

触控交互运动模型研究

摘要

人机交互是一个广受关注的交叉学科领域，用户界面是其主要的实现手段。用户界面经历了批处理界面、命令行界面和图形用户界面三次主要变革，其中，图形用户界面由于其直接操纵和技术成熟等因素，与其它用户界面相比具有明显优势，三十年来一直处于统治地位。近些年来，随着计算设备越来越小型化、普世化和智能化，人机交互步入了自然用户界面发展阶段。

触控交互技术是图形用户界面和自然用户界面中应用最为广泛的人机交互技术。触控交互技术包括触摸屏、实物交互等直接触控交互技术，也包括鼠标、触控笔、跟踪球等非直接触控交互技术，是当前人机交互学术界的热点，涌现了大量的创新型交互方式和充分的用户研究。然而，我们在不停地开发新技术和进行新的实验时，总是发现缺少具有指导意义的理论依据，Fitts' Law、Steering Law 等一些经典的人机交互理论模型在新的交互场景和任务中不再适用，或者需要研究人员根据具体的任务对其进行修正。因此，我们急需新的理论模型，能够适应新的触控交互任务和场景，能够让我们更好地理解影响用户表现和用户行为的内在机制，对交互结果做出精准预测，对交互中的用户行为做出定量描述。

在本文中，针对现有工作在移动目标获取研究的空缺，我们开展了移动目标获取不确定性建模研究，得到了一个移动目标获取的落点分布描述模型，可以准确地对落点分布进行预测；针对现有模型对连续交互运动描述的不足，我们开展了目标获取的最优反馈控制模型研究，构建了一个基于最优反馈控制的交互运动模型，实现了对静止和运动目标获取任务的运动仿真；针对现有交互运动用户特征体系的欠缺，开展了基于局部轨迹分析的运动特征研究，建立了一个任务无关的用户特征集，对现有用户评价体系进行了有效补充。本文将上述三项研究成果应用于实际触控交互场景中，对目标获取的错误率进行了有效预测，得到了一项隐式的目标选择技术，构建了一个基于绘图任务的用户运动功能评价系统，并在实际使用条件下进行了验证。

本文的主要创新点如下：

1. 首次对移动目标获取任务的落点不确定性进行建模，弥补了当前人机交互研究中移动目标获取用户表现研究的空缺。

2. 首次引入最优反馈控制机制对交互运动进行建模，为人机交互研究引入了一个新的思路，为理解和解析交互运动的过程特性提供支持。

3. 基于绘图轨迹局部运动分析，建立了一个任务无关的用户特征提取方法，实现了一般绘图任务下的用户手功能定量评价，并将相关成果应用于多家大型三甲医院的临床诊断当中。

本文的研究工作能够为触控交互的研究提供更多的理论和经验参考，指导未来触控交互界面的定量化设计，支撑新型触控交互技术的开发与实现。

关键词：人机交互、触控交互、运动模型、不确定性、反馈控制、用户特征

A Study of Motor Behavior Model on Touch Interactions

Abstract

Human-computer interaction (HCI) is a cross disciplinary which is receiving considerable attention recently. User interface is the key implement technique of HCI, it has undergone three major transformations: batch interface, command line interface and graphical user interface (GUI). Because of the maturity and usability, graphical user interface distinguishes from other user interfaces and has played a leading role for the last three decades. In recent years, as the computing devices are becoming smaller, more ubiquitous and more intelligent, human computer interaction has entered a new era, the stage of natural user interface (NUI).

Touch interaction is a widely applied technology in GUI and NUI. With touch user interface, users are able to interact with a machine by touching its screen or surface directly, or by manipulating an associated mouse, stylus, or trackball in an indirect manner. Currently, both the direct or indirect touch interactions have been paid particular attention. Numerous of relevant technologies have been developed, and their performance has been evaluated by adequate user studies. The classic interaction models, such as Fitts' Law and Steering Law, have been used as a theoretical foundation in developing new technologies and in obtaining new experiment data. However, such models may be no longer directly available in touch interaction scenarios or tasks. Therefore, it is imperative to establish a new theoretical model for touch interaction. With the model, not only the interaction results can be predicted accurately and precisely, but the essential factors affecting user performance and behavior can be analyzed qualitatively and quantitatively.

In this paper, to make up for the disadvantages of existing uncertainty models, we conducted a study on modeling the uncertainty on moving target acquisition, and proposed a model to be descriptive of distribution on moving target acquisition, by the help of the model, we can accurately predict the distribution in such tasks; To fill the blank of describing the process properties in existing motor behavior models, we conducted a study on modeling general target acquisition leverage optimal feedback control mechanism, and built an motor behavior model beads on optimal feedback control for static and moving targets, which can be sued to closely simulate the whole process of user motions in these scenarios; Aiming at the

disadvantages of existing user features extraction methods, we conducted a study on user features based on analyzing local trajectory motion, and a task independent user feature set was found, being a good complement to the existing research on user performance. Finally, we applied and evaluated the results of these three research on real-world interaction scenarios: we demonstrated how we can predict error rate of target selection in a user interface and then built an implicit target selection technique to assist the selection in that interface; we built an evaluation system for user motor function based on drawing tasks.

The main innovations of this paper are as follows:

1. The first study on modeling the uncertainty of moving target acquisition in HCI community, which supply the gap of moving target acquisition of the research on user performance.

2. The first attempt leveraging the optimal feedback control mechanism to model user's motor behavior, which introduced a new idea for HCI research on user behavior, providing new means for understanding and analyzing the process properties of interaction behavior.

3. Based analyzing local motion trajectory, a task independent user feature extraction method was found, which can be used to quantitative evaluate the user's motor function under the general drawing tasks. Our method has been used in many large tertiary hospitals.

We believe that this research can provide more theoretical supports and empirical evidences for the research on direct and indirect touch interfaces, guide the future quantitative design on the interfaces, and support the development and implementation of novel interaction technologies on the interfaces.

Keywords: human-computer interaction, touch interaction, motor behavior model, uncertainty, feedback control, user feature

目录

第 1 章 绪论	3
1.1 引言	3
1.2 触控交互在人机交互中的地位	3
1.3 本文动机和主要工作	4
1.4 论文组织结构	7
第 2 章 国内外研究进展	9
2.1 运动时间模型	9
2.2 运动不确定性模型	14
2.3 最优反馈控制模型	17
2.4 基于运动模型的交互应用技术	19
2.5 本章小结	21
第 3 章 触控交互运动的不确定性模型研究	23
3.1 引言	23
3.2 目标获取不确定性模型假设	24
3.3 任务参数对不确定性的影响	26
3.4 模型参数估计与实验验证	30
3.5 不确定性模型的在笔和触屏设备上的适用性	33
3.6 本章小结	38
第 4 章 触控交互运动的反馈控制模型研究	39
4.1 引言	39
4.2 最优反馈控制机理	39
4.3 基于最优反馈控制的运动模型构建	41
4.4 运动关键参数优化	44

4.5 模型参数估计与实验验证	46
4.6 本章小结	52
第 5 章 触控交互运动的用户特征研究	53
5.1 引言	53
5.2 绘图任务和任务自由度	53
5.3 通用轨迹切分算法	55
5.4 任务无关的绘图特征提取	60
5.5 本章小结	70
第 6 章 触控交互运动模型应用研究	73
6.1 引言	73
6.2 模型辅助的错误率预测和目标选择技术应用	73
6.3 基于轨迹特征的用户运动功能评价	81
6.4 本章小结	97
第 7 章 总结与展望	99
7.1 论文工作总结	99
7.2 进一步工作的讨论	100
参考文献	101
就读博士期间发表的学术论文目录	109
就读博士期间参加研究的课题项目	110
致谢	111

图目录

图 1 Fitts' Law 目标获取任务.....	9
图 2 MacKenzie 定义的 2D 目标获取任务.....	10
图 3 Murata 定义的 3D 目标获取任务	11
图 4 Steering Law 中一个长为 A 宽为 W 的笔直通道.....	12
图 5 Steering Law 中一个以 C 为曲线 W(s)为宽度的弯曲通道.....	12
图 6 Shota 的连续线性分段路径和分段假设[34]	13
图 7 用户对于目标大小理想利用情况、欠利用情况和过利用情况[2]	15
图 8 时域目标获取任务和错误率模型示意图[38]	17
图 9 一个典型的最优反馈控制系统.....	18
图 10 时域目标获取任务和错误率模型示意图	20
图 11 时域目标获取任务和错误率模型示意图[42]	21
图 12 1D 移动目标获取任务设置	24
图 13 实验设置和被试参与实验的情况.....	27
图 14 实验 1 中 4 种情况下实际的落点情况, 灰色区域代表目标.....	28
图 15 实验 2 中 16 种情况下实际的落点情况, 灰色区域代表目标.....	29
图 16 μ 在 4 种 V 情况 (a) 和 4 种 W 情况 (b) 下的均值	29
图 17 σ 在 4 种 V 情况 (a) 和 4 种 W 情况 (b) 下的均值	30
图 18 W 和 V 之间在 μ 和 σ 上的交互作用.....	30
图 19 模型的 $\mu=f(V,W)$ 函数的 3D 图形和经验数据对比	32
图 20 模型的 $\sigma=g(V,W)$ 函数的 3D 图形和经验数据对比.....	32
图 21 笔 (a) 和触屏 (b) 设备上的实验适用性实验	33
图 22 笔设备上模型的 $\mu=f(V,W)$ 函数的 3D 图形和经验数据对比	35
图 23 笔设备上模型的 $\sigma=g(V,W)$ 函数的 3D 图形和经验数据对比.....	35
图 24 触屏设备上模型的 $\mu=f(V,W)$ 函数的 3D 图形和经验数据对比	37
图 25 触屏设备上模型的 $\sigma=g(V,W)$ 函数的 3D 图形和经验数据对比.....	37

图 26 开环最优控制和闭环最优控制的任务计划阶段[21]	40
图 27 最优反馈控制系统的运行过程[68]	41
图 28 目标获取实验设置和被试参与实验的情况	47
图 29 静止目标获取 (a) 和动态目标获取 (b) 实验设置	47
图 30 静止目标获取 (a) 和移动目标获取 (b) 的实验数据与仿真结果对比	49
图 31 静止目标获取的经验数据和仿真结果的原始轨迹对比	50
图 32 九个移动目标获取的经验数据和仿真结果的原始轨迹对比	50
图 33 利用本模型模拟的四个交互运动过程	51
图 34 绘图任务自由度空间以及 5 个典型的绘图任务在此空间中的分布	54
图 35 一个图形复制任务的子轨迹切分	56
图 36 通用轨迹切分算法的工作流程	59
图 37 装有压力传感器和陀螺仪的触控笔数的各项数据获取通道	60
图 38 一个子轨迹的原始采样点和其 IMC	61
图 39 离散的有序点集中的曲率计算步骤	61
图 40 一个绘图任务中运动参数的可视化表示	64
图 41 点、轨迹、图形级运动信息的关系	66
图 42 从绘图任务中提取用户特征的流程	67
图 43 错误率通过对分布在目标外的部分进行积分计算	75
图 44 远离方向和靠近方向 16 种情况下的实际错误率和预测错误率	75
图 45 BayesPointer 的工作过程。(a) 界面中的两个具有不同速度和大小的移动目标; (b) 蓝色的目标被 BayesPointer 确定为意图目标	77
图 46 “Don’t Touch The White Tile”游戏的原始界面和本文中实现的三个变种	78
图 47 游戏中 12 中情况的经验和预测错误率	80
图 48 两种选择技术在 3 个游戏级别中的得分和错误率情况对比	80
图 49 连线测试和画钟测试	83
图 50 螺旋线测试、图形复制测试和文字书写测试	84
图 51 基于绘图任务的神经系统疾病诊断系统框架	84
图 52 (a) 本套系统的硬件示意图 ⁵ (b) 实际使用情况	85

图 53 本套系统的配套软件界面	86
图 54 患者组和对照组的性别分布、平均年龄和 MoCA 评分	87
图 55 选择的特征在三个不同类别特征分类中的分布	89
图 56 10 个特征的概率密度函数	92
图 57 三个变化率相关特征的概率密度函数	93
图 58 三个压力相关特征的概率密度函数	93
图 59 三个信息熵相关特征的概率密度函数	93
图 60 三个主频率能量相关特征的概率密度函数	94
图 61 三个分类器在特征数量递增时的分类准确度	95

表目录

表 1 估计的模型参数和回归系数 R^2	31
表 2 笔设备上估计的模型参数和回归系数 R^2	34
表 3 触屏设备上估计的模型参数和回归系数 R^2	36
表 4 静止目标获取和动态目标选择任务的最终估计参数.....	48
表 5 静止目标获取和动态目标选择任务的相似度.....	49
表 6 所有运动参数和他们的符号.....	62
表 7 所有特征提取方法和方法组划分.....	67
表 8 运动参数、匹配的方法组以及计算得出的特征数.....	68
表 9 ODS 和 5 个测试数据集中具有最大信息增益的特征列表.....	90
表 10 三个分类器在所有数据集中的最佳分类性能.....	95
表 11 通用模型在 5 个测试中的分类性能.....	96

第1章 绪论

1.1 引言

人机交互（human-computer interaction, HCI）是一个广受关注的交叉学科领域，是一门对人类使用的交互式计算系统进行设计，评估，和实现，并对其所涉及的主要现象进行研究的学科[5]。用户界面（user interface, UI）是指计算机和它的使用者之间的对话接口，是计算机系统的重要组成部分，是计算机科学、心理学、认知科学和人素学（human factors）的交叉研究领域[7]，它是人机交互的关键实现技术，随着计算机网络的普及，用户界面已经成为了人们日常使用最广泛的计算机技术之一，它的好坏直接影响人们日常生活和工作的质量、效率和体验。

迄今为止，用户界面的发展经历了三次主要演变：批处理界面、命令行界面和图形用户界面（graphical user interface, GUI），图形用户界面由于其直接操纵和技术成熟等因素，与其它用户界面相比具有明显优势，在近三十年中一直处于统治地位。随着技术的不断进步和发展，近年来，又出现了三维（three-dimensional, 3D）用户界面，语音用户界面，基于生理计算的用户界面和多通道用户界面等，进入了自然用户界面（nature user interface, NUI）发展阶段。

触控交互技术是图形用界面和自然用户界面中应用最为广泛的人机交互技术。触控交互技术包括触摸屏、实物交互等直接触控交互技术，也包括鼠标、触控笔、跟踪球等非直接触控交互技术，是当前人机交互学术界的研究热点，涌现了大量的创新型交互方式和充分的用户研究。然而，我们在不停地开发新技术和获取新的实验数据时，总是缺少理论依据，Fitts' Law、Steering Law 等一些经典的人机交互理论模型在新的交互场景和任务中不再适用，或者需要研究人员根据具体的任务对其进行修正。因此，我们急需新的理论模型，能够适应新的触控交互任务和场景，能够让我们更好的理解影响用户表现和用户行为的内在机制，对交互结果做出精准预测，对交互中的用户行为做出定量描述。

1.2 触控交互在人机交互中的地位

本文将触控交互定义为用户使用手或身体的其他部位，通过触摸、移动、抓握、旋转等方式控制直接或者非直接点选设备（pointing device），实现人对用户界面的控制输

入的一类交互方式。从交互通道来看,触控交互主要对用户界面的输入方式进行了限定,触控交互必须包含用户可触及的实体点选设备,例如触摸屏(touchscreen)、触控笔(stylus),不包含此类设备的交互方式,例如语音交互、脑机接口等则不属于触控交互的范畴,触控交互以视觉反馈,例如显示器,作为主要的输出手段,但不限于此。从点选设备来看,触控交互包括直接触控和非直接触控两种方式,直接触控则是指输入空间与视觉反馈空间是绝对关系的交互方式,例如触摸屏、交互桌面(interaction desktop)或者可绘图显示板(drawable display)等,这些设备上的输入信号与显示器中的视觉反馈信号保持一致。非直接触控是指输入空间与视觉反馈空间是相对关系的交互方式,例如通过鼠标、跟踪球(trackball)、手写板等外部触控设备对显示器中的交互组件进行控制,外部触控设备的输入信号,例如鼠标的物理位置,与显示器中的视觉反馈信号,例如光标,是相对位置关系。

触控交互技术是图形用户界面和自然用户界面中应用最为广泛输入技术。Ralph Benjamin 在 1946 年发明了跟踪球,它是一个非直接点选设备,被用于二战后的一个名为 CDS (Comprehensive Display System) 的火控雷达标绘系统中,跟踪球是最早得到广泛使用的触控输入设备。1964 年, Douglas Engelbart 在 Bill English 的帮助下发明了第一个鼠标原型[29], Xerox Alto 计算机在 1973 年被发明,成为了首台为个人用途设计的并启用鼠标的计算机¹, 1984 年苹果公司将鼠标用于他们 Macintosh 计算机和 Mac 操作系统中开始,鼠标开始成为最为广泛使用的点选设备。1957 年, Tom Dimond 首次将触控笔用于计算设备,今天,触控笔被广泛地用于便携式计算机、平板电脑、智能手机和专门为触控笔设计的绘图板当中,并催生了笔式用户界面交互方式。E.A. Johnson 于 1965 年最先提出了电容触摸屏,1968 年,触摸屏技术被用于一个空中交通控制系统中,今天,因为移动设备的快速发展和直接触控带来的感知学习优势,触摸屏已经成为了普通用户最常用的交互设备,几乎所有的智能手机和平板电脑都配备了这种触控设备。触控交互技术的好坏直接影响着人们日常生活和工作的质量、效率和体验。

1.3 本文动机和主要工作

尽管半个世纪以来,成功的触控交互应用和产品层出不穷,但我们仍然不了解藏在他们背后的原理。1990 年, Thimbleby 在《User Interface Design》[8]一书中写到,“我们能在复杂的系统上做很多实验,让大量的用户来评估系统,做复杂的统计测试等等,但只有当我们知道我们为何这样做,并清楚实验的结果会如何指导今后的工作,这些事情

¹ https://en.wikipedia.org/wiki/Xerox_Alto

才会变得有意义”，“我搜索了大量文献，想找到能够应用在我的场景中的理论”然而，“我没能找到任何理论，只找到了实验报告——一些报告与我的问题相关——但是，没有背后的理论支撑，我无法知道这些结果能否安全的应用于不同的设计方案，适应于使用不同语言的不同用户身上”。

事实上，在人机交互学术界的文献中，我们仍能够看到一些少数可靠的理论框架，Fitts' Law[9]和 Steering Law[15]对触控交互中的目标获取和轨迹任务的完成时间进行了准确的预测。但是，随着例如计算机游戏、交通控制系统、视频监视系统等具有动态内容的交互系统的普及，上述两个模型已经无法满足需求，以典型的移动目标获取任务为例，用户获取移动目标的过程要比静态目标更加的复杂和困难，他们必须连续地追踪这些移动着的物体，并同时做出决策点选它们，其中涉及了反馈-决策的复杂闭环控制过程，目标获取的用户表现也与目标的移动速度有关，简单的静态目标获取模型已经无法适用。此外，这些模型都仅对交互运动的结果做出预测，而忽略了运动过程，实际上，交互运动过程对于界面设计也十分重要，例如在《水果忍者》这类以滑动轨迹作为基本输入方式的游戏中，用户必须确保滑动轨迹避开炸弹而击中水果，此时应用以往的忽略中间运动过程模型，则难以对用户表现进行准确地估计。在触控交互运动的用户表现中，以往的理论主要集中于完成时间和选择错误率，实际上，一个简单的轨迹任务包含着大量的交互信息，利用轨迹信息和运动学原理对这些信息提取出可量化的用户行为特征，能够为触控交互界面提供用户状态感知的可能。

因此，为了能够更好地理解触控交互中影响用户表现和用户行为的内在机制，更好地支撑触控交互技术的开发，并对未来触控用户界面设计提供指导，本文针对现有触控交互运动模型的缺点，开展了对触控交互运动的不确定性模型和最优反馈控制模型的研究，基于这两项研究，对移动目标获取的错误率和目标获取意图预测，并给出一般目标获取任务的用户行为仿真，提出了基于轨迹任务的用户行为特征提取方法，并将它们应用于现实的交互界面中进行验证。

现将本文的主要工作总结如下：

1. 触控交互运动的不确定性模型研究

(1) 移动目标获取落点分布的模型假设

通过文献调研，和一个预实验的观察，对移动目标获取落点分布规律做出三高斯(Ternary-Gaussian)分布假设，并在该假设的基础上推导出落点分布模型的表达式。

(2) 任务参数对落点分布的影响

通过两个实验探究移动目标获取落点分布受到目标初始位置、移动速度、目标大小

的影响及相互作用，对提出的落点分布假设进行验证。

(3) 落点分布模型的参数估计

利用实验数据，对模型中的参数进行估计，将模型和实验数据进行拟合度，对其进行验证。

(4) 落点分布模型在触屏和笔设备上的验证

设计实验，将落点分布模型在触屏和笔设备上的表现进行验证。

2. 触控交互运动的反馈控制模型研究

(1) 利用最优反馈控制系统构建目标获取模型

将人机交互基本过程与最优反馈控制系统进行比对，形成利用最优反馈控制系统构建目标获取模型的核心思想，并基于此得出模型的最优反馈控制表达式。

(2) 运动关键参数优化

利用最优反馈控制系统构建的目标获取模型包含大量的参数，我们对模型进行了分析，找到了关键的影响参数，并设计了一个相似度评价指标和一个随机搜索算法对这些关键参数进行优化。

(3) 模型参数估计与实验验证

设计实验收集静止目标获取和移动目标获取的实验数据，利用数据对模型参数进行估计并对模型方针效果进行评估。

3. 触控交互运动的用户特征研究

(1) 轨迹任务与绘图任务用户特征与自由度分析

分析轨迹任务中的运动特征，给出轨迹任务与绘图任务的联系，分析绘图任务的自由度与用特征、场景设计之间的关系，为用户特征提取提供依据。

(2) 任务无关的轨迹切分算法

从绘图任务自由度出发，分析了构建任务无关的切分算法的必要性，并基于绘图任务轨迹局部几何极值和时空信息构建了一个任务无关的轨迹切分算法。

(3) 任务无关的绘图任务用户特征提取

给出一组特征提取算法，构建了一个特征提取策略，实现了从通用绘图任务数据中提取用户特征的目的。

4. 触控交互运动模型的应用研究

(1) 模型辅助的错误率预测技术

利用移动目标获取的落点分布模型和高斯累积分布函数（cumulative distribution function, CDF）推导出用户选择移动目标时的错误率模型，对选择准确性进行预测。

(2) 模型辅助的目标获取技术

利用落点分布模型辅助的意图预测规则，构建一个不对用户界面进行额外修改的目标获取技术，并将其应用于一个实际的游戏场景中，验证了本文运动模型的有效性。

(3) 基于轨迹特征的用户运动功能评价

将本文提出的任务无关的用户特征，对神经系统疾病患者的手部运动功能进行评价，实现了一个基于通用绘图任务的神经系统疾病日常监测和早期预警系统。

1.4 论文组织结构

全文共分为六章。

第一章：绪论。从人机交互的发展出发，阐明了触控交互的范畴和重要意义，分析了目前触控交互理论模型的缺陷和挑战，给出了本文的写作动机和工作的意义，最后对本文所做的主要工作和论文的组织结构做出说明。

第二章：国内外研究进展。分别阐述了当前国内外学者，在任务完成时间预测、不确定性规律、用户表现评估和触控交互技术四个方面的研究工作，总结了这些工作的优点和缺陷，为本文的主要工作建立了理论基础。

第三章：触控交互运动的不确定模型研究。提出了 Ternary-Gaussian 落点分布模型假设，基于此建立了一个 1D 移动目标获取的落点分布模型，在鼠标、笔和触屏三种不同触控设备上进行了实验验证，并对它进行了 2D 拓展；

第四章：触控交互运动的反馈控制模型研究。建立了一个一般目标获取任务的反馈控制模型，利用轨迹相似度评级指标和一个随机搜索算法对模型参数进行了估计，并对模型进行了实验验证。

第五章：触控交互运动的用户特征研究。分析轨迹任务中的运动特征和绘图任务的自由度与用特征、场景设计之间的关系，基于绘图任务轨迹局部几何极值和时空信息构建了一个任务无关的轨迹切分算法，构建了一个特征提取策略，实现了从通用绘图任务数据中提取用户特征的目的。

第六章：触控交互运动模型应用研究。给出了模型辅助的错误率预测和目标选择技术，将它们在一个真实的游戏应用中进行了验证；将绘图任务中提取的用户特征，应用于神经医学对病人的手部运动功能评价，阐述了其系统设计主要算法实现，验证了这些用户特征的有效性。

第七章：总结与展望。对全文进行总结，并对下一步的研究工作进行了展望。

第2章 国内外研究进展

近半个世纪以来，成功地应用于人机交互的定量化理论模型并不多见，尽管如此，它们也发挥着巨大作用，指导着设计者不断改善他们的用户界面，这足以体现基础理论模型的重要性。本文将触控交互运动模型的研究进展划分为以下几个方面进行介绍：运动时间模型，运动不确定性模型，以及基于运动模型的交互应用技术。

2.1 运动时间模型

2.1.1 Fitts' Law

Fitts' Law[9]被证明是最具鲁棒性和成功的人类运动行为模型，它对完成目标获取运动时间（movement time, MT）进行了精准的预测。在人机交互领域，Fitts' Law 的代表性描述由 MacKenzie[11]给出：

完成如图 1 所示的一个目标选取任务，其完成任务的时间 MT 可以由公式(1)给出：




图 1 Fitts' Law 目标获取任务

$$MT = a + b \log_2 \left(\frac{A}{W} + 1 \right) \quad (1)$$

其中，MT 为完成该任务的平均运动时间，A 为光标起始点到目标中心的距离，W 为目标的宽度，a 和 b 为由指点设备、操作人员和环境因素决定的经验参数。公式中的对数项被称之为难度系数（index of difficulty, ID）：

$$ID = \log_2 \left(\frac{A}{W} + 1 \right) \quad (2)$$

该系数越大，意味着完成任务的难度越高。难度系数的提出有着重要意义，它直观地提示了任务的完成难度与运动幅值 A （amplitude，即目标的距离）正相关，与目标的宽度 W 负相关。MacKenzie 指出，实际上，这种运动时间上的任务难度表现，其背后的作用机制来自于人类运动控制的速度准确性权衡原则（speed-accuracy tradeoff rule，以下简称速度准确性原则），这一原则同时也为本文的目标获取运动不确定性奠定了基础。由于 Fitts' Law 对运动时间的卓越估计，它被广泛的用于人机交互研究和设计当中，其中包括计算机输入设备评估[10][11]，新型交互界面的优化[12][13]，复杂手势识别算法的预测元素[14]和复杂交互任务的建模基础[15]。

Fitts' Law 描述的交互任务是一个简单的 1D 目标获取任务，然而，2D 或 3D 的目标获取任务在交互系统中则更为常见。出于这个目的，MacKenzie[30]对 Fitts' Law 进行了 2D 目标获取任务的拓展，如图 2 所示。他利用了一个简单但巧妙的原则解决了 2D 目标获取问题，将 2D 矩形目标中相对较小的边替换公式(1)中的 W ，因为目标获取中对于准确性的要求是由“相对较小的边”决定的，在原始的 Fitts' Law 的 1D 实验中，目标的高度被设置为足够大以至于用户不必考虑其影响，这个“相对较小的边”一直为 W ，因此 Fitts' Law 的 1D 目标获取实际上是 MacKenzie 二维目标获取的特殊情况。




图 2 MacKenzie 定义的 2D 目标获取任务

Murata[31]进一步将 Fitts' Law 拓展到 3D 空间中，如图 3 所示，他们发现除了距离和目标大小以外，目标所在的垂直平面（board）与用户视野中心构成的方向角度 θ 对获取运动时间有着显著影响，他们将这个方向角度 θ 加入到了原始的难度系数表达式中，如公式(3)所示，得到了 3D 空间中目标获取运动时间更为精准的预测。

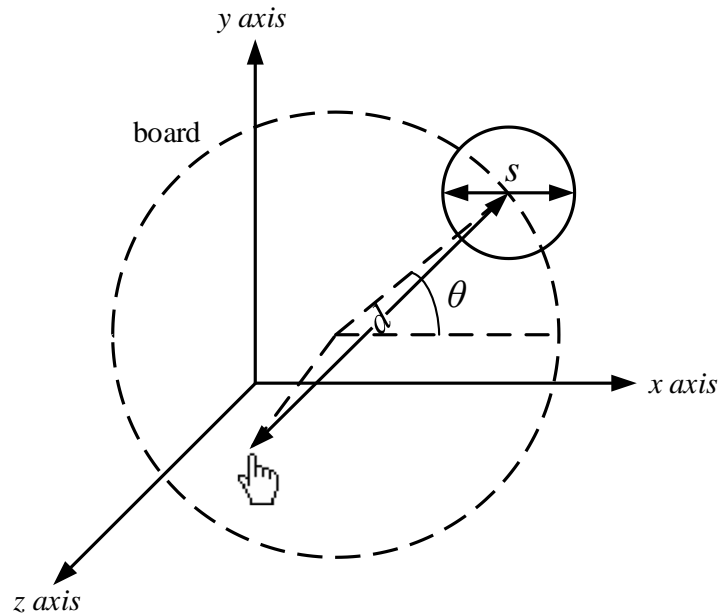


图 3 Murata 定义的 3D 目标获取任务

$$ID_3 = \log_2\left(\frac{d}{s} + 1\right) + c \sin \theta \quad (3)$$

式中， d 即为目标距离， s 为目标直径（他们中使用了一个球型目标）， c 为与任务和设备相关的常数。

随着含有动态内容的交互系统不断出现，动态目标获取变得更为常见，McGuffin 在文献[32]中探讨了 Fitts' Law 在动态扩张目标（expanding target）获取任务中的表现。他们的结果显示，这类任务的运动时间由动态目标最终的大小决定，而非初始大小。Jagacinski[28]探讨了 1D 移动目标获取运动的时间模型，他的实验结果显示获取移动目标的时间与目标移动速度高度相关，并据此构建了一个预测移动目标获取时间的模型：

$$MT = a + bA + c(V + 1)\left(\frac{1}{W} - 1\right) \quad (4)$$

式中， V 代表目标移动速度， c 为常数，其余项与公式(1)含义一致。这个模型提示移动目标获取的时间随初始距离增大而增大，随移动速度增大而增大，随目标大小的减小而增大。

2.1.2 Steering Law

Fitts' Law 描述的交互任务是目标获取任务，然而，触控交互中存在着大量的基于轨迹的交互任务（trajectory-based tasks[15]），下文简称为轨迹任务，例如在嵌套菜单列表

中移动，绘制曲线，在虚拟 3D 场景中移动，这些交互场景都无法使用这两个法则进行建模。因此，Accot 和 Zhai 在文献[15]中提出了 Steering Law，用于对轨迹任务的运动时间进行预测，他们将基于轨迹的交互任务抽象为用户控制光标移动通过一个有大小和长短约束的通道过程，如图 4 所示：




图 4 Steering Law 中一个长为 A 宽为 W 的笔直通道

光标通过该通道的运动时间可以由式子 (4) 给出：

$$MT = a + b \frac{A}{W} \quad (5)$$

其中，A 为通道的长度，W 为通道的宽度，a 和 b 为常数。




图 5 Steering Law 中一个以 C 为曲线 $W(s)$ 为宽度的弯曲通道

经过推导，Steering Law 可以拓展到任意有理通道上，如图 5 所示，在这种一般情况下，完成任务时间可以表示为无数多个微小的笔直通道的积分：

$$T = a + b \int_c \frac{ds}{W(s)} \quad (6)$$

事实上，在 Steering Law 中，轨道的长度与 Fitts' Law 的目标距离有着同样的含义，在“尽量快且准确”的要求下，从运动距离上对完成任务的速度给出了限制，而 Steering Law 中的通道宽度与 Fitts' Law 中的目标大小则是对完成任务的准确度给出了限制，二者能够成功预测这两类任务运动时间，都因其对人类运动控制中的速度准确性原则的把握。

然而，Steering Law 的后续研究发现，它仅适用于过度光滑的轨道，对于严重扭曲或

者快速变化的轨道，Steering Law 的预测性能则大大降低了。文献[33]给出了一个简单明了的例子，考虑让用户控制光标通过一个长为 A 宽为 W 的笔直的通道，和一个同样长为 A 宽为 W 但具有直角转弯的通道，在实验设备不变的情况下（常数项应保持不变），通过 Steering Law 预测将得到相同的运动时间，然而经验数据却显示，具有直角转弯的通道较笔直的通道更加费时。这是因为用户需要在通道发生改变时做出认知和运动上的调整，从认知的角度来讲，用户需要重新判定当前的速度和准确性限制，并通知控制系统以适应这种变化，从运动的角度来讲，为了不离开通道，用户必须在每一个转角处都应该首先将光标的速度降低，然后再提速，这自然需要花费更长的时间，但 Steering Law 却没有考虑这一点。

因此，许多 Steering Law 的后续研究都将主要精力放在处理通道突然发生变化的情况。例如，Robert[33]将 Steering Law 的难度系数 ID_S 与 Fitts' Law 的难度系数 ID_F 进行线性组合，得到了包含有直转角的通道任务的时间预测模型：

$$MT_C = a + bID_S + cID_F \quad (7)$$

Shota[34]讨论了通道大小发生突然变化时的时间预测模型，如图 6 所示，他们将这个轨迹任务分解为三个认知和运动阶段，第一个轨迹任务阶段，相交阶段（crossing），和第二个轨迹任务阶段，利用这三个阶段各自的难度系数的线性组合（公式(8)）对运动时间进行预测可以获得更好的效果。

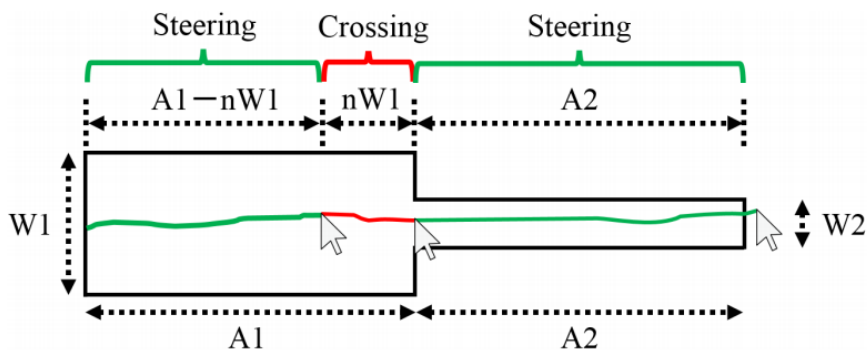


图 6 Shota 的连续线性分段路径和分段假设 [34]

$$MT = a + b\left(\frac{A_1 - nW_1}{W_1}\right) + c \log_2\left(\frac{nW_1}{W_2} + 1\right) + d\left(\frac{A_2}{W_2}\right) \quad (8)$$

Mathieu [35]则更加通用地，对 Steering Law 在复杂通道中的时间预测进行了修正，

他们将心理学研究中轨迹模型的 $2/3$ 幂率[36], 转变为轨道转弯半径的表达形式, 并引入 Steering Law 的微分表达式(6)中, 得到了可以处理复杂轨迹运动时间模型:

$$MT = a + b \int_c \frac{ds}{W(s)R(s)^{1/3}} \quad (9)$$

他们的结果显示, 这个模型在触摸屏和鼠标设备上的复杂通道任务中, 获得了 $R^2=0.87$ 和 $R^2=0.96$ 的拟合度, 相对原始 Steering Law 的 $R^2=0.64$ 和 $R^2=0.77$ 有了显著提高。

2.2 运动不确定性模型

不确定性 (uncertainty) 是指未知或者已知但不准确的事物[95]。不确定性可以是总体属性, 例如统计属性, 也可以是未知过程, 例如未被收集的信息, 但在这两种情况下, 它均为真实的。许多不确定性是可测量的, 同时也有一些是无法测量的, 例如未来事件。不确定性的价值是中性的, 不一定是负面的, 不确定性在哲学、物理学、统计学、经济学、金融学、心理学、社会学、工程学、计量学、气象学和信息科学等大量的学科领域受到关注, 且对于不同问题存在着不同定义。

虽然目标获取和轨迹任务的交互运动过程受到不确定性因素影响, Fitts' Law 和 Steering Law 的内涵也反映了这种影响因素[4], 但是它们以及基于它们拓展模型都没有直接对不确定性进行建模。随着自然人机交互的发展, 人机交互技术在更加贴近人本自然的同时, 不确定性和模糊性也在增加, 对于触控交互技术, 虽然不确定性存在于整个交互运动过程, 但目标获取的落点不确定性是被研究得最多的, 因为在大多数情况下它直接决定了交互的结果且易于利用统计方法进行描述。有效宽度就是一个利用统计属性对目标选择落点不确定性进行描述的成功案例。

2.2.1 有效宽度

有效宽度 (effective width) 最初被引入也是为了对 Fitts' Law 进行修正, 在 Fitts' Law 中, 目标距离 A 和目标大小 W , 是任务决定的先验参数, Fitts' Law 建立的交互运动时间与任务参数之间的关系, 实际上是建立在一个理想的条件下的, 即用户不多不少地完全利用了目标的精确容忍度 (precision tolerance), 也就是 W 。从统计学的角度看, 这意味着目标获取运动的落点的分布形态与目标宽度直接相关, 且几乎完全位于目标的范围之内。这种落点分布一般认为是正态的, 则我们可以用正态分布的均值 μ 和标准差 σ 来描述它。一般地, 我们认为这个落点分布的均值 μ 位于目标的中心位置, 而理想利用情况 (ideal utilization) 则可以描述为一个落点分布, 有标准差 σ 使得位于中间部分 96% 的

落点均在目标范围 W 之内, 即 $\sqrt{2\pi e}\sigma = 4.1325 \sigma = W$ 或 $\sigma = W/4.1325$ [2], 如图 7 中红色线条所示。

然而, 无论是在实验条件下还是在日常图形用户界面的使用中, 用户是无法保证总能完全利用目标宽度的。目标获取的落点分布很可能与任务目标的大小不一致, 出现欠利用 (图 7 蓝色线条) 和过利用 (图 7 黑色线条) 的情况, 这些情况可能产生于用户对目标大小的错误估计, 也可能来源于运动控制系统的噪音, 总之, 用户有可能在认知和运动层面产生了与目标大小 W 不一致的精确容忍度。一个直观的例子是, 当目标很大时, 用户一般不会完全利用目标空间, 导致落点会集中于目标中央, 而两边非常稀少, 即用户偏袒于精确度而非速度; 相反的, 当目标较小, 而选择目标时间较为紧迫时, 用户倾向于更快地做出选择而在意是否每次都选中了目标中心, 即用户偏袒于速度而非精确度。




图 7 用户对于目标大小理想利用情况、欠利用情况和过利用情况[2]

为了应对这种情况, 有效宽度很自然地被提出, 即利用实际测量中得到的落点分布标准差 σ , 按照 96% 的分布面积计算出用户实际情况下做出的准确性权衡, 即 $W_e = 4.1325\sigma$ 。然后, 再利用实际测量中得到的落点分布均值 μ , 得到有效距离 $A_e = A + \mu$ (μ 相对于目标中心), 用有效宽度和有效距离替换原始 Fitts' Law 中的目标距离和宽度, 则可以得到与真实情况更为接近的运动时间估计。

事实上, 这个对 Fitts' Law 的修正是基于信息理论隐喻的[18], MacKenzie 在文献[11]中指出 Fitts' Law 背后的信息学理论假设信号是受到白噪声影响的, 这个信号则类似于目标获取运动的距离 (因此这个距离也称为 amplitude), 而噪音则类似于落点的变异性。

随着触屏设备的广泛普及, 小型触屏设备上的目标获取吸引了研究者的注意, 与

Fitts' Law 原始的实验条件相比, 触屏设备上最突出的区别在于手指指点的不确定性, 文献[16]指出 Fitts' Law 预测的准确性在小目标获取任务上大大地降低了, 导致这个现象的主要原因就是众所周知的“胖手指 (fat finger)”问题。因此, 研究者们开始寻找修订方案, 文献[4][17]使用双高斯分布假设为小型触屏设备交互中的落点不确定性进行建模, 得到了在这类设备中的有效宽度的测量方法, 并由此推导得出了 FFitts' Law (finger Fitts' Law), 为小型触控交互中运动时间做出更为精确的预测, 对小型触控用户界面中用户的目标获取意图做出了更为精准判断。同时, 这个思想在虚拟键盘和文本输入上面得到了广泛应用[3][96], 有效的改善了键盘和文本输入的精确度。

虽然之前的研究从有效宽度出发, 对许多情况下的落点分布不确定性进行了建模, 但这些模型都是针对静态目标的, 我们没有看到针对动态目标进行的落点不确定性建模, 为了将来更好地进行运动不确定性研究和指导用户界面设计, 本文将对动态目标获取任务中的落点不确定性进行建模。

2.2.2 错误率模型

错误率是人机交互中最为重要的因素之一, 错误率模型广泛地应用于例如文本输入和计算机游戏等各种交互场景当中[37]。对于一个需要用户获取的目标, 例如虚拟键盘中的按键或者游戏中的敌人, 给出目标距离和大小和完成目标获取限定的时间, 利用错误率模型便能预测用户选中它们的概率, 这将给予设计者对重新修改和完善界面设计很大的提示和指导, 例如增大虚拟键盘按钮的尺寸或者降低游戏中敌人的移动速度。

尽管对错误率的研究在大多数人机交互工作中都有涉及, 但仅有为数不多的工作对错误率本身进行了建模。Wobbrock[37]利用 Fitts' Law 和有效宽度, 对落点分布规律进行分析, 推导出了一个 1D 目标获取的错误率模型:

$$P(E) = 1 - \operatorname{erf} \left(\frac{2.066 \frac{W}{A} \left(2^{\frac{MT_e - a}{b}} - 1 \right)}{\sqrt{2}} \right) \quad (10)$$

式中, $\operatorname{erf}(x)$ 是高斯误差函数, a 和 b 是 Fitts' Law 中的常数项, MT_e 是由有效距离和有效宽度计算出来的目标获取运动时间。他们的实验结果显示, 该模型能够很好的拟合经验数据 ($R^2=0.959$), 并从观察中得到目标大小对于错误率的影响比目标距离更为显著。

Lee[38]提出了时域目标获取 (temporal pointing) 的概念, 在时域目标获取任务中, 目标的距离是从任务开始到进入目标获取窗口的时间, 目标的大小则是能够选中目标的时间窗口长度, 如图 8 所示, 注意图中红色移动目标只是时域目标的图形化表示, 在实

际任务当中可能并不存在，例如一个“打节拍”的交互任务。




图 8 时域目标获取任务和错误率模型示意图[38]

在这项研究中，他们从时域选择落点分布出发，导出了一个时域目标获取的错误率模型：

$$E(D_t, W_t) = 1 - \frac{1}{2} \left[\operatorname{erf} \left(\frac{1 - c_\mu}{c_\sigma \sqrt{2}} \cdot \frac{W_t}{D_t} \right) + \operatorname{erf} \left(\frac{c_\mu}{c_\sigma \sqrt{2}} \cdot \frac{W_t}{D_t} \right) \right] \quad (11)$$

式中， W_t 为时域目标的大小， D_t 为时域目标的距离， c_μ 和 c_σ 为常数。这个模型显示，更小的时域目标大小和更大的时域目标距离将导致更高的错误率。这是对常理的一种定量化解释，也与本文将要进行的运动目标错误率建模的结果非常相似。

时域目标获取属于动态目标获取的一种，其基于落点分布对错误率的导出与本文将要进行的建模思路非常类似，但是，时域目标获取的错误率模型，只能应用于相对抽象的时域交互场景中，对于更为广泛和直观的空间目标获取任务，尤其是动态目标获取任务，尚没有一个量化的落点分布模型，本文将在后续的章节中，介绍这一模型的构建。

2.3 最优反馈控制模型

不论是目标获取任务还是轨迹任务，人类在进行这种交互运动的时候，总是能够很好的权衡速度和准确性的关系，这其中的奥秘在生物感知运动领域一直是一个研究热点。利用最优控制模型来解释这种多目标优化的生物机制是很有吸引力的[21]，研究者们已经将最优化模型成功地应用在这一领域，这其中主要包括开环(open-loop)和闭环(closed-loop)两类模型。

2.3.1 开环最优控制模型

在开环控制模型中，最优化的目标集中获得最合理的肌肉活动[23][22]、关节力矩[50]或者上肢姿态[24][25]，而忽略在线的感知反馈，并且经常把人类运动看作是一个预先确定的动态系统。这类模型之间的主要区别在于损失函数(cost function)的定义，并且能够准确地预测大量重复后的平均行为，例如一个平均的目标获取轨迹。但这类模型存在

两个主要的限制：首先，它们假定人类的感知运动系统仅仅对运动做了一个预先规划，而极少进行在线调整，这几乎是不可能的[51]；其次，它们无法解释每次试验之间的变异性[26]。在这种模型描述下的随机运动模式更像是在严格的实验室限制下而非现实世界中的。

2.3.2 最优反馈控制模型

在闭环控制模型中，在线的感知反馈、不确定性和延迟都被考虑到最优化的过程当中。这类模型不仅仅预测平均行为，还包括中枢神经系统对任务无关的意外变化进行的反应和调整。这种调整使我们构造的运动系统“反复地解决同一个控制问题，而非不停地重复同一个解决方案[52]”，因此，这类模型能够很好的解释运动中的不确定性、延迟、不稳定波动和环境的意外改变。越来越多的证据表明，最优反馈控制（Optimal Feedback Control, OFC）有可能使用一个统一的理论框架，同时解释大量的人类运动现象，这些现象包括运动学规律、运动协调和参数控制、神经末梢控制等，这其中也包括我们非常关注的现象[26]。

一个典型的最优反馈控制系统可以由图 9 表示：




图 9 一个典型的最优反馈控制系统

其中，相关的阐述含义如下：

reg: 决策器，最优控制的执行单元

u: 通过决策器计算出来的系统控制量

sys: 动态系统，根据一定的物理规则更新系统的状态量

w: 动态系统更新过程中，控制量中受到的噪声影响

y: 系统状态的观测量

v: 观测量受到的噪声影响

对于一个离散的最优反馈控制系统，在每一个时间点 k ，决策器无法直接得到系统

当前状态 $x(k)$ ，而只能通过 $y(k)$ 对系统状态进行估计得到估计状态 $\hat{x}(k)$ ，而 $y(k)$ 是受到噪声 $v(k)$ 影响的。决策器通过对当前系统状态的估计 $\hat{x}(k)$ 给出一个控制量 $u(k)$ ，使得在总体性能指标达到最小，而控制量 $u(k)$ 对系统状态的更新受到噪声 $w(k)$ 的影响。每一时刻的最优控制量 $u(k)$ 即为这个问题的解。

虽然我们还没看到过人机交互研究中利用最优反馈控制模型来进行运动建模，但通过细心的比较，我们还是发现最优反馈控制模型与我们想要描述的交互过程有许多相似之处，首先，在交互过程中，用户不断观察当前所处的运动状态，遵循一定的约束条件和运动规律，做出最恰当的控制决策。其次，用户对当前状态的观察是部分的，带有不确定性的，用户基于这种部分的、不确定的观察，对自身状态进行估计并做出决策。再次，用户做出一个控制决策后，这个决策并不能完全精确地执行，而是再次受到了噪声的影响。整个运动过程就是在这样的一个循环中完成，这个系统的最优解，就是用户在每一个时刻做出的控制行为，而系统的状态轨迹，就是整个交互过程的用户状态，例如手指的运动轨迹。因此，我们认为，以随机最优控制作为框架对触控交互中连续动态的交互任务进行建模将是一个很有意义的尝试。

2.4 基于运动模型的交互应用技术

与真实世界中的物理目标获取不同，计算机中虚拟的目标获取能够通过改变操作方式和用户界面显著改进[39]。根据速度准确性原则，当速度满足要求时，用户则能够拥有更多的精力关注于目标获取的准确性，同理当准确性得到保障，用户则能够尽量地提高界面操作的速度。一个成功的利用这项原则的例子是 Windows 桌面系统的 Snap 技术²，又称为分屏技术，当用户想要将两个窗口以 1/2 的比例平铺占满桌面时，用户只需要拖拽其中的一个窗口到桌面的两边即可，这一操作相比用户自己调整窗口大小要快得多，其背后的原理就是利用桌面边缘这个近似于无限大的准确容忍度，使用户只需要关注操作速度，让交互操作尽可能快的完成。

在人机交互研究中，与此类似的，基于运动模型原理设计的目标获取技术非常多，其中的一些技术，例如 Area Cursor[40]和 Bubble Cursor[39]，他们首先被用于静态目标获取场景中，之后又被证实，同样能够在移动目标选场景中发挥作用；另外的一些技术则直接面向移动目标获取场景，例如 Comet 和 Ghost[41][42]，它们能够显著改进用户操作界面的时间和准确性绩效。本文将这些技术划分为两大类：光标增强技术和目标增强

² <https://blogs.windows.com/windowsexperience/2017/02/13/windows-10-tip-stay-organized-task-view-snap/>

技术。

在光标增强技术中,根据速度准确性原则,增大光标的大小是一个直接有效的策略,如 Area Cursor[40],它能够使得目标获取的时间窗口增大[43]或者有效降低光标与目标的实际距离[44]。另一个策略是增加光标的速度,这种策略一般与用户习惯有很大关系,如果速度过快则会导致错误率的上升[28]。另外一些更聪明的技术光标技术,例如 Bubble Cursor[39]和 Implicit Fan Cursor[45],根据交互上下文动态的改变光标的大小和速度,使得交互体验较之前的这两个策略得到提升。




图 10 时域目标获取任务和错误率模型示意图

Bubble Cursor 可以看作是一个动态调整光标范围的 Area Cursor,其工作原理如图 10 所示。在 Area Cursor 中,光标的选择范围被增大到一个固定的圆形区域,使得目标获取的准确容忍度得到提升如图 10 (a) 中所示,然而,这也导致如图 10 (b) 中所示的问题,即无法区分两个排布紧密的目标的选择意图。Bubble Cursor 动态地调整选择范围的大小,如图 10 (c) 中所示,使光标每次都能捕获距离它最近的目标,并且,它还不要光标的选择范围完全包括目标,而是根据情况进行“变形(morph)”,使光标不影响周围排布密集的目标,如图 10 (d) 所示。

Bubble Cursor 背后的原理实际上非常简单,即“距离光标最近的目标为意图目标”,但这项技术却取得了巨大的成功,在各式各样的计算机辅助设计(computer-assisted design, CAD)软件中都能见到它的身影。

在目标增强技术中,根据速度准确性原则,同样可以得出增加目标大小的策略。拓展目标(expanding target)[32][47],又称鱼眼技术(fisheye)[46],基于光标的位置增加目标的大小,使用户能够更快速且准确地获取与光标接近的目标,Mac OS 的 Dock 工具栏就成功地利用这项技术加快了用户的界面操作速度的体验。动态的目标,例如最常见的移动目标的获取在许多情况下对用户而言是困难的[42],为了能够快速准确地获取移动目标,Comet[41][42]利用增大目标的方式,在此项技术中,目标被添加了一个“彗星

尾巴”，这个尾巴的大小和长度与目标移动的速度有关，使得用户能够更轻松地获取到它，如图 11 (a) 所示。Ghost[42]则利用了降低目标速度的策略，当用户按下一个激活按键后，它为移动目标创建了一个静止的替身，用户通过选择这个替身从而实现获取目标的目的，如图 11 (b) 所示。另一种技术 Hold[48]则更加直接的通过键盘操作，暂时将界面中的运动目标停止，然后让用户选择该目标，但这种方式使得界面丢失了重要的连续信息[42]。




图 11 时域目标获取任务和错误率模型示意图[42]

然而，上述这些交互技术都具有很强的任务特异性，例如 Bubble Cursor 对目标具有“粘性”，很多情况下，用户并不选中某个目标，而是希望精确的点击界面中的空白处，这项技术就容易造成困扰，这个问题在大多数的 CAD 软件中都存在。再如 Comet 为目标添加了一个尾巴，这样做在一些目标密集且相互叠加出现的界面中则失去了效果[49]，因为当目标很密集的时候，就没有空间就给这些“尾巴”了，本文最后给出的一个实际应用就是如此。而类似 Hold 和 Ghost 的技术，则需要用户进行额外的操作，增加了用户负担。总之，上述这些交互技术要么改变了原本用户界面的显示，要么需要用户进行额外的操作，在实践中，这有可能会破坏界面原本想要传递的信息或者需要额外的交互知识。

本文认为，理解触控交互运动不确定性，并对这种不确定性进行建模，可能能够得出更好的辅助目标获取解决方案，并指导未来的界面设计和人机交互研究。

2.5 本章小结

本章将触控交互运动模型的研究进展进行了回顾，通过文献调研我们发现，对于静态的触控交互运动，无论是在运动时间还是落点不确定性上，已有研究都对其进行了深入的讨论，对于动态的触控交互运动，在运动时间建模上也已经存在不少成功的先例，但我们很少看见对动态交互运动进行不确定性建模的，然而，从交互系统的发展来看，这种动态的触控交互任务正变得越来越多，对相应的交互应用技术需求也越来越迫切，因此，本文将针对动态交互运动的建模进行研究，并尝试给出能够提高用户表现的交互

应用技术。

虽然我们还没看到过人机交互研究中利用最优反馈控制模型来进行运动建模，但通过分析发现，最优反馈控制模型很适合用于对交互运动进行建模，相比 Fitts' Law 和 Steering Law 等经典的针对交互结果的建模方式，它有可能会对交互运动的过程中的不确定性、速度准确权衡、意外情况等因素做出更好的描述，因此本文同时将利用最优反馈控制模型对触控交互运动进行建模和研究，希望能够通过这项作为人机交互的理论研究工作带来更多启示。

最后，理论模型如果不能应用则失去了它应有的作用，只有对人机交互研究有所帮助或者是对界面设计有所指导的模型才有实际意义。从我们的文献调研中发现，虽然许多交互辅助技术的设计都受到了理论模型的指导，但很少是通过这些模型直接定量化得出的，这也许正好说明了现存模型无法适应实际的交互场景，很难定量的发挥作用。本文将尝试把我们的模型直接应用到实际交互场景中，用本文的模型为现实的交互应用进行用户表现预测，为交互辅助技术进行定量化参数设定，证明本文模型的泛化性和有效性。

第3章 触控交互运动的不确定性模型研究

3.1 引言

不确定性是指未知或者已知但不准确的事物，对于目标选择任务而言，不确定性可能存在于时间、轨迹等多个方面，但在人机交互研究最多的是落点的不确定性，因为目标选择落点直接决定了目标选择的交互效率和交互体验。对于精确点选设备上的目标选择任务，如鼠标或触控笔，不确定性体现得没有那么明显，然而随着小型设备和包含动态内容的用户界面的普及，目标选择的不确定性问题开始凸显出来。

近年来，例如计算机游戏、交通控制显示系统和视频监视系统等具有动态内容的交互系统越来越随处可见，虚拟现实（virtual reality, VR）和增强现实（augmented reality, AR）技术则进一步丰富了这种动态和快速变化交互场景下的内容。在这种动态交互上下文中的目标获取是普遍且具有挑战的，用户需要在不断追踪目标的同时计划按下按钮对目标进行捕获，这种看似简单的运动实际上对人类的感知控制协调系统提出了很高的要求[53]。与静态目标获取相比，动态目标获取要的时间更长且更容易出现错误。

移动目标是最为常见的一种动态目标，研究者们设计了许多新的交互技术用于辅助移动目标获取交互任务，这些技术通过增大光标的激活区域或者降低目标的移动速度，来实现目标获取的效率提升。比如 Comet 技术给移动的目标增加了一个彗星尾巴，让用户更容易点选，Hold 和 Ghost 通过暂停技术（Click-to-Pause）[48]，让用户能够选择暂时停止移动的目标或者静止的目标替身。尽管这些技术取得了很大的成功，他们的设计和参数都具有很大的任务特异性，这可能是因为他们对于该场景下用户行为的理解还不够充分。

许多工作对用户行为进行了建模，例如落点分布模型和时间模型，但它们大多是关于静止目标的，尽管这些工作给移动目标获取带来了很大启发，它们还是无法直接完全解析用户在移动目标获取中的表现。因此，我们在这里展开对于移动目标用户表现的研究，具体地说，关于移动目标落点不确定性的建模工作，我们用一个 Ternary-Gaussian 分布模型描述了移动目标获取的落点分布规律，并用实验验证了该模型的性能。

3.2 目标获取不确定性模型假设

3.2.1 问题的形式化描述

首先，我们明确地给出本研究中不确定性的定义：在目标选择任务中，一般用户反复多次获取目标的落点总体的统计性描述，即落点分布情况。

参考 Fitts' Law[9]和其它相关建模工作的方法，我们首先利用鼠标作为指点设备，研究一个 1D 目标获取任务，我们将在之后的工作中，将这个落点分布模型拓展到 2D 空间和其它触控设备中。

在这个 1D 场景中，用户控制鼠标点击一个宽度为 W 且和屏幕同高的竖长目标，如图 12 所示，在用户开始获取目标前，光标被固定在屏幕左侧的启示位置，目标以一定的速度 V ，远离或者朝向光标初始位置移动，用户控制鼠标点击竖长目标以完成一次目标获取任务。通过反复的进行该实验，我们便能得到一系列的目标获取落点。

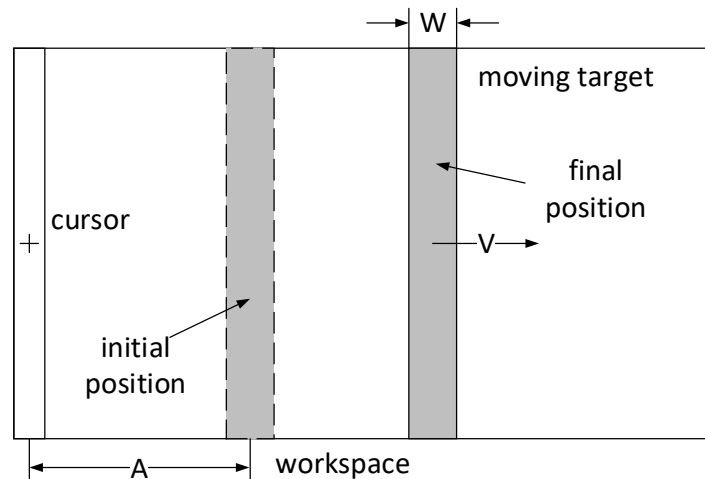


图 12 1D 移动目标获取任务设置

1D 移动目标获取任务中相关的因素如下：

初始距离 A ：目标初始位置到光标起始点的距离

目标大小 W ：目标的横向宽度

目标速度 V ：目标的移动速度

3.2.2 落点分布模型假设

为了对落点分布进行建模，受到已有研究和的启发和一个尝试实验³的观察，我们对

³ 与本章实验 1 的设置一致，被试来自于论文作者本人和研究小组成员。

移动目标获取做出以下假设：

假设 1： 移动目标获取的落点分布是高斯的。

这个假设是基于已有研究[2][4][17]结果，这些研究的结果显示，在静止目标获取任务中，目标获取的落点分布是高斯的。通过尝试实验的观察，这在移动目标获取任务中可能同样适用。

假设 2： 初始距离 A 不影响落点分布。

已有研究[2][4][17]结果表明，目标与指点设备的初始距离不影响落点分布，相反地，用户表现主要受到动态目标最终状态的影响，关于拓展目标的研究结果[32][47]间接地说明了这一点，他们的结果显示，尽管目标变大是在光标足够接近以后才开始，用户仍能够调整自己的行为使其能够利用目标最终的大小来进行选择。

假设 3： 目标大小 W 和目标速度 V 对落点分布产生影响。

目标大小 W ： 已有研究[2][4][17]结果证明，在静态目标获取任务中，落点分布是正态的，并且其标准差 σ 与目标大小正相关。他们将这种现象解释为，用户倾向于最大程度地利用目标的宽度（准确容忍度），从而尽快地完成目标获取。我们认为，这同样适用于移动目标获取当中。

目标速度 V ： 生物运动控制研究[20][21][26]表明，感知运动系统存在延迟，这可能会导致落点出现在相对目标靠后的倾向，当目标移动得更快时，这种倾向则更明显。实际上，这个原理已经被成功地应用于 Comet[41][42]技术里，在目标的后面增加的彗星尾巴，正好弥补了落点滞后这一倾向。因此，我们假设目标速度对落点分布有影响。

3.2.3 Ternary-Gaussian 模型

基于前面的三个基本假设，我们给出移动目标落点分布的 Ternary-Gaussian 模型：

落点分布是一个遵循高斯分布的随机变量 X ：

$$X \sim N(\mu, \sigma^2) \quad (12)$$

这里，我们将目标的中心位置作为原点，以目标速度方向作为正方向，这样，如果落点真如期望的有所滞后，则其落点坐标是负值。

进一步地，这个随机变量 X 是三个正态随机变量的合：

$$X = X_a + X_m + X_s \sim N(\mu, \sigma^2) \quad (13)$$

其中, $X_a \sim N(\mu_a, \sigma_a^2)$, $X_m \sim N(\mu_m, \sigma_m^2)$ 且 $X_s \sim N(\mu_s, \sigma_s^2)$, 它们分别于指点设备绝对精确度、目标速度和目标大小相关。我们对这三个随机变量进行如下解释:

第一个随机变量 X_a , 又称为绝对成分 (absolute component) 反映了指点设备的绝对不确定性, 它同样被包含到了 FFitts Law 的双高斯分布假设 (dual-distribution hypothesis) 中[17]。这个成分与用户的获取目标的愿望无关, 不服从速度准确性原则, 同时它也与目标大小和速度无关, 因此这个随机变量的两个参数 μ_a 和 σ_a 是两个常数。

第二个随机变量 X_m , 又称为移动成分 (moving component) 反映了因为目标移动导致的不确定性, 我们假设它的两个参数 μ_m 和 σ_m 都与速度 V 成比例关系。

第三个随机变量 X_s , 又称行动速度成分 (action speed component) 反映了因为用户获取目标行动快慢而产生的不确定性。这种不确定性被认为与速度准确性原则相关, 并且与目标大小成比例关系[20][21][26]。

除此之外, 我们还从尝试实验中观察到落点分布可能受到 W 和 V 的相互作用的影响。更具体地, 总体落点分布的标准差 σ 与 V 的正比关系, 随着 W 的增大而受到了抑制。这可能意味着, X_m 和 X_s 之间是不独立的。我们将这种关系用一个 V/W 正态分布相关系数来描述。

然后, 我们通过求三个高斯随机变量的合即可得到总的分布参数表达式, 其中 μ 为:

$$\begin{aligned}\mu &= \mu_a + \mu_m + \mu_s \\ &= a + bV + cW\end{aligned}\quad (14)$$

σ 为:

$$\begin{aligned}\sigma &= \sqrt{\sigma_a^2 + \sigma_m^2 + \sigma_s^2 + \text{cov}(X_m, X_s)} \\ &= \sqrt{d + eV^2 + fW^2 + g \frac{V}{W}}\end{aligned}\quad (15)$$

其中, a, b, c, d, e, f 和 g 为常数, 他们可以通过经验数据进行估计。

3.3 任务参数对不确定性的影响

为了验证我们的假设和模型, 我们设计了两个实验, 第一个实验用于验证初始距离 A 对落点分布的影响, 第二个实验用于验证目标大小 W 和目标速度 V 对落点分布的影响。

3.3.1 实验1：初始距离A的影响

在这个实验中，我们将目标大小 W 和目标速度 V 进行控制，研究初始距离 A 对落点分布的影响。

被试和实验设置：

我们招募了 12 名被试，6 男 6 女，平均年龄 27 岁，所有被试都是右手惯用手并且有两年以上使用计算机鼠标的经验。

实验在一台 Dell OptiPlex 9020 桌面计算机上进行，计算机处理器为 Intel Core i7 4 Quad core，主频 3.6 GHz，具有一个 23 寸（533.2mm * 312mm）LED 显示器，分辨率为 1920 * 1080，使用的指点设备为 Dell MS111，分辨率为 1000dpi，如图 13 所示。

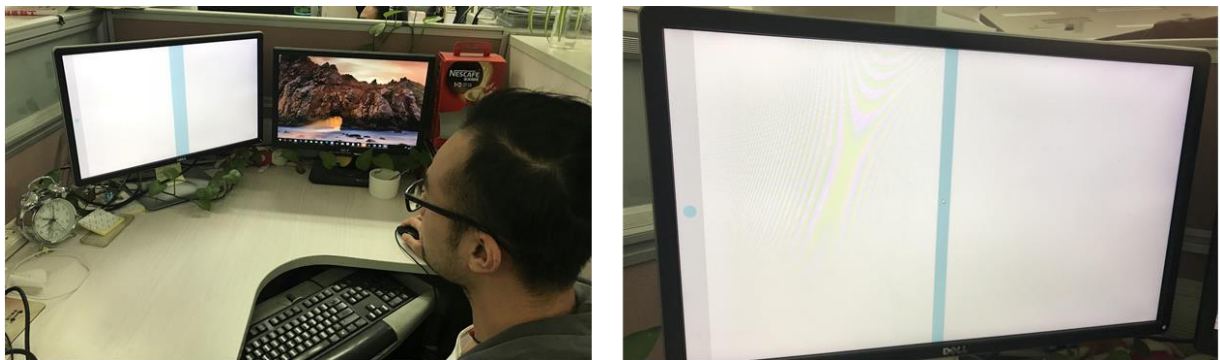


图 13 实验设置和被试参与实验的情况

实验设计和流程：

我们使用一个被试内设计（within-subjects design），与 4 个初始距离 A （192 px, 384 px, 768 px, 1152px）相对应地，实验总共包括 4 个情况。被试在每个情况下需要完成 30 次点击试验，这 30 次试验的顺序是随机排序的。整个实验大概需要 10 分钟完成，在每次试验中间被试可以停下来休息。

每次试验，被试首先点击一个“开始按钮”，在一个短暂的时间间隔后（700ms – 2000ms 的随机数值），实验系统播放一个“beep”的声音，同时显示器在上述 4 个不同初始位置显示一个移动目标，这个目标宽为 96px，移动速度为 192px/sec。被试被要求“尽可能快且准确地”点选这个移动目标。每次试验被试只有一次机会点选目标，不管目标是否被成功选中，我们都记录这次试验的落点位置。

实验结果：

我们总共获得了 48 组落点（4 个情况 * 12 个被试），所有的落点分布都通过了 Kolmogorov-Smirnov 的正态测试（ $\alpha=0.05$ ），在当前实验条件下，假设 1 得到验证。

对于所有的 48 组落点，我们利用三标准差原则剔除异常点，并使用极大似然估计（maximum likelihood estimate, MLE）估计真实情况下的高斯参数 μ 和 σ 。




图 14 实验 1 中 4 种情况下实际的落点情况，灰色区域代表目标

重复测量方差分析（repeated-measure ANOVA）显示，初始距离 A 对落点分布的 μ ($F_{3,9}=0.945, p=.911$)和 σ ($F_{3,9}=0.639, p=.237$)都没有显著性影响。图 14 显示了 $A=192\text{px}$, 384px , 768px 和 1152px , 4 种情况下实际的落点分布情况，其中 4 种情况下 μ 的值分别为 -11.03px , -11.82px , -11.08px 和 -12.66px , σ 的值分别为 19.28px , 21.25px , 23.99px 和 21.94px 。从图中可以看到，这 4 个情况下的落点分布高度重叠在一起。注意到 μ 是负值，这说明落点倾向于落在目标的后面，这与我们的假设相符。

综上所述，通过这个实验，我们给出了初始距离 A 对落点分布没有显著性影响的根据，**假设 2** 得到验证。

3.3.2 实验 2：目标大小 W 和目标速度 V 的影响

在这个实验中，我们研究目标大小 W 和速度 V 对落点分布的影响，实验被试和设置、实验任务均与**实验 1**保持一致。

我们使用一个被试内设计，对应于 4 个目标大小 W (24px , 48px , 96px , 144px)与 4 个目标速度 (96px/sec , 192px/sec , 288px/sec , 384px/sec)，本实验总共包括 16 个情况。被试在每个情况下需要完成 30 次点击试验，这 30 次试验的顺序是随机排序的。整个实验大概需要 40 分钟完成，在每次试验中间被试可以停下来休息。

因为我们在**实验 1**中已经验证了初始距离 A 对落点分布不产生影响，在**实验 2**中的每次试验中，目标的初始距离被随机地设置于 384px 至 864px 的范围内。

实验结果：

所有 192 组落点（16 个情况 * 12 个被试），都通过了 Kolmogorov-Smirnov 的正态测试 ($\alpha=0.05$)，在这个实验条件下，**假设 1** 也得到验证。与**实验 1**一样，对于所有的 192 组落点，我们利用三标准差原则剔除异常点，并使用极大似然估计估计真实情况下的高斯参数 μ 和 σ 。图 15 显示了这 16 种情况下实际的落点分布情况。




图 15 实验 2 中 16 种情况下实际的落点情况，灰色区域代表目标

多因素重复测量方差分析显示，目标速度 V ($F_{3,9}=30.538, p<.0001$) 和目标大小 W ($F_{3,9}=6.502, p=.012$) 都对落点分布的均值 μ 产生显著影响。 μ 在 4 种 V 情况下的均值分别为 0.16px, -6.49px, -13.10px 和 -17.96px, 如图 16 (a) 所示。两两比较 (pair-wise comparisons) 的结果显示所有速度 V 级别之间都存在显著性差异 ($p<.05$)。 μ 在 4 种 W 情况下的均值分别为 12.63px, -11.83px, -6.16px 和 -6.76px, 如图 16 (b) 所示。两两比较的结果显示除了 2 个级别 (-12.63 vs. -11.83, $p=0.494$; -6.16 vs. -6.76, $p=.652$) 之外, 所有大小 W 级别之间都存在显著性差异 ($p<.05$)。




图 16 μ 在 4 种 V 情况 (a) 和 4 种 W 情况 (b) 下的均值

目标速度 V ($F_{3,9}=9.730, p=.003$) 和目标大小 W ($F_{3,9}=30.214, p<.0001$) 都对落点分布的标准差 σ 产生显著影响。 σ 在 4 种 V 情况下的均值分别为 17.32px, 19.41px, 21.60px 和 24.88px, 如图 17 (a) 所示。两两比较的结果显示所有速度 V 级别之间都存在显著性差异 ($p<.05$)。 σ 在 4 种 W 情况下的均值分别为 15.64px, 16.84px, 21.59px 和 29.15px,

如图 17 (b) 所示。两两比较的结果显示除了 1 个级别 (15.64 vs. 16.84, $p=.209$) 之外, 所有大小 W 级别之间都存在显著性差异 ($p<.05$)。




图 17 σ 在 4 种 V 情况 (a) 和 4 种 W 情况 (b) 下的均值

统计结果显示 V 和 W 的组合在 μ ($F_{9,3}=34.512, p=.007$) 和 σ ($F_{9,3}=4.806, p<.0001$) 上均显示显著的交互作用, 这个结果提示后两个随机变量是不独立的。图 18 显示了这种相互作用。




图 18 W 和 V 之间在 μ 和 σ 上的交互作用

总之, 这个实验给出了以下三个结论: 1) 落点分布是高斯的, **假设 1** 得到验证; 2) 目标大小 W 和目标速度 V 都对落点分布有显著影响, **假设 3** 得到验证; 3) V 和 W 之间对落点分布有显著的交互作用。

3.4 模型参数估计与实验验证

在上一节中, 我们验证了 Ternary-Gaussian 模型的基本假设, 该模型得以确立。在本节中, 我们将对 Ternary-Gaussian 模型, 进行参数估计, 并检验它与经验数据的拟合效果。

已有研究显示, 目标移动方向会导致不同的目标获取策略和运动控制行为[41][43], 因此, 我们将 Ternary-Gaussian 在不同的目标移动方向上进行拟合, 其中包括远离和靠近两个移动方向:

远离 (away): 目标将朝着光标启示位置远离的方向移动, 用户需要追逐这个目标。

靠近 (towards): 目标将朝着光标启示位置接近的方向移动, 用户需要拦截这个目标。

基于这个定义，之前的两个实验都属于远离方向。我们将用**实验 2** 中的数据估计远离方向下的参数。我们让同样的被试，在同样的情况下进行了移动方向靠近的数据采集，并将这个数据集用于估计靠近方向下的参数。

注意到一个高斯分布由两个参数唯一确定 (μ 和 σ)，因此 Ternary-Gaussian 模型的拟合包括 μ 函数 (公式(14)) 的拟合与 σ 函数 (公式(15)) 的拟合，同时我们需要拟合两个方向上的数据，因此我们总共产生 4 组模型参数，即 μ -away, σ -away, μ -towards 和 σ -towards。

我们利用最小二乘回归方法对这些参数进行估计，结果显示，我们的模型在两个方向上都与经验数据拟合得很好，在远离方向上， μ -away 获得了 $R^2=0.926$ 的拟合度， σ -away 为 $R^2=0.97$ ，在靠近方向上， μ -towards 为 $R^2=0.978$ ， σ -towards 为 $R^2=0.923$ ，如表 1 所示。

表 1 估计的模型参数和回归系数 R^2

模型参数	常数	R^2	平均 R^2
μ -away	$a1 = 1.3921$ $b1 = -0.064$ $c1 = 0.0579$	0.926	0.952
μ -towards	$a2 = -6.0301$ $b2 = -0.0505$ $c2 = 0.1785$	0.978	
σ -away	$d1 = 1.4597$ $e1 = 0.0015$ $f1 = 0.0386$ $g1 = 19.6039$	0.97	0.946
σ -towards	$d2 = 47.3084$ $e2 = 0.0022$ $f2 = 0.0295$ $g2 = 10.908$	0.923	

图 19 显示了模型的 $\mu=f(V,W)$ 函数在远离和靠近两个方向上的 3D 图形和经验数据对比。实心点是真实采样的数据，红色意味着模型在这个位置上的值低估了，蓝色意味着模型高估了它的值。图 20 显示了模型的 $\sigma=g(V,W)$ 函数在远离和靠近两个方向上的 3D 图形和经验数据对比。

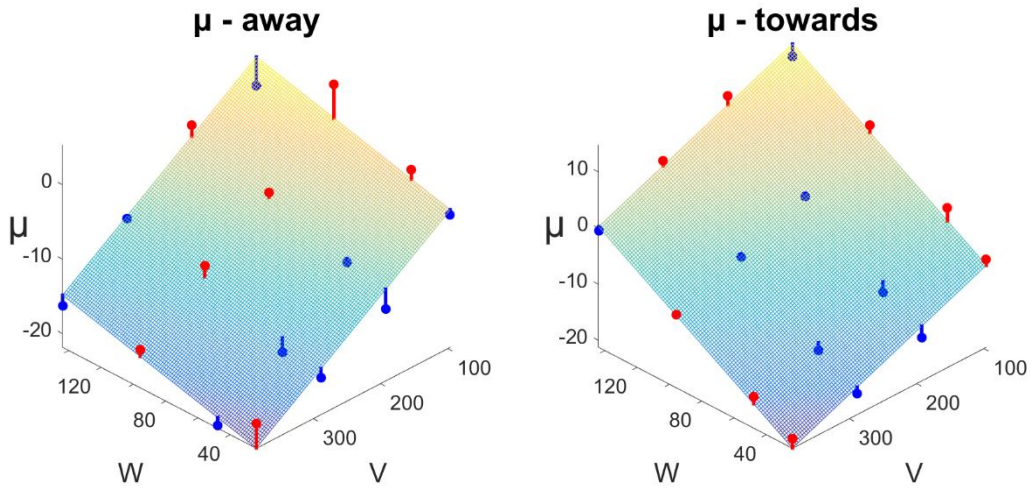


图 19 模型的 $\mu=f(V, W)$ 函数的 3D 图形和经验数据对比

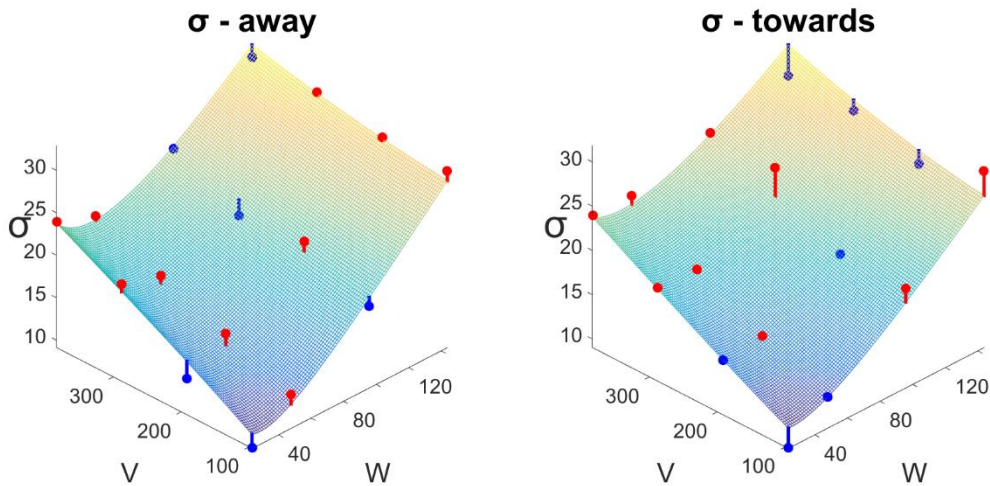


图 20 模型的 $\sigma=g(V, W)$ 函数的 3D 图形和经验数据对比

总之，我们构造了一个 Ternary-Gaussian 模型用于预测 1D 移动目标获取的终点分布，在远离和靠近两个方向上，我们的模型都与经验数据拟合得很好， μ 和 σ 分别达到了 $R^2=0.95$ 和 $R^2=0.94$ 的平均模型拟合度。

从 Ternary-Gaussian 模型的表达式中，我们可以得到以下几个移动目标获取的结论：

1. 目标和光标的初始距离对目标获取的落点分布几乎不产生影响。
2. 目标移动的速度越大落点分布的范围则越大。
3. 目标的大小越大落点分布的范围也越大。
4. 目标移动的速度越大则落点分布倾向于向目标后方偏移。
5. 增大目标的大小，会降低目标速度对落点分布产生的影响，这使得落点更倾向于分布在目标中央。

我们认为，这些结论将对触控用户界面移动目标获取的研究和设计具有重要指导意义。

3.5 不确定性模型的在笔和触屏设备上的适用性

为了使我们的模型能够适用于使用其它指点设备的用户界面，我们设计实验，对该模型在笔和触屏设备上的适用性进行验证，并对模型的参数进行拟合，如图 21 所示。




图 21 笔 (a) 和触屏 (b) 设备上的实验适用性实验

3.5.1 实验 3：不确定性模型在笔设备上的适用性

在这个实验中，我们利用一支触控笔作为指点设备，利用一个可显示绘图板作为视觉反馈，实验使用的用户界面和基本规则与**实验 1**和**实验 2**保持一致。

被试和实验设置：

我们招募了 12 名被试，7 男 5 女，平均年龄 26.4 岁，所有被试都是右手惯用手并且有两年以上使用计算机鼠标的经验。

实验使用的触控笔为一支长 14.4cm，直径 1cm，重 19g，采样率为 100Hz 的 Wacom 绘图笔；可显示绘图板型号为 Wacom Cintiq DTK-1300，屏幕大小为 13.3 英寸，分辨率为 1280×800 像素，绘图板与在一台 Dell OptiPlex 9020 桌面计算机连接，计算机处理器为 Intel Core i7 4 Quad core，计算机上安装有我们的实验程序，如图 21 (a) 所示。

实验设计：

我们使用一个被试内设计，对应于 4 个目标大小 W (24 px, 48 px, 96 px, 144px) 与 4 个目标速度 (96px/sec, 192 px/sec, 288 px/sec, 384 px/sec)，总共 16 种情况。被试在每个情况下需要完成 4 次点击试验，这 4 次试验的顺序是随机排序的。本实验还包括靠近和远离 2 个目标移动方向，两个移动方向的顺序由被试间进行抵消平衡。整个实验大概需要 10 分钟完成，在每次试验中间被试可以停下来休息。

在这个实验中，我们的目的是验证一般用户的落点分布是否能够被我们的模型很好地描述，而非研究各参数与落点分布的关系，因此我们的数据量只需要满足每种情况下的分布估计要求即可，所以，我们要求每个被试在每种情况下完成 4 次点击任务，这样 12 个被试共产生的 48 个落点就足以满足要求。

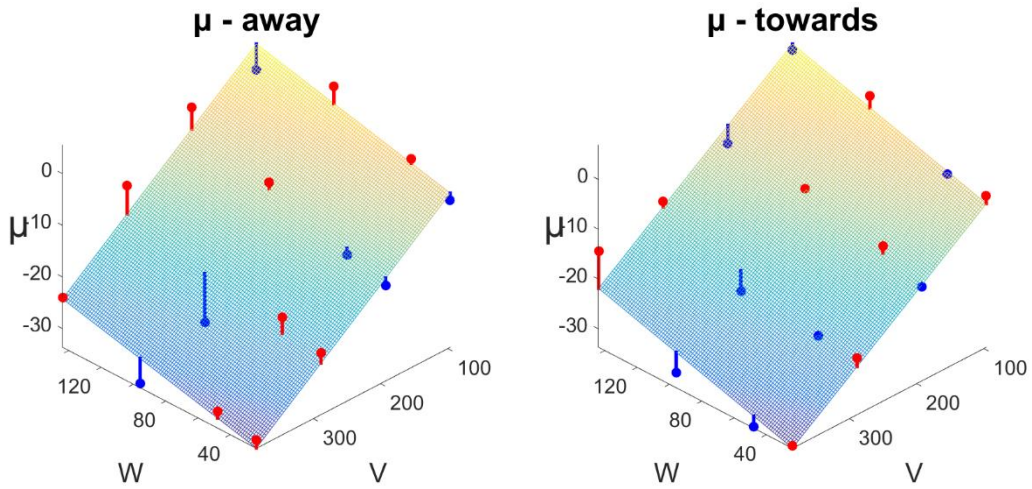
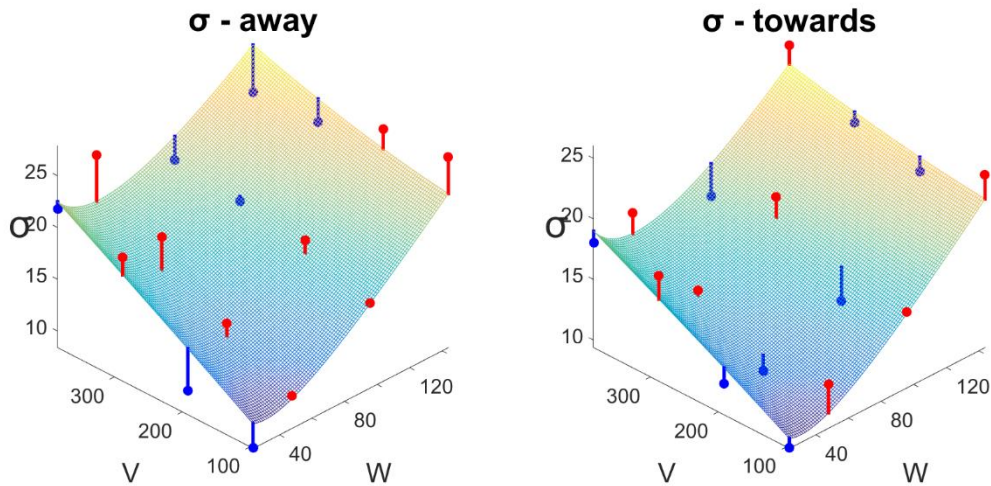
实验结果：

在本实验中，我们直接对两个移动方向的数据都进行模型拟合。结果显示，我们的模型在两个方向上都与经验数据拟合得较好，在远离方向上， μ -away 获得了 $R^2=0.946$ 的拟合度， σ -away 为 $R^2=0.77$ ，在靠近方向上， μ -towards 为 $R^2=0.946$ ， σ -towards 为 $R^2=0.868$ ，如表 2 所示。

表 2 笔设备上估计的模型参数和回归系数 R^2

模型参数	常数	R^2	平均 R^2
μ -away	$a1 = 4.3125$ $b1 = -0.1034$ $c1 = 0.0776$	0.907	0.926
μ -towards	$a2 = 2.4311$ $b2 = -0.1$ $c2 = 0.0981$	0.946	
σ -away	$d1 = 28.2006$ $e1 = -0.0015$ $f1 = -0.0236$ $g1 = -15.228$	0.77	0.819
σ -towards	$d2 = -34.6859$ $e2 = 0.0007$ $f2 = 0.0202$ $g2 = 12.6826$	0.868	

图 22 显示了模型的 $\mu=f(V,W)$ 函数在远离和靠近两个方向上的 3D 图形和经验数据对比。图 20 显示了模型的 $\sigma=g(V,W)$ 函数在远离和靠近两个方向上的 3D 图形和经验数据对比。

图 22 笔设备上模型的 $\mu=f(V, W)$ 函数的 3D 图形和经验数据对比图 23 笔设备上模型的 $\sigma=g(V, W)$ 函数的 3D 图形和经验数据对比

3.5.2 实验 4：不确定性模型在触屏上的适用性

在这个实验中，我们利用触屏作为指点设备和视觉反馈，实验中的被试与**实验 3**保持一致。

实验设置：

实验在一台 Windows Surface Pro 5 平板电脑上进行，计算机处理器为 Intel Core i7，具有一个 12.3 寸（292mm * 201mm）LED 显示器，分辨率为 1920 * 1080，使用的指点设备为触摸屏，分辨率为 267ppi，如图 21（b）所示。

实验设计：

我们使用一个被试内设计，对应于 4 个目标大小 W（30 px，60 px，120px，180px）

与 4 个目标速度 (120px/sec, 240 px/sec, 360 px/sec, 480 px/sec), 总共 16 种情况。被试在每个情况下需要完成 4 次点击试验, 这 4 次试验的顺序是随机排序的。本实验还包括靠近和远离 2 个目标移动方向, 两个移动方向的顺序由被试间进行抵消平衡。整个实验大概需要 10 分钟完成, 在每次试验中间被试可以停下来休息。

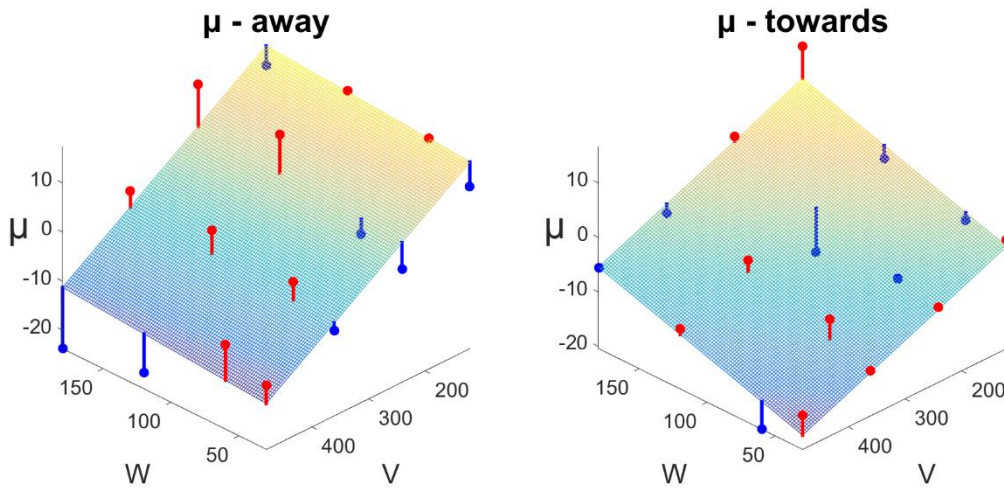
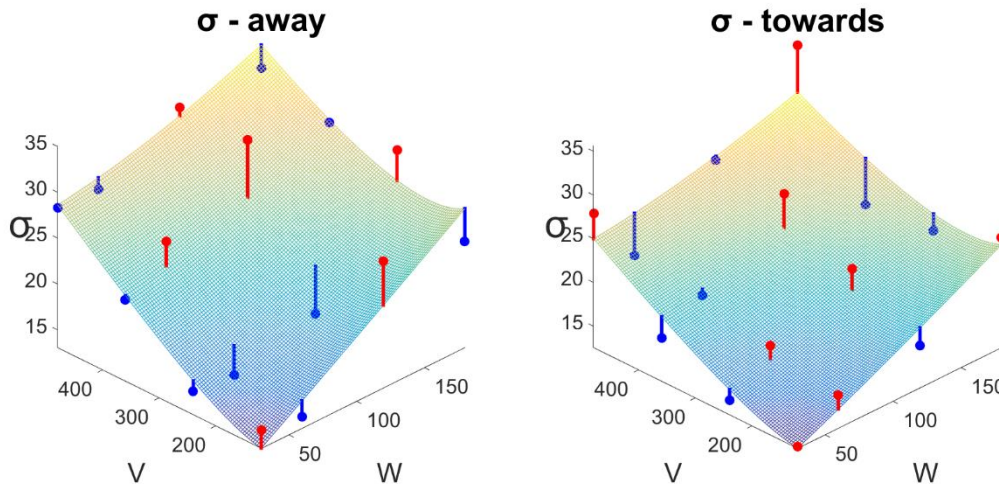
实验结果:

结果显示, 我们的模型在触屏设备上与经验数据拟合效果不如鼠标和笔设备好, 在远离方向上, μ -away 获得了 $R^2=0.772$ 的拟合度, σ -away 为 $R^2=0.796$, 在靠近方向上, μ -towards 为 $R^2=0.847$, σ -towards 为 $R^2=0.748$, 如表 3 所示。

表 3 触屏设备上估计的模型参数和回归系数 R^2

模型参数	常数	R^2	平均 R^2
μ -away	$a1 = 23.2358$ $b1 = -0.0797$ $c1 = 0.0207$	0.772	0.809
μ -towards	$a2 = 1.3275$ $b2 = -0.0449$ $c2 = 0.0822$	0.847	
σ -away	$d1 = -58.6834$ $e1 = -0.0032$ $f1 = 0.0108$ $g1 = 228.0955$	0.796	0.772
σ -towards	$d2 = 80.0628$ $e2 = -0.0023$ $f2 = -0.0077$ $g2 = 154.4136$	0.748	

图 22 显示了模型的 $\mu=f(V,W)$ 函数在远离和靠近两个方向上的 3D 图形和经验数据对比。图 20 显示了模型的 $\sigma=g(V,W)$ 函数在远离和靠近两个方向上的 3D 图形和经验数据对比。

图 24 触屏设备上模型的 $\mu=f(V, W)$ 函数的 3D 图形和经验数据对比图 25 触屏设备上模型的 $\sigma=g(V, W)$ 函数的 3D 图形和经验数据对比

总之，我们对 Ternary-Gaussian 模型在笔和触屏设备上的适用性进行了验证，实验表明，模型在使用触控笔作为指点设备时，仍能够对移动目标获取的落点分布进行准确地预测，其中对参数 μ 达到了 $R^2=0.92$ 的平均拟合度，对参数 σ 达到了 $R^2=0.81$ 的平均拟合度，模型在笔设备上表现出很强的适用性。模型在使用触屏作为指点设备时，对移动目标获取的落点分布的预测表现不如鼠标和触控笔，但已经反映出了落点分布于 W 和 V 两个参数间的主要关系，仍处于可以接受的范围，其中对参数 μ 达到了 $R^2=0.80$ 的平均拟合度，对参数 σ 达到了 $R^2=0.77$ 的平均拟合度，模型在触屏设备上表现出较强的适用性，能够满足实际应用的需求。

3.6 本章小结

本文展开了触控交互运动的不确定性模型的研究，为了定量的解释移动目标获取的落点分布规律，我们通过对已有目标获取模型的研究和预实验的观察，提出了一个 Ternary-Gaussian 分布假设，并在该假设的基础上推导出了移动目标获取落点分布模型的表达式。

为了验证我们提出的 Ternary-Gaussian 分布假设，我们设计了两个实验，分别探究移动目标获取落点分布受到目标初始位置的影响，以及落点分布受到移动速度、目标大小的影响及相互作用，实验的结果验证了我们假设的正确性。然后，利用实验中得到的数据，对模型中的参数进行估计，在远离和靠近两个方向上，我们的模型都与经验数据拟合得很好， μ 和 σ 分别达到了 $R^2=0.95$ 和 $R^2=0.94$ 的平均模型拟合度。

从 Ternary-Gaussian 模型的表达式中，我们可以得到以下几个移动目标获取的结论：

1. 目标和光标的初始距离对目标获取的落点分布几乎不产生影响。
2. 目标移动的速度越大落点分布的范围则越大。
3. 目标的大小越大落点分布的范围也越大。
4. 目标移动的速度越大则落点分布倾向于向目标后方偏移。
5. 增大目标的大小，会降低目标速度对落点分布产生的影响，这使得落点更倾向于分布在目标中央。

本章还对 Ternary-Gaussian 模型在笔和触屏设备上的适用性进行了验证，实验表明，模型在使用触控笔作为指点设备时，仍能够对移动目标获取的落点分布进行准确地预测，其中对参数 μ 达到了 $R^2=0.92$ 的平均拟合度，对参数 σ 达到了 $R^2=0.81$ 的平均拟合度，模型在笔设备上表现出很强的适用性。模型在使用触屏作为指点设备时，对移动目标获取的落点分布的预测表现不如鼠标和触控笔，其中对参数 μ 达到了 $R^2=0.80$ 的平均拟合度，对参数 σ 达到了 $R^2=0.77$ 的平均拟合度，虽然模型在触屏设备上的适用性不如鼠标和笔设备，但其落点分布规律仍与模型描述基本相符，如目标移动的速度越大、目标的大小越大则落点分布的范围越大等，能够达到支撑触屏设备上辅助交互技术设计的需求。

第4章 触控交互运动的反馈控制模型研究

4.1 引言

正如前面所看到的那样，目标获取任务是最为基础的人机交互任务之一，随着连续交互空间的交互系统，例如视频游戏、VR 和 AR 等应用系统的不断普及，理解用户选择目标时的过程特性，例如轨迹和速度，对用户表现、合理决策以及界面的布局设计等方面具有重要意义[64]。目前人机交互领域已经存在大量工作研究目标获取中的用户表现，但是其中大部分工作集中在测量用户交互结果，如运动时间和落点分布，极少有针对目标获取运动的过程特性的相关研究。可以看到，本文第3章的不确定模型，也是针对交互结果的，它描述了一个目标获取运动最终结果上的不确定性，在本章中，我们将从控制领域引入一个最优反馈控制模型，利用它对目标获取的运动过程进行建模，研究交互运动的过程特性。

相对于传统用户表现模型，基于最优反馈控制建立的交互模型，其输出是某个交互动作的重复模拟，这些重复与开环系统的平均轨迹不一样，它们之间具有相似的行为和控制特性，但却受到过程中的不确定性和突发事件影响，是一种“相似但不同”的重复[26]，因此，该系统的调整 and 评价依赖于仿真集与经验数据集之间的相似度。然而，现有的人机交互研究中，并不能给出一个这种重复事件间相似性的定义，因此，制定一个确切的量化的相似性定义是有意义的。

本文基于最优反馈控制模型，拟合经验数据的轨迹和运动不确定性来对目标获取运动进行仿真。提出了一个触控交互运动的反馈控制模型，并利用它对目标获取运动的过程特性进行建模。我们对两种典型的交互任务，包括静态目标和移动目标获取任务分别进行了研究。首先给出这两种任务的反馈控制形式化表达，其次给出了一个相似性度量方法以使用经验数据来估计模型关键参数，随后使用该模型来模拟目标获取运动并评价模拟的效果。结果表明，利用本文提出的模型，运动轨迹和运动过程的变异性得到了很好的模拟，在用户做目标获取任务时，许多重要的特征，如速度准确性原则[2]和反馈控制的不确定性[65]，都得到了很好的再现。

4.2 最优反馈控制机理

将最优控制理论用于建模目标获取运动在概念上颇具吸引力。因为最优控制理论尝

试同时考虑完成任务时花费的精力、时间和准确度，这和人们对交互行为的普遍理解高度吻合。最优反馈控制系统是一种闭环最优控制系统，它在线地利用反馈信息重新做出决策，实现对系统的最优化控制。相比开环控制系统，闭环系统采用了更加类人的处理模式，这种模式不再依赖于提前预知的“期望轨迹（desired trajectory）”，而是能够在不可预测的波动下反复再现的[26]。

两种最优化过程都首先根据任务目标制定一个损失函数，并给出一个系统的初始状态，如图 26 所示。接下来，开环最优控制得到一个期望轨迹，因为开环控制无法感知可能存在的意外噪音，它的运动计划通常在一个反馈控制器中执行，这个反馈控制器利用一些控制机制，抵消实际运行轨迹与期望轨迹之间的偏差。然而，这些控制机制是预先制定的，它们没有被系统在运行的每一步中在线地考虑。与此相对应地，闭环反馈控制中，这种控制机制是可以进行在线编辑和设计的。因此，闭环反馈控制器的设计，不在依赖于预先定义运行环境和控制方案，而是让任务和运动系统本身找到一种最适合运行环境的控制方案[21]。

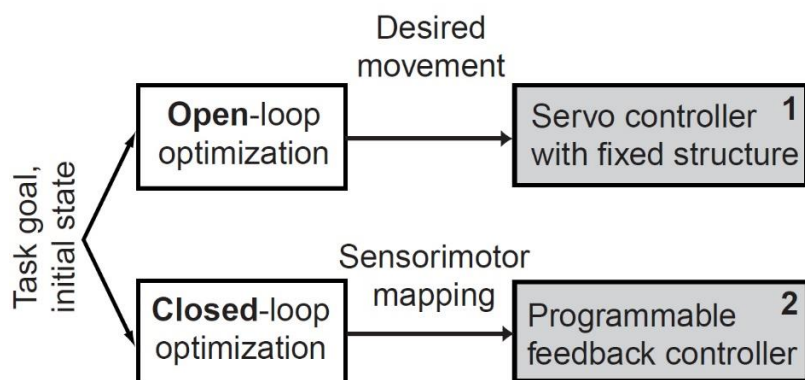


图 26 开环最优控制和闭环最优控制的任务计划阶段[21]

最优反馈控制能够很好的对人类感知运动系统进行建模，它最终要的特征是找到一个最佳的控制策略，在人类在舒适条件下获得最佳的任务表现。正如前面说到，最优反馈控制是让任务和运动系统本身找到一种最适合运行环境的控制方案，因此，最优反馈控制模型设计时，需要对于不同任务、不同运动系统和不同目标权衡机制的条件进行定义。例如，对于一个手部移动到空间一点的任务，任务目标则是最小化手与那个空间位置的距离，运动系统则包括中枢神经的控制信号发起和传递，控制力驱使手部运动的物理定律，以及感知当前手部状态和空间点位置的反馈信号等，此外，人类完成这样一个任务不会和机器一样，只考虑任务目标，而是同时考虑自身消耗，这就需要通过权衡机制解决其中的协调问题。

最优反馈控制系统的运行过程如图 27 所示，控制器根据任务目标发出一个控制指

令驱动运动系统以实现任务目标, 这个过程中控制信号可能受到外部环境意外噪声干扰, 因此, 当运动按照这个指令运行了一小段时间后, 会将当前运动系统的状态进行反馈, 控制器会根据最新反馈的情况再次做出控制。这个状态反馈有可能是部分可观测的, 并且同样是受到外部环境意外噪声干扰的, 因此控制器需要对这个观测结果进行最优化估计, 以减少外部干扰的影响。

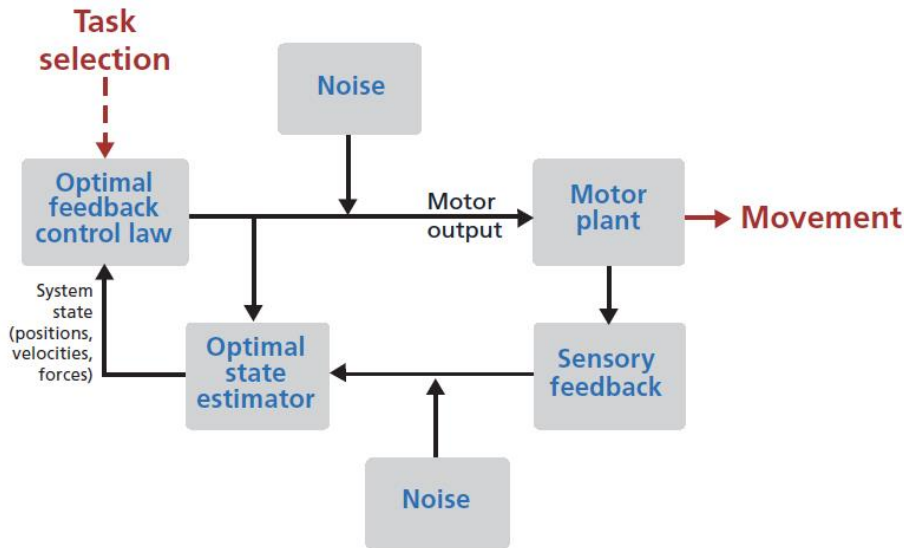


图 27 最优反馈控制系统的运行过程[66]

我们认为, 上述的最优反馈控制机理, 与触控运动中用户行为非常相似, 能够有助于很多关键特性的模拟, 在下一节中, 我们将给出最优反馈系统形式化表达, 对表达式在触控交互运动描述中的意义进行分析, 构建基于最优反馈控制的触控交互运动模型。

4.3 基于最优反馈控制的运动模型构建

本文使用了 Todorov 等人[26]提出的线性二次高斯模型 (linear-quadratic-Gaussian, LQG) 来对目标获取运动进行建模。指点设备的运动近似于由一个受控制的力所推动的质点运动, 它可以被定义为一个如下所示的线性动态系统 sys , 其中, 在离散时刻 t 的系统状态为 $\mathbf{x}_t \in \mathbb{R}^m$, 控制信号为 $\mathbf{u}_t \in \mathbb{R}^n$, 感知反馈为 $\mathbf{y}_t \in \mathbb{R}^k$:

$$\begin{aligned}
 \text{Dynamics} \quad & \mathbf{x}_{t+1} = \mathbf{A}\mathbf{x}_t + \mathbf{B}\mathbf{u}_t + \boldsymbol{\zeta}_t + \boldsymbol{\varepsilon}_t \mathbf{C}\mathbf{u}_t \\
 \text{Feedback} \quad & \mathbf{y}_{t+1} = \mathbf{H}\mathbf{x}_t + \boldsymbol{\omega}_t \\
 \text{Cost} \quad & \mathbf{x}_t^T \mathbf{Q}_t \mathbf{x}_t + \mathbf{u}_t^T \mathbf{R}_t \mathbf{u}_t
 \end{aligned} \tag{16}$$

在每个时刻 t , 通过当前观测到的反馈 \mathbf{y}_t , 控制器必须找到最优控制信号 \mathbf{u}_t , 使得整

个运动过程产生的损失 Cost 最小。其中控制信号 \mathbf{u}_t 可以模拟用户的中枢神经系统对手部运动发出的控制指令，反馈信号 \mathbf{y}_t 则模拟用户得到的视觉和触觉反馈。当控制命令发出后，推动质点的力遵循命令并推动质点运动，我们用此来模拟用户手部力量推动指点设备运动的过程。 $\xi_t \in \mathbb{R}^m$ 和 $\omega_t \in \mathbb{R}^k$ 是两个独立多维正态随机变量，他们的均值为 0，协方差矩阵为 Ω^ξ 和 Ω^ω ，可以模拟控制和感知过程中的白噪声。另一个随机变量 ε_t 是一个独立的标准正态分布随机变量，它与控制向量相乘用于产生控制信号依赖的噪音（control-dependent noise），这与速度准确性原则很契合，当用户发出更强烈控制信号促使手部运动时，其准确性一般出现下降的情况。 R 和 Q_t 是两个系数矩阵，用于定义系统与状态和控制信号有关的损耗，它们的系数的确定，同样反映着用户的身体消耗、速度和准确性之间的权衡。总之，这整个系统的运行模拟了用户根据任务需求、个人消耗、速度准确性权衡动态的调整他们的行为的过程。

上述最优化问题的解依赖于一个假设，即当前状态是对整个历史状态，包括控制、反馈信息的完全总结，基于这个假设，文献[26]给出了一个求解方法，本文采用该方法为本模型中的优化问题求解。

对于指定的目标获取运动，系统的状态 \mathbf{x}_t ，由一个 10 维向量表示，其包括光标的位置、速度、力量等：

$$\mathbf{x}_t = [p_x(t); p_y(t); \dot{p}_x(t); \dot{p}_y(t); f_x(t); f_y(t); g_x(t); g_y(t); p_x^*(t); p_y^*(t)] \quad (17)$$

其中， $p_x(t)$ 和 $p_y(t)$ 为光标的位置， $\dot{p}_x(t)$ 和 $\dot{p}_y(t)$ 为光标的速度， $f_x(t)$ 和 $f_y(t)$ 为用户的手控制光标的力， $g_x(t)$ 和 $g_y(t)$ 是一个辅助状态用于实现二次低通滤波的肌肉仿真（second-order muscle-like low-pass filter）[67]。 $p_x^*(t)$ 和 $p_y^*(t)$ 为目标的位置。初始状态 \mathbf{x}_1 由一个均值为 0，协方差为 Σ_1 的多维正态分布随机变量生成。

驱动光标移动的控制信号 \mathbf{u}_t 定义为：

$$\mathbf{u}_t = [u_x(t); u_y(t)] \quad (18)$$

然后，光标的运动由一个离散时间下的牛顿力学质点运动进行仿真，下式中 ($d = x/y$):

$$\begin{aligned} p_d(t+1) &= p_d(t) + \dot{p}_d(t)\Delta \\ \dot{p}_d(t+1) &= \dot{p}_d(t) + f_d(t)\Delta/m \\ f_d(t+1) &= f_d(t)(1 - \Delta/\tau_2) + g_d(t)\Delta/\tau_2 \\ g_d(t+1) &= g_d(t)(1 - \Delta/\tau_1) + u_d(t)(1 + \sigma_c \varepsilon_t)\Delta/\tau_1 \end{aligned} \quad (19)$$

σ_p , σ_v 和 σ_f 的白噪音, 对感知过程中的不确定性进行模拟。

运动状态产生的损耗用于驱动光标移动获取目标, 并能够在目标处停留下来, 它被如下定义:

$$\begin{aligned} statCost = & (p_x(t) - p_x^*(t))^2 + (p_y(t) - p_y^*(t))^2 + (\dot{p}_x(t)w_v)^2 + (\dot{p}_y(t)w_v)^2 \\ & + (f_x(t)w_f)^2 + (f_y(t)w_f)^2 \end{aligned} \quad (23)$$

运动控制产生的损耗用于模拟用户“尽量降低身体损耗”的特点:

$$controlCost = r(u_x^2 + u_y^2) \quad (24)$$

因此, 参数 r , w_v 和 w_f 实际上为交互运动的身体损耗、速度和力量的使用起到了权衡的作用, 他们模拟了用户使用尽量少的身体损耗, 同时控制光标尽快地移动到目标位置。将上式转换为公式(16)中, 则需设置 $R = r$, 系数矩阵 Q_t 为:

$$Q_t = \frac{1}{N} q^T q; \quad q = \begin{bmatrix} -1 & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & 1 & \cdot \\ \cdot & -1 & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & 1 \\ \cdot & \cdot & w_v & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & w_v & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & w_f & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & w_f & \cdot & \cdot & \cdot & \cdot \end{bmatrix} \quad (25)$$

由此, 我们完成了触控交互运动最优反馈控制模型的形式定义。

4.4 运动关键参数优化

从上面的模型构建过程可以看出, 触控交互运动中的很多特点在模型中的体现, 会受到下面这个参数集的影响:

$$\theta = [\sigma_c, \sigma_p, \sigma_v, \sigma_f, r, w_v, w_f] \quad (26)$$

这个参数集 θ 的选取, 将很大程度影响仿真结果的平均轨迹和轨迹变异性, 因此我们将它作为模型的关键参数集进行优化和调整, 使得模型仿真效果能够逼近经验数据。为了对该参数集进行优化, 我们首先需要定义一个评价模型仿真结果与经验数据之间相似度的函数。

受[68]研究工作的启发, 我们定义了一种相似度的度量方法, 该度量方法考虑了两个

因素：平均轨迹差异以及轨迹变异性差异。也就是说，如果仿真结果与经验数据的平均轨迹越相近则认为它们越相似，同时，如果仿真结果与经验数据的轨迹变异性越相近则认为它们越相似，反之则越不相似。注意，我们这里所说的仿真结果和经验数据，是两个轨迹集，而非两条轨迹或者平均轨迹，因此我们讨论的相似性，是用于评价本模型是否能够模拟真实交互运动中经过反复重复后出现的特征，这也是最优反馈控制模型的优势所在。

对于一个拥有 M 条轨迹的轨迹集 $\text{traj} = \{\text{traj}_j \mid j=1,2,\dots,M\}$ ，通过重采样，这些轨迹具有同样数量的轨迹点。我们用 $p_{ij} = (x_{ij}, y_{ij})$ 来表示第 j 条轨迹上的第 i 个轨迹点，则可以计算该轨迹集中所有轨迹在第 i 个点的平均位置：

$$\bar{p}_i = (\bar{x}_i, \bar{y}_i) = \left(\frac{1}{M} \sum_{j=1}^M x_{ij}, \frac{1}{M} \sum_{j=1}^M y_{ij} \right) \quad (27)$$

同时，我们可以定义轨迹集在第 i 个位置上的轨迹变异性：

$$\text{var}_i = \left(\sqrt{\frac{1}{M} \sum_{j=1}^M (x_{ij} - \bar{x}_i)^2}, \sqrt{\frac{1}{M} \sum_{j=1}^M (y_{ij} - \bar{y}_i)^2} \right) \quad (28)$$

我们用 s 和 e 分别标记仿真轨迹集和真实轨迹集，下面我们给出相似度定义：

$$\begin{aligned} \text{trE} &= \frac{1}{n} \sum_{i=1}^n \| \bar{p}_i^s - \bar{p}_i^e \| \\ \text{vaE} &= \frac{1}{n} \sum_{i=1}^n \| \text{var}_i^s - \text{var}_i^e \| \end{aligned} \quad (29)$$

其中， trE 为平均轨迹误差，它是仿真轨迹集和真实轨迹集所有对应的点位上平均位置的平均欧氏距离，该误差越大，说明两组轨迹的平均轨迹上越不相似。 vaE 为轨迹变异性误差，它是仿真轨迹集和真实轨迹集所有对应的点位上变异性的平均欧氏距离，该误差越大，说明两组轨迹的轨迹变异上越不相似。注意到仿真轨迹的产生依赖于参数集 θ 的设定，因此仿真集可以看作是参数集 θ 的函数，真实轨迹集是常数，由此 trE 和 vaE 则均为 θ 的函数，我们则可以定义以参数集 θ 作为变量的损失函数 $J(\theta)$ 为：

$$J(\theta) = \text{trE} \times \text{vaE} \quad (30)$$

因此，如果模拟轨迹集与真实轨迹集越相似，则损失函数越小。

接下来，我们构建一个随机搜索算法，并将 $J(\theta)$ 作为损失函数来估计 θ^* ，使得仿真集和经验数据集之间有最高的相似度，这个随机搜索算法包括以下几个主要步骤：

- (1) 给定一个搜索区域： $\mu_i - \Delta_i < \theta_i < \mu_i + \Delta_i (i=1, 2, \dots, n)$ 。
- (2) 在这个区域内找到 T 个 θ 满足： $J(\theta^{(1)}) > J(\theta^{(2)}) > \dots > J(\theta^{(T)})$ 。
- (3) 利用下式更新 μ_i 和 Δ_i ：

$$\mu_i = \frac{\sum_{t=1}^T W^{(t)} \theta_i^{(t)}}{\sum_{t=1}^T W^{(t)}}; \quad \Delta_i = C \sqrt{\frac{\sum_{t=1}^T W^{(t)} (\theta_i^{(t)} - \mu_i)^2}{\sum_{t=1}^T W^{(t)}}}; \quad W^{(t)} = \frac{J(\theta^{(T)})}{J(\theta^{(t)})} \quad (31)$$

- (4) 在新的区域内搜索，直到下面的收敛条件满足或者达到最大迭代次数：

$$\left| \frac{J(\theta^{(1)}) - J(\theta^{(T)})}{J(\theta^{(T)})} \right| < \varphi \quad (32)$$

在本案例中，我们有 7 个待优化参数，因此 n 的取值为 7， T 和 C 被经验地设置为 5 和 2。

模型中的其它运动学和物理参数，包括质量 m ，离散时间间隔 Δ ，肌肉控制延迟参数 τ_1 和 τ_2 ，根据文献[26]设置为 $m = 1\text{kg}$ ， $\Delta = 0.01\text{sec}$ ， $\tau_1 = \tau_2 = 0.04\text{sec}$ 。初始状态随机变量的协方差矩阵 Σ_1 被经验地设置为：

$$\Sigma_1 = (\text{diag}[10\text{px}, 10\text{px}, 10\text{px/s}, 10\text{px/s}, 1\text{N}, 1\text{N}, 0, 0, 0, 0])^2 \quad (33)$$

注意到这里使用的距离单位是像素 (px)，因为我们模拟的交互运动是在计算机显示设备的逻辑空间中进行的。最后，整个系统的步长被 N 被设置为 1000，使得模拟的最大时长为 10 秒，因为本文模拟的交互运动都在 2-5 秒内完成。

4.5 模型参数估计与实验验证

为了给参数估计提供经验数据，本文分别设计并实施了静态目标获取和动态目标获取的用户实验。

被试和实验设置：

我们招募了 20 位被试，14 男 6 女，平均年龄 26.3 岁，他们所有人都是右利手并且都有超过两年的计算机使用经验。

实验在一台 Dell OptiPlex 9020 桌面计算机上进行，计算机处理器为 Intel Core i7 4 Quad core，主频 3.6 GHz，具有一个 23 寸（533.2mm * 312mm）LED 显示器，分辨率为 1920 * 1080，使用的指点设备为 Dell MS111，分辨率为 1000dpi，如图 28 所示。

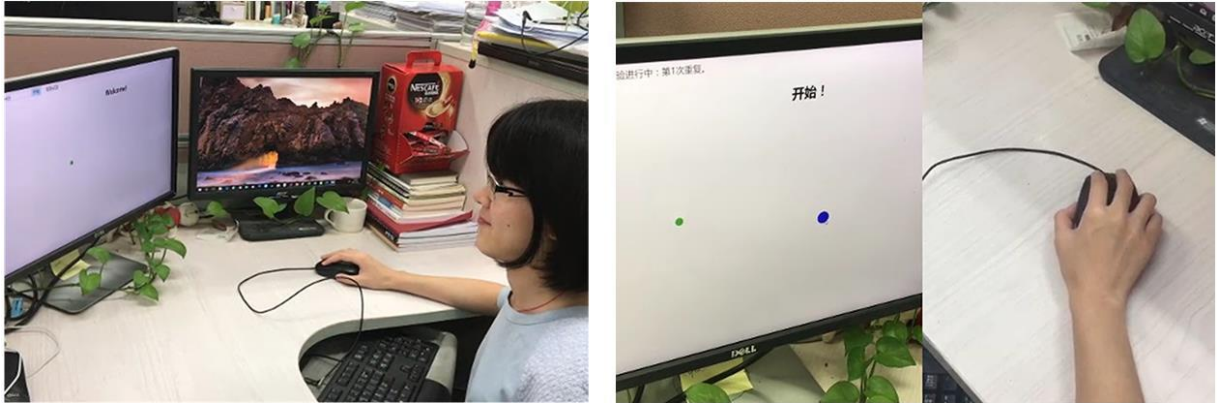


图 28 目标获取实验设置和被试参与实验的情况

实验设计和流程:

对于静态目标获取，光标的启示位置设置为屏幕中央，目标设置为距离显示器正中央 480px 外的 48px 直径大小的点，如图 29 (a) 所示。对于运动目标获取，目标设置为同样位置同样大小的点，但是该目标会以 144px/sec 的速度朝 8 个不同的方向移动，8 个不同的运动方向如图 29 (b) 所示。




图 29 静止目标获取 (a) 和动态目标获取 (b) 实验设置

对于每一次目标获取试验，光标初始时被固定在屏幕的正中央，一个蓝色的圆形目标随后出现。每位被试被要求移动光标尽量快准地到达目标处。被试只有一次机会去点取目标，如果某位被试某次点取目标失败，该被试将需要重新获取该次目标直至其获取成功。对于静态目标获取，每名被试需要完成 6 次试验。对于动态目标获取任务，每名

被试需要在 8 个方向的每个方向完成 6 次试验。在动态目标获取任务中，目标移动的 8 个方向是由程序随机设置的。整个实验大概需要 10 分钟完成，在每次试验中间被试可以停下来休息。

实验结果：

本文对包括静态目标获取和动态目标获取的 9 种任务分别做参数估计。搜索算法在初始参数范围内随机选取参数，并用每一组参数其生成一组仿真数据，然后按照上一节给出的算法进行比较和迭代，最终找到 θ^* 。为了加速收敛，本文将所有静态和动态目标选择任务的初始搜索区域设置为：

$$\begin{aligned}\mu &= [0; 0; 0; 0; 0; 0; 0] \\ \Delta &= [1000; 1000; 1000; 1000; 1000; 1000; 1000]\end{aligned}\quad (34)$$

收敛系数 φ 设置为 0.05，最大迭代次数设置为 20。

在搜索过程中，算法必须在某个具体的目标选择任务刚刚建立时就能够不断地利用最优反馈控制模型在当前的 θ 下得仿真运动轨迹。具体地，在每一步的迭代过程中，我们模拟了与实验数据具有相等数量的仿真轨迹，从而计算损失函数 $J(\theta)$ 。为了模拟 9 个目标选择任务中某个目标选择任务的一条轨迹，光标状态 \mathbf{x}_0 在均值为 $[0; 0; 0; 0; 0; 0; 0; 0; p_x^*(0); p_y^*(0)]$ ，协方差为 Σ_1 的多维正态随机变量下初始化。对于静态目标获取任务，我们通过设置 $p_x^*(t) = 480; p_y^*(t) = 0; (t = 1, 2, \dots, N)$ ，将状态中的目标位置固定在相对于屏幕中心（480px × 0px）的位置；对于移动目标获取任务，我们将目标位置设置为 $p_x^*(t) = 480 + t \times v_x; p_y^*(t) = 0 + t \times v_y; (t = 1, 2, \dots, N)$ ，其中 $\mathbf{v} = [v_x, v_y]$ 根据目标移动方向进行设置，例如，对于方向向右的移动目标获取任务，我们设置 $\mathbf{v} = [1.44, 0]$ 。每一次仿真中，如果条件 $\|p(t) - p(t)^*\| < 48$ 满足 0.5sec（50 个仿真步长）以上，则认为用户获取到目标，仿真结束。

本文对静止目标获取和动态目标选择任务的最终估计参数如表 4 所示。

表 4 静止目标获取和动态目标选择任务的最终估计参数

参数集	σ_c	σ_p	σ_v	σ_f	r	w_v	w_f
θ_s	5.4132	68.05	474.68	381.10	690.90	820.35	592.20
θ_m	10.3310	147.29	241.49	147.82	1149.71	646.96	176.89

对于运动目标选择任务，仿真出了 8 个方向的 8 组估计参数，本文使用它们的平均值作为最终运动目标选择任务的估计参数。

通过使用以上两组参数，我们对 9 个目标选择任务各模拟了 120 条用户目标获取运

动轨迹。这些轨迹的平均轨迹和轨迹变异性如图 30 所示。从图中可以看出，本文系统对文中所有实验条件的平均轨迹和轨迹变化都进行了很好地模拟。从表 5 给出了 9 个目标获取任务的平均轨迹误差 trE 和轨迹变异性误差 vaE 。对于静态目标，平均轨迹误差为 9.86px，相当于轨迹长度的 1.7%，轨迹变异性误差是 17.89px，相当于总变异性的 3.86%；8 个移动任务的平均轨迹误差最小值为 22.14px（6.59%），最大值为 52.07（10.56%），轨迹变异性误差最小值为 27.03px（3.28%），最大值为 49.75（5.6%）。这个结果表明本文提出的模型有效地仿真了文中涉及的用户目标获取任务。

表 5 静止目标获取和动态目标选择任务的相似度

误差	静止	运动 (→)	运动 (↘)	运动 (↓)	运动 (↙)	运动 (←)	运动 (↖)	运动 (↑)	运动 (↗)
trE	9.86	30.51	45.02	52.07	22.14	23.13	37.04	38.86	44.93
vaE	17.89	46.02	40.32	30.98	27.03	27.14	28.80	49.75	29.82

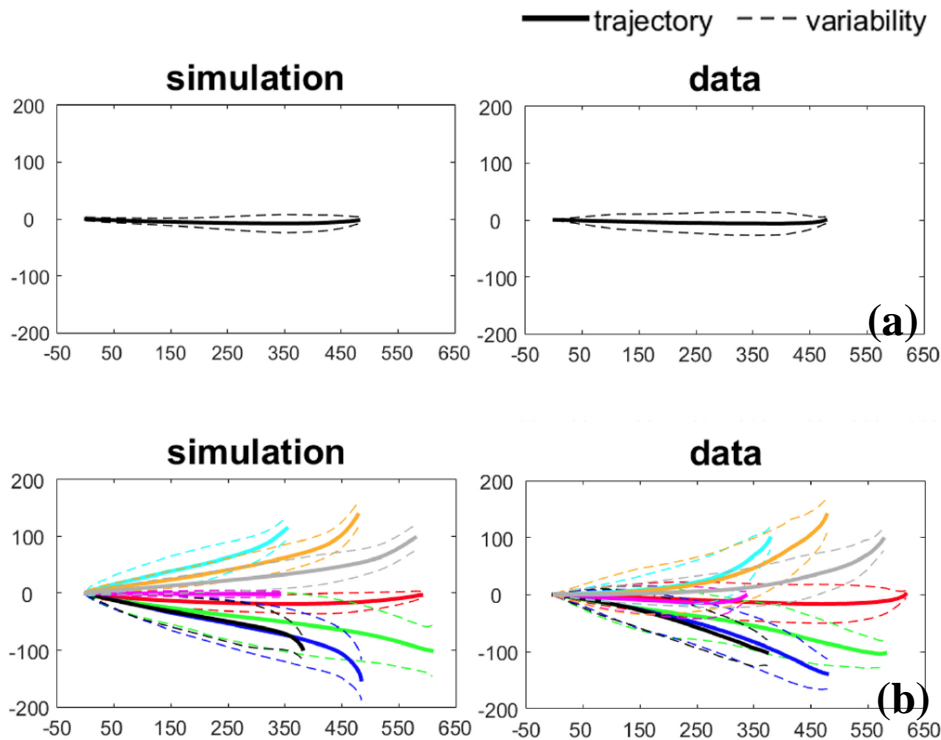


图 30 静止目标获取 (a) 和移动目标获取 (b) 的实验数据与仿真结果对比

图 31 和图 32 分别为静止目标和动态目标获取任务的仿真数据与经验数据的原始轨迹对比。整体上，用户在完成目标选择任务时，倾向于将自己预测的目标位置和跟踪的动作结合在一起，使光标在一开始时直接向预计的位置移动，随后平滑地移动到目标

处。本文的模型很好地重现了这一现象。另一方面，用户会产生无意识的移动并且不断纠正自己的移动[65]，导致每条运动轨迹各不相同但都能最终到达目标处，本文的方法和系统也重现了这一现象。此外，交互运动中的速度准确性权衡现象[2]也在本文的模型中得到了重现。




图 31 静止目标获取的经验数据和仿真结果的原始轨迹对比

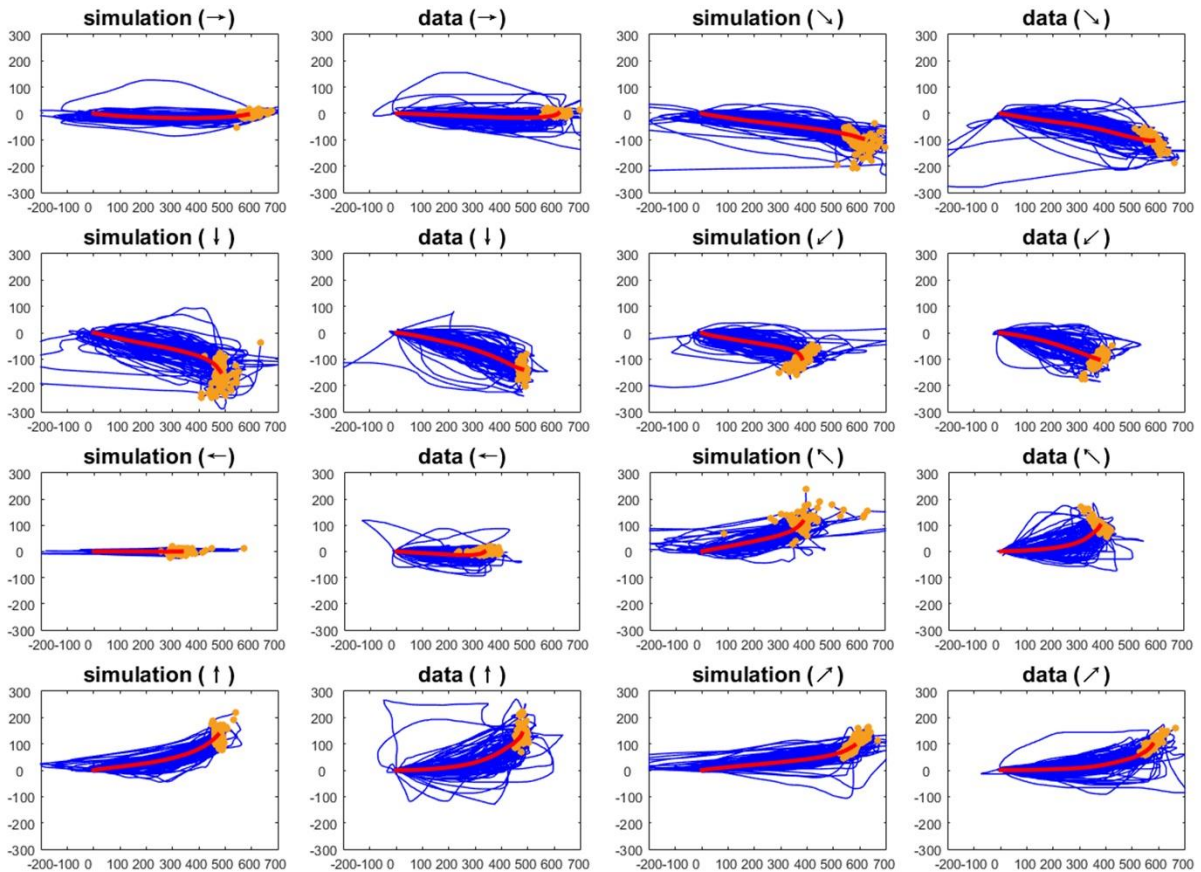


图 32 九个移动目标获取的经验数据和仿真结果的原始轨迹对比

在估计得到某一交互场景中的模型参数之后，我们就能利用该模型模拟任意位置的静止目标或者任意速度的移动目标的获取运动，如图 33 所示是利用本模型模拟的四个交互运动过程，他们包括位于右上方的静止目标、上下移动的移动目标、直角转弯的移动目标和以正弦曲线移动的移动目标。通过目标大小、位置、运动规律一起前后顺序的

组合，我们甚至可以模拟一个复杂的用户界面交互行为，例如社交网站或者购物网站的用户行为，经过适当地拓展和训练，这个模型还有可能模拟 3D 或 2D+3D 的混合空间[93]中的交互运动，甚至能够用于实物交互、眼动、VR 或 AR 等场景中，在未来的人机交互基础研究中，有可能成为非常重要的模型之一。

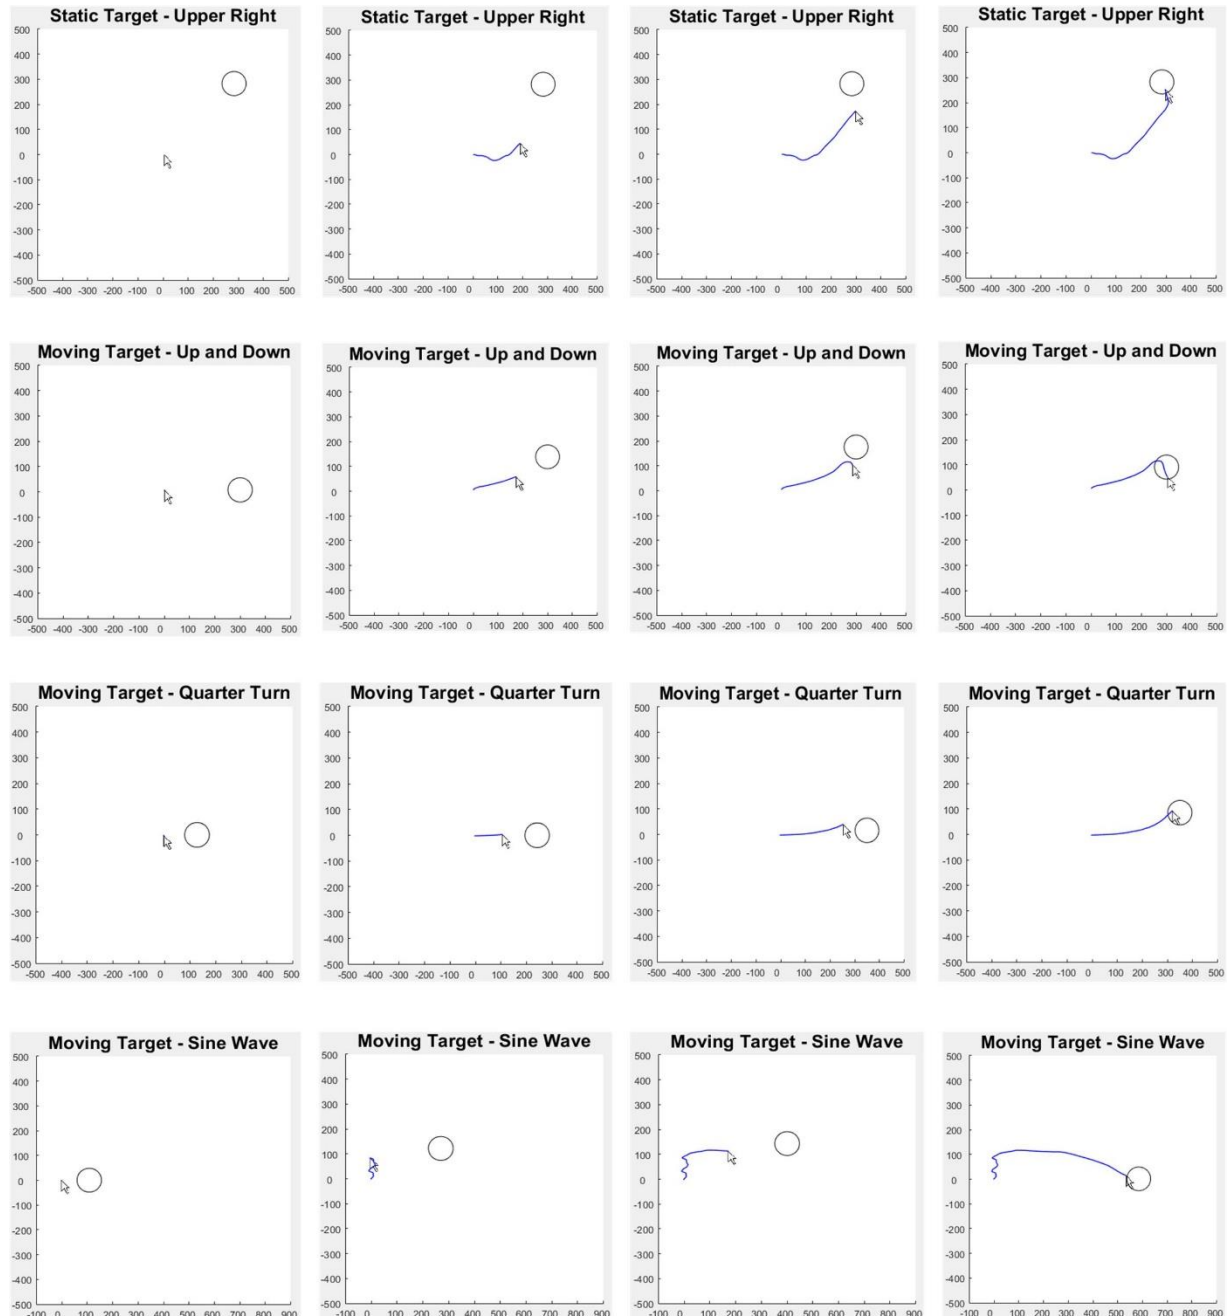


图 33 利用本模型模拟的四个交互运动过程

4.6 本章小结

本文展开了触控交互运动反馈控制模型的研究，随着连续交互空间的交互系统的不断普及，理解用户选择目标时的过程特性具有重要意义。为了弥补面向过程属性的运动模型研究的不足，在本章中我们从控制领域引入一个最优反馈控制模型，利用它对目标获取运动的过程特性进行建模。

我们首先对最优反馈控制机理进行分析，将其与交互运动中的感知运动模式进行了对比，发现了很多相似之处，然后将这种最优反馈机制用到交互运动中，提出了一个触控交互运动的反馈控制模型，并利用它对目标获取运动的过程特性进行建模。

我们对两种典型的交互任务，包括静态目标和移动目标获取任务分别进行了研究和实验验证。首先，我们给出这两种任务的反馈控制形式化表达，其次，我们设计了一个相似性度量方法以使用经验数据来估计模型关键参数，最后，我们再使用该模型来模拟目标获取运动并评价模拟的效果。结果表明，利用本文提出的模型，运动轨迹和运动过程的变异性得到了很好的模拟，在用户做目标获取任务时，许多重要的特征，如速度准确性原则和反馈控制的不确定性，都得到了很好的再现。

我们相信，本文提出的交互运动最优反馈控制模型，将会对未来的用户界面的设计起到指导作用。例如，通过模拟用户在购物网站上的运动模式预估用户在该购物网站的购物难度和购物效率。本文的工作还可能为人机交互领域的运动不确定性或理解-运动协调等论题提供新的理解。

第5章 触控交互运动的用户特征研究

5.1 引言

轨迹任务，例如在嵌套式的菜单中选择按钮，绘制一个曲线或者在 3D 虚拟的轨道中移动，在现代人机交互界面中是一个普遍的人机交互任务。目标获取任务的用户表现往往和目标获取的最后一刻紧密相关，因为这种任务的主要约束由目标，甚至是目标的最终状态产生[2][32]，而在轨迹任务中，任务的约束贯穿于整个过程[15]，这使得轨迹任务具有更加丰富的用户特征。

举例来说，如第 2 章中的图 5 所示的一个轨迹任务，要成这个任务，用户首先必须保证通过管道的每一时刻，光标始终在轨道宽度的约束范围之内，这对用户提出了一个连续的对准确性要求；其次，用户需要不断地观察前方轨道的情况，为下一刻的移动做出决策，这对用户的眼手配合能力提出了要求；再次，如果管道具有弯道，为了保证光标不“冲出轨道”，用户必须在每个弯道处减速，选择新的方向，再重新提速，这对用户的手部的肌肉控制提出了要求。这些要求使得用户的特征更具有定量化和统计意义。

轨迹任务的用户特征可以分为全局特征和局部特征两大类。全局特征与目标获取时间和错误率类似，是对整体轨迹完成情况进行评估的用户特征，这些特征包括识轨迹距离[54][55][56][94]、时间表现[56][57]、以及广泛用于手势识别和草图理解的 Rubine 特征集[59]。这种高级别的特征很好地描述了轨迹的用户表现，但是轨迹任务中表现出来的细节运动行为被忽略了。例如，笔和触控手势具有相似的轨迹任务时间表现和绘制长度，但是，却在轨迹空隙、转角距离、关节处有很大差别。

局部特征是指通过分析轨迹的绘制细节，得到的一系列与轨迹形状无关的几何学或运动学特征，这些特征的优势在于与任务无关，几乎在任何具有轨迹任务的交互场景下都可以应用。为此，本文将面向基于轨迹任务的触控交互应用，在分析轨迹任务局部特征的基础上，构建一组任务无关的用户特征集。

5.2 绘图任务和任务自由度

绘图任务由轨迹任务组成，用户在这种任务中，一般需要根据要求或提示，通过一组连续的笔划完成一个具有交互意义的图形绘制。绘图任务的典型应用是手势交互系统（Gesture-based Interaction System）[59]，这类系统中，用户通过绘制手势（gesture）实

现自然的人机交互操作。

绘图任务虽然由轨迹任务组成，但在每一个轨迹的绘制上放宽了任务约束，例如，“图形描绘”任务要求用户对指定图形进行描绘，原有图形即轨道，用户需要尽量不偏离该轨道，而非必须在轨道内通行。又如“图形复制”任务要求用户对照指定图形在空白处重新绘制一个副本，轨迹任务的约束仅存在于用户的认知状态中，而非界面实体。绘图任务虽然放宽了细节运动上的限制，但在空间几何认知能力和绘图能力上提出了要求。这些要求使得绘图任务能更反映认知方面的用户特征。

下面，我们将引入绘图任务自由度（degree of freedom, DOF）的概念，对绘图任务从空间形态约束和绘图提示两个维度上进行划分。这样做的目的有两个：（1）首次尝试对绘图任务在一个 2D 连续空间上进行类别划分，旨在能够更好的指导今后这一场景下的研究和设计。（2）验证本文的用户特征集在从不同自由度的绘图任务上的表现。

首先定义自由度的两个维度：

维度 1：几何形态约束。是指绘图任务在绘图轨迹和形态上对用户行为的约束，是运动层面的自由度，典型的约束包括：无约束、形状约束和轨迹约束。

维度 2：绘图提示强度。是指绘图任务在绘图目的和要求上对用户行为的提示度，是认知层面的自由度，典型的提示包括：无提示、认知提示和视觉提示。

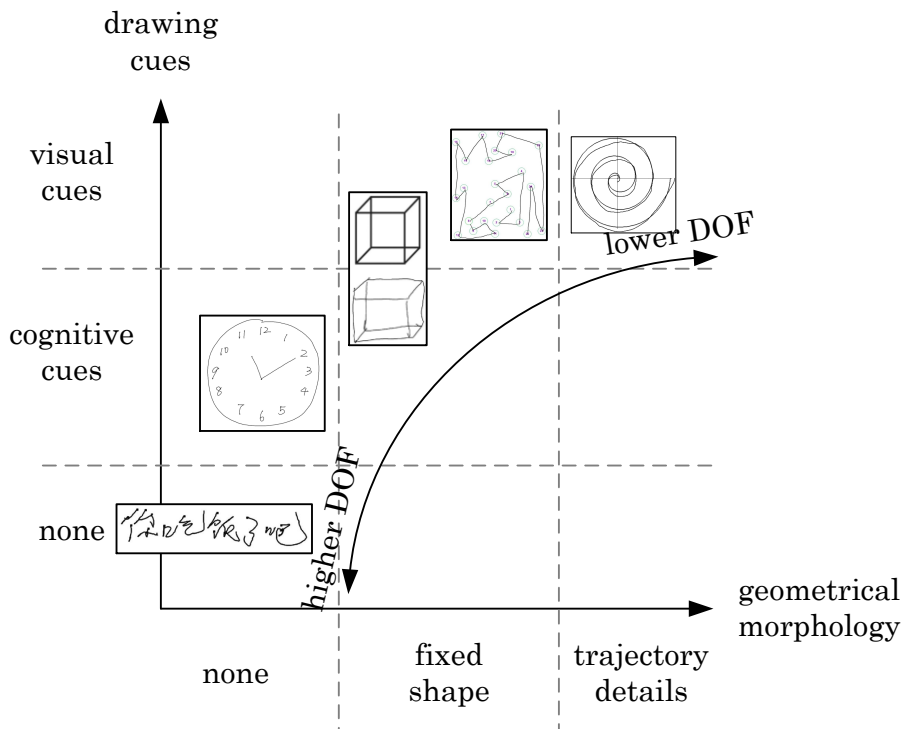


图 34 绘图任务自由度空间以及 5 个典型的绘图任务在此空间中的分布

从而，绘图任务自由度的定义为：绘图任务在几何形态和绘图提示上对用户绘图行为进行约束和限制的强度。

图 34 显示了本文定义的绘图任务自由度空间，横轴为几何形态约束，纵轴为绘图提示强度，当几何形态的约束越强，且绘图提示强度也越强时，用户受到的限制越大，绘图任务的自由度越低，相反，用户的行为越自由，绘图任务的自由度越高。如图所示，自由度最低的是一个“螺旋线描绘”任务，在让轨迹尽量接近该任务指定的螺旋线轨迹，同时，任务给出具体轨迹的视觉提示。第二个“连线任务”要求用户用笔划将一组分散的点按照顺序连接起来，相比“螺旋线描绘”，“连线任务”也提供了视觉提示，但不要求用户对指定轨迹进行描绘，而是仅用一个点的集合限制了图形的总体形态。第三个“立方体图形复制”任务要求用户对照指定图形在空白处重新绘制一个副本，该任务的绘图提示介于视觉和认知之间，因为用户必须首先理解他们看到的立方体，然后将这个认知内容转换到另一个空间中并绘制出来；同时，在几何形态上，虽然任务要求用户“画得尽量相似”但由于没有界面上的直接限制（实际上用户可以自由地绘制），它的约束也相对“螺旋线描绘”和“连线任务”更低。第四个“画钟任务”不给用户提供任何视觉提示并，也不对钟表的形状做要求，而仅要求用户绘制一个有分针和时针的钟表，并使其指向某个时间，这使得这个任务没有形状约束，提示强度也仅在认知上，而非视觉。最后一个“书写任务”要求用户写下任何一句话，它具有最高的自由度，因为这个任务不提供任何提示和形状约束，而仅要求用户写下文字。

5.3 通用轨迹切分算法

为了得到任务无关的用户特征集，一个直接的思想是基于笔划（stroke）计算细节特征，这种思想已经被文献[60][61]用于分析用户绘制笔划的细节当中。然而，当我们直接使用原始笔划，即从落笔到抬笔之间的整段笔划，用户间的差异性会导致细节特征的丢失。举例来说，画同一幅画或者写同一个字，一些用户喜欢使用小段的短笔划，一些则喜欢使用长连笔。为了解决这一问题，我们利用子笔划（sub-stroke）而非原始笔划作为分析的基本单元。考虑到通用性，下文中，我们用轨迹（trajectory）和子轨迹（sub-trajectory）来称呼。

子轨迹是这样一段轨迹，它是由指定的轨迹属性进行切分的轨迹段，这种轨迹属性通常是原轨迹的几何极值点，且通常为直线或者简单曲线形态。

然而，得到子轨迹并不简单，因为我们必须最大程度地面向不同应用场景、考虑不同的需求并为不同的轨迹任务提供切分方法。如图 35 所示的一个图形复制任务中，不同的用户复制同一个目标形状图 35 (a)，其结果大不相同，如果图形复制得很工整，如

图 35 (b) 左所示, 其切分可以利用立方体的图形信息, 用立方体的顶点进行切分, 然而, 不同用户绘制的图形差异巨大, 如图 35 (b) 中, 其笔顺和形状都与上一个不一致, 图 35 (b) 右则更甚, 基本没有按照原图进行绘制, 且还包含大量的碎笔。图 35 (c) 是直接使用原轨迹进行切分的结果, 轨迹之间的可比性大大降低了。




图 35 一个图形复制任务的子轨迹切分

为了解决这一问题, 我们提出一个通用轨迹切分算法, 它利用轨迹的空间信息和时域信息帮助我们从一个通用轨迹任务中获取到一个具有可比性的子轨迹集。在介绍该算法之前, 我们首先给出几个轨迹数据处理算法, 它们将支持我们之后对通用轨迹切分算法的描述。

5.3.1 轨迹数据处理算法

时间-空间等距重采样 (Spatio-temporal Evenly Resampling)

触控交互中的轨迹数据实际上是由一个有序的采样点集组成的, 所有的这些采样点都是通过触控设备上的位置传感器获取, 因此, 它的采样率由触控设备的软硬件决定。通常, 触控设备的采样率是固定的, 但是在实践中, 采样率可能受到系统运行环境的影响导致波动, 对后续的特征提取产生负面影响。同时, 在后续特征提取过程中, 为保证特征的一致性, 我们主要使用两类轨迹, 一类是时间等距轨迹, 它要求两个采样点之间的时间间隔保持一致, 用于计算时域相关特征; 一类是空间等距轨迹, 它要求两个采样点之间的空间距离保持一致, 用于计算位置相关特征。

因此为了解决上述问题并得到这两类轨迹, 我们使用线性插值算法对原始轨迹采样进行处理, 下面我们先给出时间等距轨迹的处理算法 (Temporal Evenly Resampling, TER):

算法 1. Temporal Evenly Resampling

Input: Stroke points (*points*) and target sampling time sampling interval (*I*)

Output: The new time uniform points (*newPoints*)

```

index = 0;
newp = points(index);
APPEND(newPoints, newp);
index++;
repeat
    q = newPoints.getLast(); // q will be the last point
    p = points(index);
    D = ptime - qtime;
    if (D ≥ I)
        foreach attribute attr in a point
            newpattr = pattr + I / D × (pattr - qattr);
        end
        APPEND(newPoints, newp);
    else
        index ++;
    end
until index == LENGTH(points);

```

该算法遍历所有原始轨迹点，计算新轨迹 *newPoints* 的最后一个点 *q* 与原始轨迹 *points* 的下一个点 *p* 之间的时间间隔 *D*。如果时间间隔 *D* 比采样间隔 *I* 更长，则创建一个新的点，通过插值算法计算这个点上的所有属性，并将其插入到新轨迹中 *newPoints* 的末尾。这里，一个点的属性包括时间戳、X 和 Y 坐标、压力等一切触控设备提供的属性值。空间等距轨迹的处理算法（Spatial Evenly Resampling, SER）与 TER 类似，唯一的差别是变量 *D* 的定义，从两个点之间的时间间隔变为欧氏距离。

无意识行为提取

滤波处理算法通常被用于除去信号噪声，在本文中，我们更希望从轨迹信号中提取看起来和噪声相似的用户无意识行为。轨迹中的无意识行为和对用户的特征提取和轨迹切分有重要作用。因此，我们反过来利用滤波器，帮助我们从原始信号中提取无意识行为：

轨迹任务中，任何属性都可以看做是一个信号 $s(n)$ ，我们假设它包含两个组成部分：有意识运动部分（intentional movement component, IMC） $i(n)$ 和无意识运动部分（unintentional movement component, UMC） $u(n)$ ：

$$s(n) = i(n) + u(n) \quad (35)$$

为了得到无意识运动部分，我们对上式进行转换：

$$u(n) = s(n) - i(n) \quad (36)$$

其中， $s(n)$ 可以直接从触控设备中得到，而 $i(n)$ 是未知的。我们使用高斯滤波器对 $i(n)$ 进行估计：

$$\hat{i}(n) = \sum_{k=-w}^w \left[\frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{k^2}{2\sigma^2}\right) s(n+k) \right] \quad (37)$$

其中， $\hat{i}(n)$ 代表估计得到的在时刻 n 的 IMC， $s(n+k)$ 是从设备中直接获得的信号，它距离 n 时刻偏置了 k 的时长， w 为处理时间窗口一半的长度。因为高斯滤波器对原始信号进行了平滑处理，用户的无意识运动被排除在 $\hat{i}(n)$ 之外，从而，我们可以通过原始信号减去 IMC 来计算 UMC：

$$u(n) = s(n) - \sum_{k=-w}^w \left[\frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{k^2}{2\sigma^2}\right) s(n+k) \right] \quad (38)$$

5.3.2 通用轨迹切分算法

下面我们给出通用轨迹切分算法描述。

算法主要包括两个步奏，首先利用局部几何极值对长而且复杂的轨迹进行切分。注意，我们在执行这一步前，有意地不对轨迹进行平滑处理，因为平滑处理会导致局部运动特征的丢失，且对于不同的任务，平滑阈值必须是不一样的，这使算法不能做到任务无关。在实践当中，这一步会产生大量的过切分轨迹段。因此，在第二步中，我们利用时间和空间信息将密集的过切分点进行聚类，并挑选最优切分点作为最终切分点。下面给出这一算法的伪代码：

算法 2. General Segmentation Algorithm

Input: Stroke points (*points*), curvature threshold (*c*), cluster length (*l*) and cluster time (*t*)

Output: Segmented strokes (*strokes*)

points = SERESAM(*points*);

points_cur = GET_CURVATURE(*points*);

points_cur = GET_UMC(*points_cur*);

foreach point *cur* in *points_cur*

if (*cur* ≥ *c*)

indexes.add(points_cur.getIndex(cur));

end

end

foreach index *i1* in *indexes*

foreach index *i2* in *indexes* **and** *i2* != *i1*

```

        if (DISTANCE(points(i1), points(i2)) ≤ l and TIME(points(i1), points(i2)) ≤ t)
            i1.nearIndexes.add(i2);
        end
    end
end
indexes = SORT_BY_NEARINDEX(indexes);
foreach index i1 in indexes
    foreach index i2 in indexes and i2 != i1
        if (i1.nearIndexes.contains(i2))
            indexes.remove(i2);
        end
    end
end
strokes = SEGMENT(points, indexes);

```

第一步，算法对轨迹进行 SER 重采样，在此基础上获得所有点的曲率并将它们放入一个链表 $points_cur$ 中，然后，利用一个高斯滤波器从 $points_cur$ 获得曲率的局部极值，并通过一个曲率阈值 A 将过切分点筛选出来放入过切分点列表中。局部极值的计算方法与 UMC 的方法相同。第二步，算法遍历所有的过切分点，将所有过切分点的一个时空领域范围 R 内的其它过切分点记录在它的一个名为 $nearIndexes$ 的数据结构中；第三步，算法对过切分点按照其 $nearIndexes$ 的数量进行降序排序；最后，遍历排序后的过切分点，将每一个过切分点的 $nearIndexes$ 中记录的其它过切分点从过切分点列表中移除。这样，剩下的过切分点列表则为最终的切分点。

这其中，阈值 A 的确定是经验性的，虽然如此，它的定制并不会对最终结果产生重大影响，因为它是一个过切分阈值，在此我们只需要尽量获得更多的过切分片段即可。时空范围 R 是这样工作的，它把与目标过切分点在时间上相差 T 并且距离上相差 D 的其它过切分点纳入该过切分点的 $nearIndexes$ 当中，时间 T 为整个原始轨迹时长的 $1/20$ ，距离 D 为整个原始轨迹长度的 $1/20$ 。

图 36 显示了这个工作流程。




图 36 通用轨迹切分算法的工作流程

图 36 (a) 是原始笔画, 图 36 (b) 是通过 UMC 局部曲率极值筛选出来的过切分点, 过切分点 1 和 7 由轨迹的起点和终点直接产生, 可以看到, 利用 UMC 已经将部分不恰当的大曲率点去掉, 但在 2, 3, 4, 5 这几个切分点上仍过于密集。算法随后计算所有这些过切分点的领域 R 内的临近过切分点 (图示中为了简单起见, 仅考虑空间邻域), 过切分点 3 的邻域中包含 2, 4, 5, 是所有过切分点中具有最多临近切分点的那个点, 因此它的邻域列表中包含的 2, 4, 5 被移除, 得到了如图 36 (c) 所标记的绿色的最终切分点。这个算法会倾向于找到一个密集过切分点集中, 处于中间位置的切分点, 且保留其它切分点的曲率信息 (不进行平滑) 作为有价值的细节运动特征。

5.4 任务无关的绘图特征提取

为了使本文提出的基于绘图任务的用户特征能够在触控交互场景中具有更广泛的适用性, 我们将基于一个装有压力传感器和陀螺仪的触控笔所获取到的数据进行之后的讨论, 除了一般触控设备能获取到的 X、Y 方向位置以外, 它还能提供触控点压力 (pressure)、触控设备空间姿态, 包括方位角 (azimuth)、高度角 (altitude) 和自转角 (rotation) 等信息, 如图 37 所示。这样做能够让我们的用户特征集既可以满足一般触控设备, 又可以支持多感知通道触控设备的应用需求。




图 37 装有压力传感器和陀螺仪的触控笔数的各项数据获取通道

5.4.1 运动参数计算

为了提取用户手部运动特征, 我们首先从原始轨迹中为每个点计算运动参数, 然后我们将利用统计、信号处理和信息熵的方法从这些运动参数中提取用户特征。我们将这运动参数分为两类, 行为参数和运动学参数。

行为参数

行为参数是指那些直接反映用户绘图行为和决策的参数, 包括 X 方向位置、Y 方向

位置、无意识运动偏离 (unintentional motion offset, UMO)、标量曲率、矢量曲率 (左旋转为正, 右旋转为负)、压力、方向角、高度角、自转角。下面介绍 UMO、标量曲率、矢量曲率、以及三个角度的计算方法, 其余参数可以直接从触控设备上读取。

我们将 UMO 定义为原始轨迹点到其 IMC 的距离, 一个位置点的 IMC 定义为 X 和 Y 的 IMC 在相互独立条件下的组合, 如图 38 所示, 灰色线条为采样点连成的轨迹, 黄色为采样点 IMC 连成的轨迹, 蓝色线条为采样点到 IMC 之间的距离




图 38 一个子轨迹的原始采样点和其 IMC

为了计算一个离散的有序点集的曲率, 我们首先利用 SER 算法对原始轨迹进行重采样, 以去掉高采样率对曲率计算造成的影响, 然后我们利用公式(39)在重采样后的轨迹中计算各点矢量曲率, 标量曲率由矢量曲率的绝对值求得, 如图 39 所示。

$$c(n) = \frac{ANGLE(\vec{v}_1, \vec{v}_2)}{|\vec{v}_1| + |\vec{v}_2|} \quad (39)$$

其中, $c(n)$ 是轨迹中点 p_n 的曲率, \vec{v}_1 是由 p_{n-1} 指向 p_n 的向量, \vec{v}_2 是由 p_n 指向 p_{n+1} 的向量, 函数 $ANGLE$ 利用余弦定理 $\theta = \arccos(\vec{v}_1 \cdot \vec{v}_2 / |\vec{v}_1| \times |\vec{v}_2|)$, 计算两个向量之间的夹角。



图 39 离散的有序点集中的曲率计算步骤

对于方位角和自转角, 我们使用增量角度而非由设备直接获取绝对角度, 我们定义增量角度为: 轨迹上任意一点的角度与轨迹起始点的角度的增量, 它能通过对轨迹上相邻点之间的增量进行累加求得。注意, 这里不能使用轨迹上任意一点的角度与轨迹起始点的角度的差代替, 因为当角度旋转超过 360° 时, 这种做法很可能导致信息丢失, 这也是我们使用增量角度而非绝对角度的原因。

对于高度角, 其理论角度范围是 $[0^\circ, 90^\circ]$, 而大部分设备只支持 $[45^\circ, 90^\circ]$, 因此它不存在上述问题, 我们从设备上直接获取高度角。

运动学参数

运动学参数已经证实能够对用户特征进行有效描述[87]，它是指由其中一部分行为参数对时间进行求导而获得的一阶和二阶运动参数。这些参数包括：X 方向速度、X 方向加速度、Y 方向速度、Y 方向加速度、速率、加速率、压力速度、压力加速度、方向角速度、方向角加速度、高度角速度、高度角加速度、自转角速度、自转角加速度。

运动学参数的计算可以通过用相应的行为参数对时间求导获得。具体地说，以 X 方向速度为例，我们首先利用 X 方向位置差除以时间差，计算两个相邻点之间连线的 X 方向速度，然后再利用前后两个连线的速度均值对中点的速度进行估计：

$$P(p_n) = \frac{P(s_{n-1}) + P(s_n)}{2} \quad (40)$$

上式中， P 代表某一参数， p_n 代表轨迹中第 n 个点， s_n 代表第 n 条连线，轨迹的起始点和终结点的运动学参数记为 0。当我们计算得到速度后，即可以利用同样的方法计算得到加速度。我们对 X 方向位置、Y 方向位置、压力、方向角、高度角、自转角都求其一阶和二阶运动参数。

对 X 方向位置、Y 方向位置的速度和加速度组成的速度和加速度矢量求模，还能得到轨迹点上的速率和加速率，他们都是标量。

综上所述，我们一共求得包括行为参数和运动学参数在内的，共 23 维运动参数。为了表示方便，我们将所有的参数用符号表示，如表 6 所示。表中，上标 x 或 y 表示 X 或者 Y 方向， mod 表示求矢量的模，下标 $1st$ 和 $2nd$ 表示一阶和二阶运动参数，所有运动参数求解前都需要进行重采样，* 表示该参数在进行重采样时使用 SER 算法，其余的使用 TER 算法。

图 40 给出了 9 项典型的运动参数在一个绘图任务上的可视化表示，图中表示的运动参数分别为 (a) UMO；(b) 标量曲率，点越粗表示曲率越大；(c) 压力，颜色越深、点越粗表示压力越大；(d) 方位角和高度角，蓝色细线的方向表示方位角，长度表示高度角；(e) 自转角，红色表示顺时针，蓝色表示逆时针方向；(f) 速度；(g) 加速度；(h) 压力速度，红色代表压力增大，蓝色代表减小；(k) 自转角速度。

表 6 所有运动参数和他们的符号

运动参数	符号	运动参数	符号	运动参数	符号
X 方向位置	Pos^x	加速率	Pos_{2nd}^{mod}	方位角加速度	Azi_{2nd}

Y 方向位置	Pos^y	X 方向加速度	Pos_{2nd}^x	高度角	Alt
轨迹偏离度	UMO	Y 方向加速度	Pos_{2nd}^y	高度角速度	Alt_{1st}
标量曲率*	Cur^{mod}	压力	Pre	高度角加速度	Alt_{2nd}
矢量曲率*	Cur	压力速度	Pre_{1st}	自转角	Rot
速率	Pos_{1st}^{mod}	压力加速度	Pre_{2nd}	自转角速度	Rot_{1st}
X 方向速度	Pos_{1st}^x	方位角	Azi	自转角加速度	Rot_{2nd}
Y 方向速度	Pos_{1st}^y	方位角速度	Azi_{1st}		




图 40 一个绘图任务中运动参数的可视化表示

5.4.2 特征提取方法

本文中用到的特征提取方法包括统计方法、信号处理方法和信息熵方法。统计方法包括求和 (Sum)、均值 (Mean)、最大值 (Max)、最小值 (Min)、四分位数 (Q1, Q2 和 Q3)、标准差 STD。信号处理方法包括时域方法和频域方法。在时域中, 我们利用了三个信号处理方法: 零点穿越次数 (number of times traveling through zero, NTZ)、零点穿越频率 (rate of traveling through zero, RTZ)、均方根 (root mean square, RMS), 其中 RMS 的计算公式如下:

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N s_i^2} \quad (41)$$

其中， N 为信号的长度， s_i 为信号序列中第 i 个信号值。一般来说，**RMS** 反映了一个信号的平均强度，它与信号的幅值有关。

在频域中，我们利用了主频率（main frequency, **MF**）、主频率能量（energy of main frequency, **EMF**）和主频率能量占比（energy ratio, **ER**）。这三个频域特征的计算，依赖于快速傅里叶变换（fast Fourier transform, **FFT**）算法[62]。假设采样频率是 F_s ，采样点的数量是 N ，那么 **FFT** 的运算结果是 N 个复数，任意一个复数与一个频率相关。更具体地，第 i 个复数与频率 f 的关系是：

$$f = (i-1) \times F_s / N \quad (42)$$

然后，频率 f 上的幅值能够通过下式计算：

$$\begin{aligned} A_f &= 2 |z_f| / N \\ &= 2 \sqrt{a_f^2 + b_f^2} / N \end{aligned} \quad (43)$$

其中， $z_f = a_f + b_f i$ 是与频率 f 有关的那个复数。接着，我们便能通过幅值的平方求得频率 f 上的能量：

$$E_f = A_f^2 \quad (44)$$

然后，**EMF** 则能够从所有频域上能量的最大值找到，相应地，**MF** 则为这个具有最大能量的频域的频率，**ER** 则是 **MF** 与所有频域能量合的比值。

我们还利用了两个信息熵来提取用户特征，其中包括香浓熵（Shannon entropy）和瑞利熵（Rényi entropy）。一个随机信号 X 的香浓熵定义如下[63]：

$$H(X) = - \sum_{x \in X} p(x) \log_2 p(x) \quad (45)$$

其中， $p(x)$ 是值 x 的概率密度函数，我们利用 **MLE** 对它进行估计：

$$p(x) = \frac{\sum_{i=1}^N I(x_i = x)}{N} \quad (46)$$

其中 I 是指示函数，因此， $p(x)$ 反映了样本 x 在总体中出现的概率。

瑞利熵是香浓熵的拓展形式，它的定义如下：

$$H_r(X) = \frac{1}{1-r} \log\left(\sum_{x \in X} p^r(x)\right) \quad (47)$$

其中 $r \geq 0$ 是瑞利熵的阶，香浓熵实际上是 $r = 1$ 的情况， $r = 2$ 的情况即为通常称呼的瑞利熵。

本文利用到的 8 个统计方法，更适合处理不包含时序信息的标量参数，例如曲率，而挑选的 6 个信号处理方法和 2 个信息熵，则更适合处理那些包含时序信息且为矢量的参数，例如 X 方向方向速度。对于那些包含时序信息且为标量的参数，则二者都可以使用。

5.4.3 特征提取策略

本文中的运动参数是用户绘图任务基础的行为和运动描述，它们是“点”一级的运动信息，接下来，我们利用统计、信息处理和信息熵的特征提取方法，对于每一个子轨迹，提取“轨迹”一级的运动信息，即轨迹级特征 (trajectory level feature)，最后，我们在对整图的所有子轨迹进行统计分析，提取“图形”一级的运动信息，即图形级特征 (graph level feature)，如图 41 所示。

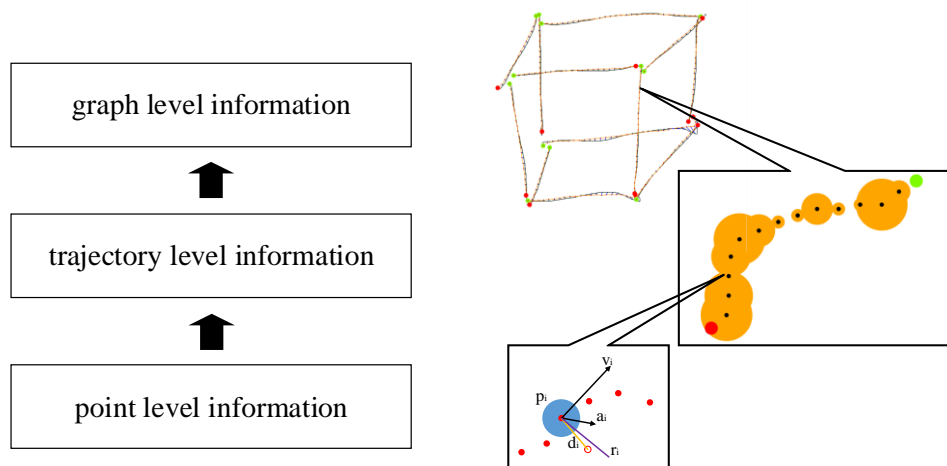


图 41 点、轨迹、图形级运动信息的关系

为了实现上面的特征提取策略，我们将上一节提到的 16 个特征提取方法分成三个

“方法组” (method group, MG), 使它们适用于处理不同种类型的数据, 如表 7 所示。MG1 包括所有 8 个统计方法, 用于提取数据中的总体统计属性, 他们在多数情况下适合于处理标量数据, 例如标量曲率, 而不适合处理带有时序信息的矢量数据。MG2 包括 8 个信号处理和熵方法和一个统计方法 STD, 他们在多数情况下适合处理带有时序信息的矢量数据, 例如 X 方向速度。具有时序信息的标量则可以使用两个方法组同时进行处理。MG3 包括 4 个最简单常用的统计方法, 用于从整图数据和特征中提取统计属性。

表 7 所有特征提取方法和方法组划分

方法组	方法	说明
MG1	Sum, Mean, Max, Min, Q1, Q2, Q3, STD	包括所有 8 个统计方法
MG2	NTZ, RTZ, RMS, MF, EMF, ER, H1, H2, STD	包括 8 个信号处理和熵方法, 统计方法 STD 也包括在内
MG3	Sum, Mean, Max, Min	包括 4 个最简单的统计方法

利用上述的三个特征提取方法组, 下面, 我们将利用四个步骤从绘图任务中提取用户特征, 如图 42 所示:

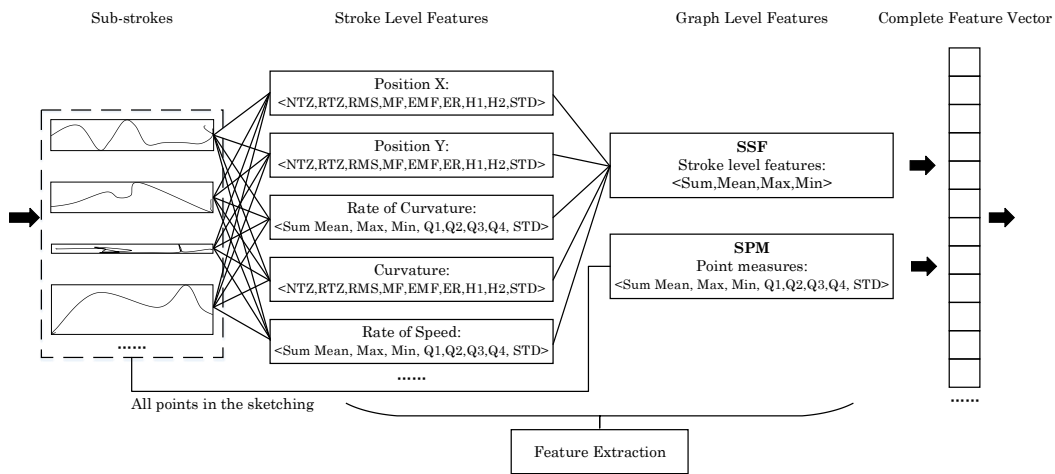


图 42 从绘图任务中提取用户特征的流程

- (1) 对绘图任务的原始轨迹利用通用轨迹切分算法进行处理, 得到一个子轨迹集。
- (2) 对于任意一段子轨迹, 计算轨迹上所有点的行为参数和运动参数。
- (3) 利用 MG1 和 MG2 从轨迹的行为参数和运动参数中提取轨迹级特征。
- (4) 提取整个绘图任务的两类图形级特征 (graph level feature): 所有绘图点运动参数的统计属性, 以及所有子轨迹特征的统计属性。对于第一类, 我们利用 MG1 从所有绘图点的运动参数中提取特征, 我们简称为 SPM (statistical properties on all sampling point

measures); 对于第二类, 我们利用 MG3 从所有子轨迹特征中提取特征, 它们是“特征的特征”, 我们简称为 SSF (statistical properties on all stroke level features)。

例如, 考虑一个绘图任务中, 子轨迹集上的 X 方向位置参数。首先, 对于整图中的所有点的 X 方向位置, 我们用 MG1 提取 8 个 SPM。然后, X 方向位置是一个时序矢量, 我们首先利用 MG2 在子轨迹集中的每条子轨迹上获得 9 个轨迹级特征, 然后我们用 MG3 计算对于这 9 个轨迹级特征, 计算整个轨迹集的图形级特征, 从而产生 $4 \times 9 = 36$ 个 SSF。在 X 方向位置上总生成特征数为 $8 + 36 = 44$ 维图形级特征。这意味着, 我们将从每一个运动参数中, 利用这一策略提取大量的图形级特征。但是正如前面所述, 特征提取策略中的第三步, MG1 和 MG2 的使用, 必须考虑运动参数的类型, 本文中对于不同运动参数, 制定了与其匹配的方法组, 我们将所有匹配的方法组和计算得出的特征数在表 8 中给出。

表 8 运动参数、匹配的方法组以及计算得出的特征数

运动参数	计算轨迹级特征的方法组	计算图形级特征的方法组和特征数			
		SPM		SSF	
Pos^x	MG2			MG3	36
Pos^y	MG2			MG3	36
UMO	MG1	MG1	8	MG3	32
Cur^{mod}	MG1	MG1	8	MG3	32
Cur	MG2			MG3	36
Pos_{1st}^{mod}	MG1	MG1	8	MG3	32
Pos_{1st}^x	MG2			MG3	36
Pos_{1st}^y	MG2			MG3	36
Pos_{2nd}^{mod}	MG1	MG1	8	MG3	32
Pos_{2nd}^x	MG2			MG3	36
Pos_{2nd}^y	MG2			MG3	36
Pre	MG1	MG1	8	MG3	32
	MG2				36
Pre_{1st}	MG2			MG3	36
Pre_{2nd}	MG2			MG3	36
Azi	MG1	MG1	8	MG3	32

	MG2				36
Azi_{1st}	MG2			MG3	36
Azi_{2nd}	MG2			MG3	36
Alt	MG1	MG1	8	MG3	32
	MG2				36
Alt_{1st}	MG2			MG3	36
Alt_{2nd}	MG2			MG3	36
Rot	MG1	MG1	8	MG3	32
	MG2				36
Rot_{1st}	MG2			MG3	36
Rot_{2nd}	MG2			MG3	36
小计		$8 \times 8 = 64$		$32 \times 8 + 36 \times 19 = 940$	
总计	$64 + 940 = 1004$				

正如上表中显示的那样，我们首先根据不同的运动参数，从子轨迹中提取了轨迹级特征，然后从这些轨迹级特征中提取图形级特征共 $32 \times 8 + 36 \times 19 = 940$ 项 SSF，再由所有点集直接计算统计属性，提取图形级特征 $8 \times 8 = 64$ 个，共组成 $64 + 940 = 1004$ 维特征。只要能够提供相应的运动参数，这些特征能够在任何触控设备中使用，并且与具体的绘图任务无关，具有很强的通用性。

5.4.4 特征命名规则

为了给每一个用户特征进行唯一标识，我们给出一套形式化的特征表示方式：

我们用下面的表达式表示轨迹级特征：

$$F_{str}(A)_M \quad (48)$$

其中， A 表示指定的特征提取方法，它可以是 16 种方法中的任意一个， M 表示指定的运动参数。符号 $traj$ 是 trajectory 的缩写，表示轨迹的意思。例如， $F_{str}(Sum)_{Pos_{1st}^{mod}}$ 代表以下特征：利用统计方法 Sum 从 Pos_{1st}^{mod} （速率）中提取的轨迹特征，即一个轨迹中所有点速度的合。

进一步地，我们利用以下表达式表示图形级特征 SSF：

$$F_{SSF}(B, F_{str}(A)_M) \quad (49)$$

其中， B 表示指定的特征提取方法， $F_{str}(A)_M$ 表示轨迹特征。例如， $F_{SSF}(Mean, F_{str}(MF)_{Azi_{2nd}})$ 代表以下特征：利用统计方法 $Mean$ 从轨迹级特征 $F_{str}(MF)_{Azi_{2nd}}$ 中提取的特征， $F_{str}(MF)_{Azi_{2nd}}$ 代表一个轨迹中方位角加速度的主频率，则整个特征的意义是整个绘图任务中，所有轨迹的方位角加速度的主频率的均值。

最后，图形级特征 SPM 表示为：

$$F_{SPM}(C)_M \quad (50)$$

它与轨迹级特征类似， C 表示指定的特征提取方法， M 表示指定的运动参数。但是其计算方式不一样， SPM 特征是从整个图形的所有点中提取统计属性。例如 $F_{SPM}(Max)_{UMO}$ 表示整个绘图运动中，所有点的 UMO 的最大值。

5.5 本章小结

本章展开了触控交互运动用户特征提取方法的研究，我们先分析了轨迹任务的全局特征和局部特征两大类，我们指出局部特征的优势在于与任务无关，几乎在任何具有轨迹任务的交互场景下都可以应用，为此，我们希望面向基于轨迹任务的触控交互应用，基于轨迹任务局部特征的分析，找到一种任务无关的用户特征提取方法。

绘图任务由轨迹任务组成，相对轨迹任务，是一种更贴近应用场景能够获取更多用户信息的任务，我们首先展开了对绘图任务的分析，将其在两个维度的绘图自由度上进行了划分，得出要做到任务无关，必须基于子轨迹集进行特征提取的结论。

然后，为了从绘图任务中得到子轨迹集，我们给出了轨迹数据处理算法和通用轨迹切分算法，其中后者实现了利用轨迹局部几何极值和时空信息的一般绘图任务子轨迹切分功能，为下一步的轨迹级和图形级特征提取做好准备。

运动参数是用户绘图任务基础的行为和运动描述，它们是“点”一级的运动信息，我们利用统计、信息处理和信息熵的特征提取方法，对于每一个子轨迹，提取轨迹级特征，最后，我们在对整图的所有子轨迹进行统计分析，提取图形级特征，最终实现了任务无关的用户特征提取，最后，为了通过本方法得出的大量特征的唯一标识，我们还给出了一个特征命名规则，为之后应用场景中的特征分析做好准备。

本文提出的这组特征能够适用于任意绘图任务，以子轨迹作为分析单元，从触控交互运动中提取了大量有价值的用户特征，是识轨迹距离[54][55][56]、时间表现[56][57]、

以及广泛用于手势识别和草图理解的 Rubine 特征集[59]等特征集的有效补充，能更好的体现轨迹的局部运动细节，能够更好地对用户行为做出评价。我们将在第 6 章中，给出一个利用本特征集进行用户手功能评价的应用，对本特征集的可用性进行验证。

第6章 触控交互运动模型应用研究

6.1 引言

理论模型如果不能应用则失去了它应有的作用，只有对人机交互研究有所帮助或者是对界面设计有所指导的模型才有实际意义。在本章中，我们将尝试把我们的模型直接应用到实际交互场景中，用本文的模型为现实的交互应用进行用户表现预测，为交互辅助技术进行定量化参数设定，证明本文模型的泛化性和有效性。

基于 Ternary-Gaussian 模型的拓展，我们首先给出一个模型辅助的错误率预测和目标选择技术应用，并将其在一个包含大量移动选择的计算机游戏中进行验证。在下文中我们将看到，相比已有的 Comet 和 Ghost 等移动目标选择技术，我们的技术不改变原有的用户界面也不需要额外的用户操作，且具有更强的通用性，能够直接运用于一般的实际交互场景中，对包含动态内容的用户界面设计提供参考。

笔交互作为一项成熟的触控交互技术，具有交互效率高、认知负荷低等特点。运笔状态和图形绘制结果可有效反应神经系统疾病患者在运动以及认知功能上异常的信息。我们将笔交互技术应用于神经系统疾病的辅助诊断上面，将本文提出的基于绘图任务的交互运动用户特征，作为疾病诊断的关键特征嵌入系统，实现在通用的笔交互场景中，对神经系统疾病患者的手部运动功能进行评价。

6.2 模型辅助的错误率预测和目标选择技术应用

某个任务行为的成功率，是计算机游戏中的一个重要评价指标，它能够在游戏设计阶段为设计者提供重要参考，也能在游戏维护阶段提供数据平衡依据，目标选择是游戏中大量存在的一类任务，我们将基于 Ternary-Gaussian 模型给出目标选择的错误率预测模型，并在实际游戏当中进行验证，旨在对未来的游戏设计和数据平衡给出建议和指导。

既然目标选择是游戏中大量存在的一类任务，如果我们能够利用技术手段提升这类任务的用户表现，就能极大地改进游戏的用户体验，然而目前已有的移动目标选择技术大多数需要对界面进行更改或者额外的用户操作，这不利于保持计算机游戏的可玩性和趣味性，因此，我们将基于 Ternary-Gaussian 模型给出一项隐式的目标选择技术，辅助玩家对游戏中大量存在的移动目标进行选择，并对游戏中的用户表现进行验证，旨在对未来的计算机游戏和其它场景下的目标选择技术提供参考。

6.2.1 Error-Model: 移动目标错误率预测模型

目标获取任务中，错误率被定义为所有目标获取尝试中的失败的比例。对于基础的目标获取技术，当用户获取目标的落点落在了目标的范围之外，则认为尝试失败。既然 Ternary-Gaussian 模型能够为我们预测目标获取的落点分布情况，我们则可能从中推导出这些落点落到目标外或者目标内部的次数，从而达到预测错误率的目的，下面我们给出错误率预测的方法。

利用 Ternary-Gaussian 模型，知道了目标的大小，速度和移动方向，我们首先计算出该任务下用于描述落点分布的参数 μ 和 σ ，然后，我们则可以通过高斯累积分布函数计算错误率。

对于给定的一个高斯随机变量 X ，高斯累积函数给出高斯概率密度（probability density function, PDF）函数从负无穷到 x 之间区域的面积。对于指定的高斯随机变量参数 μ 和 σ ，高斯累积分布函数可以写成：

$$P(x) = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^x \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right) \quad (51)$$

通过以下的式子，我们能够计算出随机变量 X 落入范围 $(-\infty, x)$ 的概率：

$$P(x) = \frac{1}{2} \left[1 + \operatorname{erf}\left(\frac{x-\mu}{\sigma\sqrt{2}}\right) \right] \quad (52)$$

式中， $\operatorname{erf}(x)$ 是高斯误差函数：

$$\operatorname{erf}(x) = \frac{2}{\sqrt{\pi}} \int_0^x e^{-t^2} dt \quad (53)$$

通过这个定义，错误率则为随机变量 X 落入范围 (x_0, x_1) 的概率，这里的 x_0 和 x_1 分别代表目标的左右边界：

$$\begin{aligned} ER(\mu, \sigma) &= 1 - [P(x_1) - P(x_0)] \\ &= 1 - \frac{1}{2} \left[\operatorname{erf}\left(\frac{x_1-\mu}{\sigma\sqrt{2}}\right) - \operatorname{erf}\left(\frac{x_0-\mu}{\sigma\sqrt{2}}\right) \right] \end{aligned} \quad (54)$$

式中， μ 和 σ 即为 Ternary-Gaussian 模型预测的落点分布参数。图 43 显示了这个公式的计算过程。




图 43 错误率通过对分布在目标外的部分进行积分计算

我们将公式(54)称为基于 Ternary-Gaussian 模型构建的移动目标获取错误模型——Error-Model。接下来，我们将用第 3 章中的实验数据对 Error-Model 的拟合程度和泛化性能进行验证。

6.2.2 模型验证

Error-Model 在我们的数据集中获得了很高的拟合度，其中在移动方向为远离的数据集中取得了 $R^2=0.974$ 的拟合度，在移动方向为靠近的数据集中取得了和 $R^2=0.966$ 的拟合度。图 44 显示了远离和靠近两个方向下，模型对 16 种 $V*W$ 组合的预测和实际错误率。




图 44 远离方向和靠近方向 16 种情况下的实际错误率和预测错误率

我们进一步地，利用重复二折交叉验证 (two-fold cross-validation) 去检验 Error-Model 错误率预测的泛化性能，在每次验证中，模型参数 (μ 和 σ) 使用 6 名被试的数据进行估计，然后利用剩下的 6 名被试数据进行验证。我们利用预测值和测试值之间的平均绝对误差 (mean absolute error, MAE) 来衡量这个测试的好坏。经过了 100 次重复，我们在远离方向数据集上获得了 4.7% (SD=1.6) 平均绝对误差，在靠近方向数据集上获得了 5.8% (SD=2.3) 的平均绝对误差。

6.2.3 BayesPointer: 隐式移动目标获取技术

在这一节中,我们将演示如何基于 Ternary-Gaussian 模型对移动目标获取的意图目标进行预测,我们将首先介绍意图目标预测方法,然后再给出对该方法的实验验证。

BayesPointer 是一个基于 Ternary-Gaussian 模型的“隐式”移动目标获取技术。在这里,“隐式”的意义是,这项技术不会对当前的用户界面进行额外修改,也不会要求用户进行额外操作,我们的技术在不被用户察觉的情况下发挥作用。BayesPointer 的核心思想是:将 Ternary-Gaussian 模型嵌入贝叶斯(Bayes)决策原则中,从而为我们决定用户最有可能选择的目标,我们称之为意图目标(intended target),而非传统技术中利用目标的实际大小。这个判定策略可以形式化的描述如下:

用 $T=\{t_1, t_2, \dots, t_n\}$ 代表 n 个用户界面中的移动目标(也可以有静止目标,即速度为零),当界面中出现了任意一个用户产生的落点 s ,则 t ($t \in T$) 是意图目标的条件概率可以表示为 $P(t|s)$ 。要找到意图目标,则等同于找到 t^* 使得 $P(t|s)$ 最大。利用贝叶斯公式,我们能够如下计算 $P(t|s)$:

$$P(t|s) = \frac{P(s|t)P(t)}{P(s)} \quad (55)$$

其中, $P(t)$ 为在没有观察到 s 之前,用户选择目标 t 的先验概率,我们将其设为 $1/N$ (N 为界面中的目标数目),意味着所有目标被选择的概率相同。 $P(s|t)$ 是贝叶斯公式中的似然函数(likelihood function),它给出一个选择事件 s 属于一个目标 t 的概率。似然函数的这个定义,在我们的场景中,与落点分布的概率密度函数函数相同。最后, $P(s)$ 是归一化常数,用于保证总概率合为 1。

由此,意图目标 t^* 能够通过以下函数找到:

$$t^* = \arg \max_t (P(t|s)) = \arg \max_t (P(s|t)) \quad (56)$$

即求出落点 s 属于任意一个目标的概率,然后找到这其中最大的概率的那个目标。注意到,每一个目标 t 都具有指定的 V 和 W ,因此,我们可以通过 Ternary-Gaussian 模型计算得出它的落点分布参数 μ 和 σ ,这样我们就有:

$$\begin{aligned}
 t^* &= \arg \max_t (P(x | \mu_t, \sigma_t)) \\
 &= \arg \max_t \left(\frac{1}{\sqrt{2\sigma_t^2\pi}} e^{-\frac{(x-\mu_t)^2}{2\sigma_t^2}} \right)
 \end{aligned} \tag{57}$$

公式(57)即 BayesPointer 的决定意图目标的策略。

图 45 显示了这个策略在实践中的工作过程。两个具有不同移动速度和大小的目标出现在界面中，我们不妨假设蓝色的目标为用户想要选择的目标（意图目标），因为感知运动系统的延迟，用户最终选择目标的落点出现在蓝色目标的后面，恰好落到了灰色目标内部。在这个例子中，传统的目标获取技术会错误地将灰色目标作为用户的意图目标，而 BayesPointer 通过比较两个目标的似然函数（落点分布概率），发现蓝色目标的概率更大，而最终正确地将蓝色目标作为这任务的意图目标。

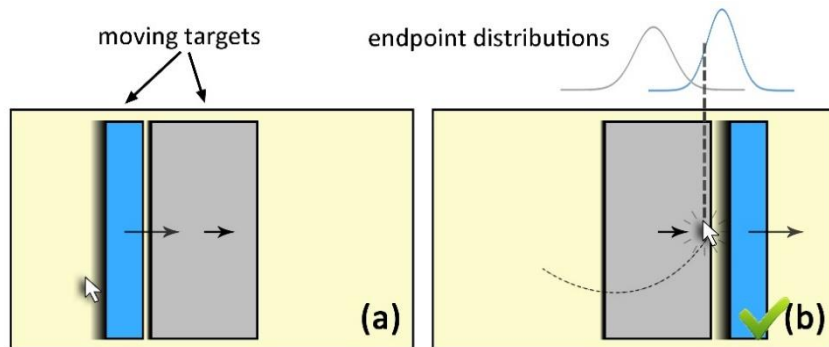


图 45 BayesPointer 的工作过程。(a) 界面中的两个具有不同速度和大小的移动目标；(b) 蓝色的目标被 BayesPointer 确定为意图目标

6.2.4 “Don't Touch The White Tile” 触屏游戏实例

我们利用一个名为“Don't Touch The White Tile（中文名：别碰白块）”的触屏游戏，如图 46（左 1）所示，对 Error-Model 和 BayesPointer 经行验证。正如这个游戏的名字一样，游戏规则是：玩家需要尽可能多地点击黑色方块且避开空白方块。在该游戏中，存在大量的朝着固定方向移动的目标，非常贴近我们的模型。然而，游戏中也存在许多构建情况下不存在的额外干扰，例如除了要求用户点中移动的目标，还要求他们有很好的节奏感和视觉搜索能力。在接下来的章节中，我们将会展示我们的模型在这种复杂的真实场景中依然表现出色。




图 46 “Don’ t Touch The White Tile” 游戏的原始界面和本文中实现的三个变种

游戏实现

在原本游戏中，黑块与白块会随机拼成马赛克的样子，从屏幕的上端出现并往下降落，玩家需要在黑块落到屏幕底端之前将其点中，如果没有点中黑块或者错误地点到了白块，则游戏结束。在玩的过程中，方块的移动速度会逐渐加快，直到玩家最终出现了错误。游戏的最终得分为玩家点中的黑块个数。

我们在原游戏规则的基础上做了一些修改，如图 46（左 3）所示。在我们修改的版本中，玩家拥有 5 次错误的机会，这样能够使我们在每次试验中采集到更多的落点。我们还给位于最底端的目标行添加了一个紫色的加粗提示框，使得玩家更容易找到要点击的目标。为了增加游戏难度，一些绿色的干扰块会从底部随机移动到屏幕上方。另外，为了测试我们模型在不同目标大小下的表现，我们还给游戏设计了三个级别，对应三种不同的方块高度。理论上，高度越小的方块越难选中。

为了体现 BayesPointer 相对传统目标选择的优势，我们设计了两个版本的游戏分别对应两种选择技术：Basic 和 BayesPointer。前者为传统的 PC 或智能手机操作系统中的选择技术，以此作为对比的基准，后者则是本文的隐式目标选择技术，它通过贝叶斯法则来决定是否选中目标。

注意到游戏包含二维的运动目标。因此我们需要将我们的选择技术对游戏通过以下步骤进行适配：1) 在水平方向上，采用传统的目标选择方案，如果想要选中目标落点必须落在目标的水平边界内。2) 在竖直方向上，我们使用 BayesPointer 技术来选择目标。

被试和实验设置：

我们招募了 12 名被试，6 男 6 女，平均年龄 24.5 岁，所有被试都是右手惯用手并且有两年以上使用触屏设备的经验。

实验在一台 Windows Surface Pro 5 平板电脑上进行，计算机处理器为 Intel Core i7，具有一个 12.3 寸（292mm * 201mm）LED 显示器，分辨率为 1920 * 1080，使用的指点设备为触摸屏，分辨率为 267ppi。

实验设计:

我们使用被试内的实验设计将 Basic 和 BayesPointer 这两种选择技术进行对比。游戏中使用的方块宽度都是 230 像素,高度(H)为 135、90、45 像素,分别对应游戏级别 1 到游戏级别 3。每个游戏级别下方块的移动速度(V)都是均匀增加,最高的速度分别为 1312, 875, 437px/sec。在戏级别 2 和 3 中,我们设置了较低的速度来降低游戏难度。

十二名参与者都需要玩完两种选择技术下的 3 个游戏级别,总共有 $3 \times 2 \times 12 = 72$ 次试验,在每次试验和游戏级别间隙允许被试休息。每次试验大约需要 2 分钟,每名参与者总共需要 12 分钟左右完成测试。在正式测试前,被试可以进行练习。两种技术的测试顺序因素在被试间进行了平衡抵消。

实验流程:

在每一次试验中,被试点击开始按钮后开始游戏。一旦游戏开始,被试需要持续进行游戏直到错误了 5 次后游戏才结束。所有点击事件,不管有没有点中黑块,落点都会被记录。如果被试点中目标块,目标块会变成灰色,否则,被点到的方块就会出现大约 0.5sec 的红色闪烁作为错误提醒。

评价参数:

在实验中,我们收集了所有速度和方块高度组合的错误率,以及每个游戏级别的总得分。我们还要求参与者在实验后填写对每种选择技术的主观感受问卷,主观感受问卷包含两个问题,评分从 1 分最低到 7 分最高,这两个问题是:

- (1) 请你对两项技术的喜欢程度进行打分,1 分为最低,7 分为最高。
- (2) 请你对两项技术的准确程度进行打分,1 分为最低,7 分为最高。

我们还问了被试一个主观问题:你是否察觉到两个版本的游戏,用户界面有什么不同?

6.2.5 实验结果与讨论

错误率预测

我们用 Basic 技术的点击数据来测试错误率预测的效果。通过观察,我们发现参与者一般都会在速度增加到第 5 挡后开始出现大量失败。因此,我们只用前 4 个档位的速度范围内的数据,这些数据占总数据的 85.4%。

在 12 中速度 V 和高度 H 组合的条件下错误率预测的 MAE 是 2.7%,表明我们模型在所有种情况下,平均高估或者低估了 2.7%的目标选择错误率。图 47 展示了每种情况下经验和预测的错误率。

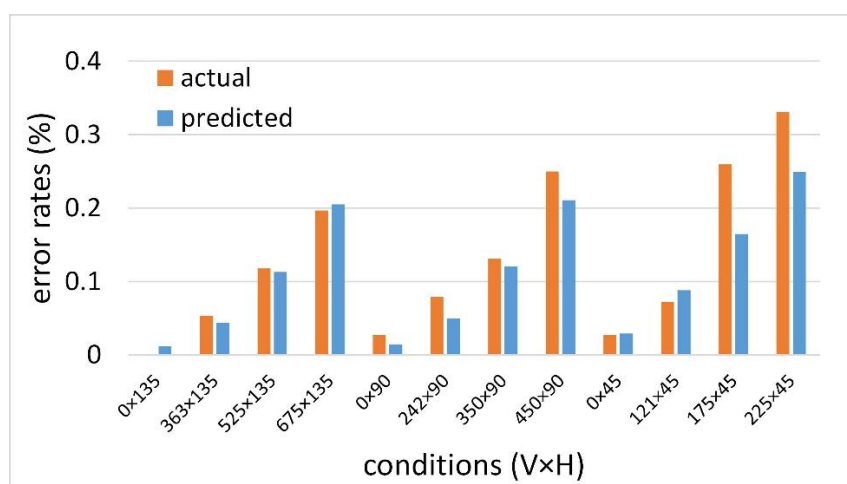


图 47 游戏中 12 中情况的经验和预测错误率

如图 47 所示，当速度增加或者目标大小减小时。错误率会随之增加。我们的模型已经可以很好地预测这种趋势，但是当速度很快时，尤其是游戏级别 3 的后两种情况，我们对错误率的预测值偏低。我们认为这可能是因为我们的模型没有考虑节奏感和视觉搜索能力对错误率的影响，当目标更小、速度更快时这种影响使得任务变得更加困难。

辅助目标选择技术

重复测量方差分析显示，两种选择技术在最终得分上具有显著性差异($F_{1,11}=22.215$, $p=.0006$)，其中使用 BayesPointer 选择技术在 3 个游戏级别中的平均得分分别为 34.94, 31.63 和 25.69，相比 Basic 技术提高了 33.6%，43.0%和 39.9%，如图 48 (a) 所示。

统计分析显示，两种技术在错误率上也具有显著性差异($F_{1,11}=36.819$, $p<.0001$)。BayesPointer 选择技术表现出更低的错误率，其中游戏级别 1 的错误率最低，为 0.153，接着是级别 2, 0.159 和级别 3, 0.181，比起 Basic 技术低了 25.7%，24.8%和 23.4%，如图 48 (b) 所示。

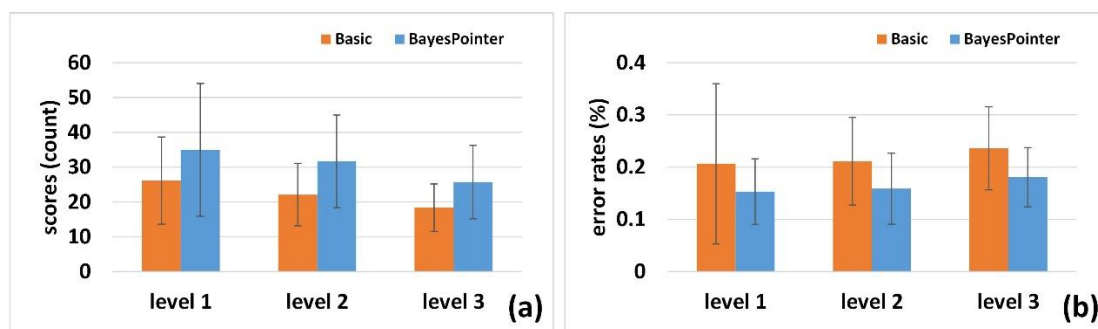


图 48 两种选择技术在 3 个游戏级别中的得分和错误率情况对比

主观评价

我们的使用主观问卷结果显示，比起 Basic 技术 ($M=4.08$, $SD=0.66$) 被试们更喜欢

使用 BayesPointer 选择技术($M=5.16, SD=0.93$), 并且他们认为使用 BayesPointer($M=5.33, SD=1.17$) 选择技术与 Basic ($M=4.16, SD=0.89$) 选择技术相比有更高的准确率。

同时, 对于问题“你是否察觉到两个版本的游戏, 用户界面有什么不同?” 的回答中, 用户大多没有察觉到两项技术之间的差异, 下面是一些典型回答:

被试 6: “这两个不是一样的吗?”

被试 8: “没有感觉到它们有什么差别, 但似乎红色的点的更准一些。”(红色即为我们的 BayesPointer 技术⁴)

实验证明, 基于本文运动模型的目标选择错误率预测和辅助选择技术, 都能够很好的在实际交互应用中发挥作用, 在实际场景中, 可能需要考虑更多的外部因素, 例如本游戏对用户的节奏感和视觉搜索能力要求, 但我们的模型仍表现优异, 这证明了模型的鲁棒性。

在第3章分析结论的基础上, 结合本章的实际应用情况和实验结果的分析, 我们进一步对移动目标选择的准确性给出以下结论:

1. 目标和光标的初始距离对目标获取的难易程度几乎不产生影响。
2. 目标移动的速度越大、目标大小越小则目标获取的难度越大, 用户越容易出现错误。
3. 目标移动的速度越大则目标获取落点越倾向于向目标后方偏移, 因此移动目标选择技术应更注重解决落点滞后的问题。
4. 增大目标的大小, 会降低目标速度对落点分布产生的影响, 因此设计更大的尺寸, 是应对快速移动目标的有效方案。

我们希望这个应用研究工作和实验结果, 能在未来的游戏设计和数据平衡给出建议和指导, 能对未来的计算机游戏和其它场景下的目标选择技术提供参考。

6.3 基于轨迹特征的用户运动功能评价

神经系统疾病为发生在中枢神经系统, 周围神经系统, 植物神经系统的由细菌感染或遗传等多种病因引起的, 其症状通常表现为运动障碍及记忆认知障碍等多方面问题, 例如运动能力下降, 语言能力下降, 记忆力减弱以及记忆缺失等。常见的神经系统疾病

⁴ 我们在游戏界面旁边用红色数字 1 标记 BayesPointer, 用蓝色数字 2 标记 Basic, 好让用户记住他们使用的技术, 但用户并不知道它们使用的技术名称或者任何技术细节。

如帕金森症[69], 阿尔茨海默病[70], 和脑小血管病[71], 其临床表现表现为静止性震颤、肌强直和平衡障碍等运动功能障碍, 以及记忆丧失、语言和定向力障碍等认知功能障碍。

由于环境的变化以及人口的老龄化, 罹患神经系统疾病的患者数量越来越多, 这些疾病在很大程度上影响着患者及其家庭的生活质量[72][73][74]。由于此类疾病发病机制复杂, 检查步骤繁琐, 医疗费用昂贵, 因此尚未获得经济有效的日常监测方案。随着计算机科学技术的不断发展以及人类对于生理信息与疾病之间关系认知的逐渐深入, 使得通过计算机获取并分析生理信息, 检测神经系统功能疾病变得可行, 与人工诊断相比, 通过分析生理信息的计算机辅助诊断系统可以降低主观因素对判决结果的影响[91][92], 有利于疾病的诊断以及早期预警, 对于提升神经系统疾病患者的存活率有着重要的意义[75][76]。

笔交互作为一项成熟的触控交互技术, 具有交互效率高、认知负荷低等特点。运笔状态和图形绘制结果可有效反应神经系统疾病患者在运动以及认知功能上异常的信息。如 Atila 等人从数字笔的笔迹、压力和倾角上提取多项特征, 并将其组合进行模型训练进行帕金森疾病诊断取得了很好的效果[77]。Esther 等人利用数字笔提取的信息研究帕金森疾病, 找到了用于定量评估运动徐缓、字体过小和手部震颤症状的特征[78]。绘图理解作为检测神经系统疾病的重要手段[79], Randall 等利用算法对画钟测试(clock drawing test, CDT)进行理解[80], 得到钟面、数字等组成部分和几何参数用于神经系统疾病诊断, 连线测试(trail making test, TMT) 进一步将完成时间、错误次数、连线的笔直程度这些特征与时序相关的运笔特征结合[81]评估了其对于不同神经系统疾病的诊断效果。

但是, 上述检测方法都是针对特定的任务, 必须根据指定绘图任务修改特征提取方法, 并且, 上述这些测试的执行, 必须在医护人员的监督之下进行, 无法实现日常生活中对病人的长期实时监测。因此, 考虑将本文提出的任务无关的用户特征, 对神经系统疾病患者的手部运动功能进行评价。

6.3.1 面向神经系统疾病诊断的绘图任务

我们挑选了 5 个用于神经系统疾病临床诊断的绘图任务, 包括 TMT、CDT、阿基米德螺旋测试 (Archimedes spiral test, AST)、图形复制测试 (graph copying test, GCT)、文字书写测试 (handwriting test, HWT)。其中前三个测试是经典的用于神经系统疾病临床诊断的绘图任务, 后两个是从两个广泛使用的神经心理学测试简易智能状态检查 (mini-mental state exam, MMSE) 和蒙特利尔认知检查 (Montreal cognitive assessment, MoCA) 中挑选出来绘图任务。我们挑选这些绘图任务的原因是用户对它们最为熟悉, 且最容易集成于笔交互场景中, 例如绘图课或者日常签字。下面我们对每个任务进行介绍。

TMT: 连线测试是一种应用广泛的神经心理学测验, 其要求受试者将无序分散的数

字 1→25 按从小到大的顺序依次连接, 如所示, 用户在进行正式测试前, 将在测试人员的指导下首先完成一个与正式测试类似的简化测试(连接数字 1→8)[82][83], 如图 49 (a) 所示。

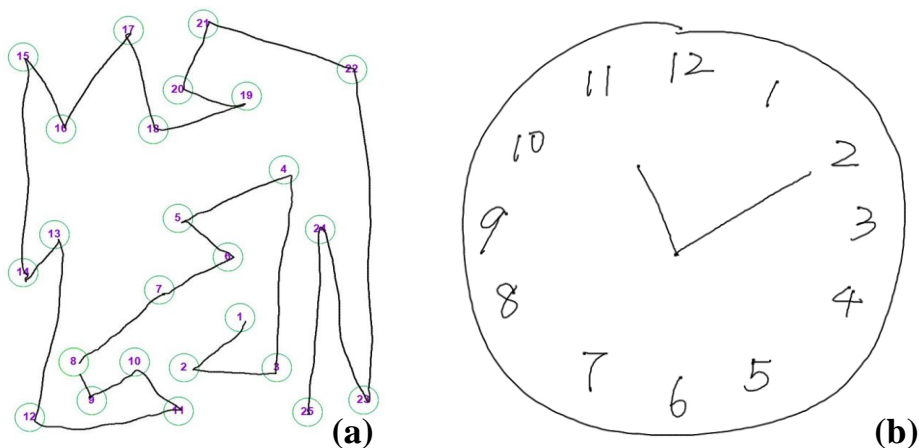


图 49 连线测试和画钟测试

CDT: 画钟测试是一个评估患者的心理状态的有效方式, 它近 30 年来已被广泛用于神经系统疾病的临床诊断, 它提供了一个直观的认知功能的视觉表示, 并且操作简单易于实施[84]。被测者需要清晰地画出一个具有钟面、数字和指针的钟表, 并且将钟表的指针指向 11 点 10 分钟, 除了口头讲述之外, 这个测试没有其它提示, 被测者需要根据自己的认识完成钟表的绘制, 如图 49 (b) 所示。

AST: 阿基米德螺旋测试, 或螺旋线测试, 被广泛用于评价患有震颤和其它运动障碍症状患者的健康状况[85][86]。在该项测试中, 被测者需要在一个标准的螺旋线轨迹之上进行描绘, 描绘过程中, 他们被要求尽量保持连贯不要抬笔, 如图 50 (a) 所示。

GCT: 在图形复制测试中, 被测者需要对照给出的线框形式的立方体, 在空白处重新绘制一个, 如图 50 (b) 所示。。

HWT: 在文字书写测试中, 被测者需要写下一句完整的句子, 如图 50 (c) 所示。

特征提取：利用第 5 章介绍的任务无关的绘图特征提取方法，从所有运动参数中提取绘图特征。

分类诊断：在得到的总数据特征集上，运用特征选择算法筛选出与疾病最为相关的特征，利用它们训练一个分类模型，将其用于疾病的自动诊断。

系统硬件由一支触控笔、一个可显示绘图板和一台普通桌面计算机组成，如。触控笔为一支长 14.4cm，直径 1cm，重 19g，采样率为 100Hz 的 Wacom 绘图笔；可显示绘图板型号为 Wacom Cintiq DTK-1300，屏幕大小为 13.3 英寸，分辨率为 1280×800 像素，硬件示意如图 52 (a) 所示⁵。选择这套设备的主要原因是，除了基础笔迹外，它还支持压感和笔身姿态等数据获取，使得我们能够获取更全面的手部运动特征；配套的计算机上安装有上述软件系统，如图 53 所示，软件系统由 C#编程语言开发，运行于 .NET Framework 4.0 框架下，使用 SQLite 和文件系统进行用户数据存储和管理。系统采用统一的数据结构存储笔迹数据，一个笔迹数据为一个有序的采样点集，采样点的数据结构为：

$$data = \{timestamp, x, y, pressure, azimuth, altitude, rotation, pen_event\} \quad (58)$$

其中 *timestamp* 为时间戳，*pen_event* 为标记笔状态的枚举类型，它用于标记“落笔” (PEN_DOWN)、“绘图” (PEN_MOVE)、“抬笔” (PEN_UP) 等事件。




图 52 (a) 本套系统的硬件示意图⁵ (b) 实际使用情况

⁵ <http://www.wacom.com/en-us/products/pen-displays>



图 53 本套系统的配套软件界面

本系统是一个长期部署项目，从项目开始的软件编写、数据采集，到模型训练、临床辅助诊断，经历了大约 3 年时间，在项目的前中期，我们的工作主要围绕数据采集，病理特征选择和分析，以及模型训练和验证展开，下面我们将对这三方面工作分别进行介绍。

6.3.3 数据采集

被测人群：

用户数据采集地点为北京市顺义区各乡镇以及北京协和医院，共 490 例用户数据。其中 107 人（平均年龄 65.51 岁，男性 71 人）在北京协和医院经过系列严格筛查，临床诊断患有神经系统疾病，包括 21 例帕金森，73 例脑小血管病变，13 例运动障碍，其中运动障碍为神经系统异常引起的运动障碍，但无法判定具体的疾病类型；为保证训练数据的均衡，从招募的 379 个普通测试用户中选出与每一个病人样本性别、年龄相匹配的 107 人（平均年龄 63.98 岁，男性 71 人）作为对照组，样本挑选步骤如下：

对于每一个疾病用户样本，（1）从健康测试人群中挑选性别匹配的用户数据集合；（2）从步骤一的数据集合中选择与病人年龄 N 相同的用户数据；（3）如果步骤二没有与年龄 N 完全匹配的用户数据，逐步扩展年龄搜索范围到 $N \pm i$ ($i=1,2,3\dots$) 直到获取至少包含一个用户数据；（4）从步骤三得到的子集里，找年龄最为接近的正常人作为对照样本，如果年龄相同则随机选择一个。

数据采集过程是北京市协和医院医学流调和门诊检查的医疗测试程序之一，所有的数据标签都经过医院认证。单因素方差分析显示，患者组和对照组之间在年龄 ($F_{1,213}=1.062, p=0.304$)、MoCA 评分 ($F_{1,213}=1.883, p=0.171$) 上没有显著差异。患者组和对照组的性别分布、平均年龄和 MoCA 评分如图 54 所示。

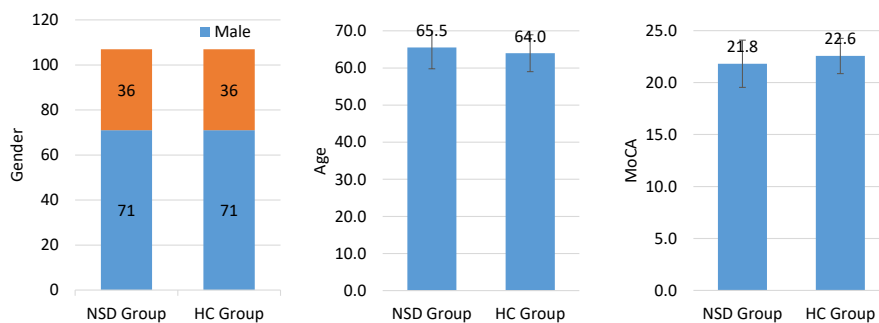


图 54 患者组和对照组的性别分布、平均年龄和 MoCA 评分

测试过程:

每一位被测者单独坐在一个的房间的一张桌子前面，桌面上放置着本系统的绘图板和配套的触控笔，在检查过程中，一位神经科医生坐在桌子的另一侧，引导被测者进行测试。5 个测试各自的流程如下：

TMT: 医生首先为被测者演示一个包含 8 个点的连线测试示例，然后，令被测者尝试完成这个示例测试，接着，他们被要求完成包含 25 个点的完整连线测试。如果被测者在连线过程中连接了错误的点并忽视了这个错误继续连线，则医生会给出提醒。在其他情况下，例如被测者找不到正确点，则不进行任何提示。每位被试有 150 秒的时间完成连线，如果在规定时间内没有完成，则剩下的点都被视为错误。

如果被试画线正确，绘图板上将实时地显示画线笔迹，如果连线过程出现错误，例如连接到错误的点，则从最后一个正确连线点到当前绘制的轨迹会被擦除，并且错误的点变成红色进行提示，这些点的初始状态是蓝色的，正确连接后变成绿色。这个改进有助于帮助被测者更好的完成连线测试。除了连线测试对，以下的所有测试都保持原始的纸-笔方式，无论画得如何都将显示绘制的轨迹。

AST: 被测者被要求在一个红色的螺旋线模板之上进行描绘，他们被要求绘制的笔迹与红色模板尽可能的贴近，尽量保持连贯不要抬笔。

GCT: 被测者被要求对照着一个线框形式的立方体进行复制，立方体显示在绘图屏的左上方，被测者被要求在绘图屏下方的空白处进行绘制。

CDT: 被测者被要求在绘图屏空白处绘制一个钟表，并将时间指向 11 点 10 分，钟表必须有圆形的钟面、分针和时针以及表示时间的数字，不能用电子时钟来代替。

HWT: 被测者被要求写下一句具有意义的完整句子，句子应当具备简单的主谓宾结构，或者是日常使用的短语，每个句子应当包含 5 中国字以上。

我们将 5 个测试得到的所有样本数据进行组合，得到一个包含 1070 个样本（每个测

试 214 个样本) 的总体数据集, 我们称之为 ODS (overall dataset), 此外, 每个测试各自的样本数据集个包含 214 个样本, 按照各测试的缩写命名, 即 TMT、AST、CDT、GCT 和 HWT。在之后的分析中, 我们将对这 6 个数据集分别进行分析。

6.3.4 病理特征选择和分析

得到了所有被测者数据后, 我们利用第 5 章介绍的任务无关的绘图任务特征提取方法, 处理所有的 5 个测试数据, 在每项测试的每个样本中均得到 1004 维特征, 下面, 我们将对这个特征集进行特征选择, 找出面向神经系统疾病手部运动功能评价中最为重要的特征集, 并对这些特征进行分析。我们对包括 ODS 和 5 个测试各自的数据集进行特征分析, 通过 ODS 的特征分析我们可以得到在不同任务中均表现出色的特征集, 通过对 5 个测试数据集的特征分析我们可以得到适合不同自由度和不同场景下的特征集。

病理特征选择

为排除样本的空值、异常特征值和特征取值范围对后续处理的影响, 我们对数据特征进行了清洗和归一化, 具体步骤如下: (1) 剔除缺失 30% 以上特征数据的样本; (2) 在非空数据里面, 计算每一维特征的均值和标准差; (3) 使用每一维的特征均值替换样本数据对应维度的空值特征; (4) 使用每一维特征均值替换各维在三倍标准差以外的特征数据; (5) 将针对病理特性提取的特征向量利用最大最小值将数据范围归一化到[0,1]。

由于样本数量较少, 而样本特征维度会增加运算的复杂度并引起分类模型的过拟合, 因此为了增加运算速度并且不丢失最主要的特征信息, 我们对 1004 维特征中进行特征选择。本文选择基于相关性的特征选择方法 (Correlatioin-based feature selection, CFS) [88] 搜索最优子集, CFS 是根据属性子集中每一个特征的预测能力以及特征之间的相关性进行评估, 选择与预测结果高度相关而特征子集间相关性较低的特征集合作为最终的特征选择结果。利用与病理诊断结果最相关而特征间冗余性最低的特征向量进行病理模型训练, 可降低冗余特征或噪声对结果的影响, 算法利用了以下启发式指标, 引导最优子集的搜索过程:

$$M_s = \frac{\overline{kr_{cf}}}{\sqrt{k + k(k-1)r_{ff}}} \quad (59)$$

其中 M_s 是包含 k 个特征的子集 S 优良度, $\overline{r_{cf}}$ ($f \in S$) 是平均的特征-类别相关系数, $\overline{r_{ff}}$ 是平均特征-特征内部相关系数。我们用 Best First 搜索策略在特征集内进行搜索, 在初始状态最优子集是一个空集, 然后不断地从全集内往最优子集添加单个特征, 如果加入后优良度有所提升则保留该特征, 否则不保留。

特征选择算法在 ODS 中挑选了 27 个最优特征子集，在 AST、TMT、GCT、CDT 和 HWT 中分别挑选了 30、51、38、37 和 56 个特征。我们用三种不同的方法将这些特征进行分类，从而分析绘图任务中不同类别特征的表现。(1) 根据运动参数类别进行划分为位置、UMO、曲率、速度、加速度、压力、方位角、高度角和自转角 9 个类别的相关特征。(2) 根据轨迹级特征提取方法组划分为 MG1 (统计) 和 MG2 (信号与熵) 两个类别的相关特征。(3) 根据图形级特征类别划分为 SPM (点参数的统计属性) 和 SSF (轨迹级特征的统计属性) 两个类别的相关特征。图 55 显示了所有挑选出来的特征分布情况。注意到图 55 (b) 包含 5 个任务的特征，所以概率总值为 500%。

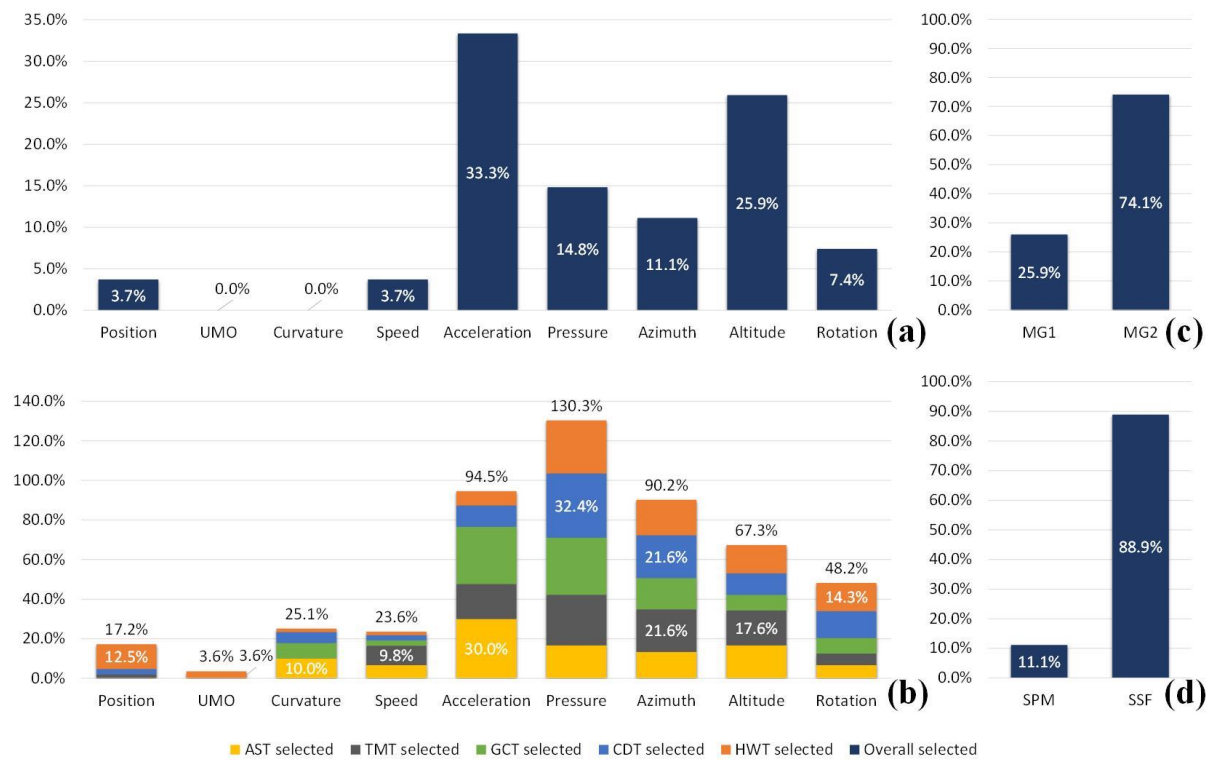


图 55 选择的特征在三个不同类别特征分类中的分布

图 55 (a) 显示，在 ODS 中，加速度和高度角相关的特征提供了最多的特征，在最优特征集中分别占据的比例为 33% 和 25.9%，同时压力、方位角和自转角也提供了许多关键特征，其比例为 14.8%、11.1% 和 7.4%，特征选择算法没有从 UMO 和曲率相关特征中挑选特征。这表明在所有绘图任务中，加速度和高度角相关的特征表现出很强的通用性，适合用于不同自由度绘图任务的疾病分类。图 55 (b) 显示，从特征提取方法的角度看，信号和熵方法 MG2 比统计方法 MG1 为我们产生了更多有价值的特征，其占比分别为 74.1% 和 25.9%。这表明包含时间序列信息的特征比单纯的统计属性更有效。图 55 (d) 显示，从两类图形级特征来看，SSF 比 SPM 提供了更多有价值的特征，其占比分

别为 88.9%和 11.1%，这表明从整图的所有采样点的参数中提取统计特征的效果，远不及利用子轨迹作为基本单元的特征提取有效。图 55 (c) 显示，在 5 个测试各自的特征集中，压力、加速度和方位角占据的特征比例最高，分别为 130.3%、94.5%和 90.2%，其中压力和方位角在任务特异情况下比 ODS 中占据了更多关键特征，说明这两类特征在具体任务中得到的区分度更好，然而在通用绘图任务中则不那么有效。

病理特征分析

为了显示我们的特征对疾病诊断的效果，我们为所有选择的特征计算它们与类别之间的信息增益 (information gain, IG) [89]和斯皮尔曼相关系数 (Spearman's correlation coefficients)。其中，对于一个特征 X 而言，信息增益是系统没加入它和加入它时信息量发生的变化，这个信息量，或者是不确定性通常用熵进行定义：

$$gain = H(Y) - H(Y | X) \quad (60)$$

其中， $H(Y)$ 是类别 Y 的熵，而 $H(Y/X)$ 为加入特征 X 后的熵。

在接下来的章节中，我们将利用 5.5.4 章节中的特征命名代表每一个特征，特征的上标表示它属于 ODS 还是 5 个测试的各自特征集。

表 9 给出了 ODS 信息增益最高的 5 个特征以及 5 个测试数据集中最大信息增益的特征。同时，其斯皮尔曼相关系数绝对值 $|\rho|$ 和该特征在一个 1R 分类器中的表现也在该表中给出。1R 分类器是一个只利用一个特征和一条规则对类别进行分类的分类器。

表 9 ODS 和 5 个测试数据集中具有最大信息增益的特征列表

数据集	特征	IG	$ \rho $	1R[%]
ODS	$F_{SSF}^{ALL} (Mean, F_{str} (MF)_{Azi_{2nd}})$	0.195	0.480	69.1
	$F_{SSF}^{ALL} (Mean, F_{str} (MF)_{Alt_{2nd}})$	0.147	0.415	66.4
	$F_{SSF}^{ALL} (Max, F_{str} (MF)_{Azi_{2nd}})$	0.115	0.380	64.9
	$F_{SSF}^{ALL} (Max, F_{str} (RTZ)_{Pre_{2nd}})$	0.100	0.357	61.2
	$F_{SPM}^{ALL} (Min)_{Pre}$	0.098	0.334	58.7
AST	$F_{FSF}^{AST} (Max, F_{str} (MF)_{Pos_{2nd}^x})$	0.260	0.559	68.6

TMT	$F_{FSF}^{TMT} (Mean, F_{str}(MF)_{Alt_{2nd}})$	0.335	0.501	63.3
GCT	$F_{FSF}^{GCT} (Max, F_{str}(RTZ)_{Pre_{2nd}})$	0.179	0.274	59.9
CDT	$F_{FSF}^{CDT} (Mean, F_{str}(MF)_{Azi_{2nd}})$	0.365	0.610	74.7
HWT	$F_{FSF}^{HWT} (Mean, F_{str}(MF)_{Azi_{2nd}})$	0.448	0.673	80.0

从表 9 中可以看到, MF 和 RTZ 特征提取方法是出现得最多的轨迹级特征提取方法, 在 ODS 中, 前 5 个最高信息增益的特征中包含 4 个 SSF 图形级特征和 1 个 SPM 特征, 在 5 个测试数据集中, 排名最高的都是 SSF 图形级特征。方位角、加速度、高度角加速度、和压力加速度是产生这 10 个特征中最重要的运动参数。在这 10 个特征中, $F_{SSF}^{ALL} (Mean, F_{str}(MF)_{Azi_{2nd}})$ 在 ODS 中获得了 0.195 的信息增益和 69.1% 的分类准确率; $F_{FSF}^{AST} (Max, F_{str}(MF)_{Pos_{2nd}})$ 在 AST 中获得了 0.260 的信息增益和 68.6% 的分类准确率; $F_{FSF}^{TMT} (Mean, F_{str}(MF)_{Alt_{2nd}})$ 在 TMT 中获得了 0.335 的信息增益和 63.3% 的分类准确率; $F_{FSF}^{GCT} (Max, F_{str}(RTZ)_{Pre_{2nd}})$ 在 GCT 中获得了 0.179 的信息增益和 59.9% 的分类准确率; $F_{FSF}^{CDT} (Mean, F_{str}(MF)_{Azi_{2nd}})$ 在 CDT 中获得了 0.365 的信息增益和 74.7% 的分类准确率; $F_{FSF}^{HWT} (Mean, F_{str}(MF)_{Azi_{2nd}})$ 在 HWT 中获得了 0.448 的信息增益和 80.0% 的分类准确率。

这些结果表明, 观察到这些特征在很大程度上降低了类别的不确定性, 它能为疾病分类提供有效的识别能力。从表 9 我们也可以推断, 我们的特征很可能在任务特异的情况下有更好的表现, 特征在除了 GCT 的四个测试中都比 ODS 表现出更高的区分度。注意, 1R 分类器并没有考虑特征之间的任何可能的组合, 组合特征的分类结果将在之后的章节中给出。

图 56 给出上述 10 个特征的密度分布函数。图中, 横轴为归一化后特征的取值, 纵轴为特征在不同取值范围内的概率, 红色表示神经系统疾病患者该特征的密度分布, 蓝色表示正常人的密度分布。我们可以看到, 大部分的特征在患者组和对照组中都显示了明显的区分度。图 56 显示了患者组中, 高度角加速度、方位角加速度、压力加速度和 X 方向加速度的 MF 和 RTZ 特征值比对照组更高, 这表明在绘图运动中的这些参数上, 神经系统疾病患者具有更高的变化频率。这是因为患者的运动功能障碍导致了其运笔稳定性下降。这个结果同样体现了信号处理方法在对这类用户特征时具有很强的描述能力。

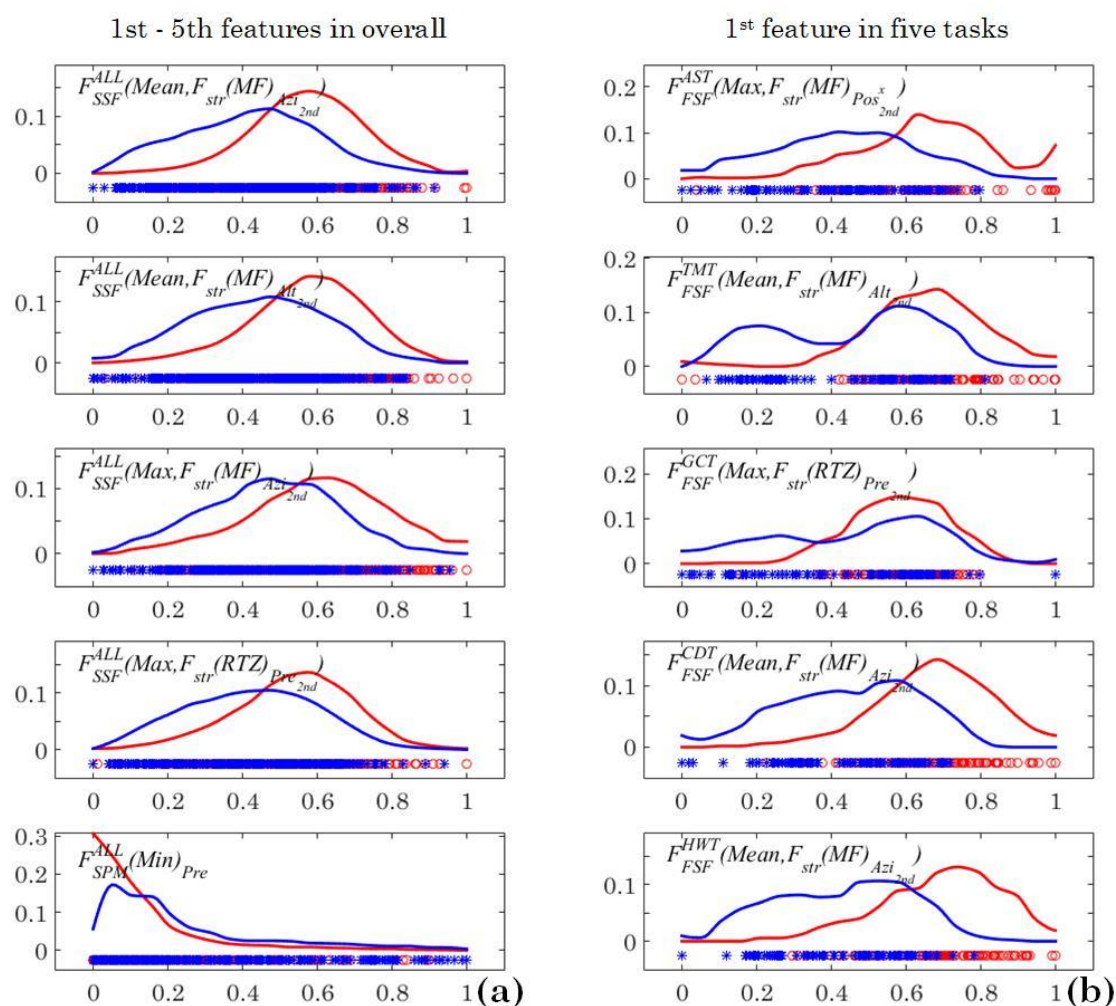


图 56 10 个特征的概率密度函数

图 56 (a) 中的最后一幅图显示，患者组相比对照组显示出更低的运笔压力。根据我们在这项研究中的观察，当被测者面对一个较难的绘图任务时，他们倾向于对笔施加更大的压力以确保绘图准确性和稳定性。然而神经系统疾病患者因为其手部控制能力不足，他们将无法控制手部施加这种额外的压力，导致了压力特征值相对对照组更低的现象。

除了上面的 10 个特征之外，我们也对选择出来的其它特征进行了研究，我们将研究得到的发现进行如下总结：

第一，患者组的绘图数据具有更高的变化频率是一个普遍现象，我们在每项测试中的许多与速度、加速度、笔身姿态等参数相关的特征中都发现了这一现象，图 57 显示了三个这种情况的典型特征。其中，我们发现患者在 TMT 的 Y 方向加速度中表现出更高的主频率，在 CDT 的 Y 方向速度中表现出更高的零点穿越次数，在 HWT 的压力加速度中表现出更高的零点穿越率。




图 57 三个变化率相关特征的概率密度函数

第二，患者组在绘图过程中倾向于使用更低压力这一现象在各项测试中均存在，如图 58 所示，我们发现患者在 AST 和 CDT 的轨迹最小压力和 CDT 的整图最小压力都比对照组更低。




图 58 三个压力相关特征的概率密度函数

第三，患者组大部分的信息熵特征表现出比对照组更高的不确定性，但是也存在一些反例。如图 59 所示，患者组在 CDT 的 X 方向位置信息熵比对照组更大，患者组在 HWT 的 Y 方向位置信息熵比对照组更大，但是，患者组在 AST 的 X 方向速度信息熵比对照组更小。更高的信息熵表示信号具有更多的不确定性和随机性，这符合神经系统疾病病理现象，因为更低的手部运动控制能力会导致绘制轨迹出现更高的随机性。但是在一些高阶运动参数，例如速度和加速度等，这个现象变得复杂而难以解释，但是考虑到这些特征提供的高区分度，我们选择将它们保留在特征集中。




图 59 三个信息熵相关特征的概率密度函数

第四，患者组在许多运动参数的主频率能量占比更低。如图 60 所示，患者组在 TMT 的 X 方向加速度，GCT 的 X 方向速度，HWT 的高度角上显示出更低的主频率能量占比。导致这一现象的原因可能是患者组的信号变异性更大，信号的频率分布于一个更广

的频域范围，导致较低主频率能量占比。




图 60 三个主频率能量相关特征的概率密度函数

6.3.5 诊断模型训练

为了检验我们的用户特征对神经系统疾病的诊断效果，我们利用 ODS 以及 5 个测试各自的数据集对 3 个分类器进行训练并对分类效果进行了评估。这三个分类器包括决策树 (C4.5)、朴素贝叶斯 (native Bayesian, NB) 和一个线性支持向量机 (support vector machine, SVM)。所有的测试均通过十折交叉验证进行评估，并且给出分类器的平均准确率以及患者组的查准率、查全率、F 值和接受者操作特征曲线 (Receiver operating characteristic, ROC) 下的面积 (are under ROC curve, AUC)。

分类准确率代表在整个数据集中正确分类的类别 (患者组和对照组) 的百分比。患者组的查准率代表被预测为患者的患者样本的百分比。患者组的召回率是患者组中正确预测为患者的百分比。F 值是查全率和查准率的几何平均，是一个权衡两个者的指标。ROC 曲线，是一个有二分类器系统的性能为纵坐标，判别阈值为横坐标的曲线图。ROC 曲线面积也是衡量分类器总体性能的指标，其取值范围为[0,1]，1 表示一个完美的分类性能。

为了获得更高的分类性能，对于 6 个数据集，我们计算了三个分类器在特征数量递增时的分类准确度，如图 61 所示。这些特征递增的顺序信息增量的大小决定。在所有的数据集中，最高的分类性能均在增加特征数量的过程中达到。较大的特征集能提供更多的相关信息来识别类别，从图中可以看出，使用更大数量的特征时可以获得更高的准确度。另一方面，当使用相当少的特征数 (例如 10 个特征) 时，分类器的性能只会轻微降低，这表明我们的模型在低维数据集中也能表现得很好。

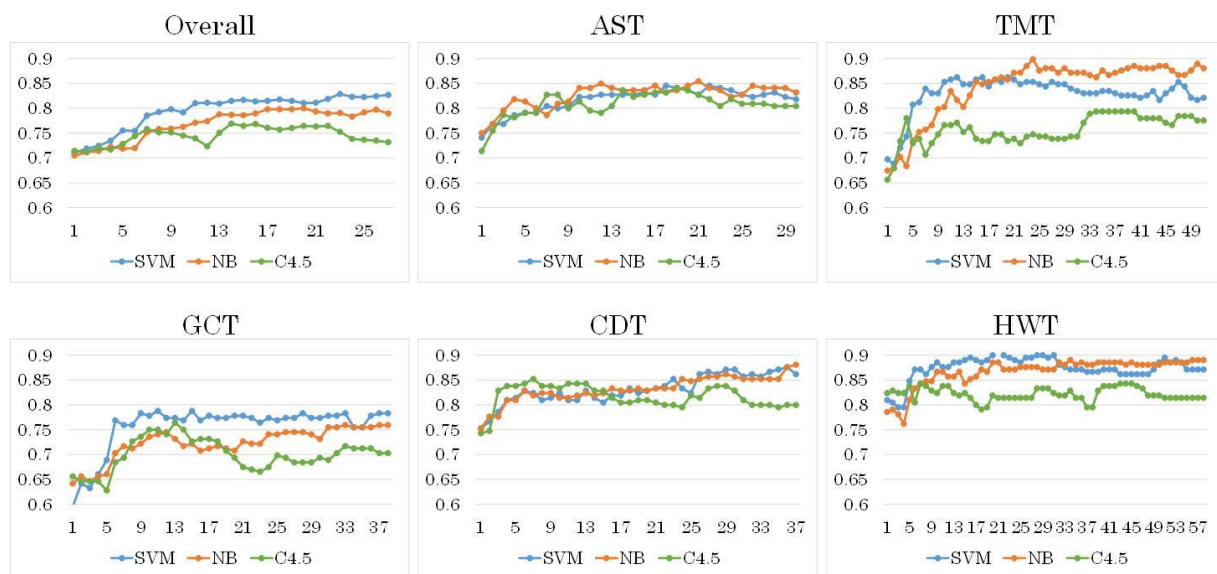


图 61 三个分类器在特征数量递增时的分类准确度

C4.5、NB 和 SVM 三个分类器在 ODS 中的最佳性能在特征数为 14、20、23 时达到，在 AST 中为 19、21、18，在 TMT 中为 34、24、12，在 GCT 中为 13、33、11，在 CDT 中为 7、37、36，在 HWT 中为 7、34、21。因为一些单个特征在 CDT 和 HWT 中表现出非常强的分类能力，因此在这两个测试中，最佳的分类性能很早就达到了。所有这个过程的最佳分类表现被记为最终表现记录在表 10 中。

表 10 三个分类器在所有数据集中的最佳分类性能

数据集	分类器	准确率	查准率	查全率	F 值	AUC
ODS	C4.5	76.92	0.791	0.731	0.760	0.795
	NB	80.00	0.778	0.839	0.808	0.870
	SVM	82.90	0.828	0.830	0.829	0.896
AST	C4.5	84.09	0.844	0.836	0.840	0.834
	NB	85.45	0.836	0.882	0.858	0.921
	SVM	84.55	0.858	0.827	0.843	0.921
TMT	C4.5	79.36	0.814	0.761	0.787	0.816
	NB	89.91	0.892	0.908	0.900	0.943
	SVM	86.24	0.856	0.872	0.864	0.930
GCT	C4.5	76.42	0.730	0.840	0.781	0.773
	NB	75.94	0.752	0.774	0.763	0.840
	SVM	78.77	0.775	0.811	0.793	0.859
CDT	C4.5	85.24	0.911	0.781	0.841	0.828
	NB	88.10	0.885	0.876	0.880	0.937
	SVM	87.62	0.891	0.857	0.874	0.938

HWT	C4.5	84.29	0.840	0.848	0.844	0.864
	NB	89.05	0.894	0.886	0.890	0.940
	SVM	90.48	0.929	0.876	0.902	0.949

从表 10 中我们可以看到,除了 GCT 之外,分类器在任务特异情况下较整体数据集有更好的表现。整个数据集的最佳性能是由 SVM 分类器达到,为 82.90%,它同时达到了最佳的查准率 0.828, F 值 0.829 和 AUC 值 0.896,最好的召回率被 NB 获得,为 0.839。在 5 个任务特异的数据集中,三个分类器在 HWT 中均取得了最高的分类准确度,其中 SVM 最高,为 90.48%,这表明在这 5 个测试中, HWT 是用于识别神经系统疾病的最有效的测试。对于其他的 4 个测试, AST、TMT 和 CDT 也取得了相当的性能,最好的准确率分别为 85.45%、89.91% 和 88.10%。在所有的测试中, GCT 具有最低的分辨性能, 78.77%,但仍处于可以接受的范围。

为了进一步评估我们的方法的泛化能力和鲁棒性,我们将在 ODS 选出的 23 个特征和 SVM 分类器的内核作为本研究的一个通用模型,并且测试了这个模型在任意一个测试数据集中的表现,以验证它是否能够在任务无关的场景中同样表现出良好的分类性能。

从表 11 中可以看出,通用模型在 5 个测试中的分类准确度保持在一个较为稳定的水平,5 个测试的平均准确率为 83.15%, GCT 最低,为 82.33%, TMT 最高,为 83.89%。平均查准率为 0.831,通过任意一个绘图任务,被我们的模型归类为患者有 83% 以上的概率是正确的。平均查全率 0.832,这意味着我们的模型会将超过 83% 的患者正确地诊断为病人。通用模型在 F 值和 AUC 上也表现良好,在平均的 F 值和 AUC 分别为 0.832 和 0.898。虽然这个结果低于所有任务特异的情况(除了 GCT 以外),这种折衷仍然是可以接受的,因为这个通用模型可以作为运动功能评价相关笔交互应用的内置组件,且不需要额外的数据收集和训练过程。

表 11 通用模型在 5 个测试中的分类性能

数据集	准确率	查准率	查全率	F 值	AUC
AST	83.70	0.842	0.829	0.836	0.902
TMT	83.89	0.851	0.821	0.836	0.904
GCT	82.33	0.815	0.836	0.825	0.889
CDT	82.64	0.818	0.839	0.829	0.894
HWT	83.18	0.831	0.834	0.832	0.899
平均	83.15	0.831	0.832	0.832	0.898

本文构建的这个系统,是利用笔交互技术在一般绘图任务中实现自动识别神经系统疾病的的首个尝试。我们的工作给出了一个技术框架,一个鲁棒且准确的识别模型和大量的经验数据。将来,这个领域的研究人员和设计者可以根据我们的方法构建各种应用程序。例如,集成到家庭、工作场所或学校适用的设备中,我们可以为神经系统疾病的

预警构建无处不在的系统，当人们签收快递，写一封信或在黑板上画画时，这些系统便采集数据，我们的方法提供了在无监督的，任务无关的情况下，对神经系统疾病进行检测的可能。我们也可以在医院建立辅助诊断系统，例如标准的医疗检查或康复评估。在康复评估的情况下，我们的方法可以在无干扰的情况下定期对病人的健康状况进行更有效的检查，通过合理的系统设计，这项检查甚至有可能在病人写下他们想要吃的东西时就已经完成。

6.4 本章小结

在本章中，我们利用移动目标获取的落点分布模型和高斯累积分布函数推导出用户选择移动目标时的错误率模型，对选择准确性进行预测。利用落点分布模型辅助的意图预测规则，构建一个不对用户界面进行额外修改的目标获取技术，并将其应用于一个实际的游戏场景中，验证了本文运动模型的有效性。在第3章分析结论的基础上，结合本章的实际应用情况和实验结果的分析，我们进一步对移动目标选择的准确性给出以下结论：

1. 目标和光标的初始距离对目标获取的难易程度几乎不产生影响。
2. 目标移动的速度越大、目标大小越小则目标获取的难度越大，用户越容易出现错误。
3. 目标移动的速度越大则目标获取落点越倾向于向目标后方偏移，因此移动目标选择技术应更注重解决落点滞后的问题。
4. 增大目标的大小，会降低目标速度对落点分布产生的影响，因此设计更大的尺寸，是应对快速移动目标的有效方案。

将本文提出的任务无关的用户特征，对神经系统疾病患者的手部运动功能进行评价，实现了一个基于通用绘图任务的神经系统疾病日常监测和早期预警系统，对系统的分类模型进行了分析和验证，结果显示我们的模型能够对神经系统疾病进行准确预测，并发现了许多能够为神经系统疾病诊断提供启示的结果。这个系统是利用笔交互技术在一般绘图任务中实现自动识别神经系统疾病的的首个尝试，将来，这个领域的研究人员和设计者可以根据我们的方法，在家庭、学校、工作场所或医院中构建各种应用程序，实现真正有效的无处不在地疾病监测和辅助诊断。

第7章 总结与展望

7.1 论文工作总结

触控交互技术是图形用户界面和自然用户界面中应用最为广泛的人机交互技术，是当前人机交互学术界的研究热点，涌现了大量的触控交互技术，同时研究者们也对这些技术做了充分的用户研究，然而，我们在不停地开发新技术和获取新的实验数据时，总是缺少理论依据，Fitts' Law、Steering Law 等一些经典的人机交互理论模型在新的交互场景和任务中不再适用，或者需要研究人员根据具体的任务对它们进行修正。我们急需新的理论模型，能够适应新的触控交互任务和场景，能够让我们更好地理解影响用户表现和用户行为的内在机制，对交互结果做出精准预测，对交互中的用户行为做出定量描述。

经过文献调研我们发现，在现有的人机交互理论体系中，起码在以下三个方面存在空缺和不足：首先，现有的理论模型没有对移动目标获取的落点不确定性进行建模，无法有效地支撑包含移动目标的用户界面设计和研究；其次，现有理论模型多为针对交互运动结果的开环模型，缺乏交互运动的过程性描述，无法对连续交互空间内的用户行为进行预测和仿真；再次，现有的交互运动用户特征体系中，缺乏任务无关的定量化描述方法，无法有效地支持不同交互场景中的用户评价。

因此，在本文中，我们首先开展了运动目标获取的不确定性模型研究，得到了一个运动目标获取的落点分布描述模型，可以准确地对落点分布进行预测；其次，开展了静止和运动目标获取的最优反馈控制模型研究，构建了基于最优反馈控制的交互运动模型，实现了对一般目标获取任务的运动过程仿真；再次，开展了基于局部轨迹运动分析的用户特征研究，建立了一个任务无关的用户特征集，对现有用户评价体系进行了有效补充。本文还将上述三项研究成果应用于实际交互场景中，对触控交互目标获取的错误率进行了有效预测，得到了一项隐式的触控交互目标选择技术，提升了实际用户界面中的交互效率和用户体验，构建了一个基于触控绘图任务的用户运动功能评价系统，并在实际使用场景中对评价系统进行了验证。

论文的主要工作和总结如下：

1. 研究了触控交互运动的不确定性模型，基于“三高斯分布”假设，构建了移动目标获取的落点分布模型，通过实验对提出的落点分布假设和模型进行验证，并将该模型应用于触屏和笔交互设备上，对模型的适用性和泛化性进行了验证。

2. 研究了触控交互运动的反馈控制模型，将人机交互基本过程与最优反馈控制系统进行比对，并基于此完成包括静止和移动目标获取的交互运动最优反馈控制模型构建，设计了一个相似度评价指标和一个随机搜索算法对模型的关键参数进行优化，并设计实验对模型的用户行为仿真效果进行验证。
3. 研究了触控交互运动的用户特征提取方法，对轨迹任务与绘图任务用户特征与自由度进行了分析，构建了一个任务无关的轨迹切分算法，通过一组特征提取算法和特征提取策略，从轨迹局部运动参数中提取用户特征，实现了从通用绘图任务数据中提取用户特征的目的。
4. 将本文的运动模型应用于实际用户界面当中，对动态交互界面的目标选择错误率进行了准确预测，得到了一项隐式移动目标获取技术，有效提升了用户界面移动目标获取交互效率和用户体验。
5. 将本文的用户特征提取方法应用于医疗辅助诊断当中，构建了一个任务无关的神经系统疾病日常监测和早期预警系统，将其部署于多家大型三甲医院的神经科门诊，对神经科医生的临床诊断提供了帮助。

7.2 进一步工作的讨论

受论文篇幅所限，文本有很多问题都未能详细的展开，还有待于进一步的研究，具体如下：

1. 多模态自然人机交互是当前人机交互研究的热点，触控交互技术在许多场景中能够很好地与其它交互通道进行融合，在多通道融合交互场景下，运动模型将会发生怎样的变化？本文的模型是否还能适用？在下一步的工作中，将在这一类多模态融合的复杂交互场景中进行运动建模的研究。
2. 交互运动不确定性建模是一项新颖且非常有意义的工作，在虚拟现实、实物交互等未来的自然交互场景中将发挥重要作用，本文在运动目标不确定性建模方面进行了首次尝试，目前构建的模型是一个一维模型，在下一步的工作中，将对该模型进行二维和三维拓展，并在更多的应用场景下进行验证。
3. 基于绘图任务的神经系统疾病诊断系统已经在临床诊断中发挥了作用，如果能够将这套系统带到普通用户的日常生活中，利用画画、签名等日常动作获取数据，实现无处不在的运动功能或其它状态的监测，将会使其发挥更大的作用，在下一步的工作中，将对在系统的小型化和普世化上做出进一步改进。

参考文献

- [1] A. T. Welford. 1968. *Fundamentals of Skill*. Methuen.
- [2] Shumin Zhai, Jing Kong, Xiangshi Ren. 2004. Speed-accuracy tradeoff in Fitts' law tasks—on the equivalency of actual and nominal pointing precision. *International Journal of Human-Computer Studies*, 61(6), 823-856.
- [3] Niels Henze, Enrico Rukzio, Susanne Boll. 2012. Observational and experimental investigation of typing behaviour using virtual keyboards for mobile devices. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems (CHI '12)*, 2659-2668.
- [4] Xiaojun Bi and Shumin Zhai. 2013. Bayesian touch: a statistical criterion of target selection with finger touch. In *Proceedings of the 26th annual ACM symposium on User interface software and technology (UIST '13)*, 51-60.
- [5] Thomas T Hewett, Ronald M Baecker, Stuart K Card, Tom Carey, Jean B Gasen, Marilyn M Mantei, Gary Perlman, Gary W Strong, William Verplank. 1992. ACM SIGCHI Curricula for human-computer interaction. ACM.
- [6] Nikolai Tillmann, Michal Moskal, Jonathan De Halleux, Manuel Fahndrich. 2011. TouchDevelop: programming cloud-connected mobile devices via touchscreen. In *Proceedings of the 10th SIGPLAN symposium on New ideas, new paradigms, and reflections on programming and software*. (Onward! 2011, part of SIGPLAN '11), 49-60.
- [7] William Buxton, Ralph D Hill, Peter Rowley. Issues and techniques in touch-sensitive tablet input. 1985. In *Proceedings of the 12th annual conference on Computer graphics and interactive techniques*. (SIGGRAPH '85), 215-224.
- [8] Harold W Thimbleby. 1990. User Interface Design. ACM New York, NY, USA.
- [9] Paul M Fitts. 1954. The information capacity of the human motor system in controlling the amplitude of movement. *Journal of experimental psychology*, 47, 6 (Jun 1954), 381-391.
- [10] Stuart K Card, W K English, B J Burr. 1978. Evaluation of mouse, rate-controlled isometric joystick, step keys, and text keys for text selection on a CRT. *Human-computer interaction*, Morgan Kaufmann Publishers Inc. San Francisco, CA, USA, 386-392.
- [11] I. Scott MacKenzie. 1992. Fitts' law as a research and design tool in human-computer interaction. *Human-Computer Interaction*, 7, 1 (March 1992), 91-139.
- [12] Xiaojun Bi, Barton A Smith, Shumin Zhai. 2012. Multilingual Touchscreen Keyboard Design and Optimization. *Human-Computer Interaction*, 27(4), 352 - 382.
- [13] James R Lewis, Peter J Kennedy, Mary J Lalomia. 1999. Development of a Digram-Based Typing Key Layout for Single-Finger/Stylus Input. In *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*. 43(5), 415 - 419.

- [14] Shumin Zhai, Per Ola Kristensson. 2013. The word-gesture keyboard: reimagining keyboard interaction. *Communications of the ACM*. 55(9), 91-101.
- [15] Johnny Accot and Shumin Zhai. 1997. Beyond Fitts' law: models for trajectory-based HCI tasks. In *Proceedings of the ACM SIGCHI Conference on Human factors in computing systems* (CHI '97), 295-302.
- [16] A T Welford, A H Norris, N W Shock. 1969. Speed and accuracy of movement and their changes with age. *Acta Psychologica*. 30, 3-15.
- [17] Xiaojun Bi, Yang Li and Shumin Zhai. 2013. FFitts law: modeling finger touch with fitts' law. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems* (CHI '13), 1363-1372.
- [18] Crossman, E.R.F.W. 1957. The speed and accuracy of simple hand movements. In *The Nature and Acquisition of Industrial Skills*, E.R.F.W. Crossman and W.D. Seymour (eds). Report to the M.R.C. and D.S.I.R. Joint Committee on Individual Efficiency in Industry.
- [19] Steve J Young. 2010. Cognitive user interfaces. *IEEE Signal Processing Magazine*, IEEE, 27(3), 128-140.
- [20] Emanuel Todorov. 2005. Stochastic optimal control and estimation methods adapted to the noise characteristics of the sensorimotor system. *Neural Computation*. 17(5), 1084-1108.
- [21] Emanuel Todorov. 2004. Optimality principles in sensorimotor control. *Nature Neuroscience*, 7(9), 907-915.
- [22] C K Chow, D H Jacobson. 1971. Studies of human locomotion via optimal programming. *Mathematical Biosciences*, 10, 239-306.
- [23] H Hatze, J D Buys. 1977. Energy-optimal controls in the mammalian neuromuscular system. *Biological Cybernetics*, 27(1), 9-20.
- [24] W L Nelson. 1983. Physical principles for economies of skilled movements. *Biological Cybernetics*, 46, 135-147.
- [25] Tamar Flash, Neville Hogan. 1985. The coordination of arm movements: An experimentally confirmed mathematical model. *Journal of Neuroscience*, 5(7), 1688-1703.
- [26] Emanuel Todorov and Michael I. Jordan. 2002. Optimal feedback control as a theory of motor coordination. *Nature Neuroscience*. 5, 11 (November 2002), 1226-1235.
- [27] 王青, 陈宇, 张颖昕, 侯砚泽. 最优控制——理论、方法与应用. 高等教育出版社, 北京, 2011.
- [28] Richard J. Jagacinski, Daniel W. Repperger, Sharon L. Ward and Martin S. Moran. 1980. A test of Fitts' law with moving targets. *Human Factors: The Journal of the Human Factors and Ergonomics Society*, 22, 2 (April 1980), 225-233.
- [29] Thierry Bardini. 2000. Bootstrapping: Douglas Engelbart, Coevolution, and the Origins of Personal Computing. *Stanford: Stanford University Press*.
- [30] I Scott Mackenzie, William Buxton. 1992. Extending Fitts' law to two-dimensional tasks. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems* (CHI

- '92), 219-226.
- [31] Atsuo Murata, Hirokazu Iwase. 2001. Extending Fitts' law to a three-dimensional pointing task. *Human Movement Science*, 20(6), 791-805.
- [32] Michael McGuffin and Ravin Balakrishnan. 2002. Acquisition of expanding targets. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems (CHI '02)*, 57-64.
- [33] Robert Pastel. Measuring the difficulty of steering through corners. 2006. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems (CHI '06)*, 1087-1096.
- [34] Shota Yamanaka, Wolfgang Stuerzlinger, Homei Miyashita. Steering Through Sequential Linear Path Segments. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems (CHI '17)*, 232-243
- [35] Mathieu Nancel, Edward Lank. Modeling User Performance on Curved Constrained Paths. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems (CHI '17)*, 244-254.
- [36] Francesco Lacquaniti, Carlo Terzuolo, and Paolo Viviani. 1983. The law relating the kinematic and figural aspects of drawing movements. *Acta Psychologica*, 54, 115–130.
- [37] Jacob O. Wobbrock, Edward Cutrell, Susumu Harada and I. Scott MacKenzie. 2008. An error model for pointing based on Fitts' law. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems (CHI '08)*, 1613-1622.
- [38] Byungjoo Lee and Antti Oulasvirta. 2016. Modelling Error Rates in Temporal Pointing. In *Proceedings of the 2016 CHI Conference on Human Factors in Computing Systems (CHI '16)*, 1857-1868.
- [39] Tovi Grossman and Ravin Balakrishnan. 2005. The bubble cursor: enhancing target acquisition by dynamic resizing of the cursor's activation area. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems (CHI '05)*, 281-290.
- [40] Paul Kabbash and William Buxton. 1995. The “prince” technique: Fitts' law and selection using area cursors. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems (CHI '95)*, 273-279.
- [41] Tyler J. Gunn, Pourang Irani and John Anderson. 2009. An evaluation of techniques for selecting moving targets. In *CHI '09 Extended Abstracts on Human Factors in Computing Systems (CHI EA '09)*, 3329-3334.
- [42] Khalad Hasan, Tovi Grossman and Pourang Irani. 2011. Comet and target ghost: techniques for selecting moving targets. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems (CHI '11)*, 839-848.
- [43] James R. Tresilian. 2005. Hitting a moving target: Perception and action in the timing of rapid interceptions. *Perception & Psychophysics*, 67, 1 (January 2005), 129-149.
- [44] Michael Victor Ilich. 2009. *Moving target selection in interactive video*. Master's thesis, (December 2009) University of British Columbia, Vancouver, BC.

- [45]Xiaojun Su, Oscar Kin-Chung Au and Rynson W.H. Lau. 2014. The implicit fan cursor: a velocity dependent area cursor. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems* (CHI '14), 753-762.
- [46]Manojit Sarkar, and Marc H. Brown. Graphical fisheye views of graphs. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems* (CHI '92), 83-91.
- [47]Shumin Zhai, Stéphane Conversy, Michel Beaudouin-Lafon and Yves Guiard. 2003. Human on-line response to target expansion. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems* (CHI '03), 177-184.
- [48]Abir Al Hajri, Sidney Fels, Gregor Miller and Michael Ilich. 2011. Moving target selection in 2D graphical user interfaces. In *Proceedings of the International Conference on Human Computer Interaction* (INTERACT '11), 141-161.
- [49]Renaud Blanch, Michaël Ortega. 2011. Benchmarking Pointing Techniques with Distractors: Adding a Density Factor to Fitts' Pointing Paradigm. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems* (CHI '11), 1629-1638
- [50]Yoji Uno, Mitsuo Kawato, Ryoji Suzuki. 1989. Formation and control of optimal trajectory in human multijoint arm movement: Minimum torque-change model. *Biological Cybernetics*, 61, 89–101.
- [51]Mitchell Glickstein, Gregory R Bock, Jamie A Goode. 1998. Sensory guidance of movement. *Novartis Foundation Symposium 218*, Wiley, Chichester, UK, 176–201.
- [52]N Bernstein. 1967. The coordination and regulation of movements. Pergamon Press, Oxford.
- [53]Reza Shadmehr, Maurice A. Smith and John W. Krakauer. 2010. Error correction, sensory prediction, and adaptation in motor control. *Annual Reviews of Neuroscience* 33, 1 (March 2010), 89–108.
- [54]Lisa Anthony, Jacob O Wobbrock. 2010. A lightweight multistroke recognizer for user interface prototypes. In *Proceedings of the Graphics Interface 2010 Conference* (GI '10), Toronto, Ont., Canada, 245–252.
- [55]Radudaniel Vatavu, Lisa Anthony, Jacob O Wobbrock. 2012. Gestures as point clouds: a \$P recognizer for user interface prototypes. In *Proceedings of the 14th ACM international conference on Multimodal interaction* (ICMI '12), ACM, New York, NY, USA, 273–280.
- [56]Jacob O Wobbrock, Andrew D Wilson, Yang Li. 2007. Gestures without libraries, toolkits or training: a \$1 recognizer for user interface prototypes. In *Proceedings of the 20th annual ACM symposium on User interface software and technology* (UIST '07), ACM, New York, NY, USA, 159–168.
- [57]Xiang Cao, Shumin Zhai. 2007. Modeling human performance of pen stroke gestures. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems* (CHI '07), ACM, New York, NY, USA, 1495–1504.
- [58]Rachel Blagojevic, Samuel Hsiaoheng Chang, Beryl Plimmer. 2010. The power of automatic feature selection: Rubine on steroids. In *Proceedings of the Seventh Sketch-Based Interfaces and Modeling Symposium* (SBIM '10), Eurographics Association, Aire-la-Ville,

- Switzerland, 79–86.
- [59] Dean Rubine. 1991. *The automatic recognition of gestures*. Doctoral Thesis. Carnegie Mellon University.
- [60] Lu Hao, and Yang Li. 2015. Gesture On: Enabling Always-On Touch Gestures for Fast Mobile Access from the Device Standby Mode. In *Proceedings of the ACM Conference on Human Factors in Computing Systems (CHI '15)*. ACM, New York, NY, USA, 3355-3364.
- [61] Ke Liu, Yea S Huang, Ching Y Suen. 1997. Robust stroke segmentation method for handwritten Chinese character recognition. In *Proceedings of international conference on document analysis and recognition (ICDAR '97)*. 1, 211–215.
- [62] Matteo Frigo, Steven G Johnson. 1998. FFTW: An adaptive software architecture for the FFT. In *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing*. Seattle, WA, USA, USA, 3, 1381-1384.
- [63] Claude E Shannon. 1948. A Mathematical Theory of Communication. *Bell System Technical Journal*. 27, 3, 379-423.
- [64] Robert St Amant, Mark O Riedl. 2001. A perception/action substrate for cognitive modeling in HCI. *International Journal of Human-computer Studies*. 55(1), 15-39.
- [65] Konrad P Kording, Daniel M Wolpert. 2004. Bayesian integration in sensorimotor learning. *Nature*, 427(6971), 244-247.
- [66] Stephen H Scott. 2002. Optimal strategies for movement: success with variability. *Nature Neuroscience*, 5(11), 1110-1111.
- [67] David A Winter. 1990. Biomechanics and motor control of human movement. New York, Wiley.
- [68] Radudaniel Vatavu, Lisa Anthony, Jacob O Wobbrock. Relative accuracy measures for stroke gestures. In *Proceedings of the International Conference on Multimodal Interfaces (ICMI'13)*, 2013: 279-286.
- [69] Karin Wirdefeldt, Hansolov Adami, Philip Cole, Dimitrios Trichopoulos, Jack S Mandel. 2011. Epidemiology and etiology of Parkinson's disease: a review of the evidence. *European Journal of Epidemiology*, 26(1), 1-58
- [70] Morgado P.M. 2012. Automated diagnosis of Alzheimer's disease using PET images a study of alternative procedures for feature extraction and selection electrical and computer engineering. Higher Technical Institute, Technical University of Lisbon.
- [71] Eric E Smith, Martin Odonnell, Gilles R Dagenais, Scott A Lear, Andreas Wielgosz, Mukul Sharma, Paul Poirier, Grant Stotts, Sandra E Black, Stephen C Strother, Michael D Noseworthy, Oscar R Benavente, Jayesh Modi, Mayank Goyal, Saima Batool, Karla Sanchez, Vanessa Hill, Cheryl R McCreary, Richard Frayne, Shofiqul Islam, Jane Dejesus, Sumathy Rangarajan, Koon K Teo, Salim Yusuf. 2015. Early cerebral small vessel disease and brain volume, cognition, and gait. *Annals of Neurology*, 77(2), 251-261.

- [72] M C De Rijk, L J Launer, K Berger, Monique M B Breteler, Jeanfrancois Dartigues, Marzia Baldereschi, Laura Fratiglioni, Antonio Lobo, J Martinezlage, Claudia Trenkwalder, A Hofman. 2000. Prevalence of Parkinson's disease in Europe: A collaborative study of population-based cohorts. *Neurology*, 54(5), S21-S23.
- [73] Martin Prince, Gemmaclaire Ali, Maelenn Guerchet, A Matthew Prina, Emiliano Albanese, Yutzu Wu. 2016. Recent global trends in the prevalence and incidence of dementia, and survival with dementia. *Alzheimer's Research & Therapy*, 8(1), 23.
- [74] Jong S Kim. 2015. Small vessel disease: not a small problem. *Journal of Stroke*, 17(1), 1.
- [75] S Skodda, W Gronheit, N Mancinelli, U Schlegel. 2013. Progression of voice and speech impairment in the course of Parkinson's disease: a longitudinal study. *Parkinson's Disease*, 2013, 389195-389195.
- [76] F Segovia, Juan M Gorriz, Javier Ramírez, D Salas-Gonzalez, Ignacio Alvarez Illan. 2015. Early diagnosis of Alzheimer's disease based on partial least squares, principal component analysis and support vector machine using segmented MRI images. *Neurocomputing*, 151, 139-150.
- [77] Atilla Ünlü, Rüdiger Brause, Karsten Krakow. 2006. Handwriting analysis for diagnosis and prognosis of Parkinson's disease. In *Proceedings of the 7th international conference on Biological and Medical Data Analysis (ISBMDA'06)*. Springer Berlin Heidelberg, 441-450.
- [78] Esther J Smits, Antti Tolonen, Luc Cluitmans, Mark Van Gils, Bernard A Conway, Rutger C Zietsma, Klaus L Leenders, Natasha Maurits. 2014. Standardized handwriting to assess bradykinesia, micrographia and tremor in Parkinson's disease. *PLOS ONE*, 9(5), e97614.
- [79] Hyungsin Kim, Young Suk Cho, Ellen Yiluen Do. 2010. Context-bounded refinement filter algorithm: improving recognizer accuracy of handwriting in clock drawing test. In *Proceedings of the 7th AAAI Conference on Visual Representations and Reasoning, (AAAIWS '10-07)*, 53-60.
- [80] Randall Davis, David J Libon, Rhoda Au, David Pitman, Dana L Penney. 2015. THink: inferring cognitive status from subtle behaviors. *AI Magazine*, 36(3), 49-60.
- [81] Stuart Hagler, Holly Jimison, Misha Pavel. 2014. Assessing executive function using a computer game: computational modeling of cognitive processes. *IEEE Journal of Biomedical and Health Informatics*, 18(4), 1442-1452.
- [82] AITB. 1944. *Army Individual Test Battery. Manual of directions and scoring*. War Department, Adjunct General's Office, Washington, DC.
- [83] James A Arnett, Seth S Labovitz. 1995. Effect of physical layout in performance of the trail making test. *Psychological Assessment*, 7(2), 220-221.
- [84] Kenneth I Shulman. 2000. Clock-drawing: is it the ideal cognitive screening test?. *International Journal of Geriatric Psychiatry*. 15(6), 548-561.
- [85] Rodger J Elble, Raj Sinha, C Higgins. 1990. Quantification of tremor with a digitizing tablet. *Journal of neuroscience methods*. 32(3), 193-198.

- [86] Francesc Miralles, S. Tarongi, Antonio Espino. 2006. Quantification of the drawing of an Archimedes spiral through the analysis of its digitized picture. *Journal of neuroscience methods*, 152(1), 18-31.
- [87] Oliver Tucha, Lara Mecklinger, Johannes Thome, Astrid Reiter, G L Alders, H Sartor, Markus Naumann, Klaus W Lange. 2006. Kinematic analysis of dopaminergic effects on skilled handwriting movements in Parkinson's disease. *Journal of Neural Transmission*, 113, 609-623.
- [88] Mark A Hall. 1998. *Correlation-based feature subset selection for machine learning*. Doctoral Thesis, University of Waikato.
- [89] J R Quinlan. 1986. Induction of Decision Trees. *Machine learning*, 1(1), 81-106.
- [90] Huang Jin, Han Dongqi, Chen Yineng, Tian Feng, Wang Hongan, Dai Guozhong. A Survey on Human-Computer Interaction in Mixed Reality. 2016. *Journal of Computer-Aided Design & Computer Graphics*, 2016, 28(6), 869-880. (In Chinese)
(黄进, 韩冬奇, 陈毅能, 田丰, 王宏安, 戴国忠. 混合现实中的人机交互综述. 计算机辅助设计与图形学学报, 2016, 28(6): 869-880)
- [91] Huang Jin, Chen Yineng, Liu Jie, Tian Feng, Dai Guozhong, Wang Hongan. 2016. Multimodal Human-Computer Interaction Model for Nerve Function Assessment in Mobile Environment. *Journal of Software*, 27(Sup.2), 156-171. (In Chinese)
(黄进, 陈毅能, 刘杰, 田丰, 戴国忠, 王宏安. 移动环境下神经功能评价多通道交互模型. 软件学报, 2016, 27(Sup.2): 156-171)
- [92] Yineng Chen, Xiaojun Su, Feng Tian, Jin Huang, Xiaolong(Luke) Zhang, Guozhong Dai, Hongan Wang. 2016. Pactolus: A Method for Mid-Air Gesture Segmentation within EMG. *CHI '16 Extended Abstracts on Human Factors in Computing Systems (CHI EA '16)*, EA 3329-3334
- [93] Liu Jie, Huang Jin, Tian Feng, Hu Weiping, Dai Guozhong, Wang Hongan. 2017. A Study of the Hybrid Gesture Interaction Model in the Continuous Interaction Space. *Journal of Software*, 28(8), 2080-2095 (In Chinese)
(刘杰, 黄进, 田丰, 胡伟平, 戴国忠, 王宏安. 连续交互空间下的混合手势交互模型. 软件学报, 2017, 28(8): 2080-2095)
- [94] Liu Jie, Huang Jin, Han Dongqi, Tian Feng, Dai Guozhong, Wang Hongan. 2016. Template Matching Algorithm for 3D Gesture Recognition. *Journal of Computer-Aided Design & Computer Graphics*. 2016, 28(8), 1365-1372. (In Chinese)
(刘杰, 黄进, 韩冬奇, 田丰, 戴国忠, 王宏安. 模板匹配的三维手势识别算法. 计算机辅助设计与图形学学报, 2016, 28(8): 1365-1372.)
- [95] Hugh Mcmanus, Daniel E Hastings. 2006. A framework for understanding uncertainty and its mitigation and exploitation in complex systems. *IEEE Engineering Management Review* 34(3), 81-81.
- [96] Daryl Weir, Henning Pohl, Simon Rogers, Keith Vertanen, Per Ola Kristensson. 2014.

Uncertain text entry on mobile devices. In *Proceedings of the ACM Conference on Human Factors in Computing Systems (CHI '14)*, 2307-2316.

就读博士期间发表的学术论文目录

1. **Jin Huang**, Feng Tian, Xiangmin Fan, Xiaolong(Luke) Zhang, Shumin Zhai. Understanding the Uncertainty in Moving Target Selection. In Proceedings of the ACM Conference on Human Factors in Computing Systems (CHI '18). (已收录)
2. **Jin Huang**, Xiaolan Peng, Feng Tian, Hongan Wang, Guozhong Dai. Modeling Target Selection Motion Leveraging Optimal Feedback Control Mechanism. Science China Information Sciences. (已收录)
3. **黄进**, 陈毅能, 刘杰, 田丰, 戴国忠, 王宏安. 移动环境下神经功能评价多通道交互模型. 软件学报, 2016, 27(Sup.2): 156-171
4. **黄进**, 韩冬奇, 陈毅能, 田丰, 王宏安, 戴国忠. 混合现实中的人机交互综述. 计算机辅助设计与图形学学报, 2016, 28(6): 869-880
5. Yineng Chen, Xiaojun Su, Feng Tian, **Jin Huang**, Xiaolong(Luke) Zhang, Guozhong Dai, Hongan Wang. Pactolus: A Method for Mid-Air Gesture Segmentation within EMG. CHI '16 Extended Abstracts on Human Factors in Computing Systems (CHI EA '16), 2016, EA 3329-3334
6. 李洋, **黄进**, 田丰, 韩冬奇, 范俊君, 陈辉, 彭晓兰, 戴国忠, 王宏安. 云端融合的神经系统疾病多通道辅助诊断研究. 中国科学: 信息科学. (已收录)
7. 刘杰, **黄进**, 田丰, 胡伟平, 戴国忠, 王宏安. 连续交互空间下的混合手势交互模型. 软件学报, 2017, 28(8): 2080-2095
8. 刘杰, **黄进**, 韩冬奇, 田丰, 戴国忠, 王宏安. 模板匹配的三维手势识别算法. 计算机辅助设计与图形学学报, 2016, 28(8): 1365-1372
9. 田丰, **黄进**, 朱以诚, 崔丽英, 王宏安. 基于数字笔的连线测试多通道数据采集方法及系统. 发明专利. 申请号: 201610081222X
10. 田丰, **黄进**, 王宏安. 基于数位笔的画钟测试检测方法及系统. 发明专利. 申请号: 2017101005307

就读博士期间参加研究的课题项目

1. 云端融合的自然交互设备和工具，2016.7-2020.6，国家重点研发计划，2016YFB1001400
2. 脑神经多模态定量化关键技术，2015.1-2017.12，国家高技术研究发展计划项目（863计划项目），2015AA020506
3. 自然人机交互基础理论和方法研究，2013.1-2017.12，国家自然科学基金重点项目，61232013
4. 人机界面技术，2015.01-2017.12，国家优秀青年基金项目，61422212

致谢

攻读博士学位的时光收获了很多，不仅有丰富的知识技能，也有宝贵的人生经验。值此论文完成之际，谨在此向多年来给予我关心和帮助的老师、学长、同学、朋友和家人表示衷心的感谢！

感谢我的导师田丰研究员。田老师治学严谨、远见卓识、虚怀若谷、厚德载物，能够在博士研究生阶段师从田老师让我感到无比的荣幸。田老师在学术上拥有广阔的视野、敏锐的洞察力和超凡的驾驭力，对待工作仅仅有条、精益求精。从我第一次踏入中国科学院软件研究所，走进田老师的办公室，和他第一次见面交谈的那一刻起，就仿佛感受到我的人生将从此改变。我的当时的感觉没错，正是因为田老师，我第一次能让自己的编程能力在国家重大项目上一展身手，能有机会潜心研究人类行为表面现象后的规律，能与那么多优秀的老师、学者、同学们一起研究问题，能走出国门参加国际顶尖的学术会议，与学术巨匠们一起交流。我的每一点成绩和进步都凝聚着田老师的心血，请允许我再次向我的博士研究生导师、关心我照顾我的好长辈、我的好朋友田丰老师，表示最诚挚的谢意！

感谢戴国忠研究员和王宏安研究员，他们是实验室的领路人，从二位老师的身上学习到了认真治学的态度和一丝不苟的精神，二位老师渊博的学识、敏锐的洞察力以及对科学的孜孜不倦令人佩服，在心中，我默默地将他们作为榜样和进步的明灯。感谢他们一手创办的中科院软件所人机交互实验室，这里有一流的老师、一流的环境、一流的资源和一流的学术氛围。真心祝愿实验室科研水平越来越高，承担更多更好的国家重大项目，在国内国际的影响力越来越大。

感谢翟树民老师，作为人机交互学术和产业界的顶尖学者，他在两次 ACM SIGCHI 论文撰写和投稿期间不厌其烦地对我进行指导，小到语法错误大到论文构思，他都亲自和我讨论，来来回回发了五十多封电子邮件，他的每一句话都和指导思想，对于我在交互运动模型的研究工作帮助都非常之大。虽然我只与翟老师在 2015 年 SIGCHI 大会期间有过一面之缘，短短的二十分钟交流内却感到醍醐灌顶，对当前的科研工作和人机交互的未来都都有了更为清晰想法。再次感谢他给我的帮助和指导。

感谢张小龙老师和范向明老师，他们在论文写作上给予了我莫大的帮助。张老师在统计学技巧和论文写作上帮助我解决了很多问题，与他进行的几次面对面的交流都得到了他的宝贵意见和建议，每次都让我的下一步研究工作更加脚踏实地，考虑问题的方法更加全面而具体。范老师虽然比我年轻却才华横溢、博闻多识，在最近一次的 ACM

SIGCHI 论文投稿过程中，刚到实验室的他就毫无保留地帮助我们修改论文，传授我们论文写作技巧，与我们一起熬夜一起喝酒，第二天，再一起起个大早重新投入科研工作当中，这是我最难忘又最愉快的一次投稿经历。

感谢实验室的陈辉老师、马翠霞老师、张凤军老师、邓小明老师、乔颖老师、苏晓君老师，还有曾经在实验室工作的王丹力老师、王永炎老师、周祥东老师、吕菲老师、杨海燕老师。感谢各位老师在学习、科研、工作与生活中的教导与帮助，各位老师的指导让我受益匪浅。

感谢实验室行政工作组的徐桂荣老师、陈晓燕老师、刘宁老师、刘琨老师和刘嘉丽老师。感谢中科院软件研究所研究生部李彩丽老师、张欢老师和汤诗豪老师，综合办公室韩鸿泉老师，科技处李洁老师、巢燕老师和李莹烛老师。感谢他们在入学、科研事务、实验室事务、毕业方面的给予我的大力协助。

感谢北京协和医院朱以诚大夫、姚明大夫、赵琰大夫、宗黎霞大夫、翟菲菲大夫、苏宁大夫、张江涛大夫、张江霞大夫。各位大夫在医学上造诣匪浅，有着崇高的职业素养，无私奉献，有海一样的情怀。和各位大夫的合作非常的开心，也一起取得了良好的跨学科研究成果，感谢他们。

感谢陈毅能同学，作为田老师的开山大弟子，是你第一次将我领入人机交互实验室，也是你第一次带着我一起搞科研做实验，逐渐融入人机交互这个充满创意设计和黑科技的神奇世界，你一直是我学习的好榜样、工作的好拍档、生活的好伙伴，希望你能在今后的道路上越走越好，更上一层楼。

感谢在科研工作和生活中陪我度过三个春秋的小伙伴们，姚乃明、范俊君、彭晓兰、李洋，我们组成了初中生开放性实践活动中的四大组长，也是最老资格的王牌教师，完成了一个又一个艰巨的教学任务；我们组成了一个活泼快了的科研小组，一起写代码、一起讨论问题、一起修改论文，搞定了一个又一个科研问题，合作产出了好几篇高水平论文；我们组成了最为坚定的吃饭军团，所食堂、公寓食堂、大拇指、马华、桂林米粉、刀削面、鑫蜀园、融科、五道口，吃饭必备开黑环节，饭前一局饭后一局，吃饱玩尽后又一起回到实验室继续加班搞科研，因为他们我的博士生活不再沉闷，而成为了生命中最难忘的回忆。

感谢课题组里的其它同学，路璐、刘杰、王赫然、姜超词、贺悦、胡伟平、施大鹏、韩冬奇、焦阳、李念龙、李翔、高敬、孙伟、仝青山、马帅、张宗琦、汪柳萍。他们有的睿智，有的勤奋，有的活泼，有的豪放，博士研究生涯可以和这样一群欢乐的人一起度过，是多麽值得庆幸的事。

感谢现在以及曾经实验室里的其它同学和同事，胡仲义、齐云凤、黄燕、袁野、杨

硕、张晓宇、刘孟孟、李江东、张泽华、黄朝殿、贾唯秦、晏琪、李耀宗、董为、吴云坤、张鹏、李依霖、郭清沛、徐超、杨心盼、张澜、胡海琛、李义超、王琨、王娟娟、沈琼、冷昶、刘胜航、巩向林、朱倩，我们曾一起在实验室里默默的工作，一起参加党员民主生活会，一起参加运动会一起打篮球，一起熬夜赶论文，一起等待毕业一起期盼明天，感谢你们陪我一同走过这段开心而难忘的日子。

感谢在百忙之中评阅论文的各位专家，你们的评审能让我准确认识工作的要点和改进的方向，明确今后的工作重心。

谨以此文献给我敬爱的父母、亲爱的妻子和我的宝贝女儿，感谢你们一直以来对我的关爱和支持，愿你们永远健康、平安幸福。