DOI: 10. 19650/j. cnki. cjsi. J2311989

基于前馈隐马尔可夫模型的机器人演示 轨迹精准重构方法研究

苏永彬,洪瑞康,刘暾东

(厦门大学萨本栋微米纳米科学技术研究院 厦门 361005)

摘 要:针对隐马尔可夫模型在机器人演示轨迹编码过程中存在的参数估计效率低,轨迹重构精度差的问题,提出了一种基于 前馈隐马尔可夫模型的机器人演示学习方法。该方法通过林德-布佐-格雷(LBG)算法对采集的多条演示轨迹进行关键点识 别,利用最小失真准则选取合适的轨迹计算模型初始化参数,结合鲍姆-韦尔奇算法完成模型参数估计。在此基础上,通过维 特比算法计算每个样本点最可能的归属状态,并采用极大似然估计对归属每个状态的样本点重新计算状态参数,最后通过高斯 混合回归获得重构轨迹。为验证算法的有效性,设计了手写字母轨迹数据集和晶圆机械臂自动上料轨迹的演示学习实验,并引 入平均弗雷歇距离定量评估轨迹重构精度。实验结果表明:采用本文所提方法的重构轨迹在晶圆机械臂自动上料轨迹中的平 均弗雷歇距离为 5.49,较传统方法提升了 15.15% 的轨迹重构精度,具有良好的应用前景。

关键词: 演示学习;LBG 算法;隐马尔可夫模型;轨迹重构

中图分类号: TH241.2 文献标识码: A 国家标准学科分类代码: 510.8050

Research on the precise reconstruction method of robot demonstration trajectory based on feedforward hidden Markov model

Su Yongbin, Hong Ruikang, Liu Tundong

(Pen-Tung Sah Institute of Micro-Nano Science and Technology, Xiamen University, Xiamen 361005, China)

Abstract: A method for robot demonstration learning based on forward hidden Markov models is proposed to address the problems of low parameter estimation efficiency and poor trajectory reconstruction accuracy in the process of robot demonstration trajectory encoding. The method identifies key points of multiple collected demonstration trajectories using the Linde-Buzo-Gray (LBG) algorithm, selects appropriate trajectory calculation model initialization parameters using the minimum distortion criterion, and completes model parameter estimation by combining the Baum-Welch algorithm. On this basis, the Viterbi algorithm is used to calculate the most likely attribution state of each sample point, and the maximum likelihood estimation is utilized to recalculate the state parameters of each sample point attributed to each state. Finally, the reconstructed trajectory dataset and a demonstration learning experiment of wafer mechanical arm automatic feeding trajectory are designed. The average Fréchet distance is introduced to quantitatively evaluate the trajectory reconstruction accuracy. The experimental results show that the proposed method improves the trajectory reconstruction accuracy by 15. 15% compared to traditional methods, with an average Fréchet distance of 5. 49 in the automatic wafer loading trajectory of the robotic arm, which indicates promising application prospects.

Keywords: demonstration learning; LBG algorithm; hidden Markov model; trajectory reconstruction

0 引 言

机器人运动轨迹的演示学习 (learning from

收稿日期:2023-10-04 Received Date: 2023-10-04

demonstration, LFD)是指机器人学习由专家提供的演示轨迹 来获取运动技能的方法^[1],用于解决传统离线示教编程带来 的学习成本高、过程繁琐和适应性差的问题^[2],为机器人的 轨迹学习提供了一个简单友好的学习框架^[3]。

演示学习分为3个阶段:演示轨迹的获取:轨迹编 码;轨迹的重构和泛化^[4]。其中,轨迹编码又称轨迹学习 与建模,是演示学习的关键步骤,能够将所有的演示轨迹 总结为一个具体的带参数的模型,可进行轨迹的重构和 泛化。按照演示轨迹的数量不同,演示轨迹的学习与建 模方法可分为两大类:以动态运动基元[5]为代表的单轨 迹建模;以高斯混合模型[6-7]和隐马尔可夫模型[8-9]等统 计学习方法为代表的多轨迹建模。基于动态运动基元单 轨迹建模在许多演示学习方法[10-12]中得到广泛的应用, 不仅能够编码轨迹和姿态,也能对力进行组合编码;但由 于单轨迹编码的随机性和不确定性,在实际工程应用中 局限性很大[13]。多轨迹建模方法采用相同任务的几条 重复演示轨迹的概率表示,消除了单一轨迹的随机性影 响,因此更适合于工程应用。其中,隐马尔可夫模型对顺 序序列数据的时空变化表现出更强的鲁棒性,成为机器 人演示学习领域使用最广泛的方法之一^[14]。

隐马尔可夫模型是功能强大的统计模型,可用于对 机器人的运动进行编码,并从一组演示轨迹中找到概率 最高的状态路径[15],已成功应用于许多演示学习方法 中[14,16-19]。基于隐马尔可夫模型的机器人运动轨迹编码 的主流方案是:利用隐状态个数和数据点个数计算的固 定值进行参数初始化^[20],通过隐状态分布的均值^[18]或关 键点的聚类和插值[14]来重构演示轨迹。然而固定值初 始化的方法在参数估计的迭代过程中收敛速度慢,效率 不高。此外通过隐状态分布的均值或关键点聚类和插值 的轨迹重构方法精度差,在晶圆上下料机器人、晶粒分拣 机器人等轨迹重构精度要求高的场景并不适用。为此, 本文提出了一种基于前馈隐马尔可夫模型的机器人演示 轨迹精准重构方法。首先,为解决隐马尔可夫模型参数 估计效率低的问题,提出了一种基于林德-布佐-格雷 (Linde-Buzo-Gray, LBG)算法^[21]和最小失真准则^[14]来寻 找最优演示轨迹的初始化方法。其次,为实现演示轨迹 的精准重构,在隐马尔可夫模型的隐状态参数求解上引 入前馈技术,并结合高斯混合回归来重构演示轨迹。最 后,开展基于手写字母轨迹数据集和晶圆机械臂自动上 料轨迹的演示学习实验,并引入弗雷歇距离以定量评估 轨迹重构精度,验证了所提方法在参数估计效率和轨迹 重构精度上的优越性。

1 隐马尔可夫模型的参数辨识

为实现多演示轨迹下隐马尔可夫模型的高效参数辨 识,本文提出了一种基于 LBG 算法的参数初始化方法, 并结合鲍姆-韦尔奇^[22]算法进行迭代优化,从而完成参 数的估计。首先将获取的多条轨迹进行特征向量的提 取,采用归一化速度和位置组成的向量来作为候选关键 点的特征向量,然后将所有的候选关键点通过 LBG 算法 进行聚类,得到 k 个关键点(聚类中心),最后将所有轨迹 分别与聚类中心通过最小失真准则计算最优轨迹,并将 其作为隐马尔可夫模型的初始化参数的设置依据。

1.1 隐马尔可夫模型

隐马尔可夫模型是一种有向图模型,可以表述为包 含一系列隐藏状态变量和相应的观测变量序列的马尔可 夫链,已广泛应用于语音识别,文字识别和故障诊断等领 域。隐马尔可夫模型的图形表示如图1所示,*t*时刻的隐 藏状态用*S_i*表示,观测状态用*O_i*表示。模型的状态空间 $Q = \{q_1,q_2,\dots,q_N\}, 观测空间 V = \{v_1,v_2,\dots,v_M\}, 用状态$ $转移概率矩阵<math>A = \{a_{ij}\}$ 来表示从当前状态转移到下一个 状态的概率分布,其中*i*,*j* $\in \{1,2,\dots,N\}$,具体表示为 a_{ij} = $P(S_{t+1} = q_i | S_t = q_i)$ 。用观测概率矩阵 $B = \{b_i(k)\}$ 来 表示当前状态下对应不同观测结果的概率分布,其中 $i = \{1,2,\dots,N\}, j = \{1,2,\dots,M\},$ 具体表示为 $b_i(k) =$ $P(O_i = v_k | S_i = q_i)$ 。模型的初始状态 $\pi = \{\pi_1, \pi_2, \dots, \pi_N\},$ 其中 $\pi_i = P(S_1 = q_i)$ 。上述的 π, A, B 即为隐马尔可 夫模型的三要素,因此一个完整的隐马尔可夫模型可以 由一组参数 $\lambda = \{\pi, A, B\}$ 来描述。



Fig. 1 Graphical representation of HMM

对于机器人运动轨迹的编码,通常采用一系列的高 斯分布来作为隐马尔可夫模型的隐状态,可表示为 $q_i \sim N(\mu_i, \Sigma_i)$,其中 μ_i 和 Σ_i 分别表示状态 q_i 所属的高斯分 布的均值和方差。以手写字母 M 为例,对 5 条轨迹进行 隐马尔可夫建模,状态数量设置为 10,得到的隐状态高 斯分布如图 2(a)所示,图中不同颜色的椭圆区域对应不 同状态的高斯分布。与之对应的状态转移概率如 图 2(b)所示,箭头颜色越深表示概率越大。因此一组演 示轨迹就由隐马尔可夫模型编码完成。

1.2 基于 LBG 算法的模型参数初始化

LBG 算法是 k 均值聚类算法的变种,能将一组输入 数据划分为多个聚类,并且不依赖于初始条件。其核心 思想是从一个数据集群开始,通过不断迭代将集群数量 加倍,直到满足终止条件。假设采集到的一组机器人运 动轨迹集定义为 $X_m = \{(x_{1,m}, x_{2,m}, \cdots, x_{N_m,m})\}_{m=1}^{M}$,其中 M表示轨迹数量, N_m 表示第 m条轨迹的采样点数量,每 个采样点是一个 D 维向量,即 $x_{n,m} = (x_{n,m}^1, x_{n,m}^2, \cdots, x_{N_m,m}^n)$ 。每个采样点的速度用当前点与下一个点的位置差



Fig. 2 HMM encoding process

表示,即 $v_{n,m}^{d} = x_{n+1,m}^{d} - x_{n,m}^{d}$,终点处设为0。因此每一个采 样点可以用一个包含位置和速度信息的归一化特征向量 来描述,定义为 $T = \{\alpha_{n,m}\}, 其中 \alpha_{n,m} = [\hat{x}_{n,m}, \hat{v}_{n,m}]^{T},$ $n = 1, 2, \dots, N_{m}, m = 1, 2, \dots, M_{o}$ 给定失真阈值和聚类中 心个数,通过 LBG 算法可以得到所有的聚类中心集合。 其中 LBG 算法的伪代码如算法 1 所示。

算法1 LBG 算法

输入:轨迹的采样点集 T,失真阈值 ε(一个很小的正数),聚 类中心个数 k

输出:k个聚类中心以及每个样本点的归属

1)初始化:令N = 1,设置聚类中心 c_1^* 为所有样本的均值,计 算总失真度 D_{m*}^* :

$$c_{1}^{*} = \frac{1}{\sum_{m=1}^{M} N_{m}} \sum_{m=1}^{M} \sum_{n=1}^{N_{m}} \boldsymbol{\alpha}_{n,m}, D_{ave}^{*} = \frac{1}{\sum_{m=1}^{M} N_{m}} \sum_{m=1}^{M} \sum_{n=1}^{N_{m}} || \boldsymbol{\alpha}_{n,m} - \boldsymbol{c}_{1}^{*} ||^{2}$$

2)分裂:对*i* = 1,2,…,*N*,聚类中心分别为:

$$= (1 + \varepsilon) \boldsymbol{c}_{i}^{*}, \boldsymbol{c}_{N+i}^{0} = (1 - \varepsilon) \boldsymbol{c}_{i}^{*}$$

 $3) \diamondsuit N = 2N$

 \boldsymbol{c}^0

4) 令初始失真度 $D_{ave}^{0} = D_{ave}^{*}$, 令 i = 0, 开始迭代:

(1) 为 T 中的所有样本寻找归属的聚类中心:

$$n^* = \underset{0 < n < N_m}{\operatorname{argmin}} \|\boldsymbol{\alpha}_{n,m} - \boldsymbol{c}_n^i\|^2$$
$$Q(\boldsymbol{\alpha}_{n,m}) = \boldsymbol{c}^i *$$

(2) 对于 n=1,2,…,N,通过以下公式更新所有聚类中心

$$\boldsymbol{c}_{n}^{i+1} = \frac{\sum_{\boldsymbol{Q}(\boldsymbol{\alpha}_{n,m}) = c_{n}^{i}} \boldsymbol{\alpha}_{n,m}}{\sum_{\boldsymbol{Q}(\boldsymbol{\alpha}_{n,m}) = c_{n}^{i}} 1}$$

 $(3) \Leftrightarrow i = i + 1$

(4) 计算当前总失真度

$$D_{ave}^* = \frac{1}{\sum_{m=1}^{M} N_m}$$

$$\sum_{m=1}^{M} \sum_{n=1}^{N_m} \| \boldsymbol{\alpha}_{n,m} - Q(\boldsymbol{\alpha}_{n,m}) \|^2$$
(5) 计算相对失真改进量 $\boldsymbol{\omega} = (D_{ave}^{i-1} - D_{ave}^i)/D_{ave}^{i-1}$
(6) 如果 $\boldsymbol{\omega} > \boldsymbol{\varepsilon}$, 继续迭代
否则,对于 $n = 1, 2, \dots, N$, 当前聚类中心为 $\boldsymbol{c}_n^* = \boldsymbol{c}_n^i$, 终
止迭代
5) 如果 $N < k$, 重复步骤 2)~4)
6) 终止,得到 k 个聚类中心 $\{ \boldsymbol{c}_1^*, \boldsymbol{c}_2^*, \dots, \boldsymbol{c}_k^* \}$, 以及每个样本
点的归属

得到所有聚类中心后,采用最小失真准则来选择一条合适的轨迹 X_s,并以此来计算隐马尔可夫模型的参数 初始化参数,其选择依据如下公式:

$$\delta = \underset{1 \le m \le M}{\operatorname{argmin}} \frac{\sum_{n=1}^{N_m} \left(\boldsymbol{\alpha}_{n,m} - c(\boldsymbol{\alpha}_{n,m}) \right)}{N_m}$$
(1)

其中, $c(\boldsymbol{\alpha}_{n,m})$ 为样本 $\boldsymbol{\alpha}_{n,m}$ 所属的聚类中心。然后 令 $T = \{\boldsymbol{\alpha}_{n,\delta}\}$,其中 $\boldsymbol{\alpha}_{n,\delta} = [\hat{\boldsymbol{x}}_{n,\delta}, \hat{\boldsymbol{v}}_{n,\delta}]^{\mathrm{T}}, n = 1, 2, \dots, N_{\delta}$,再 执行 LBG 算法,得到单条轨迹 X_{δ} 的 k 个关键点 $\{\boldsymbol{\delta}_1, \boldsymbol{\delta}_2, \dots, \boldsymbol{\delta}_k\}$ 。以手写字母 R 为例,令 k = 16,原始轨 迹样本点分布如图 3(a)所示,通过 LBG 算法得到的关键 点分布如图 3(b)所示。





Fig. 3 Extract key points by LBG algorithm

对于轨迹 X_{δ} 的每个样本点 $x_{n,\delta}$,都被映射到一个隐 状态 $s_{n,\delta}$, 且 $s_{n,\delta} \in \{\delta_1, \delta_2, \dots, \delta_k\}$ 为通过 LBG 算法求出 的关键点。此外,对于每条轨迹的每个样本点 $x_{n,m}$,都被 映射到一个观测状态 $o_{n,m}$, 且 $o_{n,m} \in \{c_1^*, c_2^*, \dots, c_k^*\}$ 为 通过 LBG 算法求出的聚类中心,因此观测序列可定义为 $O = \{O_m = (o_{1,m}, o_{2,m}, \dots, o_{n,m})\}_{m=1}^M$ 。则隐马尔可夫模型 的初始化参数定义为:1) 状态转移矩阵 A 的元素: $a_{i,i} =$ $1 - N_{\delta}/n_{\delta}(\delta_i), a_{i,i+1} = N_{\delta}/n_{\delta}(\delta_i),$ 其中 $n_{\delta}(\delta_i)$ 表示为轨 迹 X_{δ} 中归属于状态 δ_i 的样本点个数;2) 观测概率矩阵 B的元素: $b_i(k) = n_{i,\delta}(c_k^*)/n_{\delta}(\delta_i),$ 其中 $n_{i,\delta}(c_k^*)$ 表示参考 轨迹中在处于状态 δ_i 的情况下观测到 c_k^* 的样本点个数; 3)初始状态 π 定义为: $\pi = [1,0,\dots,0]_o$

1.3 基于鲍姆-韦尔奇算法的 HMM 参数估计

鲍姆-韦尔奇算法是一种用于寻找隐马尔可夫模型 参数的算法,是期望最大化算法的一个特例。其核心的 迭代思想是在n+1次迭代时,在E步求出联合概率分布 $P(O, |\lambda)$ 基于条件 $P(I|O,\lambda^n)$ 的期望,其中O表示观 测序列,I表示状态序列, $\lambda = \{\pi, A, B\}$ 是隐马尔可夫模 型的参数, λ^n 表示第n次迭代时的模型参数。然后在 M 步求大化这个期望,就能得到更新后的模型参数。其迭 代公式如下:

$$\pi_i^{n+1} = \gamma_1(i) \tag{2}$$

$$a_{i,j}^{n+1} = \sum_{i=1}^{T-1} \xi_i(i,j) / \sum_{i=1}^{T-1} \gamma_i(i)$$
(3)

$$b_{j}(k)^{n+1} = \sum_{i=1}^{r} \gamma_{i}(j) I(o_{i} = v_{k}) / \sum_{i=1}^{r} \gamma_{i}(j)$$
(4)

其中, $\gamma_t(i)$ 表示在观测到序列O的条件下,t时刻处 于状态 q_i 的概率,即:

$$\boldsymbol{\gamma}_{i}(t) = P(i_{t} = q_{i} \mid \boldsymbol{O}, \boldsymbol{\lambda})$$
(5)

 $\xi_i(i,j)$ 表示在观测到**O**的条件下,*t*时刻处于状态 q_i ,且t + 1时刻处于 q_i 的概率,即:

$$\boldsymbol{\xi}_{i}(i,j) = P(i_{i} = q_{i}, i_{i+1} = q_{j} \mid \boldsymbol{O}, \boldsymbol{\lambda})$$
(6)

其中, $I(o_t = v_k)$ 的值由以下条件判断: a_t 时刻观测 到 v_k 时其值为 1, 否则为 0。鲍姆 – 韦尔奇算法具体可由 如下伪代码如算法 2 所示。

算法2 鲍姆-韦尔奇算法

输入:观测序列 $O = \{o_1, o_2, \dots, o_T\}$,失真阈值 ε (一个很小的 正数) 输出:HMM 模型参数 λ^* 1)初始化:令 $\lambda' = [A^0, B^0, \pi^0]$ 2)令 n = 0,开始迭代: (1)根据式(2)~(4)计算得到 λ^{n+1} (2)如果 $|\lambda' - \lambda^{n+1}| > \varepsilon$,令 $n = n + 1, \lambda' = \lambda^{n+1}$ 否则,迭代终止

3)终止,得到模型参数 $\lambda^* = [A^{n+1}, B^{n+1}, \pi^{n+1}]$

整体参数估计算法的流程框架由图 4 给出,首先对 输入的演示轨迹执行 LBG 算法,得到 k 个聚类中心 c_k , 使用最小失真准则选取和聚类中心误差最小的轨迹 X_s 作为参考轨迹,对参考轨迹点执行 LBG 算法得到 k 个 关键点 $\{\delta_1, \delta_2, \dots, \delta_k\}$ 。然后以聚类中心为观测状态, 关键点为隐状态,构建隐马尔可夫链,参考 X_s 中样本点 的归属隐状态和观测值,计算隐马尔可夫模型的初始 化参数,最后使用鲍姆-韦尔奇算法完成参数估计。同 样以字母 R 为例,输入 5 组轨迹数据,每组轨迹采样 50个数据点,如图 5(a)所示,设置状态数为 10,在执行 鲍姆-韦尔奇算法后得到的状态可视化为 10 个高斯分 布,如图 5(b)所示。





2 基于前馈隐马尔可夫模型的轨迹重构 算法

完成隐马尔可夫模型的参数估计后,为提高重构轨 迹的精度,本文提出了一种基于前馈隐马尔可夫模型的 轨迹重构算法,首先对获取的轨迹点集通过维特比算 法^[23]计算每个样本点最大概率的归属状态,然后对属于 同状态的样本点通过极大似然估计,重新计算该状态的 参数,最后通过高斯混合模型和高斯混合回归进行轨迹 的重构。

2.1 维特比算法

已知隐马尔可夫模型产生的观测序列,要求解产生 这个观测序列最可能的隐藏状态序列,通常使用维特比 算法。维特比算法是一种动态规划算法,能够保证所得 的状态序列是全局最优的。其基本思想包含以下3点: 1)如果最优路径(概率最大)经过状态转移网络的某一 个节点,则从起始节点到该节点的子路径也一定是最优 的;2)假设在 t 时刻有 k 个状态,从起始节点到 t 时刻的 k 个状态有 k 条最短路径,且最优路径必定经过其中一条;
 3)在计算 t + 1 状态时,只需要计算从开始到 t 时刻的 k 个 状态的最短路径,和 t 时刻到 t + 1 时刻的最短路径即 可。其伪代码如算法 3 所示。

算法3 维特比算法

输入:模型参数 $\lambda = [A, B, \pi]$ 和观测序列 $O = \{o_1, o_2, \dots, o_T\}$ 输出:最优路径 $I^* = \{i_1^*, i_2^*, \dots, i_T^*\}$ 1)初始化:对于 $i = 1, 2, \dots, N: \delta_1(i) = \pi_i b_i(o_1), \psi_1(i) = 0$ 2)对于 $t = 2, 3, \dots, T$,计算最优路径概率 $\delta_i(i)$ 和上一时刻最 佳状态 $\psi_i(i)$:

$$\begin{split} \delta_t(i) &= \max_{1 \leq j \leq N} \left[\delta_{t-1}(j) a_{j,t} \right] b_i(o_t) \quad i = 1, 2, \cdots, N \\ \psi_t(i) &= \arg_{1 \leq i \leq N} \left[\delta_{t-1}(j) a_{j,i} \right] \quad i = 1, 2, \cdots, N \end{split}$$

3) 找到路经概率最大值 P*:

$$P^* = \max_{1 \le i \le N} \delta_T(i), i_T^* = \arg\max_{1 \le i \le N} [\delta_T(i)]$$

4)最优路径回溯:对于 $t = T - 1, T - 2, \dots, 1$ $i_t^* = \psi_{t+1}(i_{t+1}^*)$ 5)终止,得到最优路径 $I^* = \{i_1^*, i_2^* \dots, i_T^*\}$

2.2 基于前馈技术和 GMR 的轨迹重构算法

通过维特比算法得到轨迹集中的每个点归属的状态,如图 6(a) 所示,图中相同颜色的轨迹采样点表示属 于相同的状态。为了进一步提高轨迹重构的精度,对每 个状态下包含的轨迹点采用极大似然估计的方法进行重 新计算其状态参数。详细的前馈技术原理流程框图如下 图 7 所示,传统方法直接将求得的高斯簇进行回归,会忽 略掉不包含在高斯簇内的轨迹点的贡献,加入前馈技术 后能合理且充分地利用所有轨迹点,有利于精度提升。 $X_m = \{(x_{1,m}, x_{2,m}, \dots, x_{N_m,m})\}_{m=1}^{M}$ 总共包含 K 个隐状态 $(K 个高斯分布), 定义 X_k = \{x_{n,m} | s(x_{n,m}) = q_k\}, k = 1, 2, \dots, K, 其中 <math>s(x_{n,m})$ 表示 $x_{n,m}$ 所属的隐状态,即 $X_k = \{(x_{1,k}, x_{2,k}, \dots, x_{N_k,k})\}_{k=1}^{K}$ 。通过如下公式重新对每个轨 迹点集 X_k 计算高斯参数。

$$\hat{\boldsymbol{\mu}}_{k} = \frac{1}{N_{k}} \sum_{i=1}^{N_{k}} \boldsymbol{x}_{i,k}$$
(7)

$$\boldsymbol{\Sigma}_{k} = \frac{1}{N_{k}} \sum_{i=1}^{n_{k}} \left(\boldsymbol{x}_{i,k} - \boldsymbol{\mu} \right) \left(\boldsymbol{x}_{i,k} - \boldsymbol{\mu} \right)^{\mathrm{T}}$$
(8)

得到的新的高斯分布如图 6(b) 所示。

由此可以定义一个高斯混合模型: $P(x^1, x^2) = \sum_{k=1}^{k} \pi_k N(\mu_k, \Sigma_k)$,采用高斯混合回归的方法对轨迹进行 重构。首先按照如下方式分解 μ_k 和 Σ_k :







图 7 前馈技术原理流程框图



$$\boldsymbol{\mu}_{k} = \begin{bmatrix} \boldsymbol{\mu}_{k,x^{1}}^{\mathrm{T}}, \boldsymbol{\mu}_{k,x^{2}}^{\mathrm{T}} \end{bmatrix}^{\mathrm{T}}$$
(9)

$$\boldsymbol{\Sigma}_{k} = \begin{bmatrix} \boldsymbol{\Sigma}_{k,X^{1}} & \boldsymbol{\Sigma}_{k,X^{1}X^{2}} \\ \boldsymbol{\Sigma}_{k,X^{2}X^{1}} & \boldsymbol{\Sigma}_{k,X^{2}} \end{bmatrix}$$
(10)

在给定输入 x¹ 的情况下,x² 的输出可以用条件概率 分布来描述:

$$P(x^{2} | x^{1}) = \sum_{k=1}^{K} h_{e}(x^{1}) N(\mu_{k,x^{2}} + \Sigma_{k,x^{2}x^{1}} \Sigma_{k,x^{1}}^{-1}(x^{1} - \sum_{k,x^{2}x^{1}} \Sigma_{k,x^{2}}^{-1}(x^{1} - \sum_{k,x^{2}x^{2}} \Sigma_{k,x^{2}}^{-1}(x^{1} - \sum_{k,x^{2}x^{2}} \Sigma_{k,x^{2}}^{-1}(x^{1} - \sum_{k,x^{2}} \Sigma_{k,x^{2}}^{-1}(x^{1} - \sum_{k,x^{2}} \Sigma_{k,x^{2}}^{-1}(x^{1} - \sum_{k,x^{2}} \Sigma_{k,x^{2}}^{-1}(x^{1} - \sum_{k,x^{2}} \Sigma_{k,x^{2}}^{-1}(x^{2} - \sum_{k,x^{2}} \Sigma_{k,x^{2}}^{-1}(x^{2$$

$$\boldsymbol{\mu}_{k,X^{1}}), \boldsymbol{\Sigma}_{k,X^{2}X^{1}} \boldsymbol{\Sigma}_{k,X^{1}}^{-1} \boldsymbol{\Sigma}_{k,X^{1}X^{2}})$$
(11)

得到分布后,可计算给定输入 x¹ 的情况下,x² 的期 望为:

$$h_{k}(x^{1}) = \frac{\pi_{k}N(x^{1};\boldsymbol{\mu}_{e,X^{1}},\boldsymbol{\Sigma}_{k,X^{1}})}{\sum_{l=1}^{K}\pi_{l}N(x^{1};\boldsymbol{\mu}_{l,X^{1}},\boldsymbol{\Sigma}_{l,X^{1}})}$$
(13)

将 x² 作为重构数据点,指导机器人重构轨迹的生成。对图5的两组分布分别进行高斯混合回归,得到图8 的重构轨迹,其中批注 A 的轨迹代表由图6(a)中的高斯分布参数得到的回归轨迹,而批注 B 的轨迹代表增加前馈技术后(图6(b)的高斯分布参数)得到的回归轨迹。



图 8 高斯混合回归得到的重构轨迹 Fig. 8 Reconstructed trajectory obtained by GMR

3 实验分析与讨论

为了验证基于前馈隐马尔可夫模型的机器人演示学 习方法的参数估计性能和轨迹重构精度,本文分别设计 了基于手写字母数据集的轨迹编码和重构实验,以及基 于晶圆机械臂自动上料任务的轨迹编码和重构实验。通 过一系列的对比实验,验证所提出的方法的有效性和优 越性。

3.1 定量评价指标

为了定量评估轨迹重构精度,本文引入平均弗雷歇 距离来衡量重构轨迹和演示轨迹之间的相似性。弗雷歇 距离^[24]是一种衡量两条长度不同的轨迹之间空间相似 性的重要指标,定义为两条曲线之间距离最大值的下界。

假设 $(t_k)_{k=0}^{n+1}$ 是在单位区间 [0,1] 上由互不相同的 数字构成的单调递增数列,定义 $(A(t_k))_{k=0}^{n+1}$ 和 $(B(t_k))_{k=0}^{n+1}$ 分别为数列 $(t_k)_{k=0}^{n+1}$ 在曲线A和B上的点列, 由图9中的大黑点给出,大黑点间的连线表示他们之间 的距离,定义为 $d(A(t_k),B(t_k))$ 。引入曲线的重参数化 函数 α 和 β ,作用于曲线A和B,得到对应的重参数化曲 线为A'和B',则A' (t_k) 和B' (t_k) 之间的距离可以定义为 $d(A'(t_k),B'(t_k))$,即 $d(A(\alpha(t_k)),B(\beta(t_k)))$,由图9 中的小黑点和虚线给出。则曲线A和B的弗雷歇距离 F(A,B)定义为:

 $F(A,B) = \inf_{\alpha,\beta} \max_{t \in [0,1]} \{ d(A(\alpha(t)), B(\beta(t))) \}$ (14) 平均弗雷歇距离定义为:

$$\overline{F} = \frac{1}{M} \sum_{m=1}^{M} F(\boldsymbol{R}, \boldsymbol{X}_m)$$
(15)

其中, **R** 表示重构轨迹, $\{X_m\}_{m=1}^M$ 表示演示轨迹集。

3.2 手写字母轨迹重构实验

选取手写字母数据集中的{M,R,W,Z,P}5个字母 作为实验数据,每个字母分别选取5条轨迹,每条轨迹采



样 50 个样本点,采用本文提出的方法进行实验。实验平 台为 MATLAB2022b,处理器为 11th Gen Intel(R) Core (TM) i5-11400F,频率为 2.6 GHz,RAM 容量为 16 GB。

为了验证本文提出的基于 LBG 算法的隐马尔可夫 模型参数初始化方法的优越性,通过将本方法与随机 轨迹初始化和固定值初始化进行比较,其中随机轨迹 是指在除了本方法选取的轨迹 X₈之外的其他演示轨迹 中选取一条作为初始化参数的依据,而固定值初始化 则遵循文献[19]的源代码设置。对每个字母运行 10 次参数估计代码,然后分别记录不同方法下鲍姆-韦尔 奇算法的平均迭代次数和平均参数估计的总时间,得 到表 1 的结果。

表 1 参数估计时间对比 Table 1 Time comparison of parameter estimation

演示轨迹	迭代次数/参数估计时间			
	随机轨迹	固定值	本文方法	
字母 M	51 次/367 ms	78 次/550 ms	43 次/352 ms	
字母 R	54 次/382 ms	80 次/564 ms	44 次/362 ms	
字母 W	49 次/344 ms	73 次/506 ms	40 次/326 ms	
字母 Z	55 次/385 ms	81 次/556 ms	46 次/365 ms	
字母 P	45 次/326 ms	67 次/482 ms	38 次/319 ms	

从表1可以看出,本文提出的隐马尔可夫模型参数 初始化方法优于其他两种方法。随机轨迹方法之所以 优于固定值的方法,是因为任意一条轨迹都包含了整 组轨迹集的部分信息,以此为依据的初始化参数能够 让模型更快收敛。而本文方法是首先从整组轨迹集中 先选取一条更具代表性的轨迹,所以优于基于随机轨 迹的方法。

为验证本文提出的基于前馈隐马尔可夫模型的机器人轨迹重构方法的优越性,将本文方法得到的重构轨迹和未加前馈技术得到的重构轨迹进行比较,得到图10的结果。其中点表示轨迹采样点,批注 A 的曲线表示本文方法得到的重构轨迹,批注 B 的曲线表示未加前馈技术得到的重构轨迹。此外,分别计算两种方法的平均弗雷歇距离,得到表 2 的结果。



图 10 不同字母的轨迹重构 Fig. 10 Trajectory reconstruction of different letters

表 2 轨迹重构精度 🛛	对比
--------------	----

 Table 2
 Comparison of track reconstruction accuracy

		cm
演示轨迹	未加前馈技术	加入前馈技术
字母 M	1.56	1.34
字母 R	1.48	1.27
字母 W	1.52	1.30
字母 Z	1.66	1.42
字母 P	1.34	1.11

结合表 2,图 8 和 10 可以看出,加入前馈技术后的重 构轨迹明显更加能概括演示轨迹的特征,从而验证了本 方法的有效性和优越性。

3.3 晶圆机械手上料轨迹的重构实验

为进一步验证本方法在实际机器人上的运行效果, 在团队自主研发的全自动半导体晶圆表明缺陷检测设备 上进行机器人上料演示实验。其中软件控制系统通过 EtherCAT 协议与伺服驱动通信,进而获取机器人的轨迹 信息并进行运动控制。首先采用动觉示教的方式采集机 器人的演示轨迹如图 11 所示,采样频率为 500 Hz,即在 系统按下开始按钮后,每 2 ms 获取一次关节角度信息, 进而计算机器人的末端位置。为了控制轨迹点的数量, 软件每隔 25 个周期记录一次机器人末端位置,演示时间 控制在 10 s 左右,从而每条演示轨迹获取 200 个左右的 轨迹点。



(a) 初始位置 (a) Initial position

(b) 吸住晶圆片 (b) Catching wafer



(c) 往目标移动 (c) Moving to target

(d) 放置晶圆片 (d) Placing wafer

图 11 机器人动觉示教

Fig. 11 Robot kinesthetic demonstrations

采集到的 10 条机器人末端的运动轨迹如图 12 所示,然后遵循上一节的步骤,分别研究不同轨迹数量的情况下本文方法和其他方法在参数估计效率和重构轨迹精度上的差异,结果如表 3 所示。



图 12 晶圆机器人上料过程的演示轨迹和重构轨迹 Fig. 12 Demonstration trajectory and reconstruction trajectory of the wafer robot loading process

表 3 不同方法下算法性能对比 Table 3 Comparison of algorithm performance under

different methods				
指标	方法	数值		
	随机轨迹初始化	73 次/9 035 ms		
参数估计时间	固定值初始化	92 次/11 213 ms		
	本文方法	64 次/8 243 ms		
劫泣重劫摔座	未加前馈技术	6.47 cm		
机迎里构相及	加入前馈技术	5.49 cm		

从图 12 可看出,在接近终点的位置,实线轨迹处于 演示轨迹的边缘区域,而虚线轨迹包含在演示轨迹中,可 定性判断其与演示轨迹的平均弗雷歇距离更小,轨迹重 构精度更高。进一步定量计算,如表 3 所示,本文方法与 10 条演示轨迹之间的平均弗雷歇距离为 5.49,相较于未 加前馈技术的 6.74,精度上提高了 15.15%。此外,在参 数估计时间上,相较于传统的初始化方法减少了 26.49%,进一步验证了本方法的有效性和优越性。

4 结 论

针对隐马尔可夫模型在机器人演示轨迹编码过程中 存在的参数估计效率低,轨迹重构精度差的问题,提出了 一种基于前馈隐马尔可夫模型的机器人演示学习方法。 在模型参数辨识阶段,引入基于 LBG 算法和最小失真准 则的参数初始化方法,通过找到一条最优演示轨迹来初 始化模型参数,从而减少迭代次数,提高参数辨识效率。 在轨迹重构阶段,提出了一种隐状态参数的前馈技术,利 用尽可能多的数据点来得到更优的参数,从而提高轨迹 重构精度。最后进行了人类手写字母轨迹重构和实际晶 圆机械臂自动上料的轨迹重构实验,并引入平均弗雷歇 距离来定量评估轨迹重构精度。结果表明,本文提出的 方法在参数估计效率和轨迹重构精度上都表现出更优的 性能。

参考文献

- [1] 黄艳龙,徐德,谭民. 机器人运动轨迹的模仿学习综述[J]. 自动化学报,2022,48(2):315-334.
 HUANG Y L, XU D, TAN M. A review of imitation learning of robot motion trajectories[J]. Acta Automatica Sinica,2022,48(2):315-334.
- [2] 张春涛,王勇,李家旺.基于摩擦模型的机器人力/位 安全控制方法研究[J].电子测量与仪器学报,2021, 35(9):19-26.

ZHANG CH T, WANG Y, LI J W. Research on robot force/position safety control method based on friction model[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(9): 19-26.

[3] 迟明善,姚玉峰,刘亚欣. 基于示教编程的共融机器 人技能学习方法的研究进展[J]. 仪器仪表学报, 2020,41(1):71-83.

CHI M SH, YAO Y F, LIU Y X. Research progress on inclusive robot skill learning methods based on teaching programming [J]. Chinese Journal of Scientific Instrument, 2020,41(1):71-83.

- [4] SOSA-CERON A D, GONZALEZ-HERNANDEZ H G, REYES-AVENDANO J A. Learning from demonstrations in human-robot collaborative scenarios: A survey [J]. Robotics, 2022, 11(6): 126.
- [5] IJSPEERT A J, NAKANISHI J, HOFFMANN H, et al. Dynamical movement primitives: Learning attractor models for motor behaviors [J]. Neural Computation, 2013, 25(2): 328-373.
- [6] REYNOLDS D A. Gaussian mixture models [J]. Encyclopedia of Biometrics, 2009, 741:659-663.
- [7] PARSONS O E. A gaussian mixture model approach to classifying response types [J]. Mixture Models and Applications, 2020: 3-22.
- [8] RABINER L R. A tutorial on hidden markov models and selected applications in speech recognition [J].
 Proceedings of the IEEE, 1989, 77(2): 257-286.
- [9] FINK G A. Markov models for pattern recognition: from theory to applications [M]. Berlin: Springer Science & Business Media, 2014.
- [10] WANG N, CHEN C, DI N A. A framework of hybrid force/motion skills learning for robots [J]. IEEE Transactions on Cognitive and Developmental Systems, 2020, 13(1): 162-170.
- [11] ITURRATE I, KRAMBERGER A, SLOTH C. Quick setup of force-controlled industrial gluing tasks using learning from demonstration [J]. Frontiers in Robotics and AI, 2021, 8: 767878.
- WU M, TAETZ B, HE Y, et al. An adaptive learning and control framework based on dynamic movement primitives with application to human-robot handovers[J]. Robotics and Autonomous Systems, 2022, 148: 103935.
- [13] 吴晓敏,贺苗,刘暾东,等. 基于狄利克雷过程聚类的机器人演示学习研究[J]. 仪器仪表学报,2023,44(1):265-74.
 WUXM,HEM,LIUTD, et al. Research on robot demonstration learning based on Dirichlet process clustering[J]. Chinese Journal of Scientific Instrument, 2023,44(1):265-74.
- [14] VAKANSKI A, MANTEGH I, IRISH A, et al.

Trajectory learning for robot programming by demonstration using hidden markov model and dynamic time warping[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), 2012, 42 (4): 1039-1052.

- [15] GARRIDO J, YU W, LI X. Robot trajectory generation using modified hidden markov model and Lloyd's algorithm in joint space[J]. Engineering Applications of Artificial Intelligence, 2016, 53: 32-40.
- [16] AMOR H B, VOGT D, EWERTON M, et al. Learning responsive robot behavior by imitation [C]. 2013 IEEE/ RSJ International Conference on Intelligent Robots and Systems, IEEE, 2013.
- [17] KULIC D, TAKANO W, NAKAMURA Y. Incremental learning, clustering and hierarchy formation of whole body motion patterns using adaptive hidden markov chains[J]. The International Journal of Robotics Research, 2008, 27(7): 761-784.
- [18] ZHUANG C, ZHOU H, SAKANE S. Learning by showing: An end-to-end imitation leaning approach for robot action recognition and generation [C]. 2016 IEEE International Conference on Robotics and Biomimetics (ROBIO), IEEE, 2016: 173-178.
- [19] WANG L, WANG G, JIA S, et al. Imitation learning for coordinated human-robot collaboration based on hidden state-space models [J]. Robotics and Computer-Integrated Manufacturing, 2022, 76: 102310.
- [20] CALINON S, LEE D. Learning control [M]. Humanoid Robotics: A Reference [M]. Springer: Dordrecht, 2019.
- [21] LINDE Y, BUZO A, GRAY R. An algorithm for vector quantizer design [J]. IEEE Transactions on Communications, 1980, 28(1): 84-95.
- [22] BACCI G, INGOLFSDOTTIR A, LARSEN K G, et al. Active learning of markov decision processes using baumwelch algorithm [C]. 2021 20th IEEE International

Conference on Machine Learning and Applications (ICMLA), IEEE, 2021.

- [23] VITERBI A. Error bounds for convolutional codes and an asymptotically optimum decoding algorithm [J]. IEEE Transactions on Information Theory, 1967, 13 (2): 260-269.
- [24] FRECHET M M. Sur quelques points du calcul fonctionnel [J]. Rendiconti del Circolo Matematico di Palermo (1884-1940), 1906, 22(1): 1-72.

作者简介



苏永彬,2019年于福州大学获得学士学 位。现为厦门大学萨本栋微米纳米科学技 术研究院博士研究生。主要研究方向为工 业机器人控制。

E-mail: suyongbin@ stu. xmu. edu. cn

Su Yongbin received his B. Sc. degree from Fuzhou University in 2019. He is currently a Ph. D. candidate at Pen-Tung Sah Institute of Micro-Nano Science and Technology, Xiamen University. His main research interest is the field of industrial robot control.



刘暾东(通信作者),2003 年于中国科 学技术大学获得博士学位。现为厦门大学 萨本栋微米纳米科学技术研究院教授,博士 生导师。主要研究方向为工业机器人与机 器视觉技术。

E-mail: ltd@ xmu. edu. cn

Liu Tundong (Corresponding author) obtained his Ph.D. degree from the University of Science and Technology of China in 2003. He is currently a professor and a Ph.D. advisor at Pen-Tung Sah Institute of Micro-Nano Science and Technology, Xiamen University. His main research interests include industrial robotics and machine vision technology.