN>LSTM,以1DCNN效果最优,其对应 E_{MA} 、 E_{RMS} 平均值分别为0.006 m、0.007 m,RNN与LSTM效果次之。上述表明4种预测模型对3个关键特征区域拟合效果良好,能够理想地捕捉时间序列数据的局部变化,在处理井筒变形时间序列数据时具有优劣性。

4 工程应用

4.1 工程背景

以两淮某煤矿为研究区域,进行井筒变形修复治

理,该矿区于2004年正式投产,一期设计生产能力为150万t/a,井筒净直径为6.5 m,最大井壁外直径为8.2 m,井筒最大埋深为357 m。其中,煤田上覆松散层厚度较大,地层多被第四系冲、洪积平原所覆盖,属于全隐蔽式煤田,且井田松散层中含有4个含水层组,地层富水性强,水体间存在不同程度水力联系,与鲁南矿区巨野煤田地质采矿条件相类似。经现场实测,井壁多处发生出水灾害,其中埋深−94、−118 m处出水量分别为1.5~2.0、4 m³/h,且井筒发生不同程度的倾斜变形。为监测井筒安全状态,根据煤矿副井相关设计准则,确定在副井内层井壁上布设光纤光栅应变计,每层监测水平布设8个(图13),实现井壁混凝土竖向、环向应变监测,并根据监测结果,对副井井壁竖向、环向应力进行计算分析,实时评估井筒受力变形状态。

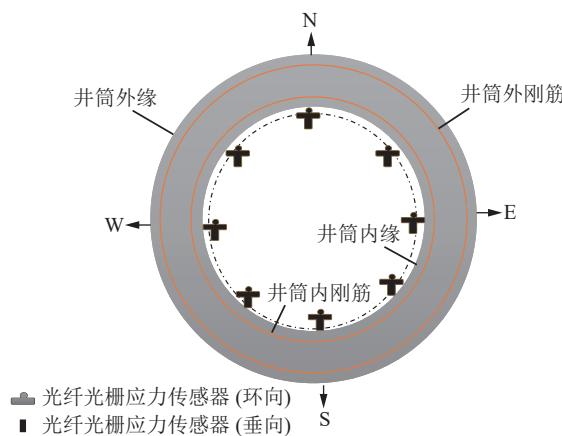


图 13 监测水平元件布设示意

Fig.13 Schematic diagram of the layout of the components on the monitoring level

4.2 井筒变形预测

深度学习未对数据的统计属性进行任何预先假设,且神经网络能够从当前数据中推断出其内在联系,

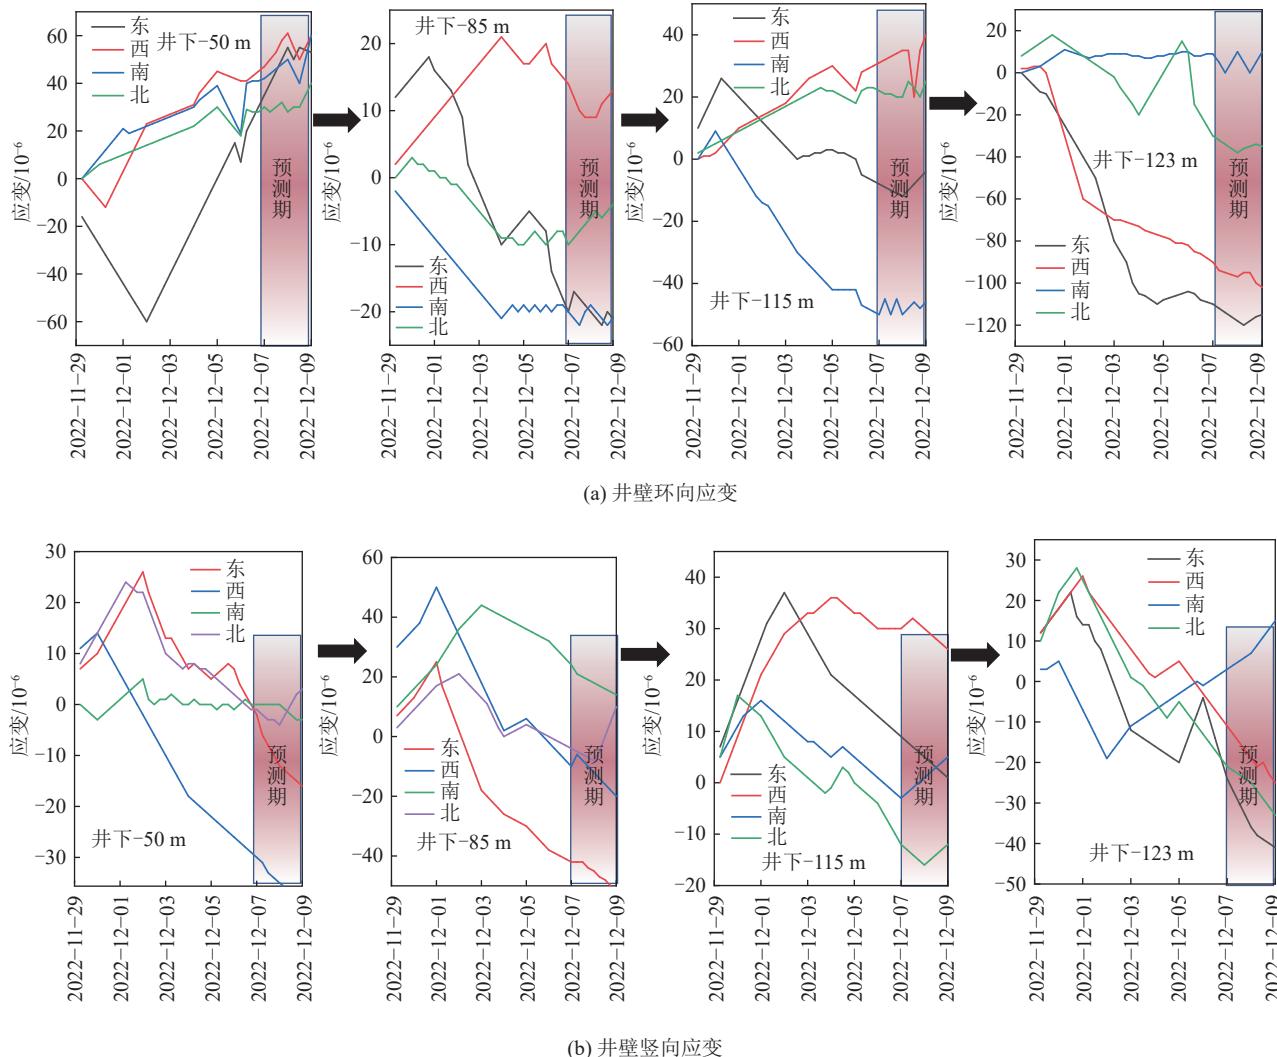


图 14 应变监测及预测变化
Fig.14 predicted changes in stress monitoring

因此基于上述已有的井筒变形预测模型,开展矿区井筒修复治理。通过井筒光纤光栅监测系统实时监测和在线传输井壁应变信息,分析处理井壁生产运行时实际监测数值,以 2022-11-29—2022-12-07 累计 36 期应力应变监测值作为训练样本,为更好地进行应力预测,提高模型的准确率,选取上述预测效果最优的 1DCNN 神经网络,在已训练模型的基础上采用井筒应力应变数据进行迁移学习,预测井壁破损变形严重区域(埋深-50~ -130 m)动态信息,获取 12 月 8 日至 9 日井壁应力变化,如图 14 所示。

根据混凝土井壁原始受力状态,考虑平面问题和自重问题,参考荷载相关系数,确定井筒破坏预警值,对井筒井壁进行环向应变预警和竖向应变预警。由图 14 中可知:在预测期内,井壁环向、竖向应变量整体呈现大幅增长。其中,井下-115、-123 m 处环向应变明显增加,最大值分别增长至 -50 、 -120×10^{-6} , -85 m 处较小,整体在 $\pm 20 \times 10^{-6}$ 以内,而井下-50 m 环向应变

在12月8日达到 65×10^{-6} 左右,临近3级警戒值的80%;在竖向方向上,井下-50、-80、-115及-123 m四个层位竖向应变虽明显增加,但整体范围在 $\pm 50 \times 10^{-6}$ 以内,相较于井壁各级预警值相对稳定。综上表明,井筒-50~-130 m内应变显著变化,分析认为该区域井筒井壁最易发生破坏和倾斜变形灾害。

基于上述预测值,结合井壁出水灾害,对井筒预计破损区域进行注浆充填治理,工程于2022年12月底完工,共完成钻探注浆孔9个,最终注浆工程量130.9 m³。其中,井筒出水点位已有效封堵,井筒倾斜变形得到了有效减缓,井壁竖向、环向应力均下降到正常范围。综上表明,井筒注浆工程治理效果良好,提高了井筒受注段强度,保护了矿区安全生产,研究成果在井筒注浆修复治理工程中得到了有效应用,为矿井安全管理提供了技术参考与工程经验。

5 结 论

1) 针对厚含水松散层深立井倾斜破損灾害,以鲁南某矿深立井井筒(800 m)为研究对象,开展了井筒倾斜变形监测,研究了井筒倾斜时空变化特征,分析了井筒倾斜主要影响因素,研究结果表明井筒倾斜主要发生在松散层,倾斜值由浅到深线性减小、并偏向采空区一侧,基岩层变形较小;开采引起厚松散层变形传播范围增大、地下水随地层裂隙渗漏、底部含水层沿井壁渗流疏水是导致井筒倾斜变形的主要原因。

2) 在此基础上,基于深度学习理论,综合采用长短期记忆网络(LSTM)、循环神经网络(RNN)、门控循环单元(GRU)、一维卷积神经网络(1DCNN)四种经典深度学习网络,构建了井筒倾斜变形预测模型,并将预测结果与实测值进行对比,分析了井筒变形预测模型精度,研究了井筒整体与局部关键区域预测效果,结果表明4种模型预测值与实测值最大偏差为0.043 m, E_{MA} 在0.003~0.009 m内, E_{RMS} 在0.004~0.011 m内,模型与实测值相关性Spearman系数最大为0.978,最小为0.867,均能够满足工程需要,且整体预测效果以1DCNN模型最优;主要倾斜方向(偏向采空区一侧的东西方向)预测精度略低于变形量较小的方向(南北方向)。

3) 井筒整体预测曲线与实际倾斜方向一致,井口、松散层基岩交界面 E_{MA} 与 E_{RMS} 平均值分别为0.005 m、0.006 m,井底对应值为0.012 m、0.013 m,井筒整体、关键区域预测效果均表现良好,表明基于深度学习的井筒变形预测模型具有良好的预测能力,研究成果在井筒注浆修复治理工程中得到了有效应用,为井筒安

全管理提供了技术参考和数据支撑,为类似工程提供了实践经验。

参 考 文 献(References):

- [1] 刘辉,左建宇,苏丽娟,等.巨厚含水松散层下开采地表移动变形规律研究[J].煤炭科学技术,2022,50(5): 49~56.
LIU Hui, ZUO Jianyu, SU Lijuan, et al. Study on surface movement and deformation laws in mining under thick water-bearing loose layer[J]. Coal Science and Technology, 2022, 50(5): 49~56.
- [2] MA F S, DENG Q H, CUNNINGHAM D, et al. Vertical shaft collapse at the Jinchuan nickel mine, Gansu Province, China: Analysis of contributing factors and causal mechanisms[J]. Environmental Earth Sciences, 2013, 69(1): 21~28.
- [3] HAN J H, ZOU J Q, HU C C, et al. Deflection mechanism and safety analysis of coal mine shaft in deep soil strata[J]. Mathematical Problems in Engineering, 2019, 2019(1): 9461742.
- [4] 徐晓峰,经来旺,杨仁树,等.疏水沉降下井壁次生地压及附加力分布规律[J].煤炭学报,2010,35(2): 203~207.
XU Xiaofeng, JING Laiwang, YANG Renshu, et al. Distribution rules of additional force and secondary ground pressure stress of shaft wall in seepage sedimentation[J]. Journal of China Coal Society, 2010, 35(2): 203~207.
- [5] 独知行,靳奉祥,吴庆忠.矿山井筒变形的数学模型及应用[J].中国有色金属学报,2000,10(4): 604~608.
DU Zhixing, JIN Fengxiang, WU Qingzhong. Mathematical model of mine shaft deformation and its application[J]. The Chinese Journal of Nonferrous Metals, 2000, 10(4): 604~608.
- [6] 李文平.深部土层失水变形时土与井壁相互作用试验与理论研究[J].岩土工程学报,2000,22(4): 475~480.
LI Wenping. Testing and theoretical studies on the interaction between soil and shaft wall during deep soil compression due to losing water[J]. Chinese Journal of Geotechnical Engineering, 2000, 22(4): 475~480.
- [7] 杨维好,杜子博,杨志江等.基于与围岩相互作用的冻结壁塑性设计理论[J].岩土工程学报,2013,35(10): 1857~1862.
YANG Weihao, DU Zibo, YANG Zhijiang, et al. Plastic design theory of frozen soil wall based on interaction between frozen soil wall and surrounding rock[J]. Chinese Journal of Geotechnical Engineering, 2013, 35(10): 1857~1862.
- [8] HAN J H, ZOU J Q, HU C C, et al. Study on size design of shaft protection rock/coal pillars in thick soil and thin rock strata[J]. Energies, 2019, 12(13): 2553.
- [9] 程桦,张亮亮,姚直书,等.厚松散层薄基岩非对称开采井筒偏斜机理[J].煤炭学报,2022,47(1): 102~114.
CHENG Hua, ZHANG Liangliang, YAO Zhishu, et al. Mechanism of shaft deflection caused by asymmetric mining in thin bedrock and deep loose strata[J]. Journal of China Coal Society, 2022, 47(1): 102~114.
- [10] 高杰.水位下降诱发深厚表土层井壁破裂机理及治理效果模拟研究[D].青岛:青岛理工大学,2009.

- GAO Jie. The simulation research on the mechanism and treatment of shaft wall fracture in thick alluvium induced by dewatering[D]. Qingdao: Qingdao University of Technology, 2009.
- [11] 郭洛. 厚表土层中井筒简单侧漏排水地层变形及其对井筒的影响 [D]. 徐州: 中国矿业大学, 2020.
- GUO Luo. Strata deformation induced by drainage on one side of shaft and its influence on the shaft in thick topsoil. Xuzhou: China University of Mining and Technology, 2020.
- [12] 徐勇. 牛儿庄矿主井井筒损坏监测、预测及防护[D]. 徐州: 中国矿业大学, 2021.
- XU Yong. Monitoring, Prediction and Protection of Main Wellbore Damage in Niuerzhuang Mine[D]. Xuzhou: China University of Mining and Technology, 2021.
- [13] 王坚, 岳广余, 王继刚. 自适应 GM(1, 1) 模型进行地表沉降预报 [J]. 北京测绘, 2003, 17(1): 40–42.
- WANG Jian, YUE Guangyu, WANG Jigang. Self-adaptive GM(1, 1) model in predicting earth's surface subsidence value[J]. Beijing Surveying and Mapping, 2003, 17(1): 40–42.
- [14] 彭涛, 杨岸英, 梁杏, 等. BP 神经网络—灰色系统联合模型预测软基沉降量 [J]. 岩土力学, 2005, 26(11): 1810–1814.
- PENG Tao, YANG Anying, LIANG Xing, et al. Prediction of soft ground settlement based on BP neural network-grey system united model[J]. Rock and Soil Mechanics, 2005, 26(11): 1810–1814.
- [15] 唐艳梅, 王坚, 彭祥国, 等. 煤矿井筒变形混沌特征及预报模型研究 [J]. 金属矿山, 2011(2): 149–152.
- TANG Yanmei, WANG Jian, PENG Xiangguo, et al. Study on coal mine shaft chaos characteristics and deformation prediction model[J]. Metal Mine, 2011(2): 149–152.
- [16] 胡安峰, 李唐, 陈缘, 等. 深度学习在实测沉降数据预处理中的应用研究 [J]. 湖南大学学报(自然科学版), 2021, 48(9): 43–51.
- HU Anfeng, LI Tang, CHEN Yuan, et al. Deep learning for pre-processing of measured settlement data[J]. Journal of Hunan University(Natural Sciences), 2021, 48(9): 43–51.
- [17] YUAN D B, GENG C X, ZHANG L, et al. Application of gray-Markov model to land subsidence monitoring of a mining area[J]. IEEE Access, 2021, 9: 118716–118725.
- [18] LIU Y H, ZHANG J. Integrating SBAS-InSAR and AT-LSTM for time-series analysis and prediction method of ground subsidence in mining areas[J]. Remote Sensing, 2023, 15(13): 3409.
- [19] 程桦, 彭世龙, 姚直书, 等. 厚松散层薄基岩地层井筒偏斜综合治理技术 [J]. 煤炭科学技术, 2023, 51(1): 260–271.
- CHENG Hua, PENG Shilong, YAO Zhishu, et al. Comprehensive treatment technology for wellbore deflection in thick loose bed and thin bedrock formation[J]. Coal Science and Technology, 2023, 51(1): 260–271.
- [20] 程桦, 张楠, 姚直书, 等. 厚表土井筒修复内套钢板混凝土井壁技术研究 [J]. 煤炭科学技术, 2019, 47(6): 58–65.
- CHENG Hua, ZHANG Nan, YAO Zhishu, et al. Study on the technology of inner steel plate concrete shaft lining for thick topsoil wellbore repair[J]. Coal Science and Technology, 2019, 47(6): 58–65.
- [21] 郭倩倩, 刘尚国, 刘金龙. 基于组合式激光测距的立井井筒及罐道垂直度检测 [J]. 煤炭技术, 2018, 37(11): 86–89.
- GUO Qianqian, LIU Shangguo, LIU Jinlong. Vertical wellbore and tank verticality detection based on combined laser range finder[J]. Coal Technology, 2018, 37(11): 86–89.
- [22] 王正洋, 陈涛, 郑文华. 矿井立井井筒变形检测方法探究 [J]. 矿山测量, 2016(1): 46–49, 76.
- WANG Zhengyang, CHEN Tao, ZHENG Wenhua. Exploration of deformation detection methods of shafts in mine vertical shafts[J]. Mine Surveying, 2016(1): 46–49, 76.
- [23] 王坚, 高井祥. 井筒变形监测理论与方法 [M]. 武汉: 武汉大学出版社, 2018.
- [24] 彭世龙, 程桦, 姚直书, 等. 厚松散层底含直覆薄基岩开采地表沉陷预计及特征研究 [J]. 煤炭学报, 2022, 47(12): 4417–4430.
- PENG Shilong, CHENG Hua, YAO Zhishu, et al. Study on prediction and characteristics of surface subsidence in mining when bottom aquifer of thick loose directly covers thin bedrock[J]. Journal of China Coal Society, 2022, 47(12): 4417–4430.
- [25] 刘辉, 李玉, 苏丽娟, 等. 厚松散层薄基岩下开采地表变形规律: 以鲁南矿区为例 [J]. 煤炭科学技术, 2023, 51(9): 11–23.
- LIU Hui, LI Yu, SU Lijuan, et al. Surface deformation law of mining under thick loose layer and thin bedrock: Taking the southern Shandong Mining Area as an example[J]. Coal Science and Technology, 2023, 51(9): 11–23.
- [26] 唐岳松, 孙文超, 李增强, 等. 冲击地压矿井充填开采工作面采动应力激增与跌落机制 [J]. 煤炭学报, 2024, 49(S1): 22–35.
- TANG Yuesong, SUN Wenchao, LI Zengqiang, et al. The mechanism of mining induced stress surge and drop in the filling mining face of a mine with rockburst pressure[J]. Journal of China Coal Society, 2024, 49(S1): 22–35.
- [27] 彭世龙. 厚表土薄基岩开采地层沉陷规律及其井筒偏斜致因研究 [D]. 淮南: 安徽理工大学, 2019.
- PENG Shilong. Study on stratigraphic subsidence law and cause of shaft deflection in thick topsoil and thin bedrock[D]. Huainan: Anhui University of Science and Technology, 2019.
- [28] 姚庆健. 郭屯煤矿含水层参数计算及井筒沉降与偏斜机理分析 [D]. 淮南: 安徽理工大学, 2017.
- YAO Qingjian. Calculation of aquifer parameters and analysis of the mechanism of shaft settlement and deflection in Guotun Mine[D]. Huainan: Anhui University of Science and Technology, 2017.
- [29] 赵仁乐, 李红友, 侯维华, 等. 郭屯矿底部含水层水文地质特征及其失水因素 [J]. 煤矿安全, 2021, 52(6): 65–71.
- ZHAO Renle, LI Hongyou, HOU Weihua, et al. Hydrogeological characteristics and water loss factors of “bottom aquifer” in Guotun Coal Mine[J]. Safety in Coal Mines, 2021, 52(6): 65–71.
- [30] FANG W, CHEN Y P, XUE Q Y. Survey on research of RNN-based spatio-temporal sequence prediction algorithms[J]. Journal on Big Data, 2021, 3(3): 97–110.
- [31] SHERSTINSKY A. Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network[J]. Physica D: Nonlinear Phenomena, 2020, 404: 132306.

- [32] 张智, 王翔辉, 黄媚, 等. 基于随机森林和长短期记忆网络模型的高压气井环空带压预测方法[J]. 天然气工业, 2024, 44(09): 167–178.
ZHANG Zhi, WANG Xianghui, HUANG Mei, et al. A prediction method of annular pressure in high-pressure gas wells based on the RF and LSTM network models[J]. Natural Gas Industry, 44(9): 167–178.
- [33] 刘青豪, 张永红, 邓敏, 等. 大范围地表沉降时序深度学习预测法[J]. 测绘学报, 2021, 50(3): 396–404.
LIU Qinghao, ZHANG Yonghong, DENG Min, et al. Time series prediction method of large-scale surface subsidence based on deep learning[J]. Acta Geodaetica et Cartographica Sinica, 2021, 50(3): 396–404.
- [34] YANG S D, YU X Y, ZHOU Y. LSTM and GRU neural network performance comparison study: Taking yelp review dataset as an example[C]//2020 International Workshop on Electronic Communication and Artificial Intelligence (IWECAI). Piscataway, NJ: IEEE, 2020: 98–101.
- [35] ALZUBAIDI L, ZHANG J L, HUMAIDI A J, et al. Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions[J]. Journal of Big Data, 2021, 8(1): 53.