

基于改进的能量生成对抗网络表面肌电数据增强方法

王寒黎, 马铭宇

(重庆交通大学 机电与车辆工程学院, 重庆 400074)

摘要: 肌电控制是智能假肢研究的重点, 其识别算法需要大量的肌电数据支持, 而表面肌电信号存在采集困难、数据多样性匮乏及质量不稳定的问题; 因此, 提出一种基于改进的能量生成对抗网络 (EBGAN) 的肌电数据增强方法; 将卷积神经与 EBGAN 模型相结合, 完成模型改进优化从而模拟原始数据生成过程, 并采用动态时间翘曲和信号快速傅里叶变换幅度的均方误差作为评价指标, 从时、频两域评估生成数据的真实性; 使用支持向量机等模型对合成以及原始数据进行分类识别, 验证其有效性; 实验证明, 改进的 EBGAN 模型生成的肌电信号与原始信号具有高度相似性, 合成数据集显著提升了分类准确率, 提升幅度在 1%~9% 之间; 证实了数据增强方法的有效性, 为肌电信号的智能化分析和应用提供了新的途径。

关键词: 表面肌电信号; 数据增强; 生成对抗网络; 分类准确率

Surface EMG Data Enhancement Method Based on Improved Energy Generation Adversarial Networks

WANG Hanli, MA Mingyu

(School of Mechanical, Electrical and Vehicle Engineering, Chongqing Jiaotong University,
Chongqing 400074, China)

Abstract: Electromyography (EMG) control is a research focus in intelligent prosthetics, where its recognition algorithm relies on on extensive EMG data. However, Surface EMG signals have the characteristics of difficulties in acquisition, lack of data diversity, and instability in quality. Hence, an EMG data augmentation method based on an improved energy-based generative adversarial network (EBGAN) is proposed. This method combines convolutional neural networks with the EBGAN model to enhance the model's optimization and simulate the generation process of original data. Dynamic time warping and mean squared error (MSE) of the fast Fourier transform (FFT) amplitude are employed as metrics to evaluate the authenticity of the generated data across time and frequency domains. Support vector machines (SVMs) and other models are used to classify and validate the effectiveness of the synthesized and original data. Experimental results demonstrate that the EMG signals generated by the improved EBGAN model are highly similar to the original signals, and the synthesized data set significantly improve the classification accuracy, with an increase range of 1% to 9%. This confirms the effectiveness of the data augmentation method and provides a new approach for the intelligent analysis and application of EMG signals.

Keywords: surface EMG signals; data enhancement; generative adversarial network; classification accuracy

0 引言

根据《2020 中国残疾人事业统计年鉴》, 截至 2019 年底, 全国残疾人口基础数据库的入库持证残

疾人总数为 3 681.7 万, 其中包括上肢缺失在内的肢体残疾人总数为 2 021.1 万, 超过总人数的一半^[1]。截肢患者在日常生活中有诸多不便, 而使用合适的假肢可以让截肢患者回归正常生活。在假手的相关研究

收稿日期:2024-04-14; 修回日期:2024-05-24。

基金项目:重庆市教委科学技术研究项(KJZD-K201900702)。

作者简介:王寒黎(1999-),女,硕士研究生。

引用格式:王寒黎, 马铭宇. 基于改进的能量生成对抗网络表面肌电数据增强方法[J]. 计算机测量与控制, 2025, 33(6): 161-167.

中, 肌电控制是其研究重点, 表面肌电信号 (sEMG, surface EMG signal) 是肌肉收缩过程中产生的一种生理电信号, 是一种对表层肌肉和神经的电活动的综合作用。可以直接反映肌电的动态变化, 并能间接反映大脑的动作意愿, 而且具有非侵入性, 生物兼容性好、稳定性好等优点^[2]。因此不少学者利用神经网络模型识别 sEMG, 判断手势动作, 以驱动上肢假肢。文献 [3] 使用人工神经网络模型 (ANN, artificial neural network) 进行手势识别, 实现了手势识别的实时响应, 并得到了 90.7% 的识别准确率。文献 [4] 提出了基于注意机制的双向卷积门控递归单元深度神经网络方法, 并对 NinaPro 第五子库的 17 种手势进行识别, 其准确率为 88.73%。文献 [5] 又提出了一种双流卷积神经网络, 通过 sEMG 图像与 DWTC 图像分别卷积得到对应的高级特征, 之后将这些特征融合共同输入 Softmax 分类器里, 在 NinaPro 数据库上的准确率为 84.9%。然而为了保证肌电识别的准确率, 肌电模式识别算法正在往多层数、多特征融合发展^[6], 故需要庞大的肌电数据量支持。

但是采集肌电数据的实验繁琐, 需要指定参与者多场景长时间训练, 还需要不断调整肌电采集设备位置, 而截肢患者只能凭借大脑发出指令, 尽可能地活动残缺肌肉。这极易产生肌肉疲劳, 使得采集的可用数据较少^[7]。此外, 想要提取肌电信号数据的过程相当繁琐, 需要严格的伦理审批程序, 且因为涉及患者隐私, 肌电数据难以共享^[8], 导致肌电数据集匮乏, 限制了基于模式识别的假肢的临床可行性^[9], 阻碍了 sEMG 信号研究的发展。为了更加深入地研究基于肌电信号的智能假肢, 必须增加肌电数据的数量。

目前已有不同类型的数据增强方法, 例如基于机器学习的增强算法, 以及对数据本身的旋转、平移、翻转等增强方式^[10]。但是这些研究多集中在图像生成上, 并不都适用于表面肌电信号的扩充。为此, 有学者利用 2014 年文献 [11] 提出的生成对抗网络 (GAN, generative adversarial network) 进行肌电数据增强, 它为该问题的研究提供了一个新的、行之有效的框架。文献 [12] 将肌电信号转换成灰度图, 并利用深度卷积生成对抗网络 (DCGAN, deep convolutional generative adversarial network) 直接生成肌电灰度图像, 但由于没有对数据集进行特征提取和分类器参数调整, 整体的分类精度不高。文献 [13] 提出了两种基于深度卷积生成对抗网络和风格迁移的数据增强方法, 用于增强帕金森患者的肌电信号, 提出的模型可以适应不同频率和振幅的震颤, 模拟每个患者的震颤模式, 并将其扩展到不同的运动方案数据集。文献

[14] 提出用能量生成对抗网络 (EBGAN, energy-based generative adversarial network) 直接生成下肢肌电信号的时域特征, 使用可量化指标和典型分类方法评估合成数据质量。

上述表明了利用生成对抗网络进行数据增强的有效性, 然而, 目前多数研究集中于肌电信号的时频域特征生成。考虑到肌电信号随时间变化而变化, 具有强烈的非线性特性, 单一的特征并不能完全涵盖肌肉微小变化^[15]。因此, 直接生成原始肌电信号以扩充肌电数据库, 最大化反映肌肉的动态变化十分重要。由于肌电信号固有的信噪比低、非平稳等复杂特性以及个体之间肌电信号的显著差异性, 生成原始肌电信号难度较大, 故国内外以原始肌电信号为对象的数据生成与增强的相关研究较少。

针对上述问题, 本文直面肌电信号在模式识别、人机交互和肌电控制方面的重要性, 着眼于原始肌电信号的增强, 提出了一种改进的能量生成对抗网络 (EBGAN) 模型。在 EBGAN 模型的生成器以及判别器中, 分别替换和添加一维卷积层, 利用卷积神经网络 (CNN) 提取时序信号特征的优势以及 EBGAN 本身的稳定框架结构, 直接生成原始肌电信号, 解决肌电可用数据少的问题, 实现肌电数据库的有效扩充, 为截肢人群提供更丰富和真实的数据资源。

1 数据集与预处理

1.1 公共数据集 NinaPro

本实验数据集采用公共数据集 NinaPro, 该数据库提供了广泛的肌电图 (EMG) 信号数据, 这些数据是为了研究和开发能够适应用户肌肉活动的先进假肢技术而收集的。NinaPro 数据库收集自多名志愿者, 包括有肢体缺失和健全的参与者。志愿者被要求执行一系列标准手部和手指运动, 如握拳、伸指、旋转手腕等, 期间使用表面肌电图 (sEMG) 技术记录了肌肉活动。这些数据对于研究如何解析和识别复杂的肌电信号模式至关重要, 有助于开发能够准确解释用户运动意图的假肢控制系统。它包括不同性别、年龄、肢体大小和健康状况的参与者提供的数据。为检验模型的泛化性, 本实验使用 NinaPro 的第二个数据库 (DB2) 与第三个数据库 (DB3), 前一个数据包含 40 个完整受试者的数据 (28 名男性, 12 名女性; 右手 34 人, 左手 6 人; 年龄 29.9 ± 3.9 岁)。后一个数据库包含来自 11 名经桡骨截肢受试者的数据 (11 名男性; 10 人惯用右手, 1 人惯用左手; 年龄 42.36 ± 11.96 岁)。其数据主要包括以下 3 个练习^[16], 包括手指和手腕的基本动作、抓握和功能运动、能力模式。其信号采集实验如图 1 所示。




图 1 采集肌肉分布和实验场景示意图

1.2 数据预处理

由于 sEMG 的有效信号范围在 0~500 Hz 之间，主要能量集中在 20~400 Hz，对所采集的数据首先利用 60 Hz 陷波器滤除工频干扰，再利用 4 阶巴特沃斯带通滤波器在 20~350 Hz 之间进行带通滤波^[17]，同时利用 10 点移动平均滤波器去除信号中的随机噪声和不必要的短时波动，并且不会对信号的整体趋势产生太大影响，能有效平滑信号波形。最后，对滤波后的信号进行归一化处理 and 去均值化，重新缩放肌电信号，使不同信号的幅度范围控制在 -1~1 之间，便于后续的处理与分析，并从每个信号中减去其均值，去除信号的直流成分，从而突出变化趋势和波动模式。减少信号的偏置，使得分析更加集中于信号的动态变化。滤波后的表面肌电信号如图 2、3 所示，高频噪声以及电源干扰得以去除，从上至下依次显示了正常人与截肢患者的滤波前、后的表面肌电信号。




图 2 去噪前后正常人表面肌电信号

2 改进的能量生成对抗网络基本结构

2.1 能量生成对抗网络原理

GAN 网络由生成器 (Generator) 与判别器 (Discriminator) 组成，它们以对抗的方式训练。生成器 G 接收一个随机噪声作为输入，通过这个噪声创造出足以




图 3 去噪前后患者表面肌电信号

欺骗判别器的假数据，而判别器 D 则努力区分真实数据和生成器的产物，如图 4 所示。在 GAN 的训练框架中，生成器 G 的训练目标是最大化判别器 D 分类错误的几率，这构成了一种极大极小的二人博弈问题。在这个博弈中，理论上存在一个均衡点，在该点上，生成器 G 能够完美地复现训练数据的分布，而判别器 D 则无法区分真实数据与生成数据，其输出概率在所有点上均为 0.5，既达到纳什平衡。其训练机制如下：

$$\min_G \max_D V(D, G) = E_{x \sim p_{\text{data}}(x)} \{ \log[D(x)] \} + E_{z \sim p(z)} \{ \log\{1 - D[G(z)]\} \} \quad (1)$$

式中， $D(x)$ 为判别器输出作为真实样本的可能性， $D[G(z)]$ 为判别器输出为生成样本的可能性。而生成器利用学习真实分布 p_{data} 来欺骗判别器 D，从而使 $G(z)$ 被识别为真实样本的可能性增加。故生成器损失函数与判别函数分别如下：

$$\min_G V(D, G) = E_{z \sim p(z)} \{ \log\{1 - D[G(z)]\} \} \quad (2)$$
$$\max_D V(D, G) = E_{x \sim p_{\text{data}}(x)} \{ \log[D(x)] \} + E_{z \sim p(z)} \{ \log\{1 - D[G(z)]\} \} \quad (3)$$

由于原始 GAN 引入了一个复杂的 min-max 优化问题，其在训练过程中会出现梯度消失和模式崩溃问题等问题。EBGAN 模型将判别器视作能量函数而非传统的分类器^[18]。在 EBGAN 框架下，当生成的数据更接近




图 4 能量生成对抗网络架构图

真实数据分布时, 会被赋予较低的能量; 反之, 则赋予较高的能量, 指示出数据质量的低下。这种基于能量的视角降低了模型架构和损失函数的限制性, 为 GAN 的设计和训练带来了更大的灵活性和鲁棒性。EBGAN 生成器与判别器的损失函数如下:

$$L_G(z) = D[G(z)] \quad (4)$$

$$L_D(x, z) = D(x) + \{m - D[G(z)]\}^+ \quad (5)$$

式中, m 是大于 0 的超参数, $[\cdot]^+ = \max(0, \cdot)$, L_G 是生成器的损失函数, L_D 是判别器的损失函数。

2.2 改进的 EBGAN 模型构建与优化

卷积神经网络在处理识别图像以及时序数据中的局部模式方面表现出卓越的能力^[19], 可以直接应用于识别肌电信号的特征, 学习到肌电信号中不同运动状态的独特模式。本文利用 CNN 处理肌电信号方面的优势, 将 EBGAN 模型的生成器中部分全连接层替换为一维卷积层, 并在判别器中添加一维卷积层, 来提升模型性能。改进后的 EBGAN 模型不仅能利用其特有的能量函数为肌电信号的生成提供一个更为稳健的框架, 使得生成的数据更接近真实的数据分布, 还能利用 CNN 强大的特征提取能力, 捕捉到肌肉活动的细微变化, 进一步增强模型生成肌电信号的准确性和多样性, 从而生成高质量的信号。

改进后的生成网络 G 和判别网络 D 的具体架构如图 5 所示。在这种结合框架中, G 的输入是随机噪声, 通过多个卷积层和批量归一化层的堆叠来捕获并学习真实肌电信号的分布, 最终生成类似于真实肌电信号的数据。卷积层的引入增强了模型对时空特征的学习能力, 而批量归一化则有效防止了训练过程中可能出现的梯度消失或爆炸现象^[20]。判别器 D 先利用原始肌电信号进行预训练, 卷积层加入使其具有更强的肌电特征识别能力, 可以区分原始数据与重构数据, 从而使重构数据和原始数据的偏差减小。在预训练完成后, 判别器对原输入数据及其对应的重构数据进行运算, 利用 L2 范数计算原始数据与重构数据之间的误差, 并将其作为判断的




图 5 改进后 EBGAN 的架构图

依据, 定义为能量。初始训练阶段, 真实数据的重构误差较小, 意味着较低的能量; 生成数据的重构误差较大, 表现为较高的能量, 这显示出生成数据在质量上与真实数据的差距。训练的目标是不断减少生成数据的重构误差, 即降低其能量, 从而使生成数据的分布逐渐接近真实数据的分布。能量差值越小, 则越接近实际的数据分布, 从而完成模型的迭代优化。

改进的 EBGAN 网络模型的训练过程包括以下步骤: 1) 使用预训练方法初始化生成器和判别器的参数。接着, 从真实数据集中提取一批样本, 并从噪声分布中抽取噪声向量, 将其输入生成器生成数据点; 2) 计算真实数据和生成数据的能量值, 调整判别器参数, 使真实数据的能量值降低, 生成数据的能量值升高; 3) 再次从噪声分布中抽取新的噪声向量, 输入生成器生成新的数据点, 并计算其能量值, 调整生成器参数使其能量值减小; 4) 重复这一过程, 直到达到预设的训练次数或生成数据的质量达到预期。在改进的 EBGAN 中, 生成器的输出被视为向量, 而不是概率分布, 因此不需要使用交叉熵等损失函数。

模型训练过程中, 因为 RMSprop 算法能够自适应调整学习率, 确保训练过程更加稳定, 并有效处理稀疏梯度, 减少超参数调节需求, 从而加速模型收敛, 所以生成网络 G 和判别网络 D 的优化算法都选择 RMSprop 算法^[21], 其中, 一阶矩估计的参数 $\beta_1 = 0.9$, 初始学习率 $learning_rate = 0.000\ 01$, 训练轮次 $epochs = 200$, $batch_size$ 设置为 32, 按照 1:3 的比率交替训练生成器与判别器, 即训练 3 次 D, 再训练 1 次 G。图 6 概括了本文所提改进的 EBGAN 模型生成肌电数据的全部流程, 其包括通过数据预处理得到原始数据集, 训练判别器与生成器, 当判别器达到纳什平衡后, 输出生成数据并进行相似性验证。




图 6 改进后 EBGAN 的工作流程图

2.3 量化评价指标

为了评估时间序列数据的生成, 文献 [22] 提出使用动态时间规整 (DTW, dynamic time warping) 和最大平均差异 (MMD, maximum mean difference) 作为

评价指标, 并指出 DTW 对训练不稳定性和对真实数据和生成数据之间的相对幅度的敏感性更强, 所以本文将 DTW 作为首选目标, 其计算原理如下:

$$D(i, j) = d(s_i, t_j) + \min \left\{ \begin{array}{l} D(i-1, j-1), \\ D(i-1, j), \\ D(i, j-1) \end{array} \right\} \quad (6)$$

其中: $d(s_i, t_j)$ 是两个时间序列在 (i) 和 (j) 点的距离, 这里是欧几里得距离。

此外, 为全面证明生成数据与原始数据的相似性, 本文还使用信号 FFT 幅度之间的均方误差 (MSE) 作为评估指标, 从频域角度评价生成数据的可用性。其计算原理如下:

$$X[k] = \sum_{n=0}^{N-1} x[n] \cdot e^{-2\pi i / N kn} \quad (7)$$

式 (7) 为离散傅里叶变换的计算公式, 对原始数据与生成数据进行快速傅里叶变换, 得到信号幅度之间的均方误差 (MSE) 如下:

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (8)$$

其中: Y_i 是第 (i) 个实际观测值, $\hat{Y}_i$ 是第 (i) 个预测值, n 是观测点的数量。

3 实验结果分析

3.1 生成数据的真实性评估

本文没有进行传统的特征提取, 直接将正常人与截肢患者预处理后的原始肌电信号作为输入, 利用改进的 EBGAN 模型直接生成肌电信号, 图 7、8 从上到下依次展示了正常人与患者的原始肌电数据 (上图) 和生成肌电数据 (下图) 对比。通过这一可视化展示, 可以直观地观察到改进的 EBGAN 模型生成的肌电信号与真实信号之间的相似性, 从而证明了生成数据的一定程度的真实性。




图 7 正常人原始数据与生成数据对比




图 8 截肢患者原始数据与生成数据对比

此外, 本文进一步对比了改进的 EBGAN 与传统 GAN、EBGAN、以及使用梯度惩罚机制来满足 Lipschitz 连续条件的 WGAN-GP (WGAN with gradient penalty) 方法^[23] 的 DTW、FFT MSE 指标。两个指标的数值越低, 表明生成数据越接近真实数据, 也就表明生成数据的质量越好。以 DB2、DB3 中的肌电信号为例, 生成肌电数据与原始数据之间的 DTW 与 FFT MSE 数值如表 1 所示, 可以看出改进后的 EBGAN 模型在两个评价指标上的效果最好, 且截肢人群的生成信号与原始信号的相似度略高于正常人的。充分证明了该模型对于截肢人群的表面肌电数据增强的有效性和适用性。

表 1 原始数据与真实数据之间的 DTW、FFT MSE 数值

	DTW		FFT MSE	
	DB2	DB3	DB2	DB3
GAN	356.47	164.34	201.11	50.75
WGAN-GP	312.69	153.66	184.36	46.11
EBGAB	35.62	25.57	1.91	0.91
改进的 EBGAN	3.39	2.91	0.08	0.04

3.2 合成数据的分类性能验证

将改进后的 EBGAN 模型应用于原始肌电数据集进行对抗训练, 以使生成网络 G 能够产生肌电信号。其次, 使用 G 网络生成与原始数据集相当规模的生成样本, 并进行标注, 与原数据样本一起构成合成数据集。接着, 从原始及合成数据集中提取时域特征, 分成 80% 训练集和 20% 测试集。利用分类模型对这两组数据进行训练, 以验证合成数据的有效性。考虑到样本规模对分类效果的影响, 合成数据集包含不同规模的生成样本, 数量为原始样本的 0.5~3 倍。这些数据集分别标记为“合成数据集 * 0.5”至“合成数据集 * 3.0”。

本文选择支持向量机 (SVM, support vector machine)、K 邻近 (KNN, k-nearest neighbor)、人工神经网络 (ANN, artificial neural networks) 这 3 种典型的机器学习分类模型。并提取均方根 (RMS)、绝对均值 (MAV)、方差 (VAR) 以及平均值 (MEAN) 这 4 个时域特征进行分类识别。分类结果如表 2 所示。

表 2 不同规模数量合成数据集在各分类模型的分
类准确率 %

分类模型	DB2			DB3		
	SVM	KNN	ANN	SVM	KNN	ANN
原始数据集	67.9	73.2	71.4	52.7	51.4	50.5
合成数据集 * 0.5	74.4	78.9	76.5	61.2	61.7	54.3
合成数据集 * 1	78.1	81.2	75.5	64.9	69.1	63.4
合成数据集 * 2	79.1	77.9	77.2	60.8	65.5	59.7
合成数据集 * 3	77.4	75.1	72.7	55.4	56.5	56.5

各分类模型的基本信息如下:

1) SVM, 它在解决小样本、非线性及高维模式识别中表现出许多特有的优势, 并能够推广应用到函数拟合等其他机器学习问题中。在 SVM 中, 选择超平面以最佳地将输入变量空间中的点与它们的类分开。

2) KNN, 其核心思想是如果一个样本在特征空间中的 k 个最相邻的样本中的大多数属于某一个类别, 则该样本也属于这个类别, 并具有这个类别上样本的特性。该方法在确定分类决策上只依据最邻近的一个或者几个样本的类别来决定待分样本所属的类别。

3) ANN, 通过模拟生物神经网络的工作原理, 将输入数据逐层传递并处理, 以进行分类或预测。在 ANN 中, 数据经过输入层进入隐藏层, 每个神经元根据输入数据和相应的权重计算出一个输出值, 并通过激活函数进行非线性变换。然后, 这些输出值传递到下一层神经元, 直至最终输出层生成预测结果。ANN 通过调整权重和偏置来最小化误差, 从而优化模型性能。该方法能够处理复杂的非线性问题, 具有强大的模式识别和自学习能力。

结果表明, 使用改进后的 EBGAN 生成样本的合成数据集在各分类模型上的分类效果均优于原始数据集, 准确率均提高至 1%~9%。其中 KNN 的分类效果更好, 我们认为虽然 ANN 和 SVM 在处理复杂非线性关系方面具有优势, 但 KNN 在这种特定应用场景中可能更有效, 因为它不依赖模型训练, 而是直接利用邻近样本的信息来进行分类。肌电信号的分类存在高维特征和复杂模式, 而 KNN 通过简单直观的邻近样本比较, 能够更加准确地反映这些特征和模式, 从而实现更高的分类效果。

对于基于机器学习的分类模型来说使用“合成数

据集 * 1~* 2”分类效果更好。实验结果表明, 使用合成数据集可以提高基于机器学习分类模型的分
类准确率, 也从侧面证明了数据增强方法有助于提高分类器的分类性能。同时, 分类模型训练效果与合成数据集中生成样本的规模数据量非线性关系, 过多地引入生成样本, 将使得扩充数据的样本主体由原始数据变为合成数据, 而合成样本不可能无限接近于真实样本, 从而导致分类准确率下降, 合成数据时需要分配好样本之间的权重。

3.3 改进的 EBGAN 模型对肌电数据增强的适用性

为了进一步探究改进的 EBGAN 模型对于原始肌电信号的适用性, 本文将 EBGAN 与改进的 EBGAN 模型的合成数据用于 SVM 等上述分类模型中, 合成数据集
中的生成样本为原始样本的一倍。分类情况如图 9 所示, 可以看出改进的 EBGAN 的合成数据集分类准确率是最高的, EBGAN 的合成数据集分类结果也略高于原始数据集, 结果表明使用改进的 EBGAN 模型对表面肌电数据增强的适用性与优越性。此外, 由于 GAN 与 WGAN-GP 模型生成的肌电数据质量较差, 缺乏真实性, 故没有对比两个模型合成数据分类结果。





图 9 各分类模型在不同生成模型的合成
数据集分类准确率

4 结束语

本文针对因肌电信号数据量少、采集困难繁杂且受
环境影响大导致的肌电分类准确率不高的问题, 提出了
基于卷积神经网络与能量生成对抗网络结合的肌电数据
增强方法, 开展了肌电信号预处理、改进 EBGAN 模型

的构建与优化、增强效果评价等研究,并使用可量化指标和典型分类方法客观地评估表面肌电生成方法的有效性。结果表明,本文方法能够有效生成足够真实的肌电特征,相较于传统 GAN、EBGAN、WGAN-GP 模型,改进的 EBGAN 模型的生成数据更加逼真,有助于提升典型机器学习模型的分类效果,验证了本文数据生成方法的有效性以及合成样本的泛化能力。同时,合成数据集不会对原始敏感训练数据构成重大隐私问题或构成数据泄露,具有较高的应用前景。

由于本文主要着手于表面肌电数据增强方法的可行性,对于分类方法并没有着重考虑,故整体的分类准确率不高。后续将对模型进行优化以提高肌电数据的生成速率,并利用肌电识别算法开展肌电信号在线生成与识别研究。

参考文献:

- [1] 张海迪,周奎奎,吕世明,等. 中国残疾人事业统计年鉴 2020 [J]. 中国残疾人事业统计年鉴, 2020, 19: 28-34.
- [2] 唐晓. 基于表面肌电的运动单位活动特性分析及应用 [D]. 北京: 中国科学技术大学, 2021.
- [3] BENALCAZAR M E, MOTOCHÉ C, ZEA J A, et al. Real-time hand gesture recognition using the Myo armband and muscle activity detection [C] // IEEE Second Ecuador Technical Chapters Meeting (ETCM), 2017: 1-6.
- [4] XIE B, MENG J, LI B, et al. Gesture recognition from bio-signals using hybrid deep neural networks [C] // IEEE International Conference on Artificial Intelligence and Computer Applications (ICAICA), 2020: 493-499.
- [5] 卫文韬,李亚军. 基于双流卷积神经网络的肌电信号手势识别方法 [J]. 计算机集成制造系统, 2022, 28 (1): 124-131.
- [6] 张文哲. 基于肌电模式识别的触觉智能假手控制系统研发 [D]. 南京: 东南大学, 2022.
- [7] GEETHANJALI P. Myoelectric control of prosthetic hands: state-of-the-art review [J]. Medical Devices: Evidence and Research, 2016: 247-255.
- [8] ALEXIOU A, THEOCHAROPOULOU G, VLAMOS P. Ethical issues in neuroinformatics [C] // Artificial Intelligence Applications and Innovations: 9th IFIP WG 12.5 International Conference, 2013: 700-705.
- [9] SAMUEL O W, ASOGBON M G, GENG Y, et al. Intelligent EMG pattern recognition control method for upper-limb multifunctional prostheses: advances, current challenges, and future prospects [J]. IEEE Access, 2019, 7: 10150-10165.
- [10] 郑赞,马玉良,陈林楠,等. 基于生成对抗网络的情绪识别数据增强方法 [J]. 传感技术学报, 2022, 35 (12): 1650-1654.
- [11] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks [J]. Communications of the ACM, 2020, 63 (11): 139-144.
- [12] CHEN Z, QIAN Y, WANG Y, et al. Deep convolutional generative adversarial network-based EMG data enhancement for hand motion classification [J]. Frontiers in Bioengineering and Biotechnology, 2022, 10: 909653.
- [13] ANICET ZANINI R, LUNA COLOMBINI E. Parkinson's disease EMG data augmentation and simulation with DC-GANs and style transfer [J]. Sensors, 2020, 20 (9): 2605.
- [14] ZHANG X, MA M. Research on sEMG feature generation and classification performance based on EBGAN [J]. Electronics, 2023, 12 (4): 1040.
- [15] KIM S, SHIN D Y, KIM T, et al. Enhanced recognition of amputated wrist and hand movements by deep learning method using multimodal fusion of electromyography and electroencephalography [J]. Sensors, 2022, 22 (2): 680.
- [16] 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.
- [17] 谷中历,张霞,徐梓桓,等. 一种基于 sEMG 信号多重分形的肌肉疲劳特征分析方法 [J]. 河北科技大学学报, 2023, 44 (2): 103-111.
- [18] ZHAO J, MATHIEU M, LECUN Y. Energy-based generative adversarial network [J]. Arxiv Preprint Arxiv: 1609.03126, 2016.
- [19] APICELLA A, ISGRÒ F, POLLASTRO A, et al. Adaptive filters in graph convolutional neural networks [J]. Pattern Recognition, 2023, 144: 109867.
- [20] LANGE S, HELFRICH K, YE Q. Batch normalization preconditioning for neural network training [J]. Journal of Machine Learning Research, 2022, 23 (72): 1-41.
- [21] XU D, ZHANG S, ZHANG H, et al. Convergence of the RMSProp deep learning method with penalty for nonconvex optimization [J]. Neural Networks, 2021, 139: 17-23.
- [22] DELANEY A M, BROPHY E, WARD T E. Synthesis of realistic ECG using generative adversarial networks [J]. Arxiv Preprint Arxiv: 1909.09150, 2019.
- [23] GULRAJANI I, AHMED F, ARJOVSKY M, et al. Improved training of wasserstein gans [J]. Advances in Neural Information Processing Systems, 2017, 30.