

合成肌电信号的生成对抗网络研究综述

王一博, 路 扬, 马小蕾, 张学沛, 白金峰

(内蒙古民族大学 计算机科学与技术学院, 内蒙古 通辽 028000)

摘要: 基于表面肌电(sEMG)的运动意图识别与神经康复评估高度依赖高质量数据,但数据稀缺、跨被试差异和类别不平衡等问题严重制约了系统性能,因而sEMG数据增强技术被广泛应用以缓解这些挑战。然而,常规的数据增强方法都存在着不可避免的缺陷,难以突破信号内在生理机制,而生成式模型凭借对复杂分布的隐式建模能力,为合成高保真sEMG提供了新途径。首先,介绍当前流行的3种生成式模型:基于概率的变分自编码器、扩散模型和生成对抗网络;其次,回顾生成对抗网络的4种经典模型,包括卷积生成对抗网络、Wasserstein GAN、条件GAN和自注意力GAN;再次,整理归纳公开和私人数据集,阐述肌电信号合成质量评价指标,并就它们在不同数据集、模型输入,以及下游手势识别、疲劳回归、病理检测任务中的性能差异及优缺点进行对比分析。结果表明:卷积GAN结构简单、实时性好;WGAN-GP训练稳定性和多样性优异;条件GAN支持可控生成;自注意力GAN模型提高信号的全局一致性。最后,展望未来研究方向,即应当围绕“生理驱动—临床可用—高效部署”展开,为sEMG-GAN技术在假肢控制、神经康复和人机交互等真实应用中实现高效、安全和可信的落地打下坚实基础。

关键词: 深度学习;生成对抗网络;数据增强;sEMG合成;肌电信号模型

DOI:10.11907/rjdk.251534

扫描二维码阅读全文:



中图分类号:TP181

文献标识码:A

文章编号:1672-7800(XXXX)0XX-0001-10

A Survey on Generative Adversarial Networks for Synthetic Electromyography Signal Generation

WANG Yibo, LU Yang, MA Xiaolei, ZHANG Xuepei, BAI Jinfeng

(College of Computer Science and Technology, Inner Mongolia Minzu University, Tongliao 028000, China)

Abstract: Surface electromyography (sEMG)-based motor intention recognition and neurorehabilitation assessment rely heavily on high-quality data, yet challenges such as data scarcity, inter-subject variability, and class imbalance severely limit system performance. Data augmentation is widely used to mitigate these issues, but conventional methods often fail to capture the underlying physiological mechanisms. Generative models, with their ability to implicitly model complex distributions, offer a promising approach for synthesizing high-fidelity sEMG signals. This review first introduces three major generative paradigms: probabilistic variational autoencoders, diffusion models, and generative adversarial networks (GANs), followed by a systematic overview of four representative GAN architectures, including convolutional GANs, Wasserstein GANs (WGANs), conditional GANs (cGANs), and self-attention/diffusion-based GANs. Public and private datasets and evaluation metrics for synthetic sEMG quality are also discussed. Comparative analyses across datasets, model inputs, and downstream tasks—such as gesture recognition, fatigue regression, and pathological detection—highlight differences in performance, advantages, and limitations. Results indicate that convolutional GANs are simple and computationally efficient, WGAN-GP provides stable and diverse training, conditional GANs enable controllable generation, and self-attention/diffusion hybrids achieve superior fidelity and high-frequency detail recovery. Finally, future research directions focus on physiology-driven modeling, clinical applicability, and efficient deployment, laying a solid foundation for safe, reliable, and practical applications of sEMG-GANs in prosthetic control, neurorehabilitation, and human-machine interaction.

Key Words: deep learning; generative adversarial network; data enhancement; sEMG synthesis; sEMG model

收稿日期:2025-09-18

基金项目:内蒙古自然科学基金项目(2023LHMS06021);自治区直属高校基本科研业务费项目(GXKY22134,GXKY23Z015);内蒙古民族大学博士科研启动基金项目(BSZ002)

作者简介:王一博(2002-),男,内蒙古民族大学计算机科学与技术学院硕士研究生,研究方向为生物信息、人工智能;路扬(1979-),男,博士,内蒙古民族大学计算机科学与技术学院副教授,研究方向为生物信息、人工智能;马小蕾(1984-),女,博士,内蒙古民族大学计算机科学与技术学院副教授,研究方向为生物信息、人工智能;张学沛(2000-),男,内蒙古民族大学计算机科学与技术学院硕士研究生,研究方向为生物信息、人工智能;白金峰(2000-),男,内蒙古民族大学计算机科学与技术学院硕士研究生,研究方向为生物信息、人工智能。本文通讯作者:路扬。

0 引言

肌电 (Electromyography, EMG) 信号记录了神经系统对肌纤维的激活情况, 具有高时间分辨率和对肌群运动意图的直接反映能力, 在假肢控制、人体—机接口、运动康复及神经退行性疾病监测等领域具有重要应用价值^[1]。表面肌电 (Surface Electromyography, sEMG) 通过贴片式电极采集, 便捷但易受皮肤—电极接触、肌肉脂肪厚度及噪声干扰影响; 高密度肌电 (High Density Electromyography, HD-EMG) 采用阵列电极采集, 可获得更丰富的空间分布信息, 但硬件成本和布置复杂度提升了实验难度^[2]。此外, 肌电信号的跨被试差异显著: 不同受试者的解剖结构、生理状态和电极位置轻微移动均可引起信号分布漂移, 导致同一模型难以在跨被试场景中保持稳定性能。伦理审批和隐私保护也导致现有公开数据集规模仍有限且门槛较高, 使得现有公开数据集数量有限、采样率和通道数分布不均, 严重制约了数据驱动方法的推广与验证^[3]。为缓解数据稀缺与分布偏差, 传统研究通过时间伸缩、幅值扰动、频域滤波等数据增强手段提高训练样本多样性, 但这类基于手工设计的变换难以突破信号内在生理机制, 生成的样本往往缺乏与真实肌电一致的时频特征与空间相关性^[4]。

现有关于肌电信号的综述多聚焦于特征提取与分类算法, 如 Moctar 等^[5]梳理了传统手工特征与基于深度学习的自学特征在 sEMG 信号分类中的应用, 构建了特征—分类器性能对照体系, 并讨论了数据稀缺性与模型可解释性等深度学习面临的挑战。同时, 还对比了在小样本条件下, 传统特征+SVM (Support Vector Machine)/LDA (Linear Discriminant Analysis) 等方法与卷积神经网络、循环神经网络等模型分类效果, 并指出未来研究重点应放在少样本学习、模型压缩及可视化分析等方向。Nazmi 等^[6]聚焦于等张与等长肌电信号模式识别, 首先介绍了信号预处理与基于概率密度函数的特征提取方法, 然后对比了 LDA、kNN (k-Nearest Neighbors)、支持向量机、多层感知机等分类算法在不同收缩条件下的实时识别性能, 并附有各方法在手部不同负载与动作上的分类准确率对比表, 为实际工程中的算法选型提供了实证依据。Oskoei 等^[7]从“基于模式识别”与“非模式识别”两大类控制策略切入, 全面回顾了滑动窗口与特征投影、时域/频域/时频域特征、模糊系统、隐马尔可夫模型及神经网络在肌电控制中的应用; 分析了各算法的响应延迟、计算负担和健壮性, 并讨论了从实验室到临床应用的主要瓶颈与改进方向; Reaz 等^[8]回顾了 EMG 信号的关键处理流程: 检测 (单/双阈值法)、分解 (小波变换、希尔伯特—黄变换)、信号降噪 (高阶统计量、滤波技术) 及分类 (自回归模型、谱特征、人工神经网络); 并列出了多种硬件实现 (专用滤波芯片、可演化硬件) 在假

肢控制与人机交互中的应用案例, 对比了不同方法在实时性与准确性之间的权衡。

然而, 与影像重建领域已有多篇生成对抗网络 (Generative Adversarial Networks, GAN) 系统综述不同, 针对肌电信号的生成与增强方向, 尤其是基于 GAN 的技术路线尚无专门综述^[9-11]。少数泛生物信号综述虽涵盖了心电图 (Electrocardiogram, ECG)、脑电 (Electroencephalogram, EEG) 和肌电 (EMG) 的生成方法, 但对肌电信号的任务特异性、模型变体及评价指标未作深入区分与实证对比, 在这一背景下有必要对该方向的研究进展进行系统综述^[12]。本文研究的意义在于: 一方面, 可以全面总结 GAN 及其变体在 sEMG 合成中的应用情况, 比较不同方法在稳定性、生成质量与实际应用上的优势与不足, 为肌电信号的特征提取与分类算法等方向提供数据增强; 另一方面, 可为后续研究者提供清晰的知识框架和参考路径, 推动该领域在医学康复、智能假肢及人机交互等场景的进一步落地与发展。

本文主要贡献如下: ①对基于生成对抗网络 (GAN) 的合成肌电 (sEMG) 信号生成方法进行了全面系统的综述, 涵盖了其基本原理、模型演进与实际应用; ②从模型架构、数据集特性、评价指标以及下游任务性能等多个角度, 对不同生成模型在肌电信号增强中的效果进行了细致对比与分析; ③总结现有挑战并提出未来重点研究方向, 包括增强生成信号的生理真实性与临床可用性、优化模型稳定性与多样性、推动轻量化与边缘计算部署, 以及强化可解释生成与临床决策支持的有效结合。

1 生成式模型概述

生成式模型根据其数据分布的建模方式, 可分为三大类: 基于概率的变分自编码器 (Variational Autoencoder, VAE)、扩散模型 (Diffusion) 和生成对抗网络 (GAN)。下文将逐一介绍它们的核心原理、训练机制及其在信号合成中的典型应用, 并对比它们在合成质量、效率与可控性方面的优劣。

1.1 基于概率的变分自编码器

VAE 通过在编码器—解码器框架中引入概率建模, 将输入信号映射到参数化的隐空间分布, 再通过重参数化技巧对隐变量采样并重构输入。其训练目标是最大化证据下界 (Evidence Lower Bound, ELBO), 如式 (1) 所示^[13]。

$$L(\theta, \varphi; x) = E_{\varphi}(q\varphi(z|x))[\ln p_{\theta}(x|z)] - D_{KL}(q\varphi(z|x) \| p(z)) \quad (1)$$

其中, L 是 VAE 的目标函数, θ 是生成器 (解码器) 的参数, φ 是推断器 (编码器) 的参数, x 是观测到的真实样本, z 是隐变量 (Latent Variable), $q_{\varphi}(z|x)$ 是近似后验分布, $p_{\theta}(x|z)$ 是条件似然分布, $p(z)$ 是先验分布 (通常是 $\mathcal{N}(0, I)$), $\mathbb{E}$ 是期望运算符, $\ln$ 是自然对数, D_{KL} 是 KL (Kullback-Leibler Di-

vergence)散度。

VAE的优点是训练稳定、具有明确概率解释;隐空间连续,适合插值与条件生成。但缺点是重构样本常偏向平滑,难以精细刻画高频成分,且ELBO最大化可能与生成样本的多样性冲突。针对这些问题,Zhang等^[14]在此基础上提出一种扩展型VAE架构,将sEMG信号分解为共享表征与私有表征,并在损失函数中融入跨被试对齐项,从而大幅提升了模型的跨被试泛化能力。实验证明,该方法在多个公开手势数据集上的识别准确率较传统VAE模型提高了约8%。Dai等^[15]针对开放集中可能出现的未知手势,设计了基于VAE的未知样本拒识框架,为已知手势构建条件潜在分布,并结合重构误差与潜在空间概率制定联合判别准则,实现对未知手势的高效检测。测试结果显示,未知样本误识率低于5%,且已知类别分类性能下降不足2%。

1.2 扩散模型

扩散模型定义一个正向扩散过程逐步向数据添加噪声,再学习一个反向去噪过程以逐步重建样本。其训练目标是 minimized 反向过程与真实后验之间的KL散度。如式(2)所示^[16]。

$$q(x_t|x_{t-1}) = \mathcal{N}(x_t; \sqrt{\alpha_t} x_{t-1}, (1 - \alpha_t)I) \quad (2)$$

其中, q 是前向扩散分布, x_t 是第 t 步的样本, x_{t-1} 是第 $t-1$ 步的样本, $\mathcal{N}(\mu, \Sigma)$ 是高斯分布,均值为 μ ,协方差是 Σ , $\sqrt{\alpha_t}$ 是保留的信号强度, α_t 是噪声调度参数, I 是单位矩阵。

扩散模型的优点是生成样本质量高、多样性强、收敛稳定;缺点是生成过程需数百步迭代,速度慢、计算开销大。为改进其在sEMG任务中的表现,Liu等^[17]提出的SDEMG采用score-based扩散框架对噪声sEMG进行逐步去噪,在信噪比上提升约4 dB,波形保真度提升约12%。Xiong等^[18]提出PatchEMG,将扩散过程划分为局部时间窗进行训练,即使在极少样本条件下(≤ 5 条样本/类),也能生成高保真肌电序列,下游分类准确率提升约7%。这些结果说明扩散模型适用于高质量sEMG样本的合成与少样本学习任务。

1.3 生成对抗网络

生成对抗网络由Goodfellow等^[19]提出,旨在生成与给定训练数据集高度相似的新数据。其核心是通过生成器(Generator, G)与判别器(Discriminator, D)的动态博弈实现对数据分布的隐式学习^[20]。标准GAN的目标函数如式(3)所示^[19]。

$$\min_G \max_D v(D, G) = \mathbb{E}_{x \sim p_{data}(x)} [\log D(x)] + \mathbb{E}_{z \sim p_z(z)} [\log (1 - D(G(z)))] \quad (3)$$

其中, $\min_G$ 是生成器最小化, $\max_D$ 是判别器最大化, G 是生成器(Generator), D 是判别器(Discriminator), $x \sim p_{data}(x)$ 是从真实数据分布采样, $z \sim p_z(z)$ 是从噪声分布采样, p_{data} 是真实数据分布, p_z 是先验噪声分布(常为 $\mathcal{N}(0, I)$), $\log$ 是自然对数, $D(x)$ 是判别器对真实样本的预测概率, $D(G(z))$ 是判别器对生成样本的预测概率。

GAN的优点是能生成与真实分布高度相似的样本,细节保真度高,并可通过条件GAN实现对类别、幅值等的控制。但其训练易不稳定,存在模式崩溃(Mode Collapse)风险,对网络结构与优化策略敏感。在sEMG研究中,GAN特别适合需要增强样本多样性与实现条件控制的任务,例如假肢闭环控制、在线疲劳模拟和少样本信号增强等。生成对抗网络结构如图1所示。




Fig. 1 Generative adversarial network structure

图1 生成对抗网络结构

从上述3类生成模型的机制与应用可以看出,它们在效率、合成质量与条件可控性方面各有优势。VAE通过概率建模和重参数化技巧,在生成效率上表现突出,且隐空间连续性有利于潜在特征表示与信号插值,但生成结果往往较为平滑,高频细节容易丢失。扩散模型依托逐步去噪过程,能够在全局结构与局部细节上同时保持较高的保真度,尤其在高频特征敏感的sEMG信号合成与去噪中表现优异。但由于需要多轮迭代,其生成效率较低,更适合离线场景。GAN则通过生成器与判别器的博弈学习,实现了毫秒级的高效生成,并能较好地保持信号的多样性和时频特征,同时具备较强的条件可控性,但在训练过程中容易受到模式崩溃的影响,需要较为复杂的优化策略。整体而言,VAE更适合用于潜在空间探索与快速数据建模,扩散模型适合需要高保真与细节恢复的任务,而GAN在效率、多样性与可控性之间取得了良好平衡,尤其适用于实时性和多样性要求较高的肌电信号生成与增强任务。

Table 1 Advantage comparison of generative models

表1 生成模型的对比优势

模型类型	生成效率	合成质量	条件可控性	典型应用场景
GAN	毫秒级	中	强(原生支持标签或连续条件输入)	实时闭环假肢控制、在线反馈式疲劳监测
扩散模型	秒级	优	中(通过条件引导或微调实现)	离线高保真信号合成、运动伪迹去除
VAE	毫秒级	较低	中(隐空间插值或条件VAE)	潜空间探索、信号特征可视化与快速数据降维

2 典型 GAN 模型与架构改进

生成对抗网络自提出以来,在合成信号领域不断演进与创新^[19]。针对肌电信号(EMG)生成的特性,研究者围绕 GAN 的基础理论和改进结构进行了大量探索。

2.1 基于 DCGAN 的 sEMG 合成与识别

Radford 等^[21]提出的 DCGAN(Deep Convolutional Generative Adversarial Network)使用深度卷积生成对抗网络进行无监督表示学习是首个将深度卷积结构与 GAN 有效结合的模型。其核心思路包括:采用全卷积生成器(G)和判别器(D),去除池化与全连接层,实现端到端特征抽取和生成;在每一层引入批归一化(BatchNorm)以稳定训练过程,使用 ReLU 和 LeakyReLU 激活以促进梯度流动;特别适合处理时序和空间模式较为复杂的 1D/2D 信号,是肌电信号合成的基础模型。在肌电信号领域,深度卷积生成对抗网络 3 种典型变体尤为突出。Gouda 等^[22]提出了一种一维深度卷积生成对抗网络(1D-DCGAN),专门用于生成手势的表面肌电(sEMG)信号。该实验和本文所涉及的大部分实验噪声处理方式均为训练前利用前置滤波/平滑削弱的常规方法去噪,生成器因而更倾向于学习“净化后的”信号,判别器也只看“净化后”的波形与特征,不涉及噪声条件,后续论述方法中无特殊情况便不再赘述。与传统 DCGAN 不同,作者将所有二维卷积层替换为一维卷积/转置卷积,以更贴合 sEMG 的时序特性;生成器输出长度固定的时域波形,判别器输入 1-D 波形。并且,利用两套公开或自建的手势 sEMG 数据集进行培训与验证,结果表明,1DDC-GAN 能够生成与真实数据在统计分布和判别难度上高度一致的合成样本。Chen 等^[23]报道了针对多通道 sEMG 提出了“图像化 DCGAN”增强方法。首先,将滑窗后的多通道肌电信号重塑并归一化为灰度图像,弱化了采集噪声,然后,采用标准的 2D-DCGAN(生成器:多层 Conv2D+Transpose+BatchNorm+ReLU;判别器:多层 Conv2D+Leaky-ReLU)进行对抗训练。训练完成后,合成的图像被逆转换回时域信号,并与真实数据共同用于手势分类器的训练。Zanini 等^[24]提出了一个两阶段增强框架以模拟帕金森病患者的肌电信号。第 1 阶段使用一维 DCGAN 训练并生成健康受试者的 sEMG 波形;第 2 阶段将生成的健康信号通过神经风格迁移网络转换其频谱,从而赋予病理特征。其利用公开的 EMG 数据进行训练和验证,结果显示,该方法能有效仿真出符合病理特征的肌电样本,为后续面向疾病检测或辅助康复训练的“离线”数据扩增提供了可行方案。

2.2 WGAN-GP 与多分支判别器

传统 GAN 在训练过程中易出现模式崩溃和梯度消失问题。为此, Gulrajani 等^[25]提出了 Wasserstein GAN(WGAN),并在后续引入梯度惩罚(WGAN-GP) Wasser-

stein GAN 的改进训练。其创新点如下:用 Wasserstein 距离代替 JS 散度量生成分布与真实分布的差异,使损失函数与生成质量高度相关;通过“权重裁剪”或“梯度惩罚”机制,确保判别器满足 1-Lipschitz 连续性;显著提升了 GAN 在生理信号高维复杂分布下的稳定性和训练效率。WGAN-GP 及其变体在肌电信号生成任务中被广泛采用,尤其适合多通道、高维、样本分布多样性强的场景,有效缓解了生成样本“单一模式”问题。

判别器采用 Wasserstein 距离,如式(4)所示^[25]。

$$L_D = \mathbb{E}_{x \sim p_{\text{real}}} [D(x)] - \mathbb{E}_{z \sim p_z} [D(G(z))] + \lambda \mathbb{E}_{\hat{x} \sim p_k} \left[\left(\|\nabla_{\hat{x}} D(\hat{x})\| - 1 \right)^2 \right] \quad (4)$$

其中, L_D 是判别器损失, p_{real} 是真实数据分布, p_z 是噪声分布, $D(x)$ 是判别器对真实样本的输出, $G(z)$ 是生成器输出的假样本, λ 是梯度惩罚系数, $\hat{x}$ 是在真实样本与生成样本之间线性插值得到的点, p_k 是 $\hat{x}$ 的分布(采样策略), $\nabla_{\hat{x}} D(\hat{x})$ 是判别器对输入的梯度, $\|\cdot\|$ 是向量的范数。

在 sEMG 数据增强方面, Coelho 等^[26]设计了基于 WGAN-GP 的生成模型以合成手势肌电信号。将 WGAN-GP 应用于 sEMG 数据增强。通过训练一个基于 WGAN-GP 的生成器以合成手势肌电信号,并将这些合成样本与真实数据混合,使用卷积神经网络(Convolutional Neural Network, CNN)对多类手势进行分类。实验表明,与未使用合成数据的基线模型相比,加入 WGAN-GP 合成样本的分类器在多种测试场景下均表现出更优的分类性能,验证了该方法在提升 sEMG 下游识别任务中的有效性。

2.3 条件 GAN(cGAN)实现可控生成

Mirza 等^[27]提出的 cGAN 条件生成对抗网络通过将类别标签或先验条件作为输入嵌入到生成器和判别器,实现了条件控制生成。其主要特征:生成器与判别器均接收条件信息(如动作类别、肌肉部位、疲劳水平等);目标是生成符合指定条件分布的样本,极大提高了合成 EMG 信号的实用性和多样性;训练过程可在小样本条件下有效增强少数类数据,对不平衡任务和稀缺场景极具价值。cGAN 模型在手势分类、疲劳状态检测、病理信号模拟等 EMG 下游应用中具有重要作用,可定向增强特定标签的样本,提高下游模型的泛化能力和可靠性。经检索,公开文献中尚无单纯以卷积或循环为骨架的 cGAN 模型专门用于 sEMG 信号的生成或增强。具有代表性的是 Li 等^[28]将 cGAN 架构与纯 Transformer 结构相结合,用多层自注意力与前馈网络取代了卷积/循环层,以更好地捕获长序列依赖。其生成器接收信号作为输入,经过若干层 Transformer 解码器后输出任意长度的合成生理序列;判别器则将输入送入 Transformer 编码器,以全局注意力机制判断生成是否与条件匹配。并且,在多种生理信号上评估了该方法的性能,使用改进的小波相干性量化合成序列与真实序列的时频一致性,并在少样本情况下通过混合合成与真实数据训练的分

类器,验证了合成数据可提升分类准确率。虽然 TTS-
CGAN 并未针对 sEMG 数据集开展验证,但它代表了在条
件 GAN 框架下引入自注意力/Transformer 的可行范式。

2.4 自注意力 Transformer-GAN

Vaswani 等^[29]提出的 Transformer 模型,核心为多头自
注意力 (Multi-Head Self-Attention),无需卷积或循环结构
即可实现全局信息建模。近年来,Transformer 及其变种被
引入 EMG 生成任务:生成器与判别器中融合多头自注意
力,使模型捕获长距离依赖,提高信号的全局一致性与上
下文相关性;特别适合长序列、空间多通道 EMG 的建模,
显著提升了生成信号的物理一致性和分布多样性。与传
统卷积 GAN 相比,Transformer 结构在复杂运动模式、持续

疲劳合成、情感/多模态信号生成等场景下更具表现力和
可解释性。Nasrallah 等^[30]使用自采数据集,其中生成器与
判别器均基于 Transformer 自注意力堆叠模块,条件输入为
手势类别标签;通过 Wavelet Coherence 评估合成波形与真
实波形的时频一致性,并在少样本 (每类仅 10~20 条)场景
下,将合成数据与真实数据混合训练 CNN 分类器。

表 2 系统梳理了 5 种典型生成对抗网络 (GAN) 模型在
肌电信号合成中的应用概况,详细对比了各模型所采用的
实验数据集、核心架构特点、关键训练参数以及最终的性
能表现结果,清晰呈现了不同 GAN 变体在生成质量、跨数
据集泛化能力和下游任务增强效果方面的差异与优势。

Table 2 Typical GAN model
表 2 典型的 GAN 模型

实验模型	数据集与实验条件	核心架构与设置	主要趋势性结果
1D-DCGAN (Gou- da et al.2023)	公共+私有数据集;1D 卷积;窗口=生成器:5 层 Conv1D-Transpose, BatchNorm+Re- 固定长度,步长未说明;跨被试未 LU;判别器:多视图输入 (原始/DTW/FFT/小波); 涉及 Adam (lr=2e-4, $\beta_1=0.5$), 200 epoch		合成样本在分布特征上接近真实数据,Fréchet 距离较 低;加入合成数据后,CNN 分类准确率提升约 2~3 个百 分点 (被试内设置)
Image-DCGAN (Chen et al., 2022)	Myo-DB-HGD (8 通道, 200 Hz);滑 窗 200 ms,跨被试未验证	将多通道 sEMG 重构为灰度图输入 2D-DCGAN, 再逆变换回时域波形	合成数据与真实数据混合训练后,SVM/RF 分类器性能 提升约 1%~2%;但纯合成数据交叉验证准确率仅约 50%,说明其增强作用主要体现在“与真实数据结合”
DCGAN+风格迁移 (Zanini & Colombi- ni, 2020)	NinaPro (健康)+私有 PD 患者;窗 口与步长未说明;跨被试未涉及	阶段 1:1D-DCGAN 生成健康受试者信号;阶段 2:U-Net 风格迁移,频谱映射为 PD 震颤特征 (4~ 8 Hz)	在诊断任务中能有效再现病理性震颤特征,辅助分类模 型达到较高准确率和敏感性;说明该方法更适合病理信 号仿真与扩增,而非一般手势识别
WGAN-GP (Coel- ho et al.2023)	CapgMyo DB-a (1 kHz, 8×16 矩阵 电极)+自采数据;窗口 200 ms,跨 会话划分	生成器:多尺度 Conv1D+残差;判别器:1-Lip- schitz 约束+梯度惩罚 ($\lambda=10$)	在手势分类中,合成样本与真实数据混合训练,CNN 准 确率提升约 4 个百分点;表明 WGAN-GP 在多通道高维 信号增强上比 DCGAN 类方法更稳健
Transformer-CGAN (Nasrallah et al.2023)	自采 3 通道手部 sEMG,少样本 (10~20 条/类);窗口未说明;跨被 试未涉及	生成器:6 层 Transformer 解码器 (多头注意力+前 馈);判别器:Transformer 编码器	在少样本条件下 (被试内实验),加入合成样本后 CNN 分类准确率提升约 5%~8%;说明自注意力结构更适合 小样本与长依赖建模

3 数据集分析

数据集是开展生成对抗网络 (GAN) 研究的基石,其质
量、规模与多样性直接影响模型训练效果与泛化能力。然
而,受数据采集成本高昂、伦理审批严格和隐私保护需求
等因素制约,公开的肌电信号数据集相对稀缺,且在数据
规模、标准化程度和跨被试一致性等方面存在显著挑战。
以下将对多个具有代表性的肌电信号数据集进行全面剖
析,探讨它们在 GAN 研究中的应用现状、面临的问题及优
化策略。

3.1 主流公开数据集

NinaPro 是肌电领域极具影响力的多模式数据集,包
含多个子数据库 (如 DB1-DB10 等),主要聚焦于表面肌电
(sEMG) 数据^[31]。以 DB1 为例,它对 27 名健康被试的 52 类
手部动作进行了采集,这些动作涵盖了日常生活中常见的
抓握、伸展等操作,为手势识别、假肢控制等研究提供了丰
富的素材。该数据集的采样率通常为 2 000 Hz,采用多通
道电极进行信号采集,能够较为全面地反映肌肉活动的电

生理特征。在 GAN 研究中,NinaPro 常被用于验证模型在
多样化动作合成上的有效性,例如通过 DCGAN、WGAN 等
模型生成类似的手势信号,以评估模型对不同动作模式的
学习能力。然而,其跨被试差异较大,且样本量对于复杂
模型训练仍显不足。该数据集的具体介绍如表 3 所示。

CapgMyo 是表面肌电信号手势识别领域的重要基准
数据集,由 3 个子数据库 (DB-a、DB-b、DB-c) 构成^[32]。它
通过 8×16 高密度电极阵列进行记录,采样率为 1 000 Hz。

Table 3 Ninapro dataset
表 3 NinaPro 数据集

类型	受试者	动作 种类	信号采集设备
DB1	27 名健康	52	10 Otto Bock
DB2	40 名健康	49	12Delsys Trigno
DB3	11 名截肢	49	12Delsys Trigno
DB4	10 名健康	52	12 Cometa
DB5	10 名健康	52	2 Thalmic Myo Armbands (16 electrodes)
DB6	10 名健康	7	14Delsys Trigno
DB7	20 名健康 2 名截肢	6	12Delsys Trigno
DB8	10 名健康 2 名截肢	9	16Delsys Trigno
DB9	77 名健康	40	22Cyberglove-II
DB10	30 名健康 15 名截肢	10	12Delsys Trigno

其中, DB-a 对 23 名受试者中的 18 名采集了 8 个等距和等张手势。该数据集的采集装置采用矩阵式(8×16)差分电极阵列, 配备银湿电极, 能精确捕捉肌肉活动的电信号变化, 为分析肌肉活动的空间分布提供高分辨率信息。在手势识别模型构建中, 常将奇数次采集信号用作训练数据, 偶数次采集信号用作测试数据。例如, 在评估不同算法时, 较传统方法和部分深度学习方法有显著提升。在 GAN 应用中, 其高密度电极数据有助于训练模型捕捉精细的空间特征, 但样本量有限, 且不同子集间的差异也对模型的泛化能力提出了挑战。该数据集的具体介绍如表 4 所示。

CSL-HDEMG 为高密度表面肌电数据集, 采用 7×24 双极阵列(192 通道)在 2 048 Hz 采样率下记录, 包含 5 名健康受试者、27 个手指手势, 每名受试者包含 5 个采集 session 与多个重复试次^[33]。在 GAN 研究中, 可利用其多组别

Table 4 Capgmyo dataset

表 4 CapgMyo 数据集

类型	受试者	动作种类	信号采集设备
DB-a	18 名健康	8	自研矩阵式差分银湿电极阵列
DB-b	20 名健康	8	自研矩阵式差分银湿电极阵列
DB-c	23 名健康	12	自研 8×16 矩阵式差分银湿电极阵列

数据训练模型, 生成不同病理状态下的肌电信号, 辅助疾病诊断与康复治疗研究。然而, 其被试数量较少, 且病理数据的复杂性使得模型训练难度增加。该数据集的具体介绍如表 5 所示。

表 6 介绍了上述 3 种公开数据集 NinaPro、CapgMyo、CSL-HDEMG 在肌电信号识别研究领域的使用情况。

Table 5 CSL-HDEMG dataset

表 5 CSL-HDEMG 数据集

类型	受试者	动作种类	信号采集设备
CSL-HDEMG	5	27	矩阵式电极网格

Table 6 Usage of typical public datasets

表 6 典型公开数据集的使用情况

数据集	代表性论文	受试者与采样率	任务/实验条件	主要趋势性结果
NinaPro DB1	Gijsberts et al.2014, IEEE TN-27	27 名健康, 被试内划分; 2 kHz	50 类手势, 时域+频域特征→RF 分类	平均准确率约 75%, 验证了公开大规模数据集对基准评测的重要性
NinaPro DB5	Qin et al.2023, <i>Integrated sEMG Gesture Recognition</i>	10 名健康; 200 Hz; 滑窗 200 ms; 被试内划分	53 类手势(含 8 类子集); CNN 分类	在低采样率条件下, 整体准确率较高(约 86%), 说明深度模型能在资源受限环境下有效工作
CapgMyo DB-a	Bahador et al.2020, <i>Sensors</i> 20:3097	18 名健康; 1 kHz; 8×16 电极; 被试内划分	8 手势, CNN 在全通道/子通道对比	高密度电极在全通道条件下可实现接近满分的分类性能, 表明其在空间分布建模中的价值
CapgMyo DB-a + 自采 Myo 数据	Coelho et al.2023, <i>CMBBE</i> 26:243	CapgMyo(18 名健康)+自采(15 名健康); 1 kHz; 窗口 200 ms	每类额外生成 200 条样本, 与真实数据混合; CNN 分类	合成数据在被试内场景下可带来 3~4 个百分点的准确率提升, 说明 GAN 增强的有效性
CSL-HDEMG	Geng et al.2016, <i>Sci. Rep.</i> 6:36564	5 名健康; 2048 Hz; 192 通道; 跨会话评估	27 类手势; 单帧 vs 多帧分类	单帧准确率较低, 多帧投票策略显著提升性能(至约 97%), 提示跨会话/跨帧信息整合的重要性
CSL-HDEMG	Chen J. et al.2020, <i>IEEE JBHI</i> 24:2657	同上, 重采样至 4 096 Hz; 窗口 40~150 ms	3D 卷积分类	与 2D CNN 相比提升 12~18 个百分点, 说明 3D 建模有助于捕捉时空特征
Myo-DB-HGD	Chen X. et al.2022, <i>Frontiers Bioeng.</i> 10:909653	10 名健康; 200 Hz; 8 通道; 窗口未说明	10 类手势; 灰度图 DCGAN 增强	GAN 增强带来约 1~2 个百分点的分类提升, 说明在低通道、低采样率下 GAN 仍能补充有限的训练样本

3.2 私人数据集

MyoData 数据集通过 Myo 臂环采集, 这是一种便携式的肌电信号采集设备, 便于在日常环境中使用^[34]。它包含多种动作类别, 如手臂的屈伸、旋转等, 采样率为 200 Hz。虽然 Myo 臂环的通道数相对较少(通常为 8 通道), 但因其便携性, 使得数据采集更为便捷, 适合研究日常生活中的肌电信号模式。在 GAN 应用中, 其数据可用于训练轻量级模型, 生成适用于可穿戴设备的肌电信号, 助力移动健康与智能交互领域的发展。但受限于设备特性, 其信号分辨率和准确性相对较低, 对模型的细节捕捉能力要求更高。

SARD-Hand 专注于手部动作的肌电信号采集, 包含多种精细手部动作(如捏、握、手指独立运动等)。该数据集的采集采用标准化流程, 确保了数据的一致性和可比性。它对每个动作进行了多次重复采集, 有助于分析动作的稳定性和变异性。在 GAN 研究中, 可利用其丰富的动作类别训练模型, 生成更贴近实际应用场景的手部肌电信

号, 提升假肢控制和虚拟现实交互中的手部动作模拟精度。然而, 其公开的数据规模相对较小, 难以满足大规模模型的训练需求。

3.3 数据集在 GAN 应用中的共性挑战

数据集在 GAN 应用中主要存在如下共性挑战:

(1) 样本量不足与多样性受限。尽管各数据集在动作类别或病理状态上各有侧重, 但总体而言, 多数公开数据集的被试数量较少(通常小于 50), 动作类别有限。例如, CapgMyo 虽聚焦于特定手势, 但面对复杂动作组合时, 样本量仍显不足; SARD-Hand 的动作多样性在某些复杂场景下也难以满足需求。小样本训练易导致 GAN 出现过拟合, 生成信号缺乏多样性, 难以覆盖真实场景中的各种变化。以 NinaPro 为例, 即使其被试数相对较多, 但在面对个体差异极大的肌肉解剖结构时, 仍无法充分训练模型适应所有情况^[31]。

(2) 跨被试差异显著。不同被试的肌肉解剖结构、电极放置位置、肌肉激活模式等因素, 导致同一动作的肌电

信号差异极大。例如,电极位置偏差 1 cm 可使信号幅值变化 30% 以上,不同被试的肌肉纤维走向、脂肪厚度等差异,使得信号的频率成分和空间分布也存在显著区别^[1]。这种差异使得在某一被试数据上训练的 GAN 模型,直接应用于其他被试时性能大幅下降。如在 MyoData 数据集中,不同被试使用 Myo 臂环采集的信号,因佩戴位置和肌肉特征不同,差异明显,增加了模型的跨被试泛化难度。

(3)数据标注与标准化缺失。部分数据集标注信息简单,仅提供动作类别,缺乏肌肉激活程度、力学参数、情感状态细节等细粒度标注。同时,采集标准不统一,如采样率(从 200 Hz 到 2 048 Hz 不等)、电极类型(干电极 vs 湿电极)、通道布局等差异显著。例如,NinaPro 与 CapgMyo 的采样率和电极布局不同,MyoData 与 CSL-HDEMG 的通道数和采集设备差异较大,这些都增加了数据融合与模型对比难度,阻碍了 GAN 研究的标准化进展。缺乏统一的标注规范和采集标准,使得不同研究之间的结果难以直接比较,限制了领域的整体发展。

4 评价指标体系

4.1 点误差度量

均方误差 (MSE)/均方根误差 (RMSE) 如式 (5) 所示^[35]。

$$RMSE = \sqrt{MSE} \quad (5)$$

其中, $MSE = \frac{1}{N} \sum_{i=1}^N (x_{gen}[i] - x_{real}[i])^2$, N 是信号长度(采样点总数); $x_{gen}[i]$: 是第 i 个生成信号采样值; $x_{real}[i]$ 是第 i 个真实信号采样值。

平均绝对误差 (MAE) 如式 (6) 所示^[35], 百分比均方根差 (PRD) 如式 (7) 所示^[36]。

$$MAE = \frac{1}{N} \sum_{i=1}^N |x_{gen}[i] - x_{real}[i]| \quad (6)$$

$$PRD = 100\% \times \sqrt{\frac{\sum_{i=1}^N (x_{gen}[i] - x_{real}[i])^2}{\sum_{i=1}^N (x_{real}[i])^2}} \quad (7)$$

式中符号同式 (5)。

4.2 形态相关度量

皮尔逊相关系数 (PCC) 如式 (8) 所示^[37]。

$$PCC = \frac{\sum_{i=1}^N (x_{gen}[i] - \mu_{gen})(x_{real}[i] - \mu_{real})}{\sqrt{\sum_{i=1}^N (x_{gen}[i] - \mu_{gen})^2} \sqrt{\sum_{i=1}^N (x_{real}[i] - \mu_{real})^2}} \quad (8)$$

其中,生成信号均值是 $\mu_{gen} = \frac{1}{N} \sum_{i=1}^N x_{gen}[i]$, 真实信号均值是 $\mu_{real} = \frac{1}{N} \sum_{i=1}^N x_{real}[i]$, $x_{gen}[i]$: 是第 i 个生成信号采样值; $x_{real}[i]$ 是第 i 个真实信号采样值。

平均相对误差 (MRE) 如式 (9) 所示^[38]。

$$MRE = \frac{1}{N} \sum_{i=1}^N \frac{|x_{gen}[i] - x_{real}[i]|}{|x_{real}[i]| + \varepsilon} \quad (9)$$

其中, ε 为防止除零的小常数, $x_{gen}[i]$: 是第 i 个生成信号采样值; $x_{real}[i]$ 是第 i 个真实信号采样值。

4.3 时序对齐度量

动态时间规整 (DTW) 如式 (10) 所示^[39]。

设 $X = \{x_{gen}[i]\}$, $Y = \{x_{real}[j]\}$, 定义累积距离矩阵 $D(i, j) = |x_{gen}[i] - x_{real}[j]| + \min \{D(i-1, j), D(i, j-1), D(i-1, j-1)\}$ 。其中, $D(1, 1) = |x_{gen}[1] - x_{real}[1]|$ 。

$$DTW(X, Y) = D(N, N) \quad (10)$$

其中, $D(i, j)$ 是累积距离矩阵, $DTW(X, Y)$ 是动态时间规整的最终距离, i, j 是序列索引, $|\cdot|$ 是绝对值。

最大互相关延迟 (Max-Corr Delay) 如式 (11) 所示^[40]。

$$\text{NormMaxCorr} = \frac{\text{MaxCorr}}{\sqrt{\sum_{i=1}^N x_{gen}[i]^2} \sqrt{\sum_{i=1}^N x_{real}[i]^2}} \quad (11)$$

$\text{Corr}(\tau) = \sum_{i=1}^{N-\tau} x_{gen}[i]x_{real}[i+\tau]$, 表示滞后 τ 时的互相关, $\text{MaxCorr} = \max_{\tau \in [0, \tau_{max}]} \text{Corr}(\tau)$, 表示最大互相关值, NormMaxCorr 是归一化最大互相关, τ 是时间延迟, τ_{max} 是最大允许延迟。

4.4 分布级别度量

最大均值差异 (MMD) 如式 (12) 所示^[41]。

令生成样本集 $\{g_p\}_{p=1}^P$, 真实样本集 $\{r_q\}_{q=1}^Q$, 核函数为 $k(\cdot, \cdot)$, 则:

$$\text{MMD}^2 = \frac{1}{P^2} \sum_{p,p'} k(g_p, g_{p'}) + \frac{1}{Q^2} \sum_{q,q'} k(r_q, r_{q'}) - \frac{2}{PQ} \sum_{p,q} k(g_p, r_q) \quad (12)$$

MMD 是最大均值差异, P 是生成样本数, Q 是真实样本数, g_p 是第 p 个生成样本, r_q 是第 q 个真实样本, $k(\cdot, \cdot)$ 是核函数 (常用高斯核)。

Fréchet 距离 (FD)/FID 如式 (13) 所示^[42]。

设特征提取后生成样本均值与协方差为 $(\mu_{gen}, \Sigma_{gen})$, 真实样本为 $(\mu_{real}, \Sigma_{real})$, 则:

$$\text{FD} = \|\mu_{gen} - \mu_{real}\|^2 + \text{Tr} \left(\Sigma_{gen} + \Sigma_{real} - 2(\Sigma_{gen} \Sigma_{real})^{\frac{1}{2}} \right) \quad (13)$$

FD 是 Fréchet 距离 (FID), μ_{gen} 是生成数据的均值向

量, μ_{real} 是真实数据的均值向量, Σ_{gen} 是生成数据的协方差矩阵, Σ_{real} 是真实数据的协方差矩阵, $Tr(\cdot)$ 是矩阵的迹, $\|\cdot\|$ 是向量的欧几里得范数。

4.5 下游任务性能

在评估生成对抗网络(GAN)合成肌电(EMG)信号的实际效用,最具说服力的手段是将其应用于实际下游任务,并通过定量指标与真实数据进行对比。当前主流下游场景涵盖手势识别、疲劳分级、病理检测和异常识别等,采用真实实验对合成数据带来的性能提升进行验证。

在手势识别任务中,Chen等^[23]将基于DCGAN的合成sEMG数据与真实数据混合,用于训练手势分类模型,实验证明合成样本能带来分类性能的小幅提升。同样,Coelho等^[26]使用WGAN-GP进行了数据增强,结果显示增强后的数据可以提高下游分类器的泛化能力。

在肌肉疲劳和输出幅值的回归场景中,已有研究利用WGAN-GP生成疲劳状态下的sEMG数据,并将合成样本与真实数据混合用于回归模型的训练。Ao等^[43]在一项基于WGAN-GP的研究中,对非疲劳与疲劳条件下的手势sEMG信号进行了数据增强。结果显示,使用合成数据扩充后的回归模型在中值频率(Median Frequency, MF)和幅值预测上的误差有显著下降,验证了合成样本对回归任务的支持作用。

在病理检测与异常识别任务中,针对病理肌电信号,Zanini等^[24]提出的DCGAN+风格迁移框架能够模拟帕金森病患者的震颤特征,并将合成样本用于疾病分类,验证了对少量真实病理数据的补充价值。

4.6 生理真实性

为克服生理信号依赖指标相似性的局限从而导致忽略“生理真实性”,还可以采用已被验证的生理学与生物物理判据作为信号判真的标准。首先,共同驱动/低频相干:真实肌肉的运动单位(motor unit, MU)放电存在稳定的低频同步波动,生成信号在通道包络或(可分解时)MU放电率之间应呈现显著相干峰与面积,否则提示群体神经驱动未被保留^[44];其次,招募顺序与率编码:依据“先小后大”与“驱动 $\uparrow$ →放电率 $\uparrow$ ”的经典规律,分别以招募阈值与运动单位动作电位(Motor Unit Action Potential, MUAP)振幅或肌纤维传导速度(Muscle Fiber Conduction Velocity, MFCV)的秩相关,以及放电率-力(或幅值代理)的斜率与决定系数(Coefficient of Determination, R^2)评估一致性;再次, MU可分解性与脉冲-噪声比(Pulse-to-Noise Ratio, PNR):统计可分解MU数量、PNR分布与模板稳定性,用以判定合成信号是否具备可解释的MU级结构;最后,疲劳一致性:在等长或持续收缩条件下,中值/平均频率与MFCV应随时间下降,而均方根/平均整流值应上升,可用斜率差或效应量比较生成与真实的方向与量级是否一致^[45]。上述判据与现有统计指标互补,更能指向“深层生理机制”的保真度。

5 现代应用场景及未来研究方向

5.1 应用场景分析

在假肢控制与人机接口场景中,研究者通过对表面肌电(sEMG)信号进行手势识别以驱动假肢或外骨骼,强调端到端延迟需低于100 ms、分类准确率及F1得分要分别达到或超过90%。常用的公开数据库包括NinaPro、ISR Myo-I等^[31]。评价指标以分类准确率、Precision、Recall和F1最为常见,并辅以系统延迟测量。典型研究有:利用DCGAN对ISR Myo-I数据进行增强,将生成样本与真实样本混合后用于训练SVM模型,实验证明增强数据能够提升手势分类性能^[23]。

在运动康复和疲劳监测中,核心需求是合成信号必须保留中值频率(MF)随疲劳程度下降趋势并可调整峰值与功率谱密度(PSD)等疲劳特征。回归模型的评价通常采用RMSE和PRD指标以及MF回归误差,常用数据集为CapgMyo^[32]。Ao等^[43]基于WGAN-GP生成非疲劳和疲劳条件下的合成sEMG,并与真实数据混合用于回归模型训练,结果显示MF回归误差显著下降,验证了合成样本对疲劳回归任务的支持作用。

病理信号仿真旨在扩充稀缺的患者肌电数据以支持疾病诊断与监测算法开发,关键在于生成信号需保真病理特征(如帕金森病纤颤电位频率、尖波幅度分布)并能模拟不同病程阶段的演变过程。常见数据库包括帕金森病sEMG(静息与运动任务)和CSL-HDEMG(健康、肌病与ALS患者的高密度肌电)^[24,33]。Zanini等^[24]提出的DCGAN+风格迁移框架,通过生成健康sEMG再将其频谱风格化为病理特征,实现了对PPMI数据集的有效扩增,并显著提升了病理分类模型的诊断性能。

在多模态与情感/认知状态识别中,研究者将sEMG与EEG、GSR、呼吸等生理信号融合,以实现唤醒度、愉悦度等情感状态分类,要求多通道信号在时频特征上一致并保证不同模态间的时间对齐,常用数据库为DEAP^[46]。但目前尚无公开文献将GAN用于DEAP数据的情感识别增强,该方向仍待进一步探索。

5.2 未来研究方向

生成对抗网络(GAN)在肌电信号合成领域已展现出巨大潜力,但仍存在诸多挑战亟待解决。未来研究可以重点关注以下4个方向:

(1)提升生成信号的生理真实性与临床相关性。当前,GAN生成的肌电信号在微观生理机制(如运动单元发放模式、肌肉疲劳动态变化)和宏观动作意图表达(如手势分类、连续运动控制)上仍存在偏差,导致部分合成数据无法满足临床或工程应用的严格要求。例如:①存在生理合理性不足,即合成信号可能缺乏真实肌电的运动单位动作电位(MUAP)时序特征,影响假肢控制的自然性;②临床可

解释性弱,即生成模型难以关联病理特征(如 ALS 患者的肌电衰减模式),限制其在医疗诊断中的应用。解决方法:①融合生物物理模型,即将 Hodgkin-Huxley 方程或 Hill 肌肉模型嵌入 GAN 生成器,约束信号生成符合肌纤维电生理规律;②多模态数据联合生成,即结合运动捕捉数据或力学传感器信号,确保肌电一动作关联性。例如,生成同步的 sEMG 和关节角度数据,提升康复机器人训练的逼真度。

(2)优化模型稳定性与多样性。现有 GAN 在肌电合成中常面临模式崩溃(如仅生成单一幅度的信号)和训练不稳定(判别器过早收敛)问题,导致生成样本多样性不足,难以覆盖复杂动作或病理场景。解决方法:①渐进式训练策略,即采用分层生成方式,先生成基础动作(如握拳)的肌电信号,再逐步扩展至连续动作序列(如抓取—释放);②条件扩散模型应用,即利用扩散模型的多步去噪机制生成高保真肌电信号,并通过动作标签或疲劳等级控制生成过程。

(3)推动轻量化与边缘计算适配。现有模型(如 Transformer-GAN)计算复杂度高,难以部署至可穿戴设备或嵌入式假肢控制器。解决方法:①知识蒸馏与模型压缩,即将复杂 GAN(如 WGAN-GP)的知识迁移至轻量 1D-CNN;②量子—经典混合计算,即采用量子生成对抗网络(Q-GAN)处理噪声编码,经典网络解码波形,降低计算负载。

(4)生成模型的训练理论与泛化性分析。合成肌电信号实验的核心在于系统研究生成对抗网络在训练过程中出现的不稳定现象(如模式崩溃和梯度异常),以及模型在不同被试或采集环境下性能下降的根源。重点包括:①探索适用于肌电信号的损失函数和正则化方法,从理论层面解释其改善训练稳定性的机制;②分析模型在跨被试数据上的泛化误差边界,为少样本学习和域自适应策略提供理论依据。该方向致力于将理论分析与实际算法改进相结合,旨在提升生成模型的可靠性和实用价值,为构建高性能的肌电信号生成系统奠定基础。

6 结语

本文系统综述了生成对抗网络(GAN)在肌电信号合成领域的研究进展,从模型架构、数据集、评价指标和应用场景 4 个维度进行了全面分析。研究表明,GAN 通过 DC-GAN、WGAN-GP、cGAN 等模型的不断演进,在时序保真度、空间相关性和生成效率等方面取得了显著提升,为缓解肌电数据稀缺问题提供了有效解决方案。合成数据在下游任务中展现出重要价值,可提高手势分类准确率、病理检测,特别是在假肢控制、运动康复等场景表现突出。然而,当前研究仍面临生理机制建模不足、计算效率与生成质量难以兼顾、标准化缺失等挑战。展望未来,研究应当沿着“生理驱动—临床可用—高效部署”三位一体的技

术路线发展。本综述不仅填补了肌电生成领域系统研究的空白,更为跨学科协作提供了理论支撑和实践指南,推动 GAN 技术在医疗康复、人机交互等领域的深度应用,最终实现未来可探索面向应用的“合成即服务”模式,为普惠医疗和无障碍技术的发展作出贡献。

参考文献:

- [1] FARINA D, MERLETTI R, ENOKA R M. The extraction of neural strategies from the surface EMG: 2004–2024[J]. *Journal of Applied Physiology*, 2025, 138(1): 121–135.
- [2] HOLOBAR A, FARINA D. Blind source identification from the multichannel surface electromyogram[J]. *Physiological Measurement*, 2014, 35(7): R143–R165.
- [3] TSINGANOS P, CORNELIS B, CORNELIS J P H, et al. Data augmentation of surface electromyography for hand gesture recognition[J]. *Sensors*, 2020, 20(17): 4892.
- [4] ATZORI M, GJSBERTS A, CASTELLINI C, et al. Electromyography data for non-invasive naturally-controlled robotic hand prostheses[J]. *Scientific Data*, 2014, 1: 140053.
- [5] MOCTAR S M, RIDA I, BOUDAUD S. Comprehensive review of feature extraction techniques for sEMG signal classification: from handcrafted features to deep learning approaches[J]. *IRBM (Innovation and Research in Biomedical Engineering)*, 2024, 45: 100866.
- [6] NAZMI N, RAHMAN M A A, ROSLAN Z, et al. A review of classification techniques of EMG signals during isotonic and isometric contractions[J]. *Sensors*, 2016, 16(8): 1304.
- [7] OSKOEI M A, HU H. Myoelectric control systems—a survey[J]. *Biomedical Signal Processing and Control*, 2007, 2(4): 275–294.
- [8] REAZ M B I, HUSSAIN M S, MOHD-YASIN F. Techniques of EMG signal analysis: detection, processing, classification and applications[J]. *Biological Procedures Online*, 2006, 8(1): 11–35.
- [9] HUSSAIN J, BATH M, IVARSSON J. Generative adversarial networks in medical image reconstruction: a systematic literature review[J]. *Computers in Biology and Medicine*, 2025, 191: 110094.
- [10] HABASHI A G, ABDELAZIZ A, KHALIL M, et al. Generative adversarial networks in EEG analysis: an overview[J]. *Journal of NeuroEngineering and Rehabilitation*, 2023, 20(1): 91.
- [11] HAN C, FU R X, ZHOU Y S, et al. A review of generative ECG data enhancement methods based on artificial intelligence[J]. *Computer Engineering and Applications*, 2025, 61(16): 64–75.
韩闯,付瑞雪,周钰森,等. 基于人工智能的生成式心电图数据增强方法研究综述[J]. *计算机工程与应用*, 2025, 61(16): 64–75.
- [12] HAZRA D, BYUN Y C. SynSigGAN: generative adversarial networks for synthetic biomedical signal generation[J]. *Biology*, 2020, 9(12): 441.
- [13] KINGMA D P, WELING M. Auto-encoding variational Bayes[DB/OL]. <https://arxiv.org/abs/1312.6114>.
- [14] ZHANG Z, YANG Z, FANG S, et al. An extended variational autoencoder for cross-subject electromyograph gesture recognition[J]. *Biomedical Signal Processing and Control*, 2025, 99: 106828.
- [15] DAI Q, ZHANG B, WANG J, et al. Rejecting unknown gestures based on surface-electromyography using variational autoencoder[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2024, 32: 750–758.
- [16] HO J, JAIN A, ABBEEL P. Denoising diffusion probabilistic models[C]// *Conference on Neural Information Processing Systems*, 2020: 6840–6851.

- [17] LIU Y, WANG K, LIU K, et al. SDEMG: score-based diffusion model for surface electromyographic signal denoising [C]//2024 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2024: 1736–1740.
- [18] XIONG B, ZHANG Y, CAO Y, et al. PatchEMG: few-shot EMG signal generation with diffusion models for data augmentation to improve classification performance [J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 2527414.
- [19] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets [C]// Conference on Neural Information Processing Systems, 2014: 2672–2680.
- [20] XIA X, PAN X, LI N, HE X, et al. GAN-based anomaly detection: a review [J]. Neurocomputing, 2022, 493: 497–535.
- [21] RADFORD A, METZ L, CHINTALA S. Unsupervised representation learning with deep convolutional generative adversarial networks [DB/OL]. <https://arxiv.org/abs/1511.06434>.
- [22] GOUDA M A, HONG W, JIANG D, et al. Synthesis of sEMG signals for hand gestures using a 1D-DCGAN [J]. Bioengineering, 2023, 10 (12): 13353.
- [23] CHEN Z, ZHANG Y, HUANG Z. Deep convolutional generative adversarial network-based EMG data enhancement for hand motion classification [J]. Frontiers in Bioengineering and Biotechnology, 2022, 10: 909653.
- [24] ZANINI R A, COLOMBINI E L. Parkinson's disease EMG data augmentation and simulation with DCGANs and style transfer [J]. Sensors, 2020, 20 (9): 2605.
- [25] GULRAJANI I, AHMED F, ARJOVSKY M, et al. Improved training of Wasserstein GANs [C]// Conference on Neural Information Processing Systems, 2017: 5767–5777.
- [26] COELHO F, SILVA R, PEREIRA A, et al. A novel sEMG data augmentation based on WGAN-GP [J]. Computer Methods in Biomechanics and Biomedical Engineering, 2023, 26 (9): 1008–1017.
- [27] MIRZA M, OSINDERO S. Conditional generative adversarial nets [DB/OL]. <https://arxiv.org/abs/1411.1784>.
- [28] LI X, NGU A H H, METSIS V. TTS-CGAN: a transformer time-series conditional GAN for biosignal data augmentation [DB/OL]. <https://arxiv.org/abs/2206.13676>.
- [29] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C]// Conference on Neural Information Processing Systems, 2017: 5998–6008.
- [30] NASRALLAH C, BOUDAUD S, LAFORET J, et al. sEMG signal generation for data augmentation using time series transformer based conditional GAN [C]//2023 Seventh International Conference on Advances in Biomedical Engineering (ICABME), 2023: 137–141.
- [31] ATZORI M, MÜLLER H. The Ninapro database: a resource for sEMG naturally controlled robotic hand prosthetics [C]//Proceedings of the Conference on IEEE Engineering in Medicine and Biology Society, 2015: 715–718.
- [32] GENG W, DU Y, JIN W, et al. Gesture recognition by instantaneous surface EMG images [J]. Scientific Reports, 2016, 6: 36571.
- [33] AMMA C, KRINGS T, BÖER J, et al. Advancing muscle-computer interfaces with high-density electromyography [C]//Proceedings of the 33rd Annual ACM Conference on Human Factors in Computing Systems, 2015: 327–336.
- [34] ABREU J G, TEIXEIRA J M, FIGUEIREDO L S, et al. Evaluating sign language recognition using the Myo armband [C]//Proceedings of XVIII Symposium on Virtual & Augmented Reality (SVR), 2016: 64–70.
- [35] CHAI T, DRAXLER R. Root mean square error (RMSE) or mean absolute error (MAE)? —arguments against avoiding RMSE in the literature [J]. Geoscientific Model Development, 2014, 7: 1247–1250.
- [36] BLANCO-VELASCO M, CRUZ-ROLDÁN F, GODINO-LLORENTE J I, et al. On the use of PRD and CR parameters for ECG compression [J]. Medical Engineering & Physics, 2005, 27 (9): 798–802.
- [37] PEARSON K. Notes on regression and inheritance in the case of two parents [J]. Proceedings of the Royal Society of London, 1895, 58: 240–242.
- [38] ARMSTRONG J S, COLLOPY F. Error measures for generalizing about forecasting methods: empirical comparisons [J]. International Journal of Forecasting, 1992, 8 (1): 69–80.
- [39] SAKOE H, CHIBA S. Dynamic programming algorithm optimization for spoken word recognition [J]. IEEE Transactions on Acoustics, Speech, and Signal Processing, 1978, 26 (1): 43–49.
- [40] OPPENHEIM A V, SCHAFER R W, BUCK J R. Discrete-time signal processing [M]. 3rd ed. Upper Saddle River: Pearson/Prentice Hall, 2010.
- [41] GRETTON A, BORGAWARDT K M, RASCH M J, et al. A kernel two-sample test [J]. Journal of Machine Learning Research, 2012, 13: 723–773.
- [42] HEUSEL M, RAMSAUER H, UNTERTHINER T, et al. GANs trained by a two time-scale update rule converge to a local nash equilibrium [C]// Conference on Neural Information Processing Systems, 2017: 6626–6637.
- [43] AO J, LIANG S, YAN T, et al. Overcoming the effect of muscle fatigue on gesture recognition based on sEMG via generative adversarial networks [J]. Expert Systems with Applications, 2024, 238: 122304.
- [44] DE LUCA C J, ERIM Z. Common drive of motor units in hand-muscle electromyogram [J]. Journal of Neurophysiology, 1994, 71 (5): 1508–1518.
- [45] DIMITROVA N A, DIMITROV G V. Interpretation of EMG changes with fatigue: facts, pitfalls, and fallacies [J]. Journal of Electromyography and Kinesiology, 2003, 13 (1): 13–36.
- [46] KOELSTRA S, MÜHL C, SOLEYMANI M, et al. DEAP: a database for emotion analysis using physiological signals [J]. IEEE Transactions on Affective Computing, 2012, 3 (1): 18–31.

(责任编辑:孙娟)