基于LSTM-DCNN和迁移学习的矿山地下开采地表沉降预测方法*

张东炜[1],张艺山[1],焦诗卉[2],赵永[2],邓文学[2],薛斌[2],文鑫[2]

(1.海南矿业股份有限公司, 海南 昌江黎族自治县 572700;
2.东北大学 资源与土木工程学院, 辽宁 沈阳 110819)

摘要:地下矿体开采过程中,采空区坍塌会破坏岩层的应力平衡,进而引发地质灾害并危及地表设施。为在矿山未开采阶段缺乏实际监测数据的情况下提高矿山地表沉降预测的精度,保障人员安全和矿区生产,提出了一种结合神经网络和迁移学习的矿山地下开采地表沉降预测方法,融合长短时记忆神经网络准确提取时间序列特征以及深度卷积神经网络提取数据的局部特征的优点,提高预测模型的准确性。根据中干沟钒钛磁铁矿的开采设计,利用预测模型开展不同开采进度下地表沉降预测。结果表明,随着出矿量的增加,各分段的均方误差均小于0.4,所提出的模型在不同开采进度下的地表沉降预测中表现出较高的准确性。该方法能够为类似矿山的地表沉降预测和安全监测提供参考。

关键词:地下矿山;长短时记忆神经网络;深度卷积神经网络;迁移学习;地表沉降预测

中图分类号:TD327 **文献标识码**:A **文章编号**:1005-2763(2026)02-0158-09

Prediction Method for Surface Subsidence in Underground Mining Based on LSTM-DCNN and Transfer Learning

ZHANG Dongwei[1], *ZHANG Yishan*[1], *JIAO Shihui*[2], *ZHAO Yong*[2], *DENG Wenxue*[2], *XUE Bin*[2], *WEN Xin*[2]

(1.Hainan Mining Co., Ltd., Changjiang Li Autonomous County, Hainan 572700, China;
2.School of Resources and Civil Engineering, Northeastern University, Shenyang, Liaoning 110819, China)

Abstract: During the mining process of underground ore bodies, the collapse of goaf can disrupt the stress balance of rock strata, leading to geological disasters and endangering surface facilities. In order to improve the accuracy of surface subsidence prediction in mines without actual monitoring data during the unmined stage, as well as to ensure personnel safety and mining production, a method combining neural networks and transfer learning for underground mining surface subsidence prediction was proposed. The method combines the advantages of long-short-term memory neural networks to accurately extract time series features and deep convolutional neural networks to extract local features of data, improving the accuracy of the prediction model. According to the mining design of Zhonggangou vanadium titanium magnetite, the prediction model was used to predict the surface subsidence under different mining schedules. The results show that with the increase of ore output, the mean square error of each segment is less than 0.4. The proposed model shows a high accuracy in surface subsidence prediction under different mining schedules. This method can provide a reference for surface subsidence prediction and safety monitoring of similar mines.

Key words: Underground mine, Long-short-term memory neural network, Convolutional neural network, Transfer learning, Surface subsidence prediction

0 引言

地下开采活动会扰动岩体结构,破坏矿区地层的原始应力平衡,进而引发地表移动和变形。这种变形可能诱发地质灾害,导致地面建筑和生产设施受损,给生产和生活带来潜在安全隐患。因此,对地

* **收稿日期**:2025-02-17
基金项目:国家自然科学基金项目(52374157)
作者简介:张东炜(1985—),男,江西上饶人,硕士,工程师,主要从事金属矿山安全开采及岩石力学等方面的研究工作。E-mail:zdw450674870@163.com
通信作者:赵永(1991—),男,山东临沂人,博士,副教授,主要从事岩体孕灾机理与灾变预警、微震监测理论与应用等研究工作。E-mail:zhaoyong0724@mail.neu.edu.cn

下矿山开采引起的地表变形进行预测,对于保障矿区的安全生产以及保护人员生命和财产安全具有至关重要的意义。

地下开采的地表变形预测研究主要经历了从经验法、影响函数法、理论模型法到基于计算机的人工智能方法的发展阶段。相关研究始于 19 世纪比利时工程师通过调查提出的垂线理论,而后波兰科学家 Knothe 和 Budryk 在探究塌陷区地表移动的过程中提出了影响函数理论,并确立了可以在沉陷盆地中计算水平变形情况的改良版高斯型影响曲线“Budryk—Knothe 方法”。1965 年,我国岩石力学与岩土工程专家提出了概率积分预计法[1],直到今天,该方法依然是我国矿山地质工作者的主要计算手段之一[2-4]。得益于计算机的迅猛发展,数值模拟法逐渐被广泛应用于地下开采的地表变形预测研究中,该方法结合弹塑性理论和力学模型,依赖大量的岩石力学和物理力学参数进行计算。在岩土工程领域被广泛应用的计算方法主要有有限元法、有限差分法、离散元法等。贺小卫等[5]采用有限元法对地面沉降预测公式进行验证,并确定引起地面沉降的重要因素。黄鑫康等[6]分别利用机器学习和数值模拟的方法预测某磷矿采空区引起的地表沉陷,并进行对比研究。崔轩等[7]利用耦合仿真手段对空场法开采的地表位移变化进行分析。章海兵等[8]结合理论分析、数值模拟等方法,验证了沉降预测模型的实用性。

随着人工智能的高速发展,深度学习模型被应用于国内外地下开采地表沉降预测中,神经网络、支持向量机、时序分析模型等研究均取得了较好的成果[9-10]。传统机器学习方法需要通过大量有标记的数据进行学习,当目标域中缺少足够标记的训练数据,或者训练专用模型的计算成本很高时,通常希望在一个或多个域(源域)中训练模型,然后将其应用到另一个不同但相关的域(目标域)中[11]。迁移学习就是这样一种运用已有知识解决相似任务的一种新的机器学习方法,是一项潜力巨大的人工智能技术。迁移学习作为未来深度学习的驱动力,可以充分挖掘源域中历史数据,解决数据获取和标注缺少的问题[12]。当一个新的矿山开采时,由于缺少足够的历史运行数据,很难预测矿山开采时的地表变化情况,若此时能够通过迁移学习,将数值模拟预测模型用于矿山实际生产中预测,那么历史数据不足的问题将能够得到很好的解决。对于地下矿山开采的岩层变形预测问题,由于各个矿山的工程背景不同,彼此之间虽然有一定借鉴作用,但针对金属矿山在大采空区影响下,岩层和地表的动态研究、时间和空间上的变化等问题研究还不够深入,鲜有利用迁移学习进行地下金属矿山开采地表沉降预测的研究。

本文依托中干沟钒钛磁铁矿地下开采项目,采用长短时记忆神经网络(Long Short-Term Memory Neural Network, LSTM)和深度卷积神经网络(Deep Convolutional Neural Network, DCNN),融合 LSTM 能够准确提取时间序列的特征以及 DCNN 提取数据的局部特征的优点,提出了一种结合深度学习和迁移学习的矿山地下开采地表沉降预测方法,并开展了不同开采进度下地表沉降预测研究。研究思路如图 1 所示,以数值模拟计算得到的每一步地下开采地表沉降曲线为源域,输入模型进行训练并保存模型各层超参数。为模型增加一个全连接层,冻结其他各层参数,将概率积分法计算得出的地表沉降曲线作为目标域输入模型重新训练。研究结果有望为类似矿山地下开采地表沉降预测提供新的方法。

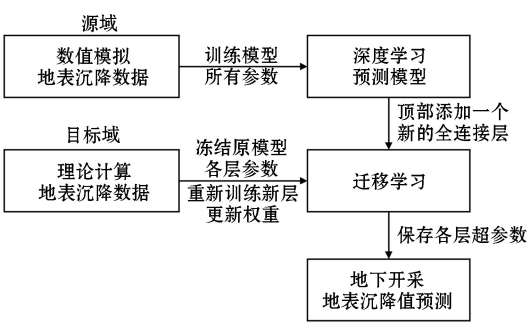


图 1 研究思路

Fig.1 Research approach

1 深度学习预测模型构建

1.1 长短时记忆神经网络

递归神经网络(Recurrent Neural Network, RNN)能够捕捉相邻时间步输入数据之间的序列关系,并具有记忆历史信息的能力。然而,在反向传播训练过程中,由于参数数量庞大,RNN 在网络层数增加时容易出现梯度消失或梯度爆炸的问题。为了解决这一难题,HOCHREITER 等[13]提出了

LSTM。目前,LSTM 已广泛应用于涉及时序信号的多个领域,如交通速度预测[14]、电力负荷预测[15]和语音识别[16],并取得了显著成果。

LSTM 网络包含 3 个主要的门控机制:遗忘门、输入门和输出门,其模型结构如图 2 所示[17]。其中,C_{t-1}表示前一时刻的储存单元;h_{t-1}表示前一时刻的隐藏状态;x_t 表示 t 时刻的输入;C_t 表示当前时刻的储存单元;h_t 表示当前时刻的隐藏状态;σ_f、σ_i、σ_o 分别表示遗忘门、输入门、输出门的激活层;tan$h$ 为激活函数。

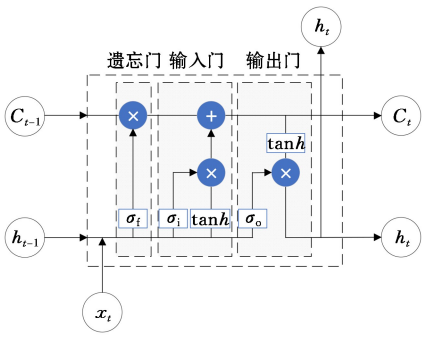


图 2 LSTM 模型结构

Fig.2 Structure of LSTM model

通过 3 个门的协同作用,LSTM 不仅能灵活地通过控制信息的流动来决定信息的遗忘、更新或保留,还能有效避免梯度爆炸和长期依赖的问题。在每次循环中,LSTM 都会利用前一时刻的状态信息,使得当前的输出受到历史状态的影响。这种特性使 LSTM 能够更好地捕捉长期依赖关系,非常适合处理时间序列预测等涉及长期规律的问题。

1.2 卷积神经网络

卷积神经网络(Convolutional Neural Network,CNN)是深度学习中的核心模型之一。近年来,凭借其强大的特征提取能力,CNN 受到了广泛关注,并在计算机技术和大数据发展的推动下迅速进步。在图像分类、语音识别等领域,CNN 取得了显著的突破。与传统神经网络的全连接结构不同,CNN 采用局部连接和权重共享的方式,显著减少了模型参数,降低了网络复杂度,从而有效减少了训练所需的参数量[18]。这种结构不仅提升了训练效率,还减轻了内存占用,为大数据处理提供了支撑[19]。通常,CNN 包括输入层、卷积层、池化层、全连接层和输出层,其模型结构如图 3 所示。DCNN 通过堆叠多个卷积层,进一步增强了 CNN 的空间特征提取能力,为复杂模式识别和预测任务提供了更强的支持。

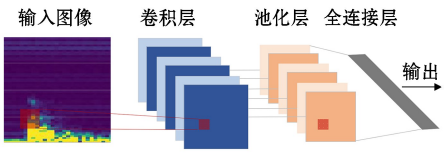


图 3 CNN 模型结构

Fig.3 Structure of CNN model

1.3 LSTM-DCNN 预测模型

在解决预测问题时,通常会采用多种不同的预测模型。由于各模型基于不同的理论基础,它们提供的信息各异,预测精度也存在差异。此外,不同模型往往依赖于特定的假设条件,适用于各自特定的应用场景。鉴于预测本身存在不确定性,依赖单一模型可能会带来较高的风险。为提高预测结果的可靠性,可以将多种模型进行组合,充分整合各模型的信息,从而提升预测的准确性和稳定性[17]。近年来,将 LSTM 与 CNN 结合使用成为深度学习领域的一个研究热点,特别是在自然语言处理和时间序列预测方面取得了显著成效。

本文所构建的混合模型主要由 LSTM 和 DCNN 两部分组成。在该模型中,采用 LSTM 作为编码器,利用其在时序上具有的记忆特性准确提取时间序列特征。采用 DCNN 作为解码器,通过局部连接和共享权值的方式,通过卷积层和池化层的使用来获取数据的局部特征,用于底层表达及抽取重构空间的特征信息[20]。LSTM 作为处理时间序列数据的网络结构,擅长捕获数据的长短期依赖关系。在数据的时间依赖性较强时,将 LSTM 放在前面可以提取全局的时序特征,再交由 CNN 提取空间或局部模式,从而更适合完成任务。LSTM 的记忆机制可以有效过滤时间序列数据中的噪声或非平稳性,将提取的时序特征平滑化或规范化,作为后续 CNN 的输入。尤其是当原始时间序列信号中噪声较多时,这种处理可以减轻 CNN 在面对复杂时间序列时的困难。因此,将 LSTM 前置,可以通过时间序列建模,将高维的时序数据压缩为较低维的特征,后续的 CNN 网络只需处理 LSTM 提取的特征,而不需要直接处理复杂的原始数据,从而减少了 CNN 的计算复杂度。将 LSTM 前置还可以直接输出时间序列的特征向量或隐藏状态,这些特征能够更直观地解释时间序列中的模式或变化趋势。相较于 CNN-LSTM,LSTM-CNN 的结构在分析时间序列的贡献或因果关系时更加透明。LSTM-DCNN 结构见表 1。

表 1 LSTM-DCNN 结构

Table 1 LSTM-DCNN structure

序号	层	激活函数	输出尺寸	卷积核
1	LSTM1	—	100×2	—
2	LSTM2	—	100×8	—
3	LSTM3	—	100×128	—
4	改变数组结构	—	100×128×1	—
5	卷积层 1	ReLU	100×128×16	3×3
6	最大池化层 1	—	50×64×16	2×2
7	卷积层 2	ReLU	50×64×32	3×3
8	最大池化层 2	—	25×32×32	2×2
9	卷积层 3	ReLU	25×32×32	3×3
10	最大池化层 3	—	13×16×32	2×2
11	压平层	—	6 656	—
12	全连接层 1	ReLU	100	—
13	丢弃层 1	—	100	—
14	全连接层 2	ReLU	100	—
15	丢弃层 2	—	100	—
16	全连接层 3	Softmax	1	—
17	输出层	—	—	—

地表沉降数据输入后首先经过 3 层 LSTM,通过堆叠 LSTM 网络层,可以提取更高层的抽象特征。与单层 LSTM 相比,堆叠 LSTM 具有更深的隐藏层结构,能够捕捉到更复杂的数据模式,从而提供更精确的特征。每一层 LSTM 负责处理输入数据的不同方面,并将其结果传递至下一层,逐层提炼信息,最终由最后一层生成输出[21]。这种层次化的处理方式在一定程度上比浅层模型更有效,能够更好地适应复杂的预测和分类任务[22]。然后改变数组结构,将 DCNN 的输入数据转换为三通道的像素矩阵,随后依次经过 3 组由卷积层和最大池化层组成的结构。完成 3 次卷积和池化操作后,数据通过一层压平层展平,最后经过 3 层全连接层处理后输出结果。为了降低网络记住训练数据特定特征的可能性,为全连接层的输入添加一个小的丢弃层,设置丢弃率为 0.5,其主要作用是在训练过程中随机使部分神经元失去活性,断开它们之间的连接,使这些神经元在当前训练轮次中不参与参数更新。这样可以减少神经元的数量,简化模型结构,从而有效缓解过拟合问题[23]。优化器采用自适应矩阵(Adaptive Moment Estimation,Adam),且学习率设为 0.001。目前,尚未成熟的理论可以定量给出所需的网络层数和神经元数,本文 LSTM-DCNN 的网络结构参数通过试错法确定。

2 迁移学习数据集构建

2.1 迁移学习源域数据

由于数值模拟具有高效性、可控性和灵活性等特性,使用模拟结果作为迁移学习的源域数据集对模型进行训练具有一定意义。一方面,数值模拟可以在复杂地质条件下生成大量高质量的样本数据,充分弥补实际观测数据不足的问题;另一方面,模拟数据具有明确的边界条件和参数设定,有助于训练模型提取更全面、更准确的特征。此外,数值模拟结果能够覆盖多种工况,提供丰富的先验知识,为迁移学习中的目标域任务提供坚实的基础,从而提升模型在实际应用中的预测能力和泛化性能。因此,本文选用数值模拟结果来构建高效迁移学习模型的数据集。

根据现场资料中的勘探线、中干沟矿区地质纵剖面和矿区地质横剖面,构建中干沟钒钛磁铁矿三维计算模型。提取断层、围岩、夹岩、西南矿组和东部矿组的边界线,确定其空间姿态以及空间位置。采用“放样”对某一围岩或夹岩等数个断面线构建切割实体面,共计 698 条切割边界线、66 组切割剖面线以及 66 个切割实体面。根据“由大到小,从外到内”的基本原则,采用布尔运算依次对初始模型进行切割,完成整个中干沟钒钛磁铁矿三维精细化计算模型的构建及网格划分。数值模拟模型如图 4 所示,模型的长×宽×高为 2 480 m×2 055 m×2 200 m,Z 方向上面随着地形线的起伏不固定,模型中共有计算单元 112.3 万个,节点 38.9 万个。采场结构布置方式如图 5 所示。

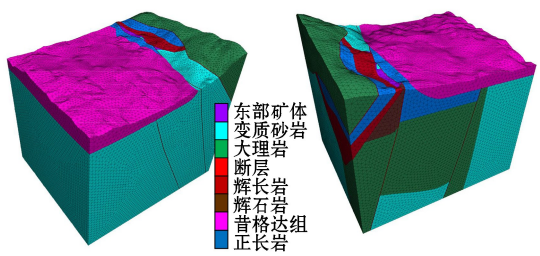


图 4 数值模拟模型

Fig.4 Numerical simulation model

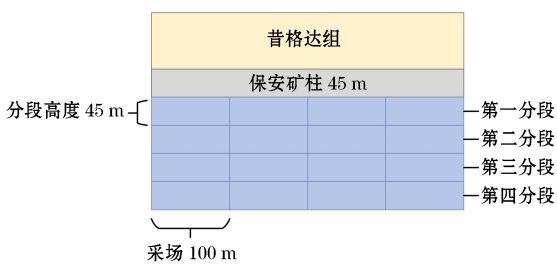


图 5 采场结构布置方式

Fig.5 Layout of stope structure

本次计算采用 Mohr-Coulomb 本构模型,数值模拟计算采用的岩体力学参数见表 2。

表 2 数值模拟计算采用的岩体力学参数

Table 2 Rock mechanics parameters used in numerical simulation calculation

材料	弹性模量/GPa	泊松比	黏聚力/MPa	内摩擦角/(°)	抗拉强度/MPa
昔格达	0.40	0.33	0.20	23.25	0.10
大理岩	33.13	0.16	3.26	42.52	1.12
断层	6.00	0.26	0.17	30.00	0.20
辉长岩	5.88	0.25	1.66	42.75	0.46
正长岩	7.59	0.23	2.13	42.21	0.45
变质砂岩	14.51	0.21	2.61	45.10	0.89
辉石矿	12.38	0.17	3.90	43.86	1.20
橄辉矿	11.47	0.18	3.42	37.35	0.86
充填体(1∶10)	0.81	0.28	0.39	29.00	0.15
充填体(1∶25)	0.35	0.13	0.17	18.00	0.09

中干沟钒钛磁铁矿尚未开展地应力测试,本次模拟参照《工程岩体分级标准》(GB/T 50218—2014)附录 C 中关于岩体初始应力场评估建议,水平向主应力为最大主应力,取 $0.8\gamma H \sim 1.2\gamma H$ 的平均值(H 为距地表埋深,m;γ 为岩体重力密度,kg/m^3)。选取水平主应力为 $1.0\gamma H$,第一主应力为垂直向,第二与第三主应力为水平向,第二主应力与断层走向正交。计算时对模型四周进行法向约束,模型底部进行全约束。对模型根据表 2 进行均质赋值,回采结束后运算至三维数值模型系统的不平衡力达到 1×10^{-5},则视为平衡。然后进行充填,同样运算至不平衡力达到 1×10^{-5}。重复上述过程直至完成计算。

选择地表变形移动中心(1 120,960,1 938)作为验证模型预测准确性的目标域。以目标点为中心,前后左右间隔 1 m,共选择 9 个点作为数值模拟监测点。矿体共分 16 步进行开挖回填,每 4 步为一个分段。提取每一分段开挖监测点地表沉降数据,得到地表沉降结果如图 6 所示。

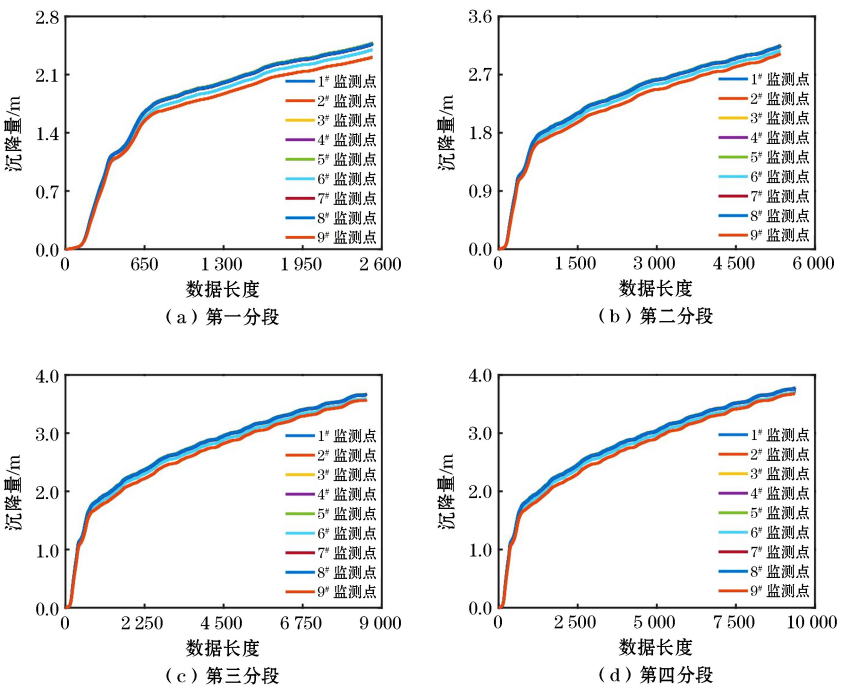


图 6 数值模拟计算的地表沉降结果

Fig.6 Surface subsidence results calculated by numerical simulation

2.2 迁移学习目标域数据

由于矿山尚未开采,缺少实际监测的岩层变形数据,因此本文使用概率积分法计算得出的理论结果作为迁移学习的目标域数据集,并对模型进行重新训练。概率积分法计算得出的理论沉降值反映了目标区域的特定地质条件和实际工程参数,能够弥补数值模拟数据在描述特定工况时的局限性。目标域数据集包含了实际场景中的关键特征和约束条件,通过对模型进行重新训练,可以有效减少源域数据与目标域实际情况之间的分布差异,增强模型的适应性和预测精度。因此,结合理论计算结果对模型进行微调,能够显著提升模型在目标域的应用效果。

概率积分法常用于煤矿的开采预测,但黄刚等[24]发现该方法也可用于金属矿山的场景。概率

积分法基于随机介质理论,将采矿引起的地表变形视为随机事件。该方法通过概率积分或其倒数来描述微小单元开采所导致的地表移动和变形模型,并利用叠加原理计算整体开采引起的地表变形[25]。概率积分法在模型中并未考虑采空区覆岩的岩土体力学性质、覆岩的岩层空间分布、地质构造以及采矿技术等外部因素的影响。因此,该方法的理论公式相对简单,半无限开采下地表及深部岩体任一点的下沉值 W 的计算公式为:

$$W(x,z)=W_0\left(\frac{1}{\sqrt{\pi}}\int_0^{\frac{\sqrt{\pi}x}{r_z}}e^{-\lambda^2}d\lambda+\frac{1}{2}\right) \quad (1)$$

式中:W_0 为地表最大下沉值,$W_0=m\eta\cos\alpha$,m 为矿体开采厚度,η 为地表下沉系数,$\cos\alpha$ 为矿体倾角的余弦值;r_z 为主要影响半径,$r_z=\sqrt{4A\pi}=\dfrac{H}{\tan\beta}$,$A$ 为一个反映理论模型格子尺寸的常数,H 为采深,$\tan\beta$ 为主要影响角正切值;λ 为水平方向积分距离。

根据公式(1)及有关参数,编制计算程序[26]。计算参数如下:a 为矿体与水平面夹角;L_1 为沿走向方向开采总长度;L_2 为沿倾向方向开采总长度;s_1 为走向左边界拐点偏距;s_2 为走向右边界拐点偏距;s_3 为下山拐点偏距;s_4 为上山拐点偏距;b 为水平移动系数。计算参数取值见表 3。

表 3 计算参数取值

Table 3 Calculation parameter values

a	L_1	L_2	$\tan\beta$	s_1	s_2	s_3	s_4	b
80	447	600	1.5	60	40	50	50	0.51

根据 2.1 节建立的三维矿体模型,按开采的 4 个步骤,计算每一步的地表理论变形值。按照开采步骤进行矿体模型切割,建立 10 m×10 m×10 m 的立方体,将矿体离散化,导出 21 716 个块体质心点坐标及边长,作为程序输入数据。计算出矿山开采过程中的地表沉降值,作为检验预测模型准确性的真实值,基于概率积分法的地表沉降理论值如图 7 所示。

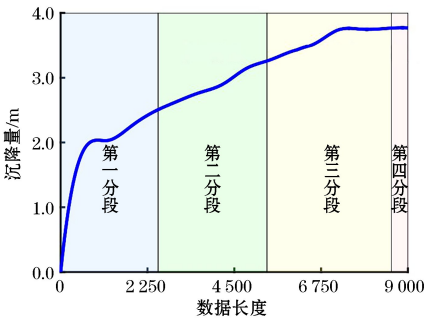


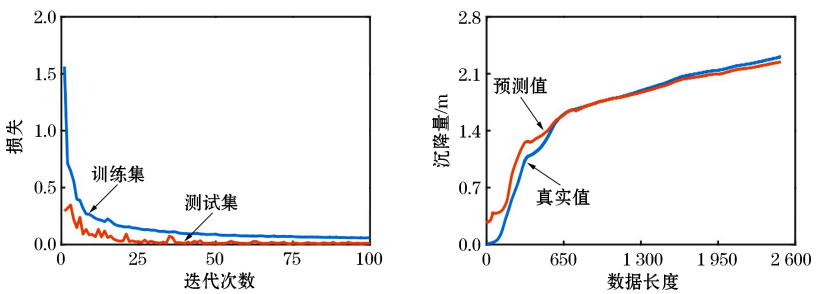
图 7 基于概率积分法的地表沉降理论值

Fig.7 Theoretical values of surface subsidence based on probability integral method

3 地表沉降预测结果

预测地表沉降属于回归问题,可以利用损失来量化预测结果与真实值之间的差异。损失是衡量机器学习模型在整个数据集上预测不准确性的总体指标,它反映了模型预测与真实值之间的差异,并将这些差异进行聚合,以提供一个标量值来表示预测的总体不准确性。通过最小化损失可以优化模型参数并改进预测性能。损失的具体计算是通过损失函数来完成的,损失函数接受模型的预测值和真实值作为输入,并输出一个标量值,即损失值,表示模型在整个数据集上的总体预测误差。通过绘制训练损失和验证损失随迭代次数的变化,可以直观看出模型在训练过程中损失值的变化趋势,以及是否遭遇过拟合或欠拟合等问题,进而调整模型结构和训练策略。

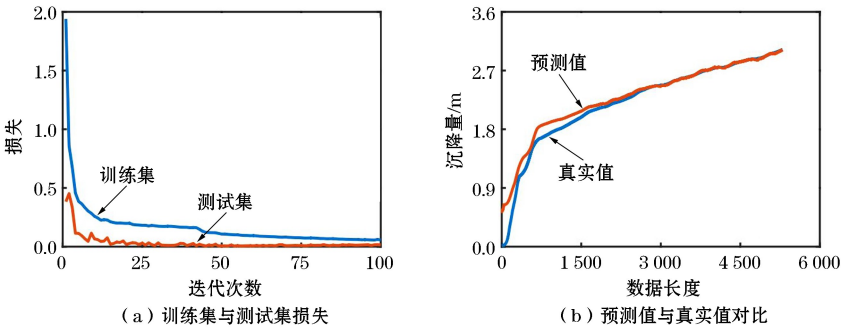
将 9 条数值模拟监测数据输入模型,进行迭代训练并保存预训练后的模型。在预训练模型的顶部引入一个新的全连接层,以便更好地适应特定的新任务。冻结预训练模型的所有参数,使用 2.2 节地表沉降理论计算结果作为少量的新数据集进行微调。在微调过程中,仅对新添加的层进行训练,从而保持预训练模型中已学到的特征不被破坏。最后进行测试和验证,评估微调后的模型性能。第一分段至第四分段开挖的地表沉降预测结果分别如图 8 至图 11 所示。



(a) 训练集与测试集损失 (b) 预测值与真实值对比

图 8 第一分段开挖地表沉降预测结果

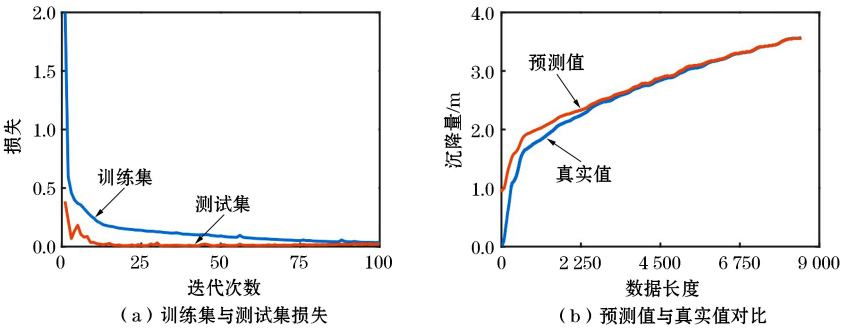
Fig.8 Prediction results of surface subsidence during excavation of the first segment



(a) 训练集与测试集损失 (b) 预测值与真实值对比

图 9 第二分段开挖地表沉降预测结果

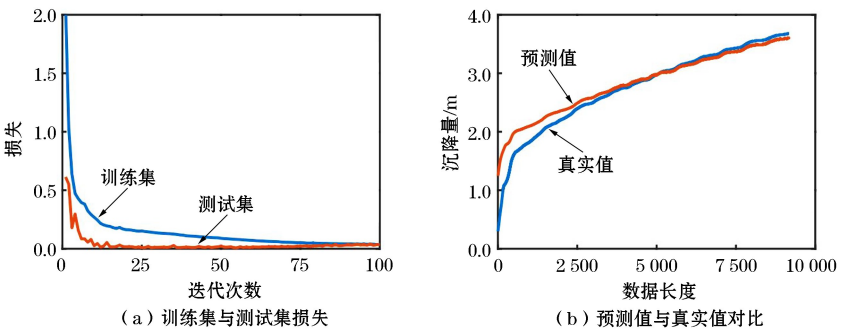
Fig.9 Prediction results of surface subsidence during excavation of the second segment



(a) 训练集与测试集损失 (b) 预测值与真实值对比

图 10 第三分段开挖地表沉降预测结果

Fig.10 Prediction results of surface subsidence during excavation of the third segment



(a) 训练集与测试集损失 (b) 预测值与真实值对比

图 11 第四分段开挖地表沉降预测结果

Fig.11 Prediction results of surface subsidence during excavation of the fourth segment

本文分别使用均方误差(E_{MS})、平均绝对百分比误差(E_{MAP})、平均绝对误差(E_{MA})、均方根误差(E_{RMS})4 种误差值评价模型的预测效果,具体计算公式如下:

$$E_{MS}=\frac{1}{N}\sum_{i=1}^{N}(y_i-y'_i)^2 \tag{2}$$

$$E_{MAP}=\frac{1}{N}\sum_{i=1}^{N}\left|\frac{y_i-y'_i}{y_i}\right| \tag{3}$$

$$E_{MA}=\frac{1}{N}\sum_{i=1}^{N}|y_i-y'_i| \tag{4}$$

$$E_{RMS}=\sqrt{\frac{1}{N}\sum_{i=1}^{N}(y_i-y'_i)^2} \tag{5}$$

式中:N 表示样本数量;y_i 表示真实值;y'_i 表示预测值。计算误差越小,表示预测值与真实值之间的差异越小,模型的拟合效果越好。

各分段开挖出矿量及预测误差值见表 4。由表 4 可知,预测误差在各分段的 E_{MS} 均小于 0.04,E_{MA} 的变化幅度较小,表示该模型对地下开采地表沉降预测具有较高的准确性,且模型在各分段中的表现较为稳定。但随着出矿量的增加,开采后矿区地质条件更加复杂,加之数据量的增加,导致预测模型的适用性减弱,4 种误差均呈现出一定的增大趋势,说明该模型仍存在一定的改进空间,尤其是在后期分段的预测精度上。

表 4 各分段开挖出矿量及预测误差值

Table 4 Ore output and predicted error values of each segment excavation

分段名称	出矿量/($\times 10^6$ m^3)	E_{MS}	E_{MAP}	E_{MA}	E_{RMS}
第一分段	79.41	0.013 3	0.074 9	0.071 2	0.115 4
第二分段	136.07	0.017 6	0.082 7	0.068 4	0.132 7
第三分段	179.74	0.030 7	0.093 0	0.073 1	0.175 2
第四分段	204.67	0.034 4	0.122 4	0.080 0	0.185 5

4 结论

(1) 本文提出了一种基于深度学习和迁移学习的矿山地下开采地表沉降预测方法,建立了一种新的地表沉降预测模型,融合 LSTM 与 DCNN,采用 LSTM 准确提取时间序列特征和 DCNN 提取数据的局部特征,提高了对时间序列预测的准确性。

(2) 依托中干沟钒钛磁铁矿地下开采项目,以数值模拟结果为源域数据,对模型进行预训练并冻结原模型各层参数。为预训练的模型添加一个全连接层,使用概率积分法计算的地表沉降理论值作为目标域重新训练模型,对参数进行微调并更新权重,得到适用于地表沉降理论计算值的预测模型。结果显示,随着出矿量的增加,各误差值有所增长,但 E_{MS} 均小于 0.04,表示该模型对地下开采的地表沉降预测具有较高的准确性。

(3) 本文提出的方法可为类似矿山相关问题的研究提供新思路。在基于迁移学习和深度学习进行地表沉降预测时,由于矿山尚未开采,缺乏实际监测数据,本文使用概率积分法计算出的理论变形值来替代监测数据,以验证模型的预测准确性。当矿山开始开采后,应将实际动态监测数据实时输入到模型中,对预测结果进行进一步修正。此外,模型的结构应根据实际数据情况进行进一步的优化,以提高预测效果。

参考文献(References):

[1] 刘宝琛,戴华阳.概率积分法的由来与研究进展[J].煤矿开采,2016,21(2):1-3.
LIU Baochen, DAI Huayang. Research development and origin of probability integral method [J]. Coal Mining Technology,2016,21(2):1-3.

[2] 杨小磊,王海,马秋红.黄土丘陵区煤矿采空塌陷地表移动预测及其对公路稳定性的影响分析[J].公路,2025,70(1):121-129.
YANG Xiaolei, WANG Hai, MA Qiuhong. Prediction of surface movement in the coal mine void in Loess Hilly Region and its impact on highway stability analysis [J]. Highway,2025,70(1):121-129.

[3] 叶应高,李永昇,李卓然,等.基于概率积分法的复杂多层采空区隧道地表变形预测方法研究[J].北方交通,2024(5):71-75.
YE Yinggao, LI Yongsheng, LI Zhuoran, et al. Research on prediction method for tunnel surface deformation of complex multi-layer goaf based on probability integration method[J]. Northern Communications,2024(5):71-75.

[4] 黄刚,李东伟,陆港.基于概率积分法和数值模拟的某铁矿地表沉降影响研究[J].武汉理工大学学报,2024,46(2):94-101.
HUANG Gang, LI Dongwei, LU Gang. Research on surface settlement impact of a certain iron mine based on probability integration method and numerical simulation[J]. Journal of Wuhan University of Technology,2024,46(2):94-101.

[5] 贺小卫,王虎军,高宇,等.多孔顶管施工诱发地面沉降预测及数值模拟研究[J].特种结构,2025,42(1):64-68.
HE Xiaowei, WANG Hujun, GAO Yu, et al. Prediction and numerical simulation of ground settlement induced by porous pipe jacking construction [J]. Special Structures, 2025,42(1):64-68.

[6] 黄鑫康,刘萍,芦庆和,等.基于改进麻雀搜索算法优化 SVR 和 FLAC3D 的开采地表沉降预测[J].矿业研究与开发,2023,43(10):110-118.
HUANG Xinkang, LIU Ping, LU Qinghe, et al. Prediction of mining surface subsidence by optimized SVR based on improved sparrow search algorithm and FLAC3D [J]. Mining Research and Development,2023,43(10):110-118.

[7] 崔轩,杨胜利.地下开采诱发的地表岩移演化规律及稳定性分析[J].矿业研究与开发,2023,43(8):78-83.
CUI Xuan, YANG Shengli. Evolution law and stability analysis of surface rock displacement induced by underground mining[J]. Mining Research and Development,2023,43(8):78-83.

[8] 章海兵,刘勤志,孔德中,等.喀斯特山区重复采动下地表沉陷预测研究[J].矿业研究与开发,2024,44(3):65-72.
ZHANG Haibing, LIU Qinzhi, KONG Dezhong, et al. Study on surface subsidence prediction under repeated mining in Karst Mountainous Areas[J]. Mining Research and Development,2024,44(3):65-72.

[9] 陈耀华,卢茂琼.基于 WOA-BP 神经网络的采空区地表沉降安全预测模型[J].价值工程,2024,43(24):55-58.
CHEN Yaohua, LU Maoqiong. Safety prediction model of surface settlement in the mining area based on WOA-BP neural networks [J]. Value Engineering, 2024, 43 (24): 55-58.

[10] 高墨通,杨维芳,刘祖昱,等.结合卷积神经网络和注意力机制的 LSTM 采空区地表沉降预测方法[J].测绘通报,2024(6):53-58+170.
GAO Motong, YANG Weifang, LIU Zuyu, et al. LSTM goaf surface subsidence prediction method combining convolutional neural network and attention mechanism[J]. Bulletin of Surveying and Mapping,2024(6):53-58+170.

[11] DREDZE M, KULESZA A, CRAMMER K. Multi-domain learning by confidence-weighted parameter combination[J]. Machine Learning,2010,79:123-149.

[12] LU J, BEHBOOD V, HAO P, et al. Transfer learning using computational intelligence: a survey[J]. Knowledge-Based Systems,2015,80:14-23.

[13] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation,1997,9(8):1735-1780.

[14] HSUEH Y L, YANG Y R. A short-term traffic speed prediction model based on LSTM networks[J]. International journal of intelligent transportation systems research,2021,19:510-524.

[15] DUDEK G, PEŁKA P, SMYL S. A hybrid residual dilated LSTM and exponential smoothing model for midterm electric load forecasting[J]. IEEE Transactions on Neural Networks and Learning Systems,2021,33(7):2879-2891.

[16] YANG Z, LI Z, ZHOU S, et al. Speech emotion recognition based on multi-feature speed rate and LSTM [J]. Neurocomputing,2024,601:128177.

[17] 赵永,焦诗卉,赵乾百.基于 Mel 频谱和 LSTM-DCNN 的矿山微震信号混合识别模型[J].东北大学学报(自然科学版),2023,44(10):1481-1489.
ZHAO Yong, JIAO Shihui, ZHAO Qianbai. Hybrid recognition model of microseismic signals for mining based on Mel spectrum and LSTM-DCNN [J]. Journal of Northeastern University (Natural Science),2023,44(10):1481-1489.

[18] SOKOLIĆ J, GIRYES R, SAPIRO G, et al. Robust large margin deep neural networks[J]. Transactions on Signal Processing,2017,65(16):4265-4280.

[19] 赵永.基于微震数据的采动围岩损伤及裂隙通道演化分析方法与应用[D].沈阳:东北大学,2020.
ZHAO Yong. Analysis method and application of damage and fracture channel evolution of mining surrounding rock based on microseismic data[D]. Shenyang: Northeastern University,2020.

[20] 胡彦军.基于深度学习的桃树缺铁症细粒度识别与矫治系统[D].新乡:河南科技学院,2024.
HU Yanjun. Deep learning-based peach tree iron deficiency granule recognition and correction system[D]. Xinxiang: Henan Institute of Science and Technology,2024.

[21] 黄雪婷.基于 SARIMA 和 CNN-LSTM 组合模型的呼叫中心日话务量预测研究[D].南京:南京邮电大学,2022.
HUANG Xueting. Daily arrivals forecasting of call center based on combined model of SARIMA and CNN-LSTM[D]. Nanjing: Nanjing University of Posts and Telecommunications, 2022.

[22] 张一凡,张双辉,刘永祥,等.基于注意力机制的堆叠 LSTM 网络雷达 HRRP 序列目标识别方法[J].系统工程与电子技术,2021,43(10):2775-2781.
ZHANG Yifan, ZHANG Shuanghui, LIU Yongxiang, et al. Radar HRRP sequence target recognition method of attention mechanism based stacked STM network [J]. Systems Engineering and Electronics, 2021, 43 (10): 2775-2781.

[23] 刘镇融.基于 CNN-LSTM 和迁移学习的股价预测建模研究[D].哈尔滨:哈尔滨师范大学,2023.
LIU Zhenrong. Research on stock price prediction modeling based on CNN-LSTM and transfer learning[D]. Harbin: Harbin Normal University,2023.

[24] 黄刚,李东伟,陆港.基于概率积分法和数值模拟的某铁矿地表沉降影响研究[J].武汉理工大学学报,2024,46(2):94-101.
HUANG Gang, LI Dongwei, LU Gang. Research on surface settlement impact of a certain iron mine based on probability integration method and numerical simulation[J]. Journal of Wuhan University of Technology,2024,46(2):94-101.

[25] 贾艳昌,谢谟文,昌圣翔,等.基于概率积分法和自四归模型的开采沉陷算法[J].科学技术与工程,2017,17(7):148-152.
JIA Yanchang, XIE Mowen, CHANG Shengxiang, et al. The subsidence prediction of goaf based on probability integral method and auto regressive moving average model [J]. Science Technology and Engineering, 2017, 17 (7): 148-152.

[26] SIKORA P, WESOOWSKI M. Numerical assessment of the influence of former mining activities and plasticity of rock mass on deformations of terrain surface[J]. International Journal of Mining Science and Technology, 2021, 31 (2): 209-214.