

用于运动单元活动追踪的动作电位卷积神经网络分类方法仿真研究

李怡欣^{1,2}, 郑杨^{1,2}

(1. 西安交通大学机械工程学院, 710049, 西安;

2. 西安交通大学机械制造系统工程国家重点实验室, 710049, 西安)

摘要: 为了解决在真实条件下运动单元动作电位(MUAP)波形变异导致的 MUAP 分类识别准确率低,进而降低运动单元(MU)追踪性能的问题,提出了一种基于卷积神经网络(CNN)的 MUAP 分类方法,并利用仿真数据进行了效果验证。该方法以被称为 MU 指纹的 MUAP 波形作为模型输入,结合 Keras 深度学习框架设计的 CNN 网络结构简单,并采取 Early-stop 策略训练网络,可实现不同 MU 的准确分类和匹配,从而持续追踪给定 MU 放电活动。所提基于 CNN 的 MU 分类方法能够在样本量较小的情况下,即每个 MU 可获取 (54.49 ± 29.28) 个 MUAP 波形样本,对平均 (30.23 ± 5.37) 个 MU 进行准确分类,分类准确性达到 $(89.41\% \pm 3.72\%)$,显著高于现有的基于 MUAP 波形相似度的方法 $(49.66\% \pm 6.12\%)$ 。结果表明,所提方法对 MUAP 波形变异展现出了更好的鲁棒性,为开展真实条件下 MU 放电活动持续追踪研究提供重要的技术支撑,对运动控制的神经机制研究等具有重要意义。

关键词: 肌电分解;运动单元追踪;运动单元动作电位;卷积神经网络

中图分类号: R318.04 **文献标志码:** A

DOI: 10.7652/xjtuxb202306002 **文章编号:** 0253-987X(2023)06-0010-08

Simulation Study on CNN-Based Motor Unit Action Potential Classification Method for Activity Tracking of Motor Unit

LI Yixin^{1,2}, ZHENG Yang^{1,2}

(1. School of Mechanical Engineering, Xi'an Jiaotong University, Xi'an 710049, China;

2. State Key Laboratory for Manufacturing Systems Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: To solve the problem of low accuracy of motor unit action potential (MUAP) waveform similarity classification method caused by MUAP waveform variation under real conditions, which reduces the tracking performance of the motor unit (MU), a MUAP classification method based on convolutional neural network (CNN) was proposed and tested using the simulated high-density electromyogram (EMG) recordings in this paper. The network was designed with the Keras deep-learning framework and had a simple structure with the MUAP waveform called MU "fingerprints" as the input. The network was trained using the early-stop strategy in order to realize the classification and matching of different MUs, and thus longitudinal tracking of the dis-

收稿日期: 2022-11-16。 作者简介: 李怡欣(1999—),女,硕士生;郑杨(通信作者),男,副教授,博士生导师。 基金项目: 科技创新 2030 基金资助项目(2022ZD0209800);国家自然科学基金资助项目(52105309);陕西省秦创原引用高层次创新创业人才资助项目(QCYRCXM-2022-34)。

网络出版时间: 2023-01-30 网络出版地址: <https://kns.cnki.net/kcms/detail//61.1069.T.20230120.1545.003.html>

charge activities of given MUs. The results showed that the proposed CNN-based method could reach a classification accuracy of $(89.41\% \pm 3.72\%)$ among (30.23 ± 5.37) MUs on average even when only (54.49 ± 29.28) MUAP waveform samples were available for individual MUs. The performance of the proposed method was significantly higher than the conventional MUAP waveform similarity classification method with an accuracy of $(49.66\% \pm 6.12\%)$. These results demonstrated that the proposed method was more robust to the variation of MUAP waveforms. The proposed method has the potential to promote the studies in which longitudinal tracking of MU discharge activities is needed, and it is of great significance for multiple studies such as the exploration of the neural mechanisms underlying motor control.

Keywords: electromyogram decomposition; motor unit tracking; motor unit action potential; convolution neural network

肌肉收缩的最小功能单元是运动单元(MU),即一个 α 运动神经元及其支配的所有肌纤维。中枢神经系统(脑、脊髓)控制肌肉收缩实际是通过调节运动单元活动实现的,即中枢神经系统会根据不同的任务,通过改变募集MU的数量、类型和放电频率来调节肌力大小,进而产生协调的运动。MU放电活动信息在运动控制神经基础研究^[1]、运动损伤神经机制研究^[2]及神经-肌接口^[3]等多个方面均具有重要应用价值。

运动单元放电活动可通过表面肌电分解^[4]技术获得,即通过记录的肌电(EMG)信号反演求解各MU放电事件序列,但现有的经典肌电分解算法无法在两次独立的肌电分解过程后追踪同一个MU的放电活动。具体来讲,尽管对每次实验记录的EMG数据进行分解可分别获得若干MU的放电活动,但目前还无法准确判断两次肌电分解所提取识别的MU是否同属一个MU,导致无法连续追踪某一特定MU的放电活动。追踪MU放电活动特性变化对运动控制神经基础研究、运动损伤神经机制研究以及肌电自适应实时分解技术中均具有重要作用^[5]。

MU单次放电后,EMG电极所记录到的电位变化称为这个MU的动作电位(MUAP),是MU所包含肌纤维动作电位经过低通滤波后之和,而EMG信号实际是所有被募集MU动作电位的叠加。MUAP波形可在提取MU放电事件序列后利用锁时平均法^[6]获得。由于各MU肌纤维解剖位置分布不同,各MUAP波形通常存在一定差异,可作为MU的指纹,用于识别MU。因此,MU活动追踪问题实际转化为了各MUAP波形的分类识别问题,可分的运动单元个数越多、分类准确性越高,则可同时正确追踪的MU越多。因此,Martinez等^[7]提出

了基于MUAP波形相关性的MU分类方法,该方法通过计算两MUAP波形间的平均相关系数作为两者相似度指标,并以某一固定值为阈值,若相似度大于该阈值则认为两MUAP属于同一个MU。但是,这一方法并没有考虑MUAP波形的变异性,即MUAP波形会随着多种因素的改变而发生一定变化,如动态收缩或肢体体位改变时记录电极和肌纤维相对空间位置的变化、肌疲劳、放电频率,电极与皮肤接触阻抗等^[8-10]。MUAP波形的变异性会导致基于MUAP波形相似度指标的方法准确性降低,特别是很难区分两个具有类似MUAP波形的MU。此外,固定阈值的选取也缺乏一定的理论或实验依据。

深度学习理论以其强大的建模与数据处理能力,在数据处理方面具有独特的优势^[11],引来了大批学者的关注与研究^[12-13]。现已广泛应用于计算机视觉^[14]、语音识别^[15]以及自然语言处理^[16]、故障诊断^[17]等领域。卷积神经网络(CNN)通常由卷积层、激活层、池化层、全连接层4个部分构成^[18]。与普通神经网络相比,其卷积层具有局部连接和权值共享的特性,这有利于减少卷积层的训练参数,在一定程度上降低了网络的复杂度和计算量^[19],并且CNN对样本噪声有一定的抵抗力^[20]。

针对真实条件下MUAP波形变异导致的基于MUAP波形相似度的分类识别方法准确率显著降低,进而降低运动单元追踪性能的问题,本文提出一种基于卷积神经网络的MUAP波形分类识别方法,利用仿真数据验证了其性能,并与优化了的基于MUAP波形相似度指数的MUAP分类方法进行了性能对比。

1 仿真高密度EMG信号


为验证所提MUAP分类识别方法的有效性,

本研究基于 EMG 信号卷积和模型^[21], 生成了仿真高密度 EMG 信号, 即


$$x_i(k) = \sum_{j=1}^n \sum_{l=0}^{L-1} h_{ij}(l) s_j(k-l) + n_i(k) \quad (1)$$

$$i = 1, 2, \dots, m; k = 0, 1, \dots, K$$


式中: $x_i(k)$ 为第 i 个电极记录的 EMG 信号; k 为离散时间; n, m 分别为被募集 MU 个数、表面电极个数; $n_i(k)$ 为电极 i 处的加性噪声; $h_{ij}(l)$ 为电极 i 记录到的第 j 个 MU 的 MUAP 波形; L 为 MUAP 波形离散时间长度。所用 MUAP 波形具有 $64(8 \times 8)$ 阵列) 个通道, 数据来源于先前的实验数据^[22], 并通过锁时平均法获得。在生成仿真 EMG 信号时, MUAP 波形会随机分配给不同 MU。 $s_j(k)$ 是第 j 个 MU 的放电事件序列, 可由文献^[23]中 MU 募集与编码模型获得, 兴奋性驱动、运动单元放电序列和仿真肌电信号如图 1 所示。模型输入, 即用最大自主收缩力 F_{MVC} 归一化后的肌肉驱动信号时长为 92 s, 并在 0% 至 25% 间变化。当神经驱动达到 25% 时, 共募集 MU 62 个。



(a) 用于生成仿真 EMG 信号的兴奋性驱动



(b) 一次仿真实验生成的 MU 放电序列



(c) HV-SNR5 条件下生成的第 1 通道肌电信号

图 1 兴奋性驱动、运动单元放电序列和仿真肌电信号

Fig. 1 Excitatory drive, motor unit spike trains and simulated EMG signal

为了考察 MUAP 波形变异程度对 MUAP 分类性能的影响, 每次放电时 MUAP 波形幅值会发生随机变化, 并设置了高变异(HV)和低变异(LV)两个等级^[5]。为了考察噪声对分类性能的影响, 生成后的 EMG 信号会添加 5 dB(SNR5) 或 20 dB(SNR20)

的白噪声。因此, 本研究共涉及了 HV-SNR5、HV-SNR20、LV-SNR 和 LV-SNR20 这 4 种仿真实验条件, 每种条件下仿真生成 10 次实验数据, 每次时长 92 s, 采样率为 1 024 Hz。

2 数据处理

2.1 MUAP 波形数据集提取

基于 MUAP 波形特征的 MU 追踪方法, 本质上可转化为对 MUAP 波形的分类问题。为了考察 MUAP 波形分类性能, 需要从仿真 EMG 信号中提取已知标签的 MUAP 波形数据集。具体步骤如下。

步骤 1 以 24 s 为窗长, 12 s 为窗滑动步长, 利用 Fast-ICA 算法对每个窗内的 EMG 数据进行分解, 获得若干 MU 的放电事件序列。

步骤 2 相邻两窗重叠的 12 s 内, 从前窗任选一个 MU, 并考察其与后窗所有 MU 放电事件的同步性, 若最大的同步性数值高于 0.8, 则认为最大同步性数值对应的 MU 与前窗所选 MU 为同一 MU, 并对其放电事件序列进行拼接; 重复上述过程, 直至为前窗所有 MU 完成拼接。

步骤 3 重复步骤 2 所述过程, 直至所有相邻窗间 MU 均完成匹配拼接, 可获得若干 MU 在 92 s 内的持续放电序列。舍弃总放电次数小于 250 的 MU。

步骤 4 对于给定的某一 MU, 利用锁时平均法每 20 次连续放电事件提取一个 MUAP 波形, 如图 2 所示, 则各 MU 可获得数量不等的 MUAP 波形样本。




图 2 HV-SNR5 条件下某 MU 的一个 MUAP 样本

Fig. 2 An MUAP template sample of an MU under the HV-SNR5 condition

至此, 每次实验可获得若干 MU 的数量不等的 MUAP 波形样本, 每个 MUAP 波形样本为 $m \times L$

(本文中为 64×17) 矩阵。


由于不同 MU 的放电事件同步性通常较低,因此可利用放电时刻同步性来判断两个放电事件序列是否同属一个 MU,这一方法广泛应用于先前研究^[5,24-25],其中同步性可计算为 $2N_{\text{com}}/(N_1 + N_2)$, N_{com} 代表两放电事件序列同步的放电次数, N_1 、 N_2 分别代表两放电序列的放电次数。

为了避免样本内最优化问题,将每个 MU 的 MUAP 波形样本数据随机分为 5 份,以 4:1 的比例划分训练集和测试集进行交叉验证,并求取 5 次验证结果的平均值。


2.2 基于 MUAP 相似度指数的 MU 分类器

(1) 相似度指数。相似度指数量化了两个 MUAP 波形间的绝对差异。对于给定的两个 MUAP 波形 $x_i(t)$ 、 $y_i(t)$,其中 $i = 1, 2, \dots, m$ 代表 EMG 通道, $t = 1, \dots, L$ 为离散时间,相似度指数公式^[5]为

$$I_s = 1 - \frac{\sum_i D_i W_i^{-1}}{\sum_i W_i^c}$$
$$D_i = \sum_t (x_i(t) - y_i(t))^2$$



(a) 相似度指数法训练测试流程



(b) CNN 分类器训练测试流程

图 3 两种分类器的分类流程

Fig. 3 Classification process of two classifiers

(3) MUAP 波形分类性能测试。利用测试集 MUAP 样本对基于 MUAP 相似度指数的分类器性能进行测试。对于测试集中的每个 MUAP 样本,计算其和训练集中获得的某一 MUAP 模板间的相似度指数。如果其中最大的相似度指

$W_i = \sum_t (|x_i(t)| + |y_i(t)|)^2$ (2) 式中 $c = 4$ 为调节因子。相似度指数取值范围 $0 \sim 1$,越接近 1 表明两 MUAP 波形越相似,同属一个 MU 的概率越大。

(2) 相似度阈值确定。由于每个 MU 的动作电位波形变异程度不同,因此需要为每个 MU 单独确定一个相似度阈值。当相似度指数大于此阈值时认为不同时刻提取的两个 MUAP 波形同属一个 MU,否则认为属于不同 MU,两种分类器的分类流程如图 3 所示。对于训练集中的某一 MU,首先求取其训练集中所有 MUAP 样本的均值作为此 MU 的 MUAP 模板,然后计算训练集中所有 MUAP 样本和此 MUAP 模板的相似度指数,图 4 所示为 HV-SNR5 条件下某次实验训练集中各 MU 的 MUAP 样本和对应模板间的相似度指数箱型图。由图 4 可知,不同 MU 的 MUAP 波形相似度指数分布存在较大差异,因此需要为每个 MU 单独确定个性化的相似度指数阈值。通过前期测试,取相似度指数分布的 80% 分位数作为各 MU 的相似度指数阈值通常可取得较好的分类效果。

数大于对应 MU 的相似度指数阈值,则认为测试集中的此 MUAP 样本属于对应的 MU。将测试集中所有 MUAP 样本进行分类后,依据测试集各 MUAP 真实标签建立混淆矩阵,并计算准确率。




图 4 一次 HV-SNR5 实验中各 MU 的 MUAP 样本相似度指数箱型图

Fig. 4 Box chart of the MUAP similarity index for individual MUs from a representative trial under the HV-SNR5 condition

2.3 基于 CNN 的 MU 分类器

CNN 避免了对特征的显式抽取,且主要用来识别位移、缩放及其他形式扭曲但又具有特异性的二维图形。对于高密度电极阵列采集到的 MUAP 波形,由于具备一定的二维空间信息,利用 CNN 法有利于挖掘 MUAP 各电极间和单个电极内 MUAP 波形的深层次变化特征。

(1)CNN 模型搭建与训练。利用训练集各 MU 的 MUAP 样本进行 CNN 模型搭建与训练。以各 MUAP 样本作为网络输入,以各 MU 编号作为网络输出,确定初始化参数,结合 Keras 深度学习框架,调用网络层函数,设计 CNN 网络。依据初步测试,为防止过度拟合,本研究选择使用单个卷积层,网络结构如图 5 所示。第 1 层为输入层,输入为 MUAP 样本矩阵为 $L \times 1 \times m$ (本文中为 $17 \times 1 \times 64$);第 2 层为卷积层,滤波器个数为 f (本文中为 64),选用 relu 激活函数,输出大小等于输入大小;第 3 层为平滑层,对数据进行展开;第 4、5 层为全连接层,其中第 4 层的输出个数为 d_1 (本文中为 64),选用 relu 激活函数,第 5 层的输出个数为 N ,即 MU 类别数目(每一组实验中的类别数不一),选用




图 5 CNN 网络结构

Fig. 5 CNN network structure

softmax 激活函数。由于标签本身无序,训练中使用 One-hot 编码器对类别标签进行“二进制化”操作,相对应地选用 categorical_crossentropy 作为损失函数。


采用 Early-stopping 策略训练 CNN 网络,以最低验证集损失为监测指标,设置忍耐次数为 100,防止过拟合现象。持续监控验证集损失,并保存最低验证集损失所对应最优模型。

(2)MUAP 波形分类性能测试。对测试集中的 MUAP 样本,利用训练好的 CNN 网络对其进行分类,获取各 MUAP 样本的编号。输出为 $1 \times N$ 的矩阵,分别代表了该 MUAP 样本属于不同编号 MU 的概率,概率和为 1。选取概率值最大的对应 MU 编号为最终识别结果,同时最大概率值需大于 $1/(N-1)$,否则认为分类失败。将测试集中所有 MUAP 样本进行分类后,依据测试集各 MUAP 真实标签建立混淆矩阵,并计算准确率。


3 结 果

3.1 MUAP 样本集

一 共 在 4 种 条 件 (HV-SNR5, HV-SNR20, LV-SNR5, LV-SNR20) 下 生 成 了 高 密 度 EMG 信 号,每 种 条 件 下 仿 真 生 成 10 次 实 验 数 据,每 次 时 长 92 s。拼 接 后 得 到 的 放 电 次 数 大 于 250 的 MU 数,及 单 个 MU 获 取 的 MUAP 波 形 样 本 数 如 图 6 所 示。



(a) 4 种仿真条件下拼接得到 MU 数



(b) 4 种仿真条件下单个 MU 生成的 MUAP 波形样本数

图 6 4 种仿真条件下拼接得到 MU 数及单个 MU 生成的 MUAP 波形样本数

Fig. 6 Number of spliced MUs obtained under four simulation conditions

4 种仿真条件下拼接能得到 MU 数为 30, 225

± 5.366 , 单个 MU 的 MUAP 样本数为 54.4913 ± 29.2756 。通过多因素方差分析,在置信度 0.05 下,HV、LV 条件下可提取的 MU 数不具有显著差异性($F=0.87, P=0.3519$),而 SNR5 与 SNR20 下可提取的 MU 数目差异显著($F=426.99, P<0.0001$)。更高的信噪比可以提取到更多 MU,这可能与离线分解过程中信噪比更高的 EMG 能够获得更好的分解结果有关。

3.2 MU 分类准确率

根据对精确度和召回率的统计,基于 MUAP 相似度指数的分类器对正例的判定激进,对负例的判别较保守,而基于 CNN 的分类器对正负例判定较为中立。两种分类方法在不同仿真实验条件下两种分类器的混淆矩阵如图 7 所示。




图 7 4 种不同仿真条件下的混淆矩阵

Fig. 7 Confusion matrix under four different conditions

在本文所生成的所有数据中,基于 CNN 的 MU 分类器总体分类准确率($89.41\% \pm 3.72\%$)显著高于基于 MUAP 相似度指数的 MU 分类器准确率($49.66\% \pm 6.12\%$),4 种条件下两种分类器的准确率对比如图 8 所示。




图 8 两种分类器的准确率对比

Fig. 8 Comparison of accuracy of two classifiers

通过多因素方差分析考察 MUAP 波形变异大小及 EMG 信号信噪比对两种方法性能的影响,结

果表明,MUAP 波形变异大小($F=8.53, P=0.0039$)及 EMG 信号信噪比($F=36.92, P<0.0001$)可对基于相似度指数的分类器性能产生显著影响。此外,MUAP 波形变异大小($F=4.04, P=0.0457$)同样可对基于 CNN 的分类器性能产生显著影响,但 EMG 信噪比对基于 CNN 的分类器性能无显著影响($F=6.19, P=0.483>0.05$)。因此,CNN 分类器在不同 MUAP 波形变异等级和不同信噪比情况下具有更好的鲁棒性。

由于各 MU 支配肌纤维空间分布、大小等存在差异,导致在皮肤表面记录到的各 MU 的 MUAP 波形存在差异,可用于识别追踪各 MU 活动。现有方法通过直接比较两个 MUAP 波形的差异来判断是否同属一个 MU,但是这种方法没有考虑 MUAP 波形变异性等带来的影响。在本研究中,仿真 EMG 数据引入了 MUAP 波形变异,从而导致现有基于相似度指数分类方法的性能显著降低。相反,基于 CNN 的方法并不要求 MUAP 波形绝对恒定,CNN 通过卷积运算代替一般神经网络的乘法运算,使用多个卷积核分别进行卷积处理,能够自适应提取不同类型的特征,卷积的稀疏连接同时也起到了正则化的效果,网络稳定性和泛化能力优异。这意味着一维卷积层可以识别序列中的局部模式,该模式可以稍后在其他位置被识别,此外卷积层局部链接和权值共享提供了更小的计算代价,运算迅捷,因此在面对 MUAP 波形变异时可取得更好的分类识别效果。

4 结 论

针对真实条件下 MUAP 波形变异导致的基于 MUAP 波形相似度的分类识别方法准确率显著降低,进而降低运动单元追踪性能的问题,本文提出一种利用 CNN 网络挖掘 MUAP 波形时空信息的 MU 分类追踪方法。此方法无需人工提取 MUAP 波形特征,模型直接以 MUAP 波形作为输入,并可自动通过学习并不断优化,最终达到理想的识别分类效果。仿真研究结果表明,基于 CNN 的分类器性能显著优于已有的基于波形相似度的 MUAP 分类识别方法。在平均 30 个 MU 的情况下,分类准确率可接近 90%,且与现有方法相比,对 EMG 信号信噪比和 MUAP 波形变异程度具有更好的鲁棒性。本文所提基于 CNN 网络的 MU 分类方法,可用于 MUAP 波形存在变异情况下的 MU 放电活动追踪,对进一步开展运动损伤神经机制研究以及基

于 MU 放电活动的神经-机接口解码技术研究等具有重要意义。

本文仅考虑到 MUAP 幅值变异,后续将进一步研究 MUAP 其他类型变异对分类追踪效果的影响,并采集真是实验数据加以验证;在 CNN 模型上,后续研究将继续改进神经网络结构,加入结构风险更小的分类层,以期进一步提高该分类器的分类准确率和泛化能力。

参考文献:

- [1] SØGAARD K. Motor unit recruitment pattern during low-level static and dynamic contractions [J]. *Muscle & Nerve*, 1995, 18(3): 292-300.
- [2] MURPHY S A, NEGRO F, FARINA D, et al. Stroke increases ischemia-related decreases in motor unit discharge rates [J]. *Journal of Neurophysiology*, 2018, 120(6): 3246-3256.
- [3] ZHENG Yang, HU Xiaogang. Concurrent estimation of finger flexion and extension forces using motoneuron discharge information [J]. *IEEE Transactions on Biomedical Engineering*, 2021, 68(5): 1638-1645.
- [4] DE LUCA C J, ADAM A, WOTIZ R, et al. Decomposition of surface EMG signals [J]. *Journal of Neurophysiology*, 2006, 96(3): 1646-1657.
- [5] ZHENG Yang, HU Xiaogang. Adaptive real-time decomposition of electromyogram during sustained muscle activation: a simulation study [J]. *IEEE Transactions on Biomedical Engineering*, 2022, 69(2): 645-653.
- [6] HU Xiaogang, RYMER W Z, SURESH N L. Motor unit pool organization examined via spike-triggered averaging of the surface electromyogram [J]. *Journal of Neurophysiology*, 2013, 110(5): 1205-1220.
- [7] MARTINEZ-VALDES E, NEGRO F, LAINE C M, et al. Tracking motor units longitudinally across experimental sessions with high-density surface electromyography [J]. *The Journal of Physiology*, 2017, 595(5): 1479-1496.
- [8] 褚雪忠, 杨基海, 李强, 等. 电极配置对 MUAP 检测影响的仿真研究 [J]. *生物医学工程研究*, 2006, 25(3): 137-140, 146.
CHU Xuezhong, YANG Jihai, LI Qiang, et al. A simulation study on the influence of electrode's configuration on motor unit action potential detection [J]. *Journal of Biomedical Engineering Research*, 2006, 25(3): 137-140, 146.
- [9] STEGEMAN D F, BLOK J H, HERMENS H J, et al. Surface EMG models: properties and applications [J]. *Journal of Electromyography and Kinesiology*, 2000, 10(5): 313-326.
- [10] FARINA D, GAZZONI M, CAMELIA F. Low-threshold motor unit membrane properties vary with contraction intensity during sustained activation with surface EMG visual feedback [J]. *Journal of Applied Physiology*, 2004, 96(4): 1505-1515.
- [11] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks [J]. *Science*, 2006, 313(5786): 504-507.
- [12] LECUN Y, BENGIO Y, HINTON G. Deep learning [J]. *Nature*, 2015, 521(7553): 436-444.
- [13] LI Haoxiang, LIN Zhe, SHEN Xiaohui, et al. A convolutional neural network cascade for face detection [C]//*IEEE Conference on Computer Vision and Pattern Recognition*. Piscataway, NJ, USA: IEEE, 2015: 5325-5334.
- [14] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. *Communications of the ACM*, 2017, 60(6): 84-90.
- [15] HINTON G, DENG Li, YU Dong, et al. Deep neural networks for acoustic modeling in speech recognition: the shared views of four research groups [J]. *IEEE Signal Processing Magazine*, 2012, 29(6): 82-97.
- [16] KIM Y. Convolutional neural networks for sentence classification [EB/OL]. [2022-10-10]. <https://arxiv.org/abs/1408.5882>.
- [17] 陈保家, 陈学力, 沈保明, 等. CNN-LSTM 深度神经网络在滚动轴承故障诊断中的应用 [J]. *西安交通大学学报*, 2021, 55(6): 28-36.
CHEN Baojia, CHEN Xueli, SHEN Baoming, et al. An application of convolution neural network and long short-term memory in rolling bearing fault diagnosis [J]. *Journal of Xi'an Jiaotong University*, 2021, 55(6): 28-36.
- [18] 吕阳, 廖与禾, 王报祥, 等. 基于 VMD 和 CNN 的滚动轴承故障定量诊断方法 [J]. *中国科技论文*, 2020, 15(7): 735-742.
LÜ Yang, LIAO Yuhe, WANG Baoxiang, et al. Quantitative diagnosis method for rolling bearing faults based on VMD and CNN [J]. *China Sciencepaper*, 2020, 15(7): 735-742.
- [19] 姜洪开, 邵海东, 李兴球. 基于深度学习的飞行器智能故障诊断方法 [J]. *机械工程学报*, 2019, 55(7): 27-34.
JIANG Hongkai, SHAO Haidong, LI Xingqiu. Deep learning theory with application in intelligent fault di-

agnosis of aircraft [J]. Journal of Mechanical Engineering, 2019, 55(7): 27-34.

[20] 段艳杰, 吕宜生, 张杰, 等. 深度学习在控制领域的研究现状与展望 [J]. 自动化学报, 2016, 42(5): 643-654.
DUAN Yanjie, LÜ Yisheng, ZHANG Jie, et al. Deep learning for control: the state of the art and prospects [J]. Acta Automatica Sinica, 2016, 42(5): 643-654.

[21] CHEN Maoqi, ZHOU Ping. A novel framework based on FastICA for high density surface EMG decomposition [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2016, 24(1): 117-127.

[22] ZHENG Yang, HU Xiaogang. Real-time isometric finger extension force estimation based on motor unit discharge information [J]. Journal of Neural Engineering, 2019, 16(6): 066006.

[23] FUGLEVAND A J, WINTER D A, PATLA A E. Models of recruitment and rate coding organization in motor-unit pools [J]. Journal of Neurophysiology, 1993, 70(6): 2470-2488.

[24] ZHENG Yang, XU Guanghua, LI Yixin, et al. Improved online decomposition of non-stationary electromyogram via signal enhancement using a neuron resonance model: a simulation study [J]. Journal of Neural Engineering, 2022, 19(2): 026030.

[25] XU Feng, ZHENG Yang, HU Xiaogang. Real-time finger force prediction via parallel convolutional neural networks: a preliminary study [C]//42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society. Piscataway, NJ, USA: IEEE, 2020: 3126-3129.

(编辑 赵炜 杜秀杰)