



无监督学习型凿岩钻臂逆运动学求解方法

吴江 许皓渊 闫昊琪 熊锋 曹星宇 高路路 段京良 马飞

Inverse kinematics solution of an unsupervised learning drilling boom

WU Jiang, XU Haoyuan, YAN Haoqi, XIONG Feng, CAO Xingyu, GAO Lulu, DUAN Jingliang, MA Fei

引用本文:

吴江, 许皓渊, 闫昊琪, 熊锋, 曹星宇, 高路路, 段京良, 马飞. 无监督学习型凿岩钻臂逆运动学求解方法[J]. *北科大: 工程科学学报*, 2024, 46(8): 1479–1488. doi: 10.13374/j.issn2095–9389.2024.01.13.002

WU Jiang, XU Haoyuan, YAN Haoqi, XIONG Feng, CAO Xingyu, GAO Lulu, DUAN Jingliang, MA Fei. Inverse kinematics solution of an unsupervised learning drilling boom[J]. *Chinese Journal of Engineering*, 2024, 46(8): 1479–1488. doi: 10.13374/j.issn2095–9389.2024.01.13.002

在线阅读 View online: <https://doi.org/10.13374/j.issn2095–9389.2024.01.13.002>

您可能感兴趣的其他文章

Articles you may be interested in

基于脑电多视图混合神经网络的时空半监督睡眠分期

Multi-view hybrid neural network for spatiotemporal semi-supervised sleep staging

工程科学学报. 2023, 45(5): 797 <https://doi.org/10.13374/j.issn2095–9389.2022.03.22.005>

基于参数惩罚和经验回放的材料吸声系数回归增量学习

Incremental learning of material absorption coefficient regression based on parameter penalty and experience replay

工程科学学报. 2023, 45(7): 1225 <https://doi.org/10.13374/j.issn2095–9389.2022.05.03.006>

神经网络在无人驾驶车辆运动控制中的应用综述

Overview of the application of neural networks in the motion control of unmanned vehicles

工程科学学报. 2022, 44(2): 235 <https://doi.org/10.13374/j.issn2095–9389.2021.04.23.001>

基于监督学习的前列腺MR/TRUS图像分割和配准方法

Prostate MR/TRUS image segmentation and registration methods based on supervised learning

工程科学学报. 2020, 42(10): 1362 <https://doi.org/10.13374/j.issn2095–9389.2019.10.10.006>

软体机械臂的建模与神经网络控制

Modeling and neural network control of a soft manipulator

工程科学学报. 2023, 45(3): 454 <https://doi.org/10.13374/j.issn2095–9389.2021.12.17.003>

基于改进降噪自编码器半监督学习模型的热轧带钢水梁印识别算法

Recognition algorithm of hot-rolled strip steel water beam mark based on a semi-supervised learning model of an improved denoising autoencoder

工程科学学报. 2022, 44(8): 1338 <https://doi.org/10.13374/j.issn2095–9389.2021.01.04.004>

无监督学习型凿岩钻臂逆运动学求解方法

吴江, 许皓渊, 闫昊琪, 熊 锋, 曹星宇, 高路路, 段京良, 马 飞[✉]

北京科技大学机械工程学院, 北京 100083

✉通信作者, E-mail: yeke@ustb.edu.cn

摘 要 凿岩台车钻臂智能寻孔控制对提升凿岩钻孔作业精度和效率具有重要意义, 逆运动学求解是实现钻臂精确快速寻孔控制的核心. 现有解析法或数值法无法满足复杂钻臂逆运动学求解精度或时间效率要求, 而传统神经网络方法依赖于标签数据, 求解结果的可靠性较低. 针对上述问题, 本文提出一种考虑安全约束的无监督学习型神经网络逆运动学求解方法. 区别于传统解法, 该方法不依赖标签数据, 直接将期望钻臂末端位姿作为网络输入, 以实际末端位姿与期望末端位姿的差异作为优化目标, 通过梯度下降驱动网络更新. 同时, 为确保关节位置的安全性, 本文构造了安全碰撞惩罚, 将罚项引入到求解目标函数中, 促使网络输出的关节量满足特定环境的约束条件. 上述的研究方法不仅提高了逆运动学求解的精度, 而且显著降低了逆运动学解的碰撞率. 实验结果表明, 使用无监督学习型神经网络逆运动学求解方法所求得寻孔误差均值在 5 ~ 7 mm 之间, 相较于监督学习型方法, 逆运动学求解精度提升约 70.72%; 引入约束后, 该方法在不损失求解精度的前提下, 逆运动学解的碰撞率降低了 90.28%.

关键词 凿岩钻臂; 逆运动学求解; 无监督学习; 神经网络; 碰撞惩罚

分类号 TG142.71

Inverse kinematics solution of an unsupervised learning drilling boom

WU Jiang, XU Haoyuan, YAN Haoqi, XIONG Feng, CAO Xingyu, GAO Lulu, DUAN Jingliang, MA Fei[✉]

School of Mechanical Engineering, University of Science and Technology Beijing, Beijing 100083, China

✉Corresponding author, E-mail: yeke@ustb.edu.cn

ABSTRACT Intelligent control of the hole-seeking process of a rock drilling rig boom is crucial for enhancing the accuracy and efficiency of rock drilling operations. The inverse kinematics solution (IKS) is the core of achieving precise and rapid hole-seeking control of the boom. However, existing analytical and numerical techniques are inadequate in fulfilling the accuracy and time efficiency requirements for IKS in complex drilling boom scenarios. Conventional neural network (NN) approaches heavily depend on labeled data comprising target borehole sets derived from the activities of each joint and forward kinematics. The distribution of drill endpoints generated by this data cannot cover the entire workspace, resulting in the low reliability of the solution. To overcome these challenges, this study introduces an unsupervised learning-based NN method for IKS emphasizing safety constraints. This innovative method differs from traditional approaches in that it does not depend on labeled data. Instead, it utilizes the desired end position of the drilling boom as the network input. The network generates an eight-dimensional joint vector, and the actual drill end pose is derived through forward kinematics calculations on this vector. Then, the difference between the actual and desired drill end poses is used as the optimization objective, driving the network updates through gradient descent. The advantage of this method lies in eliminating the need for complex joint label data required in supervised learning IKS and using the differences in drill end poses directly as optimization objectives, which helps improve the accuracy of IKS. Meanwhile, a critical innovation of this study is integrating a safety collision penalty into the

收稿日期: 2024-01-13

基金项目: 国家重点研发计划资助项目 (2021YFB3401502); 国家自然科学基金资助项目 (52202487); 中央高校基本科研业务费专项资金资助项目 (FRF-OT-23-02)

objective function of the solution, ensuring that the network's output for joint positions adheres to specific environmental limitations. If the actual distance falls below the safety threshold, penalty terms are incorporated into the objective function, allowing for the adjustment of weights to maintain a balance between the precision demands of hole drilling and the design requirements of the safety constraints. This method improves the accuracy of IKS and significantly reduces its collision rate. Experimental results reveal that the mean hole-seeking error obtained using this unsupervised learning-based method achieves a mean hole-seeking error of 5–7 mm in IKS, a significant improvement of approximately 70.72% over supervised learning methods. Moreover, introducing safety constraints has successfully reduced the collision rate in IKS solutions by 90.28% without sacrificing the accuracy of the solutions.

KEY WORDS drilling boom; inverse kinematics solution; unsupervised learning; neural network; collision penalty

凿岩台车是地下矿山和隧道钻爆法施工的核心装备,其主要功能是通过钻臂定位凿岩工具,进行钻孔作业^[1].钻孔作业前,控制系统通过调整钻臂各关节的位置或角度,使其末端执行器(钻头)与巷道或隧道掌子面上预设炮孔位姿对齐,即寻孔控制过程.钻臂精准快速的寻孔控制对提升凿岩钻孔作业精度和效率具有重要意义^[2].

逆运动学求解(IKS)是实现钻臂精确快速寻孔控制的核心.该求解任务旨在根据目标位姿信息计算各关节的角度和位置,为钻臂液压执行器提供控制参考目标^[3].由于作业面钻孔作业的复杂需求,钻臂必须具有多自由度特性(通常具有8个以上自由度),其逆运动学求解较为繁琐^[4].目前,机械臂运动学求逆的经典方法包括解析法、几何法、数值法和启发式算法.解析法^[5]适用于关节之间满足特定结构的机械臂,该方法的求解效率高,但通用性差.几何法^[6]通过分析机械臂的几何结构,构建出逆运动学的几何方程并进行求解,该方法计算简单,可解释性好,但难以应用于复杂机构.数值法^[7]采用迭代计算的方式逐步逼近目标位置和姿态,该方法适用范围广,但求解效率相对较低.遗传算法^[8]、粒子群优化算法^[9]和差分进化算法^[10]等组成的启发式算法,依赖于经验、启发式信息,通过模拟一些生物或物理现象来引导搜索最优解,该方法构造简单、灵活高效,但性能高度依赖参数设置,且较难找到全局最优解.考虑到上述方法单一使用时存在的局限性,在实际计算过程中往往将多种方法进行结合.张明松等^[11]将解析法与几何法结合应用于多自由度机械臂,实现了毫米级的关节转角误差控制;杨惠珍等^[12]将几何法融入遗传算法中,解决了逆运动学求解结果的多值问题.尽管多种方法结合可以提高性能,但也显著增加计算的复杂性,因此现阶段亟需一类快速且精准的逆运动学求解方法^[13].

除上述4种经典方法外,神经网络因其强大的近似拟合能力,能够高效处理复杂的非线性问题,

在逆运动学求解领域逐渐受到重视^[14-15].现有的神经网络逆运动学研究采用监督学习框架,通过使用机械臂末端位姿(输入)和其对应的各关节量(标签或输出)组成的数据进行网络训练^[16].Pang等^[17]为解决高自由度机械臂中,反向传播(BP)神经网络在接近精确逆解时收敛速度较慢的问题,提出了将梯度下降与高斯牛顿结合的方法,通过自适应阻尼因子,改变网络权重更新公式,提高了求解迭代效率.崔孟豪等^[18]利用径向基函数(RBF)神经网络建立台车钻臂末端位姿到关节量(关节位姿)的映射,通过最小化网络输出与样本真实值的误差进行网络参数训练,最终得到的关节预测相对误差不超过0.62%.Hsieh等^[19]提出一种依托深度卷积生成对抗运动学网络(DCGAKN)的进化训练算法,该算法借助传感器识别环境图像,通过卷积层提取图像的特征,引入生成对抗网络产生预测关节位姿信息,学习多模态输入与关节输出之间的映射关系.尽管监督学习型神经网络方法在提高求解效率和结果精度方面取得了显著进展,但该类方法依赖标签数据集支撑,存在网络输入信息与实际作业信息不匹配的问题,导致求解结果可靠性较低.

此外,上述方法均在开放自由环境下开展研究,未能考虑工程作业中机械臂操作的安全性,其在实际使用中严重受限,甚至存在较高的碰撞风险.针对该问题,Sridhar等^[20]提出一种两阶段处理手段:先采用解析法计算逆运动学的解,然后对生成的关节进行碰撞检测,筛选存在碰撞风险的关节坐标;Kang等^[21]在神经网络结构中引入专门的约束层来对输出关节进行坐标调整,限制关节产生的范围,以避免关节碰撞.这些方法能一定程度提高求解的安全性,但其未充分考虑多自由度机械臂自身结构之间的自干涉,且存在多项约束作用时求精精度大幅降低的问题,严重限制了该方法在复杂作业环境中的适用性.

针对上述问题,本文提出一种考虑安全约束

的无监督学习型神经网络逆运动学求解方法. 该方法不依赖标签数据, 且能更好地保证逆运动学解的安全性. 具体创新点如下:

(1) 针对标签数据中钻头末端位姿分布与实际作业目标孔位分布不匹配的问题, 提出一种无监督学习的神经网络型逆运动学求解方法. 该方法将期望钻臂末端位姿作为网络输入, 以实际末端位姿与期望末端位姿的差异作为优化目标, 通过梯度下降驱动网络更新. 该方法不依赖标签数据, 同时可显著提高逆运动学求解的精度.

(2) 构造安全碰撞惩罚, 通过将罚项引入到逆运动学求解目标函数中, 促使网络输出的关节量满足特定环境的约束条件. 实验结果表明, 相比于无约束神经网络求逆法, 所提出算法在不损失求解精度的前提下, 逆运动学解的碰撞率降低了 90.28%.

1 八自由度钻臂逆运动学求解方法

1.1 钻臂寻孔任务

台车钻臂在寻孔过程中需要确保末端执行器的位置与隧道掌子面上实际炮孔的位置相匹配, 这对完成寻孔任务至关重要^[22]. 如图 1 所示, 当钻臂末端与目标炮孔位置对齐, 且钻臂与孔位方向一致时, 即满足高精度寻孔定位要求.




图 1 逆运动学求解任务
Fig.1 Inverse kinematics solution task

通过减小钻臂末端与目标炮孔之间的位置偏差和角度偏差实现精准寻孔是目前的主流思路, 但在实际工况中, 这两种偏差总是不可避免的^[23]. 即使钻孔初始时角度误差很小, 当在较长的巷道

内进行钻孔, 也会产生累积误差, 导致钻孔终点存在较大的位置间隙. 为解决这一问题, 本文将减小钻臂与目标炮孔的起始点和预瞄终点的位置综合偏差作为寻孔的主要目标, 如图 2 所示.




图 2 预瞄点展示
Fig.2 Preview representation

1.2 钻臂正运动学分析

本文考虑图 3(a) 所示凿岩台车的八自由度钻臂, 其中关节 3 和 8 为移动关节, 其余关节为旋转关节. 钻臂正、逆运动学分析是寻孔作业的理论基础, 其中正运动学是根据钻臂各关节量计算末端执行器(即钻头)位姿的过程. 为描述钻臂的正、逆运动学, 本文采用了 D-H 参数法^[24], 图 3(b) 展示了钻臂各关节与 D-H 坐标系之间的对应关系.

D-H 法借助齐次变换矩阵表示相邻两个关节之间的平移和旋转关系^[25], 其表达式如下:

$${}^{i-1}_i T = \text{Rot}(X, \alpha_{i-1}) \times \text{Trans}(X, a_{i-1}) \times \text{Rot}(Z, \theta_i) \times \text{Trans}(Z, d_i) = \begin{bmatrix} \cos \theta_i & -\sin \theta_i & 0 & a_{i-1} \\ \sin \theta_i \cos \alpha_{i-1} & \cos \theta_i \cos \alpha_{i-1} & -\sin \alpha_{i-1} & -d_i \sin \alpha_{i-1} \\ \sin \theta_i \sin \alpha_{i-1} & \cos \theta_i \sin \alpha_{i-1} & \cos \alpha_{i-1} & d_i \cos \alpha_{i-1} \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (1)$$

式中: ${}^{i-1}_i T$ 表示关节 i 相对关节 $i-1$ 的变换矩阵, θ_i 表示相邻连杆之间的夹角, d_i 为相邻连杆间公垂线的距离, X 为各关节运动方向, Z 为各关节垂直工作平面的运动方向, α_{i-1} 为 Z_{i-1} 与 Z_i 之间的扭角, a_{i-1} 为相邻连杆轴线公垂线的距离.

根据变换矩阵的特性, 可求得钻臂末端执行器相对基坐标系的转换方式:

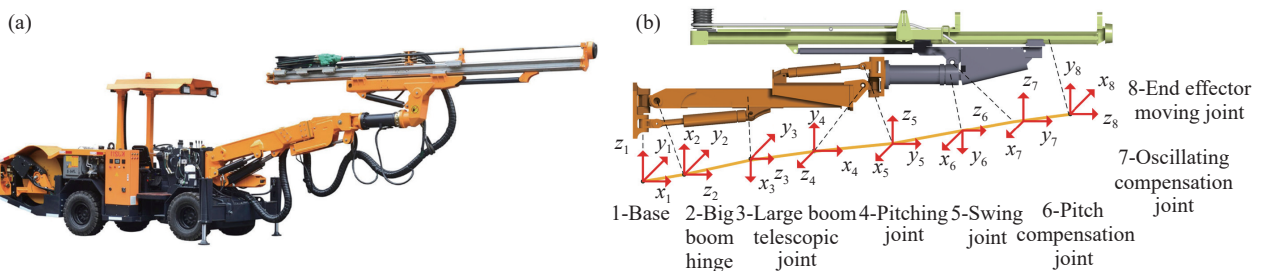


图 3 台车钻臂结构图. (a) 凿岩台车示意图; (b) 八自由度钻臂坐标系简图
Fig.3 Schematic of the rock drilling rig boom: (a) rock drilling rig; (b) eight-degree-of-freedom drilling boom coordinate system

$${}^0T = {}^0T_1 {}^1T_2 {}^2T_3 {}^3T_4 {}^4T_5 {}^5T_6 {}^6T_7 {}^7T_8 T = \begin{bmatrix} n_x & o_x & a_x & p_x \\ n_y & o_y & a_y & p_y \\ n_z & o_z & a_z & p_z \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (2)$$

式中: $[n, o, a]$ 为钻臂末端相对基坐标系的旋转矩阵, 可用于获得钻头相对于基坐标系的方向向量; $[p_x, p_y, p_z]^T$ 为钻头相对基坐标系的位置。

2 考虑安全约束的无监督学习型神经网络逆运动学求解方法

在已知钻臂末端的期望孔位和姿态的情况下, 计算其对应的各个关节量的过程即为凿岩台车钻臂逆运动学求解。然而, 由于八自由度钻臂结构的复杂性, 现有解析法难以适用, 数值法无法同时保证求解的精度和效率。为解决上述问题, 本章介绍基于神经网络的逆运动学求解方法。

2.1 监督学习型神经网络逆运动学求解方法

现有神经网络逆运动学求解方法通常以监督学习为核心框架, 通过对标签数据集的模仿或拟合学习得到钻头位姿到关节量的映射。标签数据集由各关节量(标签)和正运动学得到的目标炮孔的起始点及预瞄终点(输入)组成。具体训练过程如图 4 所示, 将标签数据集中目标炮孔的起始点和预瞄终点构造的空间向量作为六维末端位姿的网络输入, 经过网络输出得到八维关节向量作为逆运动学解, 通过最小化逆运动学解与标签数据集中期望关节量的差值进行网络优化。




图 4 监督学习型神经网络逆运动学求解方法

Fig.4 IKS method of the neural network for the supervised learning framework

图网络输入中, 目标炮孔的起始点坐标即期望钻头位置坐标 (p_x, p_y, p_z) 可通过式(2)直接获得, 预瞄终点坐标 (p'_x, p'_y, p'_z) 的计算公式如下:

$$\begin{bmatrix} p'_x \\ p'_y \\ p'_z \end{bmatrix} = D \cdot \begin{bmatrix} n_x & o_x & a_x \\ n_y & o_y & a_y \\ n_z & o_z & a_z \end{bmatrix} \cdot \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} + \begin{bmatrix} p_x \\ p_y \\ p_z \end{bmatrix} \quad (3)$$

式中: D 为巷道的深度, (p'_x, p'_y, p'_z) 是由钻头相对于

基坐标系在Z轴的方向向量所确定。

最终, 网络输入六维向量 \mathbf{P}_{exp} 表示如下:

$$\mathbf{P}_{\text{exp}} = [p_x, p_y, p_z, p'_x, p'_y, p'_z]^T \quad (4)$$

式中: (p'_x, p'_y, p'_z) 代表预瞄点坐标, (p_x, p_y, p_z) 代表炮孔起始点坐标。

根据图求解方法, 本文将逆运动学网络求解过程表示为:

$$\phi_{\text{act}} = f(\mathbf{P}_{\text{exp}}; \omega) \quad (5)$$

式中: f 为求逆网络; ω 为待优化网络参数; $\phi_{\text{act}} = [\theta_1, \theta_2, d_3, \theta_4, \theta_5, \theta_6, \theta_7, d_8]^T$ 为实际输出的关节量。

使用标签数据集 Ω_{sup} 中期望关节量 ϕ_{exp} 与逆运动学求解得到的实际输出 ϕ_{act} 构造优化目标函数 l_{joint} , 计算公式如下:

$$l_{\text{joint}} = E_{\mathbf{P}_{\text{exp}}, \phi_{\text{exp}} \sim \Omega_{\text{sup}}} \left[\|f(\mathbf{P}_{\text{exp}}; \omega) - \phi_{\text{exp}}\|^2 \right] \quad (6)$$

2.2 无监督学习型神经网络逆运动学求解方法

在上述监督学习型神经网络逆运动学求解方法中, 标签数据集 Ω_{sup} 是由各关节活动量和正运动学得到的目标炮孔的起始点及预瞄终点组成, 炮孔起始点的空间分布以及YOZ平面投影如图 5(a) 所示^[26]。然而在实际工作中, 随机生成的关节量通常无法控制钻臂末端位姿点位于掌子面, 且生成的末端点分布无法涵盖整个工作空间。以上原因造成巷道工作截面通常与标签数据集的空间截面不匹配, 进而影响逆运动学的求解精度和实用价值。为提高钻臂的工作效率和方法的通用性, 本研究根据实际作业需求构造了仅由期望孔位组成的非标签数据集(不含对应关节量)。由于实际掌子面上的目标炮孔较少, 无法直接用于网络训练, 因此本文根据掌子面轮廓和钻孔方向对炮孔数据进行了扩展。其炮孔起始点的空间分布以及YOZ平面投影如图 5(b) 所示。结合式(3)中预瞄终点的计算公式, 可以确定由目标炮孔起始点和预瞄终点组成的六维向量, 最终形成新的数据集 Ω_{unsup} 。

基于新的数据集, 进一步提出一种无监督学习型神经网络逆运动学求解方法。如图 6 所示, 该方法以目标炮孔的起始点和预瞄终点构造的空间向量 \mathbf{P} 作为期望位姿输入, 经网络输出得到八维关节向量, 同时引入正运动学运算框架求得实际钻臂末端位姿输出, 通过最小化期望位姿输入与实际位姿输出的差值更新神经网络参数。该方法的优势在于省去监督学习求解过程中所需的复杂关节量标签数据, 并将钻臂末端位姿差异直接作为优化目标, 有助于提高逆运动学求解精度。

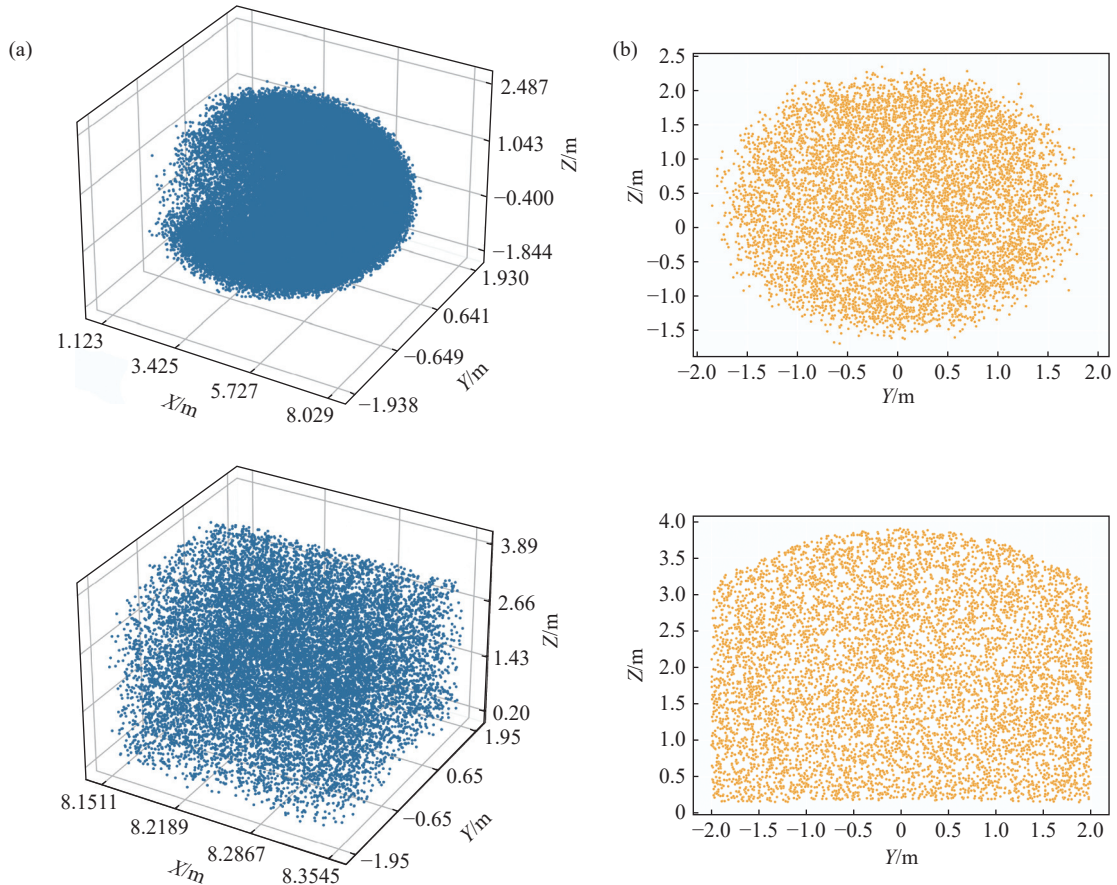


图5 神经网络结构输入。(a) 监督学习数据集 Ω_{sup} ; (b) 无监督学习数据集 Ω_{unsup}

Fig.5 Network structure input: (a) supervised learning dataset Ω_{sup} ; (b) unsupervised learning dataset Ω_{unsup}




图6 无监督学习型神经网络逆运动学求解方法

Fig.6 IKS method of the neural network for the unsupervised learning framework

该方法的网络优化目标表达式如下:

$$l_{pos} = E_{P \sim \Omega_{unsup}} \{ \|F[P; \omega] - P\|^2 \} \quad (7)$$

式中: E 为数学期望, F 为正运动学计算公式; f 为求逆网络; ω 为待优化网络参数; P 为来自数据集 Ω_{unsup} 中的六维输入向量. 基于该损失函数, 采用梯度下降对网络参数进行更新:

$$\omega' = \omega - \eta_0 \left(1 - \frac{t}{T} \right) \frac{dl_{pos}(\omega)}{d\omega} \quad (8)$$

式中: ω' 代表更新后的结构参数; 采用线性退火动态更新学习率, η_0 为初始学习率, 控制更新步长; T 为总的训练时长; t 为当前时刻; $l_{pos}(\omega)$ 为网络优

化目标. 待网络收敛后, 根据当前时刻孔位信息, 输出实际关节量 $\phi_{act} = f(P; \omega)$ 即可实现在线应用.

2.3 考虑安全约束的无监督学习型神经网络逆运动学求解

在确保寻孔精度的同时, 保障钻臂内部各连杆之间以及各连杆与巷道环境之间的安全距离至关重要. 为实现该目标, 本文采用一种简化的包围盒模型^[27]代替钻臂模型, 并对包围盒模型进行碰撞检测, 以评估生成关节位置的安全性.

在作业过程中, 钻臂不断调整空间姿态, 使其末端钻头与目标炮孔对齐, 这可能导致推进梁的反向初始点与大臂之间发生接触. 鉴于1、2关节的长度相对较短(图7), 本文将前三个关节视为一个整体, 并使用圆柱体进行包围盒建模. 通过检测两个圆柱包围盒的碰撞情况, 判断钻臂是否发生自身碰撞. 另一方面, 通过比较生成的各关节量在YOZ平面的投影与巷道两侧的距离, 检验是否发生环境碰撞. 针对碰撞现象, 本文设定了钻臂各部分相对自身其他部分以及相对环境之间的安全距离, 将不等式约束引入到目标函数中. 在保证求解精度的前提下, 计算得到符合约束条件的关节量,




图 7 包络面位置关系示意图

Fig.7 Envelope surface position relation diagram

各关节包围盒位置如图所示。

通过式(1)中齐次坐标变换的方法, 结合 D-H 参数, 可求得各连杆处的齐次变换矩阵为: 1_0T , 2_1T , 3_2T , 4_3T , 5_4T , 6_5T , 7_6T , 8_7T , 那么各关节相对基坐标系的位置 $A \sim H$ 可由上述变换矩阵得到. 将 A 的空间坐标表示为 (x_A, y_A, z_A) , 并采用类似的方式表示其他点的空间坐标. 据此, 图 7 中的向量 L_1 可表示为:

$$L_1 = C - A = [x_C - x_A, y_C - y_A, z_C - z_A]^T \quad (9)$$

向量 L_2 表示为:

$$L_2 = H - H_0 = \begin{bmatrix} x_H \\ y_H \\ z_H \end{bmatrix} - \left(\begin{bmatrix} x_H \\ y_H \\ z_H \end{bmatrix} + L \cdot \begin{bmatrix} n_x & o_x & a_x \\ n_y & o_y & a_y \\ n_z & o_z & a_z \end{bmatrix} \cdot \begin{bmatrix} 0 \\ 0 \\ -1 \end{bmatrix} \right) \quad (10)$$

式中: L 为推进梁的长度, 借助钻头相对基坐标系在 z 轴的反方向向量可求得推进梁的初始位置 H_0 .

向量 L_1 、 L_2 上的动点 M 、 N 在基坐标系下可表示为:

$$\begin{cases} M = H_0 + u(H - H_0) \\ N = A + v(C - A) \end{cases} \quad (11)$$

式中: u 是动点 M 在向量 L_2 上与位置 H_0 相对位置的参数; v 是动点 N 在向量 L_1 上与位置 A 相对位置的参数.

通过距离公式即可求出 M 、 N 两点之间的距离:

$$d_{MN}(u, v) = \sqrt{(\Delta x_{uv})^2 + (\Delta y_{uv})^2 + (\Delta z_{uv})^2} \quad (12)$$

式中: Δx_{uv} 为 M 、 N 两点 x 坐标的差值, 同理 Δy_{uv} 、

Δz_{uv} 为 y 、 z 坐标的差值.

令 $d_{MN}(u, v)$ 分别对 u 、 v 求偏导, 并让偏导 $\frac{\partial d}{\partial u}$ 、 $\frac{\partial d}{\partial v}$ 等于 0, 联立方程组求解出此时两连杆之间最小距离对应的 u 、 v . 若 $u \notin [0, 1]$ 或 $v \notin [0, 1]$, 表明两包围盒之间不存在最小距离, 不发生碰撞; 若 $u, v \in [0, 1]$, 则认为两待测物体可能碰撞, 再将 u 、 v 代入式(12)中, 求解出两点距离 d_{MN} .

当实际距离 d_{MN} 大于半径包络距离与安全阈值 d_{safety}^{self} 之和时, 视为自身发生不干涉, 其表达式如下:

$$d_{MN} \geq r_1 + r_2 + d_{safety}^{self} \quad (13)$$

式中: r_1 和 r_2 为两圆柱包络面的半径. 若违反上述条件, 则需要构建外部约束, 本文借助 ReLU 函数来设计惩罚项, 得到关节自身干涉的惩罚函数 l_{self} :

$$l_{self} = E \left[\text{ReLU} \left(d_{safety}^{self} + r_1 + r_2 - d_{MN} \right) \right] \quad (14)$$

在训练过程中, 若实际距离小于安全距离, 利用该式对实际距离进行惩罚, 使其有增大的趋势, 从而降低碰撞概率.

如图 8 所示, 若各个关节的 y 坐标超出左右墙面安全距离 d_{safety}^{wall} , 或 z 坐标大于拱顶安全距离 d_{safety}^{arch} , 或 z 坐标小于地面安全距离 d_{safety}^{ground} , 均可视为与环境发生碰撞, 此时各部分惩罚函数 l_{wall} 、 l_{ground} 、 l_{arch} 的构建如下:

$$\begin{cases} l_{wall} = E \left[\text{ReLU} \left(|y_i| - d_{safety}^{wall} \right) \right] \\ l_{ground} = E \left[\text{ReLU} \left(d_{safety}^{ground} - z_i \right) \right] \\ l_{arch} = E \left[\text{ReLU} \left(z_i - d_{safety}^{arch} \right) \right] \end{cases} \quad (15)$$

式中: y_i 、 z_i 为各关节在 D-H 坐标系下的 y 、 z 坐标, 通过这种构造形式, 将发生碰撞部分进行惩罚.

在最终训练过程中, 将 l_{pos} 作为优化目标函数, l_{self} 、 l_{wall} 、 l_{ground} 和 l_{arch} 作为惩罚项, 形成总的求解目标 \mathcal{L} :




图 8 巷道截面投影

Fig.8 Cross-section projection of the tunnel

$$\mathcal{L} = \lambda \cdot l_{\text{pos}} + \mu \cdot (l_{\text{self}} + l_{\text{wall}} + l_{\text{ground}} + l_{\text{arch}}) \quad (16)$$

式中: λ 、 μ 分别代表不同的权重, 用于平衡钻孔的精度需求与安全约束的设计需求. 最终得到考虑安全约束的无监督学习型神经网络逆运动学求解算法, 其伪代码如表 1 所示.

表 1 考虑安全约束的无监督学习型神经网络逆运动学求解

Table 1 IKS of an unsupervised learning drilling boom with the constraint update pseudo-code

Algorithm: IKS of an unsupervised learning drilling boom with constraints

Define the neural network model, forward kinematics equation

Initialize the policy network parameters ω and learning rate η_0

Input the expected drill end set Ω_{unsup}

Repeat

Select the batch size group data at random from $P \sim \Omega_{\text{unsup}}$

The objective function of precision optimization is constructed by equation (7)

The constraint penalty function is constructed by equations (14) and (15)

The overall optimization objective function is constructed by equation (16)

Use equation (8) to update the neural network $f(P; \omega)$

until convergence

3 试验验证

考虑到任务的复杂性, 本研究采用多层前馈神经网络作为基础模型, 网络架构涵盖 4 个隐含层, 每层配置 512 个神经元, 并选用 GeLU 作为激活函数^[28]. 网络的输出为八维向量, 对应八个关节量的逆解. 从图 5 的数据集中, 选择 10000 组期望孔位信息作为训练集, 1000 组作为测试集, 并使用式 (7) 中提到的当前起始点和预瞄终点构造空间向量来量化求解误差. 基于相同的网络结构, 监督学习型神经网络逆运动学方法 (简称为 SIKM) 和

考虑安全约束的无监督学习型神经网络逆运动学方法 (简称为 CUIKM) 的训练结果如图 9 所示, 两种方法的起始点误差、预瞄点误差曲线在迭代过程中均先减小后趋于稳定. 结果表明, 本文所提出的无监督学习方法 (平均寻孔误差 $\varepsilon_{\text{CUIKM}}=0.65$ cm) 相较于监督学习方法 (平均寻孔误差 $\varepsilon_{\text{SIKM}}=2.22$ cm) 极大程度提高了逆运动学求解精度 (提升了 70.72%), 其寻孔误差可控制在 1 cm 以下, 表 2 列举了 CUIKM 的部分逆运动学求解结果, 其中起始点和预瞄点的寻孔误差是通过期望位姿与实际位姿之间的坐标差计算得出, 均为毫米级别.

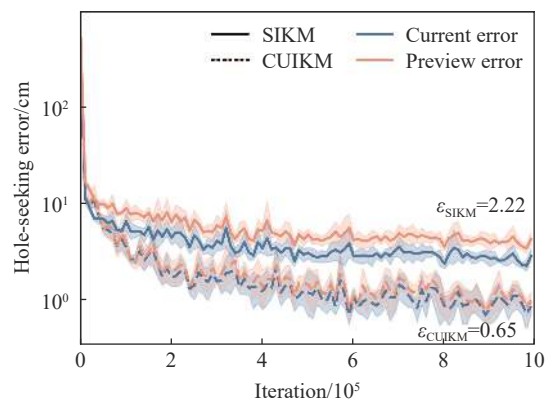


图 9 起始点和预瞄终点的寻孔误差曲线

Fig.9 Current and preview error curves

此外, 基于同一测试集进行逆运动学求解精度测试, 并将求得的起始点、预瞄点平均误差进行投影 (见图 10), 可以观察到 CUIKM 在精度方面明显优于 SIKM. SIKM 误差大的原因主要有以下 3 个方面: (1) 其训练炮孔数据集的分布与真实巷道环境的分布存在差异, 导致其外围的误差较大; (2) 仅考虑起始点误差, 未考虑预瞄点误差, 由于钻孔距离较长, 较小的寻孔角度偏差会导致较大的预瞄误差; (3) 监督型学习方法存在数据混淆的

表 2 部分逆运动学求解结果

Table 2 Results of the partial IKS

Case	Data type	Data information
1	Desired drill end pose information/cm	[793.4398, 44.0928, 130.7683, 1117.0637, 108.5795, 133.7697]
	Network eight-dimensional joint output/[cm or (°)]	[-5.6367, 94.5682, 384.5086, 91.7801, 105.1901, 127.0768, 2.7014, 293.2353]
	Actual drill end pose information/cm	[793.0550, 44.2775, 130.8357, 1116.7893, 108.2098, 133.7959]
	Hole-seeking error (current–preview)/cm	(0.4320–0.4609)
2	Desired drill end pose information/cm	[707.1773, 26.7246, 164.3249, 1015.4975, 5.9536, 280.1145]
	Network eight-dimensional joint output/[cm or (°)]	[-0.9786, -86.6738, 345.3153, 71.4261, -86.3577, 81.5845, 5.3307, 267.6779]
	Actual drill end pose information/cm	[707.7624, 27.2083, 164.7482, 1014.9023, 5.5435, 280.5214]
	Hole-seeking error (current–preview)/cm	(0.8363–0.869)

问题,只适用于输入输出一一对应的任务,然而高自由钻臂往往存在同一个位姿对应多组关节逆解的情况,这会导致监督学习结果不佳,而无监督型学习方法不受此类问题影响。

为了全面对比不同方法之间的差异,本文引入已有文献中的数值法(NM)^[29]进行对比.由于所研究的钻臂有 8 个自由度,但可列出的等式仅有 6 个,为方便求出逆解,数值法为钻臂添加两组约束条件 $\theta_2 - \theta_4 = -180^\circ$ 、 $\theta_5 + \theta_1 = -90^\circ$,并采用牛顿迭代法,根据式(2)中正运动学的坐标转化方法先求解 θ_6 ,再左乘逆矩阵求解关节参数之间的关系.最后,结合约束条件、各关节活动范围以及运动的最短路径,求解出各关节变量的值。

神经网络法和数值法(NM)的比较结果,如图 11(a)所示.结果表明,CUIKM 相较于 SIKM 在平均精度上提升了 70.72%,两种方法均优于 NM.

这是因为 NM 存在多项关节之间的耦合约束,导致其求解精度降低;而神经网络法可以直接将给定的六维向量输入映射到八维关节输出.图 11(b)展示了这 3 种方法的计算时间对比,神经网络方法的求解速度是传统数值方法的 115.60 倍,具有更好的实时性。

安全性一直是实际作业过程中需要考虑的主要因素,在复杂钻臂的执行任务中显得尤为重要,本文将式(14)和式(15)中安全距离的阈值 d_{safety}^{self} 、 d_{safety}^{ground} 设置为 0.1 m, d_{safety}^{wall} 设置为 2.0 m, d_{safety}^{arch} 设置由拱顶最大轮廓拟合曲线决定.当生成关节不满足约束条件时,则受到惩罚,以鼓励生成关节保持较大的安全距离.在 2.3 节中介绍了本文的碰撞判断标准,通过比较生成关节各部分的距离与安全距离之间的大小来判断是否发生碰撞.在试验中,我们将权重 λ 默认设置为 1.当数值 μ 过大时,会导




图 10 寻孔测试精度投影分布. (a) 监督学习型求解方法; (b) 带约束的无监督学习型求解方法
Fig.10 Hole-seeking test accuracy projection distribution: (a) SIKM; (b) CUIKM

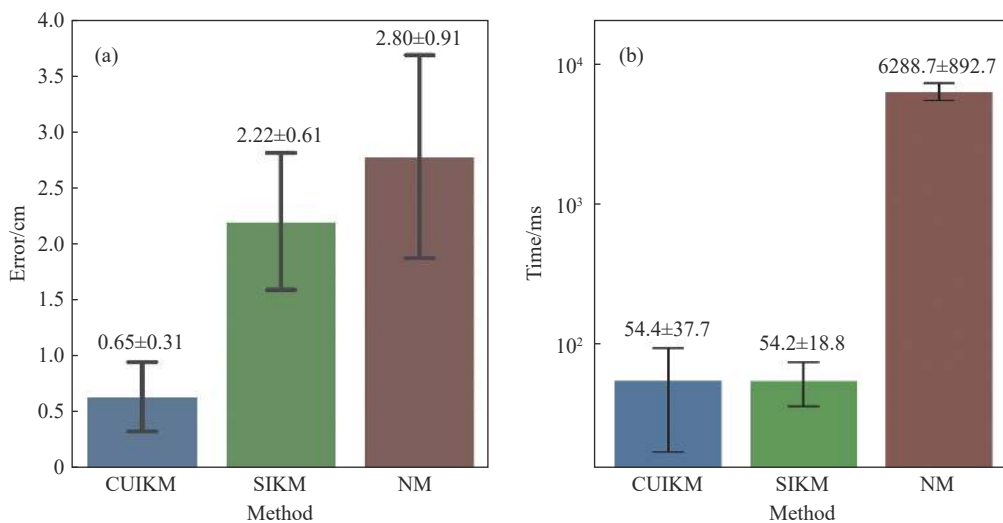


图 11 试验分析. (a) 测试精度对比图; (b) 逆运动学求解时间对比图

Fig.11 Experimental analysis: (a) comparison of testing accuracy; (b) comparison of IKS time

致求解精度降低, 而当 μ 数值过小时, 生成关节的碰撞率会增加。经过多次比较, 最终 λ 、 μ 分别设置为 1 和 10 来实现碰撞率与精度的最佳平衡。

本文对 CUIKM、不带约束的无监督学习方法 UIKM 和 SIKM 在同一测试集(1000 组炮孔信息)

的 5 组碰撞结果进行了统计, 具体情况请参见表 3。可以看出, 本文的 CUIKM(平均碰撞率为 0.62%)能够较好地避免生成关节在各个位置的碰撞, 保持较低的碰撞率, 相较于 SIKM(平均碰撞率为 6.38%), 碰撞率降低了 90.28%。

表 3 碰撞性能对比

Table 3 Comparison of collision performance

Test	CUIKM				UIKM				SIKM			
	Self	Wall	Ground	Arch	Self	Wall	Ground	Arch	Self	Wall	Ground	Arch
Group 1	8	0	1	0	184	39	25	24	50	3	4	4
Group 2	2	0	0	2	359	86	19	50	37	5	3	23
Group 3	3	0	1	0	418	48	66	78	20	1	11	55
Group 4	7	1	0	0	126	22	52	98	20	10	14	4
Group 5	3	0	0	3	658	3	43	13	30	3	18	7
Average collision rate	0.62%				48.21%				6.38%			

4 结论

(1) 本文提出了一种无监督学习型神经网络逆运动学求解方法, 该方法以目标炮孔的起始点和预瞄终点构造的空间向量作为期望位姿输入, 经网络输出得到八维关节向量, 同时对关节向量进行正运动学运算求得实际钻臂末端位姿输出, 通过最小化期望位姿输入与实际位姿输出的差值更新网络参数。训练测试的结果表明: 无监督型学习方法相较于监督型学习方法在逆运动学求解精度方面提升了 70.72%。

(2) 本文构造了一种考虑安全约束的神经网络求解方法, 通过将罚项引入到逆运动求解目标函数中, 促使网络输出的关节量满足特定环境的约束条件, 相比于无约束的监督学习求逆方法, 该方法在不损失求解精度的前提下, 逆运动学解的碰撞率降低了 90.28%。

参 考 文 献

- [1] Yang G Z, Zou X X, Li Y T. Research status and development trend of drilling jumbo. *China Heavy Equip*, 2009(1): 47
(杨光照, 邹学新, 李云涛. 凿岩台车的研发情况与发展趋势. *中国重型装备*, 2009(1): 47)
- [2] Yan H Q, Xu H Y, Gao H B, et al. Integrated drill boom hole-seeking control via reinforcement learning // 2023 *IEEE International Conference on Unmanned Systems (ICUS)*. Hefei, 2023: 1247
- [3] Kucuk S, Bingul Z. Robot Kinematics: Forward and Inverse Kinematics // Cubero S. *Industrial Robotics: Theory, Modelling and Control*. London: IntechOpen, 2006
- [4] Yan Y P, Liu X, Wei B, et al. Kinematic analysis of drilling arm of eight degrees of freedom rock drilling trolley. *Mod Manuf Technol Equip*, 2023, 59(6): 35
(燕盈萍, 刘翔, 魏波, 等. 八自由度凿岩台车钻臂运动学分析. *现代制造技术与装备*, 2023, 59(6): 35)
- [5] Qin L, Wei X, Lv L L, et al. An analytical solution for inverse kinematics of SSRMS-type redundant manipulators. *Sensors*, 2023, 23(12): 5412
- [6] Zhang H S, Xia Q J, Sun J C, et al. A fully geometric approach for inverse kinematics of a six-degree-of-freedom robot arm. *J Phys: Conf Ser*, 2022, 2338(1): 012089
- [7] Chen Y H, Luo X, Han B L, et al. A general approach based on Newton's method and cyclic coordinate descent method for solving the inverse kinematics. *Appl Sci*, 2019, 9(24): 5461
- [8] Katoch S, Chauhan S S, Kumar V. A review on genetic algorithm: Past, present, and future. *Multimedia Tools Appl*, 2021, 80(5): 8091
- [9] Tang Z L, An J Q. Position solution and motion simulation for rock drilling arm // 2019 *Chinese Control Conference (CCC)*. Guangzhou, 2019: 4673
- [10] Ge J W, Qi R B, Qian F, et al. A modified adaptive differential evolution algorithm. *J East China Univ Sci Technol*, 2009, 35(4): 600
(戈剑武, 祁荣宾, 钱锋, 等. 一种改进的自适应差分进化算法. *华东理工大学学报(自然科学版)*, 2009, 35(4): 600)
- [11] Zhang M S, Xiao J Z, Wang E H, et al. Inverse kinematical solving and trajectory planning of redundant manipulator. *J Mech Transm*, 2021, 45(6): 71
(张明松, 肖锦志, 王恩恒, 等. 冗余机械臂的逆运动求解及轨迹规划. *机械传动*, 2021, 45(6): 71)

- [12] Yang H Z, Liu X Y. Solving approach of inverse kinematics for manipulators based on improved adaptive niche genetic algorithm. *J Northwest Polytech Univ*, 2019, 37(3): 488
(杨惠珍, 刘西洋. 基于改进自适应小生境遗传算法的机械臂逆运动学求解. *西北工业大学学报*, 2019, 37(3): 488)
- [13] Li W S, Sun J, Chen W. Real-time obstacle avoidance algorithm for robots based on BP neural network. *Chin J Sci Instrum*, 2019, 40(11): 204
(李卫硕, 孙剑, 陈伟. 基于 BP 神经网络机器人实时避障算法. *仪器仪表学报*, 2019, 40(11): 204)
- [14] Csiszar A, Eilers J, Verl A. On solving the inverse kinematics problem using neural networks // *2017 24th International Conference on Mechatronics and Machine Vision in Practice (M2VIP)*. Auckland, 2017: 1
- [15] Mnih V, Kavukcuoglu K, Silver D, et al. Human-level control through deep reinforcement learning. *Nature*, 2015, 518(7540): 529
- [16] Jiang T Y, Yang J H, Xing Y W, et al. Analysis on inverse kinematics solution of drilling arm of rock drilling jumbo based on RBF neural network. *Min Process Equip*, 2023, 51(2): 1
(姜天佑, 杨聚辉, 邢亚伟, 等. 基于 RBF 神经网络凿岩台车钻臂逆解分析. *矿山机械*, 2023, 51(2): 1)
- [17] Pang Z X, Wang T Y, Liu S, et al. Kinematics analysis of 7-DOF upper limb rehabilitation robot based on BP neural network // *2020 IEEE 9th Data Driven Control and Learning Systems Conference (DDCLS)*. Liuzhou, 2020: 528
- [18] Cui M H, Ji H F, Hui Y B, et al. Kinematics of 7-DOF rock drilling jumbo boom based on RBF neural network. *J Mech Electr Eng*, 2022, 39(9): 1312
(崔孟豪, 姬会福, 惠延波, 等. 基于 RBF 神经网络的七自由度凿岩台车钻臂运动学研究. *机电工程*, 2022, 39(9): 1312)
- [19] Hsieh Y Z, Xu F X, Lin S S. Deep convolutional generative adversarial network for inverse kinematics of self-assembly robotic arm based on the depth sensor. *IEEE Sens J*, 2023, 23(1): 758
- [20] Sridhar Reddy A, Satish Chembuly V, Kesava Rao V V S. Collision-free inverse kinematics of redundant manipulator for agricultural applications through optimization techniques. *Int J Eng*, 2022, 35(7): 1343
- [21] Kang M, Cho Y, Yoon S E. RCIK: Real-time collision-free inverse kinematics using a collision-cost prediction network. *IEEE Robot Autom Lett*, 2022, 7(1): 610
- [22] Niu Y, Zhou Z S, Wang W, et al. Fully computer-based rock drilling jumbos. *Rock Drill Mach Pneumatic Tools*, 2022, 48(3): 6
(牛勇, 周忠尚, 王伟, 等. 全电脑凿岩台车. *凿岩机械气动工具*, 2022, 48(3): 6)
- [23] Cui Y M, Liu S Y, Ji H F, et al. Positioning and sequence planning of drilling boreholes in hard rock roadway. *IEEE Access*, 2020, 8: 56480
- [24] Guo R, Shi Y, Li Y T, et al. Research on trajectory planning of hydraulic rockdrilling robot manipulator. *Chin J Constr Mach*, 2021, 19(4): 289
(郭锐, 石月, 李永涛, 等. 液压凿岩机器人机械臂轨迹规划研究. *中国工程机械学报*, 2021, 19(4): 289)
- [25] Baillieul J. Introduction to ROBOTICS mechanics and control. *IEEE Trans Autom Control*, 1987, 32(5): 463
- [26] Ding F, Liu C. Applying coordinate fixed Denavit-Hartenberg method to solve the workspace of drilling robot arm. *Int J Adv Rob Syst*, 2018, 15(4): 172988141879328
- [27] Banerjee D, Yu K, Aggarwal G. Object tracking test automation using a robotic arm. *IEEE Access*, 2018, 6: 56378
- [28] Duan J L, Liu Z Y, Li S E, et al. Adaptive dynamic programming for nonaffine nonlinear optimal control problem with state constraints. *Neurocomputing*, 2022, 484: 128
- [29] Qin Y M. *Research on Trajectory Planning and Tracking Control of Hydraulic Rock-Drilling Robot Manipulator* [Dissertation]. Qinhuangdao: Yanshan University, 2019
(覃艳明. 液压凿岩机器人机械臂轨迹规划及跟踪控制研究[学位论文]. 秦皇岛: 燕山大学, 2019)