

DOI:10.16136/j.joel.2023.07.0334

融合多元经验模态分解与 Hilbert 空间填充曲线的 sEMG 处理方法

刘聪^{1,2,3*}, 马钰同^{1,2}, 许婷婷^{1,2}, 胡胜^{1,2}, 孔祥斌^{1,2}

(1. 湖北工业大学 电气与电子工程学院, 湖北 武汉 430068; 2. 太阳能高效利用湖北省协同创新中心, 湖北 武汉 430068; 3. 武汉华安科技股份有限公司 博士后科研工作站, 湖北 武汉 430068)

摘要: 基于卷积神经网络 (convolutional neural network, CNN) 的表面肌电信号 (surface electromyography, sEMG) 手势识别算法通常将一维 sEMG 转换成二维肌电图作为 CNN 的输入。针对 sEMG 瞬时样本量偏少、以及一维 sEMG 转换成二维肌电图时带来的局部时序特征丢失等问题, 提出了将多元经验模态分解 (multivariate empirical mode decomposition, MEMD) 算法与 Hilbert 空间填充曲线相结合的方法, 以提升手势识别算法的准确率。采用开源数据集 NinaPro-DB1 作为实验数据集; 通过 MEMD 算法对 sEMG 进行分解; 将分解后的本征模态函数 (intrinsic mode functions, IMFs) 作为 Hilbert 曲线的填充域 (Hilb-IMFs) 映射成二维肌电图; 选择 DenseNet 作为手势识别的基本网络。实验结果表明, 提出的方法相对于传统信号升维方法在手势识别准确率上约有 4% 的性能提升, 验证了该方法的有效性。

关键词: 表面肌电信号 (sEMG); 多元经验模态分解 (MEMD); Hilbert 空间填充曲线; 卷积神经网络 (CNN)

中图分类号: TP391 文献标识码: A 文章编号: 1005-0086(2023)07-0723-11

sEMG processing method fusing multivariate empirical mode decomposition and Hilbert space-filling curves

LIU Cong^{1,2,3*}, MA Yutong^{1,2}, XU Tingting^{1,2}, HU Sheng^{1,2}, KONG Xiangbin^{1,2}

(1. School of Electrical and Electronic Engineering, Hubei University of Technology, Wuhan, Hubei 430068, China; 2. Hubei Collaborative Innovation Center for High-efficiency Utilization of Solar Energy, Wuhan, Hubei 430068, China; 3. Postdoctoral Workstation, Wuhan Hua'an Science and Technology Co., Ltd., Wuhan, Hubei 430068, China)

Abstract: Surface electromyography (sEMG) gesture recognition algorithms based on convolutional neural network (CNN) usually convert one-dimensional sEMG to two-dimensional electromyogram (EMG) as the input of CNN. In order to solve the problems such as the lack of instantaneous samples of sEMG and the loss of local timing features caused by converting one-dimensional sEMG to two-dimensional EMG images, a processing method which fuses the multivariate empirical mode decomposition (MEMD) algorithm and the Hilbert space-filling curve is proposed to improve the accuracy of the gesture recognition algorithm. The open-source dataset NinaPro-DB1 is applied. Firstly, the sEMG is decomposed by the MEMD algorithm. Secondly, the decomposed intrinsic mode functions (IMFs) are used as the filled domain (Hilb-IMFs) of the Hilbert curve for mapping them to a two-dimensional EMG image. Finally, DenseNet is chosen as the basic network for gesture recognition. The experimental results show that the proposed method has a performance improvement of about 4% in gesture recognition accuracy compared with traditional signal dimensionalization method, which verifies the effectiveness of the method.

* E-mail: 20181008@hbut.edu.cn

收稿日期: 2022-05-08 修订日期: 2022-08-11

基金项目: 国家自然科学基金(61901165)资助项目

Key words: surface electromyography (sEMG); multivariate empirical mode decomposition (MEMD); Hilbert space-filling curve; convolutional neural network (CNN)

0 引言

随着 VR/AR 以及元宇宙技术的快速发展,基于可穿戴式设备的手势识别技术在人机交互的需求中具有越来越重要的地位^[1]。基于可穿戴式设备的手势识别技术一般分为两类,一类基于人体皮肤表面产生的表面肌电信号(surface electromyography, sEMG)来识别人体意图,另一类基于人体肌肉纤维产生的针电极肌电信号(needle electromyography, nEMG)^[2]识别人体意图。由于第二类方法需要将信号采集电极插入人体肌肉内部,对人体伤害较大,因此,在日常生活中,基于 sEMG 的手势识别算法渐成主流。

机器学习算法广泛应用于传统 sEMG 手势识别模型^[3],其主要步骤有:数据获取、数据预处理、特征提取和分类器分类。在数据预处理阶段,可使用傅里叶分析^[4]、小波分析^[5]和经验模态分解(empirical mode decomposition, EMD)^[6]等一系列信号分析方法。由于傅里叶分析和小波分析更加适用于线性平稳的信号,而 sEMG 通常为非线性不平稳信号,因此,EMD 及其变体算法的自适应特点对于 sEMG 等非线性非平稳信号更加有效。在分类器分类阶段,使用传统分类器进行手势识别精度较高的是 CASTELLINI^[7]等从 7 个电极采集到的 sEMG 中提取均方根特征(root mean square, RMS)作为支持向量机(supported vector machine, SVM)的输入,支持 3 种抓取手势的分类,识别准确率可达 97%。但传统机器学习算法存在一些缺点,比如泛化能力弱、需要人为提取的庞大特征工程和识别的手势类型较少等缺点。

近些年,深度学习模型在计算机视觉、自然语言处理等人工智能领域取得了卓越的成就,因此将深度学习框架用于 sEMG 的手势识别领域也成为了近年来大热的课题^[8]。在一些文献中,作者将 sEMG 映射成二维肌电图,使用卷积神经网络(convolutional neural network, CNN)对相应手势的肌电图进行分类,而无需手动提取特征。ATZORI 等^[9]将 CNN 应用于 NinaPro 开源数据集

的 DB1 上,取得了 66.59% 的准确率,虽然手势分类的数目高达 52 种,准确率并不高。GENG 等^[10]设计了一种基于瞬时肌电图的 CNN 结构,对 8 种手势进行分类,识别准确率达到 89%,分类的手势数量比较少。WEI 等^[11]设计了基于多通道 sEMG 的多流卷积架构,对 NinaPro-DB1 的 52 种手势进行分类,识别准确率达到 85%,但未考虑 sEMG 的时序性。TSINGANOS 等^[12]从生成肌电图的方法入手,采用 Hilbert 空间填充曲线将 sEMG 转换为二维图像,并使用多种网络进行对比实验。从时间域填充 Hilbert 曲线识别准确率最高的是与 WEI 等提出的 WeiNet 结合,提升了约 5%,该方法将 sEMG 从时域上分割并填充,对 sEMG 的时序特征有一定的影响;从电极域填充 Hilbert 空间识别准确率最高的是与 HUANG 等^[13]提出的 DenseNet 结合,识别准确率达到 81%,相较于其他方法识别准确率一般,主要原因是 sEMG 的瞬时样本量少,即采集 sEMG 的电极数偏少,用于填充一个二维 Hilbert 空间的样本较少,从而导致 Hilbert 曲线阶数较低。

针对从时域填充 Hilbert 空间破坏 sEMG 时序性,与电极域填充 Hilbert 曲线时 Hilbert 曲线阶数较低而导致的识别准确率下降的问题,本文提出多元经验模态分解(multivariate empirical mode decomposition, MEMD)算法^[14]与 Hilbert 曲线相结合的方法,将 MEMD 算法分解出的本征模态函数(intrinsic mode functions, IMFs)填充为 Hilbert 曲线,即从 IMFs 域填充 Hilbert 空间,生成二维肌电图,并送进神经网络进行分类。该方法既完整保留了 sEMG 的时序特征,同时也保证了 Hilbert 曲线的阶数不低于 3 阶,以达到提高手势识别准确率的目的。

本文将根据如图 1 所示的流程开展研究。第 1 节介绍了本文使用的数据集 NinaPro-DB1 和数据预处理方法:结合 MEMD 方法和 Hilbert 空间填充曲线;第 2 节主要介绍了本文选择的网络结构:DenseNet;第 3 节为本研究提出方法的实验结果与分析。




图 1 研究路线

Fig. 1 Research route

1 数据集与数据预处理

1.1 NinaPro 数据集

本研究采用的数据集为 NinaPro^[15,16] 开源数据集中的 DB1。DB1 数据集包含了 27 个健康受试者的测量数据,其中男性受试者为 20 人,女性受试者为 7 人。该数据集的 sEMG 由带有 22 个传感器的数据手套 CyberGlove II 采集^[17]。该手套使用 10 个 OttoBock MyoBock 13E200 表面肌电极采集信号。原始信号的带宽为 15—500 Hz,上述电极会将原始

信号放大 2000 至 10 万倍不等。根据文献[15]中的描述,其中 8 个电极均匀地放在前臂周围,即肘部正下方的桡腕关节附近,另外两个电极被安置在伸指肌和屈指肌的主要运动点上。图 2 给出了采集 DB1 数据部分电极的位置,图(a)、图(b)中的 1、2 为分别为伸指肌、屈指肌附近的均匀电极位置和备用电极位置;图(c)中的 1、2、3、4 为手臂上所有电极和传感器的位置,其中 1 和 2 对应图(a)和图(b)中的均匀电极和备用电极,3 为倾角仪,4 为装置了其他电极的数据手套主体部分。

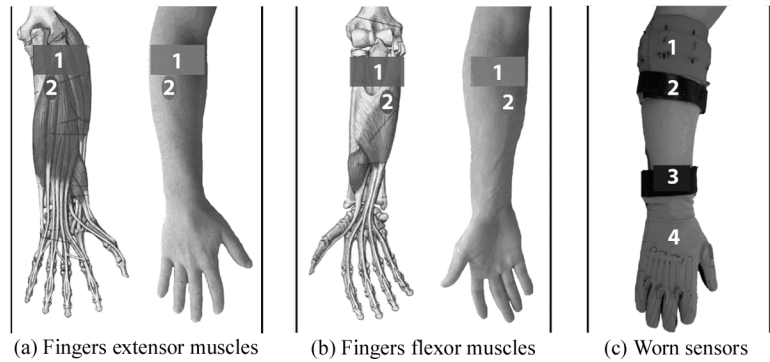


图 2 电极位置

Fig. 2 Placement of the electrodes

该数据集共包含 52 种手势动作,总体被分为 4 大类:(a) 12 种手指基本动作(弯曲和伸展)、(b) 8 种等距等张的手型、(c) 9 种手腕的基本动作和(d) 23 种抓握功能性动作,如图 3 所示。

在数据集汇总前,将 10 个电极采集到的所有数据通过线性内插,往最高频率插值来同步所有数据,随后使用二阶巴特沃斯滤波器对数据进行滤波。本文先通过文献[12]中描述的低通滤波器对数据进行

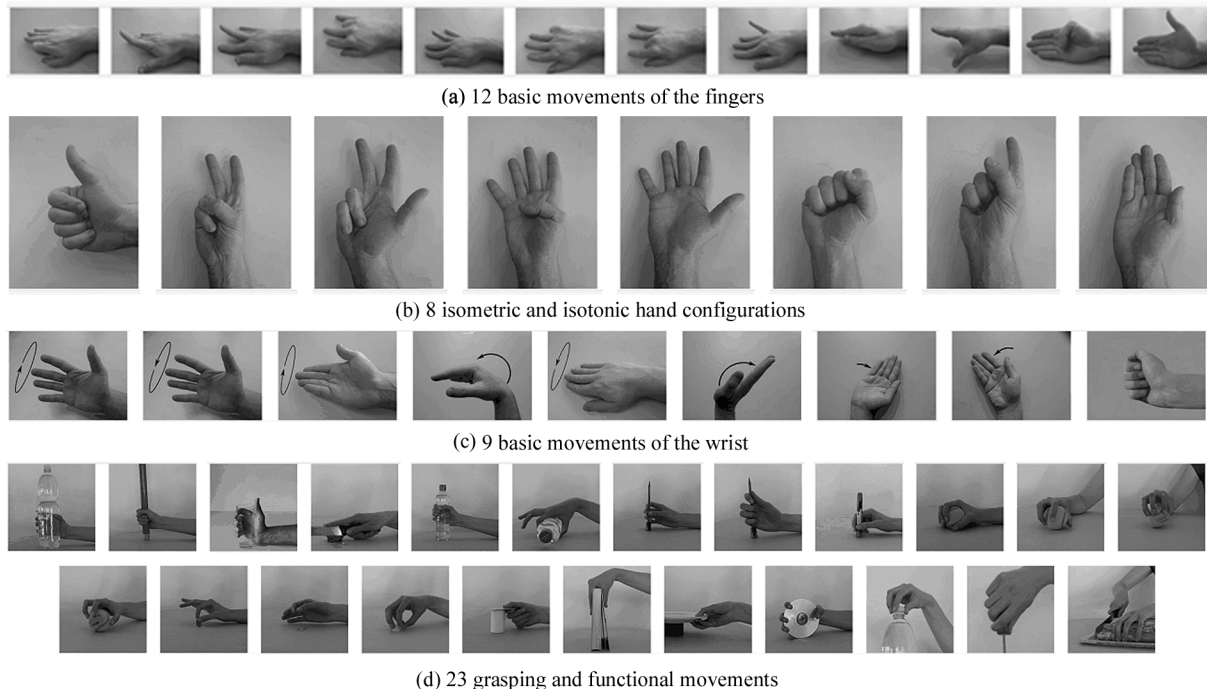


图 3 52 种手势

Fig. 3 52-classes hand-gesture

滤波,然后使用 MEMD 算法和 Hilbert 空间填充曲线对数据集进行进一步处理。

1.2 数据预处理

1.2.1 MEMD

所有 EMD 算法的扩展最终都会将原始信号分解成若干个 IMF 和一个残差(residual)。文献[6]提出,任何信号都可以分解为若干个 IMF 之和,即该算法适用于随机信号。IMF 有两个基本条件:极值点的个数和零点的个数必须相等或相差至多不超过 1 个;整个信号的上下包络线关于时间轴对称。

获取 IMF 分量,需求出上下包络线的均值,用原始信号减去均值包络线,得到一个中间信号,判断该中间信号是否满足上述两个基本条件,如果满足,则该中间信号为其中一个 IMF。获取剩余 IMF 分量,只需将原始信号减去已经获取到的 IMF 分量,并重复上述过程即可,直到获取残差分量。通过上述过程分解得到的 IMF 分量即为原始信号的各频率分量,即 IMF 分量的物理意义。

传统的 EMD 算法只能对单通道信号进行分解,且分解后的 IMF 数量无法确定,同时会产生一定程度的模态混叠现象。MEMD 算法由 REHMAN 和 MANDIC 于 2010 年提出,该算法提出从超球面的多个方向来计算多通道信号的包络和局部均值,从多元信号的角度完成了对传统 EMD 算法的扩展,从而解决了传统 EMD 算法的局部极值无法定义多通道信号的问题。另外,EMD 分解由于算法特性分解出的 IMF 分量的数量较少,而且不同电极采集 sEMG 分解 IMF 的数量不固定,对于选择 Hilbert 曲线的阶数很不利,MEMD 分解将多个通道的信号同时分解,克服了 IMF 分量个数少以及数量不固定的缺陷。综上所述,分解多通道信号选择 MEMD 算法更优。

MEMD 算法的变量定义如下:存在一个 N 维序列集合 $V_N(t) = \{v_1(t), v_2(t), \dots, v_n(t)\}$,该集合表示有 N 个通道的 sEMG 序列。存在另一个 N 维序列集合 $X^{\theta_m} = \{x_1^m, x_2^m, \dots, x_n^m\}$,该集合表示在 $n-1$ 维球面上对应 k 个角度的方向向量集,该方向向量集对应的角度向量集为 $\theta^M = \{\theta_1^m, \theta_2^m, \dots, \theta_{n-1}^m\}$ 。如果方向向量的总数为 M ,那么 $M = 1, 2, \dots, m$ 。根据上述公式变量, MEMD 算法流程如下^[18]:

1) 通过 Hammersley 序列取样法从 $n-1$ 维球面上获取合适的角度向量。

2) 计算输入信号 $v_n(t)$ 在角度向量集中每个角度的投影向量集 $P^{\theta_m} = \{p^{\theta_1}, p^{\theta_2}, \dots, p^{\theta_m}\}$ 。

3) 求出角度向量集对应的投影向量集所有极值,根据极值的瞬时时刻确定一个瞬时时刻向量集 $T_i^{\theta_m} = \{t_i^{\theta_1}, t_i^{\theta_2}, \dots, t_i^{\theta_m}\}$ 。

4) 通过多元样条插值法对极值点 $v(t_i^{\theta_m})$ 插值,得到包络线集合 $E^{\theta_m}(t) = \{e^{\theta_1}(t), e^{\theta_2}(t), \dots, e^{\theta_m}(t)\}$ 。

5) 求包络线的平均值 $a(t)$:

$$a(t) = \frac{1}{M} \sum_{m=1}^M e^{\theta_m}(t) \quad (1)$$

6) 将原始序列与均值相减,求得一个中间信号 $y(t) = v(t) - a(t)$,如果该信号满足 IMF 的两个基本条件,则将该信号作为一个新的 IMF 分量,再用原始信号 $v(t)$ 减去所有的 IMF 分量,作为步骤 2) 的输入信号,再通过步骤 2)–6) 的分析,得到新的 IMF 分量;如果不满足条件,则直接将 $y(t)$ 作为步骤 2) 的输入,重复执行到步骤 6)。

通过 MEMD 算法的处理,多个电极采集到的原始信号将被分解为一定数量的 IMF 分量 $y_j(t) = \{y_1(t), y_2(t), \dots, y_j(t)\}$ 和一个残差分量 $r(t)$, j 表示 IMF 分量的个数,公式如下:

$$v(t) = \sum_{i=1}^j y_j(t) + r(t) \quad (2)$$

每一次提取出新的 IMF 分量时,是从剩余信号中分离出频率最高的分量,即 EMD 系列算法的本质。迭代到一定的程度后,如果极值点的个数小于 3,说明信号的高频分量已经提取完毕,便停止迭代,将剩余的信号作为残差分量,整个迭代过程即可结束。

图 4 为 NinaPro 数据集中手势 2 的第 2、10 个电极通过 EMD 算法分解的时域波形图。图 5 为通过 MEMD 算法分解的时域波形图。由图 4 与图 5 对比可知, MEMD 算法很大程度上缓解了 EMD 的模态混叠现象,同时从多通道信号中获取了局部极值。

1.2.2 Hilbert 曲线

Hilbert 曲线^[19]可以线性贯穿二维或更高维度的每个离散单元,并且不会重复穿越同一个单元。另外, Hilbert 空间排列密度高,即 Hilbert 曲线上相邻的点,在原始空间上一定相邻,保持局部性特征的能力很强。图 6 给出了 1—3 阶的 Hilbert 曲线。从图中可以看出,曲线的每个点都只占据一个单元格,曲线不会相交且不会重复经过一个点。

图 7 给出了从 1 阶 Hilbert 曲线到 2 阶 Hilbert 曲线的变换过程。首先将 1 阶 Hilbert 曲线的 4 个单元格分割为 4 个更小的单元格,并在分割后的单

元格中填充 1 阶 Hilbert 曲线得到第 2 幅图;然后将左下角的 1 阶 Hilbert 曲线顺时针旋转 90° , 右下角的 1 阶 Hilbert 曲线逆时针旋转 90° , 得到第 3

幅图;最后将第 3 幅图中的 4 个 1 阶 Hilbert 曲线连接,使曲线能够不间断地遍历所有单元格。

从 2 阶 Hilbert 曲线迭代到 3 阶 Hilbert 曲线的

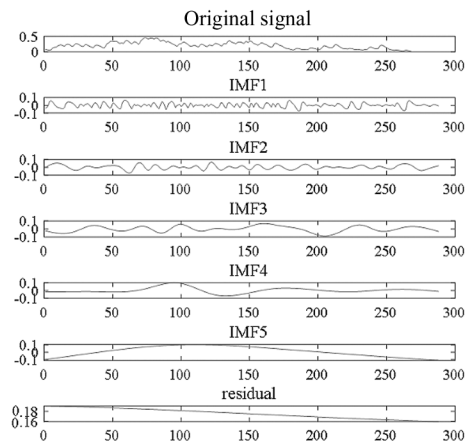
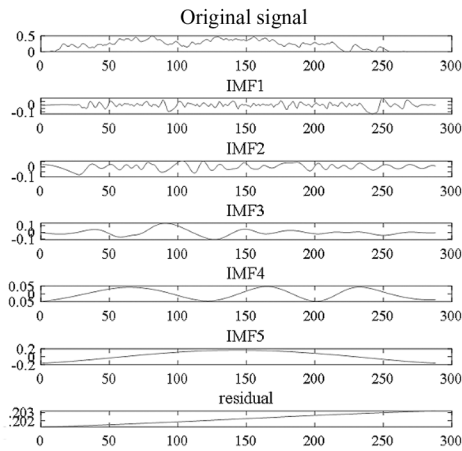


图 4 电极 2 和电极 10 的 EMD 分解

Fig. 4 EMD of electrode 2 and electrode 10

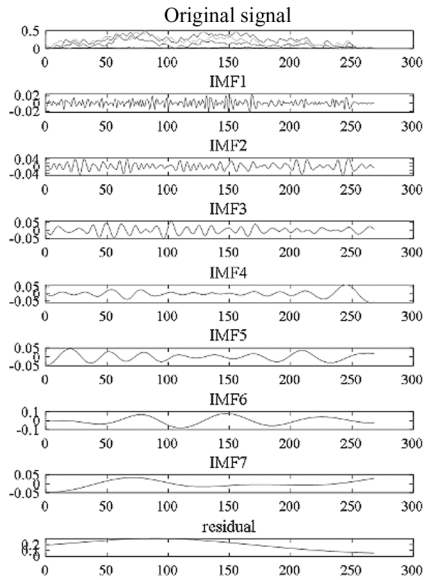



图 5 电极 2 和电极 10 的 MEMD 分解

Fig. 5 MEMD of electrode 2 and electrode 10




图 6 1,2,3 阶 Hilbert 曲线

Fig. 6 1,2,3 order Hilbert curve




图7 2阶 Hilbert 曲线迭代过程

Fig.7 The iterative process of 2-order Hilbert curve

过程与上述相同,因此,高阶的 Hilbert 曲线均是由低阶 Hilbert 曲线迭代生成,当阶数足够大时,借助极限的思想,Hilbert 曲线能够填满整个二维空间。

在文献[12]中提出,可以分别从两个维度将 sEMG 映射到 Hilbert 曲线:时间维度和电极维度,两种维度分别从时间维度和电极维度填充 Hilbert 空间。为了不破坏时序信息,提升 Hilbert 空间填充曲线的阶数,本文提出从 MEMD 算法分解出的 IMF 维度来填充 Hilbert 空间,即将 MEMD 分解后得到同一时刻的 IMFs 分量按照 Hilbert 曲线的填充顺序来填充 Hilbert 空间。具体步骤如下:

1) 获取较为明显的特征且不丢失信号过多信息,同时保证 Hilbert 空间中不会有过多的空值,从 MEMD 分解出的 IMFs 中选取前 6 个 IMF 分量,获取电极数 $X \times 6 = Y$ 个 IMFs,其中 $Y \leq L^2$, L 的值必须为 2 的幂次,即 Hilbert 空间填充曲线的阶数为

L 。

2) 将 Y 个 IMFs 分量依时域分割为长度为 I 的时间重叠窗口,分割步长为 10 ms(一个样本点),生成 $I \times Y$ 个样本。文献[12]已验证,一个时间窗口段包含 64 个样本(640 ms)时,模型表现最好。IMFs 重叠窗口采样如图 8 所示。

3) 如图 9 所示,将样本集归一化后,样本点的值映射到 0—255,然后将瞬时刻的所有 IMFs 分量按照 Hilbert 曲线的填充顺序填入 Hilbert 空间单元格,生成 $L \times L$ 的肌电图。

当样本 Y 的个数少于 L^2 时,剩余的单元格用空值填充。例如包含 64 个 IMFs 和 64 个样本的窗口段被填充成 $8 \times 8 \times 64$ 的三维肌电图。一帧时间样本只有 60 个 IMFs,因此 Hilb-IMFs 空间填充曲线的最后 4 个值为 0。




图8 重叠窗口采样

Fig.8 Overlapping window sampling




图 9 IMFs 域 Hilbert 曲线填充

Fig. 9 Hilbert curve filling of IMFs domain

2 网络模型

2.1 CNN

CNN 由多层感知机 (multilayer perception, MLP) 演变而来。LECUN 等^[20]首次提出 CNN 的概念,将反向传播(backpropagation, BP)与权值共享的卷积层结合,并将其应用于美国邮局的手写字符识别系统中。1998 年,LECUN 发明了经典 CNN 结构 LeNet-5^[21],在字符识别系统中取得了更为卓越的成效。

CNN 的结构主要由输入层(input layer)、卷积层(convolutional layer)、池化层(pooling layer)、全连接层(full connected layer)和输出层(output layer)组成。卷积层和池化层一般交替出现,也就是说,一个卷积层连接一个池化层,池化层后面再接另外一个卷积层。CNN 具有局部区域连接、权值共享和下采样等结构特点^[22],使其随着 GPU 技术的发展在计算机视觉领域大放异彩,众多基于 CNN 的变体网络结构也层出不穷,如 AlexNet^[23]、GoogleNet^[24]、VGGNet^[25]、ResNet^[26]和 DenseNet 等,以上网络结构均在开源的图像数据集上获得不错的图像识别率。

2.2 DenseNet

DenseNet 由 HUANG 等于 2017 年提出。DenseNet 与传统的 CNN 不同,传统 CNN 中每一层的输入仅是上一层的输出,DenseNet 采用了一种密集连接的方法。网络中的每一层都将前面所有层的输出作为当前层的输入,使得每一层都能充分连接,确保网络中层与层之间保持最大信息流,不仅解决了传统 CNN 梯度消失的问题,且重用之前的特征

图,使网络用更少的参数就变得更加紧凑,还能有效防止模型过拟合,在计算机视觉领域有着重大突破,因此本文选择 DenseNet 作为基本网络。

假设网络中包含 Z 层, z 表示 Z 层网络中的第 z 层,即 x_z 表示第 z 层的输出。因此, $x_z = H([x_0, x_1, \dots, x_{z-1}])$,其中 H 表示当前层的操作,一般为卷积操作,同时该式也表明,第 z 层有 $z \times \frac{z+1}{2}$ 个连接。

DenseNet 还有一个重要的超参数 s ,文献[13]将其称为网络增长率(growth rate)。 s 表示网络中每一层输出特征图的数量,因此,第 l 层输出的特征图数量为 $s_0 + (l-1)s$,其中 s_0 为输入图像的通道数。即每一层都获取了前面所有层的信息,相当于访问“集体知识”。特征图每经过一层,都将该层的输出特征图加入到公共的“集体知识”中。 s 值的大小直接影响了每一层对整个网络“集体知识”的贡献度。

另外,由于 DenseNet 提出的密集连接方法中,特征图的大小必须是相同的,而 CNN 中的下采样是十分重要的,因此 HUANG 等提出将网络结构分解为多个 denseblock,在 denseblock 内对每层进行密集连接,然后每两个 denseblock 之间穿插一个过渡层(transition layer),网络的下采样操作由过渡层来完成。denseblock 由一个批量归一化层(batch-normalization layer)、修正线性单元(rectification linear unit, ReLU)、两两交错的 1×1 卷积核和 3×3 卷积核组成;过渡层由一个批量归一化层、一个 1×1 卷积层和一个 2×2 的平均池化层组成。本文将 Hilb-IMFs 映射的肌电图作为网络的输入,网络结构如图 10 所示。

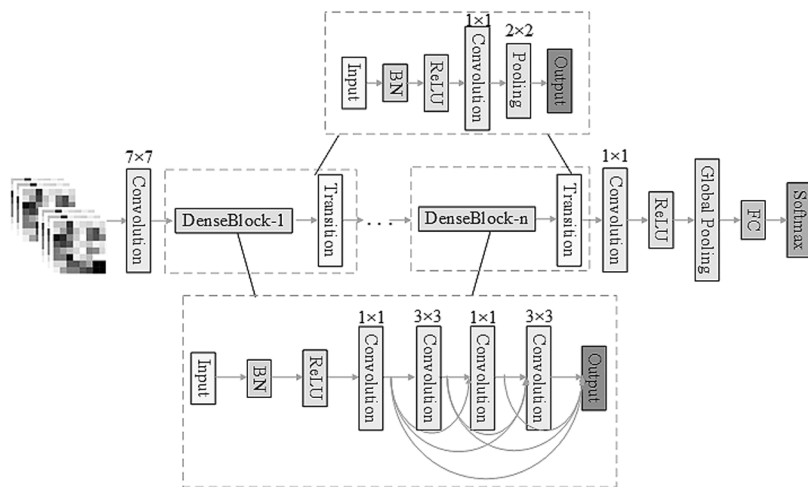


图 10 DenseNet 基本结构

Fig. 10 Fundamental structure of DenseNet

3 实验与分析

3.1 实验设置

本文使用的 MEMD 算法由 Matlab 实现,生成对应的 mat 文件,Hilb-IMFs 空间填充曲线由 Python 实现,网络结构使用深度学习框架 Tensorflow 和 Keras 实现,实验平台为 Intel Xeon(R) Gold 5218-Nvidia Titan X-32GB RAM。sEMG 数据样本分为训练集和测试集,其中训练集样本量为总样本的 80%,测试集样本量为 20%。使用随机梯度下降法训练网络,选择交叉熵损失函数,批次大小(batch-size)为 1024,迭代(epoch)100 次,不断更新模型的权重和偏置量并保存最终的参数,然后在测试集上进行验证。本文的对比实验将 MEMD-Hilbert 模型与使用了其他 EMD 变体算法或其他信号分解算法的模型进行对比,并将仅仅使用 Hilbert 空间填充曲线而不使用信号分解方法作为基准实验。除此之外,还将使用 ResNet 作为分类器与本文选择的 DenseNet 进行对比。评价标准为平均手势识别准确率。设平均准确率为 acc ,被正确分类的手势数为 N_r ,实际分类的手势数为 N_a 。计算式如下:

$$acc = \frac{1}{subjects} \sum_{i=1}^{subjects} \frac{N_r}{N_a} \quad (3)$$

3.2 实验结果分析

图 11(a)为本文提出的方法和基准实验的对比,即受试者 1 的 52 种手势测试集随着训练集训练次数的增加在两种模型下识别平均准确率和损失值的变化趋势;图 11(b)为使用 ResNet 作为基本网络结构平均准确率和损失值的变化趋势。

结合图 11(a)和图 11(b)可以看出,本文提出的融合 MEMD 和 Hilbert 曲线并使用 DenseNet 网络模型的平均准确率最高,约为 85%;其次为本次实验的基准实验,仅使用 Hilbert 曲线并使用 DenseNet 进行手势识别,平均准确率约为 81%。相对于基准实验,本文提出的方法准确率提高了约 4%。该结果表明,通过 MEMD 算法扩充数据样本,使文献[12]中提出的从电极域填充 Hilbert 空间取得了更好的效果,并验证了 DenseNet 的优越性。

为了进一步验证 MEMD 算法的有效性,本文还使用其他信号分解方法进行与本文提出的方法进行对比实验。使用 Matlab 提供的算法库对原始 sEMG 进行分解,分解出的信号对应于 MEMD 算法的 IMFs,将分解后的数据封装到 mat 文件中。类似于 Hilb-IMFs 空间填充,分解后的数据分量同样作为生成肌电图的 Hilbert 空间填充域。图 12 给出了其他信号分解方法的手势识别表现。

可以看出其他分解方法对于 sEMG 的处理表现是不如 EMD 的一些变体算法的,比未进行任何信号分解操作的准确率还低。本质原因在于 sEMG 属于一种非线性非平稳信号,其他信号分解方法分解信号时需要事先设定一个基函数,例如傅里叶分析的基函数为正余弦函数,小波分析的基函数为小波基。EMD 系列算法不需要选择固定的基函数,该算法的基函数由信号本身导出,具有良好的自适应性。因此,对于本研究中的非线性非平稳 sEMG,固定基函数的分解方法并不能取得良好的识别效果。

为了选择最合适的超参数 s ,本文选择了 5 种不同的 s 值在 DenseNet 上进行对比实验来选择最合适

的 s 值大小。表 1 给出了选择不同大小的超参数 s 的手势识别平均准确率。从表中可以看出,随着 s 值的增大,准确率在不断提升。原因是 s 值越大,

DenseNet 的“集体知识”量就越多,网络模型的表现就越好。而在 s 值超过 48 后,准确率并未提升,因此选择 48 作为本研究的固定 s 值。

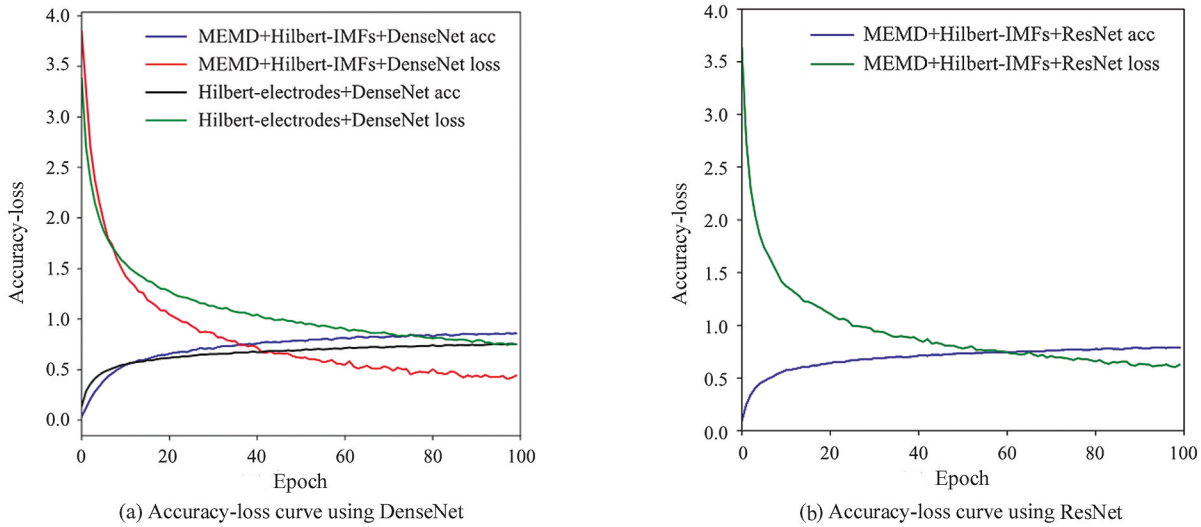


图 11 测试集 Accuracy-loss 曲线
Fig. 11 Accuracy-loss curve of test set

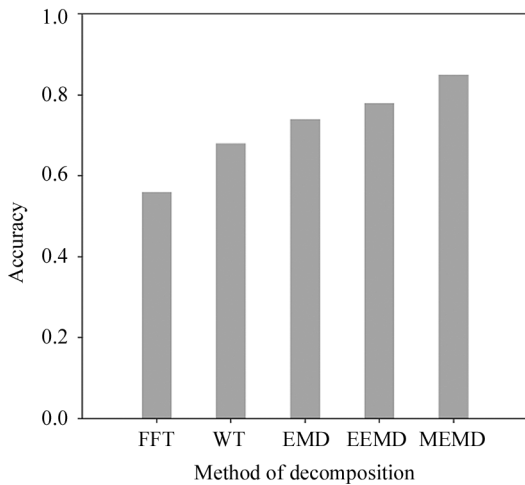


图 12 不同分解方法的准确率
Fig. 12 Accuracy of different decomposing method

表 1 不同 s 值大小对应的准确率

Tab. 1 The accuracy of different s value

s	12	24	36	48	60
Accuracy	73.78%	77.56%	81.09%	85.21%	83.81%

图 13 所示为本文提出的方法模型在 NinaPro-DB1 中的前 12 种手势识别结果的混淆矩阵。横坐标代表模型的预测的手势标签,纵坐标代表该手势的真实标签。整体来看,本文提出的融合 MEMD 与

Hilbert 空间填充曲线的模型手势识别准确率较高,阴影部分集中于对角线上,验证了该方法的有效性。另外,也存在一些识别准确率相对较低的手势,如手势 1—2、手势 4—5 和手势 9—12 等。对比图 3(a)可以发现,这些互相影响识别准确率的手势发力的拇指都是相同的,如手势 1—2 的发力拇指均为食指,手势 4—5 的发力拇指均为无名指,因此这些手势的识别效果会受到相应手势类别的影响。

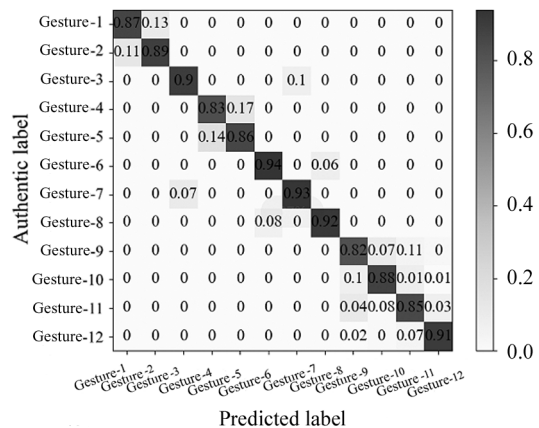


图 13 12 种手势识别结果的混淆矩阵
Fig. 13 Confusion matrix of 12 kinds of gesture

同时为了进一步验证本文提出方法的适用性和优势,使用了本文的方法对 NinaPro-DB2^[26] 数据集

中的 50 种手势进行了对比试验,与近年来提出的基于 sEMG 的手势分类方法进行比较,如表 2 所示,可以看出本文提出的方法具有一定的适用性和性能提升。

表 2 本文方法与其他 sEMG 手势分类方法对比

Tab. 2 Comparison of other sEMG gesture classification methods with ours

Method	Accuracy of NinaPro-DB1	Accuracy of NinaPro-DB2
Atzori-RF	75.30%	75.27%
AtzoriNet	66.60%±6.40%	66.28%±7.70%
GengNet	77.80%	—
VGGNet	77.36%	—
ZhaiNet ^[27]	—	78.71%
MSHilbNet	81.68%	—
Ours	85.21%	82.36%

4 结 论

为尽可能保持 sEMG 的时序特征,同时提升 Hilbert 空间填充曲线的阶数,以提高手势识别的准确率,本文提出了一种融合 MEMD 与 Hilbert 曲线的方法对 NinaPro-DB1 中 52 种手势的 sEMG 进行处理,并选择 DenseNet 作为基本网络结构,完成了 52 种手势的分类识别。该方法首先将数据集中的信号分解为多个 IMFs,使用重叠窗口对 IMFs 进行分割;并将 IMFs 作为 Hilbert 空间的填充域;最后将生成的肌电图作为输入送至 DenseNet 中进行识别分类。本文验证了 MEMD 算法与 Hilbert 空间填充曲线相结合的合理性,并且应用在深度学习手势识别模型中,相对于基准方法达成了 4% 左右的平均准确率提升,验证了该方法的有效性。

但本文也存在一些不足之处,由于选择了以电极为基础的 IMFs 作为 Hilbert 空间的填充域,导致无法使用对于分类多通道的 sEMG 更合适的多流 CNN。未来的研究中,将充分利用本方法未破坏 sEMG 时序特征的优势,基于 Hilb-IMFs 改进一种更加关注 sEMG 时序性的神经网络,以提升手势识别的平均准确率。

参考文献:

[1] MANDEEP K A, AMARDEEP S. A survey of hand gesture recognition[J]. International Journal of Advance Research in Computer and Management Studies, 2015, 3(5):266-271.

[2] ZHANG X. Body gesture recognition and interaction based

on surface electromyogram[D]. Hefei: University of Science and Technology of China, 2010.

张旭. 基于表面肌电信号的人体动作识别与交互[D]. 合肥: 中国科学技术大学, 2010.

- [3] SCHEME E, ENGLEHART K. Electromyogram pattern recognition for control of powered upper-limb prostheses: state of the art and challenges for clinical use[J]. Journal of Rehabilitation Research and Development, 2011, 48(6):643-660.
- [4] CAI L Y. A surface EMG signal identification method based on short-time Fourier transform [J]. Chinese Journal of Medical Instrumentation, 2000, 24(3):133-136.
蔡立羽. 基于短时傅里叶变换的肌电信号识别方法[J]. 中国医疗器械杂志, 2000, 24(3):133-136.
- [5] CAI L Y, WANG Z Z, ZHANG H H. Surface EMG signal classification using wavelet transform[J]. Journal of Biomedical Engineering, 2000, 17(3):281-284.
蔡立羽, 王志中, 张海虹. 小波变换在表面肌电信号分类中的应用[J]. 生物医学工程杂志, 2000, 17(3):281-284.
- [6] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences, 1998, 454(1971):903-995.
- [7] CASTELLINI C, FIORILLA A E, SANDINI G. Multi-subject/daily life activity EMG-based control of mechanical hands [J]. Journal of Neuroengineering and Rehabilitation, 2009, 6(1):1-11.
- [8] PARK K H, LEE S W. Movement intention decoding based on deep learning for multiuser myoelectric interfaces [C]//International Winter Conference on Brain-computer Interface, February 22-24, 2016, Gangwon, Korea (South). New York: IEEE, 2016:1-2.
- [9] ATZORI M, COGNOLATO M, MULLER H. Deep learning with convolutional neural networks applied to electromyography data: a resource for the classification of movements for prosthetic hands[J]. Frontiers in Neurobotics, 2016, 10:9.
- [10] GENG W D, DU Y, JIN W G, et al. Gesture recognition by instantaneous surface EMG images [J]. Scientific Reports, 2016, 6(1):1-8.
- [11] WEI W T, WONG Y K, DU Y, et al. A multi-stream convolutional neural network for sEMG-based gesture recognition in muscle-computer interface[J]. Pattern Recognition Letters, 2019, 119:131-138.
- [12] TSINGANOS P, CORNELIS B, CORNELIS J, et al. Hilbert sEMG data scanning for hand gesture recognition based on deep learning[J]. Neural Computing and Applications,

- 2021,33(7):2645-2666.
- [13] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE, 2017:2261-2269.
- [14] REHMAN N, MANDIC D P. Multivariate empirical mode decomposition[J]. Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences, 2010, 466(2117):1291-1302.
- [15] ATZORI M, GIJSBERTS A, CASTELLINI C, et al. Electromyography data for non-invasive naturally-controlled robotic hand prostheses[J]. Scientific data, 2014, 1(1):1-13.
- [16] ATZORI M, GIJSBERTS A, HEYNEN S, et al. Building the NinaPro database: A resource for the biorobotics community[C]//2012 4th IEEE RAS & EMBS International Conference on Biomedical Robotics and Biomechanics (BioRob), June 24-27, 2012, Rome, Italy. New York: IEEE, 2012:1258-1265.
- [17] XU K, BA J, KIROS R, et al. Show, attend and tell: Neural image caption generation with visual attention[C]//International Conference on Machine Learning, July 6-11, 2015, Lille, France. JMLR, 2015:2048-2057.
- [18] MA D. Research on the hand gesture recognition algorithm based on sEMG[D]. Changchun: Jilin University, 2020.
马迪. 基于表面肌电信号的手势识别算法研究[D]. 长春: 吉林大学, 2020.
- [19] TSINGANOS P, CORNELIS B, CORNELIS J, et al. A Hilbert curve based representation of sEMG signals for gesture recognition[C]//2019 International Conference on Systems, Signals and Image Processing (IWSSIP), June 5-7, 2019, Osijek, Croatia. New York: IEEE, 2019: 201-206.
- [20] LECUN Y, BENGIO Y. Convolutional networks for images, speech, and time-series[M]//The handbook of brain theory and neural networks. Cambridge, MA, United States: MIT Press, 1998:255-258.
- [21] LECUN Y, BOTTOU L. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11):2278-2324.
- [22] IMARD P Y, STEINKRAUS D, PLATT J C. Best practices for convolutional neural networks applied to visual document analysis[C]//Seventh International Conference on Document Analysis and Recognition, August 6, 2003, Edinburgh, UK. New York: IEEE, 2003:958-963.
- [23] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2012;60(6):84-90.
- [24] SZEGEDY C, LIU W, Jia Y, et al. Going deeper with convolutions [C]//IEEE Conference on Computer Vision and Pattern Recognition, June 7-12, 2015, Boston, MA, USA. New York: IEEE, 2015:1-9.
- [25] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [EB/OL]. (2014-09-04) [2022-05-08]. <https://arxiv.org/abs/1409.1556>.
- [26] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]//IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 770-778.
- [27] ZHAI X, JELFS B, CHAN R H, et al. Self-recalibrating surface EMG pattern recognition for neuroprosthesis control based on convolution neural network[J]. Frontiers in Neuroscience, 2017, 11:379.

作者简介:

刘 聪 (1982—),男,博士,副教授,硕士生导师,主要从事数字图像处理和模式识别方面的研究。