

# 基于深度学习的摘钩机器人手爪位置控制研究

贾军祥 蔡 茁 杜宗达 朱立学 陈禹桥

(辽宁大唐国际葫芦岛热电有限责任公司 辽宁 葫芦岛 125000)

**摘要** 摘钩机器人在自动化生产线中的应用日益广泛,尤其在物流和制造业中具有广阔的应用前景。摘钩任务要求机器人手爪具备高精度的空间位置控制能力,以应对复杂的工作环境,而传统的手爪控制方法往往难以应对多变的环境和多样化的目标物体。文中提出了一种基于深度学习的摘钩机器人手爪位置控制模型,利用深度卷积神经网络(Deep Convolutional Neural Network, DCNN)与强化学习算法,构建了一种适应性强、精度高的手爪位置控制系统。此外,该系统还使用了改进的梯度下降算法来优化模型参数,以提高控制精度和响应速度。实验结果表明,该控制系统在复杂多变的场景中具有优异的定位精度和较快的响应速度,显著提高了摘钩机器人的操作性能和鲁棒性。

**关键词:** 摘钩机器人;手爪位置控制;深度卷积神经网络;强化学习

**中图分类号** TP311.5

## Research on Claw Position Control of Unhooked Robot Hand Based on Deep Learning

JIA Junxiang, CAI Zhuo, DU Zongda, ZHU Lixue and CHEN Yuqiao

(Liaoning Datang International Huludao Thermoelectric Co., Ltd., Huludao, Liaoning 125000, China)

**Abstract** Hook-picking robots are increasingly widely used in automated production lines, especially in logistics and manufacturing. Hook-picking tasks require robot grippers to have high-precision spatial position control capabilities to cope with complex working environments, while traditional gripper control methods are often difficult to cope with changeable environments and diverse target objects. This paper proposes a deep learning-based claw position control model for hook-picking robots. Using Deep Convolutional Neural Network (DCNN) and reinforcement learning algorithms, a hand claw position control system with strong adaptability and high accuracy is constructed. In addition, the system also uses an improved layer descent algorithm to optimize the model parameters to improve the control accuracy and response speed. Experimental results show that the control system has excellent positioning accuracy and response speed in complex and changeable scenes, which significantly improves the operation performance and robustness of the hook-picking robot.

**Key words** Hook picking robot, Claw position control, Deep Convolutional Neural Network, Reinforcement learning

## 0 引言

摘钩机器人手爪位置控制技术是工业自动化领域的重要组成部分,被广泛应用于物流、制造业等场景<sup>[1]</sup>。摘钩任务通常要求机器人能在复杂环境中对不同目标物体进行准确定位与抓取,对手爪的控制精度和响应速度具有较高的要求。本文研究了基于深度学习的摘钩机器人手爪位置控制技术,通过构建基于 DCNN 与强化学习的控制模型,提升了手爪位置控制的精度与鲁棒性<sup>[2-3]</sup>。

## 1 基于深度学习的摘钩机器人手爪位置控制技术

摘钩机器人手爪控制主要涉及空间位置的精确调整以

及对目标物体的识别与定位。与传统基于规则的控制方法不同,深度学习能自动学习并提取环境和物体的复杂特征,实现更高效的控制。DCNN 具有强大的特征提取能力,能有效处理来自传感器的数据,并通过多层卷积和池化操作逐层提取空间信息,生成用于位置控制的高层次特征表示。深度学习和强化学习的结合使得手爪能在复杂环境下自适应调整抓取路径和力度,提高抓取操作的成功率和效率。

## 2 系统设计

### 2.1 基于深度学习的摘钩机器人手爪位置控制模型

#### 2.1.1 特征提取组件

在摘钩机器人手爪位置控制模型中,特征提取组件的

**作者简介:**贾军祥(1973—),本科,高级工程师,研究方向为摘钩机器人;蔡茁(1986—),专科,工程师,研究方向为摘钩机器人;杜宗达(1995—),本科,助理工程师,研究方向为摘钩机器人;朱立学(1973—),本科,工程师,研究方向为摘钩机器人;陈禹桥(1988—),本科,工程师,研究方向为摘钩机器人。

核心任务是从输入的传感器数据中提取空间位置特征。本文采用DCNN,通过多个卷积层和池化层来提取不同尺度和层次的图像特征。首先,通过卷积核在局部感受野中扫描图像,提取出局部的边缘、纹理等低级特征。随着卷积层的加深,这些低级特征会逐渐组合成更加复杂的特征表示,如形状和结构信息。池化层则用于对这些特征图进行降维处理,通过下采样保留重要的空间信息,同时减少计算量,避免出现过拟合现象。其中,卷积操作如式(1)所示:

$$f(x)=W \cdot x+b \quad (1)$$

其中, $f(x)$ 表示提取出的特征向量; $W$ 为卷积核矩阵,负责权重分配; $x$ 为输入的图像数据; $b$ 为偏置项,用于调整特征的激活阈值。

在特征提取过程中,DCNN通过层层递进的卷积操作不断累积和增强特征信息,最终生成用于手爪位置控制的高维特征向量。这些特征向量会被送入全连接层,用以生成对手爪位置进行精确控制的参数。这种多层次特征提取的方式使得模型能在处理复杂场景下的手爪位置控制任务时保持较高的精度和鲁棒性,确保即使在深度卷积操作下,提取的特征仍然具备良好的表达能力和分辨率,不会因为卷积层次加深而导致性能退化。

### 2.1.2 强化学习组件

强化学习组件的主要作用是通过不断地与环境交互,学习到最优的手爪位置控制策略,从而指导手爪在不同环境下作出最佳的动作决策。深度Q网络(Deep Q Network, DQN)是一种结合了深度学习与Q学习的强化学习算法,可通过学习一个Q值函数来评估每个状态-动作对的价值,即在给定状态下执行某个动作所能获得的长期回报<sup>[4]</sup>。

在DQN中,可将特征提取组件提取出的特征向量作为输入,代表机器人当前的状态。强化学习组件通过Q值函数为每一个可能的动作赋予一个价值(即Q值),然后选择Q值最大的动作作为手爪的控制信号输出。Q值函数的更新是强化学习的核心,它通过一个迭代过程逐步逼近最优策略,具体的更新规则如式(2)所示:

$$Q(s,a)=Q(s,a)+\alpha \cdot [r+\gamma \cdot \max_{a'} Q(s',a')-Q(s,a)] \quad (2)$$

其中, $Q(s,a)$ 表示在状态 $s$ 下选择动作 $a$ 的当前估计Q值; $\alpha$ 为学习率,决定了新旧值之间的平衡程度; $r$ 为即时奖励,表示在状态 $s$ 下执行动作 $a$ 后立即获得的奖励; $\gamma$ 为折扣因子,用于衡量未来奖励的重要性; $s'$ 和 $a'$ 分别为下一状态和下一个可能的动作; $Q(s',a')$ 表示在下一状态 $s'$ 下选择下一个可能的动作 $a'$ 的估计Q值。

在每一次与环境的交互过程中,强化学习组件都会根据新的观测值更新Q值函数,使得Q值函数逐步逼近真实的长期回报。通过不断的更新,DQN能有效学习到不同状态下的最优动作选择策略。具体而言,当手爪处于某个状态时,DQN会根据Q值函数选择一个动作,即确定手爪的控制信号,如移动方向和力度等。随着训练的深入,Q值函数

逐渐收敛后,即可确保手爪在各种复杂场景下都能作出最优的控制决策。这种自适应学习能力使得机器人手爪在面对环境变化和不确定性时,依然能保持高效的操作性,提高整个系统的鲁棒性和精确度。

## 2.2 模型参数优化

模型参数优化直接影响着系统的控制精度和响应速度。本文采用一种改进的梯度下降算法对控制模型的参数进行优化,以提高系统的整体性能。传统的梯度下降算法在优化过程中可能会陷入局部最优问题,且在复杂的非凸损失函数中收敛速度较慢。为克服这些问题,本文引入了动量因子和自适应学习率机制,以增强梯度下降过程的效率和稳定性<sup>[5-6]</sup>。

在DCNN中,模型参数包括卷积核矩阵 $W$ 和偏置项 $b$ 。这些参数的更新通过反向传播算法完成,而更新的关键在于计算损失函数对这些参数的梯度<sup>[7-8]</sup>。损失函数 $L(\theta)$ 的梯度计算过程如式(3)所示:

$$\frac{\partial L(\theta)}{\partial \theta}=\frac{\partial L(\theta)}{\partial W} \cdot \frac{\partial W}{\partial \theta}+\frac{\partial L(\theta)}{\partial b} \cdot \frac{\partial b}{\partial \theta} \quad (3)$$

其中, $\theta$ 代表所有模型参数,包括 $W$ 和 $b$ ; $\frac{\partial L(\theta)}{\partial \theta}$ 表示损失函数 $L(\theta)$ 对参数 $\theta$ 的梯度; $\frac{\partial L(\theta)}{\partial W}$ 表示损失函数 $L(\theta)$ 对卷积核矩阵 $W$ 的梯度; $\frac{\partial L(\theta)}{\partial b}$ 表示损失函数 $L(\theta)$ 对偏置项 $b$ 的梯度; $\frac{\partial W}{\partial \theta}$ 表示卷积核矩阵 $W$ 对参数 $\theta$ 的梯度; $\frac{\partial b}{\partial \theta}$ 表示偏置项 $b$ 对参数 $\theta$ 的梯度。

为优化这些参数,本文采用的改进梯度下降算法在标准梯度下降的基础上,加入了动量项和自适应学习率。其中,动量项用于累积过去梯度的指数加权平均,从而在更新时考虑过去的梯度变化方向,以避免陷入局部最优,如式(4)所示:

$$v_t=\beta \cdot v_{t-1}+(1-\beta) \cdot \frac{\partial L(\theta)}{\partial \theta} \quad (4)$$

其中, $v_t$ 表示当前时间步长 $t$ 的动量; $\beta$ 为动量因子,取值范围为 $[0,1)$ ; $v_{t-1}$ 表示前一个时间步长 $t-1$ 的动量。

加入动量项的梯度下降更新过程如式(5)所示:

$$\theta_{t+1}=\theta_t-\alpha \cdot v_t \quad (5)$$

其中, $\theta_{t+1}$ 表示在时间步长为 $t+1$ 时的模型参数; $\theta_t$ 表示当前时间步长 $t$ 的模型参数,即更新前的参数值。

为使模型在训练初期快速收敛,同时在接近最优解时保持稳定,本文还采用了自适应学习率机制。通过结合自适应学习率和动量因子,经过改进的梯度下降算法能在复杂的损失空间中更加稳定和高效地优化模型参数,提升手爪位置控制的精度和速度。这种优化策略显著提高了手爪在复杂场景中的操作性,以确保机器人在面对多变环境时能快速调整位置控制策略,在保持高精度的同时提高系统的鲁棒性,为摘钩机器人在工业领域的广泛应用提供了有力的技术支持。

### 3 实验验证

为验证本文所提的基于深度学习的摘钩机器人手爪位置控制系统的有效性,本文设计了一系列实验,以评估系统在不同复杂场景下的操作性能和控制精度。实验主要分为两个部分,分别是验证手爪在静态和动态目标下的定位准确性以及系统在复杂、多变环境中的适应性和响应速度。

#### 3.1 实验场景设置

实验在模拟的工业环境中进行,场景分为静态和动态两种类型。静态场景中包括规则排列的物体,如固定的挂钩阵列,机器人手爪需要在已知位置的挂钩上进行精准摘钩操作。实验旨在测试手爪位置控制模型的基本精度。在动态场景下,挂钩位置不断变化,模拟实际工业环境中可能出现的移动目标。机器人手爪需要实时调整位置,确保能准确完成摘钩任务。该实验用于评估系统在应对环境变化时的鲁棒性和响应速度。

#### 3.2 实验结果与分析

实验结果如表1所列。从表1可以看出,控制系统在静态场景下能实现高精度的定位,平均定位误差仅为0.8 cm,成功率高达97%。在动态场景中,由于目标位置的变化,定位误差有所增加,但依然保持在1.5 cm内,成功率为90%。同时,系统的平均响应时间在两种场景下分别为120 ms和150 ms,具备良好的实时性。

表1 实验结果

场景类型	平均定位误差/cm	成功率/%	平均响应时间/ms
静态场景	0.8	97	120
动态场景	1.5	90	150

实验结果表明,本文提出的基于深度学习的摘钩机器人手爪位置控制系统在不同的工业场景中均表现出优异的操作性能和较高的控制精度。在复杂的动态场景中,系统

通过自适应学习和实时调整策略,展现出较强的环境适应能力和鲁棒性。这种特性使得该系统在工业应用中具有广泛的应用前景,能有效提高自动化生产线的效率和可靠性。

### 4 结语

本文构建的基于深度学习的摘钩机器人手爪位置控制系统在复杂工业环境中表现出卓越的控制精度和适应性。通过结合深度卷积神经网络与强化学习算法,该系统不仅提升了手爪的定位准确性和响应速度,还展现出较强的环境鲁棒性,为自动化生产线的效率提升提供了有效的技术支持。未来,可以进一步优化模型参数,以适应更为复杂的应用场景。

#### 参考文献

- [1] 裴传福,成功,崔凯.翻车机摘钩机器人的研发与应用[J].中国设备工程,2024(2):35-37.
- [2] 陶唐飞,周文洁,况佳臣,等.融合多小波分解的深度卷积神经网络轴承故障诊断方法[J].西安交通大学学报,2024,58(5):31-41.
- [3] 郭书涵,胡国平,赵方正,等.基于深度卷积神经网络的DOA估计[J].空军工程大学学报,2023,24(4):62-68.
- [4] 黄岩松,姚锡凡,景轩,等.基于深度Q网络的多起点多终点AGV路径规划[J].计算机集成制造系统,2023,29(8):2550-2562.
- [5] 赵丽,张森,邓含睿.中国信用债市场动量因子有效性及投资策略探究[J].债券,2024(5):89-96.
- [6] 吉梦,何清龙.AdaSVRG:自适应学习率加速SVRG[J].计算机工程与应用,2022,58(9):83-90.
- [7] 孙长敏,戴宁,沈春娅,等.基于K-近邻算法改进粒子群-反向传播算法的织物质量预测技术[J].纺织学报,2024,45(7):72-77.
- [8] 张婷婷,王智强.基于反向传播算法的网络安全态势感知仿真[J].计算机仿真,2024,41(3):436-440.