

网络机器人的可调整自主性

苏剑波¹ 周玮¹

摘要 Internet 上数据传输的不确定延时妨碍了机器人和操作者之间迅捷而透明地交互, 严重限制了遥操作机器人的性能和应用. 本文研究了机器人的可调整自主性 (Adjustable autonomy, AA), 通过改善人机交互来补偿网络通讯存在的不确定延时对系统性能的影响. 机器人的自主性根据当前形势和环境动态调整, 操作者和机器人以适合网络状况和任务需要的模式进行交互和合作, 使得整个系统的效率大大提高. 实验结果证明了所提方法的有效性和可行性.

关键词 网络机器人, 可调整自主性, 人机交互, 用户意图, 不确定延时

DOI 10.3724/SP.J.1004.2010.00982

Adjustable Autonomy for Teleoperated Internet Robots

SU Jian-Bo¹ ZHOU Wei¹

Abstract It is very hard to have a transparent and prompt interaction between user and teleoperated internet robot due to uncertain time delays over the internet, which severely limits performance of teleoperated robot systems. This paper investigates the adjustable autonomy of robots to improve the human-robot interaction so as to compensate for the variable time delay in data transmission over internet. The autonomy of the robot is adjusted dynamically according to the environmental dynamics and network status so that the appropriate interaction pattern suited to the network conditions and task requirements can be carried out between the user and the robot. Consequently, the efficiency of the whole system can be improved to a great extent. Experimental results show the validity and feasibility of the proposed method.

Key words Internet-based robot, adjustable autonomy (AA), human robot interaction, user intention, uncertain time-delay

近年来, 随着 Internet 的广泛应用和遥操作技术的发展, 越来越多的研究人员和组织将各种可控设备和机器人连接到 Internet. 遥操作机器人不仅可以向控制者提供真实的远程场景, 而且能够根据用户发送的一系列控制指令执行和完成各种不同的远程操作任务. 然而, Internet 上数据传输的不确定延时大大妨碍了用户和机器人迅捷而及时的交互, 使用户对机器人难以实现顺畅的控制, 这严重降低和限制了网络机器人的性能和应用.

研究者们已经采取了诸多努力来尝试减小和解决 Internet 上数据传输的不确定延时问题. 办法之一就是客户端构造能够真实反映远程机器人及其环境的仿真模型, 用户将控制指令发给远端之前先在本地模型对象上模拟执行^[1-4]. 通过本地的预测演示, 用户在控制命令被机器人真正执行之前, 能够清楚地知道控制指令对远程环境产生怎样的影响. 由于仿真是在客户端构建, 整个过程并没有和远程环境交互, 也就不存在数据通讯延时带来的影响. 然

而, 一个充分真实的模型要求对远程机器人及其环境具有足够的理解, 通常这是很困难的. 而且在系统工作以前, 客户端需要下载或者安装模型相关组件, 这也不被广大 Internet 用户所接受. 更重要的是, 即使本地仿真能够被反映远端执行过程的视频或其他反馈信息补偿, 用户对远程机器人的控制实际上仍然是开环的.

控制离不开系统模型, 许多学者都试图通过对网络建模, 从控制的角度来分析和解决遥操作系统的延时问题^[5-8], 但至今仍然不清楚什么才是最好的控制策略^[9-12]. 美国 Bechman Institute 研究充分利用外部资源来帮助智能体保持或提高其面向任务的智能行为的能力, 取得了较丰硕的成果^[13], 但这个策略并不适用于所有应用领域.

Internet 延时严重阻碍了遥操作中的人机交互, 因此很自然地设想充分利用机器人系统本身所具有的智能, 或者有针对性地为机器人系统开发一定的智能, 减少人机通讯^[3, 14-16]来解决这个问题, 如机器人的自我保护能力可以帮助机器人主动避碰而不需要操作者的干预等. 在控制过程中, 操作者置于控制结构闭环之外, 承担的是在一个较高的层次上分配任务, 以及监督机器人系统状态和任务完成状况的角色. 机器人的自主性使得对通讯的带宽要求降低, 从而传输延时对整个系统性能的影响也减小. 但

收稿日期 2008-12-15 录用日期 2009-08-18
Manuscript received December 15, 2008; accepted August 18, 2009

国家自然科学基金 (60675041) 资助
Supported by National Natural Science Foundation of China (60675041)

1. 上海交通大学自动化系 上海 200240
1. Department of Automation, Shanghai Jiao Tong University, Shanghai 200240

是, 人机交互被最小化的同时造成了用户对机器人的控制缺乏直接性和透明性, 在一定程度上损失了用户智能的利用, 也降低了系统的执行效率. 而且, 人们更喜欢“手把手”(Hands-on)的直接控制, 而这种情况下的遥操作自主机器人无法提供动作层面上的完全控制和即时反馈.

遥操作的网络机器人控制需要保持恰当的人机交互和协作以完成操作任务. 然而由于 Internet 通讯延时, 一般意义下固定而刚性的机器人自主性难以保证必要的人机交互和系统性能. 机器人需要拥有更高的自主性以寻求一种合适的人机交互机制, 从而保证网络机器人系统面对不确定的延时环境时, 能够适应每一种可能出现的情况. 用户和机器人之间的交互与协作关系应该能够随着变化的网络状况动态调整, 使人机之间的交互和通讯尽可能适合当时的网络传输状况, 从而最好地实现遥操作任务.

本文研究通过在线调整机器人的自主性来改善遥操作中的人机交互, 以克服网络延时对系统性能的影响. 机器人自主性的动态调整, 意味着要充分利用人和机器人各自的优势, 最好地适应动态变化的环境和任务要求, 实现整个机器人系统性能的最优化. 基于不同的机器人自主性模式, 用户和机器人可更灵活地进行交互和合作, 以更合理的方式分配系统中人与机器人间对完成指定任务的控制能力, 从而更好地适应当前的网络状况和任务需求. 可调整自主性是机器人更高级智能的体现, 基于机器人可调整自主性的遥操作控制策略是对传统监督控制方法的重要扩展. 另外, 可调整自主性能够被集成到服务器端, 这也暗示了在遥操作过程中客户端不需任何额外的安装.

1 可调整自主性

控制任务的完成, 尤其是执行一些比较复杂的任务时, 需要整个系统具备一定的智能. 遥操作任务的顺利完成依靠操作者和机器人充分发挥各自的优势, 协调地进行合作. 在控制过程中, 网络机器人的自主性和操作者所具有的自主性(或者称操作者能够实现的控制能力)之间的关系如图 1 所示.




图 1 遥操作过程中机器人自主性与用户控制能力的关系
Fig. 1 The relationship between the robot's autonomy and the user's controllability during teleoperation

延时较小时, 用户可以实现的操作能力就较强, 这种情形下可能完全依靠用户的控制就能很好地完成任务, 机器人可以不具备任何自主能力; 延时的增大导致用户对机器人的控制能力降低, 严重时甚至没有. 这时仅仅依靠用户的控制是不可能完成任务的, 机器人的自主性必须发挥作用, 即通过增加机器人的自主性来补偿机器人由于网络传输问题而损失的从操作者获得的控制能力, 从而维护整个系统的工作效率和性能, 使控制任务最终得以完成.

可调整自主性 (Adjustable autonomy, AA) 是近年来提出的概念^[17-18], 指动态地改变多智能体系统中各个智能体的自主性, 充分利用各组成个体的优势, 最好地配置系统资源, 以适应当前任务完成形势, 实现整个系统性能的最优化. Dorais 等^[17]利用这一思想处理常量通讯时延, 从而达到利用机器人的主动能力来克服网络通讯延迟, 提高任务实现质量的目的. 在他们的系统中, 用户能够在不同的控制层面上实现基于操作者手动控制的火星勘测任务. 后来, 这一思想逐渐更广泛地应用于多智能体系统协调^[19-21], 以及人机交互的众多研究方向中^[22-23], 显示了这一思想的生命力和价值.

然而, 在已有的具备可调整自主性能力的机器人系统中, 大都仅仅是人为粗略定义了几个不同的控制方式, 通过操作者的切换来实现机器人自主性的调整. 控制方式的定义和划分缺乏必要的理论依据, 切换的合适与否完全依靠操作者的经验和对任务的理解, 而人机系统中机器人的智能没有得到应有的利用. 很明显, 真正发挥可调整自主性思想的优势还需要对机器人的“自主性”有更深刻的理解和定量定性的专门研究.

1.1 机器人的自主性

考虑一个单人单机系统 (Single-operator single-robot system, SOSR), 系统中用户和机器人两个智能个体分别以 O_H 和 O_R 表示, S_{O_H} 和 S_{O_R} 则表示相应智能体的自主性. 这样, 整个系统的自主性可表示为

$$A = \left\{ S_{O_H}, S_{O_R} \right\} \quad (1)$$

在任务执行过程中, 系统的自主性就体现为操作者和机器人的自主性之和.

网络机器人中的自主性评估主要依据系统中各个体对于任务完成做出了怎样的贡献, 以及多大程度上影响了系统结果的输出. 遥操作的控制任务通常由操作者和机器人通过交互与协作完成, 机器人每一个动作都是在人机系统(全体或部分成员)操纵下实现的. 设定在任何一个任务执行过程中, 整个系统的自主性总是保持为常值 1 (本文主要讨论机器

人在任务执行过程中所体现的自主性,机器人在任务完成过程中逐步提高的机器人智能对整个系统自主性的影响则不在本文研究范围内)。因此,控制任务的执行过程中存在以下关系:

$$S_{O_H} + S_{O_R} = 1 \quad (2)$$

其中, $0 \leq S_{O_H} \leq 1$, $0 \leq S_{O_R} \leq 1$. $S_{O_R} = 0$ 表示机器人没有自主能力,每一步行为都由用户决定;而 $S_{O_R} = 1$ 则表示机器人对自己有着完全的控制权,全自主地完成给定任务,不受用户任何干涉。

任务的执行是一个人机交互过程,这个连续的人机交互过程激发机器人做出一系列动作来完成任

$$S_{O_R} = \left\{ S_{O_R}^1, S_{O_R}^2, \dots, S_{O_R}^t, \dots, S_{O_R}^T \right\} \quad (3)$$

来对应一次任务的执行过程. 式中,该交互过程由 T 步交互行为组成. S_{O_R} 表示机器人 O_R 在某个交互过程中的自主性值,而 $S_{O_R}^t$ 则是该交互过程中的第 t 次交互行为之后机器人所呈现出的自主性值。

用一次次交互行为中机器人自主性的状况来拟合整个人机交互过程中机器人的自主性,这里用一种简单的投票策略来估计机器人自主性大小. 如果每次人机交互行为都拥有一张投票权且交互行为结束后这张票必须投出,收到投票的智能体(用户或机器人)对这次交互行为的结果有着完全的贡献,则机器人和人的自主性对任务完成的贡献可以用各自在任务已完成阶段里的交互过程中所获得的票数多少来衡量。

在一个人机交互过程中,机器人的自主性可用如下公式进行计算:

$$S_{O_R}^t = \frac{\sum_{i=1}^t V_{O_R}^i}{\sum_{i=1}^t V_{O_R}^i + \sum_{i=1}^t V_{O_H}^i} \quad (4)$$

其中, t, i 和 j 都是正整数. t 表示该交互过程已经进行了 t 次交互行为. $S_{O_R}^t$ 表示在该交互过程中,第 t 个人机交互行为之后机器人所表现的自主性值. $1 \leq i, j \leq t$, $V_{O_R}^i$ 和 $V_{O_H}^j$ 分别表示第 i 个人机交互行为对机器人投票情况和第 j 个人机交互行为对用户的投票情况,二者的取值只能为 1 或 0,即:如果第 i 次人机交互行为对机器人投了票,则 $V_{O_R}^i = 1$, $V_{O_H}^i = 0$. $\sum_{i=1}^t V_{O_R}^i$ 和 $\sum_{j=1}^t V_{O_H}^j$ 分别表示该交互过程进行到第 t 个人机交互行为后机器人和用户各自得到的票数,二者之和就是到第 t 次交互行为完成后系统投出的所有票数。

1.2 机器人的自主性模式

机器人在人机交互过程中的自主性值还不能为遥操作提供直接的帮助. 必须将机器人自主性的定量分析映射到定性描述上来,才能更加清晰地理解和应用机器人的自主性. 机器人的自主性模式定义了任务执行和开展的交互框架^[24],体现了不同的人机交互与合作方式,能够真正反映出用户以怎样的方式实现对机器人的控制,以及机器人以怎样的方式协助用户完成任务,对遥操作的执行有着极大的实际意义. 本文希望从人机交互经历中发掘出典型的机器人自主模式,获得自主性模式和交互过程之间隐含的对应关系,从而能够在遥操作过程中调整机器人的自主性,以使用户和机器人在适宜的模式下协作完成控制任务。

2 实现可调整自主性

可调整自主性调整的不是机器人的具体自主性值,而是自主性模式,其实现过程如图 2 所示。




图 2 实现流程

Fig. 2 The implementation flow

不同网络延时状况下的遥操作过程,也即用户和机器人的交互经历,组成样本数据集. 预处理进行的是从人机交互过程中提取相应的机器人自主性值变化序列的工作. 模式学习则是从样本数据中离线学习出不同的机器人自主性模式. 在遥操作中,机器人根据操作者正在进行的操作过程以及相应的网络状况,并结合学习到的模式数据,在线评估适合当前任务形势需要的机器人自主性模式. 基于预测结果,操作者能够主动调整或机器人自适应地调整任务执行的模式。

很明显,可调整自主性实施的关键在于机器人自主性模式的学习和在线评估。

2.1 学习自主性模式

本文通过期望最大化 (Expectation maximization, EM) 算法^[25-30] 从交互经历中迭代地评估机器人自主性模式. 自主模式学习的输入是一些用户和机器人的交互经历集合 $d = \{d_1, \dots, d_N\}$, 其中 d_i ($1 \leq i \leq N$) 是一次人机交互过程. 输出是一些不同类型的遥操作中可能展现的机器人自主模式 $\alpha = \{\alpha_1, \dots, \alpha_M\}$. 这里, α_m ($1 \leq m \leq M$) 表示一

种自主模式, 任何一次交互过程都在某一种自主性模式下完成.

为了表达方便, 将式 (3) 改写为

$$d_i = \left\{ x_i^1, x_i^2, \dots, x_i^i, \dots, x_i^T \right\} \quad (5)$$

式中, x_i^t 表示第 i 次交互过程中第 t 次交互行为之后机器人表现出的自主性值, $1 \leq t \leq T$. T 作为所有交互过程轨迹的最大长度, 长度为 $T' < T$ 的可以通过增加 $T - T'$ 次交互行为 (增加的交互行为并不改变机器人的自主性值) 而被扩展到长度 T .

机器人自主性模式 α_m 可以用概率分布 $p(x|\alpha_m^t)$ 来表示, 它定义了自主模式 α_m 下第 t 次人机交互之后机器人自主性状态为 x 的概率. 这样, 给定 m -th 自主模式 α_m , 交互过程 d_i 的相似度为

$$p(d_i|\alpha_m) = \prod_{t=1}^T p(x_i^t|\alpha_m^t) \quad (6)$$

本文学习方法的本质是确定一个与已有数据相似度最大化的关于机器人自主性模式的模型 α . 为了定义自主模式与已有数据的相似度, 引入相关系数的概念. c_{im} 表示一个相关系数, i 和 m 分别是交互过程 d_i 和自主模式 α_m 的索引值. 每一个相关系数 c_{im} 都是一个二元变量, 其取值非 0 即 1. 当且仅当 i -th 交互过程对应于 m -th 控制模型时, c_{im} 值为 1. 如果将自主模式看作是在某种特定的机器人自主性描述上进行的一类控制行为集合, 那么 c_{im} 是 1 就表示用户在 i -th 交互过程中进行的正是 m -th 类控制行为. 定义相对于 i -th 交互过程的所有相关变量集 c_i , 即 $c_i = \{c_{i1}, \dots, c_{iM}\}$. 对于任何一个交互过程, 其对应的相关变量总和为 1, 即

$$\sum_{m=1}^M c_{im} = 1 \quad (7)$$

假设每一种自主模式都可被带有固定标准方差 δ 的 T 个高斯分布表示. 给定自主模式的模型 α , 可以通过下式来计算一个交互过程 d_i 及其相关向量 c_i 的联合相似度:

$$p(d_i, c_i|\alpha) = \prod_{t=1}^T \prod_{m=1}^M \frac{1}{\sqrt{2\pi\delta}} e^{-\frac{1}{2\delta^2} c_{im} \|x_i^t - \mu_m^t\|^2} \quad (8)$$

因为一个交互过程只属于一种自主模式, 所以相关系数 c_{im} 的所有可能取值中只有一个为 1, 而其他的都为 0. 于是, 所有交互过程的总的相似度为

$$p(d, c|\alpha) = \prod_{i=1}^N \left(\prod_{t=1}^T \prod_{m=1}^M \frac{1}{\sqrt{2\pi\delta}} e^{-\frac{1}{2\delta^2} c_{im} \|x_i^t - \mu_m^t\|^2} \right) \quad (9)$$

由于对数函数是单调函数, 因此相似度最大化可以通过最大化其对数来实现

$$\ln p(d, c|\alpha) = \sum_{i=1}^N \left(T \cdot M \cdot \ln \frac{1}{\sqrt{2\pi\delta}} - \frac{1}{2\delta^2} \sum_{t=1}^T \sum_{m=1}^M c_{im} \|x_i^t - \mu_m^t\|^2 \right) \quad (10)$$

需要注意的是, 上式中相关系数 c 是不可观测的. 而且, 本文真正感兴趣的并不是相关系数 c 的对数相似度, 而是它所表征的与已知交互经历 d 最相符的自主模式模型 α . 因此, 可通过优化期望 $E[\ln p(d, c|\alpha)|\alpha, d]$ 来达到最大化对数似然估计 $\ln p(d, c|\alpha)$ 的目的. $E[\ln p(d, c|\alpha)|\alpha, d]$ 表示给定已知数据 d , 对数似然函数在模式模型 α 所遵循的概率分布上的期望. 由式 (10) 可得

$$E[\ln p(d, c|\alpha)|\alpha, d] = E \left[\sum_{i=1}^N \left(T \cdot M \cdot \ln \frac{1}{\sqrt{2\pi\delta}} - \frac{1}{2\delta^2} \sum_{t=1}^T \sum_{m=1}^M c_{im} \|x_i^t - \mu_m^t\|^2 \right) |\alpha, d \right] \quad (11)$$

由于期望是线性因子, 可以将其移进表达式之中, 式 (11) 可转化为

$$E[\ln p(d, c|\alpha)|\alpha, d] = E \left[\sum_{i=1}^N \left(T \cdot M \cdot \ln \frac{1}{\sqrt{2\pi\delta}} - \frac{1}{2\delta^2} \sum_{t=1}^T \sum_{m=1}^M E[c_{im}|\alpha, d] \|x_i^t - \mu_m^t\|^2 \right) \right] \quad (12)$$

式中, $E[c_{im}|\alpha, d]$ 取决于自主模式模型 α 和交互数据集 d .

EM 算法通过迭代优化一系列的下界使期望的对数似然函数最大化. 特别地, 它产生了一系列的自主模式模型, $\alpha^{[1]}, \alpha^{[2]}, \dots$, 它们逐步地增大了对数似然估计.

将式 (12) 转化为一个 Q 函数, 该函数依靠两个模型 α 和 α' :

$$Q(\alpha'|\alpha) = E[\ln p(d, c|\alpha')|\alpha, d] \quad (13)$$

这样, Q 函数可化为

$$Q(\alpha'|\alpha) = E \left[\sum_{i=1}^N \left(T \cdot M \cdot \ln \frac{1}{\sqrt{2\pi}\delta} - \frac{1}{2\delta^2} \sum_{t=1}^T \sum_{m=1}^M E[c_{im}|\alpha, d] \|x_i^t - \mu_m^t\|^2 \right) \right] \quad (14)$$

因此, 可得自主性模式系列的模型

$$\alpha^{[j+1]} = \arg \max Q(\alpha'|\alpha^{[j]}) \quad (15)$$

式 (15) 开始于初始模型 $\alpha^{[0]}$. 对于本文所研究的问题, Q 函数始终是连续的, 因此, EM 算法至少收敛于一个局部最大.

整个优化过程涉及两个步骤: 1) 给定当前模型 $\alpha^{[j]}$, 计算期望 $E[c_{im}|\alpha^{[j]}, d]$; 2) 找到一个新的模型 $\alpha^{[j+1]}$, 该新模型在这些期望下有最大的期望相似度. 在这两步中, 步骤 1) 就是 E (Expectation) 步, 步骤 2) 就是 M (Maximization) 步.

E 步. 计算期望 $E[c_{im}|\alpha^{[j]}, d]$, 运用 Bayes 规则, 遵循不同交互过程间的独立性假设, 得到

$$E[c_{im}|\alpha^{[j]}, d] = p(c_{im}|\alpha^{[j]}, d)p(c_{im}|\alpha^{[j]}, d_i) \times \eta p(d_i|c_{im}, \alpha^{[j]})p(c_{im}|d_i) \times \eta' p(d_i|\alpha_m^j) \quad (16)$$

式中, η 和 η' 为归一化常数, 它确保在所有 m 上的期望和为 1. 如果联合式 (6) 和式 (16), 并考虑自主模式模型可被表示为高斯分布, 可以得到

$$E[c_{im}|\alpha^{[j]}, d_i] = \eta' \prod_{t=1}^T e^{-\frac{1}{2\delta^2} \|x_i^t - \mu_m^t\|^2} \quad (17)$$

M 步. 通过最大化期望相似度计算得到一个新的自主模式模型 $\alpha^{[j+1]}$. 这可以通过计算一个新的高斯分布的均值 $\mu_m^{t[j+1]}$ 来得到, 即在每一个自主模式 m 和每一步交互行为 t 上进行计算. 因此, 考虑在 E 步计算得到的期望 $E[c_{im}|\alpha^{[j]}, d]$, 可得

$$\mu_m^{t[j+1]} = \frac{\sum_{i=1}^N E[c_{im}|\alpha^{[j]}, d] x_i^t}{\sum_{i=1}^N E[c_{im}|\alpha^{[j]}, d]} \quad (18)$$

EM 算法迭代以上的 E 步和 M 步重复估计模型 α , 直到该学习过程收敛到一个稳定的似然函数 $p(d, c|\alpha')$ 的不动点.

需要说明的是, 准确具体的自主性值, 用户进行遥操作时并不需要. 比如自主性值为 0.35 或者 0.47, 对用户控制而言没有任何的区别和影响. 因此, 各个自主模式对应的机器人自主性值应该有一定的差距,

这样才能真正区分不同特征的用户控制方式. 从这一点考虑, 机器人自主性模式的数目不宜过多. 参数的合适取值, 不仅符合网络机器人控制的实际情况, 而且还能完全避免 EM 算法陷入局部最大问题.

2.2 在线评估用户意图

通过聚类学习, 明确了具有怎样自主性表现的人机交互过程属于哪种机器人自主模式, 以及自主性模式和网络延时的关系. 利用这些知识, 机器人从人机交互中在线学习用户意图. 这种控制意图表现为用户期望的适合当时网络状况并与目前人机交互过程相匹配的机器人自主性模式.

给定交互经历和网络延时, 机器人自主性模式的相似度期望可表示为 $E[\alpha_m|d, TD]$. 运用 Bayes 规则, 并遵循不同交互数据间的独立性假设, 可得

$$E[\alpha_m|d, TD] = p(\alpha_m|d, TD) = \prod_{k=1}^t p(\alpha_m|x^k, TD^k) = \lambda \prod_{k=1}^t p(TD^k|\alpha_m, x^k)p(\alpha_m, x^k) \quad (19)$$

式中, λ 是归一化系数, 以保证相似度期望在整个自主模式概率空间和为 1; α_m ($1 \leq m \leq M$) 为机器人自主性模式; $d = \{x^1, x^2, \dots, x^t, \dots\}$ 是当前用户交互经历, x^t 是 d 中第 t 次交互行为完成后机器人所处的自主性状态; $TD = \{TD^1, TD^2, \dots, TD^t, \dots\}$ 表示网络延时, TD^t 是第 t 次交互行为发生时刻的延时值. $p(\alpha_m|x^k)$ 表示交互行为和自主模式的相似度, $p(TD^k|\alpha_m, x^k)$ 则取决于网络延时和自主模式之间的关系.

3 基于 Internet 的办公室服务机器人

本文利用装备了 Sony 摄像头和声纳传感器的 Pioneer 2 移动机器人, 开发了基于 Internet 的办公室服务机器人 (Internet-based office robot, IOR) 系统, 其体系结构如图 3 所示.

整个系统采用 Browser/Server 结构, 利用 Java 技术实现. 充当机器人服务器的笔记本电脑 (置于 Pioneer 2 上) 配有无网卡, 能够联入 Internet 向用户提供远程控制. 无需任何安装, 网络用户在本地客户端仅仅需要一个 Web 浏览器, 就可以控制 IOR 在远端办公室环境内移动, 并实现诸如递送文档之类的服务. IOR 具有一定的自主能力, 能够实现动态避障.

用户控制界面的左半部分展示了实时视频和图形化的声纳信号. 安置于机器人身上的摄像头从机器人的视角向用户反馈视频信息. 界面的右半部分是

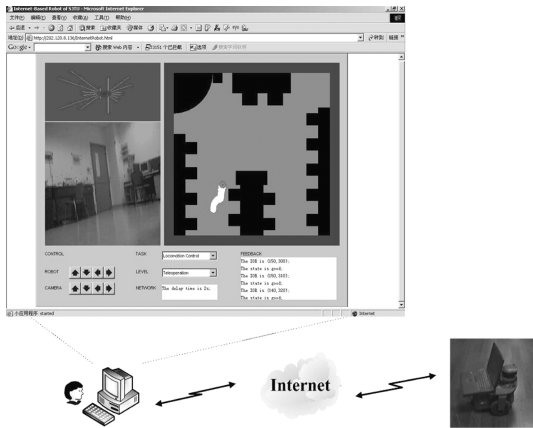


图 3 系统体系结构

Fig. 3 The system architecture

办公室的全局地图, 机器人的行为、位置以及环境特征能够在全局地图上被实时地显示和更新. 地图具有交互功能, 用户可以通过在地图上点击鼠标指定目标点位置来引导机器人移动. 当用户在地图上确定目标点后, 机器人根据全局地图信息和自身传感器输入, 基于 A^* 算法^[31] 自主进行路径规划并运动到该目标位置. 在界面的底端, 有用户用于分配机器人任务的界面, 还有八个控制按钮供用户直接操纵机器人和摄像头运动, 以让 IOR 在不发生碰撞的前提下行为完全听从用户指令. 界面右下角则是状态信息区, 提供当前网络通讯状况以及移动机器人和障碍物的位置信息.

4 实验

为了评估本文的方法, 采用 IOR 平台在办公室环境中进行了大量的实验. 办公室大小为 8×8 平方米, 机器人移动速度是 10 厘米/秒, 运动障碍物速度为 20 厘米/秒. 实验任务为用户通过图 3 所示的交互界面实现服务类移动机器人的一个基本功能, 即远程控制 IOR 安全运动到指定目标位置. 本文中利用 PingER (Ping end-to-end reporting) 工程^[32] 所给出的延时数据和相关统计特性构造了真实的广域网通讯环境. 而且, 为了充分验证本文方法, 实验中设定了比一般的 Internet 延时情况^[33-34] 更加严格和苛刻的实验条件.

本文的实验通过三个阶段开展. 首先, 通过一系列的实验证明了本文提出的方法能够从人机交互数据集中析取出不同的机器人自主性模式; 其次, 从聚类学习结果中分析典型自主性模式及其特征, 将机器人自主性离散化, 并得到机器人自主性模式和网络延时状况的关系; 最后, 从“人”和“机器人”两个方面检验了可调整自主性对改善系统性能和控制效果带来的帮助.

4.1 学习自主性模式

本节实验旨在证明本文提出的学习模型能够对所给数据进行正确分类, 即从多个人机交互经历中学习得到不同类型的机器人自主性模式.

为了全面、真实地反映用户遥控操作的一些特征, 在积累学习数据集的实验中采用五个时段作为延时随机变化区间, 即 $[0, 1]$, $[0, 2]$, $[0, 3]$, $[0, 4]$ 和 $[0, 5]$ 秒. 用户控制机器人绕过两个障碍物到达指定目标位置, 每次机器人行进距离不低于 15 米. 不同的用户 (共 4 人) 在上述五个延时区间下各有 2 次控制经历, 即共有 $4 \times 5 \times 2 = 40$ 次交互过程轨迹, 它们组成了原始数据集.

图 4 描述的是自主模式学习中每一步 EM 迭代所计算出来的相似度期望 $E[c_{im}|\alpha, d]$. 图中横坐标是 40 条交互过程轨迹 $\{d_1, d_2, \dots, d_{40}\}$, 纵坐标是 5 种机器人自主性模式 $\{M_1, M_2, \dots, M_5\}$, 其中从 M_1 到 M_5 对应的自主性值依次减小. 图中各列包括了每个交互过程轨迹 d_i 的期望 $E[c_{i1}|\alpha, d]$, $E[c_{i2}|\alpha, d]$, $E[c_{i3}|\alpha, d]$, $E[c_{i4}|\alpha, d]$ 和 $E[c_{i5}|\alpha, d]$. 每一个格子表示该格子横坐标所对应的交互过程属于其纵坐标所对应的自主模式的概率大小, 颜色越深表示概率值越大. 黑色表示概率值为 1, 也即该交互过程属于该模式; 无色则表示该交互过程属于该模式的概率是 0. 随着一步一步 EM 迭代, 数据集的所有交

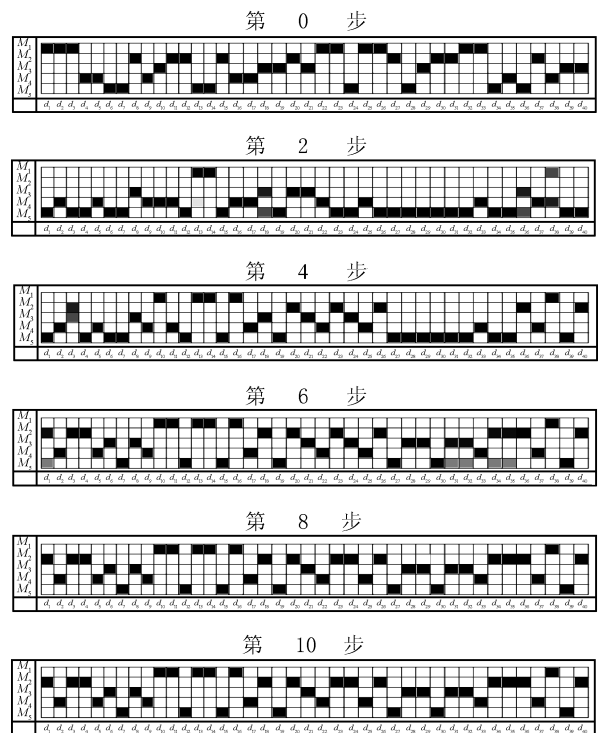


图 4 EM 算法不同迭代次数时计算的期望 $E[c_{im}|\alpha, d]$

Fig. 4 Expectations $E[c_{im}|\alpha, d]$ computed in the different iterations of the EM algorithm

互过程轨迹逐渐聚集到各个自主性模式类型下。

为避免学习过程陷入局部最大问题, 设定在初始时刻每一条交互过程的期望 $E[c_{i1}|\alpha, d], \dots, E[c_{i5}|\alpha, d]$ 都是单峰分布, 并随机选择确定哪一种自主模式占据着这唯一峰值. 图中第 0 步显示的就是按上述策略产生的初始期望分布.

从第 2 步开始, 表征分类不确定性的灰色块个数越来越少或颜色越来越淡. 这表明, 随着 EM 迭代的进行, 分类越发清晰, 聚类结果逐渐出来. 第 8 步后, 系统已经收敛到这样一个状态: 绝大部分交互数据都已经被分配给了唯一的自主模式, 还没有完成分类的交互过程也都有了全局最大期望. 到第 10 步, 每条交互过程对应的灰色块进一步减少, 最大期望进一步增大. 如 d_{20} 在第 8 步时有 M_1, M_2 和 M_3 三种可能属于的模式, 而到第 10 步时只有 M_2 和 M_3 两种了, 消除了 M_1 类; 又如 (M_2, d_{24}) 处在第 10 步时为 0.999, 大于第 8 步时的 0.9682. 由图 4 可以看到, 第 10 步以后只有 d_{13}, d_{20} 和 d_{24} 三个交互过程数据还陷于两种模式的抉择中, 但是其中每个交互过程对应的两个相似度都是大小悬殊, 如 d_{20} 对应的小的相似度是 0.0014, 而大的相似度已经达到 0.9985, 二者之比还不到 0.15%. 更重要的是, 自主性值的研究并不需要这么小的分辨率, 考虑这么小的自主性值是没有实际意义的. 因此本文简单地制定了如下一个机器人自主性模式聚类学习结束的判据:

$$\arg \max E[c_{im}|\alpha, d] > 99\% \quad (20)$$

当这个条件满足时, 占据着最大相似度的自主模式即是该交互过程所属的唯一类别. 根据这个判据, 聚类学习在第 10 步结束后完成, 所有的交互过程都准确地归类到各种典型自主性模式下.

实验中 $M = 5$ 而 $\delta = 0.1$. 这样的参数取值不仅保证了 M 和 δ 能够覆盖整个机器人自主性 $[0, 1]$ 的变化区间, 避免 EM 算法的局部最大问题, 也充分考虑了人机交互方式的多样性.

4.2 自主性模式与网络延时

EM 聚类学习得到多种典型自主性模式所对应的机器人自主性值. 实验发现, 自主性值不同的自主模式下任务执行方式和人机交互过程有着各自的特点. 自主性值为 1 的自主模式下, 任务的执行基本上都是由机器人独立完成; 自主性值为 0.89 的自主模式下, 用户虽然开始参与控制但是仍然很少, 这一模式在实验中体现为用户只用鼠标在地图上确定目标位置, 由机器人自主到达; 自主性值为 0.61 的模式下, 用户在地图上确定了一系列的中间点, 机器人自主地逐个遍历这些中间点; 自主性值为 0.28 的模式

下, 人机交互次数更多, 用户不仅指定了一系列中间位置还时时监督机器人运动, 并在机器人的自主行进中对其多次调整; 在自主性值为 0 的模式下, 控制任务都是由用户通过控制按钮直接操纵机器人实现的, 整个过程中机器人没有任何自主行为.

根据实验结果分析, 按照自主性值从大到小可总结出如下五种机器人自主性模式: 1) 全自主; 2) 目标点定向; 3) 中间点定向; 4) 基于中间点的监督控制; 5) 直接控制.

实验旨在得到机器人自主性模式和网络延时的关系, 即在不同网络延时下各种自主性模式有着怎样的表现. 为了考察各种单一自主性模式下网络机器人的任务执行情况, 本文进行了一系列实验. 图 5 描述的是延迟时间分别为 0 秒, 0.5 秒, 1 秒和 3 秒时, IOR 分别在目标点导向、中间点导向和直接控制三种模式下避过动静障碍到达指定目标 (从图示的起始位置 S 点出发到目标位置 G 点结束) 的运动轨迹. 图中的虚线是动态障碍物的移动轨迹, 运动方向是从上向下.

图 5(a) 是不存在延迟时 IOR 在三种自主性模式下的运动轨迹. 比起目标点导向和中间点导向, 直接控制下 IOR 的运行路径最短. 为了避开动态障碍物, 目标点导向下的 IOR 路径轨迹出现明显的拐角, 而增加了人机交互的中间点导向和直接控制则能轻松应付涉及动态障碍的避障问题. 在直接控制下人的智慧使得动态障碍物对机器人的运动影响极小, IOR 在用户的控制下径直到达 G 点.

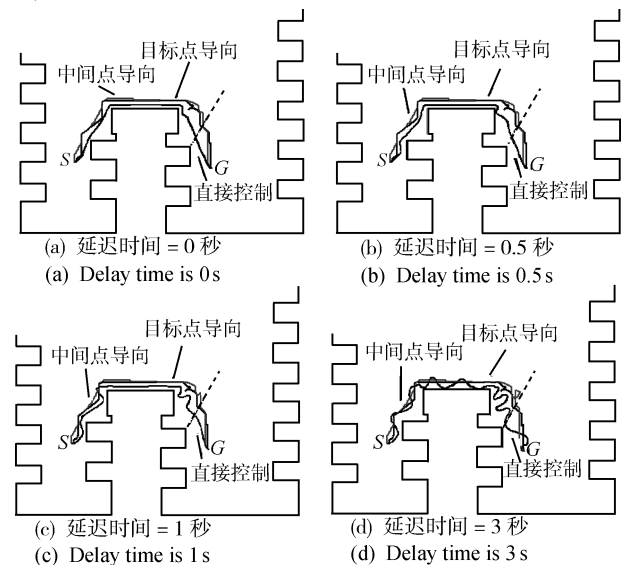


图 5 延迟时间分别为 0 秒, 0.5 秒, 1 秒和 3 秒时, IOR 在各个自主性模式下的路径 (虚线为动态障碍物运动轨迹)

Fig. 5 The paths of IOR with different autonomy levels when the delay times are 0, 0.5, 1, and 3 seconds, respectively (The dotted line depicts the path of the dynamic obstacle.)

图 5 (b) 显示的是延迟时间为 0.5 秒时 IOR 的运动轨迹. 与不存在延时相比, 目标点导向下的运动轨迹没有变化. 由于延迟时间很小, 中间点导向也基本不变, 0.5 秒的微小延时只是对直接控制略有影响, 这在图 5 (b) 中表现为其对应的路径轨迹略有波动. 值得一提的是, 没有延时或者延时很小时, 直接控制下在避开动态障碍的过程中, 都有 IOR 和障碍物很接近的情况, 这是由于直接控制充分发挥了人的优势的结果. 即使和障碍物很接近, 用户通过自己的判断和估计也能够避免碰撞, 此时的动态障碍躲避兼顾了安全和效率.

图 5 (c) 是延时为 1 秒时 IOR 在三种自主性模式下的运动轨迹. 目标点导向下的运动轨迹如前, 但延时给中间点导向和直接控制带来的影响已经逐步显现. 延时的增大使人机交互出现明显的问题. 在躲避动态障碍时, 中间点导向模式下的中间点选取也难以做到合理, 这在图 5 (c) 中表现为中间点导向下 IOR 的运动轨迹出现了不合适的拐角. 对于直接控制, 延时则带来更大的影响. 图 5 (c) 中直接控制模式下的 IOR 轨迹, 摆动次数增多了, 幅度也增大了.

图 5 (d) 显示的是延迟时间为 3 秒时 IOR 的运动轨迹. 目标点导向下的运动轨迹没有变化, 而中间点导向和直接控制则受到更大的影响, 性能明显下降. 在避开动态障碍时, 大延时使得用户对中间点的选取愈加困难甚至完全有悖于当时情况, 不合适的中间点使 IOR 的运动出现了转圈. 而直接控制下, 不仅 S 型的运动轨迹处处可见, 而且躲避动态障碍物时的轨迹更是摆动剧烈, 波动很大.

实验结果表明, 不同机器人自主性模式受延时影响的程度不同, 适用的延时情况也不同. 目标点导向模式下机器人自主完成任务时用户几乎不参与, 机器人拥有很大的通讯延时容忍度, 不管具有怎样的延时都能保持稳定的效率水平. 与目标点导向相比, 有一定人机交互的中间点导向效率较高, 但是拥有的延时容忍度减小了, 延时增大时效率降低. 直接控制方式下人对机器人的操作灵活, 可执行的任务范围大, 在小延时情形下能保持很高的效率, 但是受延时影响非常大, 随着延时增大系统效率急剧降低.

4.3 可调整自主性

为了评估可调整自主性的可行性和优越性, 从“以人为中心 (Human-centered)”和“以机器人为中心 (Robot-centered)”两个方面开展实验.

4.3.1 以人为中心

以人为中心的可调整自主性 (Human-centered adjustable autonomy, HAA) 允许用户在遥操作过程中, 根据面临的各种情况 (网络状况、环境形势、任务需要等) 手动调整机器人自主性模式.

图 6 显示了不确定延时下基于 3 种不同的自主性模式的 IOR 从起始位置 *S* 运动到目标 *G* 的路径, 图 6 (a)~6 (d) 四幅子图按时间顺序排列, 显示了机器人动态障碍躲避过程. 在不确定延时下, 目标点导向模式的 IOR 轨迹和效率仍然没有改变; 中间点导向下 IOR 避开动态障碍时路径的不平滑程度增加; 而直接控制下的 IOR 运动路径更长、更曲折.




图 6 不确定延时下 IOR 在各个自主性模式下的路径 (虚线为动态障碍物运动轨迹, 延时为 [0, 3] 秒内随机变化)

Fig.6 The paths of IOR with different autonomy levels when the delay time varies from 0s to 3s (The dotted line depicts the path of the dynamic obstacle.)

图 7 (a)~7 (d) 也是由按照时间顺序排列的四幅子图组成, 显示了不确定延时下基于 HAA 的 IOR 从位置 *S* 运动到 *G* 并动态避障的路径. IOR 开始于直接控制, 在到达 *A*, *B*, *C* 和 *D* 位置时, 自主性模式分别被用户切换到中间点导向、目标点导向、直接控制和目标点导向. 当 IOR 到达 *C* 点时 (见图 7 (a)), 由于延时用户还没有看到动态障碍, 对当前情况估计不足, 所以选择了由自己来直接控制机器人. 图 7 (b) 和 7 (c) 详细描述了这期间的 IOR 运动轨迹. 当 IOR 到达 *D* 点时, 用户才看见动态障碍迎面而来 (实际上, 图 7 (c) 已显示动态障碍已运动到 IOR 下方了, 但延时使用户看到的是此前时刻的情景), 因此又将自主模式调整成了目标点导向. 图 7 (d) 展示了 IOR 经过 *D* 点后到达终点 *G* 的运动轨迹. 与图 6 所示的任何单一自主性模式相比, 可调整自主性下的 IOR 运行路径质量更好, 就整个任务执行过程来看机器人系统保持着较高的效率.

4.3.2 以机器人为中心

以机器人为中心的可调整自主性 (Robot-centered adjustable autonomy, RAA), 就是在遥操




图7 不确定延时下具有以人为中心的可调整自主性能力的 IOR 的路径

(虚线为动态障碍物运动轨迹, 延时为 [0, 3] 秒内随机变化)
Fig. 7 The paths of IOR with HAA when the delay time varies from 0s to 3s (The dotted line depicts the path of the dynamic obstacle.)

作过程中机器人能够主动调整自身自主性以适应当前形势. 此时, 机器人需要知道怎样的自主模式才符合操作者的期望. 本节的实验首先考察了机器人在线评估操作者意图的能力, 接着检验了 RAA 对系统性能带来的帮助.

图 8 表现了第 0, 1, 3, 5, 7, 9 次人机交互行为后意图学习模型估计的各个自主模式的概率分布. 图中纵坐标表示自主模式的相似度期望, 横坐标对应 5 种自主模式. 实验之前, 对应于交互行为序列的用户真实意图 (图中以字母 *U* 标记) 已经确定, 它被用来和学习结果进行比较. 初始时设定机器人自主性模式的相似度期望是在整个自主模式允许值集合上的一致分布. 从第 1 步到第 3 步, 期望自主模式的相似度逐渐增大但还未达到全局最大, 这是因为交互行为数据太少, 机器人还不能学习到正确结果. 第 5 步时, *U* 标识的峰值最高但领先优势很小, 还不是稳定的全局最大. 随着交互行为的进行, *U* 标识的峰值继续增高, 其领先优势也不断扩大, 在第 7 步后已经成为了最显著的峰值. 第 9 步时, 期望模式相似度已经达到 0.46, 并对第二高度 0.26 有着 0.2 的领先优势, 这大大超过了第 5 步时的最高峰值 0.29 及其领先值 0.04. 经过足够样本的学习, 期望的自主模式稳定地占据了全局最大, 用户的意图已经被机器人成功捕获.

遥操作过程中机器人始终保持对用户意图的推断. 当某种自主模式相似度期望的领先值大于设定的门槛量时, 机器人自动调整到该自主模式, 直到有

新的满足判定条件的自主模式出现.

基于在线学习到的用户意图, 机器人协助用户在适宜的自主性模式上进行操作. 图 9 (a) 和 9 (b) 分别描述了 HAA 和 RAA 下, IOR 克服障碍从位置 *S* 运动到目标 *G* 的运动路径.

图 9 (a) 中, IOR 的控制从直接控制开始, 当到达 *A*, *B*, *C* 和 *D* 位置时, 它的自主模式分别被用户切换到中间点导向、目标点导向、直接控制和目标

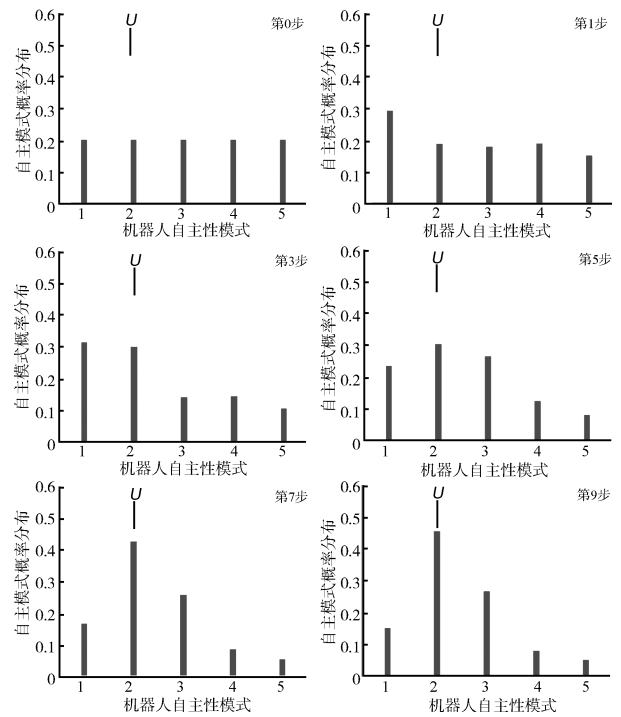


图 8 意图学习模型第 0, 1, 3, 5, 7, 9 次交互行为后推断的自主模式概率分布, 延时为 0~5 秒内随机变化

Fig. 8 When the delay time varies from 0s to 5s, user's intention inferred probability distributions after 0, 1, 3, 5, 7, 9 steps




图 9 不同控制策略下 IOR 的运动路径 (每个子图中的两个 *O* 点表示障碍物位置, 延时为 0~5 秒内随机变化)

Fig. 9 The paths of IOR with different control schemes: (a) HAA and (b) RAA when the delay time varies between 0s and 5s

(Two points labeled in each subplot by *O* are obstacles.)

点导向. 由于对哪种操作方式适合哪种网络状况并不清楚, 一般的 Internet 用户很难对自主模式进行恰当的调整. 如图 9(a) 中 $C \sim D$ 段曲线所示, 在当时的延时条件下, 直接控制是不应被选用的. 虽然用户察觉后立即进行切换, 机器人还是受到了一定的影响. 调整得是否合适和及时, 依靠操作者的经验和对任务的理解, 从这个意义上来说, 人的一些因素有时限制机器人系统性能和效率的提高.

如图 9(b) 所示, IOR 在直接控制下从起点 S 位置出发. 当 IOR 到达 A 位置时, 机器人已经根据当前人机交互和网络状况推断出控制意图, 发现当前控制方式并不合适, 于是提示用户使用预测结果——中间点导向模式. 从 A 点开始, 用户通过中间点指引 IOR 运动并顺利避过障碍物 (图中左边 O 位置处). 需要特别指出的是, 为了全面检验意图学习模型的能力, 本文有意采用了不适合当时网络状况的直接控制模式 (见图中 B 点前的小段波动轨迹). 由于机器人此时已经有了较多的交互经历, 学习数据充足, 这次控制意图的确定要快得多. 从 B 位置起用户再次依据机器人的提示在中间点导向下操作 IOR 前进. 随着控制过程的进行, 模型继续评估用户的操作意图. 到达 C 点位置时, 机器人基于进一步学习结果提示用户使用目标点导向, IOR 从 C 点开始在目标点导向下运动, 直至最后到达终点.

比较图 9(a) 和图 9(b) 所示的两种控制策略可知, 在任务执行前期 HAA 占优, 而后期则是 RAA 的性能更好. 这是因为人机交互刚开始时, 机器人缺乏学习样本, 无法确定用户意图, 而用户手动调整则是无需准备, 随时可行的. 这一情形在实验中具体表现为: 标识首次自主模式变换的 A 点在图 9(a) 中出现的时刻比在图 9(b) 中要早一些. 这说明机器人缺乏学习数据时, 人比机器人更具优势. 随着人机交互经历的增多, 机器人有了足够的学习数据来正确评估用户控制期望, 这时机器人能够协助用户进行操作的 RAA 就比可能局限于人为因素的 HAA 控制效果更好了. 比较图 9(a) 和图 9(b) 的 $C \sim G$ 段机器人路径, 不难看出后者轨迹更加平滑, 没有出现机器人摆动徘徊的现象. 与 HAA 相比, RAA 不仅可以有效地减少任务执行过程出现的明显不适宜自主模式, 还能够在出现模式选择错误后帮助用户尽快改正. 这些优势都有利于改善机器人系统完成任务的质量和效率.

无论是人主导还是机器人主导, 本文的实验都表明了动态可变的自主性有利于改善和提高遥操作机器人系统的性能和效率. 同时, 实验结果也初步揭示了人和机器人在遥操作控制中的各自具有的优势, 这对遥操作机器人系统的研究、设计和开发有一定的指导意义.

5 结论

本文研究了网络机器人的可调整自主性, 赋予机器人动态可变的自主性来适应动态不确定的网络延时. 讨论了遥操作系统中机器人自主性的表示和测量, 这是进行自主性调整和应用的基础; 提出机器人自主性模式学习模型, 机器人从人机交互中学习典型的自主模式, 并定性分析得到适合不同网络状况的机器人自主性模式; 通过用户手动或机器人在线评估用户意图后主动调整机器人的自主性, 用户和机器人在适应控制需要和延时状况的自主性模式下进行交互, 改善和提高了整个机器人系统的性能和效率. 实验结果证明了本文思想和方法的可行性和有效性.

进一步的工作是将可调整自主性的思想运用到更复杂的机器人遥操作任务中, 以完善自主性模式学习和用户意图评估的模型并扩展其适用性. 与已有控制方法相结合 (如一些延时预测方法等), 以及对遥操作系统中的人机关系以及机器人自主性的深入探讨, 也将是需要进一步研究的课题.


References

- 1 Bejczy A K, Venema S, Kim W S. Role of computer graphics in space telerobotics: preview and predictive displays. In: Proceedings of the Conference on Cooperative Intelligent Robotics in Space. Boston, USA: SPIE, 1990. 365–377
- 2 Sayers C. *Remote Control Robotics*. New York: Springer-Verlag, 1989. 95–116
- 3 Sheridan T. *Telerobotics, Automation, and Human Supervisory Control*. Cambridge: MIT Press, 1992. 199–226
- 4 Ito T, Suzuki Y, Matsui T. Alternative predictive display method of motion and force information without using environment model-design of real-image-based network teleoperation system. In: Proceedings of the International Conference on Control Applications. Toronto, Canada: IEEE, 2005. 314–321
- 5 Anderson R J, Spong M W. Bilateral control of teleoperators with time delay. *IEEE Transactions on Automatic Control*, 1989, **34**(4): 494–501
- 6 Niemeyer G, Slotine J J E. Stable adaptive teleoperation. *IEEE Journal of Oceanic Engineering*, 1991, **16**(1): 152–162
- 7 Cho H C, Park J H, Kim K, Park J O. Sliding mode based impedance controller for bilateral teleoperation under varying time delay. In: Proceedings of the International Conference on Robotics and Automation. Seoul, Korea: IEEE, 2001. 1025–1030
- 8 Xi N, Tarn T J. Action synchronization and control of internet based telerobotic systems. In: Proceedings of the International Conference on Robotics and Automation. Detroit, USA: IEEE, 1999. 219–224
- 9 Lee D, Spong M W. Passive bilateral teleoperation with constant time delay. *IEEE Transactions on Robotics*, 2006, **22**(2): 269–281
- 10 Tanner N A, Niemeyer G. Practical limitations of wave variable controllers in teleoperation. In: Proceedings of the International Conference on Robotics, Automation and Mechatronics. Singapore, Singapore: IEEE, 2004. 25–30

- 11 Jing Xing-Jian, Wang Yue-Chao, Tan Da-Long. Control of time-delayed tele-robotic systems: review and analysis. *Acta Automatica Sinica*, 2004, **30**(2): 214–223
(景兴建, 王越超, 谈大龙. 遥操作机器人系统时延控制方法综述. 自动化学报, 2004, **30**(2): 214–223)
- 12 Arcara P, Melchiorri C. Control schemes for teleoperation with time delay: a comparative study. *Robotics and Autonomous Systems*, 2002, **38**(1): 49–64
- 13 Morrow D, Wickens C, Rantanen E, Chang D, Marcus J. Designing external aids that support older pilots' communication. *International Journal of Aviation Psychology*, 2008, **18**(2): 167–182
- 14 Luo R C, Chen T M. Supervisory control of multisensor integrated intelligent autonomous mobile robot via internet. In: Proceedings of the International Conference on Intelligent Processing Systems. Gold Coast, Australia: IEEE, 1998. 12–16
- 15 Kawabata K, Ishikawa T, Fujii T, Noguchi T, Asama H, Endo I. Teleoperation of autonomous mobile robot under limited feedback information. In: Proceedings of the International Conference on Field and Service Robotics. Canberra, Australia: Springer Verlag, 1997. 158–164
- 16 Simmons R, Fernandez J L, Goodwin R, Koenig S, O'sullivan J. Lessons learned from Xavier. *IEEE Robotics and Automation Magazine*, 2000, **7**(2): 33–39
- 17 Dorais G A, Bonasso R P, Kortenkamp D, Pell B, Schreckenghost D. Adjustable autonomy for human-centered autonomous systems on Mars. In: Proceedings of the Founding Convention of the Mars Society. Boulder, USA: The Mars Society, 1998. 397–420
- 18 Pollack M E, Tsamardinos I, Horty J F. Adjustable autonomy for a plan management agent. In: Proceedings of the AAAI Spring Symposium on Agents with Adjustable Autonomy. Menlo Park, USA: AAAI, 1999. 101–105
- 19 Scerri P, Reed N E. Designing agents for systems with adjustable autonomy. In: Proceedings of the International Joint Conference on Artificial Intelligence Workshop on Autonomy, Delegation, and Control: Interacting with Autonomous Agents. Seattle, USA: AAAI, 2001. 97–102
- 20 Scerri P, Pynadath D, Tambe M. Adjustable autonomy in real-world multi-agent environments. In: Proceedings of the International Conference on Autonomous Agents. Montreal, Canada: ACM, 2001. 300–307
- 21 Crandall J W, Goodrich M A. Experiments in adjustable autonomy. In: Proceedings of the International Conference on Systems, Man, and Cybernetics. Tucson, USA: IEEE, 2001. 1624–1629
- 22 Perzanowski D, Schultz A C, Adams W, Marsh E. Goal tracking in a natural language interface: towards achieving adjustable autonomy. In: Proceedings of the International Symposium on Computational Intelligence in Robotics and Automation. Monterey, USA: IEEE, 1999. 208–213
- 23 Breazeal C. A motivational system for regulating human-robot interaction. In: Proceedings of the National Conference on Artificial Intelligence. Madison, USA: AAAI, 1998. 54–62
- 24 Martin C E, Barber K S. Representation of autonomy in distributed agent-based systems. In: Proceedings of the International Multidisciplinary Conference on Intelligent Systems: A Semiotic Perspective. Gaithersburg, USA: National Institute of Standards and Technology, 1996. 67–72
- 25 Dempster A, Laird N, Rubin D. Maximum likelihood from incomplete data via the EM algorithm. *Journal of the Royal Statistical Society, Series B*, 1977, **39**(1): 1–38
- 26 Ayer S, Sawhney H. Layered representation of motion video using robust maximum-likelihood estimation of mixture models and MDL encoding. In: Proceedings of the International Conference on Computer Vision. Cambridge, USA: IEEE, 1995. 777–784
- 27 Shatkay H, Kaelbling L. Learning topological maps with weak local odometric information. In: Proceedings of the International Joint Conference on Artificial Intelligence. Nagoya, Japan: Morgan Kaufmann Publishers, 1997. 920–927
- 28 Thrun S, Fox D, Burgard W. A probabilistic approach to concurrent mapping and localization for mobile robots. *Autonomous Robots*, 1998, **5**(3-4): 253–271
- 29 Thrun S, Martin C, Liu Y F, Hahnel D, Emery-Montemerlo R, Chakrabarti D. A real-time expectation-maximization algorithm for acquiring multiplanar maps of indoor environments with mobile robots. *IEEE Transactions on Robotics and Automation*, 2003, **20**(3): 433–442
- 30 Bennewitz M, Burgard W, Thrun S. Learning motion patterns of persons for mobile service robots. In: Proceedings of the International Conference on Robotics and Automation. Washington D. C., USA: IEEE, 2002. 3601–3606
- 31 Nilsson N J. *Artificial Intelligence: A New Synthesis*. San Francisco: Morgan Kaufmann, 1998. 139–151
- 32 The PingER Project [Online], available: <http://www-iepm.slac.stanford.edu/pinger/>, August 29, 2009
- 33 Lin Yu, Cheng Shi-Duan, Wu Hai-Tao, Jin Yue-Hui, Wang Wen-Dong. The achievement of end-to-end performance measurement technologies in IP networks. *Acta Electronica Sinica*, 2003, **31**(8): 1227–1233
(林宇, 程时端, 邬海涛, 金跃辉, 王文东. IP 网端到端性能测量技术研究的进展. 电子学报, 2003, **31**(8): 1227–1233)
- 34 Zhang Hong-Li, Fang Bin-Xing, Hu Ming-Zeng, Jiang Yu, Zhan Chun-Yan, Zhang Shu-Feng. A survey on internet measurement and analysis. *Journal of Software*, 2003, **14**(1): 110–116
(张宏莉, 方滨兴, 胡铭曾, 姜誉, 詹春艳, 张树峰. Internet 测量与分析综述. 软件学报, 2003, **14**(1): 110–116)



苏剑波 博士, 上海交通大学自动化系教授. 主要研究方向为网络机器人, 多传感器信息融合, 机器学习与人机交互. 本文通信作者. E-mail: jbsu@sjtu.edu.cn
(**SU Jian-Bo** Ph.D., professor in the Department of Automation, Shanghai Jiao Tong University. His research interest covers network robotics, multi-sensor fusion, machine learning, and human-computer interaction. Corresponding author of this paper.)



周玮 2007 年获得上海交通大学博士学位. 主要研究方向为智能机器人和人机交互. E-mail: zhwme@hotmail.com
(**ZHOU Wei** Received his Ph. D. degree from Shanghai Jiao Tong University in 2007. His research interest covers intelligent robotics and human robot interaction.)