

# 基于深度学习的煤矿掘进自动化技术研究

张亚洲 吕广辉 张悟安

华亭煤业陈家沟煤矿, 中国·甘肃 平凉 744100

**摘要:** 随着煤矿行业的自动化需求不断增长, 深度学习技术在煤矿掘进自动化中显示出巨大的潜力。论文基于深度学习, 开发一种可应对复杂环境的煤矿掘进自动化系统, 通过环境感知、决策控制与执行控制模块的集成, 实现掘进过程的智能化与高效化操作。

**关键词:** 深度学习; 煤矿掘进; 自动化

## Research on Coal Mine Excavation Automation Technology Based on Deep Learning

Yazhou Zhang Guanghui Lv Wu'an Zhang

Huating Coal Industry Chenjiagou Coal Mine, Pingliang, Gansu, 744100, China

**Abstract:** With the increasing demand for automation in the coal mining industry, deep learning technology has shown great potential in the automation of coal mining excavation. The paper is based on deep learning and develops a coal mine excavation automation system that can cope with complex environments. Through the integration of environmental perception, decision control, and execution control modules, the intelligent and efficient operation of the excavation process is achieved.

**Keywords:** deep learning; coal mining excavation; automation

## 1 引言

煤矿行业一直存在环境复杂、作业危险、效率低下等问题。随着人工智能技术的发展, 尤其是深度学习的进步, 为煤矿掘进的自动化和智能化提供了新的可能性。论文通过深度学习技术实现掘进过程的高效化和安全化操作。通过对环境感知模块的改进, 能够在复杂矿井环境中准确定位目标, 提供实时数据; 决策控制模块根据实时数据进行智能化的决策; 执行控制模块则可以高效、精准地完成掘进任务。

## 2 深度学习理论基础

深度学习作为机器学习的一个分支, 基于人工神经网络, 尤其是在处理大量数据时展现出卓越的性能。模拟人脑的处理方式能自动地从大量数据中学习复杂的模式和特征。在理论上, 深度学习主要依靠多层的神经网络结构, 每一层通过激活函数对输入信息进行转换和传递, 逐层提取信息中更为深层的特征。关键的技术包括卷积神经网络(CNN)和循环神经网络(RNN), 这些网络结构特别适合处理图像、声音及时间序列数据, 在图像识别、语音识别和自然语言处理等领域得到广泛应用。在煤矿掘进的自动化技术中, 深度学习能够通过环境的深入学习, 实现对复杂地下环境的高效识别和理解。例如, 通过训练卷积神经网络识别岩层图片, 系统可以准确地识别出不同的岩层类型, 优化掘进机的工作参数, 提高作业效率与安全性。利用循环神经网络处理历史掘进数据, 可以预测未来的地质变化, 为掘进作业提供科学的决策支持。这些应用提高了煤矿掘进的自动化水平, 为工人提供了更安全的工作环境<sup>[1]</sup>。

## 3 煤矿掘进自动化系统设计

### 3.1 系统总体架构

煤矿掘进自动化系统的总体架构是设计来优化矿井作业的安全性和效率。该系统由多个关键模块构成, 包括数据采集模块、环境感知模块、决策控制模块和执行控制模块。数据采集模块负责从矿井内部及掘进设备收集实时数据, 如岩层图像、温湿度、瓦斯浓度等, 这些数据是系统进行智能决策的基础。环境感知模块使用深度学习技术对采集的数据进行分析, 识别出关键的安全和操作信息, 如岩层稳定性和潜在的危險区域。决策控制模块则基于环境感知模块提供的信息, 使用先进的算法来制定掘进策略, 优化掘进参数, 实时调整作业计划以适应复杂多变的地下环境。执行控制模块将决策模块的输出转化为具体操作, 控制掘进机械的行动, 确保掘进工作的精确执行。系统还包括一个监控与反馈机制, 能持续监控整个掘进过程, 在必要时调整系统的运作策略, 应对突发事件和环境变化。整个系统的设计考虑到了矿井环境的特殊性和操作的复杂性, 通过集成先进的深度学习技术和自动化控制技术, 极大地提高了煤矿掘进的安全性和效率<sup>[2]</sup>。

### 3.2 环境感知模块

环境感知模块是煤矿掘进自动化系统中的关键组成部分, 尤其在三维重建与建模环节中, 通过高精度的图像采集与深度学习技术实现对矿井环境的精确模拟。在图像采集与预处理阶段, 采用高分辨率摄像机连续拍摄矿井内部的图像, 然后通过图像预处理技术, 如灰度化、噪声滤波和边

缘检测,提高图像质量以适应后续处理。图像预处理可以使用高斯模糊来减少图像噪声,边缘检测则常用 Canny 算法提取图像边缘。深度学习目标检测阶段运用卷积神经网络(CNN)模型识别图像中的关键特征和对象,例如岩层断裂和结构弱点。这一阶段常用的模型包括 YOLO (You Only Look Once) 或 SSD (Single Shot MultiBox Detector),能在保证速度的同时,实现高准确率的目标检测。在三维重建与建模环节,关键技术包括结构光法或激光扫描来获取空间点云数据,然后使用如下公式进行数据分析和三维模型构建:

$$P'(x', y', z') = R(P(x, y, z) - T)$$

其中,  $P(x, y, z)$  表示原始点云中的点,  $P'(x', y', z')$  表示转换后的点,  $R$  和  $T$  分别代表旋转矩阵和平移向量,用于校正摄像机视角带来的误差。三维模型的精细化处理还涉及网格生成和纹理映射,这有助于生成高度真实的矿井环境模型,为掘进决策提供更为准确的数据支持。整个环境感知模块通过这些高级技术的集成,确保了煤矿掘进自动化系统在复杂矿井环境中的高效与安全运行。

### 3.3 决策控制模块

决策控制模块在煤矿掘进自动化系统中起着核心作用,特别是在路径规划和行为决策两个环节。路径规划算法首先根据环境感知模块提供的三维地图数据,使用 A\* (A-Star) 算法进行高效路径搜索。A\* 算法通过计算每一步的成本 ( $g(n)$ ) 加上到目标的估计成本  $h(n)$ , 来找到总成本  $f(n)=g(n)+h(n)$  最小的路径。这一计算过程涉及以下公式:

$$f(n)=g(n)+h(n)$$

其中,  $g(n)$  是从起点到当前点的实际距离,  $h(n)$  是从当前点到终点的预估距离,通常采用欧几里得距离或曼哈顿距离来估算。

在行为决策模型方面,该模块采用基于状态的决策树来评估和执行不同的行为策略。例如,根据掘进机当前的状态(如位置、速度、周围环境等)和目标(如指定的掘进位置),决策树将输出最适合当前情况的操作决策,如调整速度、改变方向或启动其他设备功能。决策树的一个典型形式可以表示为:

$$a^* = \arg \max_{a \in A(s)} Q(s, a)$$

式中,  $s$  表示当前状态,  $a$  表示可能的行为,  $A(s)$  表示在状态  $s$  下可选的行为集合,  $Q(s, a)$  表示执行行为  $a$  时从状态  $s$  得到的预期回报。

通过这两个算法,决策控制模块不仅能够确保掘进机在复杂环境中的行动效率,还能大幅提升其对突发情况的应对能力,确保操作的安全性和稳定性。这种高度自动化和智能化的决策支持系统是实现煤矿自动化掘进的关键技术。

### 3.4 执行控制模块

执行控制模块是煤矿掘进自动化系统中实现具体操作的核心部分,其主要功能是将决策控制模块的输出转化为掘进机械的具体动作。这一模块通过高级控制算法确保掘进机

能精确执行路径规划和行为决策模型所确定的策略。典型的控制算法包括 PID (比例-积分-微分) 控制器,用于调节掘进机的速度、方向和其他操作参数,以适应复杂的地下环境和实现精确掘进<sup>[3]</sup>。

PID 控制器的基本公式为:

$$u(t) = K_p e(t) + K_i \int e(\tau) d\tau + K_d \frac{de(t)}{dt}$$

其中,  $u(t)$  是控制器输出,  $e(t)$  是目标值与实际值之间的偏差,  $K_p$ ,  $K_i$ , 和  $K_d$  分别是比例、积分和微分增益,调整这些参数可以控制系统响应的速度和稳定性。

执行控制模块还包括实时反馈机制,可以根据掘进过程中收集的数据(如位置、速度和环境感知数据)动态调整操作参数。这种反馈机制使得系统能够适应环境变化和潜在的风险,优化掘进机的性能并减少操作错误。此外,执行控制模块也配备了故障诊断和自我修复功能,能够在检测到设备异常时迅速采取措施,保证掘进作业的连续性和安全性。通过这些高级控制技术,执行控制模块不仅提升了煤矿掘进作业的精度和效率,还极大地增强了系统的自适应能力和可靠性,是实现煤矿自动化掘进技术的关键组成部分。

## 4 实验与结果分析

### 4.1 实验环境搭建

为了验证基于深度学习的煤矿掘进自动化技术的有效性,设计并搭建了专门的实验环境。实验环境模拟了真实的矿井条件,包括可变的岩石结构、不同的环境障碍和多样的地质特征。实验区域设有多种传感器,如高清摄像头、红外摄像头和激光扫描仪,这些传感器能够实时采集矿井内部的图像和空间数据。还引入了具有高计算能力的服务器,配备了 GPU 加速的深度学习平台,用于处理和分析收集的大量数据。为了确保数据的实时处理和模型的高效训练,在服务器上配置了专门的软件环境,包括 TensorFlow 和 PyTorch 等深度学习框架。这些工具支持复杂的算法实现,能进行高效的数据处理和模型优化<sup>[4]</sup>。实验环境中还包括模拟控制中心,该中心配备了高级监控系统,可以对掘进机的操作进行实时监控和调整。通过这一综合实验环境,可以在接近现场条件下测试和验证各种深度学习算法在煤矿掘进自动化中的应用效果。有助于评估技术的实际操作性能,能为进一步的技术迭代提供重要数据支持。这种实验环境的搭建,保证研究的高标准和科学性,为深入探索煤矿自动化技术提供了坚实的基础。

### 4.2 算法性能评估

为了全面评估所开发的深度学习算法在煤矿掘进自动化中的性能,采用了多个量化指标来度量算法的效率和准确性。使用准确率来评价模型在识别矿井环境特征(如岩层类型、障碍物等)上的准确性。召回率和精确率也被用来评估模型在不同操作条件下的响应能力,这对于安全关键应用尤

为重要。为了测试算法在实际矿井条件下的鲁棒性，还对比了模型在标准测试集和实际采集的矿井数据上的表现差异。采用了混淆矩阵（Confusion Matrix）来详细分析模型的分性能，从而识别模型在某些特定类别上可能存在的弱点。为了评估算法的实时处理能力，系统延迟被作为关键性能指标之一，包括从数据采集、处理到最终决策输出的整个时间周期。为了验证模型的可靠性和稳定性，进行了长时间的连续运行测试，记录并分析了模型在持续运行过程中的性能变化。通过这些综合的评估方法，不仅能够验证算法在理论上的优势，还能实际观察到其在煤矿自动化掘进过程中的表现，保证所开发技术的实际应用价值和操作安全。这种严谨的评估流程是确保技术在实际部署前达到预期效果的关键步骤。

### 4.3 系统集成测试

该测试确保各个独立开发的模块（如环境感知模块、决策控制模块和执行控制模块）能够协同工作，实现高效且稳定的自动掘进。构建的模拟矿井环境包括具有各种地质特征的模拟场景，以及可变条件，如湿度、温度和瓦斯浓度等，这些都是影响掘进机性能的重要因素。进行模块间接口测试保证各个模块的数据输入输出能够无缝对接，无数据丢失或错误解析的情况。对整体系统的数据处理和响应时间进行了压力测试，评估在数据量剧增时系统的稳定性和处理能力。特别关注系统的故障恢复能力，通过模拟各种潜在的故障情况（如传感器失效、数据传输中断等），检验系统的自我诊断和恢复机制是否能够迅速有效地恢复正常运行。在实际掘进操作的模拟测试中，细致地观察了系统在执行掘进任务时的表现，包括路径规划的准确性、执行模块的操作精度和决策模块的响应速度。为了全面评估系统性能，记录了掘进机在不同岩石类型和复杂地形中的掘进效率，以及系统在遇到意外情况时的处理策略。通过长时间的持续运行测试，进一步验证了系统的耐用性和长期稳定性。系统集成测试涉及技术层面的评估，包括操作员与系统的交互测试。这是为了确保系统的用户界面是直观易用的，操作员可以轻松掌握系统操作，快速做出反应。通过与矿工和工程师的协作，收集了实际操作中的反馈，优化系统的功能布局和操作逻辑。

### 4.4 结果分析

结果分析侧重于评估深度学习算法的效率、系统模块的协同工作能力以及最终的掘进效果。对于深度学习算法，通过比较实验前后的性能指标，如识别准确率、响应时间和处理速度，明确了算法优化的具体成效。算法在处理复杂图像和数据时显示出较高的准确性，尤其是在岩层识别和障碍物检测方面。分析算法在不同类型的岩石环境下的表现，验证了其在多样化条件下的适应性和稳定性。详细记录每个模块的操作数据和系统整体的执行日志，评估模块间的数据传输效率和处理延迟。特别是在高压和复杂环境下，系统展现出了良好的耐压性和错误处理能力，决策控制模块与执行控制模块之间的快速反馈机制有效地提升了操作的精准度和效率。系统的掘进效果分析涵盖了掘进速度、机器运行稳定性及安全性能等方面。掘进速度的提升显示出系统优化配置的成效，而机器的稳定运行则反映了设计的可靠性。安全性分析则通过模拟紧急情况，测试了系统的紧急响应机制，包括自动停机、避障和警报系统，这些都是保证矿工安全的重要功能。利用统计方法对结果进行深入分析，包括方差分析和回归分析，识别哪些因素对系统性能有显著影响。通过这些统计分析能更精确地调整系统参数，达到更高的性能标准。

## 5 结语

论文通过构建并验证基于深度学习的煤矿掘进自动化系统，证明了其在提高矿井作业效率与安全性方面的有效性。未来，进一步优化算法与增强系统稳定性将是关键，实现更广泛的应用与技术革新。

### 参考文献：

- [1] 李欢.基于深度学习的煤矿井下SLAM闭环检测算法研究[D].西安:西安科技大学,2022.
- [2] 马立森.基于深度学习的巷道顶板托盘识别方法研究[D].北京:煤炭科学研究总院,2024.
- [3] 高旭.基于深度学习的围岩钻孔裂隙识别技术研究及应用[D].徐州:中国矿业大学,2021.
- [4] 周震.基于深度学习的综采三机协同规划技术研究[D].徐州:中国矿业大学,2024.