

基于深度学习的手腕多运动模式分类模型

张 越^{1,2}, 唐源敏^{1,2}, 李素姣^{1,2,3*}

¹上海理工大学康复工程与技术研究所, 上海

²上海康复器械工程技术研究中心, 上海

³民政部神经功能信息与康复工程重点实验室, 上海

收稿日期: 2023年4月10日; 录用日期: 2023年5月24日; 发布日期: 2023年5月31日

摘 要

基于sEMG信号模式识别的假肢控制方法是目前重要的假肢控制方法, 为了解决分类识别率和时间延迟无法兼顾的问题, 本文结合CNN与RNN的优势, 提出一种适用于sEMG的基于一维卷积循环网络(1D-CNN-RNN)的手腕动作分类模型, 并对其实时识别性能进行分析。本文提出的1D-CNN-RNN分类模型对设定的多种手和腕部动作模式有较好的分类效果, 并且平均时延在人体无明显延迟感的时间范围内, 有望为肌电假肢手提供一种有效的控制方法。

关键词

分类模型, 一维卷积神经网络, 循环神经网络, 表面肌电信号

Classification Model for Hand and Wrist Multiple-Mode Pattern Based on Deep Learning

Yue Zhang^{1,2}, Yuanmin Tang^{1,2}, Sujiao Li^{1,2,3*}

¹Institute of Rehabilitation Engineering and Technology, University of Shanghai for Science and Technology, Shanghai

²Shanghai Engineering Research Center of Assistive Devices, Shanghai

³Key Laboratory of Neural-Functional Information and Rehabilitation Engineering of the Ministry of Civil Affairs, Shanghai

Received: Apr. 10th, 2023; accepted: May 24th, 2023; published: May 31st, 2023

*通讯作者。

文章引用: 张越, 唐源敏, 李素姣. 基于深度学习的手腕多运动模式分类模型[J]. 建模与仿真, 2023, 12(3): 2940-2949.
DOI: 10.12677/mos.2023.123271

Abstract

The prosthesis control method based on sEMG signal pattern recognition is an important prosthesis control method at present. A classification model of hand and wrist movements based on one-dimensional convolutional neural network and recurrent neural network (1D-CNN-RNN) was proposed, in order to solve the problem that classification recognition rate and time delay cannot be taken into account. This model combined the advantages of CNN and RNN. Its real time recognition performance was analyzed. The proposed 1D-CNN-RNN classification model has a good classification effect on various hand and wrist motion patterns. The average delay is within the time range that the human body has no obvious sense of delay. It is expected to provide an effective control method for myoelectric prosthetic hand.

Keywords

Classification Model, 1D-CNN, RNN, Surface EMG

Copyright © 2023 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

肌电假肢是通过人体自身的表面肌电(Surface Electromyography, sEMG)信号控制机械装置进行相应运动的一种假肢[1]。随着算法和微处理器的发展,研究者们提出了基于 sEMG 信号模式识别的假肢控制方法,以便于实现快速且直观的假肢控制。该方法可极大程度地利用肌电信号中蕴含的信息,例如肌肉收缩的持续时间、肌肉运动时产生的 sEMG 信号幅值大小等,实现多自由度假肢运动控制,不仅可以提升肢体残疾人群的生活质量,更对他们回归社会起到了推动作用。

当前基于 sEMG 信号的肌电假肢模式识别算法可分为两大类:基于经典分类器的模式识别算法以及基于深度学习的模式识别算法。基于传统机器学习的 sEMG 模式识别中,手工提取的特征对于识别效果起到十分重要的影响。而对于未处理的原始 sEMG 信号,传统机器学习方法因其无法有效地对抽象、高维的数据进行分类训练,具有一定的局限性,较难取得很高的分类精度。随着人工智能技术的发展,深度学习在运动模式识别和图像分类等领域取得了良好的成绩。深度学习具有强大的学习能力,因其具有可自主从输入样本中学习不同抽象层级特征的功能,可以规避传统机器学习中复杂的特征提取部分,从而实现端到端的 sEMG 模式识别。

卷积神经网络(CNN)和循环神经网络(RNN)是目前流行的两种深度学习算法模型,在表面肌电图模式检测中得到了广泛的应用。一些团队提出了基于 CNN 架构的网络模型[2] [3] [4] [5] [6]角度改进 CNN 的分类性能,包括从原始 sEMG 信号生成瞬时肌电图像[3]、延时的 sEMG 频谱图作为输入[4]、使用多流分解阶段以及融合阶段对 CNN 模型进行训练[5]、基于 CNN 的特征提取方法(CNNFeat) [6]等。RNN 模型是一种可以通过动态地改变内部状态来处理时序信息的神经网络模型[7],一些团队提出了基于 RNN 的分类模型[8] [9] [10] [11] [12],研究结果表明 RNN 模型在延时问题上有可靠的表现。另外,作为 RNN 的改进模型, LSTM 可以解决其存在的梯度消失以及长期依赖的问题[11]。还有一些团队提出了 CNN-RNN 复合神经网络结构[13] [14] [15] [16],可以同时 sEMG 灰度图像的空间信息和时序信息进行捕获,结果表

明深度体系结构可以提高分类的准确性和鲁棒性。

综上所述, 目前的研究大多集中在复杂情况下的准确性, 虽然准确性是模式识别算法的主要研究方向, 但实时性能也是模式识别算法能否应用于上肢假肢的重要因素之一。因此, 我们希望提出一种模式识别方法, 能够在实时分类性能方面取得突破, 以期为上肢假肢肌电控制提供可行的实时识别方案。CNN 能够将特征提取和分类相结合, 基于原始数据学习最优特征和分类器参数。1D-CNN 可以有效地训练数据集中有限的一维数据, 具有更好的实时性能, 而 RNN 在处理时间问题方面具有可靠的性能。两者都能在保持一定精度的基础上提高模型的实时性能。因此, 我们结合 1D-CNN 和 RNN 的优势, 提出了一种基于表面肌电信号的一维卷积循环神经网络分类模型(1D-CNN-RNN)。

2. 基于 1D-CNN-RNN 的动作分类模型

2.1. 卷积神经网络(CNN)与循环神经网络(RNN)

CNN 专用于处理如时间序列数据和图像数据这种具有类似网格结构数据, 是深度学习领域具有革命性意义的模型, 在诸多应用领域都有优异的表现。CNN 模型包括卷积层、池化层和全连接层, 一般地, 需要多个 CNN 框架组合形成最后的模型。卷积层使用卷积核, 配合步幅对上一层的输入提取局部连接的信息, 并将其传递给下一层, 从而实现前一层的权值和后一层的权值共享, 是 CNN 极其重要的组成部分。这一结构使得 CNN 可检测到平移不变的特征, 随着神经网络深度的增加, 卷积层提取的特征逐渐变得更加详细。因此, 基于这一特点, CNN 取代了手工特征提取, 实现端到端的模式识别, 显著减少了训练时长, 并降低了模型构建过程中的复杂度。

RNN 是一类用于处理序列数据的反向传播神经网络模型, 可通过循环连接进行内部状态的更改。这一特点使得 RNN 处理如语音、文本等时间依赖信号时表现优异。RNN 结构单元随时间展开后, 当前隐含层状态与上一时刻的输入和隐藏层权重有关, 当要求实现长期记忆时, RNN 当前隐含层状态的求解与前 n 次有关, 如式 1 所示。

$$s_t = f(\mathbf{U} * x_t + \mathbf{W} * s_{t-1} + \mathbf{W} * s_{t-2} + \dots + \mathbf{W} * s_{t-n}) \quad (1)$$

其中 x 为输入向量, s 为隐藏层数值, \mathbf{U} 属于输入层至隐藏层的权重矩阵, \mathbf{W} 为隐藏层上一时刻的值作为该时刻输入的权重矩阵。当 n 增大, 模型计算量将指数增长, 从而使得模型训练的时间显著延长。且处理长时间问题时, 数据在遍历 RNN 时每个步长都会丢失一些信息, 因此梯度消失造成的较远信息对该时刻产生的影响非常小, 从而导致 RNN 的状态几乎没有最初输入的痕迹[17]。因此传统 RNN 模型不适用于长期记忆计算。

而 LSTM 作为 RNN 的变体对于解决这一问题具有很大的优势, LSTM 单元主要包括主要层和三个门控制器(输入门、遗忘门和输出门)。主要层用于分析当前输入向量与短期状态, 将最重要的部分存储于长期状态中。遗忘门控制删除部分长期状态, 输入门控制添加部分长期状态, 输出门控制当前时间步长读取部分长期状态[18]。LSTM 计算公式如式 2~式 4 所示, 其中向量 h_t 为短期状态, c_t 为长期状态; i , g , f , o 分别表示输入门、主要层、遗忘门和输出门; 每层与输入向量 x_t 连接的权重矩阵是 \mathbf{W} ; b 为偏置量; \odot 表示向量对应元素相乘。

$$\begin{pmatrix} i \\ f \\ o \\ g \end{pmatrix} = \begin{pmatrix} \sigma \\ \sigma \\ \sigma \\ \tanh \end{pmatrix} \left(\mathbf{W} \begin{bmatrix} h_{t-1} \\ x_t \end{bmatrix} + b \right) \quad (2)$$

$$c_t = f \odot c_{t-1} + i \odot g \quad (3)$$

$$h_t = O_t \odot \tanh(c_t)$$

(4)

2.2. 构建一维卷积循环神经网络(1D-CNN-RNN)

本研究设计的一维卷积循环神经网络模型(1D-CNN-RNN)如图 1 所示。该神经网络模型包括四个模块：模块一包括两层 64 个一维卷积层单元，通过非线性激活函数 ReLU 提取特征；批量归一化层(Batch Normalization, BN)，主要作用是将上一层激活值规范化；以及一个窗长为 2 的最大池化层(Max Pooling, MP)。与模块一类似，模块二包括两层 128 个以 ReLU 为激活函数的一维卷积层单元、BN 层、窗长为 2 的 MP 层和 dropout 率为 0.2 的 Dropout 层；模块三由两层以 tanh 为激活函数的 LSTM 单元和两层 Dropout 层(dropout 率分别为 0.2, 0.5)组成；模块四则包含了全连接层(Dense 层)、Flatten 层和 Softmax 层，通过前面模块提取出的数据特征经 Dense 层进行连接,然后通过 Flatten 层展平,最后的 Softmax 层进行分类，输出结果。

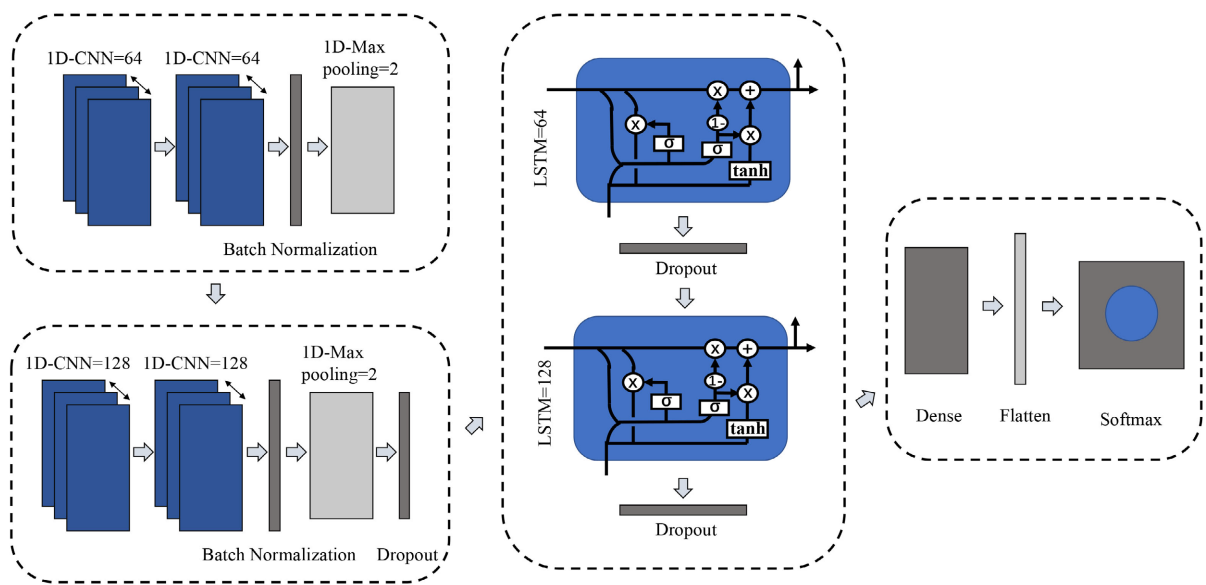


Figure 1. Schematic diagram of 1D-CNN-RNN
图 1. 一维卷积循环神经网络模型示意图

该架构的基本思想是将 CNN 和 RNN 组合，充分利用 CNN 在特征提取和多维时序信号处理方面的优势，并添加 LSTM 结构，以克服 CNN 在时延方面的缺点。1D-CNN-RNN 参数状况如表 1 所示。

Table 1. Parameter of 1D-CNN-RNN
表 1. 1D-CNN-RNN 参数

层	数据输出形状	Param
1D-CNN	(512, 64)	512
1D-CNN	(512, 64)	28,736
BN	(512, 64)	256
MP	(256, 64)	0
1D-CNN	(256, 128)	24,704
1D-CNN	(256, 128)	49,280

Continued

BN	(256, 128)	512
MP	(128, 128)	0
Dropout	(128, 128)	0
LSTM	(128, 64)	49,408
Dropout	(128, 64)	0
LSTM	128	98,816
Dropout	128	0
Dense	64	8256
Flatten	64	0
Softmax	20	1300

3. 实验与结果分析

3.1. 实验方案

实验的整体流程图如图 2 所示。本研究使用无线 gForce 肌电臂环(上海傲意信息科技有限公司)记录数据,臂环由八个肌电传感器组成,采样频率为 1000 Hz。gForce 臂环戴在受试者右前臂上方,并置于肘部折痕和尺骨鹰嘴突的远端两到三厘米处,覆盖桡侧腕伸肌、指伸肌、尺侧腕伸肌和指浅屈肌等肌肉的主收缩区。实验过程中,受试者根据引导视频进行相应的手腕运动,并以中等力度保持肌肉收缩。当引导视频中显示为恢复自然状态,受试者上肢回到放松状态。

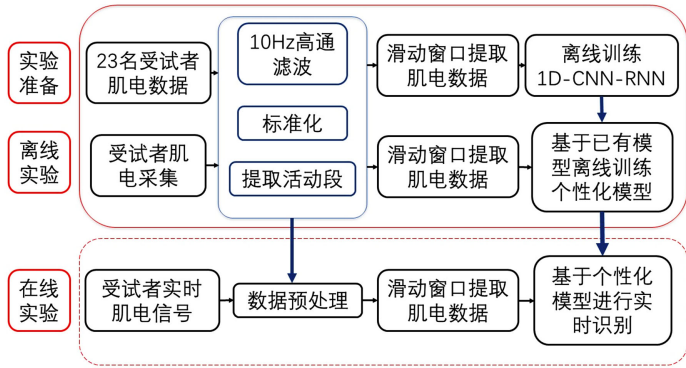


Figure 2. Online experimental design scheme

图 2. 实验设计方案

本研究设计了包括了手指和腕部的基本运动,以及日常生活中常用的手势的 20 种前臂运动模式,如图 3 所示。

实验采集受试者 20 种前臂运动模式下的 sEMG 信号,各运动重复十次,每次动作持续 3 秒,放松 3 秒后重复该动作,不同动作之间休息 5 分钟。采集完 23 名受试者的数据后,对数据进行预处理,以 64 ms 窗长、64 ms 步长的滑动窗口提取处理好的数据并生成数据集,将该数据集作为本文设计的 1D-CNN-RNN 模型与对照组模型(1D-CNN 和 LSTM)的输入,计算相应的评价指标,用于验证本文设计的 1D-CNN-RNN 的分类性能。每个模型训练时使用的超参数均一致,训练轮次 Epoch = 30,批量 batch size 均为 128,优化器使用 Adam,设置初始学习率为 0.001,采用交叉熵损失函数作为模型的损失函数。



Figure 3. Forearm movement pattern information

图 3. 前臂运动模式信息

在线实验过程中,受试者根据引导视频进行相应手腕动作,各动作重复 20 次,每次持续 3 秒,放松 3 秒后继续下一个动作,不同动作之间休息 3 分钟。实验操作人员实时记录系统显示的对应动作的识别结果。实验结束后统计结果正确次数与总次数的比例,以及实时模式识别的平均时延。

3.2. 离线实验结果分析

首先对 23 名受试者的测试数据基于 1D-CNN, LSTM 和 1D-CNN-RNN 三种模型的识别结果进行比较,各项性能评价指标如表 2 所示。分类性能方面,1D-CNN 进行了连续多层的卷积操作,提取的特征可分性较强,虽训练耗时较后两种模型而言最短,但测试集分类准确率(85.43%)和损失值(0.4446)远没有满足模式识别系统准确率的要求。LSTM 模型相较于 1D-CNN 模型分类准确率有显著提高,但训练耗时最长,为后者的 3.33 倍。而相较于单独的 1D-CNN 或 LSTM 模型,1D-CNN-RNN 对 20 种运动模式的分类性能表现更好:测试集准确率达到 98.88%;训练与测试的损失值最小;其训练耗时是 LSTM 模型的 41%;召回率为 98.88%,精确率为 98.96%, $F1$ 值为 0.9896,在三类模型中均为最高。

Table 2. Pattern recognition results of three neural network models

表 2. 三种神经网络模型的模式识别结果

模型	数据集	损失值	召回率	准确率	精确率	$F1$ 指数	训练耗时
1D-CNN	训练集	0.6431	73.14%	77.99%	83.34%	0.7791	493 分钟
1D-CNN	测试集	0.4446	79.93%	85.43%	90.55%	0.8491	/
LSTM	训练集	0.1497	94.75%	95.39%	96.17%	0.9545	1642 分钟
LSTM	测试集	0.0952	96.58%	96.88%	93.77%	0.9695	/
1D-CNN-RNN	训练集	0.0607	98.01%	98.19%	98.42%	0.9821	672 分钟
1D-CNN-RNN	测试集	0.0340	98.88%	98.96%	99.04%	0.9896	/

进一步通过混淆矩阵对三种模型的识别性能进行分析,如图 4 所示。1D-CNN 模型的分类中,动作 7、10、14 和 15 的识别准确率均未达到 80%。LSTM 模型对四指伸展(动作 11)的识别效果最差,更倾向于将其识别成拇指侧向内收(动作 12)和五指伸展(动作 14)。对于相似动作之间的识别,1D-CNN-RNN 模型具有更好地识别性能,20 种运动模式识别准确率均达到了 97% 及以上。




Figure 4. Confusion matrix for pattern recognition of three models
图 4. 三种模型模式识别混淆矩阵

综上所述,在相同的信号预处理和神经网络超参数设置下,1D-CNN-RNN 模型的模式识别性能最好,LSTM 模型居中,1D-CNN 模型最差。与 LSTM 模型相比,使用 1D-CNN-RNN 神经网络模型的优势在于 LSTM 单元之前的卷积层降低了其输入的维度,减少了计算量,进一步提高了效率。1D-CNN-RNN 模型中设计的批量归一化对于卷积层的特征提取有积极作用,添加的 dropout 层可防止过拟合,从而使得模型结构较为稳定。

3.3. 在线实验结果分析

十名在线识别实验的受试者的离线训练结果如表 3 所示。由表可知,所有受试者离线识别率均达到了 98% 以上,且召回率和精确率维持较高水平且基本稳定。该结果与 1D-CNN-RNN 离线识别结果较为一致,进一步证明了使用新增受试者数据对已有的神经网络模型进行训练的方案可行,且大量缩短了离线训练的时间,提高了效率。

Table 3. The results of each evaluation index of neural network training set
表 3. 神经网络训练集各评价指标结果

编号	准确率	损失值	召回率	精确率	F1 指数
1	99.82%	0.0065	99.80%	99.85%	0.9983
2	99.34%	0.0274	99.28%	99.39%	0.9934
3	98.73%	0.0407	98.60%	98.81%	0.9870
4	99.04%	0.0328	98.98%	99.20%	0.9909
5	98.15%	0.0580	97.98%	98.34%	0.9816
6	99.15%	0.0303	99.06%	99.25%	0.9915
7	98.18%	0.0539	97.98%	98.42%	0.9820
8	99.33%	0.0265	99.31%	99.43%	0.9937
9	98.30%	0.0547	98.19%	98.35%	0.9827
10	99.27%	0.0259	99.20%	99.35%	0.9928
平均值	0.9893 ± 0.0057	0.0357 ± 0.0162	0.9884 ± 0.0062	0.9884 ± 0.0062	0.9894 ± 0.0057

十名受试者 20 种运动模式实时识别的结果如图 5、图 6 所示。由图 5 可知, 十名受试者的各动作的平均准确率为 $91\% \pm 5\%$, 其中, 休息、伸食指和中指、五指抓、四指捏、四指伸展、握拳、五指伸展、五指捏、腕外旋、腕屈曲和腕伸展等动作模式的实时识别率均达到了 90% 以上。这些动作的特征明显, 肌肉发力方式不易混淆, 因此取得了较好的识别效果。而伸拇指、捏食指、三指捏和拇指侧向内收并未得到十分准确的识别。这可能是由于以上动作均包括拇指的相关运动, 拇指的相关运动涉及到的手部肌肉较多, 因此 sEMG 信号相似程度较高且强度较大, 其余手指运动的细节信号容易被淹没, 导致这些动作会产生错误识别。由此得出结论: 当 sEMG 信号提供的有效区分信息不足时, 易导致运动模式识别错误。




Figure 5. Identification accuracy of each action in online experiment (error bar represents standard deviation)
图 5. 在线识别中各动作的识别准确率(误差棒表示标准差)




Figure 6. Identification accuracy of each subject in online experiment (S1-S10 is subject number, error bar represents standard deviation)

图 6. 在线识别中各受试者的识别准确率(S1-S10 为受试者编号, 误差棒表示标准差)

进一步对不同受试者组内的识别进行分析, 如图 6 所示。1 号受试者的平均识别率最低, 仅 79%, 分析发现, 可能是由于其惯用手为左手, 而在线实验模型是基于以离线识别实验的右手数据以及她本人的左手数据训练出来的。而随着受试者增多, 实时识别的准确率呈上升趋势, 后续左利手受试者(3 号和 7 号受试者)的动作识别准确率也显著大于 1 号受试者, 表明随着模型训练数据的增加, 1D-CNN-RNN 识别准确率得到进一步提升。

另外, 在线实验还测试了模型在实时识别中的时间延迟, 1D-CNN-RNN 在实验过程中的平均时间延迟为 153 ms, 实验平台为 Intel (R) Core (TM) i5-10500 CPU @ 3.10 GHz, 说明 1D-CNN-RNN 的实时识别性能较为优秀。

4. 结论

为实现快速且准确的手、腕部多运动模式识别, 本研究提出了一种基于 sEMG 信号的 1D-CNN-RNN 模型, 并分别开展了离线和在线实时识别性能研究。离线模式识别中, 发现 1D-CNN-RNN 模型的各项评价指标均显著高于常用的 1D-CNN 和 LSTM 两种模型, 其准确率可达 98.96%, 对相似动作的识别效果更好。在线模式识别的结果表明, 该 1D-CNN-RNN 模型在多数动作的识别准确率上表现优异, 平均识别准确率可达到 91%, 且具有很好的时间延迟, 相较以往文献中报道的在线实时识别延时性能具有显著优势, 人体无明显延迟感的时间范围为 0~300 ms [19], 而本研究中平均时延仅为 153 ms, 因此, 有望实现肌电假肢的运动模式的低延迟实时识别。

基金项目

国家重点研发计划项目(No. 2020YFC2007902), 国家自然科学基金项目(No. 61903255)。

参考文献

- [1] Scheme, E. and Eenglehart, K. (2011) Electromyogram Pattern Recognition for Control of Powered Upper-Limb Prostheses: State of the Art and Challenges for Clinical Use. *Journal of Rehabilitation Research & Development*, **48**, 643-659. <https://doi.org/10.1682/JRRD.2010.09.0177>
- [2] Manfredo, A., Matteo, C. and Henning, M. (2016) Deep Learning with Convolutional Neural Networks Applied to Electromyography Data: A Resource for the Classification of Movements for Prosthetic Hands. *Frontiers in Neurobotics*, **10**, Article 9. <https://doi.org/10.3389/fnbot.2016.00009>
- [3] Geng, W., Du, Y., Jin, W., et al. (2016) Gesture Recognition by Instantaneous Surface EMG Images. *Scientific Reports*, **6**, Article No. 36571. <https://doi.org/10.1038/srep36571>
- [4] Zhai, X., Beth, J., Chan, R.H.M. and Tin, C. (2017) Self-Recalibrating Surface EMG Pattern Recognition for Neuroprosthesis Control Based on Convolutional Neural Network. *Frontiers in Neuroscience*, **11**, Article 379. <https://doi.org/10.3389/fnins.2017.00379>
- [5] Wei, W., Wong, Y., Du, Y., et al. (2017) A Multi-Stream Convolutional Neural Network for sEMG-Based Gesture Recognition in Muscle-Computer Interface. *Pattern Recognition Letters*, **119**, 131-138. <https://doi.org/10.1016/j.patrec.2017.12.005>
- [6] Chen, H., Zhang, Y., Li, G., Fang, Y. and Liu, H. (2020) Surface Electromyography Feature Extraction via Convolutional Neural Network. *International Journal of Machine Learning and Cybernetics*, **11**, 185-196. <https://doi.org/10.1007/s13042-019-00966-x>
- [7] Hüsken, M. and Stage, P. (2003) Recurrent Neural Networks for Time Series Classification. *Neurocomputing*, **50**, 223-235. [https://doi.org/10.1016/S0925-2312\(01\)00706-8](https://doi.org/10.1016/S0925-2312(01)00706-8)
- [8] Barron, O., Raison, M., Gaudet, G. and Achiche, S. (2020) Recurrent Neural Network for Electromyographic Gesture Recognition in Transhumeral Amputees. *Applied Soft Computing*, **96**, Article ID: 106616. <https://doi.org/10.1016/j.asoc.2020.106616>
- [9] Teban, T.-A., Precup, R.-E., Voisan, E.-I., de Oliveira, T.E.A. and Petriu, E.M. (2016) Recurrent Dynamic Neural Network Model for Myoelectric-Based Control of a Prosthetic Hand. 2016 *Annual IEEE Systems Conference (SysCon)*, Orlando, 18-21 April 2016, 1-6. <https://doi.org/10.1109/SYSCON.2016.7490531>
- [10] Koch, P., Phan, H., Maass, M., Katzberg, F. and Mertins, A. (2018) Recurrent Neural Network Based Early Prediction of Future Hand Movements. 2018 *40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Honolulu, 18-21 July 2018, 4710-4713. <https://doi.org/10.1109/EMBC.2018.8513145>
- [11] Hochreiter, S. and Schmidhuber, J. (1997) Long Short-Term Memory. *Neural Computation*, **9**, 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- [12] Quivira, F., Koike-Akino, T., Wang, Y. and Erdogmus, D. (2018) Translating sEMG Signals to Continuous Hand Poses using Recurrent Neural Networks. 2018 *IEEE EMBS International Conference on Biomedical & Health Informatics*

-
- matics (BHI)*, Las Vegas, 4-7 March 2018, 166-169. <https://doi.org/10.1109/BHI.2018.8333395>
- [13] Hu, Y., Wong, Y., Wei, W., *et al.* (2018) A Novel Attention-Based Hybrid CNN-RNN Architecture for sEMG-Based Gesture Recognition. *PLOS ONE*, **13**, e0206049. <https://doi.org/10.1371/journal.pone.0206049>
 - [14] Xia, P., Hu, J. and Peng, Y. (2018) EMG-Based Estimation of Limb Movement Using Deep Learning with Recurrent Convolutional Neural Networks. *Artificial Organs*, **42**, E67-E77. <https://doi.org/10.1111/aor.13004>
 - [15] Jiang, Y.J., Song, L., Zhang, J.M., *et al.* (2022) Multi-Category Gesture Recognition Modeling Based on sEMG and IMU Signals. *Sensors*, **22**, Article No. 5855. <https://doi.org/10.3390/s22155855>
 - [16] Chen, Y., Dai, C. and Chen, W. (2020) Cross-Comparison of EMG-to-Force Methods for Multi-DoF Finger Force Prediction Using One-DoF Training. *IEEE Access*, **8**, 13958-13968. <https://doi.org/10.1109/ACCESS.2020.2966007>
 - [17] Hakkani-Tür, D., Tur, G., *et al.* (2016) Multi-Domain Joint Semantic Frame Parsing Using Bi-directional RNN-LSTM. *The 17th Annual Meeting of the International Speech Communication Association (INTERSPEECH 2016)*, San Francisco, 8-12 September 2016, 715-719. <https://doi.org/10.21437/Interspeech.2016-402>
 - [18] Greff, K., Srivastava, R.K., Koutník, J., Steunebrink, B.R. and Schmidhuber, J. (2016) LSTM: A Search Space Odyssey. *IEEE Transactions on Neural Networks & Learning Systems*, **28**, 2222-2232. <https://doi.org/10.1109/TNNLS.2016.2582924>
 - [19] Smith, L.H., Hargrove, L.J., Lock, B.A. and Kuiken, T.A. (2011) Determining the Optimal Window Length for Pattern Recognition-Based Myoelectric Control: Balancing the Competing Effects of Classification Error and Controller Delay. *IEEE Transactions on Neural Systems & Rehabilitation Engineering*, **19**, 186-192. <https://doi.org/10.1109/TNSRE.2010.2100828>