

基于人工智能的露天煤矿边坡位移时序预测模型构建

王迪

呼伦贝尔东明矿业有限责任公司 内蒙古 呼伦贝尔 021506

摘要：本文旨在系统性地探讨基于人工智能的露天煤矿边坡位移时序预测模型的构建理论与方法体系。文章首先深入剖析了露天煤矿边坡位移的内在机理与影响因素，明确了时序预测的必要性与挑战；其次，全面梳理了从传统统计学到现代人工智能的边坡位移预测方法演进脉络，并重点论述了循环神经网络（RNN）、长短时记忆网络（LSTM）、门控循环单元（GRU）以及Transformer等主流AI时序模型的原理及其在该领域的适用性；在此基础上，提出了一套完整的、通用的AI时序预测模型构建框架，详细阐述了从多源异构数据的预处理、特征工程，到模型架构设计、超参数优化，再到模型评估与可解释性增强等关键环节的技术要点；最后，对当前研究面临的挑战与未来发展趋势进行了展望，以期为推动露天煤矿智能化安全监测与预警体系的建设提供理论参考和技术支撑。

关键词：人工智能；露天煤矿；边坡位移；时序预测；模型构建

引言

在全球能源结构转型与“双碳”目标下，煤炭在我国能源消费中短期内仍占主体地位，露天开采产量占比攀升。但随开采深度和采场规模扩大，露天矿边坡稳定性问题突出且复杂，一旦失稳破坏，会造成经济损失、中断生产，甚至引发人员伤亡，威胁周边生态环境和社会稳定。工程实践表明，边坡失稳是渐进累积损伤过程，其位移时序数据蕴含丰富信息，深入挖掘分析历史位移数据，建立准确捕捉动态规律、可靠预测未来趋势的时序预测模型，是实现滑坡灾害“由被动救灾向主动防灾”转变的关键。长期以来，边坡位移预测依赖力学原理数值模拟和基于监测数据的经验统计两类方法，但前者因复杂工程现场参数难准确获取，模型结果偏差大；后者面对边坡位移特性时预测精度和鲁棒性欠佳。而以深度学习为代表的人工智能技术，为突破局限带来机遇，其强大的能力可构建端到端、数据驱动、高精度的边坡位移智能预测模型。

1 露天煤矿边坡位移机理与影响因素分析

1.1 边坡位移的内在机理

从力学角度看，边坡位移的根本驱动力源于重力。当边坡开挖后，原有的地应力平衡被打破，坡体在自重作用下趋向于向临空面移动。这一过程受到岩土体自身强度（抗剪强度）的抵抗。根据极限平衡理论，当坡体某一部分的下滑力超过其抗滑力时，便会发生失稳破坏。但在完全失稳之前，坡体内部会经历一个漫长的蠕变变形阶段，表现为持续的、加速的位移。这个阶段的位移时序通常可以分解为趋势项、周期项和随机项。趋势项反映了由开采扰动、岩体流变等引起的长期、不可

逆的变形；周期项则主要受降雨、冻融循环、地下水位季节性波动等环境因素影响；随机项则包含了测量噪声、局部岩体崩落等偶然事件。

1.2 主要影响因素

边坡稳定性受多因素复杂耦合作用。地质与岩土条件是内因，包括岩层产状、岩性组合、节理裂隙发育、软弱夹层及岩体力学参数（如内摩擦角、粘聚力），例如顺倾向软弱夹层易引发滑动。水文地质条件是最活跃外因，降雨入渗增加岩土重度并降低抗剪强度，地下水压力亦削弱稳定性，故降雨量、强度及水位是关键驱动因子^[1]。采矿活动如台阶推进、爆破振动、运输荷载和排土堆载显著扰动应力场，加速变形。气象与环境因素如冻融循环、风化作用及地震等进一步劣化岩体性能。这些因素高度非线性、动态交织，导致传统方法建模困难，凸显AI在处理高维耦合问题中的优势。

2 边坡位移预测方法演进与AI模型概述

2.1 预测方法的演进

边坡位移预测方法的发展大致经历了三个阶段：第一阶段：经验类比与定性分析。主要依靠工程师的经验和简单的安全系数法进行判断，缺乏定量预测能力。第二阶段：确定性力学模型。以极限平衡法和连续介质数值模拟（如FLAC3D, ANSYS）为代表，试图通过求解物理方程来预测位移。这种方法物理基础扎实，但对输入参数敏感，且计算成本高昂。第三阶段：数据驱动的智能模型。随着监测技术（如GNSS、InSAR、测量机器人）的进步，海量位移时序数据得以积累。这催生了以统计学模型（如ARIMA, GM(1,1)）和机器学习模型（如SVM, RF）为代表的第四代方法。而当前正处于向以深度

学习为核心的第五代方法跃迁的过程中。

2.2 主流AI时序预测模型

针对边坡位移的时序特性，以下几类AI模型尤为适用：

2.2.1 循环神经网络（RNN）

RNN是处理序列数据的经典神经网络架构。其核心思想是引入“记忆”单元，通过隐藏状态（hidden state）来传递序列中先前时刻的信息，从而理论上能够捕捉序列的长期依赖关系。然而，在实际应用中，标准RNN容易遭遇梯度消失或爆炸问题，难以学习到长距离的依赖。

2.2.2 长短时记忆网络（LSTM）

LSTM是RNN的一种改进型，通过精心设计的“门”机制（输入门、遗忘门、输出门）来控制信息的流动。遗忘门可以选择性地丢弃不重要的旧信息，输入门则决定哪些新信息需要被存储^[2]。这种机制有效地缓解了梯度消失问题，使其能够学习和记忆非常长的序列依赖关系，成为时序预测领域的“常青树”。

2.2.3 门控循环单元（GRU）

GRU可以看作是LSTM的简化版本。它将LSTM的遗忘门和输入门合并为一个更新门，并取消了输出门。尽管结构更简单，但GRU在许多任务上表现出与LSTM相当甚至更好的性能，且计算效率更高。

2.2.4 Transformer

最初为自然语言处理任务设计的Transformer模型，凭借其强大的自注意力（Self-Attention）机制，在时序预测领域也大放异彩。自注意力机制允许模型在处理序列中的任何一个元素时，都能直接关注到序列中的所有其他元素，并根据相关性分配不同的权重。这使得Transformer能够并行处理整个序列，极大地提升了训练

速度，并能有效捕捉序列中的全局依赖关系，克服了RNN系列模型固有的顺序计算瓶颈。

3 基于AI的边坡位移时序预测模型构建框架

构建一个成功的AI预测模型是一个涉及数据、算法、工程实践等多个环节的系统工程。本文提出一个通用的四阶段构建框架。

3.1 数据采集与预处理

高质量的数据是模型成功的基石。（1）多源数据融合：理想的输入不应仅限于位移本身。应尽可能融合多源数据，包括：位移监测数据（作为目标变量Y）、降雨量、地下水位、开采进度、爆破记录等（作为特征变量X）。这种多变量输入有助于模型理解位移变化的驱动机制^[3]。（2）数据清洗：原始监测数据不可避免地包含缺失值、异常值和噪声。需要采用插值（如线性插值、KNN插值）、平滑（如移动平均、小波去噪）和异常检测（如基于统计或孤立森林的方法）等技术进行清洗。（3）数据标准化/归一化：由于不同特征的量纲和取值范围差异巨大（如位移单位为毫米，降雨量为毫米/天），必须进行标准化（Z-score）或归一化（Min-Max）处理，以加速模型收敛并提升性能。

3.2 特征工程与时序窗口构造

对于纯粹的时序预测模型（如只用历史位移预测未来位移），特征工程的核心在于构造“滑动窗口”，将一维的位移时间序列转换为监督学习问题。例如，若要根据过去N个时间步的位移来预测未来M个时间步的位移，则每个样本将是一个形状为(N, 1)的输入矩阵和一个形状为(M, 1)的输出向量。窗口大小N的选择至关重要，它决定了模型“记忆”的长度，需通过实验或领域知识确定。表1展示了典型的输入输出数据格式。

表1：滑动窗口构造示例（N = 5, M = 1）

样本ID	输入特征(过去5天位移/mm)	目标输出(第6天位移/mm)
1	[1.2, 1.5, 1.8, 2.0, 2.3]	2.7
2	[1.5, 1.8, 2.0, 2.3, 2.7]	3.1
3	[1.8, 2.0, 2.3, 2.7, 3.1]	3.6
...	...	...

3.3 模型架构设计与训练

（1）模型选择：对于初学者或计算资源有限的情况，LSTM或GRU是稳健的选择。若追求更高的精度和捕捉全局模式的能力，且拥有充足的计算资源，Transformer是更优的选择。也可以尝试将信号分解技术（如EMD, VMD）与AI模型结合，先将复杂的原始位移序列分解为若干个相对平稳的子序列，再分别建模，最

后集成预测结果。（2）损失函数：常用的损失函数包括均方误差（MSE）和平均绝对误差（MAE）。MSE对大误差更为敏感，有助于提升整体精度；MAE则更具鲁棒性。有时也会使用Huber Loss等混合损失函数。（3）超参数优化：模型性能极大程度上依赖于超参数（如LSTM/GRU的层数、每层的神经元数量、学习率、批大小、Dropout率等）。可以采用网格搜索、随机搜索或更

高效的贝叶斯优化（Bayesian Optimization）等方法进行系统性调优。表2列出了LSTM模型的关键超参数及其典型调优范围。

表2：LSTM模型关键超参数及调优范围

超参数	描述	典型调优范围	优化目标
层数(Layers)	LSTM堆叠的层数	1-4	平衡模型复杂度与过拟合风险
神经元数(Units)	每层LSTM单元的数量	32-256	决定模型的表征能力
学习率(LearningRate)	参数更新的步长	0.0001-0.01	影响收敛速度与稳定性
批大小(BatchSize)	每次迭代使用的样本数	16-128	影响内存占用与梯度估计的稳定性
Dropout率	防止过拟合的随机失活比例	0.1-0.5	提升模型泛化能力

3.4 模型评估与可解释性

（1）评估指标：除了训练集上的损失，必须在独立的测试集上使用客观指标评估模型的泛化能力。常用指标包括：均方根误差（RMSE）、平均绝对百分比误差（MAPE）、决定系数（ R^2 ）等^[4]。（2）可解释性增强：AI模型常被视为“黑箱”，这在安全攸关的工程领域是一个障碍。可以引入可解释性技术，如SHAP（SHapley Additive exPlanations）或LIME（Local Interpretable Model-agnostic Explanations），来分析各个输入特征（如降雨、历史位移）对最终预测结果的贡献度，从而增加模型的可信度和工程指导价值。

4 挑战与未来展望

尽管AI在边坡位移预测中前景广阔，仍面临四大挑战：一是高质量、长周期、多维监测数据获取成本高，且滑坡前的“失稳”样本稀少，导致严重样本不平衡；二是纯数据驱动模型易忽略物理规律，产生违背力学原理的预测，亟需融合物理先验知识，发展物理信息神经网络（PINN）；三是现有模型多仅提供点预测，缺乏对不确定性的量化，未来需引入贝叶斯神经网络、分位数回归等概率预测方法以支持风险决策；四是边坡状态动态演化，要求模型具备在线学习与自适应能力，持续更新以反映最新工况。未来研究将推动岩土力学、水文地质、数据科学与AI的深度融合，构建更智能、可靠、可解释的边坡安全预警系统。

5 结语

本文系统探讨了基于人工智能的露天煤矿边坡位移

时序预测模型构建。首先强调边坡位移预测对安全生产的重要性，并指出传统方法在处理非线性、多因素耦合问题上的不足。随后分析了边坡变形机理的复杂性，为AI建模提供理论支撑，并梳理了从传统统计到深度学习的演进路径，重点阐述LSTM、GRU和Transformer等主流时序模型的优势。核心贡献在于提出一套完整的模型构建框架，涵盖数据预处理、特征工程、模型设计、训练优化与结果评估解释，为研究与应用提供清晰技术路线。文章还客观指出当前在数据质量、模型泛化与可解释性等方面的挑战，并展望未来AI与多学科融合的发展方向。随着技术进步，AI驱动的智能预测有望成为露天煤矿安全监测与预警体系的核心，助力矿山智能化与本质安全化建设。

参考文献

[1]王忠鑫,张令非,曹建,等.大型露天煤矿边坡工程数字化与智能监测预警技术研究进展[J].工矿自动化,2025,51(11):54-64.

[2]张博超,童辉,杜飞.露天煤矿边坡稳定性及智能监测技术研究现状[J].中国矿业,2024,33(S2):92-97.

[3]梁建强.基于MEMS的露天煤矿边坡智能监测技术研究[J].资源信息与工程,2025,40(01):48-52.

[4]常友伟,孟宪中,王宇波.边坡监测系统设计在准格尔旗川发煤矿运用分析[J].江苏建筑职业技术学院学报,2025,25(04):18-21.