

基于 TiCNN-DRSN 模型的 sEMG 手势 识别算法的研究^{*}

周国良 张道辉 郭小萍

(沈阳化工大学 沈阳 110000)

摘要: 基于表面肌电信号和模式识别的手势识别方法在康复手领域中具有广阔的应用前景。提出一种基于表面肌电信号的手部姿势识别方法,以预测手部的 52 种动作。为解决表面肌电信号易受干扰的问题,提高对表面肌电信号的分类效果,提出了 TiCNN-DRSN 网络,主要作用是在拥有噪声的情况下能够更好的识别率,减少滤除噪声的时间。TiCNN 网络使用卷积核 Dropout 和极小批量训练,为卷积神经网络引入训练干扰并且增加了模型的泛化性;DRSN 网络可以有效的剔除 sEMG 信号中的冗余信号,减少信号噪声干扰。TiCNN-DRSN 网络在不需要任何降噪预处理的前提下,取得了很高的抗噪与自适应性能。本模型在 Ninapro 数据库上的识别率达到 $97.43\% \pm 0.8\%$ 。

关键词: 表面肌电信号;抗噪声;TiCNN-DRSN 网络

中图分类号: TP242 **文献标识码:** A **国家标准学科分类代码:** 510.4030

Research on sEMG gesture recognition algorithm based on TiCNN-DRSN model

Zhou Guoliang Zhang Daohui Guo Xiaoping

(Shenyang University of Chemical Technology, Shenyang 110000, China)

Abstract: The gesture recognition method based on surface electromyography and pattern recognition has a broad application prospect in the field of rehabilitation hand. In this paper, a hand gesture recognition method based on surface electromyography (sEMG) is proposed to predict 52 hand movements. In order to solve the problem that surface EMG signals are easily disturbed and improve the classification effect of surface EMG signals, TiCNN-DRSN network is proposed, whose main function is to better identify the noise and reduce the time for filtering the noise. Ti is a TiCNN network, in which convolutional kernel Dropout and minimal batch training are used to introduce training interference to the convolutional neural network and increase the generalization of the model; DRSN is a deep residual shrinkage network, which can effectively eliminate redundant signals in sEMG signals and reduce signal noise interference. TiCNN-DRSN has achieved high anti-noise and adaptive performance without any noise reduction pretreatment. The recognition rate of this model on Ninapro database reaches $97.43\% \pm 0.8\%$.

Keywords: sEMG; noise immunity; TiCNN-DRSN network

0 引言

表面肌电信号(surface electromyography, sEMG)是人体产生的一种生物电信号,反映了肌肉活动的相关信息。sEMG 信号的幅值通常在 $0 \sim 1.5$ mV 之间,主要能量集中在 $20 \sim 150$ Hz 的频率范围内。与肢体运动相比,sEMG 信号通常会提前 $20 \sim 150$ ms 产生^[1]。这种超前性使得基于 sEMG 的手势识别在人机交互、康复辅助等领域获得了广

泛应用。

近年来,随着机器学习和深度学习技术的不断进步,诸多学者针对 sEMG 手势识别问题提出了大量创新性算法。例如, Arozi 等^[2]提出了基于主成分分析(principal component analysis, PCA)和人工神经网络(artificial neural network, ANN)的单通道 sEMG 模式识别方法,实现了九种手势的识别; Bai 等^[3]则设计了一种基于轻量级卷积神经网络(convolutional neural networks, CNN)和长短期记忆

(long short-term memory, LSTM)的优化算法,在复杂手势分类上取得了 91.4% 的准确率。此外, Ma 等^[4]提出了基于深度残差网络的手势识别方法,也取得了不错的识别性能。这些基于机器学习和深度学习的方法,在一定程度上提高了 sEMG 手势识别的准确率和鲁棒性。

然而,现有方法在实际应用中仍存在问题。首先, sEMG 作为一种微弱的生物电信号,其易受环境噪声(如 50Hz 工频干扰、肌电漂移等)的影响^[5]即使进行预处理也很难彻底消除噪声。这种噪声干扰会对识别结果造成不利影响。此外,由于个体差异以及同一个人不同状态下的肌肉活动存在差异,导致采集到的 sEMG 信号呈现出较大的个体差异和非稳定性^[6],给模型的泛化性造成挑战。因此,设计一种既能有效抗噪干扰,又能增强模型泛化性的 sEMG 手势识别算法,对于提高实际应用效果至关重要。

针对上述问题,本文提出了一种基于具有训练干扰的卷积神经网络-深度残差收缩网络(convolutional neural networks with training interference-deep residual shrinkage networks, TiCNN-DRSN)模型的 sEMG 手势识别算法。该算法融合了 TiCNN 网络和 DRSN 网络的优势,在保持较低复杂度的同时,能够有效提高对含噪声 sEMG 信号的识别准确性和鲁棒性,为 sEMG 手势识别技术的实际应用提供新的解决方案。本文提出的 TiCNN-DRSN 算法在吸收了基于具有训练干扰的卷积神经网络(convolutional neural networks with training interference, TiCNN)和深度残差收缩网络(deep residual shrinkage networks, DRSN)的优势基础上,进一步增强了对噪声 sEMG 信号的抗干扰能力和泛化性,为解决 sEMG 手势识别领域的关键问题提供了新的思路。该算法的创新性和实用性为该领域的进一步发展提供了有益探索,具有重要的理论价值和应用前景。

1 DRSN 网络

深度残差收缩网络是在深度残差网络上进行改进^[7],由深度残差网络、注意力机制和软阈值函数三者集成,DRSN 网络的原理主要为,通过注意力机制关注无关特征,然后经由软阈值函数将无关特征的权重值置为零,从而增强网络对于有用特征的提取。

开发 DRSN 网络主要是为了降低噪声对分类结果的影响。首先,在对 sEMG 进行分类时,数据里难免会有一些噪声例如:高斯噪声、拉普拉斯噪声等,其次上一节也说过, sEMG 信号是一种微弱信号,其采集出来的信号本身就会受到环境影响。其次,对于采集到的肌电信号,在正常情况下,占据大部分比例的是休息或放松情况下的无太大波动的数据,这类数据在广义的情况下也能被归类为噪声,或者说是冗余数据。

1.1 软阈值

软阈值的方法对于信号去噪来说是关键的,绝对值小于某个阈值的特征将被删除,大于该阈值则会被保留。例

如,经典的小波阈值处理信号噪声方法^[8],通常是由小波分解、软阈值处理和小波重构三个步骤组成,而阈值化的关键任务就是设计个滤波器将信号中的噪声转化为接近零的特征,从而将其滤除。软阈值的公式如下:

$$\frac{\partial y}{\partial x} = \begin{cases} 1, & x > \tau \\ 0, & -\tau \leq x \leq \tau \\ 1, & x < -\tau \end{cases} \quad (1)$$

其中, x 表示输入特征, y 表示输出特征 τ 为阈值。由式(1)可以看出,软阈值的导数不是 0 就是 1,因此它可以大大降低深度学习算法中梯度消失与梯度爆炸的风险。

软阈值函数^[9]有 3 个条件必须满足:第一,阈值必须为正数;其次,阈值不能大于输入信号的最大值;最后,每个样本应该有自己独立的阈值,这是因为每个样本所含噪声量是不同的,不能用一个固定的阈值去面对所有样本。并且如果将同一阈值应用于所有 sEMG 信号通道,那么可能有关键的信息被当成噪声滤除。因此 DRSN 里的软阈值模块可以自动学习滤波器,并为各个 sEMG 信号通道分配,阈值效果样式如图 1 所示。




图 1 阈值效果样式

1.2 注意力机制

注意力机制在计算机视觉里的应用范围比较广。注意力机制就是将注意力集中于局部关键信息的机制^[10],可以分为两步:首先,通过扫描全局,发现有用信息;其次,增强有用信息并抑制冗余信息。

挤压激励网络(squeeze-and-excitation network, SENet)是一种基于注意力机制较新的深度学习新方法^[11], SENet 模块如图 2 所示,能够自动学习得到一组权重,对 sEMG 信号的各个通道进行加权,然后将这组权重与各个通道进行相乘,调整各个通道特征的大小。




图 2 SENet 模块

这样每个样本都有自己独立的权重集, SENet 的详细子模块如图 3 所示。




图 3 SENet 的详细子模块

1.3 DRSN 的结构

DRSN 网络借鉴上述的 SENet 子网络结构,在深度注意力机制下添加软阈值,DRSN 网络的基本模块如图 4 所示。通过图 4 中的子网络可以学习一组阈值,进而对每个通道进行软阈值化^[12]。




图 4 DRSN 基本模块

将一定数量的基本模块与卷积层、批处理归一化、激活函数、全连接的输出层进行叠加就可以得到一个完整的 DRSN 网络^[13],完整的 DRSN 结构如图 5 所示。

2 TiCNN

TiCNN 模型^[14]的基础是 Oxford 的 Visual Geometry Group 的组提出的用于大规模图像识别的深度卷积网络 (visual geometry group-very deep convolutional Networks, VGG-Net)。与 VGG-Net 相比,它增加了第一层卷积层的卷积核的宽度,在第一层卷积层后又添加了随机失活 (Dropout)层和批归一化(batch normalized)层,训练时减少




图 5 DRSN 结构

了批大小。该模型具有较好的抗噪性能,适应能力也优于其他方法。TiCNN 模型的结构和参数如图 6 所示。在使用了第一层大卷积核进行卷积时,先对卷积核进行 Dropout 操作,这是对 TiCNN 模型的第一个训练干扰,目的是给 TiCNN 训练时提供不完整的信号,从而强化 TiCNN 面对信号缺失时候的分类能力。之后在使用极小的批处理(mini-batch)来进行批量训练,这是设置的第二个干扰,目的是为了增大 mini-batch 的均值方差的变化范围,增强模型对测试集在均值方差发生偏移的容忍程度。

part I	Convolutional layer: kernel size 64×1, step size 16, channels 16. Dropout layer BN layer Pooling layer:Kernel size 2×1. Step size 2, channels 16
part II	Convolutional layer: kernel size 3×1, step size 1, channels 32. Dropout layer BN layer Pooling layer:Kernel size 2×1. Step size 2, channels 32
×4	Convolutional layer: kernel size 3×1, step size 1, channels 64. Dropout layer BN layer Pooling layer:Kernel size 2×1. Step size 2, channels 64
	Fully-connected layers Softmax

图 6 TiCNN 模型的结构和参数

3 TiCNN-DRSN

在单独使用 DRSN 网络对肌电信号进行识别时发现网络对于未出现的样本所进行的识别会有一定的偏差,这种偏差源自于采集环境以及个体差异,不同湿度下和不同体脂率下获取的肌电数据会有较大的波动。并且,DRSN

网络本身的应用环境是再机器故障检测这一方面,此环境下的数据除故障信号外其余信号数据相对平缓。因此,DRSN 中的软阈值可能会导致分辨不出数据是否重要或者是分辨不出数据是否为噪声,从而降低网络在应用过程中的识别率。所以,为了提高网络的泛化性和普世性,在基于 DRSN 网络的前提下引进了 TiCNN 网络,来弥补 DRSN 的泛化性。

整体 TiCNN-DRSN 网络结构由图 7 所示,首先,因为 ninapro 数据库对数据采集时进行了统一的标准化,所以,对数据用较大的卷积核进行卷积,使得数据能够分化成数据长度较小的;并且,能包含大部分独立动作信息的数据块,再进行顺序打乱用以增加网络对数据的丢失的抵抗能力,但因为数据具有一维时间性进行此操作会降低分类精度,所以此层中的 Dropout 将随机更改为了顺序,即对首位两个方向进行 Dropout。然后,在对各个具有独立动作信息的数据块再次切割为同一动作的不同次序,用以提高网络对于不同数据的普适性。




图 7 TiCNN-DRSN 模型结构

最后,对 DRSN 结构中的卷积核替换为 TiCNN 中的卷积核,以此获得对噪声以及重复更好的容忍能力、更好的分类能力和更快的训练速度。另外,因为卷积核先为大尺寸,然后在慢慢降低,这使得整体结构的感受野变得更为宽阔,不会使得网络拘泥于某一段数据片段,从而降低软阈值对网络影响。后续的 DRSN 中的卷积层则是使用大卷积核和极小的 mini-batch 来增强干扰,提高网络对于不同数据个体之间的适应性。

在模型训练过程中,使用 Adam 作为优化器,初始学习率设置为 0.000 2,设输入数据大小为 1 024,刚好也近似肌电信号拆解的倍数,第一层卷积层步数为 16,第二层卷积层步数为 8,DRSN 模型中的步长都为 2,最后加入两层全连接层和 Dropout 层交替分布来提高精度,新模型的卷积核大小、步长、通道数等参数如表 1。

本实验的主要目的是验证采用 TiCNN-DRSN 模型在

表 1 TiCNN-DRSN 相关参数

层	卷积核	步长	通道	是否补零
Conv1D-1	64×1	8×1	16	Yes
Max-pooling	2×1	2×1	16	No
Conv1D-2	32×1	3×1	32	Yes
Max-pooling	2×1	2×1	32	No
Conv1D-3	3×1	1×1	64	Yes
Max-pooling	2×1	2×1	64	No
Conv1D-4	3×1	1×1	64	Yes
Max-pooling	2×1	2×1	64	No
DRSN(ResNet18)			128	
			256	
			512	
			1 024	
Max-pooling	2×1	2×1	1 024	No
Dense	128		1	
Dense	24		1	

含噪声 sEMG 数据上的手势识别性能,并与其他主要方法进行对比。

实验数据采用 Ninapro 公开数据集,该数据集包含了 52 种手部动作的多通道 sEMG 信号。为了模拟实际应用中可能存在的噪声干扰,本文人为在原始数据上添加了不同信噪比(SNR)的高斯白噪声^[15]。

在实验设置中,本文分别构建了 TiCNN、DRSN、SVM、CNN 四种对比模型,并与本文提出的 TiCNN-DRSN 模型进行对比。各模型的超参数如下:

- TiCNN: 第一层卷积核大小 64×1 ,步长 8×1 ;后续层逐步减小
- DRSN: ResNet18 结构,通道数依次为 128-256-512-1 024
- SVM: 高斯核函数,惩罚参数 $C=1.0$, $\gamma=0.01$
- CNN: 18 层结构,通道数为 256

所有模型采用相同的训练集/验证集/测试集划分,训练过程中使用 Adam 优化器,初始学习率 0.000 2。训练轮次设置为 15、25、35、45 轮,观察各模型在不同噪声条件下的收敛性和识别准确率。无噪声对照实验结果如表 2、图 8 所示;有噪声对照实验结果如表 3、图 9 所示。

表 2 无噪声对照实验结果

无噪声	迭代次数	15	25	35	45
模型及准确率	TiCNN-DRSN	72.4	89.9	94.1	97.1
	TiCNN	75.9	77.7	78.8	79.9
	DRSN	73.6	79.7	86.4	92.4
	SVM	63.7	78.6	83.2	89.6
	CNN	58.3	64.5	70.1	76.2




图 8 无噪声对比实验结果

表 3 有噪声的对比实验结果

有噪声	迭代次数	15	25	35	45
模型及准确率	TiCNN-DRSN	60.4	81.9	89.3	96.8
	TiCNN	62.4	71.8	76.9	78.9
	DRSN	64.5	77.6	85.3	93.4
	SVM	61.1	70.6	79.4	88.9
	CNN	50.2	59.4	65.9	69.3




图 9 有噪声对比实验结果

如表 2 所示,在无噪声条件下,TiCNN-DRSN 模型的识别率随训练轮次的增加不断提高,在 45 轮时达到了 97.1% 的较高水平,明显优于 TiCNN、DRSN 和 SVM 等其他对比模型。这表明 TiCNN-DRSN 模型在干净数据上具有较强的学习和泛化能力。

当引入噪声干扰时(表 3),TiCNN-DRSN 模型仍能保持较高的识别水平,45 轮训练后达到 96.8%,远高于其他模型。这说明 TiCNN-DRSN 在抗噪性方面具有显著优势,可以有效应对实际应用中可能存在的噪声干扰。

为了进一步验证 TiCNN-DRSN 模型的性能,还将其与报告的其他主流 sEMG 手势识别算法进行了对比。结果如表 4 示,TiCNN-DRSN 的识别率已经超过了基于 PCA+ANN 的单通道算法、基于 CNN-LSTM 的优化算

法,与基于 LDA 和残差网络的方法也已接近。这表明 TiCNN-DRSN 是一种具有较强性能的 sEMG 手势识别算法。

表 4 其他实验对比

模型	识别率
基于 PCA 和 ANN 方法的单通道算法	86.7%
基于光 CNN LSTM 模型的 sEMG 手势识别优化算法应用研究	91.4% (复杂手势)
基于 EMG 的手势识别的深度残差收缩网络	81%
基于 LDA 的分类	94%
基于残差网络的手势识别	92%
基于 TiCNN-DRSN 网络	97.1%

总的来说,本文提出的 TiCNN-DRSN 模型在保持较低复杂度的同时,能够显著提高 sEMG 手势识别的准确性和鲁棒性,为实际应用提供了一种有效的解决方案。相比于其他主流算法,TiCNN-DRSN 在抗噪性、泛化能力等方面都展现出了优异的性能。

4 网络实际测试及分析

本文为验证 TiCNN-DRSN 网络在实际应用中的效果,拟设定实验流程图如图 10 所示。先用表面肌电手环将用户手势数据采集并传输给上位机,经由 TiCNN-DRSN 模型分析识别后,给出分类结果至机器手,机器手在做出分类结果相对应的动作。实际的交互测试实验图如图 11 所示。



图 10 实验流程图



图 11 实际的交互测试实验

手势数据采集前先对手势动作及持续时间进行规定,定义了有钩状抓握、拇指食指对捏、拇指食指侧捏、球状抓握、手指完全伸展、腕背伸、握拳和柱状抓握动作,具体动作如图 12 所示。



图 12 具体动作

采集过程分为 8 组,每组包含一系列手部动作,每个动作重复执行 5 次,并在每次结束后给予患者充分的休息时间。每个动作的设计时间为 6 s,用户在图片提示下完成相应的手部动作。为了确保数据的准确性和完整性,采集程序中设置了动作切换到休息状态时的冗余 0.5 s 的切换时间,在此期间数据不进行采集,以避免动作之间的干扰和混淆。

对每个患者的数据按照 8 : 2 比例划分为训练集和测试集,网络迭代次数定为 100,实验识别率达到 97.43% ± 0.8%。TiCNN-DRSN 网络识别率曲线图如图 13 所示。




图 13 TiCNN-DRSN 网络识别率图

为了验证算法的实时性,使用动态试验进行测试,主要测试了握拳、拇指食指对捏、手指完全伸展 3 个动作,共执

行了 80 次动作识别测试,实验结果分析表面,平均识别准确率为 95.42%,接近于静态识别分类结果。并且,机器手能在 sEMG 信号的产生与实际做出动作的之间的时间间隔 250 毫秒内做出分类动作,从而使得本系统的实时性得到保证。

综上所述,本文所提出的 TiCNN-DRSN 网络模型具有一定的在实时性方面有一定的成效,该模型具有高精度,而且模型体积小、运行速度快,非常适用于嵌入式硬件中的应用。

5 结 论

本文提出了一种基于 DRSN 网络与训练干扰卷积神经网络的轻型 sEMG 信号手势识别算法。以 DRSN 网络为主体,这是应为很多情况下样本中都会含有噪声或者与样本主体不相干的信息,这些信息回影响特征学习的效果,而肌电信号之中因为休息是出于大部分时间的常态,所以可以将之视为噪声或者是无用信号,这就是本文选择 DRSN 网络为主体的原因。在后续的实验中,本文对具有不同含量的噪声数据进行比较,并且对不同模型在同一数据下进行训练精度的比较。在深度模型训练中,构建了一种 DRSN+TiCNN 的训练方法,该训练模型精度高,体积小,运行速度较快,适用于嵌入式硬件中应用。

但在实验中本文发现有些的手势用于动用的肌肉群块几乎一致,这导致在肌电信号的显示上极为相近难以区分。所以在后续的实验中,本文将考虑解决多手势信号相近难以区分的问题。

参考文献

[1] WU J J, LI X O, LIU W Y, et al. sEMG signal processing methods: A review[J]. Journal of Physics: Conference Series, 2019, 1237(3), DOI:10.1088/1742-6596/1237/3/032008.

[2] AROZI M, CAESARENDRA W, ARIYANTO M, et al. Pattern recognition of single-channel sEMG signal using PCA and ANN method to classify nine hand movements[J]. Symmetry, 2020, 12(4): 541.

[3] BAI D, LIU T, HAN X, et al. Application research on optimization algorithm of sEMG gesture recognition based on light CNN+ LSTM model[J]. Cyborg and Bionic Systems, 2021, DOI: 10.34133/2021/9794610.

[4] MA Y Y, WANG C B, JIANG CH G Z, et al. Deep residual shrinkage networks for EMG-based gesture identification [J]. ArXiv Preprint, 2022, Arxiv: 2202.02984.

[5] YOUS A M, AGOUNAD S, ELBAZ S. Automated detection and removal of artifacts from sEMG signals based on fuzzy inference system and signal decomposition methods [J]. Biomedical Signal

Processing and Control,2024,94: 106307.

[6] WANG Y, ADAM L M, ZHAO Y, et al. Machine learning-enhanced flexible mechanical sensing [J]. Nano-Micro Letters,2023,15(4):196-228.

[7] ZHAO Z J, ZHANG CH L, ZHANG X, et al. A self-adaptive DRSN-GPReLU for bearing fault diagnosis under variable working conditions[J]. Measurement Science and Technology,2022,33(12): 124005.

[8] 娄华生,行鸿彦,李瑾,等. 基于改进 CEEMDAN 和小波阈值的雨声信号去噪算法研究[J]. 电子测量技术, 2023,46(7):103-109.

[9] PAN J F, ZHANG SH L, XIA L S, et al. Embedding soft thresholding function into deep learning models for noisy radar emitter signal recognition[J]. Electronics, 2022,11(14):2142-2142.

[10] GONG N, LI L, SHA J, et al. A satellite-drone image cross-view geolocalization method based on multi-scale information and dual-channel attention mechanism[J]. Remote Sensing,2024,16(6): 941.

[11] DULMINI H, YE T, HAN Y, et al. Depth as attention to learn image representations for visual localization, using monocular images [J]. Journal of Visual Communication and Image Representation, 2024, 98: 104012.

[12] KHATTAK A S, ZAIN A M, HASSAN R B, et al. Hand gesture recognition with deep residual network using Sema signal [J]. Biomedical Engineering/ Biomedizinische Technik, 2024, DOI: org/10.1515/bmt-2023-0208.

[13] SUN F, XU H, ZHAO Y H, ZHANG Y D. Data-driven fault diagnosis of control valve with missing data based on modeling and deep residual shrinkage network[J]. Journal of Zhejiang University-SCIENCE A, 2022, 23(4):303-313.

[14] XUE Y F, CAI CH ZH, CHI Y L. Frame structure fault diagnosis based on a high-precision convolution neural network[J]. Sensors, 2022, 22(23): 9427.

[15] MAJEED R J, MAROUA H, FAKHER C, et al. Gear crack detection based on vibration analysis techniques and statistical process control charts (SPCC) [J]. Machines,2023,11(2):312-312.

作者简介

周国良, 硕士, 主要研究方向为信息分析、人工智能等。
E-mail:1400068101@qq.com

张道辉, 博士, 主要研究方向为人工肌肉, 仿人手臂软体机器人, 康复机器人、基于脑肌电的人机交互。
E-mail:zhangdaohui1@sia.cn

郭小萍, 教授, 主要研究方向为数据驱动工业过程异常检测、故障诊断和质量预测。
E-mail:Gxp2001@sina.com