

EasiLTOM: 一种基于局部动态阈值的信号活动区间识别方法

周钧镨^{1,2} 王 念^{1,2} 崔 莉¹

¹(中国科学院计算技术研究所 北京 100190)

²(中国科学院大学 北京 100190)

(zjk934865517@163.com)

EasiLTOM: Signal Activity Interval Recognition Based on Local Dynamic Threshold

Zhou Junkai^{1,2}, Wang Nian^{1,2}, and Cui Li¹

¹(*Institute of Computing Technology, Chinese Academy of Sciences, Beijing 100190*)

²(*University of Chinese Academy of Sciences, Beijing 100190*)

Abstract In many practical applications of the Internet of things, the original collected signal data contains a lot of noise, especially in motion-related scenes. It is necessary to accurately identify the start and end points of the effective signal activity area from the one-dimensional time series signal with a lot of noise to support the relevant analysis. Existing recognition methods based on dual threshold rules are very sensitive to noise. The presence of noise will cause the calculated recognition threshold to fail to match the original data of the non-noise segment, which leads to the recognition of random noise data as signal activity intervals or missed signal activity interval. Recognition methods based on machine learning and deep learning require a large amount of sample data. In IoT scenarios with a small sample size, the model will have underfitting problems, thereby reducing recognition accuracy. In order to accurately identify the signal activity interval in a one-dimensional time series signal with a lot of noise and a small amount of data, a signal activity interval recognition based on local dynamic threshold EasiLTOM is proposed. This method calculates the recognition threshold based on the local signal, and it uses the shortest signal length to filter noise spikes, which can avoid the influence of random noise on the recognition of signal activity intervals, solve the problems of missed detection and false detection, and improve the recognition accuracy. In addition, EasiLTOM requires a small amount of data, which is suitable for IoT scenarios with scarce data. In order to verify the effectiveness of EasiLTOM, this study collects surface EMG data of 14 people in 3 months, and conducts comparative experiments using two public data sets. The results show that EasiLTOM method can achieve an average recognition accuracy of 93.17% for the signal activity range, which is 15.03% and 4.70% higher than the existing dual threshold and machine learning methods, and has practical value in motion analysis related scenes.

Key words signal activity interval recognition; local dynamic threshold; time series signal; noise filtering; Internet of things (IoT)

收稿日期:2020-08-28;修回日期:2021-04-07

基金项目:国家自然科学基金项目(61672498)

This work was supported by the National Natural Science Foundation of China (61672498).

通信作者:崔莉(lcui@ict.ac.cn)

摘 要 在诸多物联网实际应用中,原始采集信号数据多含有大量噪声,特别是在运动相关场景里,需从含大量噪声的一维时序信号中对有效信号活动区域起止点进行准确识别,以支持相关分析.已有的基于双阈值规则的识别方法对噪声十分敏感,噪声的存在会导致计算出的识别阈值无法匹配非噪声段的原始数据,从而导致将随机噪声数据识别为信号活动区间或者漏检信号活动区间.基于机器学习和深度学习的识别方法需要大量的样本数据,在样本量较小的物联网场景中模型会产生欠拟合问题,从而降低识别精度.为了对含有大量噪声且数据量少的一维时序信号中的信号活动区间进行准确识别,提出了一种基于局部动态阈值的信号活动区间识别方法 EasiLTOM(signal activity interval recognition based on local dynamic threshold).该方法基于局域信号计算识别阈值,并使用最短信号长度对噪声尖峰进行过滤,可避免随机噪声对信号活动区间识别的影响,解决漏检和误检问题,从而提高识别精度.此外, EasiLTOM 方法所需数据量小,适用于数据稀少的物联网场景.为验证 EasiLTOM 方法的有效性,该研究于 3 个月间采集了 14 人次的表面肌电数据,并使用 2 个公开数据集进行了对比实验.结果表明: EasiLTOM 方法对信号活动区间可达到平均 93.17% 的识别精度,相对于现有的双阈值和机器学习方法,分别提升了 15.03% 和 4.70%,在运动分析相关场景中具有实用价值.

关键词 信号活动区间识别;局部动态阈值;时序信号;噪声过滤;物联网

中图法分类号 TP391

随着科技的发展,物联网对于社会的重要性日益增加,物联网的应用和技术挑战也不断拓展.其中基于含噪一维物联网时序信号的有效活动区间起止点识别问题受到了关注,例如基于加速度信号的运动区间识别、基于声音信号的语音识别和基于肌电等生理信号的临床运动信息采集等.但是在物联网实际应用中,原始采集信号数据中多含有大量的噪声,特别是在运动相关场景里,大量噪声的存在会干扰信号活动区间起止点的识别准确性.传统的人工标记方法^[1]成本高且操作繁琐.为降低标记成本,有研究者提出了能够自动标记信号活动起止时间点的双阈值法^[2],但是双阈值法对于信号中的噪声十分敏感,难以满足对多样化的数据集和数据段的差异化信号进行标记的需求.于是一些研究者提出了基于机器学习^[3]或者深度学习^[4]的活动区间识别方法.该类方法对原始信号进行特征提取并据此训练分类器来识别信号活动区间.但此类方法需要大量的训练样本数据,不适用于样本量较小的场景.因此,研究一种抗噪声干扰能力强且适合小样本的高效准确的信号活动区间识别方法具有重要意义,本工作拟针对此问题开展.

1 相关工作

基于一维时序信号的数据分析是物联网场景中最常见的应用之一,例如基于表面肌电信号的手势识别^[5]和基于肌电信号的步态识别^[6]等.基于一

维时序信号的物联网数据分析通常需要算法首先进行信号活动区间识别,之后方可基于区间的识别结果进行后续的算法研究^[7].如果活动区间识别不精准,会导致后续分析无效等问题.例如在基于肌电信号的临床研究中^[8],错误的运动识别区间会导致待分析数据中引入无关信号和噪声数据段的问题,从而影响数据的可用性以及分析特征的有效性.因此,面向一维时序信号的活动区间识别具有十分重要的研究意义.

目前已有的基于一维时序信号的信号活动区间识别研究有 3 种类型:

- 1) 人工标记法.在该方法中,研究者根据原始信号对信号中的各个信号活动区间的开始时间点和结束时间点进行手工标记.但手工标记方法会花费大量的人力和时间成本,而且标记结果会根据研究者的经验呈现出不同程度的主观误差.此类方法的人力和时间成本需要降低,同时信号活动区间的识别精度也需要进一步提升.
- 2) 双阈值法.为实现信号活动区间的自动标记从而达到降低人工和时间成本的目的, Wang 等人^[2]提出了 DeepLap 方法,该方法提出使用基于双阈值的信号活动区间识别方法进行活动区间识别. DeepLap 利用高低 2 个阈值捕捉信号活动区间的开始时间点和结束时间点,低阈值对于信号的微小扰动十分敏感,因此可以用于捕捉细微的信号变化,达到提升信号活动区间起止点识别灵敏度和精度的目的.该方法还设置了信号高阈值,该高阈值用于再次

确定信号活动区间的产生,从而有效减少短时噪声尖峰的误识别问题.该方法的具体过程为:设置 1 个低阈值和 1 个高阈值,并将信号与低阈值和高阈值做比较.低阈值和高阈值确定方法是基于整体输入信号的均值和方差进行计算的,低阈值和高阈值的计算分别为

$$TH_{low-all} = \frac{k_1}{N_{all}} \sum_{i=1}^{N_{all}} x_i + \frac{k_2}{N_{all} - 1} \sum_{i=1}^{N_{all}} x_i^2, \quad (1)$$

$$TH_{high-all} = \frac{k_3}{N_{all}} \sum_{i=1}^{N_{all}} x_i + \frac{k_4}{N_{all} - 1} \sum_{i=1}^{N_{all}} x_i^2, \quad (2)$$

其中, N_{all} 为整体区间信号的采样点个数, x_i 为第 i 个采样点的信号值, k_1, k_2, k_3, k_4 分别为不同的阈值确定系数.

当信号值高于低阈值时,将此时间点记录为时间点 1.当信号值在始终不小于低阈值的情况下超越了高阈值时,算法将时间点 1 作为信号活动区间的开始时间点.当信号值低于低阈值时,算法将此时间点作为信号活动区间的结束时间点.DeepLap 方法实现了信号活动区间的自动标记,降低了人工和时间成本.但 DeepLap 是基于固定阈值的,对于物联网数据集来说,不同运动时间段、不同运动属性的信号之间固定阈值的最佳取值差异较大,难以适用于不同的数据集和数据段,这降低了信号活动区间的识别精度.比如在含有大量噪声的信号中,算法需要使用较高的方差和均值乘数,否则会造成非噪声的误识别;而在含有少量噪声的信号中,算法需要用到较低的方差和均值乘数,否则会造成运动区间的忽略捕捉问题.如图 1 所示,由于信号中含有的噪声较多,噪声信号会提升整体信号的均值和方差.因此在双阈值法中,基于全局信号均值和信号方差所计算出的低阈值和高阈值均会大于最优低阈值和最优高阈值.因此无法准确识别出包含噪声和多种运动的




Fig. 1 Recognition method of signal activity interval based on double threshold

图 1 基于双阈值的信号活动区间识别方法

一维时序信号中的起始点和终止点,造成了信号活动区间遗漏识别的问题.

3) 基于机器学习^[3]或者深度学习^[4]的活动区间识别方法.该方法对原始信号进行特征提取并据此训练分类器来识别信号活动区间.比如 Yamaba 等人^[9]使用支持向量机模型实现运动分类;Korpela 等人^[10]提出了一种结合 Dynamic Time Warping 和 k -NN 的运动识别分类模型;Nguyen 等人^[11]使用 k -NN 实现对不同行走类型的分类识别.基于传统机器学习的活动区间识别算法依赖于人工特征的提取,可能会造成原始信号的浪费.于是一些工作提出使用深度学习网络直接利用原始一维时序信号识别运动区间,比如 Quivira 等人^[12]使用 LSTM 利用肌电信号识别手指运动;Lee 等人^[13]通过构建一维的 CNN 实现了运动的分类识别.基于深度学习的方法虽然提升了识别的精度,但它们需要大量的训练样本数据,而某些物联网场景数据量较小,使用该方法通常会导致模型欠拟合,从而降低模型的泛化能力.

为了解决上述问题,本研究提出了 EasiLTOM: 一种基于局部动态阈值的信号活动区间识别方法.该方法的特点是通过利用局部一维信号的均值和方差对不同段信号区域的动态双阈值进行计算,并使用最短信号长度对噪声尖峰进行过滤,从而使算法能够适用于不同的信号环境,并且避免了局部噪声信号对识别阈值的影响,减少了信号特点在不同运动和不同噪声中存在差异所导致的信号活动区间误识别问题.此外,EasiLTOM 方法可适用于数据量较小的物联网场景.

2 基于局部动态阈值的信号区间识别方法原理

在物联网场景中,传感器可根据自身传感特征对环境数据进行感知.所感知的数据可描述为 $S = S_{signal} + S_{noise}$,其中 S_{signal} 为目标信号, S_{noise} 为噪声.在不同的物联网数据场景中,噪声的种类和幅值会有所差异.算法需要基于原始信号识别出信号中的活动区间的起始点和终止点.

虽然不同场景中的信号属性存在较大差异,但是活动信号区间的起始点和终止点都具有一些共同的特点,算法可以基于此进行高精度的信号活动区间的识别.在一维信号的活动区间识别场景中,活动信号区间起始点的特点是,自该时间点起,信号开始持续活跃,并在较高的幅值维持一段时间.活动信号

区间终止点的特点是, 自该时间点起, 信号开始静息, 信号的幅值较小。

考虑到活动信号区间起止点的特点, 本文提出了 EasiLTOM 方法, 其中局部是指长度为时间窗口 T 的信号区间。EasiLTOM 方法通过设置基于时间窗口 T 计算出的低阈值和高阈值对信号进行状态划分, 再通过对信号状态的判断确定信号活动区间的起止点。其中低阈值和高阈值是基于时间窗口 T 内的信号值的平均值和方差计算的, 当时时间窗口 T 过小时, 算法难以利用信号中全部的有效信息, 从而导致部分有效信号信息被浪费; 当时时间窗口过大时, 算法会引入更多的信号噪声, 导致识别阈值的适用性降低。所以 EasiLTOM 方法需要根据不同的信号类型设置合适的时间窗口 T 。此外, EasiLTOM 方法加入了最短信号长度 t_{\min} 对噪声尖峰进行过滤。由于 EasiLTOM 方法中的低阈值和高阈值是使用时间窗口为 T 的局部区域信号平均值和方差进行确定的, 从而能够避免噪声信号对识别阈值的影响, 并提升信号活动区间的识别精度, EasiLTOM 方法示意图如图 2 所示。在图 2 中, EasiLTOM 使用第 1 个局部信号区间的信号平均值和方差计算出低阈值 1 和高阈值 1 用于第 1 个信号区间的起止点(在图 2 中即为开始点 1 和结束点 1)识别; EasiLTOM 再使用第 2 个局部信号区间的信号平均值和方差计算出低阈值 2 和高阈值 2 用于第 2 个信号区间的起止点(在图 2 中即为开始点 2 和结束点 2)识别。下面本文将对信号活动区间的起始点和终止点的识别方法进行介绍。

2.1 信号活动区间的起始点和终止点识别方法

为识别信号活动区间的起止点, 本方法提出使用信号低阈值和信号高阈值共同用于信号活动区间




Fig. 2 Recognition method of signal activity interval based on local dynamic threshold EasiLTOM
图 2 基于局部动态阈值的信号活动区间识别方法 EasiLTOM 示意图

的起始点和终止点识别。当信号值高于信号低阈值, 视为信号开始波动, 方法进入状态 1, 并将此时间点记录为 t_1 。当信号在始终不低于低阈值的情况下高于信号高阈值时, 方法进入状态 2, 当信号值低于低阈值时, 方法将此时间点记录为 t_2 , 此时方法判断 t_2 与 t_1 的差值 Δt 是否大于最短信号长度 t_{\min} 。如果 $\Delta t \geq t_{\min}$, 方法此时可以确认 t_1 为信号活动区间的起始点, t_2 为信号活动区间的终止点; 如果 $\Delta t < t_{\min}$, 算法认为识别出的信号区间为噪声尖峰, 需要重新对信号活动区间的起止点进行识别。

为充分利用当前信号区间的信号特点, 并避免噪声的影响, 基于局部动态阈值的信号活动区间识别方法使用局部信号的均值和方差对低阈值和高阈值进行计算。由于信号时域特征中的均值和方差能够较好地反映出不同运动信号的特点, 所以基于局部信号的均值和方差对用于运动识别的低阈值和高阈值进行计算。方法根据此窗口中的信号均值及方差分别对低阈值和高阈值进行计算, 低阈值的计算为

$$TH_{\text{low-local}} = \frac{k_5}{N_{\text{local}}} \sum_{i=1}^{N_{\text{local}}} x_i + \frac{k_6}{N_{\text{local}} - 1} \sum_{i=1}^{N_{\text{local}}} x_i^2, \quad (3)$$

其中, N_{local} 为局部区间信号的采样点个数, x_i 为第 i 个采样点的信号值, k_5 和 k_6 分别为不同的低阈值确定系数。

高阈值的计算为

$$TH_{\text{high-local}} = \frac{k_7}{N_{\text{local}}} \sum_{i=1}^{N_{\text{local}}} x_i + \frac{k_8}{N_{\text{local}} - 1} \sum_{i=1}^{N_{\text{local}}} x_i^2, \quad (4)$$

其中, N_{local} 为局部区间信号的采样点个数, x_i 为第 i 个采样点的信号值, k_7 和 k_8 分别为不同的高阈值确定系数。

2.2 EasiLTOM 流程及描述

本文设计了 EasiLTOM 的算法流程, 如算法 1 所示:

算法 1. EasiLTOM 算法。

输入: $signal, T, t_{\min}$;

输出: 开始时间点、结束时间点。

- ① 算法初始化为状态 0;
- ② 基于时间窗口 T 使用局部平均信号值和局部信号方差值计算低阈值和高阈值;
- ③ if 信号值高于低阈值
- ④ 算法进入状态 1, 记录时间点 t_1 ;
- ⑤ if 信号值在不低于低阈值的情况下高于高阈值
- ⑥ 算法进入状态 2;

⑦ if 信号值低于低阈值
⑧ 算法记录时间点 t_2 ;
⑨ end if
⑩ end if
⑪ end if
⑫ if $t_2 - t_1 \geq t_{\min}$
⑬ 输出开始时间点 t_1 和结束时间点 t_2 , 算法恢复状态 0;
⑭ else
⑮ 算法保持状态 0;
⑯ end if

算法 1 可以对信号活动区间的起始时间点和终

止时间点进行识别,其流程如图 3 所示.下面结合流程图对算法 1 进行阐述.算法首先初始化为 0 状态,然后算法基于时间窗口 T 使用局部信号区间的平均值和方差计算低阈值和高阈值.之后算法判断信号值高于低阈值的时间点,当信号值高于低阈值时,算法进入状态 1,并将此时间点标记为 t_1 .如果信号值在始终不低于低阈值的情况下高于高阈值,算法进入状态 2,当信号值低于低阈值时,算法将此时间点记录为 t_2 ,此时算法判断时间点 t_2 与时间点 t_1 的差值 Δt 是否大于最短信号长度 t_{\min} ,如果 $\Delta t \geq t_{\min}$,算法分别将 t_1 和 t_2 作为信号活动区间的起始点和终止点进行输出,最后算法恢复 0 状态.

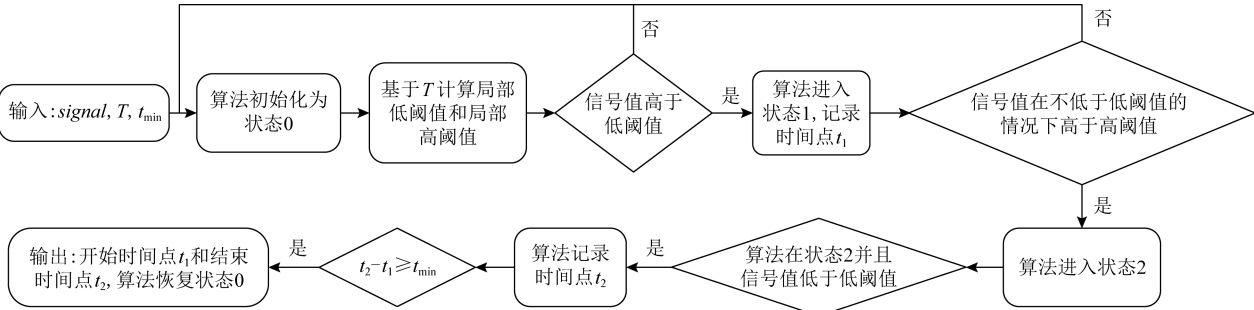


Fig. 3 Flow of signal interval recognition algorithm based on local dynamic threshold
图 3 基于局部动态阈值的信号区间识别算法流程图

3 实验分析

为验证本文提出的 EasiLTOM 方法的准确性,本节将 EasiLTOM 方法与 DeepLap 方法,以及基于机器学习的信号活动区间识别方法进行对比实验.实验内容包括方法的识别准确性验证,方法在小数据量场景中的识别精度对比.实验数据包括本研究实际部署采集的肌电数据集 EasiEMG 及 2 个 UCI 公开数据集中的部分数据.

3.1 实验设计

为验证本方法的有效性,本节首先对本文所选用的实际数据集的采集情况(3.1.1 节)以及选择的公开数据集(3.1.2 节)的情况进行介绍.之后本节总结和对比 EasiLTOM 方法、DeepLap 方法以及基于机器学习的信号活动区间识别方法在多个场景中的识别精度.

3.1.1 肌电数据集采集情况

肌电信号是一种人体生理信号,它记录了肌肉细胞产生的收缩力^[14].表面肌电信号是浅层肌肉肌电信号和神经干上电活动在皮肤表面的综合效应,

能在一定程度上反映神经肌肉的活动;表面肌电信号在测量上具有无创伤等优点,并且可以作为肌肉疼痛疾病诊断的有效依据^[15],所以广泛应用于康复医学等领域.但肌肉疼痛疾病的诊断依赖于表面肌电信号的运动区间识别.为验证 EasiLTOM 方法的有效性,本研究组在 2017-09—2017-11 期间于中国中医科学院西苑医院实际部署了一套肌电信号采集装置,对非特异性腰痛患者和正常人的肌电信号进行采集.在采集期间,该系统共采集到 14 位受试者的肌电信号,构成肌电信号数据集 EasiEMG.每次




Fig. 4 Schematic diagram of EMG test exercise
图 4 肌电测试运动示意图

采集时,受试者执行 3 次屈曲放松运动(如图 4(a)所示)、1 次左足桥式运动(如图 4(b)所示)、1 次右足桥式运动(如图 4(c)所示)、1 次双足桥式运动(如图 4(d)所示)和 1 次 Biering Sorensen 等长运动(如图 4(e)所示).在肌电信号的采集过程中,各种运动的肌电信号按时间顺序串行拼接,每 2 种运动之间无序运动,无序运动的肌电信号会作为噪声存在于整体肌电信号中.

3.1.2 公开数据集情况

本文选择了 UCI 公开数据集中的 2 个手部动作肌电信号测试数据集手部动作集 1(sEMG for basic hand movements data set database 1, Hand movements 1)^[16]和手部动作集 2(sEMG for basic hand movements data set database 2, Hand movements 2)^[17],每个测试数据集中含有 6 个手部动作的多次肌电信号测试.分别选择手部动作集 1 中的 1 名男性受试者的 180 次肌电测试信号和手部动作集 2 中的 1 名男性受试者的 600 次肌电测试信号进行信号活动区间的识别,肌电信号中存在无序手部运动的肌电信号作为噪声.

3.2 实验结果

3.2.1 识别精度验证

为验证 EasiLTOM 方法的有效性及其识别精度,本节分别使用 EasiLTOM,DeepLap 以及机器学习方法对数据集 EasiEMG 和 2 个 UCI 公开数据集中数据进行了信号活动区间的识别,其中识别精度与误检率和漏检率的关系为

$$P_{acc} = 1 - P_{false} - P_{missed}, \tag{5}$$

其中, P_{acc} 为识别精度, P_{false} 为误检率, P_{missed} 为漏检率.由于随机森林模型^[18]对于噪声的稳定性好,分类精度高,且具有较强的泛化能力,适用于信号活动

区间的起止点识别问题,所以本文选择随机森林模型作为机器学习方法以识别信号活动区间的起止点,EasiLTOM,DeepLap 及机器学习方法对于各数据集的识别精度结果如表 1 所示:

Table 1 EasiLTOM, DeepLap and Machine Learning Recognition Accuracy Results for Each Data Set

表 1 EasiLTOM,DeepLap 及机器学习各数据集的识别精度结果

数据集	DeepLap	机器学习	EasiLTOM	%
手部动作集 1	85.00	81.54	90.56	
手部动作集 2	78.00	87.57	91.00	
EasiEMG	71.43	96.29	97.96	
平均值	78.14	88.47	93.17	

实验结果表明:EasiLTOM 方法对于信号活动区间的识别精度超过了 DeepLap 方法以及基于机器学习的信号活动区间识别方法,达到了平均 93.17% 的识别精度,EasiLTOM 方法的识别精度比双阈值法的识别精度高 15.03%,比基于机器学习的信号活动区间识别方法的识别精度高 4.70%.

3.2.2 小数据量场景中的识别精度对比

许多物联网场景中的数据量稀少,因此需要一种适用于小数量场景的信号活动区间识别方法.为验证 EasiLTOM,DeepLap 及机器学习方法在小数据量场景中的识别精度,本文使用 EasiLTOM,DeepLap 及机器学习方法对各个数据集分别在数据量为 12 条和 18 条的场景下进行了信号活动区间的识别,识别精度结果如图 5 所示.

通过实验结果可以得到,当数据量为 12 条和 18 条时,机器学习方法对于各个数据的平均识别精度分别为 79.44% 和 83.12%,EasiLTOM 方法对于

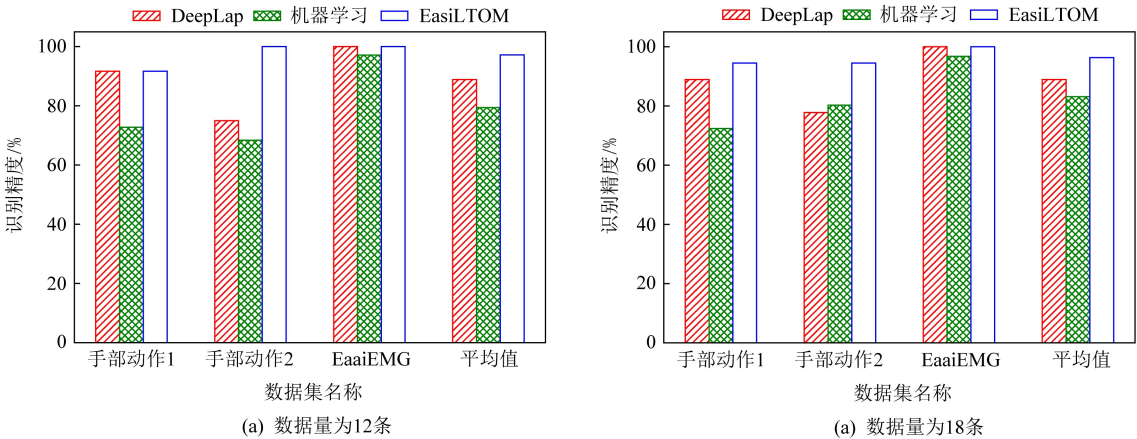


Fig. 5 Recognition accuracy of EasiLTOM, DeepLap and machine learning methods

图 5 EasiLTOM,DeepLap 及机器学习方法的识别精度

各个数据的平均识别精度分别为 97.22%和 96.29%，EasiLTOM 方法的识别精度分别比机器学习方法高 17.78%和 13.17%。

通过实验在小数据量场景中的识别精度结果对比可得,在数据量稀少的物联网场景中,机器学习方法因为模型欠拟合,导致模型的泛化能力变差,从而使识别精度下降.而 EasiLTOM 方法因为识别阈值的适用性在数据量稀少的场景中相较于在数据量大的场景中更好,从而提升了信号活动区间的识别精度.所以,EasiLTOM 方法仅需使用少量数据即可对信号活动区间进行准确地识别,十分适用于数据量稀少的物联网数据场景.

4 讨 论

本文提出了基于局部动态阈值信号活动区间识别方法 EasiLTOM,EasiLTOM 方法的特点是:可以有效地克服将噪声信号误检为信号活动区间或信号活动区间漏检的现象,而且避免了信号中的随机噪声对于信号属性不同的区间识别所带来的影响,从而提升了信号活动区间的识别准确率.此外,EasiLTOM 方法仅需使用少量数据即可对信号活动区间进行准确的识别,十分适用于数据量较小的物联网数据场景.

相对于现有的信号活动区间识别方法 DeepLap 来说,EasiLTOM 由于使用了局部动态阈值机制,所以方法对噪声的容忍度高,能够适用于更广泛的信号活动区间识别的物联网场景.例如在 3.2 节中,EasiLTOM 方法对于信号活动区间的识别精度超过了其他方法,达到了平均 93.17%的识别精度,比双阈值法的识别精度高 15.03%,比基于机器学习的信号活动区间识别方法的识别精度高 4.70%。

EasiLTOM 适用于含有噪声的一维物联网场景,因为在确定识别低阈值和高阈值时,方法综合使用了信号的局部区间的信号均值和信号方差,充分利用了当前信号区间的信号特点,避免了信号中其他段信号的噪声影响,并且加入了最短信号长度对噪声尖峰进行过滤,从而使得信号中的噪声不会对方法的适用性产生影响.例如在 EasiEMG 数据集中,肌电信号数据中含有因无序运动造成的噪声,针对此类信号,在本文 3.2 节的结果中可以看到本方法的信号活动区间识别精度最优.针对 UCI 公开数据集中的噪声,在本文 3.2 节中可以看到本方法的信号活动区间识别精度最优。

EasiLTOM 方法适用于数据量稀少的物联网数据集中,对于小数量场景,EasiLTOM 方法因为识别阈值的适用性在数据量稀少的场景中相较于在数据量大的场景中更好,所以提升了信号活动区间的识别精度,而机器学习方法因为在小数据量场景中模型欠拟合导致识别精度下降.比如在 3.2 节中,数据量为 12 条和 18 条时,EasiLTOM 方法的平均识别精度分别比机器学习方法高 17.78%和 13.17%。

5 结 论

本文针对含有大量噪声的一维时序信号难以确定活动区间的开始和结束时间点的问题,提出了一种基于局部动态阈值的信号活动区间识别方法 EasiLTOM.相对于单阈值和双阈值的信号活动区间识别方法,EasiLTOM 有效地避免了信号中的随机噪声对于信号属性不同的区间识别所带来的影响,解决了信号活动区间的漏检和误检问题,从而提高了信号活动区间的识别精度.相对于机器学习方法,EasiLTOM 方法具有识别精确度高、所需数据量少等优点,使其更加适用于数据量稀少的物联网场景.通过对比实验证明,EasiLTOM 方法达到了平均 93.17%的识别精度,EasiLTOM 方法的识别精度比双阈值法的识别精度高 15.03%,比基于机器学习的信号活动区间识别方法的识别精度高 4.70%,达到了目前最佳的运动区间识别精度.EasiLTOM 方法适用于含有大量噪声的一维时序信号活动区间识别场景。

作者贡献声明:周钧锴负责论文的写作及实验;王念负责论文的修改及实验;崔莉负责整体指导及论文的修改。

参 考 文 献

[1] Zawawi T N S T, Abdullah A R, Shair E F, et al. EMG signal analysis of fatigue muscle activity in manual lifting [J]. Journal of Electrical Systems, 2015, 11(3): 319-325

[2] Wang Nian, Zhang Zhe, Xiao Jing, et al. DeepLap: A deep learning based non-specific low back pain symptomatic muscles recognition system [C/OL] //Proc of the 16th Annual IEEE Int Conf on Sensing, Communication, and Networking(SECON). Piscataway, NJ: IEEE, 2019 [2020-06-02]. <https://ieeexplore.ieee.org/document/8824868>

[3] Shair E F, Ahmad S A, Marhaban M H, et al. EMG processing based measures of fatigue assessment during manual lifting [J]. BioMed Research International, 2017, 1(1): 2017-2029

- [4] Geng Weidong, Du Yu, Jin Wenguang, et al. Gesture recognition by instantaneous surface EMG images [J]. Scientific Reports, 2016, 6(1): 1-8
- [5] Rahimi A, Benatti S, Kanerva P, et al. Hyperdimensional biosignal processing: A case study for EMG-based hand gesture recognition [C/OL] //Proc of 2016 IEEE Int Conf on Rebooting Computing(ICRC). Piscataway, NJ: IEEE, 2016; [2020-06-02]. <https://ieeexplore.ieee.org/abstract/document/7738683>
- [6] Ryu J, Lee B, Kim D. EMG signal-based gait phase recognition using a GPES library and ISMF [C] //Proc of Int Conf of the IEEE Engineering in Medicine & Biology Society. Piscataway, NJ: IEEE, 2016; 2003-2006
- [7] Thirumuru R, Gangashetty S, Vuppala A. Improved vowel region detection from a continuous speech using post processing of vowel onset points and vowel end-points [J]. Multimedia Tools and Applications, 2017, 77(2): 4753-4767
- [8] Semplicini C, Arzel M, Stojkovic T, et al. EMG diagnosis of McArdle disease with long exercise test [J]. Neuromuscular Disorders, 2016, 26(2): S198-S210
- [9] Yamaba H, Kurogi T, Aburada K, et al. On applying support vector machines to a user authentication method using surface electromyogram signals [J]. Artificial Life and Robotics, 2018, 23(1): 87-93
- [10] Korpela J, Maekawa T, Eberle J, et al. Tree-structured classifier for acceleration-based activity and gesture recognition on smartwatches [C/OL] //Proc of IEEE Int Conf on Pervasive Computing and Communication Workshops. Piscataway, NJ: IEEE, 2016 [2020-06-02]. <https://ieeexplore.ieee.org/abstract/document/7457053>
- [11] Nguyen N D, Bui D T, Truong P H, et al. Classification of five ambulatory activities regarding stair and incline walking using smart shoes [J]. IEEE Sensors Journal, 2018, 18(13): 5422-5428
- [12] Quivira F, Koike T, Wang Ye, et al. Translating sEMG signals to continuous hand poses using recurrent neural networks [C] //Proc of IEEE EMBS Int Conf on Biomedical & Health Informatics. Piscataway, NJ: IEEE, 2018; 166-169
- [13] Lee S, Sang M, Cho H. Human activity recognition from accelerometer data using convolutional neural network [C] //Proc of IEEE Int Conf on Big Data & Smart Computing. Piscataway, NJ: IEEE, 2017; 131-134
- [14] Dorin C, David S, Engi D, et al. High-level control algorithm based on sEMG signalling for an elbow joint SMA exoskeleton [J]. Sensors, 2018, 18(8): 2522-2532
- [15] Khan M, Singh J, Tiwari M. A multi-classifier approach of EMG signal classification for diagnosis of neuromuscular disorders [J]. International Journal of Computer Applications, 2016, 133(4): 13-18
- [16] Sapsanis C, Georgoulas G, Tzes A, et al. Improving EMG based classification of basic hand movements using EMD [C] //Proc of the 35th Annual Int Conf of the IEEE Engineering in Medicine and Biology Society 13(EMBC 13). Piscataway, NJ: IEEE, 2013; 5754-5757
- [17] Sapsanis C. Recognition of basic hand movements using electromyography [D]. Patras: University of Patras, 2013
- [18] Shaik S, Ravibabu U. Classification of EMG signals based on curvelet transform and random forest tree method [J]. Journal of Theoretical and Applied Information Technology, 2017, 95(24): 6856-6866



Zhou Junkai, born in 1998. PhD candidate. His main research interests include machine learning and artificial intelligence.

周钧锴, 1998 年生. 博士研究生. 主要研究方向为机器学习和人工智能.



Wang Nian, born in 1993. PhD. His main research interests include Internet of things, wireless sensor network, machine learning and transfer learning.

王 念, 1993 年生. 博士. 主要研究方向为物联网、无线传感器网络、机器学习和迁移学习.



Cui Li, born in 1962. PhD, professor, PhD supervisor, IET fellow, RSC fellow. Her main research interests include sensor technology, wireless sensor networks and Internet of things.

崔 莉, 1962 年生. 博士, 教授, 博士生导师, IET 会士, RSC 会士. 主要研究方向为传感器技术、无线传感器网络和物联网.