

# 控制与决策

Control and Decision

## 基于多约束条件的机器人抓取策略学习方法

崔涛, 李凤鸣, 宋锐, 李贻斌

引用本文:

崔涛,李凤鸣,宋锐,李贻斌. 基于多约束条件的机器人抓取策略学习方法[J]. *控制与决策*, 2022, 37(6): 1445–1452.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2020.1716>

---

## 您可能感兴趣的其他文章

Articles you may be interested in

### 机器人抓取检测技术的研究现状

Recent researches on robot autonomous grasp technology

控制与决策. 2020, 35(12): 2817–2828 <https://doi.org/10.13195/j.kzyjc.2019.1145>

### 基于多层级特征的机械臂单阶段抓取位姿检测

Single-stage grasp pose detection of manipulator based on multi-level features

控制与决策. 2021, 36(8): 1815–1824 <https://doi.org/10.13195/j.kzyjc.2019.1840>

### 基于生物启发神经网络和DMPC的多机器人协同搜索算法

Multi-robot cooperative search algorithm based on bio-inspired neural network and DMPC

控制与决策. 2021, 36(11): 2699–2706 <https://doi.org/10.13195/j.kzyjc.2020.0959>

### 移动机器人运动规划中的深度强化学习方法

Deep reinforcement learning for motion planning of mobile robots

控制与决策. 2021, 36(6): 1281–1292 <https://doi.org/10.13195/j.kzyjc.2020.0470>

### 基于接触状态感知发育的机器人柔性装配方法

Flexible assembly method based on contact state perception development

控制与决策. 2021, 36(4): 876–884 <https://doi.org/10.13195/j.kzyjc.2019.1079>

# 基于多约束条件的机器人抓取策略学习方法

崔涛, 李凤鸣, 宋锐<sup>†</sup>, 李贻斌

(山东大学控制科学与工程学院, 济南 250061)

**摘要:** 针对机器人在多类别物体不同任务下的抓取决策问题, 提出基于多约束条件的抓取策略学习方法. 该方法以抓取对象特征和抓取任务属性为机器人抓取策略约束, 通过映射人类抓取习惯规划抓取模式, 并采用物体方向包围盒(OBB)建立机器人抓取规则, 建立多约束条件的抓取模型. 利用深度径向基(DRBF)网络模型结合减聚类算法(SCM)实现抓取策略的学习, 两种算法的结合旨在提高学习鲁棒性与精确性. 搭建以 Reflex 1 型灵巧手和 AUBO 六自由度机械臂组成的实验平台, 对多类别物体进行抓取实验. 实验结果表明, 所提出方法使机器人有效学习到对多物体不同任务的最优抓取策略, 具有良好的抓取决策能力.

**关键词:** 机器人抓取策略; 抓取决策; 多约束条件; 神经网络; 方向包围盒; 灵巧手

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2020.1716

开放科学(资源服务)标识码(OSID):



**引用格式:** 崔涛, 李凤鸣, 宋锐, 等. 基于多约束条件的机器人抓取策略学习方法[J]. 控制与决策, 2022, 37(6): 1445-1452.

## A learning method of robotic grasping strategy based on multi-constraint conditions

CUI Tao, LI Feng-ming, SONG Rui<sup>†</sup>, LI Yi-bin

(School of Control Science and Engineering, Shandong University, Ji'nan 250061, China)

**Abstract:** Aiming at the problem of robot grasping decision under different tasks of multiple objects, a learning method of the grasping strategy based on multiple constraints is proposed, in which, the characteristics of grasping objects and the attributes of grasping tasks are taken as the multiple constraints of the a robot grasping strategy. Furthermore, the method uses human grasping habit to map to robot grasp types, and the grasping rules of a robot are established by using the object bounding box(OBB). The fetching model with multiple constraints is established. Then, the radial basis function RBF network model is combined with the de-clustering algorithm SCM to realize the grasping strategy learning. The combination of the two algorithms aims to improve the robustness and accuracy of learning. Using the AUBO six-degree-of-freedom robotic arm with Reflex 1 dexterity hand, experiments are conducted to grasp objects with different shapes and multiple tasks. Experimental results show that the proposed method enables the robot to effectively learn the optimal grasping strategy for different tasks of multiple objects and has good grasping decision-making ability.

**Keywords:** robotic grasping strategy; grasping decision; multiple constraints; neural network; oriented bounding box; dexterous hand

## 0 引言

近年来,“工业 4.0”和“中国制造 2025”渐渐成为下一场工业革命中的重要概念,机器人逐步应用在众多生产生活领域. 机器人抓取是机器人与外界交互的重要操作能力<sup>[1]</sup>,一直是机器人领域重要的研究方向. 机器人抓取主要涉及检测、决策和控制 3 个方面<sup>[2]</sup>,随着视觉图像<sup>[3-4]</sup>、触觉信息<sup>[5-6]</sup>、自然语言处理<sup>[7-8]</sup>等方式的流行与成熟,处理抓取物体检测

技术的研究较为广泛,人们提出了如基于抓取物体模型<sup>[9-11]</sup>或基于数据信息<sup>[12-14]</sup>的抓取检测模型. 而研究抓取决策是实现最终成功抓取的重要组成部分. 随着复杂生产和生活环境对机器人操作能力提出更高的要求<sup>[15]</sup>,制定合理的抓取决策规则越来越成为实现满意抓取的前提.

文献[16]基于深度卷积网络,利用触觉感知规划局部抓握调整,提出了触觉局部转换的再抓取控制

收稿日期: 2020-12-09; 录用日期: 2021-03-03.

基金项目: 广东省重点领域研发计划项目(2020B090925001); 国家自然科学基金面上项目(61973196).

责任编辑: 谢晖.

<sup>†</sup>通讯作者. E-mail: rsong@sdu.edu.cn.

策略. Berscheid等<sup>[17]</sup>提出了基于强化学习的机器人在杂乱环境中推动物体再抓取的方法,自监督学习以某种方式移动或推动对象等预抓取操作. Shukla等<sup>[18]</sup>通过提出一种GDQN结构进行物体位姿学习,实现了机器人刚性物体的抓取,其结果优于改良的MVGG16. 喻群超等<sup>[19]</sup>提出一种三级串联卷积神经网络用于未知物体抓取框学习,并在Youbot机器人上实现高准确度的抓取操作. 刘正琼等<sup>[20]</sup>通过提取工件上特征点进行形状匹配的方法实现对超视场工件的抓取策略学习. 杜学丹等<sup>[21]</sup>使用深度学习方法进行目标物体姿态与抓取位置的学习,在UR5上实现有效的抓取. 这些方法中针对的问题是固定操作下的物体抓取,且大多采用了灵巧度较低的传统二指夹持器实现物体抓取,但在生产与生活等非结构化场景中,抓取物体特征不尽相同,因此使用普通机械结构的夹持器较难实现多种物体的灵巧抓取.

与夹持器相比,灵巧手具有更高的自由度,可根据结构的不同实现多种抓取模式,所以利用灵巧手的灵巧特性解决抓取决策问题逐渐成为重要的研究方向. Jarque-Bou等<sup>[22]</sup>采用主成分分析法对手指抓取运动学降维,对不同直径及质量的圆柱抓握模式进行了研究. Rao等<sup>[7]</sup>提出了一种基于物体自然语言描述的拟人手抓取分类的确定方法. 陈小静等<sup>[23]</sup>利用神经网络建立了手部特征及物体特征与拇指-食指抓握模式的非线性映射关系,对两指抓握模式进行了预测. 周思跃等<sup>[24]</sup>采用模糊控制的方法对机器人灵巧手的抓取决策进行控制. 苏杰等<sup>[25]</sup>通过处理目标物体几何点云信息,提出了一种基于多重几何约束的未知物体抓取决策方法.

上述关于抓取决策的方法研究中,抓取的约束条件大多为尺寸、重量、摩擦系数、接触力等抓取物体特征与抓取本身. 而通常情况下,抓取是一种有目的的行为<sup>[26]</sup>,在执行某项任务时,机器人不仅需要稳定地握住工具,同时要正确使用工具,以便完成后续的任务<sup>[27]</sup>. 因此认为抓取后的任务同抓取对象是决策抓取的基本条件,在设计机器人抓取策略时需要充分考虑. 目前有关抓取约束文献中,大多只考虑物体抓取动作,而研究物体任务属性对抓取影响的相关工作较少,为了使多指灵巧手具有人类自然抓取决策能力,研究实现具有任务约束的灵巧抓取成为重要问题.

针对具有任务约束的抓取问题,本文提出一种多约束条件下机器人抓取策略学习模型,重点研究抓取物体特征约束和抓取任务属性约束条件下的三指灵

巧手抓取策略,提出以基于OBB的刚性物体抓取任务的三面映射方法,并按照人类自然抓取习惯,建立多约束抓取决策的映射关系. 采用SCM-RBF网络模型实现抓取策略的学习,并通过在真实场景的实验验证该网络模型抓取策略学习模型的准确性和实用性.

## 1 抓取策略约束条件

按照人类抓取习惯,抓取策略受到抓取物体外观、物体尺寸、完成抓取之后的任务动作等因素的影响,本文重点考虑抓取对象特征和抓取任务属性的影响结果.

### 1.1 抓取对象特征约束

在为抓取对象数据集选择特征时,着重考虑对抓取决策有显著影响的物理属性,根据目标特征如尺寸、重量、几何外形等来选择不同抓握方式,所讨论的抓取模型只包括常见的刚性物体. 表1中所示的一系列特征对人类抓握刚性物体时的选择影响最大,各个要素是人类在分析信息时在对象描述中寻找的主要特性.

表1 目标物体特征集

特征	描述	值
$L, W, H/cm$	沿正交方向尺寸	$L \geq W \geq H$
$S$	物体形状	棱柱、方体、球状

建立如图1所示的目标物体方向包围盒(OBB)的尺寸坐标系,规定 $L, W, H$ 为目标物体长、中、短三轴线长度, $q_{grasp}$ 为抓取面法向量.




图1 抓取物体坐标系

由表1中的尺寸与形状建立数据集,定义4维向量抓取目标属性特征集 $F$ 为

$$F = [L, W, H, S], L, W, H \in \mathbb{R}, S \in \Omega. \quad (1)$$

其中 $\Omega$ 为抓取物体形状集合.

### 1.2 抓取任务属性约束

人的抓取动作是有目的性的. 人对目标物体实施抓握动作时,会通过关联下一任务需求决策抓取动作. 对于常见物体,不考虑手内运动情况,人抓取的目的是可分为放置、使用、递交等.

为便于模型建立,本文研究的抓取目标在抓取前

处于静置状态. 以包围盒为基础, 将目标物体所在静置平面称为放置面 (place side,  $s_p$ ). 目标物体被执行抓取动作后, 通常会有一端处于任务状态, 将此端所在平面称为任务面 (assignment side,  $s_a$ ), 而被抓取一端所在平面成为抓取面 (grasp side,  $s_g$ ).

对于同一目标物体, 根据任务要求会产生相应任务面和抓取面. 表2列举了7种常见事物的抓取任务, 若模糊化定义各操作面标签, 任务面为标签0, 无操作面为标签1, 放置面为标签2, 可抓取面为标签3, 则可将各事物操作面属性绘制相关性热力图如图2所示. 其中横轴为物体编号, 纵轴为OBB六个面.

表2 一般事物抓取目的

编号	物体名称	抓取任务
a	水杯	将杯中水倒出
b	鼠标	拾起并放置指定位置
c	乒乓球	拾起并放置指定位置
d	书本	翻开书籍
e	纸盒	拾起并放置指定位置
f	画笔	绘制轨迹
g	羽毛球筒	倒出筒内物体

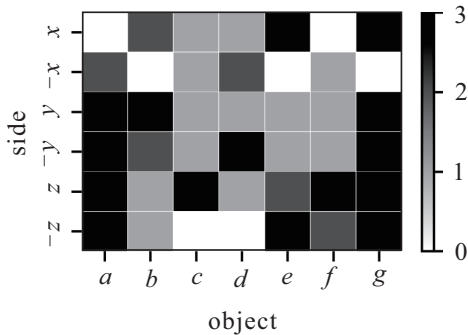


图2 事物操作面相关性热力图

观察图2发现,  $b$ 、 $c$ 、 $e$ 、 $g$  抓取中,  $s_g$  和  $s_a$  总平行于目标物体某一轴线, 而  $a$ 、 $d$ 、 $f$  中  $s_g$  平行于  $s_p$ , 不同事物间可抓取面取决于该事物的抓取任务. 在自然抓取中,  $s_g$  平行于  $s_a$  是为了便于后续任务的进行, 而考虑到物体不同, 在物体特征  $L$ 、 $W$ 、 $H$  比例较大时采用  $s_g$  平行于  $s_p$  的策略. 注意到对于物体  $c$  与  $g$  的抓取, 其放置面与任务面重合, 对于物体  $a$  与  $g$  的抓取有较多抓取面选择, 而实验中选取同类型物体相同抓取面. 因此, 三平面关系能够在一定程度上描述抓取任务要求.

定义 OBB 的法向量  $q$  为任务向量, 同图1中  $q_{grasp}$ ,  $q$  的方向总沿该物体包围盒坐标系某一坐标轴, 规定任务向量指向目标物体, 因此任务向量为

$$q = [x_q, y_q, z_q]. \quad (2)$$

定义  $\alpha$  为任务空间, 表示三平面关系, 则有

$$\alpha = [q_{s_p}, q_{s_a}, q_{s_g}]. \quad (3)$$

## 2 机器人抓取模型

不同于已有相关工作<sup>[19-25]</sup>考虑物体精密抓取, 本文抓取动作为物体外围抓取.

### 2.1 抓取规划

根据被抓取目标物的抓取面大小, 通过关联人类抓取的方式习惯, 将三指灵巧手的抓取模式规划采用三指平行抓取、三指包络抓取和二指平行抓取3种典型的抓取方式 (GTD). 3种抓取方式又分为指端抓取和强力抓取.

#### 1) 三指平行抓取.

对于抓取面较大的目标物体, 采用三指平行抓取模式. 灵巧手三指均与目标物体接触, 且三指未旋转进行抓取, 能够稳定抓取较大体积物体, 如图3所示. 图中手掌直径为  $P_{hand}$ .




图3 三指平行抓取

#### 2) 三指包络抓取.

当抓取面非方正且物体体积较大时采用三指包络抓取. 灵巧手三指均与目标物体接触, 且指1和指2旋转至与指3形成包络状态, 以实现如球状物体的抓取, 如图4所示.




图4 三指包络抓取

#### 3) 二指平行抓取.

对于抓取面小于手掌宽度  $P_{hand}$  的目标物体, 采用二指平行抓取模式. 灵巧手仅使用指1和指2进行抓取, 能够抓取较小体积物体, 如图5所示.

综上, 对于抓取模式  $h_i$ , 有

$$h_i \in T_G, W_G, R_G, T_G^e, W_G^e, R_G^e. \quad (4)$$

其中:  $T_G$  为三指平行抓取,  $W_G$  为三指包络抓取,  $R_G$  为二指平行抓取, 指端抓取使用  $e$  标示.




图5 二指平行抓取

2.2 抓取规则建立

为方便抓取决策模型的计算,对形状描述的抓取物体属性值进行模糊化处理,即S为棱柱、方体、球体,分别取值0、1、2.

对于抓取任务属性,规定抓取法向量q的方向总沿某一坐标轴,由式(2),有

$$x_q, y_q, z_q = 0 \text{ or } 1 \text{ or } -1, \quad (5)$$

$$\|x_q + y_q + z_q\| = 1. \quad (6)$$

同样,对由灵巧手的6种抓取模式组成的抓取决策空间D进行数字化处理,得到表3.

表3 抓取决策空间

参数	参数值	参数描述
$T_G$	$h_1 = 0$	三指平行抓取
$W_G$	$h_2 = 1$	三指包络抓取
$R_G$	$h_3 = 2$	二指平行抓取
$T_G^e$	$h_4 = 3$	三指平行抓取(指端)
$W_G^e$	$h_5 = 4$	三指包络抓取(指端)
$R_G^e$	$h_6 = 5$	二指平行抓取(指端)

2.3 抓取模型

抓握姿态由手指的关节角度决定.本文使用的Reflex 1型灵巧手具有5自由度,因此,每个抓握姿态D是关节角度的5维向量,定义为

$$D = [\theta_1, \theta_2, \theta_3, \theta_4, \theta_5]. \quad (7)$$

根据上一节中抓取模式分类结果,每一种抓取模式 $h_i$ 对应一个抓取姿态,则对于每个抓取模式 $h_i$ ,有

$$D_i = [\theta_{i1}, \theta_{i2}, \theta_{i3}, \theta_{i4}, \theta_{i5}]. \quad (8)$$

完整抓取约束特征集描述为

$$P = [F, \alpha]. \quad (9)$$

抓取约束描述与抓取模式之间的映射关系即为抓取决策模型,本文抓取模型表示为

$$D = f(F, \alpha), \quad (10)$$

其中f为决策函数.

3 抓取策略学习方法

抓取模型中决策函数f的分类效果极大程度上决定了模型的准确性.为保证模型结果的准确性,使用减聚类(subtractive clustering method, SCM)优化后的径向基函数(radial basis function, RBF)网络解决分类决策问题<sup>[28-29]</sup>,同时通过SCM<sup>[30-31]</sup>能够提高网络的收敛速度与模型鲁棒性.

3.1 RBF网络模型

RBF模型拓扑结构包括输入层、径向基函数层和输出层,如图6所示.




图6 RBF网络抓取决策模型拓扑结构

径向基函数使用的是高斯核函数,其函数表达式为

$$\phi_j(x) = \exp\left(-\frac{\|x - c_j\|^2}{2\sigma_j^2}\right). \quad (11)$$

其中:x为样本数据, $\phi_j$ 为径向基函数空间第j单元输出, $c_j$ 为径向基函数空间第j单元的中心向量, $\sigma_j$ 为径向基函数空间第j单元宽度向量.

设 $w_{kj}$ 为隐含层到输出层的连接权重值,则输出层输出值为

$$z_i = \sum_{j=1}^N w_{kj} \phi_j(x). \quad (12)$$

3.2 SCM-RBF

一般情况下RBF模型径向基函数空间参数的选取采用随机选取、监督学习、自组织学习等策略,由于隐含层节点数对神经网络性能有较强的影响,采用自组织学习法选取中心点.一般情况下,通过K-means聚类等学习模型确定中心点参数,但是K-means初始点的随机选取导致网络具有很强的不确定性,聚类结果不稳定.本文采用的减聚类算法以样本为候选集,根据数据集密度确定中心点,能够较好地实现中心点的选取,避免了聚类结果的随机性.

首先计算各点密度,设N个样本数据点 $x_1, x_2, \dots, x_N$ ,则第i个数据点的密度指标 $M_i$ 为

$$M_i = \sum_{j=1}^N \exp\left(-\frac{\|x_i - x_j\|^2}{\left(\frac{\gamma_\alpha}{2}\right)^2}\right), \quad (13)$$

其中 $\gamma_\alpha$ 为 $x_i$ 领域半径内数据点对该点的贡献度.由

密度计算公式计算各点指标值,选择密度指标最大的点作为首个聚类中心点  $C_{best}^1$ ,记密度指标为  $M_{best}^1$ .为确定下一聚类点,需要修正其余数据点密度指标,如下所示:

$$M_i^k = M_i^{k-1} - M_{best}^{k-1} \exp\left(-\frac{\|x_i - C_{best}^k\|}{(\gamma_\beta/2)^2}\right)^2. \quad (14)$$

通常情况下,  $\gamma_\beta = 1.5\gamma_\alpha$ ,聚类终止判别式为

$$\frac{M_{best}^{k+1}}{M_{best}^1} < r. \quad (15)$$

通过减聚类算法,得到聚类中心个数为  $k$ .因此本文先通过减聚类算法求得中心点个数,再通过上一步中的参数初始化网络,并通过监督学习训练得到模型权重,直到训练回合结束.

### 4 实验结果及分析

#### 4.1 实验设置

为验证算法的有效性,使用装有 Reflex 1 三指灵巧手的 AUBO 六自由度机械臂为抓取决策实验平台,在 Ubuntu16.04 操作系统中 Kinetic 版 ROS 环境下,实现平台的运动控制.进行实验时,将待抓取物体放置于工作台固定位置,灵巧手距离待抓取物体的距离不大于 200 mm,设置灵巧手手掌轴线总沿物体包围盒一轴,实验平台如图 7 所示.



图 7 抓取决策实验平台

网络模型参数设置和训练具体步骤如下.

step 1: 确定 RBF 网络模型结构. 根据拓扑图 6, 输入层节点数为 7, 输出层节点数为 1, 利用减聚类算法计算 750 个样本的聚类中心, 领域半径为 0.7, 利用 SCM 得到最优聚类中心 34 个, 则中间层径向基函数空间节点数为 34 个.

step 2: 数据归一化处理. 为避免量纲不同而影响分析的结果, 采用规范化的方式处理抓取属性数据以避免量纲产生的影响. 采用 Z-score 规范化, 其转换函数为

$$x^* = \frac{x - \mu}{\sigma}. \quad (16)$$

step 3: 模型函数选取. 对于神经网络中的神经元

计算过程, 采用 Sigmoid 激活函数和交叉熵损失函数组合的形式, 并引入正则化项提高模型的泛化能力. 本文使用  $L_2$  范数罚方法,  $\lambda$  值选取为 0.01, 有

$$C = C_0 + \frac{\lambda}{2n} \sum_w w^2. \quad (17)$$

step 4: 模型训练. RBF 网络模型学习率选取 0.015, 训练次数为 1 500 次, 分别利用 K-means 聚类法和梯度下降算法训练径向基函数中心点参数.

#### 4.2 抓取样本库建立与模型训练

由式 (9) 建立的抓取约束特征集  $P$  建立样本空间  $U$ , 将其用于算法的训练与测试. 该数据集中包含 750 个样本对象, 包括简单方体、简单柱体、简单球体以及水杯、眼镜盒、螺丝刀等生活常用物品, 对每个样本在多个任务模式下进行数据采集, 每个对象抓取属性定义为  $P_i$ . 实验样本数据如表 4 所示.

表 4 抓取决策空间

序号	输入							输出
	$x$	$y$	$z$	$S$	$s_p$	$s_a$	$s_g$	
1	13.00	12.00	8.00	0	5	4	3	0
2	5.00	5.00	5.00	1	2	4	1	3
3	9.00	9.00	5.00	0	3	4	1	5
4	11.00	11.00	11.00	0	5	5	1	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
750	19.00	19.00	19.00	2	3	1	4	2

利用 BPNN、Kmean RBFNN 和 SCM-RBFNN 三种不同模型对样本进行训练, 训练集样本 600 个, 测试集样本 150 个, 3 种网络训练准确率、测试准确率效果对比如图 8 和图 9 所示, 损失值对比如图 10 所示.




图 8 训练准确率




图 9 测试准确率




图10 损失值

由训练结果可知,利用SCM算法优化的RBF网络训练效果较好,训练准确率达到96.0%,测试准确率达到92%,但训练误差值稍高于BP网络。Kmeans RBF网络表现效果较二者较差,表明SCM优化RBF网络能够进行较为准确的抓取决策,且成功率较高。

### 4.3 实物抓取实验

为进一步验证所提出算法的有效性,设置真实场景下的抓取实验以测试算法准确率。如图9所示,在灵巧手可抓握范围内设置23种物体抓取实验,包括13个不同形状积木类物体以及10种至少有一轴长度小于200 mm的生活常见物品。




图11 抓取物体集合

将待抓取的23种物体单独放置在工作台上进行实验,考虑到物体姿态问题,规定物体坐标系与桌面坐标系一致。每个待抓取物体均设置两组任务,每组任务设置10次实验。任务1为将物体放置到指定位置,任务2为根据待抓取物体的特性各自设置特定任务,积木类物体任务2均为指定面放置,生活类物体任务2描述如表5所示。


表5 抓取物体任务

物体名称	任务2	物体名称	任务2
水杯	杯中水倒出	羽毛球筒	倒出筒内物体
胶带	一端用于粘贴	马克笔	使用一端绘制
乒乓球	放入箱中	螺丝刀	使用一端拧螺丝
书籍	翻阅	订书机	使用一端订纸
纸盒	倒出盒内物体	鼠标	放入箱中

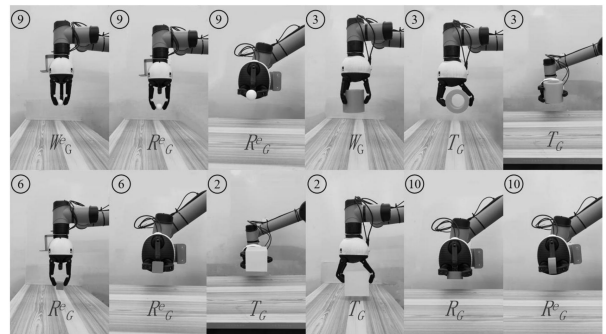
在抓取实验中,首先利用网络模型进行物体抓取决策,然后通过灵巧手执行抓取动作,抓取成功的评判标准为:机械臂抓取物体垂直离开工作台,并保持5s以上不掉落。抓取过程手指不与工作台发生接触,

物体被抓取后不与桌面发生碰撞。


任务1:不同物体抓取。以图12(a)积木抓取为例,在任务1放置的指定位置中,5号球和3号圆柱决策结果为 $W_G$ ,4号圆柱、1号方体、8号圆柱和9号球决策结果分别为 $T_G^e$ 、 $T_G$ 、 $W_G^e$ 、 $R_G^e$ 。该实验中积木类抓取成功130次,生活类物体抓取成功94次。结果表明,根据被抓取物体的形状与尺寸,对比得出模型在物体特征的约束下能够决策出符合人类抓取习惯的抓取策略。



(a) 任务1下积木抓取结果



(b) 任务2下积木抓取结果



(c) 多约束条件生活物品抓取结果

图12 抓取结果

任务2:同一物体抓取。以积木抓取为例,在任务1和任务2的抓取中,根据任务约束的不同,决策结果如图12(b)所示。如在9号球的决策中,由于包络抓取能够更加稳定地移动被抓取物体,任务1的决策结果为 $W_G^e$ ,而为保证指定面能够完成后续任务,任务2的决策结果为 $R_G^e$ ,结果符合人类的抓取习惯。其中积木类和生活物体分别抓取成功126次和95次,表明该模型能够在不同任务的约束下,对相应物体决策出合适的抓取策略,实现成功抓取。

任务3:多约束条件下不同物体抓取。以生活类物品为例,在物体特征和任务属性的多约束条件下,

抓取结果如图12(c)所示. 如水杯的抓取中,为了平稳放置水杯,模型决策结果为 $W_G$ ,而为了完成将杯中水倒出任务,模型决策结果为 $T_G$ ,与3号圆柱积木的指定面放置抓取结果相同,表明不同物体的任务可映射到简单物体包围盒形式进行分析.

表6中所示数据为13种积木和10种生活类在多约束条件下的抓取成功率,其中包括260次积木抓取和200次生活类物体抓取.

表6 多约束条件下抓取结果

物体类别	成功次数	成功率 / %
积木类	256	98.46
生活类	189	94.50
总计	445	96.74

以上抓取结果表明,本文研究的多约束条件下机器人抓取决策的方法具备以下特性: 1) 针对不同任务下不同物体的抓取决策,学习算法根据抓取习惯,实现最优抓取模式的决策,表明该方法具有一定的智能抓取特性. 2) 对于实验中未学习过的生活物品样本数据,该算法仍能做出较好决策,表明该学习模型具有较好的鲁棒性,在抓取新目标时可实现最优决策.

虽然模型训练中测试率为92%,但在本文实验中抓取成功率为96.74%,其原因为存在决策错误但抓取成功的情况,且该类型抓取不妨碍物体任务面进行后续工作,因此将在下一步工作中考虑以任务完成情况评估决策结果.

机器人对部分抓取时会遇到抓取失败的情况,如物体较重、表面光滑、重量分布不均、抓取面法向尺寸过长等情况,在后续工作中将加入物体抓取力约束、重量预测等研究内容,进一步提升抓取适应性.

## 5 结论

本文针对机器人在抓取具有后续任务属性的物体时的抓取决策问题,给出了一种基于多约束条件下抓取策略学习方法. 利用包围盒方式描述待完成的抓取任务,将物体特性和任务属性作为约束条件,通过映射人类的抓取习惯实现抓取模型的建立,采取SCM优化RBF网络学习抓取决策模型,实验表明该决策模型具有良好的精确性,实现了多类型物体不同任务的抓取决策,验证了模型的实用性. 当抓取任务进一步复杂时,可利用多维凸包对物体进行建模分析,抓取物体各属性面存在情况将进一步增多,如何通过深度学习的方法学习任务约束的多维凸包抓取模型,是机器人抓取领域亟待解决的问题.

## 参考文献(References)

- [1] 秦方博,徐德. 机器人操作技能模型综述[J]. 自动化学报, 2019, 45(8): 1401-1418.  
(Qin F B, Xu D. Review of robot manipulation skill models[J]. Acta Automatica Sinica, 2019, 45(8): 1401-1418.)
- [2] 刘亚欣,王斯瑶,姚玉峰,等. 机器人抓取检测技术的研究现状[J]. 控制与决策, 2020, 35(12): 2817-2828.  
(Liu Y X, Wang S Y, Yao Y F, et al. Recent researches on robot autonomous grasp technology[J]. Control and Decision, 2020, 35(12): 2817-2828.)
- [3] Deng Z, Gao G, Frintrop S, et al. Attention based visual analysis for fast grasp planning with a multi-fingered robotic hand[J]. Frontiers in Neurorobotics, 2019, 13(60): 1-12.
- [4] Choi C, Schwarting W, DelPreto J, et al. Learning object grasping for soft robot hands[J]. IEEE Robotics and Automation Letters, 2018, 3(3): 2370-2377.
- [5] Hirayama C, Watanabe T, Kawabata S, et al. Acquiring grasp strategies for a multifingered robot hand using evolutionary algorithms[C]. IEEE International Conference on Systems, Man, and Cybernetics. Banff, 2017: 1597-1602.
- [6] Spiers A J, Liarakapis M V, Calli B, et al. Single-grasp object classification and feature extraction with simple robot hands and tactile sensors[J]. IEEE Transactions on Haptics, 2016, 9(2): 207-220.
- [7] Rao A B, Krishnan K, He H S. Learning robotic grasping strategy based on natural-language object descriptions[C]. IEEE/RSJ International Conference on Intelligent Robots and Systems. Madrid, 2018: 882-887.
- [8] Rao A B, Li H, He H S. Object recall from natural-language descriptions for autonomous robotic grasping[C]. IEEE International Conference on Robotics and Biomimetics. Dali, 2019: 1368-1373.
- [9] Yun L, Yu S. Robot grasp planning based on demonstrated grasp strategies[J]. The International Journal of Robotics Research, 2015, 34(1): 26-42.
- [10] Su J H, Qiao H, Liu C K, et al. Grasping objects: The relationship between the cage and the form-closure grasp[J]. IEEE Robotics & Automation Magazine, 2017, 24(3): 84-96.
- [11] 郑晶怡,李恩,梁自泽. 基于形状先验模型的平面型工件抓取位姿检测[J]. 机器人, 2017, 39(1): 99-110.  
(Zheng J Y, Li E, Liang Z Z. Grasping posture determination of planar workpieces based on shape prior model[J]. Robot, 2017, 39(1): 99-110.)
- [12] Song D, Ek C H, Huebner K, et al. Multivariate discretization for Bayesian Network structure learning in robot grasping[C]. IEEE International Conference on Robotics and Automation. Shanghai, 2011: 1944-1950.
- [13] Santina C D, Arapi V, Averta G, et al. Learning from humans how to grasp: A data-driven architecture for autonomous grasping with anthropomorphic soft hands[J]. IEEE Robotics and Automation Letters, 2019,

- 4(2): 1533-1540.
- [14] 仲训杲, 徐敏, 仲训昱, 等. 基于多模特征深度学习的机器人抓取判别方法[J]. 自动化学报, 2016, 42(7): 1022-1029.  
(Zhong X G, Xu M, Zhong X Y, et al. Multimodal features deep learning for robotic potential grasp recognition[J]. Acta Automatica Sinica, 2016, 42(7): 1022-1029.)
- [15] 刘乃军, 鲁涛, 蔡莹皓, 等. 机器人操作技能学习方法综述[J]. 自动化学报, 2019, 45(3): 458-470.  
(Liu N J, Lu T, Cai Y H, et al. A review of robot manipulation skills learning methods[J]. Acta Automatica Sinica, 2019, 45(3): 458-470.)
- [16] Hogan F R, Bauza M, Canal O, et al. Tactile regrasp: Grasp adjustments via simulated tactile transformations[C]. IEEE/RSJ International Conference on Intelligent Robots and Systems. Madrid, 2018: 2963-2970.
- [17] Berscheid L, MeiSSner P, Kröger T. Robot learning of shifting objects for grasping in cluttered environments[C]. IEEE/RSJ International Conference on Intelligent Robots and Systems. Macao, 2019: 612-618.
- [18] Shukla P, Kumar H, Nandi G C. Robotic grasp manipulation using evolutionary computing and deep reinforcement learning[J]. Intelligent Service Robotics, 2021, 14(1): 61-77.
- [19] 喻群超, 尚伟伟, 张驰. 基于三级卷积神经网络的物体抓取检测[J]. 机器人, 2018, 40(5): 762-768.  
(Yu Q C, Shang W W, Zhang C. Object grasp detecting based on three-level convolution neural network[J]. Robot, 2018, 40(5): 762-768.)
- [20] 刘正琼, 万鹏, 凌琳, 等. 基于机器视觉的超视场工件识别抓取系统[J]. 机器人, 2018, 40(3): 294-300.  
(Liu Z Q, Wan P, Ling L, et al. Recognition and grabbing system for workpieces exceeding the visual field based on machine vision[J]. Robot, 2018, 40(3): 294-300.)
- [21] 杜学丹, 蔡莹皓, 鲁涛, 等. 一种基于深度学习的机械臂抓取方法[J]. 机器人, 2017, 39(6): 820-828.  
(Du X D, Cai Y H, Lu T, et al. A robotic grasping method based on deep learning[J]. Robot, 2017, 39(6): 820-828.)
- [22] Jarque-Bou N, Gracia-Ibáñez V, Sancho-Bru J L, et al. Using kinematic reduction for studying grasping postures an application to power and precision grasp of cylinders[J]. Applied Ergonomics, 2016, 56: 52-61.
- [23] 陈小静, 彭培成, 张高峰, 等. 基于BP神经网络的仿人两指末端执行器抓握模式预测[J]. 河南理工大学学报: 自然科学版, 2020, 39(2): 97-102.  
(Chen X J, Peng P C, Zhang G F, et al. Prediction of humanoid two-finger end-effector grasp type based on BP neural network[J]. Journal of Henan Polytechnic University: Natural Science, 2020, 39(2): 97-102.)
- [24] 周思跃, 龚振邦, 袁俊. 基于模糊逻辑控制的机器人灵巧手的抓取方式[J]. 计算机工程, 2006, 32(23): 183-185.  
(Zhou S Y, Gong Z B, Yuan J. Grasp modes of robot dexterous hand based on fuzzy logic control[J]. Computer Engineering, 2006, 32(23): 183-185.)
- [25] 苏杰, 张云洲, 房立金, 等. 基于多重几何约束的未知物体抓取位姿估计[J]. 机器人, 2020, 42(2): 129-138.  
(Su J, Zhang Y Z, Fang L J, et al. Estimation of the grasping pose of unknown objects based on multiple geometric constraints[J]. Robot, 2020, 42(2): 129-138.)
- [26] Feix T, Romero J, Schmiedmayer H B, et al. The GRASP taxonomy of human grasp types[J]. IEEE Transactions on Human-Machine Systems, 2016, 46(1): 66-77.
- [27] Cini F, Ortenzi V, Corke P, et al. On the choice of grasp type and location when handing over an object[J]. Science Robotics, 2019, 4(27): 1-13.
- [28] 胡晓伟, 安立雄, 王宪伦. 基于GA优化RBF神经网络的机器人轨迹规划[J]. 计算技术与自动化, 2020, 39(1): 18-22.  
(Hu X W, An L X, Wang X L. Robot trajectory planning based on GA optimized RBF neural network[J]. Computing Technology and Automation, 2020, 39(1): 18-22.)
- [29] 杨超, 郭佳, 张铭钧. 基于RBF神经网络的作业型AUV自适应终端滑模控制方法及实验研究[J]. 机器人, 2018, 40(3): 336-345.  
(Yang C, Guo J, Zhang M J. Adaptive terminal sliding mode control method based on RBF neural network for operational AUV and its experimental research[J]. Robot, 2018, 40(3): 336-345.)
- [30] 张远绪, 程焕新, 宋生建. 基于改进的RBF神经网络的滚动轴承故障诊断[J]. 工业仪表与自动化装置, 2018(6): 31-34.  
(Zhang Y X, Cheng H X, Song S J. Fault diagnosis of rolling bearing based on improved RBF neural network[J]. Industrial Instrumentation & Automation, 2018(6): 31-34.)
- [31] Shan Y F, Sun L, Fu H, et al. Gas sensor fault diagnosis based on wavelet packet and RBF neural network identification[J]. Chinese Journal of Sensors and Actuators, 2015, 28(2): 278-283.

## 作者简介

崔涛(1998—), 男, 硕士生, 从事机器学习、机器人柔性操作的研究, E-mail: 202014761@mail.sdu.edu.cn;

李凤鸣(1984—), 女, 博士生, 从事机器学习、机器人柔性操作的研究, E-mail: lifengming@sucro.org;

宋锐(1975—), 男, 教授, 博士生导师, 从事智能机器人控制、机器人柔性作业等研究, E-mail: rsong@sdu.edu.cn;

李贻斌(1960—), 男, 教授, 博士生导师、从事智能机器人、机器人柔性操作等研究, E-mail: liyb@sdu.edu.cn.

(责任编辑: 郑晓蕾)