



视觉驱动机械臂自主作业技术综述

摘要

视觉驱动机械臂自主作业技术在工业生产、航空航天以及深海探测等诸多领域都具有重要的意义.在回顾多年视觉驱动机械臂自主作业技术的基础上,从基于几何驱动的控制和基于数据驱动的控制两个方向进行归纳总结.对不同的控制方法,介绍了控制的原理,总结了每一类自主作业控制的研究成果,并对每种控制方法的特点以及存在的问题进行分析.针对视觉驱动机械臂自主作业在关键领域中的研究,本文重点分析讨论了海洋开发与探测领域中存在的关键问题与挑战.

关键词

机械臂;视觉驱动;自主作业

中图分类号 TP13

文献标志码 A

收稿日期 2020-03-01

资助项目 国家自然科学基金(U2006228, 61703381)

作者简介

杨学文,女,硕士生,研究方向为图像处理与机器人技术.yangxuewen@stu.ouc.edu.cn

王楠(通信作者),女,博士,副教授,主要研究方向为人工智能与机器人技术.wangnansu@163.com

0 引言

1973年,经典科幻电影《西部世界》向我们展示了一个科幻迷离的世界,近50年来,机器人已经从一个似乎遥不可及的科幻主题发展成了当今社会不可或缺的一部分.机器人已经出现在我们生活的各个角落,近到家庭扫地机器人、工厂焊接装配机器人、医疗机器人,远到深海开发探测机器人、外太空探测机器人等,它们在危险、苛刻的条件下作业,并帮助人们从繁重的工作中解放出来,在许多领域都彰显出了巨大的潜力.2015年5月,国务院正式印发《中国制造2025》,将机器人产业的发展提升到战略层面,由此,我国全面展开了在机器人产业领域的建设与布局.

机械臂是机器人与环境进行交互的重要部分^[1],甚至很多机器人本身只表现为一个机械臂,如美国加利福尼亚大学开发的Dex-Net 2.0^[2]、丹麦Universal Robots公司的UR5机器人、德国KUKA公司开发的LBR iiwa机器人^[3]等.机械臂的控制水平是机器人技术发展的重要衡量标准.从控制策略的角度来看,可以将机械臂的控制分为示教控制、遥操作控制、半自主控制和全自主控制等.示教控制指通过人工设定轨迹对机械臂进行控制,该方法对处理器要求不高,已广泛应用于流水的生产线任务,如汽车组装生产线^[4].但是这种控制方法无法通过对外界感知自适应地控制机械臂.遥操作的控制最早出现在20世纪四五十年代,其目的在于保护在放射性环境中的工作人员.遥操作控制包括人与机器人的交互以及机器人与环境的交互.人与机器人的交互中,人通过通信接口进行决策规划,而机器人与环境的交互中,机器人代替人类在恶劣的环境中进行工作^[5].该方法在很大程度上促进了空间技术、海洋探索以及远程医疗等危险或恶劣环境下的探索发展需求,如达芬奇机器人的使用不仅使得远程医疗成为现实,还可以帮助医生实现更为精细、微创的操作.然而在很多领域,仍然需要机械臂自主控制,如在海洋开发与探索领域中,机械臂采集到的信息无法实时地反馈到人机界面,工作人员无法实时地操作,同时深海环境是不断变化的,这种决策上的延迟极大地影响了机械臂作业的精度与效率,因此实现机械臂的自主控制对海洋开发与探索等众多领域具有重要意义.

视觉是对周边环境进行感知的重要方式之一.视觉控制机械臂自主作业很早就被提出,它的发展主要是从基于分析的方法^[6]到基于

¹ 中国海洋大学 信息科学与工程学院,青岛, 266100

数据驱动的方法^[7].日本琉球大学的 Shirai 等^[8]最早研究基于视觉的机器人,他们在 1973 年提出了一种基于开环的视觉机器人控制系统,先通过视觉获取目标位置,然后基于位置来控制机器人,形成了早期的视觉机器人系统,限于当时的硬件水平,它对于目标的定位和抓取并不精确.随着成像系统及计算机技术的不断发展,视觉伺服控制成为有效的控制方法之一,该方法通过图像反馈的信息实现闭环控制.对于简单场景下的抓取操作,视觉伺服的控制已经取得了显著成效,如在分拣、搬运等流水作业上.但是视觉伺服控制难以应对复杂场景和非结构化环境下的自主作业,如水下复杂动态场景下目标的抓取.近年来,随着硬件水平的提高,尤其是 GPU 等高速并行模块的开发,以及深度学习在机器视觉领域的快速发展,基于数据驱动的方法得到广泛关注.基于数据驱动的方法包括监督学习的方法和无监督学习的方法.监督学习的方法重点在于对环境的感知,一般通过目标检测或语义分割^[9]等技术得到最佳的抓取位姿^[10-11],然后采用逆运动学变换的方法控制机械臂抓取.但是这种方法一般采用的是开环控制,难以满足动态变化场景下的自主作业需求.无监督学习的方法将机械臂自身与环境进行交互,通过经验进行学习,为机械臂训练一个像人一样的大脑来对外界环境进行感知并决策出最合适的动作完成既定任务.这一类方法一般对抓取任务进行顺序上的推理,在复杂动态场景中展现出巨大的潜力.近年来,基于视觉驱动机械臂自主作业在各个领域的研究成果斐然,有必要对该研究历程以及发展趋势进行分析与讨论,因此本文对国内外视觉驱动机械臂自主作业的研究现状以及面临的问题与挑战进行梳理和讨论.

本文从基于几何驱动的控制和数据驱动的控制两个大的方向展开介绍,如图 1 所示.首先,在第 1 节对基于几何驱动的视觉伺服控制进行介绍,包括视觉伺服的原理以及国内外相关工作,进而对视觉伺服控制方法存在的问题进行讨论;第 2 节对基于数据驱动的机械臂自主控制进行了介绍,首先介绍了基于数据驱动的控制原理,然后从监督学习与无监督学习两个方向的相关工作进行介绍,并对数据驱动的机械臂自主控制存在的问题进行分析;第 3 节对视觉驱动机械臂自主作业在深海开发与探测领域仍存在的问题与挑战进行分析;第 4 节对本文内容进行总结.

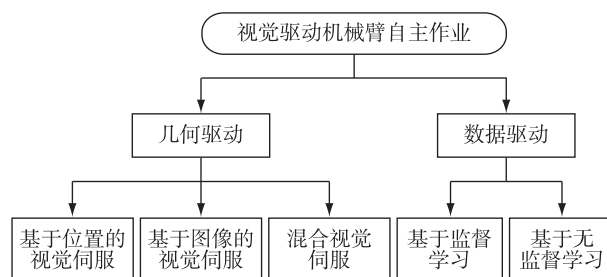


图 1 视觉驱动机械臂自主作业研究框

Fig. 1 Framework of review on autonomous operation technology of vision-based manipulator

1 基于几何驱动的机械臂自主作业

1.1 几何驱动机械臂控制介绍

几何驱动是通过几何学、运动学等进行解析从而规划出最合理的抓取的姿态.这一类方法主要处理数据库中已知物体的抓取,需要事先将待抓取物体的模型存入数据库中,通常与传统的视觉伺服相结合.

视觉伺服的概念^[12]于 1979 年被提出,指的是利用计算机视觉控制机器人的运动^[13],是一种闭环控制方式.它通过传感器不断采集到图像信息作为反馈信号,对机器做进一步控制或自适应调整的行为.Hutchinson 等^[14]在 1996 年编写的视觉伺服的教程中将视觉伺服分为基于位置的视觉伺服 (Position-Based Visual Servo, PBVS) 和基于图像的视觉伺服 (Image-Based Visual Servo, IBVS). 1999 年, Malis 等^[15]提出了混合视觉伺服 (Hybrid Visual Servoing, HVS) 的概念.

基于位置的视觉伺服 (PBVS) 控制方法的反馈信号以笛卡尔坐标系的形式给出,输入的误差信号为期望位姿与当前位姿的差值,如图 2 所示.首先将传感器采集到的图像信息进行处理,提取特征点,根据相机标定求取目标物位置处的期望位姿与机械臂末端执行器位姿的差值,然后利用逆运动学求解关节转动角度进而实现对机械臂的控制.其核心任务为根据提取的物体特征等实现对物体的位姿估计.针对位姿估计有多种方法,如解析法^[16]、迭代法^[17]、基于滤波的方法^[18]等.文献[19]使用了双目相机视觉得到目标位姿,文献[20]通过扩展卡尔曼滤波器对目标位姿进行实时估计.类似地,还有文献[21]等.随着 Intel RealSense、Kinect 等高性能 RGB-D 相机的出现,越来越多的人通过深度相机预测目标位姿,李树春等^[22]针对非结构化环境,使用 Kinect 获

取目标点云,然后通过提取快速点特征直方图描述子结合奇异值分解算法来估计目标位姿。




图2 基于位置的视觉伺服

Fig. 2 Schematic diagram of position-based visual servo

基于图像的视觉伺服 (IBVS) 实现了在图像空间的闭环控制,如图3所示.该控制方法的反馈信号为图像特征的期望值与当前值的差,将测量得到的图像信号与目标位置的图像信号进行比较,利用所获得的图像的误差进行控制.该方法提取出图像中的特征点,但无需进行位姿估计计算,而是将机器人的运动与图像特征点的运动通过雅可比矩阵建立一个动态的控制模型,然后根据该动态控制模型得到计算机的控制指令.其核心为找到稳定的特征点建立起视觉空间和机器人运动空间之间的非线性映射关系,常见的几何特征如点、线特征,或者基于图像矩的特征^[23].另外,也有将整幅图像作为特征建立目标函数来描述图像特征的运动模型.如基于点的特征,设特征点相对于相机坐标系的空间坐标为 (x, y, z) ,映射至成像平面的像素点坐标为 $(X, Y, 1)$,其中 $X = x/z, Y = y/z$.可得,相机运动引起目标点 (x, y, z) 的变化,从而引起 $(X, Y, 1)$ 的变化.平面像素点特征的雅可比矩阵 L_p 描述了相机运动速率和像素点坐标变化速率之间的转化关系,即:

$$\begin{bmatrix} \dot{X} \\ \dot{Y} \end{bmatrix} = L_p \begin{bmatrix} \boldsymbol{v}_{cam} \\ \boldsymbol{\omega}_{cam} \end{bmatrix}, \quad (1)$$

其中, $\boldsymbol{v}_{cam} = [v_x, v_y, v_z]^T, \boldsymbol{\omega}_{cam} = [\omega_x, \omega_y, \omega_z]^T$ 分别为相机的线速度向量和角速度向量,

$$L_p = \begin{bmatrix} -\frac{1}{z} & 0 & \frac{X}{z} & XY & -(1+X^2) & Y \\ 0 & -\frac{1}{z} & \frac{Y}{z} & 1+Y^2 & -XY & -X \end{bmatrix}. \quad (2)$$

在基于图像的视觉伺服系统中模型主要是指图像雅可比矩阵与机械臂运动学模型,如何快速地求取图像雅可比矩阵是一个关键的问题.文献[24]将图像雅可比矩阵的计算转换为最小二乘问题,利用 Broyden 方法估计图像雅可比矩阵;文献[25]在每




图3 基于图像的视觉伺服示意

Fig. 3 Schematic diagram of image-based visual servo

一时刻添加试探性的动作监测图像特征变化,再使用最小二乘法估计当前的图像雅可比矩阵,实现 2D 平面上的插孔任务;文献[26]采用递归高斯-牛顿的方法估计动态场景下的图像雅可比矩阵.

基于混合视觉伺服 (HVS) 包含了笛卡尔坐标空间的闭环控制和图像空间的闭环控制,又被称为 2.5D 视觉伺服^[27].该控制方法的反馈信号为期望图像与当前图像之间的单应性矩阵,通过对单应性矩阵的分解获取姿态控制分量.该方法融合了 PBVS 和 IBVS 的优势,增强了算法的鲁棒性,但其计算量较大,实时性也较差.也有的研究人员通过在不同的视觉伺服控制方式间切换实现机械臂的控制,如 2020 年 Haviland 等^[28]提出了 PBVS 和 IBVS 进行切换的方法实现非静止目标的抓取,先采用 PBVS 的视觉伺服从远处接近目标,然后切换到 IBVS 继续接近目标,实现了由粗到精的视觉伺服策略.

1.2 基于视觉伺服控制的问题与挑战

经过几十年的发展,视觉伺服机器人控制已经取得了很大的进展,并在多个领域都具有广泛的应用前景.通常来说,基于位置的视觉伺服的优点是可以直接根据机械臂末端与目标位姿的误差控制机械臂,缺点是位姿和运动估计容易受到摄像机标定误差、目标模型精度和图像测量噪声的影响.基于图像的视觉伺服对相机标定精度不太敏感,更适用于实际机器人的控制任务,但是缺乏目标的深度信息.尽管基于混合视觉伺服的控制较为有效,但在实际使用中通常比基于位置的或基于图像的视觉伺服更为复杂.

总体来说,视觉伺服的过程往往难以满足实时性的需求,无论是基于位置的视觉伺服中目标位姿的估计还是基于图像的视觉伺服中图像雅可比矩阵的估计都需要有效的算法来提升实时性.为了扩展视觉伺服的应用领域,提升算法效率是一个关键的问题.另外,目前大多数的视觉伺服系统往往针对的是静态、简单的环境,而对于复杂动态的环境中存在

的遮挡等问题可能会导致机械臂控制失败。

2 基于数据驱动的控制

2.1 数据驱动机械臂控制原理

随着深度学习的快速发展,研究人员将该领域运用到视觉驱动机械臂自主作业中,形成数据驱动的控制方法.数据驱动的控制方法包括监督学习的方法和无监督学习的方法。

基于监督学习的机械臂自主抓取的研究主要集中在抓取位姿的估计上.基于深度学习的自主控制大致流程和几何驱动的控制一致,相比于几何驱动的方法,基于深度学习的数据驱动借助于神经网络这一强有力的特征提取架构在杂乱、有遮挡的作业场景中更具有鲁棒性,可实现对已知、相似、未知物体的抓取。

强化学习也是机器学习的一个领域,属于无监督学习的方法.如图4所示,强化学习是一种通过智能体与环境进行互动,对外界环境进行感知,然后根据感知到的状态进行决策,进而得到环境反馈的评价,根据与环境交互所得到的信息不断调整策略以获得最大奖励的机器学习的方法.由于其具有自主学习能力且能够模拟人类和动物的学习过程而被认为是一种能有效解决控制与决策问题的机器学习方法.强化学习主要算法包含基于价值的方法、基于策略的方法以及两者相结合的方法^[29].基于价值的方法估计某一状态或某一状态-动作对的期望回报,并通过最大化这个期望回报得到最佳的策略,通常用于处理离散的动作空间.基于价值的方法有 Q-learning^[30-31]、Sarsa^[32-33]等.为了能够处理连续的动作空间,基于策略搜索的方法采用参数化的策略,并对这个参数化的策略进行优化得到最优策略,如 Policy gradient 的方法^[34].但是基于策略搜索的方法存在高方差的问题,因此将基于价值的思想与基于策略的思想相结合,即 actor-critic 的方法,如 DDPG^[35]等。




图4 强化学习示意

Fig. 4 Schematic diagram of reinforcement learning

2.2 基于监督学习的机械臂控制

基于监督学习的机械臂自主作业的研究将外界感知与运动控制分离.通过深度神经网络实现外界的感知,得到抓取位姿,然后通过逆运动学变换等实现控制机械臂.基于深度学习的机械臂控制研究主要集中在抓取检测上,根据抓取环境的不同,主要分为 2D 平面的抓取和 6 个自由度(6 Degrees of Freedom, 6DOF)的抓取,本文分别从这两个方面展开介绍。

2.2.1 2D 平面抓取

在 2D 平面的抓取研究中,6D 的抓取位姿可以简化为 3D 表示,即 2D 平面的坐标位置以及 1D 旋转角度,因此抓取检测可以转化为与目标检测相类似的问题.2D 平面的抓取主要包括基于抓取矩形估计的方法和基于抓取点估计的方法。

1) 基于抓取矩形估计的抓取位姿估计

在 2D 平面的抓取检测方法中,较为广泛的是对抓取矩形进行估计,其方法大致可以分为基于分类的方法、基于回归的方法和基于检测的方法.其中大多数的方法都采用文献[36]中的 5D 的抓取表示,即 (x, y, θ, h, w) ,其中 (x, y) 表示抓取矩形中心点的坐标, θ 表示矩形的旋转量, h 和 w 表示抓取矩形的大小。

基于分类的方法训练分类器对候选的抓取框进行评估,选取最佳的抓取框.文献[36]首次将深度学习应用于机械臂的抓取中,文中基于滑动窗口法,提出了两个阶段的级联系统,使用较小的神经网络搜索潜在的矩形,然后利用较大的神经网络对潜在的矩形进行排序,找到靠前的矩形,该方法在康奈尔数据集上取得了良好的效果.类似地,还有文献[11, 37]等。

基于回归的方法中第一类是直接回归的方法,即直接得到抓取框的位置参数,如文献[38-39]的工作.另外,文献[40]基于像素点的回归,利用全卷积神经网络对图像的每个像素点都得到一个以该像素点为中心的抓取矩形估计。

目标检测算法在目标抓取检测中应用也较为广泛.一种是利用基于目标检测的方法得到感兴趣域,进而对感兴趣域进行抓取检测,如文献[41]利用区域生成网络得到目标区域,然后利用基于分类的方法预测最佳的抓取角度,类似地还有文献[42]等.另外,文献[43-44]则基于 Faster RCNN 的思想,针对 Faster RCNN 目标检测算法中没有考虑目标框角度

的问题,在边界框回归时添加抓取角度的信息.

2) 基于抓取点估计的抓取位姿估计

在 2D 平面的抓取中,抓取点也可以唯一地确定抓取姿态.一种是基于采样的方法,即对点云进行采样得到候选的抓取点,进而通过神经网络对候选抓取点抓取成功的可能性进行评估.如 Mahler 等^[2]提出了 GQ-CNN 模型用以对抓取点的抓取成功可能性进行估计.另外,文献[45-46]则针对像素级的抓取点进行检测,采用全卷积网络对每一个像素点进行密集估计得到抓取成功的概率图,进而根据概率图执行动作.

2.2.2 6DOF 抓取

6DOF 的抓取位姿估计包含基于模型的方法和不基于模型的方法.其中,基于模型的方法的重点是寻找观测模型与模型数据库中模型的相关性,而不基于模型的方法是直接根据点云数据估计抓取位姿.

1) 基于模型方法

对于数据库中已知目标的抓取可以通过匹配的方法是将局部点云与已知模型库中模型进行匹配,进而得到 6DOF 抓取位姿,不需要对位姿进行估计.对于相似目标的抓取,也不需要估计其 6D 姿态,但是由于当前目标对象与数据库中的对象并不完全相同,所以可以通过学习观测目标与数据库中模型的对对应关系得到抓取位姿^[47-48].

2) 不基于模型方法

在很多情况下并没有合适的模型数据库,基于模型的方法会失效,而不基于模型的方法可以直接得到抓取位姿,是一种更为通用的方法,因而备受关注.不基于模型的方法可以通过局部点云或者是目标姿态估计的方法得到抓取位姿.

局部点云分析法是指仅仅根据输入的局部点云数据来估计 6DOF 抓取姿态.一种方法是基于局部点云通过采样的方法生成抓取的候选,然后对抓取候选进行分类或评分得到最佳的抓取位姿^[1,49-50].另外,也有的工作中直接根据输入的局部点云生成抓取位姿,如文献[51]利用变分自编码器生成最佳的抓取位姿.

精确的 6D 物体位姿可以有效地提升抓取的成功率,一些研究人员对目标位姿进行估计以提升抓取的准确率^[10,52-53].此外,完整的目标几何形状也使抓取位姿估计更加精确.基于此,有的研究人员研究从局部点云^[54-58]或 RGB-D 图像^[59-61]中重构目标的

几何形状,进而对抓取位姿进行估计.

2.3 基于无监督学习的机械臂控制

无监督的强化学习方法使机械臂在与环境进行交互的过程中自主学习,不需要对环境进行建模,因而得到广泛关注.目前使用强化学习算法进行机械臂自主作业控制的研究主要处于实验阶段.近年来有各种相关的技术和算法不断被提出,新的研究成果不断涌现.很多机械臂的训练环境直接将机械臂位姿参数或是目标位姿参数作为强化学习状态输入实现机械臂控制^[62-64],这种方法训练速度快且效果较好,但是实际使用中直接使用机械臂或目标位姿参数训练是不现实的,图像输入是更为通用可行的方式.

2.3.1 感知与控制分离的方法

得益于深度学习对环境的感知能力,很多研究人员将深度学习的感知结果与强化学习进行结合实现自主控制.

第一种方法是将位姿估计与强化学习参数训练相结合.首先通过目标位姿估计或机械臂位姿估计等方法得到机械臂和待抓取目标的位姿信息,然后采用位姿参数进行强化学习训练.如 Zuo 等^[65]首先通过 Encoder-Decoder 网络对机械臂的位姿进行估计,进而使用强化学习的方法进行规划.这种方法中无监督的强化学习过程体现在机械臂的控制上.第二种方法是将特征表示学习与强化学习参数训练相结合.通过对图像进行低维的特征表示,如文献[66-67],首先利用目标检测算法得到目标在图像中的位置,然后对目标附近的图像块进行特征描述得到特征向量,进而采用强化学习的方法将特征向量映射为机械臂的动作,类似地,还有文献[68].同样地,第二种方法中强化学习的过程体现在机械臂的控制环节.

还有的研究人员采用的是图像到图像的映射,即采用全卷积神经网络将采集的图像映射为抓取的热力图,根据热力图选择抓取位置,然后采用逆运动学变换的方法进行控制.如 Zeng 等^[69]在仿真环境与实物环境中利用 Q 网络联合训练抓取和推动的动作,其直接将 RGB-D 相机的观测作为输入,利用 Q 网络得到抓取以及推动位置的热力图,并选择一个最优的位置作为执行的动作,类似的方法还有文献[70-73].这一类方法中强化学习的过程体现在图像层面上的抓取姿态或推动姿态的预测.其与基于深度学习的方法从图像中进行抓取点检测的工作类

似,但又有所提升.但是上述方法是开环的控制,不是基于任务的顺序推理,只是在图像层面上进行感知,而距离信息直接由深度相机得到,成功的效率依赖于相机的标定,在一些不能直接得到准确的深度信息或者动态变化的场景下并不适用.

2.3.2 端到端的控制方法

端到端的控制方法是图像到动作的直接映射,即直接将环境中采集到的图像作为状态,将当前图像映射为机械臂的下一步的动作,实现自主控制.近几年,基于这一思想的机械臂的控制方法^[74-76]逐渐被提出,其中具有代表性的是文献[76]中的 QT-Opt 算法. Kalashnikov 等^[76]在实物平台上做了机械臂对物体的抓取实验,结合随机优化的方法对 DQN 进行改进,提出了 DQN 对连续动作空间的处理方法.这种图像到动作的直接映射的控制方法是动态、闭环的控制,在每一步中感知与控制紧密交织.相比于开环的控制方法,这种动态闭环的控制方法在未知物体、传感器信息不精确以及动态场景下具有更大的潜力.

2.4 基于数据驱动机械臂的问题与挑战

得益于硬件水平的不断提升以及计算机视觉领域的不断进步,基于数据驱动的机械臂自主控制取得了极大的进展,并展现出了巨大的潜力.

基于监督学习的控制从原始图像或深度图像中得到最鲁棒的抓取位姿进行抓取,借助于深度神经网络的特征提取能力,可以对已知、相似,甚至未知的目标进行操作,然而这一类方法中良好的泛化能力的前提是需要庞大的、标定的训练数据集来支撑的.目前较为常用的数据集如康奈尔大学的康奈尔抓取数据集^[36].当然也有的数据集通过机械臂与环境进行交互,根据任务的实际完成情况确定标签,避免了人工标定的过程,如 Pinto 等^[11]在单台机械臂上花费 700 h 完成 50 000 次抓取尝试.谷歌数据集采用 8 台机械臂花费 2 个月的时间采集 800 000 次抓取尝试^[77].但是这种大规模的数据采集是非常昂贵的.

基于无监督学习的控制依赖的是机械臂自身与环境进行交互,从环境给出的经验中学习,为机械臂训练一个像人一样的“大脑”,这种方法可以实现在非结构化的环境中自适应地进行控制,使机械臂更好地适应新的环境.虽然这种方法在非结构化的场景中的控制展现出了巨大的潜力,但其自身发展仍存在一些挑战.比如,控制模型自主作业往往是在仿

真环境中进行训练的,如 Gazebo、V-rep 等.一个原因是采用真实的机械臂直接与环境进行互动难以掌控,容易对人或机械臂自身造成损害,另外一个原因是机械臂的制造成本往往比较高.但是仿真环境与真实环境是不同的,在仿真环境中训练的模型不一定能直接应用于真实的场景,从仿真环境到真实环境的迁移是一个关键的问题.此外,在与环境的交互过程中,奖励机制的设计是至关重要的部分,直接影响到机械臂“大脑”学习的好坏.在机械臂的自主作业控制中,奖励往往是稀疏的,如何在稀疏的奖励中得到满意的训练仍需要深入的研究.

3 在深海开发与探测领域中面临的挑战

视觉驱动机械臂自主作业的研究对很多尖端的领域都具有重要、长远的实际意义,如工业生产领域、航空航天领域以及海洋开发与探测领域等,因而受到国内外学者的广泛关注,也需要来自相关学科的学者从不同角度进行研究.视觉驱动机械臂自主作业在工业界和物流行业应用较为广泛,主要还是集中在视觉伺服对简单、结构化场景的控制.虽然目前的关于视觉驱动机械臂自主作业的优秀成果层出不穷,取得了令人瞩目的成绩,但是仍然没有形成普遍使用的理论和方法,在一些领域中有其自身发展的局限性,需要针对具体场景进行具体分析,并采取相应的策略.

由于笔者团队重点研究的是水下复杂动态场景下视觉驱动机械臂自主作业,因此这里着重对该领域发展的挑战进行分析.海洋环境不同于陆地环境,它包含着大量的人类目前无法掌握的未知因素,对海洋资源的开发与利用面临着严峻的挑战,也影响了水下自主作业机械臂的研究与发展.下面对关键的几点进行分析:

1) 针对视觉驱动机械臂的自主作业的研究往往是在理想的静态环境下进行的,对于这种固定的场景中,视觉驱动机械臂自主作业可以取得较好的结果,但是在水下这种非结构化的真实场景下,由于外在环境的复杂性、多变性、动态性以及未知性,视觉驱动机械臂自主作业仍然面临着巨大挑战.

2) 目前很多技术是在仿真环境中进行实验或训练的,如何有效地迁移到水下真实的机械臂中进行自主作业仍需进一步研究.

3) 水下真实的场景中,深度信息的获得仍然是一个具有挑战性的问题.水下场景由于其自身环境

的特殊性,陆地上的一些设备或技术不能直接应用于水下环境,如深度相机等,这也成为水下场景中距离信息获取的一大障碍。

4) 传感器信息质量问题.视觉驱动机械臂自主作业研究中,视觉是一个关键因素,然而由于水的吸收以及散射等因素的影响,采集到的水下图像质量往往不高,这也就影响了自主作业的精确度。

5) 面对复杂的外界环境与抓取目标的多样性,单一传感器难以实现对环境显式的表达,就需要多种传感器协同作用以增强对外界环境的感知,如视觉感知、触觉感知以及力觉感知等,如何对多种传感器的感知信息进行有效融合也是研究的重点。

4 总结

本文从基于几何驱动的控制和基于数据驱动的控制两个方向介绍视觉驱动自主作业机械臂的相关研究内容.首先介绍了不同方向的控制原理,进而总结了两种机械臂控制方法中的最新研究进展,并分析讨论了不同控制方法中存在的问题.最后针对深海开发与探测领域中存在的关键问题与挑战进行分析与讨论。

参考文献

References

- [1] Zhao B L, Zhang H B, Lan X G, et al. REGNet: REgion-based Grasp Network for single-shot grasp detection in point clouds[J].arXiv, e-print, 2020.arXiv:2002.12647
- [2] Mahler J, Liang J, Niyaz S, et al. Dex-net 2. 0: deep learning to plan robust grasps with synthetic point clouds and analytic grasp metrics [C] // Robotics: Science and Systems XIII. Robotics: Science and Systems Foundation, 2017. DOI: 10.15607/rss.2017.xiii.058
- [3] Borst C, Ott C, Wimbock T, et al. A humanoid upper body system for two-handed manipulation [C] // Proceedings 2007 IEEE International Conference on Robotics and Automation. April 10 - 14, 2007, Rome, Italy. IEEE, 2007: 2766-2767
- [4] Hodson R. How robots are grasping the art of gripping [J]. Nature, 2018, 557(7704): S23-S25
- [5] 宋爱国. 力觉临场感遥操作机器人(1): 技术发展现状[J]. 南京信息工程大学学报(自然科学版), 2013, 5(1): 1-19
SONG Aiguo. Force telepresence telerobot (1): review of the history and development[J]. Journal of Nanjing University of Information Science & Technology (Natural Science Edition), 2013, 5(1): 1-19
- [6] Weisz J, Allen P K. Pose error robust grasping from contact wrench space metrics [C] // 2012 IEEE International Conference on Robotics and Automation, 2012: 557-562
- [7] Bohg J, Morales A, Asfour T, et al. Data-driven grasp synthesis: a survey [J]. IEEE Transactions on Robotics, 2014, 30(2): 289-309
- [8] Shirai Y, Inoue H. Guiding a robot by visual feedback in assembling tasks [J]. Pattern Recognition, 1973, 5(2): 99-108
- [9] Jonschkowski R, Eppner C, Höfer S, et al. Probabilistic multi-class segmentation for the Amazon Picking Challenge [C] // 2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). October 9 - 14, 2016, Daejeon, Korea (South). IEEE, 2016: 1-7
- [10] Zeng A, Yu K T, Song S R, et al. Multi-view self-supervised deep learning for 6D pose estimation in the Amazon Picking Challenge [C] // 2017 IEEE International Conference on Robotics and Automation (ICRA). May 29 - June 3, 2017, Singapore. IEEE, 2017: 1383-1386
- [11] Pinto L, Gupta A. Supersizing self-supervision: learning to grasp from 50K tries and 700 robot hours [C] // 2016 IEEE International Conference on Robotics and Automation (ICRA). May 16 - 21, 2016, Stockholm, Sweden. IEEE, 2016: 3406-3413
- [12] Hill J. Real time control of a robot with a mobile camera [C] // 9th International Symposium on Industrial Robots, 1979: 233-246
- [13] Chaumette F, Hutchinson S, Corke P. Visual servoing [M]. Cham: Springer International Publishing, 2016: 841-866
- [14] Hutchinson S, Hager G D, Corke P I. A tutorial on visual servo control [J]. IEEE Transactions on Robotics and Automation, 1996, 12(5): 651-670
- [15] Malis E, Chaumette F, Boudet S. 2 1/2 D visual servoing [J]. IEEE Transactions on Robotics and Automation, 1999, 15(2): 238-250
- [16] Dhome M, Richetin M, Lapreste J T, et al. Determination of the attitude of 3D objects from a single perspective view [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1989, 11(12): 1265-1278
- [17] Dementhon D F, Davis L S. Model-based object pose in 25 lines of code [J]. International Journal of Computer Vision, 1995, 15(1/2): 123-141
- [18] Larouche B P, Zhu Z H. Autonomous robotic capture of non-cooperative target using visual servoing and motion predictive control [J]. Autonomous Robots, 2014, 37(2): 157-167
- [19] Shauri R L A, Nonami K. Assembly manipulation of small objects by dual-arm manipulator [J]. Assembly Automation, 2011, 31(3): 263-274
- [20] Lippiello V, Siciliano B, Villani L. Position-based visual servoing in industrial multirobot cells using a hybrid camera configuration [J]. IEEE Transactions on Robotics, 2007, 23(1): 73-86
- [21] Dong G Q, Zhu Z H. Position-based visual servo control of autonomous robotic manipulators [J]. Acta Astronautica, 2015, 115: 291-302
- [22] 李树春, 张静, 张华, 等. 面向机器人抓取过程中目标位姿估计方法 [J]. 传感器与微系统, 2019, 38(7): 32-

- 34,38
- LI Shuchun, ZHANG Jing, ZHANG Hua, et al. Object pose estimation method for robot grasping process [J]. *Transducer and Microsystem Technologies*, 2019, 38(7) : 32-34,38
- [23] Chaumette F. Image moments: a general and useful set of features for visual servoing [J]. *IEEE Transactions on Robotics*, 2004, 20(4) : 713-723
- [24] Hosoda K, Asada M. Versatile visual servoing without knowledge of true Jacobian [C] // *Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS'94)*. September 12 - 16, 1994, Munich, Germany. IEEE, 1994: 186-193
- [25] Yoshimi B H, Allen P K. Alignment using an uncalibrated camera system [J]. *IEEE Transactions on Robotics and Automation*, 1995, 11(4) : 516-521
- [26] Piepmeier J A, Lipkin H. Uncalibrated eye-in-hand visual servoing [J]. *The International Journal of Robotics Research*, 2003, 22(10/11) : 805-819
- [27] Malis E, Chaumette F. 2 1/2 D visual servoing with respect to unknown objects through a new estimation scheme of camera displacement [J]. *International Journal of Computer Vision*, 2000, 37(1) : 79-97
- [28] Haviland J, Dayoub F, Corke P. Predicting target feature configuration of non-stationary objects for grasping with image-based visual servoing [J]. *CoRR*, 2020
- [29] Arulkumaran K, Deisenroth M P, Brundage M, et al. A brief survey of deep reinforcement learning [J]. *IEEE Signal Processing Magazine*, 2017, 34(6). DOI: 10.1109/MSP.2017.2743240
- [30] Watkins C J C H. *Learning from delayed rewards* [M]. Cambridge: University of Cambridge, 1989
- [31] Watkins C J C H, Dayan P. Q-learning [J]. *Machine Learning*, 1992, 8(3/4) : 279-292
- [32] Rummery G A, Niranjan M. *On-line Q-learning using connectionist systems* [M]. Cambridge, UK: University of Cambridge, 1994
- [33] Sutton R S. Generalization in reinforcement learning: successful examples using sparse coarse coding [C] // *Advances in Neural Information Processing Systems*, 1996: 1038-1044
- [34] Thomas P S, Brunskill E. Policy gradient methods for reinforcement learning with function approximation and action-dependent baselines [J]. *arXiv, e-print*, 2017. *arXiv*: 1706.06643
- [35] Lillicrap T P, Hunt J J, Pritzel A, et al. Continuous control with deep reinforcement learning [J]. *arXiv, e-print*, 2015. *arXiv*: 1509.02971
- [36] Lenz I, Lee H, Saxena A. Deep learning for detecting robotic grasps [J]. *The International Journal of Robotics Research*, 2015, 34(4/5) : 705-724
- [37] Park D, Chun S Y. Classification based grasp detection using spatial transformer network [J]. *arXiv, e-print*, 2018. *arXiv*: 1803.01356
- [38] Redmon J, Angelova A. Real-time grasp detection using convolutional neural networks [C] // *2015 IEEE International Conference on Robotics and Automation (ICRA)*. May 26 - 30, 2015, Seattle, WA, USA. IEEE, 2015: 1316-1322
- [39] Kumra S, Kanan C. Robotic grasp detection using deep convolutional neural networks [C] // *2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. September 24 - 28, 2017, Vancouver, BC, Canada. IEEE, 2017: 769-776
- [40] Kumra S, Joshi S, Sahin F. Antipodal robotic grasping using generative residual convolutional neural network [C] // *2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. October 24 - January 24, 2021, Las Vegas, NV, USA. IEEE, 2021: 9626-9633
- [41] Chu F J, Xu R N, Vela P A. Real-world multiobject, multi-grasp detection [J]. *IEEE Robotics and Automation Letters*, 2018, 3(4) : 3355-3362
- [42] Zhang H B, Lan X G, Bai S T, et al. ROI-based robotic grasp detection for object overlapping scenes [C] // *2019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. November 3 - 8, 2019, Macao, China. IEEE, 2019: 4768-4775
- [43] Zhou X W, Lan X G, Zhang H B, et al. Fully convolutional grasp detection network with oriented anchor box [C] // *2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. October 1 - 5, 2018, Madrid, Spain. IEEE, 2018: 7223-7230
- [44] Guo D, Sun F C, Liu H P, et al. A hybrid deep architecture for robotic grasp detection [C] // *2017 IEEE International Conference on Robotics and Automation (ICRA)*. May 29 - June 3, 2017, Singapore. IEEE, 2017: 1609-1614
- [45] Zeng A, Song S R, Yu K T, et al. Robotic pick-and-place of novel objects in clutter with multi-affordance grasping and cross-domain image matching [C] // *2018 IEEE International Conference on Robotics and Automation (ICRA)*. May 21 - 25, 2018, Brisbane, QLD, Australia. IEEE, 2018: 3750-3757
- [46] Cai J H, Cheng H, Zhang Z P, et al. MetaGrasp: data efficient grasping by affordance interpreter network [C] // *2019 International Conference on Robotics and Automation (ICRA)*. May 20 - 24, 2019, Montreal, QC, Canada. IEEE, 2019: 4960-4966
- [47] Tian H, Wang C B, Manocha D, et al. Transferring grasp configurations using active learning and local replanning [C] // *2019 International Conference on Robotics and Automation (ICRA)*. May 20 - 24, 2019, Montreal, QC, Canada. IEEE, 2019: 1622-1628
- [48] Patten T, Park K, Vincze M. DGCM-net: dense geometrical correspondence matching network for incremental experience-based robotic grasping [J]. *Frontiers in Robotics and AI*, 2020, 7: 120. DOI: 10.3389/frobt.2020.00120
- [49] Ten Pas A, Gualtieri M, Saenko K, et al. Grasp pose detection in point clouds [J]. *The International Journal of Robotics Research*, 2017, 36(13/14) : 1455-1473
- [50] Liang H Z, Ma X J, Li S, et al. PointNetGPD: detecting grasp configurations from point sets [C] // *2019 International Conference on Robotics and Automation (ICRA)*. May 20 - 24, 2019, Montreal, QC, Canada. IEEE, 2019:

- 3629-3635
- [51] Mousavian A, Eppner C, Fox D. 6-DOF GraspNet: variational grasp generation for object manipulation [C] // 2019 IEEE/CVF International Conference on Computer Vision (ICCV). October 27–November 2, 2019, Seoul, Korea (South). IEEE, 2019:2901-2910
- [52] Wong J M, Kee V, Le T, et al. SegICP: integrated deep semantic segmentation and pose estimation [C] // 2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). September 24–28, 2017, Vancouver, BC, Canada. IEEE, 2017:5784-5789
- [53] Wang C, Xu D F, Zhu Y K, et al. DenseFusion: 6D object pose estimation by iterative dense fusion [C] // 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). June 15–20, 2019, Long Beach, CA, USA. IEEE, 2019:3338-3347
- [54] Varley J, DeChant C, Richardson A, et al. Shape completion enabled robotic grasping [C] // 2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). September 24–28, 2017, Vancouver, BC, Canada. IEEE, 2017:2442-2447
- [55] Lundell J, Verdoja F, Kyrki V. Robust grasp planning over uncertain shape completions [C] // 2019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). November 3–8, 2019, Macao, China. IEEE, 2019. DOI:10.1109/IROS40897.2019.8967816
- [56] Watkins-Valls D, Varley J, Allen P. Multi-modal geometric learning for grasping and manipulation [C] // 2019 International Conference on Robotics and Automation (ICRA). May 20–24, 2019, Montreal, QC, Canada. IEEE, 2019:7339-7345
- [57] Tosun T, Yang D, Eisner B, et al. Robotic grasping through combined image-based grasp proposal and 3D reconstruction [J]. arXiv, e-print, 2020. arXiv:2003.01649
- [58] Mark V, Lu Q, Sundaralingam B, et al. Learning continuous 3D reconstructions for geometrically aware grasping [C] // 2020 IEEE International Conference on Robotics and Automation (ICRA). May 31–August 31, 2020, Paris, France. IEEE, 2020:11516-11522
- [59] Wang S X, Wu J J, Sun X Y, et al. 3D shape perception from monocular vision, touch, and shape priors [C] // 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). October 1–5, 2018, Madrid, Spain. IEEE, 2018:1606-1613
- [60] Yan X C, Hsu J, Khansari M, et al. Learning 6-DOF grasping interaction via deep geometry-aware 3D representations [C] // 2018 IEEE International Conference on Robotics and Automation (ICRA). May 21–25, 2018, Brisbane, QLD, Australia. IEEE, 2018:3766-3773
- [61] Sajjan S, Moore M, Pan M K, et al. Clear grasp: 3D shape estimation of transparent objects for manipulation [C] // 2020 IEEE International Conference on Robotics and Automation (ICRA). May 31–August 31, 2020, Paris, France. IEEE, 2020:3634-364
- [62] Mahmood A R, Korenkevych D, Vasan G, et al. Benchmarking reinforcement learning algorithms on real-world robots [C] // 2nd Conference on Robot Learning, 2018: 561-591
- [63] Andrychowicz M, Wolski F, Ray A, et al. Hindsight experience replay [J]. arXiv, e-print, 2017. arXiv:1707.01495
- [64] Nair A, McGrew B, Andrychowicz M, et al. Overcoming exploration in reinforcement learning with demonstrations [C] // 2018 IEEE International Conference on Robotics and Automation (ICRA). May 21–25, 2018, Brisbane, QLD, Australia. IEEE, 2018:6292-6299
- [65] Zuo Y M, Qiu W C, Xie L X, et al. CRAVES: controlling robotic arm with a vision-based economic system [C] // 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). June 15–20, 2019, Long Beach, CA, USA. IEEE, 2019:4209-4218
- [66] Kiatos M, Malassiotis S. Robust object grasping in clutter via singulation [C] // 2019 International Conference on Robotics and Automation (ICRA). May 20–24, 2019, Montreal, QC, Canada. IEEE, 2019:1596-1600
- [67] Sarantopoulos I, Kiatos M, Dougeri Z, et al. Split deep Q-learning for robust object singulation [C] // 2020 IEEE International Conference on Robotics and Automation (ICRA). May 31–August 31, 2020, Paris, France. IEEE, 2020:6225-6231
- [68] Kim T, Park Y, Park Y, et al. Acceleration of actor-critic deep reinforcement learning for visual grasping in clutter by state representation learning based on disentanglement of a raw input image [J]. arXiv, e-print, 2020. arXiv:2002.11903
- [69] Zeng A, Song S R, Welker S, et al. Learning synergies between pushing and grasping with self-supervised deep reinforcement learning [C] // 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). October 1–5, 2018, Madrid, Spain. IEEE, 2018:4238-4245
- [70] Berscheid L, Meißner P, Kröger T. Robot learning of shifting objects for grasping in cluttered environments [J]. 2019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 2019:612-618
- [71] Zhang J H, Zhang W, Song R, et al. Grasp for stacking via deep reinforcement learning [C] // 2020 IEEE International Conference on Robotics and Automation (ICRA). May 31–August 31, 2020, Paris, France. IEEE, 2020:2543-2549
- [72] Song S R, Zeng A, Lee J, et al. Grasping in the wild: learning 6DoF closed-loop grasping from low-cost demonstrations [J]. IEEE Robotics and Automation Letters, 2020,5(3):4978-4985
- [73] Yang Y, Liang H Y, Choi C. A deep learning approach to grasping the invisible [J]. IEEE Robotics and Automation Letters, 2020,5(2):2232-2239
- [74] Zhang F Y, Leitner J, Milford M, et al. Towards vision-based deep reinforcement learning for robotic motion control [J]. arXiv, e-print, 2015. arXiv:1511.03791
- [75] Quillen D, Jang E, Nachum O, et al. Deep reinforcement learning for vision-based robotic grasping: a simulated comparative evaluation of off-policy methods [C] // 2018 IEEE International Conference on Robotics and Automation (ICRA). May 21–25, 2018, Brisbane, QLD, Australia. IEEE, 2018:6284-6291
- [76] Kalashnikov D, Irpan A, Pastor P, et al. QT-Opt: scalable

- deep reinforcement learning for vision-based robotic manipulation [J]. arXiv, e-print, 2018. arXiv: 1806. 10293
- [77] Levine S, Pastor P, Krizhevsky A, et al. Learning hand-eye coordination for robotic grasping with deep learning and large-scale data collection [J]. The International Journal of Robotics Research, 2018, 37(4/5): 421-436

Review on autonomous operation technology of vision-based manipulator

YANG Xuewen¹ WANG Nan¹

¹ College of Information Science and Engineering, Ocean University of China, Qingdao 266100

Abstract Autonomous operation of vision-based manipulator is of great significance in many fields such as industrial production, aerospace and deep-sea exploration. Here we summarize the autonomous operation technology of vision-based manipulator in light of their control schemes: geometric driven control and data driven control. The control principles as well as related work are introduced, then strengths of and challenges faced by each category are analyzed. Finally, key issues and challenges for autonomous control of vision-based manipulator in fields of ocean development and exploration are summarized.

Key words manipulator; vision driven; autonomous operation