

DOI:10.3969/j.issn.1003-5060.2023.11.007

长短时记忆脉冲神经网络手语识别模型

冯一飞, 王青山

(合肥工业大学 数学学院, 安徽 合肥 230601)

摘要:手语识别是人机交互领域中的重要问题之一。随着人工智能技术的发展,越来越多的机器学习和深度学习的方法被应用在手语识别任务上。文章设计一种轻量级的长短时记忆脉冲神经网络(long short-term memory-spiking neural network, LSTM-SNN)手语识别模型用于识别常用手语。首先提出自适应脉冲编码,将手语信号转化为脉冲信号;接着将脉冲信号输入到改进的带泄漏整合发放(leaky integrate-and-fire, LIF)神经元模型,以时间驱动的方式进行信息传导,完成网络训练。在收集到的 101 个手语手势数据集上的实验结果表明,该模型准确率达到 95.37%,表明该文提出的模型优于其他深度学习和机器学习模型。

关键词:深度学习;模式识别;长短时记忆网络(LSTM);脉冲神经网络(SNN);手语识别

中图分类号:TP391.4 **文献标志码:**A **文章编号:**1003-5060(2023)11-1479-06

Long short-term memory-spiking neural network model for sign language recognition

FENG Yifei, WANG Qingshan

(School of Mathematics, Hefei University of Technology, Hefei 230601, China)

Abstract: Sign language recognition is an important problem of human-machine interaction. With the development of artificial intelligence, many machine learning and deep learning methods have been applied to sign language recognition tasks. Aiming at the problem of structure complexity of sign language recognition model, a lightweight long short-term memory-spiking neural network(LSTM-SNN) model for sign language recognition was designed. Firstly, adaptive spiking coding was proposed, which converted sign language signals into spiking signals. Then, the spiking signals were input into the improved leaky integrate-and-fire(LIF) model to conduct information transmission in a clock-driven way to complete the training of the network. Experiments on 101 types of sign language dataset were conducted, and the accuracy of the model reached 95.37%, showing that the proposed model is superior to other deep learning and machine learning models.

Key words: deep learning; pattern recognition; long short-term memory(LSTM); spiking neural network(SNN); sign language recognition

0 引言

据世界卫生组织 2017 年的统计,全球大约有 5.5% 的人遭受听力损失的困扰,合计人口达到 4.66 亿,仅在中国就有 2 780 万听障人士。手语是听障人士最重要的交流方式,然而对于没有专

门学习过手语的健全人来说,手语是一种难懂的语言,这使得听障人士和健全人之间形成沟通障碍^[1]。沟通障碍一方面影响了听障人士的工作、学习、娱乐等生活状态;另一方面可能使他们形成自卑心理,不利于形成健全的人格。为了让听障人士更好地融入社会,越来越多的研究者开始关

收稿日期:2022-04-05;修回日期:2022-05-23

基金项目:中国残联残疾人辅助器具专项研究课题资助项目(CJFJRRB19-2020)

作者简介:冯一飞(1997—),男,天津市人,合肥工业大学硕士生;

王青山(1975—),男,安徽合肥人,博士,合肥工业大学教授,博士生导师,通信作者,E-mail:qswang@hfut.edu.cn.

注手语识别问题。

目前,已经存在许多手语识别的形式,从采集信号的种类上看,有基于视觉图像的方法^[2-4]、基于 WIFI 的方法^[5]和基于传感器的方法^[6-7];从采用的识别方法来说,有机器学习方法^[8-9]和深度学习^[10-11]等。基于视觉图像的方法可以采集到手和面部的特征,往往在多目标的手语识别任务中表现更出色,然而由于需要借助摄像机采集图像数据采集,难以在现实生活中普及。基于 WIFI 的方法可以采集到除了手和手臂以外身体其他部分的运动,但是对于比较细粒度的运动,比如手指的运动,会损失采集的精确性。基于传感器的方法通过佩戴手环来采集手势的肌电流和运动的惯性信号,无需通过摄像头采集,采集到的手势信号也更为精确。

目前,脉冲神经网络(spiking neural network, SNN)^[12]已经应用在一些深度学习的任务中,如模式识别^[13-15]、强化学习^[16]。脉冲神经网络中的神经元更接近生物神经元的组成,它利用稀疏的脉冲来表示信息,而不像传统人工神经网络的神经元使用连续的变量表示信息。由于这种仿生的机制,脉冲神经网络有潜力在使用更少神经元的情况下达到和人工神经网络相似的性能^[9],使得脉冲神经网络非常适合实际的场景。另外,脉冲神经网络可以在线学习,对复杂信号处理的鲁棒性高于人工神经网络^[17]。然而利用脉冲神经网络对手势进行识别^[13,18]工作较少,文献^[13]设计了预训练脉冲神经网络,使得脉冲神经网络的隐藏层数更深,对 8 种手势进行识别。文献^[18]提出了深度卷积脉冲神经网络,缩短了处理信号所需的时间,在 2 个 8 分类的手势数据集上验证网络性能。它们识别的手势规模较小,本文研究脉冲编码和训练方法来设计轻量级的脉冲神经网络,对 101 个常用手语手势进行识别。

本文提出了基于表面肌电流(surface electromyography, sEMG)手语识别模型,该模型由轻量级长短时记忆脉冲神经网络(long short-term memory-spiking neural network, LSTM-SNN)组成。在模型中设计自适应脉冲编码对输入的手语信号进行编码,改进带泄漏整合发放(leaky integrate-and-fire, LIF)神经元模型进行网络训练,最后通过实验来比较该模型与其他深度学习和机器学习模型的准确率等方面的性能。

1 模型设计

手语识别系统框架如图 1 所示,首先使用

MYO 手环采集数据得到原始手语 sEMG 信号,然后将 sEMG 信号经过自适应脉冲编码后获得脉冲信号,脉冲信号作为 LSTM-SNN 的输入,通过时间驱动方式训练神经元中的参数,由全连接层对特征向量进行识别分类,最后由 LSTM-SNN 中的 softmax 层输出手语分类的结果。

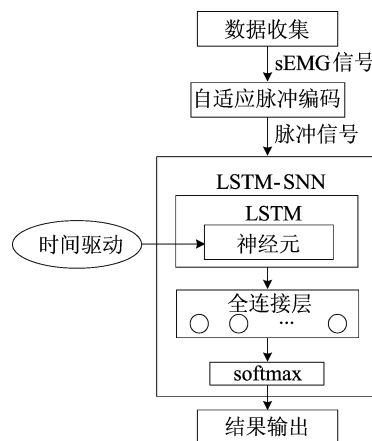


图 1 手语识别系统框架

1.1 脉冲编码

脉冲编码过程主要是将输入信号转化为脉冲信号,从而产生脉冲网络的输入。本文设计了一种自适应脉冲编码来对手语信号编码,其主要思想是通过计算当前时刻编码手语信号前后变化信息进行自适应脉冲编码。

对给定的手语信号 $X = (x_1, x_2, \dots, x_T)$, 其中, $x_t \in \mathbf{R}, 1 \leq t \leq T, T$ 为信号的帧数,经过脉冲编码得到的序列为 $Y = (y_1, y_2, \dots, y_L)$, 其中, $y_l \in \{0, 1\}, 1 \leq l \leq L, L$ 为脉冲序列长度,一般来说 $L = T$ 。因为产生脉冲的原因是在膜电位形成了电位差,即该时刻产生的电压变化较大,所以本文根据信号的变化程度进行脉冲编码。当信号变化程度越大,发射脉冲的时间就越早。标准脉冲的发放时间表示为:

$$t_f(z_t) = (T-1)(1-x_t) \quad (1)$$

其中: T 为脉冲最大的发放时长; x_t 为当前时刻的输入,且 $x_t \in [0, 1)$ 。本文设计的自适应脉冲编码思想,如图 2 所示。

1) 计算手语信号在当前时刻($2 \leq t \leq T$)与上一时刻 $t-1$ 的差值 $d_t = |x_t - x_{t-1}|$ 。假设上述差值中最大值为 d_{\max} ($2 \leq \max \leq T$),通过 d_t/d_{\max} 将 d_t 映射到 $[0, 1]$ 之间。

2) 计算当前时刻 t 后 k 帧手语信号的均方根,来表示当前时刻信号 x_t 的未来变化情况(本

文中 $k=5$)。计算整段信号 X 的均方根 $R_t = \sqrt{(x_{t+1}^2 + \dots + x_{t+k}^2)/k}$, 然后对每个 $x_t (1 \leq t \leq T-k)$ 都计算其后 k 帧的均方根 R_t 。




图 2 自适应脉冲编码

3) 通过比较 R_t 与 R_T 的大小来计算脉冲发放的时间。根据式(1)和 $R_t = \sqrt{(x_{t+1}^2 + \dots + x_{t+k}^2)/k}$, 本文定义脉冲发放时间为:

$$t_t(d_t, R_t) = \begin{cases} (T-1)\left(1 - \frac{d_t}{d_{\max}}\right), & R_t \leq R_T; \\ (T-1)\left(1 - \frac{d_t}{d_{\max}} - \frac{R_t - R_T}{R_T}\right), & R_t > R_T \end{cases} \quad (2)$$

由式(2)可知, 如果 $R_t \leq R_T$, 说明当前时刻 t 后 k 帧的信号变化较小, 那么可以推迟脉冲发放的时间; 反之, 则尽早发放脉冲。

1.2 LIF 神经元与时间驱动训练方式

本文使用带泄漏整合发放神经元模型来实现脉冲神经网络中信息的传递。该模型主要模拟生物体内神经元突触之间的信息传递方式, 通过不断地充电和放电来产生脉冲信号, 这种方式被称为时间驱动方式。

神经元的信息传输过程主要分为充电、放电和复位。充电和放电的具体过程分别用以下公式表达, 具体计算公式如下:

$$H_t = V_{t-1} + \Delta v_t \quad (3)$$

$$\theta_t = \begin{cases} 1, & H_t \geq V_{\text{threshold}}; \\ 0, & H_t < V_{\text{threshold}} \end{cases} \quad (4)$$

在充电的表达式(3)中; H_t 为 t 时刻神经元未发放脉冲的瞬时电压; V_{t-1} 为上一个时刻 $t-1$ 的电压; Δv_t 为 t 时刻的电压增量。在放电的表达式(4)中; θ_t 表示是否产生了脉冲; 如果 H_t 超过阈值 $V_{\text{threshold}}$, 那么就会产生一个脉冲, 随后膜电位会立即回到一个静息电位, 此过程叫做复位; 反之, 不产生脉冲。

本文采用当前膜电位减去阈值 $V_{\text{threshold}}$ 的方

式来复位, 这样膜电位在充电的过程中不需要从 0 开始增长, 提高了脉冲放电的效率。具体的复位方式如下:

$$V_t = H_t - V_{\text{threshold}}\theta_t \quad (5)$$

其中, V_t 为 t 时刻的电压。

第 i 层脉冲神经元的输入输出和内部的充电放电过程如图 3 所示, 其中输入 $b_{j,i} (1 \leq j \leq n)$ 和输出 θ_i^j 都是脉冲表示, 即二值表示。对所有的输入信号 $b_{j,i}$ 乘以网络中相应的权重 $w_{j,i}$ 求和得到该层网络的增量 v_i^j , 然后通过式(3)和式(4)计算输出 θ_i^j 。




图 3 脉冲网络的神经元

1.3 LSTM-SNN 手语识别模型

长短时记忆网络是一类特殊的循环神经网络 (recurrent neural networks, RNN), 能够为信号的时间依赖性建模, 同时解决了循环神经网络结构面临的梯度消失问题^[19]。因为肌电流信号是时间序列信号, 所以本文选择了长短时记忆网络来捕捉脉冲神经网络中信号的时间依赖性。长短时记忆脉冲神经元工作原理如图 4 所示。

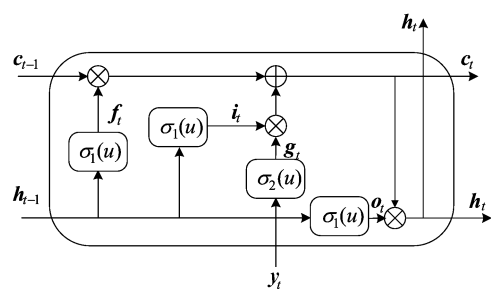


图 4 长短时记忆脉冲神经元工作原理

长短时记忆脉冲神经元与长短时记忆神经网络一样, 都使用了细胞状态 c_t 来管理神经元之间信息的传递。 f_t 是遗忘门, 决定了哪些信息会保存; i_t 是输入门, 控制了输入单元的信息和另一个辅助的输入 g_t , g_t 由另一个脉冲激活函数来调节; o_t 是输出门, 形成下个神经元的输入。具体来讲, 对于一组给定的脉冲序列 (y_1, y_2, \dots, y_L) , 长短时记忆脉冲神经网络 LSTM 的门和状态可

以用如下方程描述:

$$\begin{cases} f_t = \sigma_1(\omega_{f,h}h_{t-1} + \omega_{f,y}y_t + b_{f,h} + b_{f,y}), \\ i_t = \sigma_1(\omega_{i,h}h_{t-1} + \omega_{i,y}y_t + b_{i,h} + b_{i,y}), \\ g_t = \sigma_2(\omega_{g,h}h_{t-1} + \omega_{g,y}y_t + b_{g,h} + b_{g,y}), \\ c_t = f_t \odot c_{t-1} + i_t \odot g_t, \\ o_t = \sigma_1(\omega_{o,h}h_{t-1} + \omega_{o,y}y_t + b_{o,h} + b_{o,y}), \\ h_t = o_t \odot c_t \end{cases} \quad (6)$$

其中: \odot 代表 Hadmard 乘积; σ_1, σ_2 为反应膜电位的脉冲激活函数,当函数值超过阈值时会产生脉冲。

2 实验与结果

本文对所提的 LSTM-SNN 手语识别模型进行性能评价分析,具体包括实验环境设置、LSTM-SNN 性能、不同编码方式对 LSTM-SNN 性能影响、LSTM-SNN 与其他模型性能对比。

2.1 数据集

本文使用 MYO 手环采集肌电流数据,其包含 8 个表面肌电流传感器,采样频率为 200 Hz。将手环佩戴于前臂,可以采集到手部运动的信息,并通过蓝牙设备传输到电脑,完成数据的收集。肌电流信号采集设备如图 5 所示。



图 5 肌电流信号采集设备

本数据集包含 101 个日常生活中常见的手语手势。该数据集由 16 位志愿者采集,包括 8 男 8 女,其中有 4 位手语老师和 6 位听障学生,其余的志愿者也都经过了专业的手语训练,可以熟练地使用手语。在本数据集中每个手语手势有 10 个样本,一共 1 010 个样本,每种手势中都包含了至少 3 位志愿者的手语样本。

本文通过电脑端完成网络的训练,CPU 是 i7-9700F、32 GiB RAM, GPU 采用 NVIDIA RTX 2080Ti;深度学习框架和训练过程通过 Pytorch 完成。另外,本文应用深度学习框架惊蛰^[20]搭建脉冲神经网络。式(2)中的 T 设置为 20。因为本文构建一个轻量级的网络,所以网络模型只设置了 1 层 LSTM-SNN 加 1 层全连接层,LSTM 的隐藏层数量设置为 128,训练模型的 epoch 设置为 800, batchsize 为 32,采用 Adam 作为优化器,优化器的学习率设置为 0.001。

本文使用的评估指标包括准确率 A (accuracy)、精确率 P (precision)、召回率 R (recall) 和 F_1 分数。准确率可以表现出模型对所有样本的分类能力;精确率可以反映出模型对正样本分类的能力;召回率反映模型对正样本的误判情况; F_1 为综合考虑精确度和召回率的结果。这些指标经常被应用于分类任务中,作为评价模型性能的重要标准。

评估指标的计算公式如下:

$$A = \frac{N_{tp} + N_{tn}}{N_{tp} + N_{tn} + N_{fp} + N_{fn}} \quad (7)$$

$$P = \frac{N_{tp}}{N_{tp} + N_{fp}} \quad (8)$$

$$R = \frac{N_{tp}}{N_{tp} + N_{fn}} \quad (9)$$

$$F_1 = \frac{2PR}{P+R} \quad (10)$$

其中, $N_{tp}, N_{fp}, N_{tn}, N_{fn}$ 分别表示真阳性、假阳性、真阴性和假阴性样本的个数。

2.2 LSTM-SNN 性能分析

本实验对 101 个手语手势进行识别评价 LSTM-SNN 的性能,将数据集中的 70% 作为训练集,30% 作为验证集,得到验证集的准确率为 95.37%、精确度为 94.88%、召回率为 94.53%、 F_1 为 94.70。这说明该模型可以正确分类大部分的样本。进一步,本文对分类效果较差的 16 个手势进行实验分析其准确率,将模型输出的维度调整为 16,以 16 个手势对应的 160 个样本作为验证集进行验证,得到的混淆矩阵如图 6 所示。

由图 6 可知,准确率为 86.88%,说明模型在单独分类这些样本时效果并不差。从混淆矩阵的坐标轴中可以看出,这些手语在含义上并不相近,产生这种现象的原因可能是在这些手语手势信号中有相似的肌电流信号,导致模型在分类时容易产生混淆。

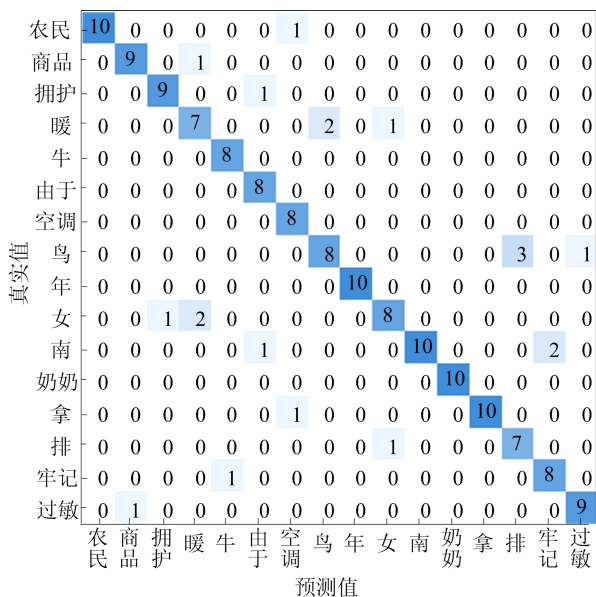


图 6 16 个手语词的混淆矩阵

2.3 编码方式对 LSTM-SNN 性能的影响

本文将所提自适应脉冲编码、常见的周期编码和泊松编码进行了性能比较,实验结果见表 1 所列。从表 1 可以看出,采用自适应编码在性能表现上都优于其他常见的编码方式。

表 1 不同编码方式的性能比较

编码方式	A/%	P/%	R/%	F ₁
周期编码	80.20	77.23	72.43	74.75
泊松编码	91.42	89.55	90.03	89.79
本文编码	95.37	94.88	94.53	94.70

2.4 LSTM-SNN 与其他模型性能对比

本文将所提模型 LSTM-SNN 同手语识别中现有的机器学习和深度学习模型进行性能比较,包括单层卷积神经网络(convolutional neural networks,CNN)、单层长短时记忆网络、单层全连接网络(fully connected,FC)、多并行卷积神经网络模型^[21]、改进支持向量机(support vector machine,SVM)模型^[22]和人工神经网络模型^[23]。另外,实验还搭建并训练了卷积脉冲神经网络(CNN-SNN)和全连接脉冲网络(FC-SNN),这些模型的搭建与长短时脉冲网络的搭建类似,将其中的激活函数替换为 LIF 神经元,再使用自适应编码和时间驱动方式进行训练。这些模型的实验结果见表 2 所列。

从表 2 可以看出,所提模型 LSTM-SNN 在所有指标上性能最好。另外,传统神经网络 LSTM、CNN 和 FC 在采用脉冲神经元之后性能

都有一定程度提升。

表 2 不同模型的性能比较

模型	A/%	P/%	R/%	F ₁
CNN-SNN	89.11	88.68	87.24	87.95
FC-SNN	63.11	54.51	56.30	55.39
LSTM	89.44	88.04	86.34	87.18
CNN	87.46	87.69	89.09	88.38
FC	62.95	60.96	53.38	56.92
文献[21]	88.41	83.44	86.94	85.15
文献[22]	86.23	84.19	89.86	86.93
文献[23]	90.19	85.16	85.79	85.47
LSTM-SNN	95.37	94.88	94.53	94.70

3 结 论

本文提出一种轻量级长短时记忆脉冲神经网络模型,该模型对输入信号设计了自适应脉冲编码方法,改进了 LIF 模型进行网络训练,实现对 101 个手语手势的识别。实验结果表明,该模型在手语识别任务上较现有模型取得更高的准确率。本研究还有不足之处,例如,没有探讨手语识别实时性的问题,当手语数据集扩展后脉冲神经网络系统的鲁棒性问题,这些将在未来的工作中进行研究。

[参 考 文 献]

- [1] CAMGOZ N C, KOLLER O, HADFIELD S, et al. Sign language transformers: joint end-to-end sign language recognition and translation [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). [S. l.]: IEEE, 2020: 10023-10033.
- [2] WANG S, GUO D, ZHOU W G, et al. Connectionist temporal fusion for sign language translation [C]//26th ACM Multimedia Conference. [S. l.]: ACM, 2018: 1483-1491.
- [3] HUANG J, ZHOU W, ZHANG Q, et al. Video-based sign language recognition without temporal segmentation [C]// AAAI Conference on Artificial Intelligence. [S. l.]: AAAI, 2018: 2257-2264.
- [4] ZHENG L, LIANG B. Sign language recognition using depth images [C]//International Conference on Control, Automation, Robotics and Vision. [S. l.]: s. n., 2016: 1-6.
- [5] REGANI S D, WANG B, LIU K. Wifi-based device-free gesture recognition through-the-wall [C]//IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). [S. l.]: IEEE, 2021: 8017-8021.

(下转第 1541 页)

- phritic activity of a polysaccharide from okra (*Abelmoschus esculentus* (L.) Moench) via modulation of AMPK-Sirt1-PGC-1 α signaling axis mediated anti-oxidative in type 2 diabetes model mice [J]. *International Journal of Biological Macromolecules*, 2019, 140:568-576.
- [18] PAN Y N, YUAN S L, TENG Y L, et al. Antioxidation of a proteoglycan from *Ganoderma lucidum* protects pancreatic beta-cells against oxidative stress-induced apoptosis *in vitro* and *in vivo* [J]. *International Journal of Biological Macromolecules*, 2022, 200:470-486.
- [19] 梁结斐,陈震尧,吴伟斌. 番石榴叶水提物对四氧嘧啶诱导体外胰岛 INS-1 细胞凋亡的保护作用及其机制[J]. *中国当代医药*, 2022, 29(31):5-10, 15.
- [20] YANG X D, BAI Z F, ZHANG Y, et al. Flavonoids-rich extract from *Bidens bipinnata* L. protects pancreatic β -cells against oxidative stress-induced apoptosis through intrinsic and extrinsic pathways[J]. *Journal of Ethnopharmacology*, 2021, 275:114097.
- [21] 东韦正. 植物多糖降血糖作用及其机理研究进展[J]. *医学食疗与健康*, 2022, 20(12):145-148.

(责任编辑 闫杏丽)

(上接第 1483 页)

- [6] FENG D, REN X, YANG Y. A gesture recognition system based on time domain features and linear discriminant analysis[J]. *IEEE Transactions on Cognitive and Developmental Systems*, 2021, 13(1):200-208.
- [7] HOU J, LI X Y, ZHU P, et al. Signspeaker: a real-time, high-precision smart watch-based sign language translator [C]//The 25th Annual International Conference. [S. l. : s. n.], 2019:1-15.
- [8] OLIVEIRA M, SUTHERLAND A, FAROUK M. Two-stage PCA with interpolated data for hand shape recognition in sign language[C]//IEEE Applied Imagery Pattern Recognition Workshop. [S. l.]; IEEE, 2016:1-4.
- [9] LEE J H, DELBRUCK T, PFEIFFER M. Training deep spiking neural networks using backpropagation[J]. *Frontiers in Neuroscience*, 2016, 10:508.
- [10] GUO D, ZHOU W, LI H, et al. Hierarchical LSTM for sign language translation[C]//AAAI Conference on Artificial Intelligence. [S. l.]; AAAI, 2018:6845-6852.
- [11] WU D, PIGOU L, KINDERMANS P J, et al. Deep dynamic neural networks for multimodal gesture segmentation and recognition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 38(8):1583-1597.
- [12] YAN Z, ZHOU J, WONG W F. Energy efficient ECG classification with spiking neural network[J]. *Biomedical Signal Processing and Control*, 2021, 63:102170.
- [13] CHENG L, LIU Y, HOU Z G, et al. A rapid spiking neural network approach with an application on hand gesture recognition[J]. *IEEE Transactions on Cognitive and Developmental Systems*, 2019, 13(1):151-161.
- [14] CAO Y, CHEN Y, KHOSLA D. Spiking deep convolutional neural networks for energy-efficient object recognition [J]. *International Journal of Computer Vision*, 2015, 113(1):54-66.
- [15] TAHERKHANI A, COSMA G, MCGINNITY T M. Optimization of output spike train encoding for a spiking neuron based on its spatiotemporal input pattern[J]. *IEEE Transactions on Cognitive and Developmental Systems*, 2020, 12(3):427-438.
- [16] TANG G, KUMAR N, YOO R, et al. Deep reinforcement learning with population-coded spiking neural network for continuous control [C]//Conference on Robot Learning (CoRL). [S. l. : s. n.], 2020:2016-2029.
- [17] MAASS W. Noisy spiking neurons with temporal coding have more computational power than sigmoidal neurons [M]//Advances in Neural Information Processing Systems. [S. l. : s. n.], 1997:211-217.
- [18] KE W, XING Y, CATERINA G D, et al. Deep convolutional spiking neural network based hand gesture recognition[C]//2020 International Joint Conference on Neural Networks (IJCNN). [S. l. : s. n.], 2020:1-7.
- [19] REZAABAD A L, VISHWANATH S. Long short-term memory spiking networks and their applications[C]//Proceedings of the International Conference on Neuromorphic Systems. [S. l. : s. n.], 2020:1-9.
- [20] FANG W, CHEN Y Q, DING J H, et al. Spikingjelly[EB/OL]. [2022-04-18]. <https://github.com/fangwei123456/spikingjelly>.
- [21] SU Z, LIU H, QIAN J, et al. Hand gesture recognition based on sEMG signal and convolutional neural network [J]. *International Journal of Pattern Recognition and Artificial Intelligence*, 2021, 35(11):2151012.
- [22] CONG L N, ZHOU S, HU S, et al. Hand gesture recognition based on sEMG signal and improved svm voting method[C]//2020 IEEE 3rd International Conference on Information Systems and Computer Aided Education (ICISCAE). [S. l.]; IEEE, 2020:605-608.
- [23] SAYIN F S, OZEN S, BASPINAR U. Hand gesture recognition by using sEMG signals for human machine interaction applications [C]//2018 Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA). [S. l. : s. n.], 2018:27-30.

(责任编辑 李 凯)