

用于穿戴式鼠标信号的端点检测研究

(孙闻¹² 姚志勇^{24*} 钟纪权²⁴ 胡跃辉²³)

1. 安徽华明航空电子系统有限公司, 安徽, 芜湖 241010.
2. 合肥工业大学, 特种显示技术国家工程实验室, 安徽, 合肥 230009.
3. 合肥工业大学, 光电技术研究院, 安徽, 合肥 230009.
4. 合肥工业大学, 仪器科学与光电工程学院, 安徽, 合肥 230009.

*通讯作者: 姚志勇

摘要: 本文研究利用神经网络进行穿戴式鼠标中的鼠标手势信号端点检测。我们将长短期记忆神经网络(Long Short Term Memory, LSTM)用作基本神经单元, 并引入了一个线性距离因子。神经网络模型在该因子的帮助下可以适应性的更新分割函数。在验证时利用总计约 3000 个手势数据样本对模型进行了训练和评估。结果表明, 在鼠标手势的端点检测中, 相比于传统固定的双门限方法, 基于 LSTM 的神经网络端点检测算法模型适应性好, 无需附加任何阈值即可有效应用于手势分割, 而且可以明显提升最终手势分类识别率, 使其平均识别率达到了 95. 8%。

关键词: 穿戴鼠标, 端点检测, 手势识别, 神经网络

Research on Endpoint Detection for Wearable Mouse Signal

(Sun Wen¹² Yao Zhiyong^{24*} Zhong Jiquan²⁴ Hu Yaohui²³)

1. Anhui Huaming Avionics System Limited Company, Wuhu 241010, China.
2. National Engineering Laboratory of Special Display Technology, Hefei University of Technology,

作者简介: 孙闻(1983-), 男, 安徽华明航空电子系统有限公司, 高级工程师, 2005 年安徽工程大学本科毕业, 研究方向为无人机交互技术。E-mail: sw9813@126.com ; 姚志勇(通讯作者)(1998-), 男, 2020 年于合肥工业大学获得学士学位, 现为合肥工业大学硕士研究生, 研究方向为生物医学工程和人机交互技术。E-mail: 1326931687@qq.com

2958-1478/© Shuangqing Academic Publishing House Limited All rights reserved.

Article history: Received March 11, 2023 Accepted April 26, 2023 Available online April 27, 2023

To cite this paper: 孙闻, 姚志勇, 钟纪权, 胡跃辉 (2023). 用于穿戴式鼠标信号的端点检测研究. 人工智能研究, 第 1 卷, 第 2 期, 1-15.

Doi: <https://doi.org/10.55375/aif.2023.2.1>

Hefei 230009, China.

3. Academy of Opto-electric Technology, Hefei University of Technology, Hefei 230009, China.

4. School of Instrument Science and Opto-electronics Engineering, Hefei 230009, China.

Abstract: This article uses neural networks to study the endpoint detection of mouse gesture signals in wearable mice. We introduce a linear distance factor by using Long Short Term Memory (LSTM) as the basic neural unit. The neural network model can adaptively update the segmentation function with the help of this factor. The model was trained and evaluated using approximately 3,000 gesture data samples for verification. The experimental results show that compared to the traditional fixed dual-threshold method, the proposed LSTM-based neural network endpoint detection algorithm is adaptable and can be effectively applied to gesture segmentation without additional thresholds. Moreover, it can significantly improve the final gesture classification recognition rate, with an average recognition rate of 95.8%.

Keywords : Wearable mouse, Endpoint detection, Gesture recognition, Neural network

1. 介绍

穿戴式鼠标也是手势识别装置的一种。相较于常见的大幅度手势，操作鼠标的点击滑动手势等鼠标手势具有时间短，信号小的特点，对准确率也有更高的要求。准确分割出活动手势片段是影响手势识别工作质量和效率的最主要因素之一。目前大多数手势信号分割方法是通过引入一些预定义的阈值来确认边界，例如经典的半自动化分割边界的双门限方法。针对鼠标手势识别的实时、自动、快速的要求，并利用手势信号在时间上的前后相关性，提出了一种基于递归神经网络的手势分割方法。本文研究利用神经网络进行穿戴式鼠标中的鼠标手势信号端点检测。

我们从驻极体传感器阵列的设计出发，制作了一个能够感知手指运动时腕背部运动信号、并且能够实现实时数据标注的简易可穿戴式手环，该手环设备能够采集 8 通道传感器数据和 1 通道标注数据并以串口通讯的方式发送至上位机。在对数据进行预处理后，我们搭建了一个基于 LSTM 神经网络的手势信号端点检测模型，实现对活动手势片段和非活动手势片段的自动分割，其端点检测准确率达到 96.85%。在基于端点检测基础上，我们对分割结果进行保存，并逐步搭建用于手势分类的数据库，然后我们再利用 LSTM 神经网络搭建了第二个用于手势分类的模型并对其进行训练，在手指动作分类的实验中，整体识别达到 95.8%，与采用传统的端点检测算法的手势识别系统相比，其最终的识别率提升了约 28%，基本满足了技术要求。

随着可穿戴移动设备的日益普及，人机交互设备也向着移动式方向发展，这些可穿戴移动设备在带给用户们全新的体验同时，也对人机交互的方式和技术提出了更高的要求，人们

更期望能够把交互设备设计的简易轻便、佩戴舒适，最好像是装饰品那样，例如手环。因此，有研究人员提出通过检测腕部运动信号来识别手势^[1]，进而实现一个穿戴式的鼠标从而进行更便捷的人机交互。对于手势识别，当前大部分的研究都集中在手语手势识别场景，对于鼠标手势识别场景的研究很少，穿戴式鼠标的手势识别相比较于手语识别，其手势相对来说较少，一般 3-5 个手势即可实现大部分的操作，另外，它要求系统要具备高识别率，最好能达到 100%。鼠标的操作有点击和滑动两种，这里我们将其统称为鼠标手势。文献^[2]利用一种 PVDF 压电薄膜的腕部传感器环绕手腕一周采集手指动作信号，对食指点击，中指点击以及食指滑动三个操作鼠标常用的动作的识别率达到了 96.7%。虽然手腕内侧的手指动作连接的肌肉更多、动作特征更明显^[3]，但是手腕内侧往往是手环的连接处，不利于传感器的集成，所以更希望在腕背部位置集成传感器来实现穿戴式鼠标。文献^[4]同样利用 PVDF 压电薄膜来制作腕部穿戴鼠标，但只在腕背部采集手指动作信号。该文献利用双门限方法来分割手势。因为在腕背部检测运动信号相对比较困难，所以对 3 个手指动作的识别率降到了 94%。为了尽可能的提升精准度，我们需要在之前工作的基础上，进一步改进穿戴式鼠标手势识别的模型和算法。

端点检测是整个穿戴式鼠标系统中容易被忽视的点，但也是整个系统能够取得成功的关键，它的任务是在一段连续的信号中找到活动手势起始点和终点，以此来拆分活动段和非活动段。穿戴式鼠标系统是一中实时手势识别系统，要求从连续的手势信号序列里划分出活动片段。在大多数现有方法中都是通过提取信号的特定特征用于检测边界^{[5]-[7]}，这种方法利用实验经验预先设定一些先验阈值，但是在多个受试者参与的情况下，由于受试者的手部结构和动作幅度会有差异，其检测精度也会波动很大。

理想的端点检测方法应该具有实时、快速、适应性高等特点。为了解决上述问题，一方面，我们分析考察了利用 PVDF 等压电传感器采集到的手势信号，发现和语音信号具有很高的相似性，两者都是频率范围在几十到几千赫兹之间的时间序列，并且前后相关。另一方面，神经网络由于适应性好，能够实现自动检测等特性，它在语音信号处理领域得到了有效利用^{[8]-[18]}。我们提出了一种基于 LSTM 的鼠标手势信号端点检测算法，将前后几帧的手势信息进行融合用以实现对当前帧的联合判决；另外，由于手势边界处信号变化剧烈，容易产生模糊判定，进而导致网络模型的输出会出现一定数量的突起，这种突起会给手势分割任务带来困难，并且会影响最终手势分类的准确率。为了抑制突起的发生，我们在输出层引入了一个线性距离因子来帮助手势分割。我们把该方法应用在三种鼠标手势动作信号(左击，右击和滑动)的分类中，并与不同的端点检测算法进行比较。实验结果表明，我们所提出的基于 LSTM 的神经网络端点检测算法模型适应性好，无需附加任何阈值即可有效应用于手势分割，而且其最终手势分类识别率也有明显提升。

2. 基于神经网络的腕部运动信号端点检测方法

本文提出了一种基于神经网络的鼠标手势信号端点检测方法。在该方法中，我们首先对手势信号序列 $X(n)$ 进行分帧加窗处理，然后提取帧内的特征信息，接下来通过对输入信息随时间动态变化的规律进行学习，将过去信号帧信息作用于当前帧判决，利用手势信号所具备的特点选择 LSTM 作为基本的神经单元来构建网络模型，并针对 LSTM 在输出层表现的不足进行改进，将网络的输出概率值关联成一段具有时间相关性的序列，最后在执行具体的分割任务时通过数据统计分析引入一个距离因子，并在该因子的帮助下进行分割。

端点检测及手势识别的处理流程如图 1 所示。图中主要包含以下 4 个阶段：

1. 手势数据预处理
 2. 用于手势信号端点检测的网络模型训练
 3. 手势分割
 4. 手势分类

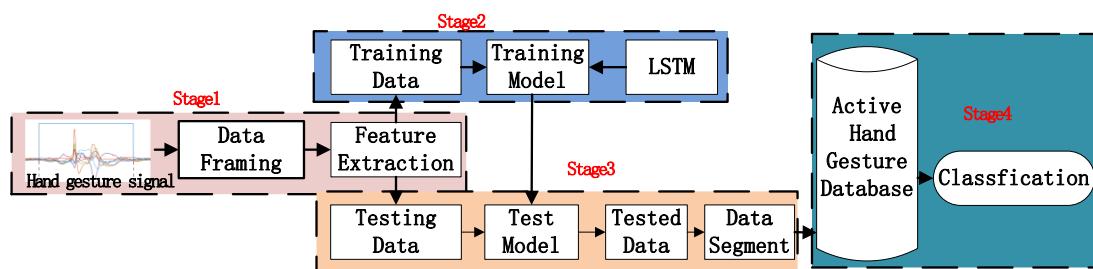


图 1. 腕部运动信号端点检测及识别系统

Fig1. Wrist motion signal endpoint detection and recognition system

2.1 手势数据预处理

该阶段预处理的信号是下位机 1KHz 的采样率采集的 8 通道手势数据，其在采集时已被标注好，具体的数据采集及标注方法将在 3.2 节和 3.3 节中详细介绍。然后我们对手势信号序列 $X(n)$ 进行分帧处理，帧长设置为 32ms，帧移设置为 16ms，每一帧包含 32 个采样点。从文件头部开始，每个手势信号帧都是按照固定长度 T 进行截取，如果最后一帧的长度小于 T 则使用该帧的最后一个采样点补充至长度 T。通常最后一帧是非活动段，所有这样处理不会影响分割精度。紧接着对每帧信号计算其特征参数用于接下来的网络训练，在分类识别中已经被使用的特征包括时域和频域共计有 20 多种，例如最大值、最小值、均方根、峰峰值、谱距等...。本方法中为端点检测算法选择的特征仅仅是时域上的短时能量 En 和短时过零率 Zn ，这样选择是因为简单的特征计算减少了数据训练时间和复杂度，提升系统的实时性。

$$En = \sum_{m=0}^{N-1} [x_n(m) \bullet w(n-m)]^2 \quad (1)$$

$$Z_n = \frac{1}{2} \sum_{m=0}^{N-1} |sgn[x_n(m)] - sgn[x_n(m-1)]| \cdot w(n-m) \quad (2)$$

其中 Wn 是窗函数, $sgn[n]$ 是象函数。

$$sgn[n] = \begin{cases} 1, & x_n \geq 0 \\ -1, & x_n < 0 \end{cases} \quad (3)$$

2. 2 用于手势信号端点检测的网络模型训练

在阶段 2 中, 搭建好网络模型对训练集数据读取, 对于手势信号时间序列, 对其边界的判断不应该只关注于当前的信息, 在其之前的信号也应该被考虑进来, 所以模块 2 的网络模型我们选用 LSTM 来搭建。

在基于 LSTM 的手势信号端点检测算法中, 网络的每个节点输入是一段长度为 T 的时间序列, 最后一层各个神经元的输出是对当前时刻序列 T 以及过去序列的部分信息的映射。

给定手势序列 $S = \{s_1, s_2, \dots, s_N\}$, 每帧手势的检测结果 $Y = \{y_1, y_2, \dots, y_N\}$, 其中 N 为手势序列的长度, 每个信号帧 S_t 的长度都一样, $S_t = \{x_t^1, x_t^2, \dots, x_t^{31}, x_t^{32}\}$, x_t^i 为一个采样点。
 $Y_t = \{0, 1\}$, 其中 0 代表该帧信号 S_t 属于连续手势信号中的非活动段, 1 代表 S_t 属于活动段, $t \in [1, N]$ 。模型的训练过程如图 2 所示:

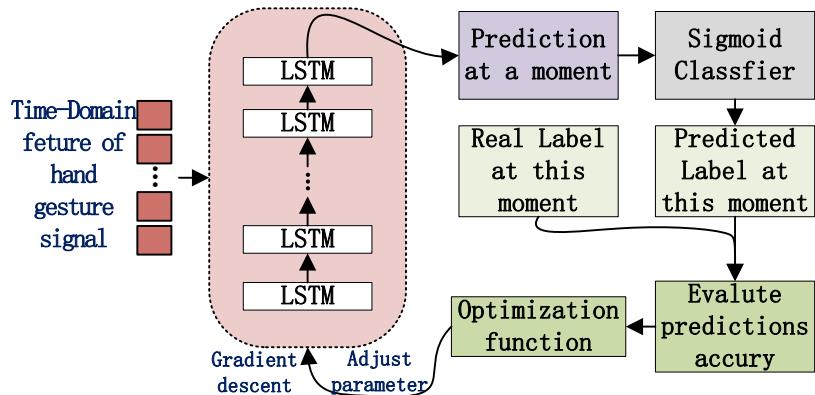


图 2. 网络的训练过程

Fig2. Network training process

模型准确性的评估是采用交叉熵(Cross-entropy)的方式进行, 它是一种广泛用于精度测量的性能指标, 两个类别得到的预测概率值分别为 p 和 $1-p$, 此时表达式为:

$$L = \frac{1}{N} \sum_i -(y_i \log(p_i) + (1-y_i) \log(1-p_i)) \quad (4)$$

其中, y_i 表示真实的标签值, p_i 表示预测的标签值。

3. 3 手势分割

需要指出的是, 由于神经网络完成的是输入向量与目标向量的映射, 对于手势信号端点

检测，在手势的边界处，由于信号处于过渡期，输出的概率难免会有波动，这种波动会使得边界处的判断出现一些突起，而后续的手势识别需要从检测的结果切割出活动片段，这些突起会给分割任务带来麻烦。为了保证系统的稳定性，我们需要合理的处理这些突起。

我们对数据集进行了统计，在遍历了所有手势数据集后，发现真实标签中连续 1 标签的长度(即活动手势片段)和连续的 0 标签长度(即非活动手势片段)具有如表 1 所示的特征。

表 1. 活动手势片段长度的统计属性

Table 1. Statistical attributes of active gesture segment length

	Max	Min	Mean
1-Length(ms)	510	340	424
0-Length(ms)	8365	650	1319

根据表 1 的统计特征，我们将网络的输出看成一个序列 $Z = \{z_1, z_2, \dots, z_N\}$ ，并对序列 Z 进行了重新调整，具体调整操作为：

1. 设定一个线性距离因子，其长度为最小活动片段长度的一半，即 170。
2. 遍历序列 Z ，当检测到 1 时，记录该位置并标记为活动手势起点 a ，接着继续往下读取。
3. 当检测到 0 时，记录该位置并标记为活动手势的终点 b 。
4. 统计 a 到 b 的长度 L_{ab} ，若 $L_{ab} < 170$ ，则认为区间 $[a, b]$ 是突起，并非活动手势，并将区间内的预测值更改为 0。若 $L_{ab} \geq 170$ ，则重复操作 2, 3, 4。
5. 调整后的序列为 $Y = \{y_1, y_2, \dots, y_N\}$ 。

由于活动片段长度小于非活动片段长度，并且少于一半的手势片段的信息已经严重丢失，会影响系统的稳定性，所以 170 的设定是合理的。

通过以上操作，我们就把网络的每个时刻输出也关联了起来，在分割时利用前后的相关性，这样会有利于信号的分割，提升手势分类的准确率。调整后的 y_i 可表示为：

$$y_i = z_{i-k} \oplus \dots \oplus z_i \oplus \dots \oplus z_{i+k} \quad (5)$$

其中， k 表示前后的相邻帧数， \oplus 表示连接操作。对输出层进行改进后的网络结构如图 3 所示：

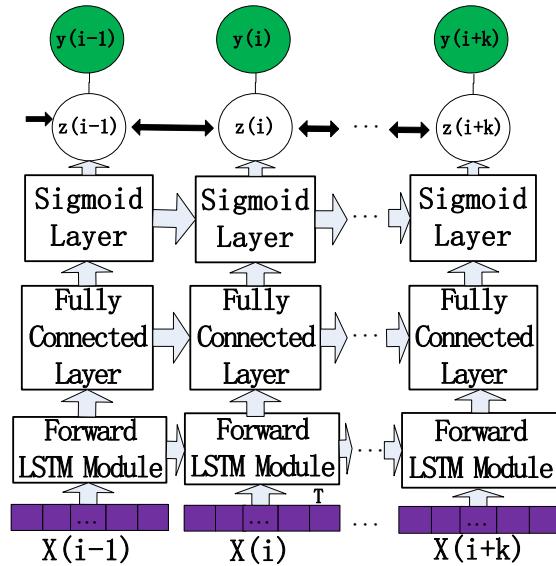


图 3. 模型结构

Fig 3. Model structure

2. 4 手势分类

阶段 4 就是在将所有的手势数据分割完后，建立起我们的手势数据库，搭建一个基于 LSTM 神经网络的分类器，完成手势的分类识别。我们分别使用 LSTM 神经网络搭建的模型和改进输出层后的 LSTM 神经网络结构对采集的腕背部运动信号进行端点检测，并进行对比，从而进一步说明改进输出层后算法的效果，实验的对比结果将在在 3.3 节有详细说明。

3. 实验

3. 1 运动感知传感器阵列设计

目前，应用于穿戴式手势识别的传感器从测量原理上主要分为：力学传感器、电学传感器、光学传感器等几种。其中基于 PVDF(Polyvinylidene Fluoride, 聚偏氟乙烯)压电薄膜的压力传感器在穿戴式鼠标中取得了较好的测量效果^[4]，不过利用该种材料制备的传感器容易发生老化失效，导致性能变差，所以本次验证实验选择的是基于驻极体薄膜的压力传感器，它同样拥有很高的灵敏度，此外在耐用性方面表现的更加稳定。

与该文献^[4]类似，我们制作一个由 8 个驻极体传感器以 4*2 的方式排列的穿戴式鼠标系统。每系统中个传感器的直径大约 5 毫米，8 个传感器覆盖了手腕背部的大部分位置，可以确保有效的检测腕背部的运动信号。此外，还在每个传感器外层敷了一层硅胶膜，与传感器感知面形成一个密闭的空气腔室。硅胶膜作用为改变谐振频率使之对语音信号不敏感，并且还拥有佩戴舒适、防止汗液侵蚀传感器等优点。每个传感器单元接了一个抗混叠低通滤波器，数据传输至一个以 STM32F103 为核心的下位机。传感器阵列如图 4 所示。

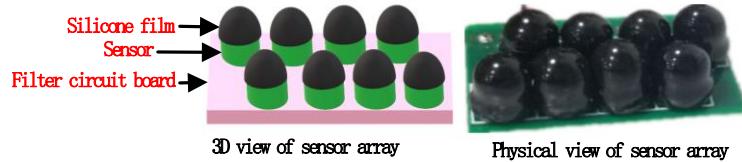


图 4. 传感器阵列

Figure 4. Sensor array

3.2 手势数据采集

下位机将采集到的数据通过串口传输到上位机。对于每个传感器，以 1kHz 的采样频率采样来自驻极体传感器阵列的信号。每个受试者做三种手势，分别为食指点击、中指点击、中指滑动，每种手势重复 500 次，共计 6000 个样本混合。另外，在针对单个人试验时，四人中其中一人每个手势做 1000 次，共计 3000 个种间样本，如图 5 所示。

4 名年龄在 23-26 之间的受试者参加了这次研究，所有受试者都是右手习惯，并且知情同意参加。图 5 所示传感器阵列放置于腕带内侧，腕带系于受试者的右手手腕上，腕带宽约 3 厘米，长约 35 厘米，并在腕带首尾缝有魔术贴。压电传感器阵列贴在腕带内侧，在确保传感器能充分感知肌肉形变的情况下，贴合到安全且舒适的紧绷状态，以免引起疼痛。受试者将腕带佩戴于手臂前下半部分，类似于手表佩戴的位置，图 4 显示了传感器阵列的位置分布。

受试者坐在桌子前的椅子上，将他们的手臂和肘部放在桌子上，没有任何压力，保持手掌略微高于桌面，用于标记数据的压力传感器放置在手指下面。当受试者做出简单的食指向下滑动时，对比鼠标的左击动作，他们的食指会接触到用于标记数据的触摸式电容传感器。其他的手势动作与此相同。

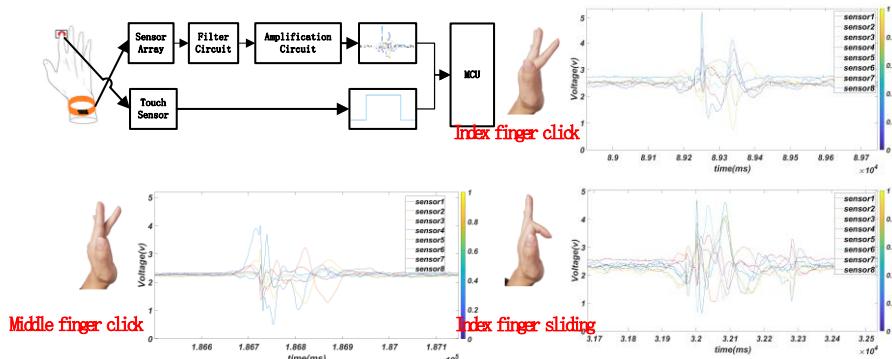


图 5. 三种手势运动信号

Fig 5. Three gesture motion signals

3.3 数据标注方法

为了指导神经网络模型进行有效学习，我们需要在采集数据的同时对数据进行标注，记录每个手势的开始和结束位置。放置在每个受试者手指下方的用于数据标注的触摸式电容传感器(TTP223)提供了对一段连续手势样本中活动手势片段的标记，每次触摸该传感器时，二进制计数器都会读取 1，而触摸的结束二进制计数器将会返回 0。该传感器与手腕的驻极体传感器的读取都是同时记录的，以便相应的标记数据可以与每个点击手势相关联，如图 6 所示。

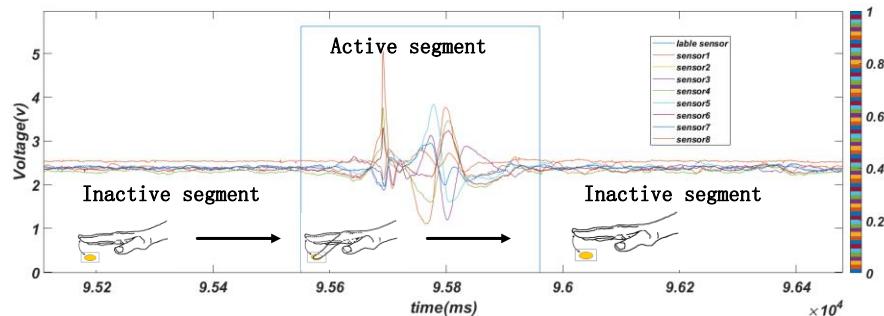


图 6. 动作变化导致标注数据和手势数据变化

Fig6. Change of annotation data and gesture data caused by action change

3.4 数据分析和预处理

在实验中，我们发现，标注通道并不能完全的覆盖完整的活动手势，而是在一个手势的开始和结束部分存在遗漏标记。这是由于活动手势的开始是从手指往下按的这一刻开始，从手指往上抬这一时刻结束的，而这两个时间段手指并未触摸的标注通道电容传感器，因此会出现标记不完全的现象，如图 7 所示。为解决这一问题，我们提出一种利用一阶高斯滤波的方法来修正这一误判。通过调整均方值，将一阶高斯函数与原始标签信号 $T(n)$ 做卷积，最终通过阈值决策来重新规定起点和终点，达到扩宽标注长度的目的。

一维高斯函数原型为：

$$f(x) = ae^{-\frac{(x-b)^2}{2c^2}} \quad (6)$$

式中 a 是曲线尖峰的高度， b 是尖峰中心的坐标， c 称为标准方差，表征的是 bell 钟状的宽度。

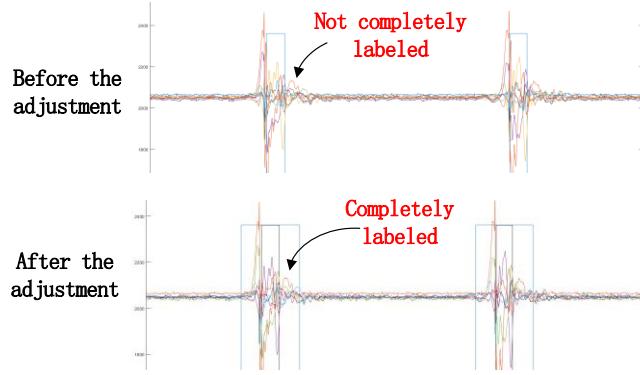


图 7. 校正前后的比较

Figure 7. Comparison before and after correction

4. 实验结果

4.1 端点检测结果

原始压电传感器数据如图 8 中 a 中所示，描述了手指敲击时的原始数据，X 轴表示的是时间，Y 轴表示的是 12 位范围内记录的电压变化。由于本实验使用了 8 个手势数据传感器和 1 个标记数据传感器共 9 个通道，每个通道都以不同的颜色标记。矩形波形是标记数据，曲线波形是手势数据。

我们连续的采集了食指点击、中指点击、食指滑动这三组鼠标手势，每个手势做 1000 个，共计 3000 个，其中 80% 用于模型训练，10% 用于测试，10% 用于验证。实验结果表明，端点检测平均达到的 98% 的预测准确率。

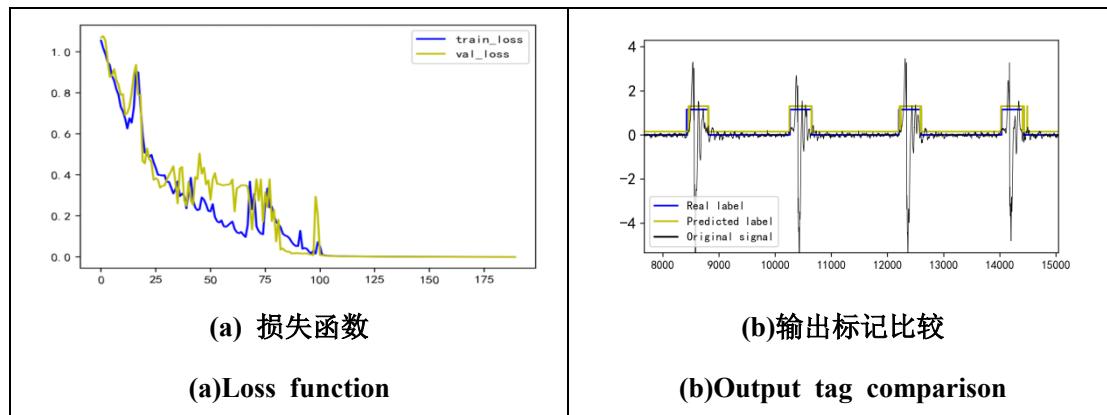


图 8. 端点检测结果

Figure 8. Endpoint detection results

根据对总体活动手势片段的统计，我们将单个活动手势片段长度定义为 480 个采样点 (0.48s)，利用训练好的网络模型来进行分段，由于每个活动手势长度存在一定的差异，我们

需要统一每个分割出来的手势片段，不足 480 个采样点的两边补 0，高于 480 个采样点的裁剪除两边多余的采样点。

4.2 手势分类

根据上述数据分段的结果，我们继续搭建了一个用于活动手势片段分类的神经网络。数据集是数据分段网络模型的分段结果，共计 3000 个活动手势片段，每个手势 1000 个左右。其中 80% 用于数据训练，20% 用于测试。实验结果表明，总数据集分类准确率达到 99.5%，测试集准确率达到 95.8%。当我们使用混合数据集实验时，手势分类准确率会降到 88.0%。

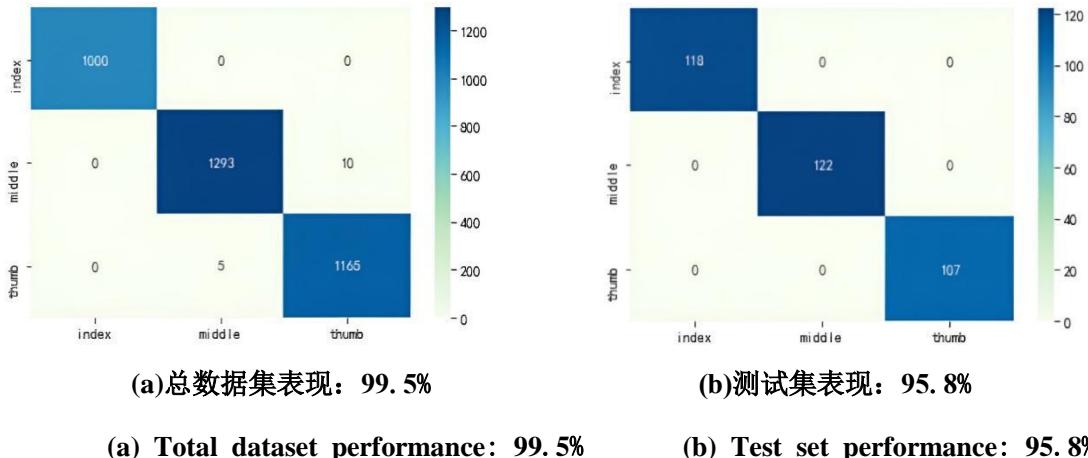


图 9. 手势分类结果

Fig 9. Gesture classification results

4.3 结果分析

为了直观显示优化后的分割函数所展现出的分割效果，我们将优化前和优化后的分割效果作图 10 与图 11：

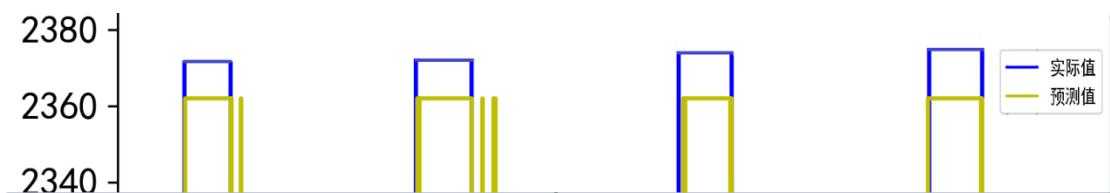


图 10. 优化分割函数前的模型输出标记

Fig 10. Model output mark before optimizing segmentation function

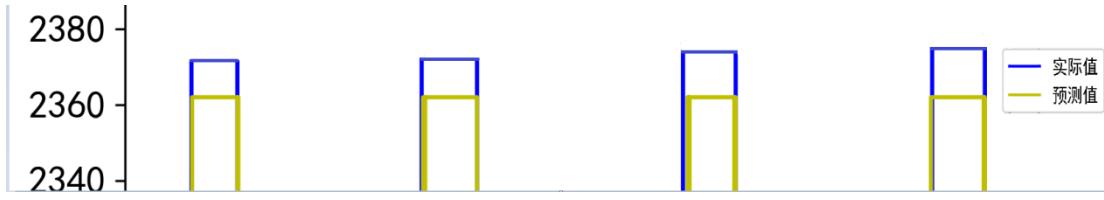


图 11. 优化分割函数后的模型输出标记

Figure 11. Model output mark after optimizing segmentation function

基于 LSTM 的端点检测算法尽管可以利用输入序列的前后相关性。但是，对于手势信号的边界处，即开始和结束位置的检测不灵敏，经常会出现一些持续时间较短的突起，使得判决函数不能及时的下降。此时，直接进行分割并会对手势造成误分割。我们基于错误样本进行分析，提出前文所描述的分割函数，可以看到在手势边界处，其输出概率值可以迅速下降，使得突起数大幅度减少，这解释了识别率的上升。

同时，为了验证所提出的端点检测方法的有效性，我们用双门限方法对本次数据集做了数据分割，并基于分割结果进行分类，实验结果表明，手势分类的结果和之前的工作获得的结果是相似的，识别率为 93.8%。

表 2 不同端点检测的识别结果

Table 2 Recognition results of different endpoint detection

Sensor Type	Sensor Number	endpoint detection	Accuracy
PVDF	8	Threshold Judge	94.0%
Electret	8	Threshold Judge	93.8%
Electret	8	Lstm Network	95.8%

对比表 2 进行结果分析，我们所提出的端点检测方法在进行连续手势信号分段时，其分段后在进行手势的分类识别，相比于传统的阈值判定方法在效果上有了明显的提升。这证明了我们之前的猜想：手势信号在时间上是具有相关性的时间序列，要找到其手势的起点和终点应该在当前帧数据的基础上融合过去的信息来共同决定。长短时记忆网络的这一优点弥补了阈值判定的这一缺陷。

5. 总结

我们提出了一种利用神经网络进行穿戴式鼠标中的鼠标手势信号端点检测的方法，该方法将 LSTM 用作网络模型的基本神经单元，对过去帧的信息加以利用并作用于当前帧的判

决。为了减少系统的复杂度，只提取了信号的短时能力和短时过零率。同时，为了抑制在信号边界处容易出现的突起，还引入一个基于统计数值的线性距离因子来适应性的调整网络的输出，减小了对手势识别的影响。为了进一步说明利用神经网络进行端点检测的有效性，我们还利用双门限方法对本文数据库进行了对比实验。结果表明，在手腕背侧进行类鼠标手势识别时，基于 LSTM 神经网络的端点检测算法对手势的分类识别具有更高的识别率，并且提出的方法无需先验阈值即可快速、自动的完成端点检测。

Reference

- [1] Hu, Yaohui, Kang, Wuwei, Fang, & Yong, et al. (2018). Piezoelectric poly(vinylidene fluoride) (pvdf) polymer-based sensor for wrist motion signal detection. *Applied Sciences*.
- [2] (2019). Method of finger motion recognition based on polyvinylidene fluoride sensor array. *Sensors and materials*, 31(9), 2931–2946.
- [3] Siddiqui, N. , & Chan, R. (2017). A wearable hand gesture recognition device based on acoustic measurements at wrist. *IEEE*.
- [4] Hu, Y. , Chen, Y. , Yi, X. , Zhong, J. , & Fang, Y. (2021). Wrist dorsal sensor array for finger movement recognition. *Sensors and Materials*, 33(8), 2825.
- [5] Zhang, Y. , Liu, B. , & Liu, Z. (2018). WristMouse: Wearable mouse controller based on pressure sensors. *2018 IEEE 15th International Conference on Wearable and Implantable Body Sensor Networks (BSN)*. IEEE.
- [6] Bulling, A. , Blanke, U. , & Schiele, B. (2014). A tutorial on human activity recognition using body-worn inertial sensors. *Acm Computing Surveys*, 46(3), 1–33.
- [7] 茹海峰, & 殷业(2005). 基于与图像相结合的语音端点检测方法研究. 第三届全国信息获取与处理学术会议.
Ru Haifeng, & Yin Ye (2005). Research on Speech Endpoint Detection Method Based on Combining with Images The Third National Academic Conference on Information Acquisition and Processing.
- [8] Birdwell, J. A. , Hargrove, L. J. , Weir, R. F. F. , & Kuiken, T. A. .

- (2014). Extrinsic finger and thumb muscles command a virtual hand to allow individual finger and grasp control. *IEEE transactions on bio-medical engineering*, 62(1).
- [9] Hargrove, L. J., Li, G. , Englehart, K. B. , & Hudgins, B. S. (2009). Principal components analysis preprocessing for improved classification accuracies in pattern-recognition-based myoelectric control. *IEEE Transactions on Biomedical Engineering*, 56(5), 1407–1414.
- [10] Ng, T. W. (2003). The optical mouse as a two-dimensional displacement sensor. *Sensors & Actuators A Physical*, 107(1), 21–25.
- [11] 李玉萍, 朴春俊, & 韩永成(2008). 一种改进的语音信号端点检测方法研究. 国外电子测量技术(1), 7–9.
Li Yuping, Park Chunjun, & Han Yongcheng(2008). Research on an improved endpoint detection method for speech signals Foreign Electronic Measurement Technology(1), 7–9.
- [12] 陆欢(2019). 基于卷积神经网络的音乐流派分类. 电子测量技术, 42(21), 4.
Lu Huan (2019). Music genre classification based on convolutional neural networks Electronic measurement technology, 42(21), 4.
- [13] 黎林, & 朱军(2013). 基于小波分析与神经网络的语音端点检测研究. 电子测量与仪器学报, 27(6), 7.
Li Lin, & Zhu Jun (2013). Research on Speech Endpoint Detection Based on Wavelet Analysis and Neural Networks Journal of Electronic Measurement and Instrumentation, 27 (6), 7.
- [14] Toledano, D. T. (2000). Neural network boundary refining for automatic speech segmentation. *Acoustics, Speech, and Signal Processing, 2000. ICASSP '00. Proceedings. 2000 IEEE International Conference on*. IEEE.
- [15] Iliya, S. , Menzies, D. , Neri, F. , Cornelius, P. , & Picinali, L. (2014). Robust impaired speech segmentation using neural network mixture model. *IEEE International Symposium on Signal Processing and Information Technology (IEEE ISSPIT 2014)*. IEEE.
- [16] Vuuren, V. V. , Bosch, L. T. , & Niesler, T. (2013). A Dynamic Programming

Framework for Neural Network-Based Automatic Speech Segmentation. Interspeech. .

- [17] Graves, A. , Mohamed, A. R. , & Hinton, G. (2013). Speech recognition with deep recurrent neural networks. IEEE International Conference on Acoustics (Vol. 38). IEEE.
- [18] Yang, J. , Su, P. , & Li, Z. (2019). An Automatic Blind Syllable Segmentation Model Based on Bi-directional LSTM. 2019 IEEE 2nd International Conference on Computer and Communication Engineering Technology (CCET). IEEE.