

基于不平衡多标记学习的心电图分类及其可解释性*

李 想¹, 操思源², 陈松灿²

¹(南京信息工程大学 计算机学院/网络空间安全学院, 江苏 南京 210044)

²(南京航空航天大学 计算机科学与技术学院, 江苏 南京 211106)

通信作者: 陈松灿, E-mail: s.chen@nuaa.edu.cn



摘 要: 临床 12 导联心电图 (ECG) 是测试心脏活动最常用的信号源, 其自动分类及可解释性对心血管疾病的早期筛查和诊断至关重要. 现有的 ECG 分类研究多集中于单标记分类, 即每条心电记录仅对应一种心功能障碍, 而在临床中, 心血管疾病患者常伴有多种并发心脏疾病, 因此多标记 ECG 分类任务更符合现实需求. 现有基于深度神经网络的多标记 ECG 分类方法主要聚焦于标记相关性分析或神经网络架构的改进, 而忽略了多标记学习中的本质问题, 即天然存在的正负标记不平衡. 为此, 提出一种策略, 即每次仅推开一对标记, 使得正负标记在训练过程中维持平衡. 具体而言, 最大化正负标记之间的间隔并由此导出一个新的损失函数, 以缓解正负标记不平衡问题. 此外, 针对现有 ECG 方法可解释性不足, 难以辅助诊断的问题, 引入时域显著性重缩放方法来对提出方法的实验结果进行可视化展示, 以辅助定位并解释不同的疾病. 在 PhysioNet Challenge 2021 ECG 标准数据集上 (包含 8 个子集) 进行实验, 结果表明与最先进的多标记 ECG 分类方法相比, 所提方法取得了更优的性能.

关键词: 心电图分类; 多标记; 不平衡; 可解释性

中图法分类号: TP391

中文引用格式: 李想, 操思源, 陈松灿. 基于不平衡多标记学习的心电图分类及其可解释性. 软件学报, 2026, 37(8): 3370–3385. <http://www.jos.org.cn/1000-9825/7492.htm>

英文引用格式: Li X, Cao SY, Chen SC. Electrocardiogram Classification and Interpretability Based on Imbalanced Multi-label Learning. Ruan Jian Xue Bao/Journal of Software, 2026, 37(8): 3370–3385 (in Chinese). <http://www.jos.org.cn/1000-9825/7492.htm>

Electrocardiogram Classification and Interpretability Based on Imbalanced Multi-label Learning

LI Xiang¹, CAO Si-Yuan², CHEN Song-Can²

¹(School of Computer Science/School of Cyber Science and Engineering, Nanjing University of Information Science & Technology, Nanjing 210044, China)

²(College of Computer Science and Technology, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China)

Abstract: The 12-lead electrocardiogram (ECG) is the most commonly used signal source for testing cardiac activity, and its automatic classification and interpretability are crucial for the early screening and diagnosis of cardiovascular diseases. Most ECG classification studies focus on single-label classification, where each ECG record corresponds to only one type of cardiac dysfunction. However, in clinical practice, patients with cardiovascular diseases often have multiple concurrent heart diseases, making multi-label ECG classification more aligned with real-world needs. Existing deep learning-based multi-label ECG classification methods have mostly concentrated on label correlation analyses or neural network modifications, neglecting the fundamental issue in multi-label learning: the inherent imbalance between positive and negative labels. To address this issue, this study proposes a novel strategy that balances positive and negative labels during training by pushing away only one pair of labels each time. Specifically, it maximizes the margin between positive and negative labels and derives a new loss function to mitigate the imbalance issue. Furthermore, to address the insufficiency of interpretability in existing ECG methods, which hinders diagnostic assistance, the study introduces a temporal saliency rescaling method to visualize the

* 基金项目: 国家自然科学基金 (62376126); 江苏省教育强省建设专项资金-2025 年优势学科-人才启动费 (1083142501007)

收稿时间: 2024-12-29; 修改时间: 2025-05-09; 采用时间: 2025-06-14; jos 在线出版时间: 2025-10-29

CNKI 网络首发时间: 2025-10-31

experimental results of the proposed method, aiding in the localization and interpretation of different diseases. Experiments conducted on the PhysioNet Challenge 2021 ECG dataset, which includes 8 subsets, demonstrate that the proposed method outperforms state-of-the-art multi-label ECG classification methods.

Key words: ECG classification; multi-label; imbalance; interpretability

心血管疾病是全球范围内致死率最高的疾病之一, 据统计, 其死亡率在世界范围内持续位居前列^[1]. 12 导联心电图 (electrocardiogram, ECG) 作为筛查和评估心脏异常的重要诊断工具, 以其廉价且无创的优点被广泛应用于临床实践. 该检测方法能提供大量与心脏活动相关的生理信息, 为心血管疾病的分析和诊断提供重要支持^[2]. 然而, 记录和分析大量的生理信号不仅耗时费力, 而且需要专业的医学知识和丰富的临床经验^[3]. 此外, 人工分析和诊断可能因医生的经验、疲劳或主观判断而产生偏差. 为应对上述问题, 近年来, 研究者提出了基于自动分类的心电图生理信号分析方法, 旨在提高诊断的效率和准确性, 并辅助医生进行决策^[4,5].

在早期的心电图信号自动分类研究中, 传统的机器学习分类方法, 如支持向量机和隐马尔可夫模型等^[6,7], 被广泛应用于生理信号数据的处理和分析. 然而这类方法存在两方面的局限: 一是特征提取主要依赖于手工设计, 难以充分适应复杂多样的信号特征; 二是对于大规模数据集的处理能力不足, 限制了其在大数据时代的推广应用. 近年来, 随着深度神经网络 (deep neural network, DNN) 飞速发展, 其在心电图自动分类中的应用潜力也逐渐显现^[8]. DNN 凭借其强大的逼近能力自动拟合数据特征, 摆脱了对人工特征提取的依赖, 显著提高了分析效率和准确性. 同时, 得益于其灵活的模型结构和强大的特征学习能力, DNN 在诸多场景下的性能表现都优于传统机器学习分类器^[8].

目前, 大多数使用 DNN 的心电图分类研究工作主要关注多分类问题^[9-12], 即对心电图波群的起始和结束点进行分割, 提取每一个心跳的时序数据, 然后输出其对应的类别, 也称为单标记分类. 如图 1(a) 所示, 每个病人的心电图数据仅对应一种心血管疾病 (其中 AF、PAC、BBB 分别表示心房颤动、房性早搏、束支传导阻滞). 然而, 在临床实践中, 每个病人的心电图信号往往同时包含多种心血管疾病, 需对应多个标记, 如图 1(b) 所示. 此时单标记分类不再满足临床诊断的需求, 而多标记 ECG 分类则更符合现实情况. 相较于单标记分类, 多标记 ECG 分类面临更大的挑战. 具体而言, 多标记分类需要处理指数级增长的标记组合空间. 例如, 对于包含 100 个类别的心电数据, 其可能的标记组合多达 2^{100} 种, 如此庞大的标记空间显著增加了学习任务的难度. 为了应对这个挑战, 一系列多标记 ECG 分类算法被相继提出.




图 1 ECG 的多分类问题与多标记问题

现有的基于 DNN 多标记 ECG 分类研究主要聚焦于多标记相关性和改造网络. 合理利用标记相关性已在多标记学习领域被证明有益于性能提升^[13,14], 受此启发, 研究者也在 ECG 领域进行了一系列多标记相关性的研究. 例如, 图卷积网络 (graph convolutional network, GCN)、循环神经网络 (recurrent neural network, RNN)、流形正则化、标记相关性嵌入等模型或技术被用来刻画标记之间的相关性, 以探究 ECG 中不同疾病之间的关系. 除此之外, 由于 ECG 数据的特殊性, 如时序性、周期性、多源性等, 另一类流行的工作则针对性地进行 DNN 的改造, 以更好地适应 ECG 数据. 例如, Luo 等人^[15]将 CNN 和双向长短期记忆 (long short-term memory, LSTM) 网络相结合, 其中 LSTM 被用作处理 ECG 的时序性和周期性; Yang 等人^[16]设计了一种基于多视图和多尺度的深度神经网络,

该网络将不同导联作为不同的视图并利用多视图网络融合不同导联特征,以应对 ECG 的多源性. 尽管上述方法在多标记 ECG 分类任务上取得了长足的进步,然而它们往往忽视了对多标记学习中的本质问题,即天然存在的正负标记不平衡. 本文对常用的 ECG 数据集进行统计,并展示了不同数据集中正负标记的直方图(因版面限制,这里以 3 个数据集为例,其他数据集的结果类似). 图 2 表明,所有统计的数据集均存在严重的正负标记不平衡问题. 现有的多标记 ECG 分类方法默认采用二元交叉熵 (binary cross entropy, BCE) 作为损失函数,由于 BCE 平等对待每个标记^[17],因而严重占优的负标记将主导训练过程,导致了分类性能的退化.




图 2 正负标记不平衡统计图

针对上述问题,本文设计了一个损失函数来替代传统的 BCE,以解决多标记中正负标记不平衡问题. 由于 BCE 损失函数在训练时同时推开所有的正负标记,导致了在用于多标记分类任务时负标记占优的问题. 为此,本文提出了一个简洁且有效的策略,即每次仅推开一对标记,使得正负标记在训练优化过程中维持平衡. 该策略成功的关键在于选择怎样的一对正负标记以进行优化? 为了回答该问题,受大间隔理论^[18]启发,本文选择一对最为接近的正负标记: 其一是得分最低的正标记,另一则是得分最高的负标记(此处得分特指神经网络的 logits 输出). 通过最大化所选标记对的得分差,使它们的间隔更大,从而增加判别性,实现更明显的分离. 该最大化最接近分数间差异的策略与著名的大间隔理论相一致,该理论也给增强判别性提供了理论支撑. 通过该设计,训练过程中负标记的主导作用被抑制,同时正标记的重要性也得到巩固. 后文中的梯度分析表明,本文所提出的损失函数 BPNL (balanced positive-negative labels) 相较于 BCE,可以获得更加平衡的梯度更新,详见第 2.3 节.

除了上述的正负标记不平衡问题外,多标记 ECG 分类任务还面临另一个亟待解决的问题,即结果的可解释性. 鉴于 ECG 异常诊断直接关系到健康安全,深度学习模型作为“黑盒子”应用于该任务时也伴随着高风险. 因而如何解释这些黑盒模型的决策过程成为关键问题. 现有的 ECG 分类可解释性研究大多采用梯度加权类激活映射 (GradCAM) 方法^[19]对时域信号进行特征重要性的热力图分析,而未充分考虑多导联 ECG 中的不同空间通道(导联)的重要性信息,而这些导联恰好反映了心脏不同位置健康状况,且某些疾病也大多发生在特定导联区域,如心房颤动通常在 V1 导联处的特征最为明显. 因此空间通道(导联)信息对于定位疾病和解释决策也十分关键,而简单应用 GradCAM 来解释 ECG 分类并不完全可靠. 针对该问题,本文引入了时域显著性重缩放 (temporal saliency rescaling, TSR) 方法^[20]. 不同于仅考虑时域特征的 GradCAM 方法,TSR 方法同时考虑了时域和空间域(导联)的特征重要性,通过计算重要特征的时间戳及其对应的通道相关性分数,来同时对 12 导联心电图的时间和空间(导联)作显著性特征热力图分析,从而更全面、准确地给分类决策依据提供合理的解释.

本文的贡献主要包含以下 3 个方面.

(1) 提出一个损失函数 BPNL,可以解决 ECG 多标记学习中普遍存在的正负标记不平衡问题. 该损失函数不包含任何需要调节的超参数,且在梯度分析和实验验证中均证实了其有效性.

(2) 引入 TSR 方法来辅助定位并解释不同疾病的 ECG 特征. 该方法给模型的决策提供了诊断依据,可以更好地辅助诊断,也为深度学习方法辅助临床医疗诊断提供了可能性.

(3) 在 PhysioNet Challenge 2021 ECG 标准数据集上进行实验验证, 结果表明与现有多标记 ECG 分类方法相比, 采用本文所提出的损失函数训练的模型性能更加优越。

本文第 1 节回顾 ECG 多标记分类的相关工作, 第 2 节详细介绍本文提出的方法, 第 3 节展示实验设置及结果验证, 第 4 节给出本文的结论以及未来工作展望。

1 多标记 ECG 分类相关工作

多标记 ECG 自动分类由于能处理包含多种心血管疾病的数据, 更加符合临床诊断的需求, 近年来受到了越来越多的关注。现有的多标记 ECG 分类的相关工作主要可分为 3 大类: 转换为多个二分类问题、利用标记相关性以及改造神经网络。

第 1 类工作借用多标记学习中问题转换的思想, 将多标记 ECG 分类转化成多个二分类问题, 如 Wong 等人^[21]采用梯度提升树集成进行特征工程, 然后利用 XGBoost 二元分类器输出最终的结果。这类方法简单易实现, 但没有考虑标记相关性, 因而限制了其性能表现。针对该问题, 第 2 类方法则主要利用标记间的相关性来提升分类的性能, 典型的代表工作如: Jiang 等人^[22]采用 GCN 建模, 其中栈式的 GCN 层被用来刻画 ECG 中标记间的相关性。Ge 等人^[23]基于 ECG 标记的频率以及贝叶斯条件概率将 ECG 异常划分为不同的层次, 并利用多标记相关性引导不同层次的特征融合。Du 等人^[24]通过 RNN 来捕获隐藏记忆状态下的上下文信息, 以隐式地建模标记间的依赖关系。Li 等人^[25]计算心律不齐等疾病间的相似性程度, 并在一个多目标优化的框架中嵌入标记间的流形正则化。Ran 等人^[26]利用不同的心律不齐疾病之间的相关性矩阵来获取标记相关性嵌入, 然后计算标记嵌入与特征空间之间的余弦相似系数, 得到分类关注系数。而第 3 类方法则致力于 DNN 的改造以更好地适应 ECG 数据, Qin 等人^[27]设计了一个多标记疾病知识蒸馏网络, 其中教师网络采用 12 导联 ECG 数据训练, 而学生网络仅采用单导联进行训练, 该网络通过改造的纵向 Softmax 函数来输出多标记的疾病诊断。Luo 等人^[15]将 CNN 和双向 LSTM 网络相结合, 其中 CNN 用于特征提取, 而双向 LSTM 则用于整合 ECG 生理信号的跨时间特征。Yang 等人^[16]设计了一种基于多视图和多尺度的深度神经网络, 该网络将不同导联作为不同的视图, 并利用多视图融合不同导联特征。同时使用多尺度卷积神经网络结构获取心电信号在不同尺度下的时序特征以增强网络特征表示能力。Hwang 等人^[28]设计了一个 ResNet 和 DenseNet 级联的网络, 其中 ResNet 通过引入残差块来解决深度神经网络中的梯度消失问题, 并更好地捕捉多尺度特征, 而 DenseNet 则通过密集连接的方式加强了特征传递和重用, 使得模型更加稳健并且具有更好的泛化能力。Zhou 等人^[29]提出了一种新的多分支网络架构, 该网络引入了生物医学知识, 将 12 导联心电图分为不同的分支, 每个分支都采用多尺度卷积神经网络结构以提取更全面的特征; Huang 等人^[30]构造了一个多分辨率互学习网络, 包含多尺度卷积模块、双分辨率注意力模块和特征互补模块, 实现了同时对高分辨率和低分辨率特征的有效处理。Sadeghi 等人^[31]设计了一个 3D ECG 网络, 该网络首先通过一个 3D 转换器将原始的心电信号转换为三维数据, 然后通过挤压和激励残差模块增强重要通道的影响并降低不重要通道的影响。Hwang 等人^[32]提出了一个由二维残差 U-Net (ResUNet) 和导联合并器组成的网络。二维 ResUNet 通过堆叠二维残差 U 形块, 重复下采样和上采样以在不同尺度提取 ECG 特征, 所提模型有效地利用了多尺度中的跨导联和同导联 ECG 信息。Li 等人^[33]针对动作单元 (action unit, AU) 数据集中存在的严重不平衡问题, 提出了一个与类别频率成反比的加权策略, 以提升低频类别中被错误分类样本的惩罚程度。

尽管上述方法在多标记 ECG 分类任务上都取得了长足的进步, 然而它们大多忽视了多标记学习中本质的问题, 即天然存在的正负标记不平衡问题。大多数方法仍然简单地采用 BCE 作为损失函数, 无法有效解决这一不平衡问题。为此, 本文设计了一个损失函数以代替 BCE, 将在第 2 节进行详细阐述。

2 基于不平衡多标记 ECG 分类的损失函数及可解释性

本节将详细介绍本文所提出的方法, 具体组织如下: 首先在第 2.1 节给出多标记 ECG 分类的问题描述; 其次在第 2.2 节给出 BPNL 损失函数的推导; 然后在第 2.3 节给出 BPNL 梯度分析; 最后在第 2.4 节引入 TSR 方法, 并

给出可解释性分析.

2.1 问题描述

给定一个多标记 ECG 训练数据集 $\mathcal{D} = \{(\mathbf{x}_i, \mathbf{y}_i)\}_{i=1}^N$, $\mathbf{x}_i$ 表示第 i 个 ECG 样本, $\mathbf{y}_i$ 为其对应的标记, N 表示总样本数. 其中 $\mathbf{x}_i \in \mathbb{R}^{F \times T}$, F 为特征通道数, T 为时间戳的长度, $\mathbf{y}_i = [\mathbf{y}_{i1}, \mathbf{y}_{i2}, \dots, \mathbf{y}_{iC}] \in \{0, 1\}^{1 \times C}$, 其中 $\mathbf{y}_i$ 的每个元素对应着一种心律失常类型, C 为标记数. 若 $\mathbf{y}_{ij} = 1$, 表示样本 $\mathbf{x}_i$ 含有第 j 个标记, 称为正标记, 否则 $\mathbf{y}_{ij} = 0$, 称为负标记. 多标记 ECG 分类的目标是训练一个模型 $f: \mathcal{X} \mapsto 2^{\mathcal{Y}}$, 以预测输入空间 $\mathcal{X}$ 中测试样本的标记.

2.2 BPNN 损失函数

由图 2 所示可知, ECG 数据中存在严重的正负标记不平衡问题, 现有的 ECG 分类算法往往忽略了这一问题, 且大多采用 BCE 作为损失函数, 而 BCE 并不能解决不平衡问题. 为此, 本文提出了一个平衡的正负标记 BPNN 损失函数, 该损失函数的动机来源于一个非常直接的策略, 即每次仅选择一对正负标记来进行优化, 使得正负标记在训练时维持平衡. 该策略成功的关键在于选择怎样的一对标记来进行优化? 受大间隔理论启发, 本文首先定义了正负标记之间的间隔, 即得分最小的正标记和得分最大的负标记之间的距离, 此处得分指的是神经网络的 logits 输出 (未经过 Sigmoid 激活). 间隔 Δ_g 的正式定义如下:

$$\Delta_g = \min_{p \in \Omega_p} s_p - \max_{n \in \Omega_n} s_n \quad (1)$$

其中, s_p 和 s_n 分别是正标记和负标记的得分, Ω_p 和 Ω_n 分别是正负标记对应的索引集合.

在定义了正负标记的间隔 Δ_g 后, 基于大间隔理论最大化 Δ_g , 可得到公式 (2):

$$\max_{\theta} \Delta_g = \max_{\theta} \left(\min_{p \in \Omega_p} s_p - \max_{n \in \Omega_n} s_n \right) \quad (2)$$

其中, θ 是神经网络的参数.

由于 $\min(a, b) = -\max(-a, -b)$, 可将公式 (2) 转化成如下的等价形式:

$$\max_{\theta} \left(-\max_{p \in \Omega_p} (-s_p) - \max_{n \in \Omega_n} s_n \right) \quad (3)$$

为方便推导损失函数, 将公式 (3) 中第 1 个 $\max$ 替换为 $\min$, 可得到公式 (4):

$$\min_{\theta} \left(\max_{p \in \Omega_p} (-s_p) + \max_{n \in \Omega_n} s_n \right) \quad (4)$$

考虑到 $\max$ 函数不可微, 这里采用其对应的光滑近似 $\log \text{sum exp}$ 函数来代替. $\log \text{sum exp}$ 的定义如下:

$$\log \text{sum exp}(a_1, a_2, \dots, a_k) = \log \sum_{i=1}^k e^{a_i} \quad (5)$$

其中, $a_i \in (-\infty, +\infty)$, $i = 1, 2, \dots, k$. $\log(\cdot)$ 是对数函数, $e^{(\cdot)}$ 是指数函数. 将公式 (5) 代入公式 (4), 可得如下目标函数:

$$\min_{\theta} \left(\log \left(\sum_{p \in \Omega_p} e^{-s_p} \right) + \log \left(\sum_{n \in \Omega_n} e^{s_n} \right) \right) \quad (6)$$

自然地, 令 $\mathcal{L} = \log \sum_{p \in \Omega_p} e^{-s_p} + \log \sum_{n \in \Omega_n} e^{s_n}$ 为损失函数, 然而该损失函数无界, 最小化 $\mathcal{L}$ 会导致损失趋向于负无穷, 使得用于神经网络训练时不稳定且难以优化. 为了解决该问题, 本文分别在损失函数项里添加了两个常数 1, 使得损失函数非负, 也即有界. 最终得到平衡的正负标记 BPNN 损失函数如下:

$$\mathcal{L}_{\text{BPNN}} = \log \left(1 + \sum_{p \in \Omega_p} e^{(-s_p)} \right) + \log \left(1 + \sum_{n \in \Omega_n} e^{s_n} \right) \quad (7)$$

在完成上述损失函数设计后, 下文将介绍 12 导联 ECG 信号的训练学习过程, 具体如图 3 所示. 首先将 12 导联 ECG 信号切割成固定大小的时间序列窗口, 输入主干网络中进行特征提取, 然后网络输出一个预测向量 $\mathcal{Y}_p(\theta)$, 以表示模型对心电图数据的分类结果或置信度, 也记作 $\mathcal{Y}_{\text{pred}}$. 随后, 模型将预测结果 $\mathcal{Y}_{\text{pred}}$ 与真实标记 $\mathcal{Y}_{\text{true}}$ 进行比

对, 通过计算 BPNL 损失函数并利用反向传播算法优化网络参数 θ 以完成训练. 框架图的下半部分展示了损失函数优化标记的训练过程, 即每次仅选择一对正负标记进行优化, 此过程迭代进行, 直至网络训练收敛.




图3 总体结构框架图

2.3 梯度分析

本节将分别给出 BCE 损失函数以及本文所提出的 BPNL 损失函数的梯度分析, 以验证 BPNL 损失函数的梯度更新相较于 BCE 更加平衡.

首先, BCE 损失函数的表达式如下所示:

$$\mathcal{L}_{\text{BCE}} = -\frac{1}{C} \sum_{j=1}^C [\mathbb{I}_{[y_{ij}=1]} \log(g_{ij}) + \mathbb{I}_{[y_{ij}=0]} \log(1 - g_{ij})] \quad (8)$$

其中, $\mathbb{I}$ 是指示函数, g_{ij} 是标记 y_{ij} 对应的预测得分. 令 $h = \mathbf{h}_{ij}$, Sigmoid 函数 $g = 1/(1 + e^{-h})$, 则 BCE 损失函数关于 logits h 的梯度计算可表示为:

$$\begin{cases} \frac{\partial \mathcal{L}_{\text{BCE}}}{\partial h} = \frac{\partial \mathcal{L}_{\text{BCE}}}{\partial g} \frac{\partial g}{\partial h} = \frac{-e^{-h}}{1 + e^{-h}}, & y_{ij} = 1 \\ \frac{\partial \mathcal{L}_{\text{BCE}}}{\partial h} = \frac{\partial \mathcal{L}_{\text{BCE}}}{\partial g} \frac{\partial g}{\partial h} = \frac{e^h}{1 + e^h}, & y_{ij} = 0 \end{cases} \quad (9)$$

类似地, 易得 BPNL 损失函数关于得分 s_p 和 s_n 的梯度为:

$$\begin{cases} \frac{\partial \mathcal{L}_{\text{BPNL}}}{\partial s_p} = \frac{-e^{-s_p}}{1 + \sum_{p \in \Omega_p} e^{-s_p}}, & y_{ij} = 1 \\ \frac{\partial \mathcal{L}_{\text{BPNL}}}{\partial s_n} = \frac{e^{s_n}}{1 + \sum_{n \in \Omega_n} e^{s_n}}, & y_{ij} = 0 \end{cases} \quad (10)$$

令 $\Delta_{\text{BCE}} = e^h/(1 + e^h) - (-e^{-h}/(1 + e^{-h}))$, $\Delta_{\text{BPNL}} = e^h/(1 + \sum e^h) - (-e^{-h}/(1 + \sum e^{-h}))$, 由于 $e^h/(1 + e^h) > e^h/(1 + \sum e^h)$, $-e^{-h}/(1 + e^{-h}) < -e^{-h}/(1 + \sum e^{-h})$, 易得 $\Delta_{\text{BCE}} > \Delta_{\text{BPNL}}$, 因此相较于 BCE 函数, BPNL 损失函数关于正负标记的梯度更新更加平衡.

2.4 TSR 方法

现有的 ECG 分类可解释性研究大多采用 GradCAM 方法对时域信号进行特征重要性的热力图分析, 而未充分考虑多导联 ECG 中的不同空间通道 (导联) 的重要性信息, 而不同的导联恰好反映了心脏不同位置健康状况, 且某些疾病也通常发生在特定导联区域, 如心房颤动通常在 V1 导联处的特征最为明显. 因此空间通道 (导联) 信息对于定位疾病和解释决策至关重要, 而简单应用 GradCAM 来解释 ECG 分类并不完全可靠. 为了解决该问题,

本文引入了 TSR 方法^[20], 不同于仅考虑时域特征的 GradCAM 方法, TSR 方法同时考虑了时域和空间域两个维度的特征重要性. 具体而言, TSR 计算被认为是重要性特征的时间戳及其对应的通道相关性分数, 并按照相关性分数由高到低从中选择前 n 个时间戳作为重要特征, 来同时对 12 导联心电图的时间和空间 (导联) 作显著性特征热力图分析, 并生成更全面的可辅助医生诊断的模型结果可解释性图. TSR 的算法可总结如算法 1.

算法 1. TSR 方法.

输入: 输入样本 $\mathbf{x}$, 可解释性基线方法 $R(\cdot)$; //此处 $R(\cdot)$ 为 GradCAM 方法

输出: TSR 可解释性方法 $R^{\text{TSR}}(\cdot)$ 对应的重要性分数.

```

1. for  $t$  from 0 to  $T$  do
2.   掩码时间戳  $t$  下的所有通道特征值:  $\bar{\mathbf{x}}_{:,t} = 0$ , 否则  $\bar{\mathbf{x}} = \mathbf{x}$ 
3.   计算时间相关性分数  $\Delta_t^{\text{time}} = \sum_{i,t} |R_{i,t}(\mathbf{x}) - R_{i,t}(\bar{\mathbf{x}})|$ 
4. end
5. for  $t$  from 0 to  $T$  do
6.   for  $i$  from 0 to  $F$  do
7.     if  $\Delta_t^{\text{time}} > \alpha$  then //  $\alpha$  在实验中固定为 0.9
8.       掩码时间戳  $t$  下的第  $i$  个通道特征值:  $\bar{\mathbf{x}}_{i,:} = 0$ , 否则  $\bar{\mathbf{x}} = \mathbf{x}$ 
9.       计算通道相关性分数  $\Delta_i^{\text{channel}} = \sum_{i,t} |R_{i,t}(\mathbf{x}) - R_{i,t}(\bar{\mathbf{x}})|$ 
10.    else
11.      通道相关性分数  $\Delta_i^{\text{channel}} = 0$ 
12.    end
13.    计算 (时间, 通道) 重要性分数  $R_{i,t}^{\text{TSR}} = \Delta_t^{\text{time}} \times \Delta_i^{\text{channel}}$ 
14.  end
15. end
16. return  $R_{i,t}^{\text{TSR}}$ 

```

需要注意的是, Δ_i 表示掩码前后差值的绝对值所对应的相关性分数, 该分数根据模型训练中的准确率和召回率综合评估得出. 通过该方法, 可以帮助医生定位疾病主要表现在哪些通道上 (不同通道对应心脏不同部位), 从而提高诊断的精准性.

3 实验及分析

本节在标准 ECG 数据集上进行多标记分类实验, 以验证所提出 BPNL 方法的有效性, 并采用 TSR 方法对模型得到的结果进行可解释性分析.

3.1 数据集

本文实验采用 PhysioNet Challenge 2021 ECG 标准数据集^[34], 其包含 88 253 条 12 导联 ECG 数据记录, 分别来自 8 个不同数据库: CPSC2018 数据库、CPSC 额外数据库 (CPSC-EXTRA)、物理技术联邦数据库 (PTB)、PTB 扩展数据库 (PTB-XL)、乔治亚州 12 导联 ECG 挑战数据库 (G12EC)、查普曼大学和绍兴人民医院数据库 (Chapman-Shaoxing)、宁波市第一医院数据库 (Ningbo) 和圣彼得堡数据库 (St. Petersburg). 表 1 展示了这些数据集的正负标记不平衡度 (负标记个数/正标记个数). 为了对比实验的公平性, 本文采用与对比方法相同的实验设置. 实验中, 数据集按 8:2 的比例划分为训练集和测试集. 在数据预处理时, 所有的 ECG 信号均重新采样至 500 Hz, 并按 10 s 的时间窗口分割, 最后应用 Z 分数归一化 (Z-score normalization)^[35]. 根据 PhysioNet/CinC 2020/2021 挑战赛的设置, 本文采用官方提供的 SNOMED CT 代码, 使用 26 个类别进行模型评估.

表 1 本文实验采用的数据集不平衡度统计

数据集	正标记个数	负标记个数	不平衡度
Chapman-Shaoxing	13 431	252 991	18.84
CPSC2018	3 477	175 325	50.42
CPSC-EXTRA	1 447	88 331	61.04
G12EC	14 619	254 325	17.40
Ningbo	54 229	853 301	15.74
PTB	117	13 299	113.67
PTB-XL	36 796	530 966	14.43
St. Petersburg	32	1 892	59.13
PhysioNet Challenge 2021	124 148	2 170 430	17.48

3.2 评价指标

为了评估模型性能, 本文使用了 Macro $F1$ 分数、AUPRC (area under the precision-recall curve, 精确率-召回率曲线下的面积)、Kappa 系数 (Cohen's Kappa)、Macro AP (average precision, 平均准确率) 这 4 种常用于检测心电图失常分类模型评估的指标^[36,37]. Macro $F1$ 分数是对模型精确率 (precision) 和召回率 (recall) 的调和平均值得到的 $F1$ 分数再求算术平均得到的整体 $F1$ 分数, 用于权衡模型在正类样本上的错误分类, 是针对不平衡数据的一个更为公平的评价指标. AUPRC 也是衡量模型在类别不平衡情况下的性能指标, 它对于少数类的表现尤为敏感, 反映了模型在不同阈值下如何平衡正确识别少数类 (召回率) 与减少误报 (精确率) 的能力. Kappa 系数 (Cohen's Kappa) 评估预测标记与实际标记之间的一致性程度. Macro AP, 即对每个类别分别计算平均精确率, 然后对所有类别的平均精度取算术平均. Macro AP 关注每个类别的整体性能, 而不受类别不平衡的影响, 是一种均等地评估所有类别的指标. 通过这 4 种指标, 本文全面评估了模型在不平衡数据上的表现及预测一致性方面的综合性能.

3.3 实施细节

为了公平性, 本文在进行对比实验时, 采用由 ResNet 和 DenseNet 级联构成的网络作为主干网络的特征提取器^[28], 输出特征维度为 26 (对应 26 个类别). 模型训练设置为 35 个轮次 (epoch), 批次 (batch) 大小为 64, 并使用 Adam 优化器进行优化, 初始学习率设置为 0.001. 训练过程中采用阶梯式衰减 (step decay) 策略^[38], 在第 26 轮时学习率按固定系数 0.1 逐步衰减. 模型训练时使用的是本文提出的 BPNL 损失函数.

本文实验的具体环境如下: 软件配置方面基于 Ubuntu 20.04, CUDA 12.0 和 CUDNN 11.7 和 Python 3.7, PyTorch 2.0.0 和 Torchvision 0.15.0 深度学习框架进行^[39]; 硬件配置方面基于 GPU GTX 3060 (显存为 12 GB), 搭配 Intel i5 13400F 处理器和 32 GB 内存.

3.4 实验结果及分析

为验证本文所提出的 BPNL 损失函数在处理正负标记不平衡问题时的有效性, 本节在 PhysioNet Challenge 2021 ECG 标准数据集上进行了实验, 并与几种相关的基准方法和 SOTA (state-of-the-art) 方法进行对比. 其中 Ribeiro 等人^[8]以及 Wong 等人^[21]将多标记问题视作多个二分类问题, 他们所提出的方法作为基准方法; Yang 等人^[16]设计了一种基于多视图和多尺度的深度神经网络, Nejedly 等人^[40]提出了一种混合的损失函数, 即二元交叉熵、自定义挑战损失和自定义稀疏损失混合, Hwang 等人^[28]设计了一个 ResNet 和 DenseNet 级联的网络用于优化多标记 ECG 分类问题, 后 3 个方法作为 SOTA 方法.

从表 2 (加粗数据表示最优性能结果) 可以看出, 本文所提出的 BPNL 方法在所有评估指标上均取得了最佳的性能表现. 具体而言, 相较于基准方法, 本文的 BPNL 方法在 3 个指标上都有非常显著的提升, 如在 Macro $F1$ 和 Kappa 评价指标上, 有超过 20 个百分点以上的提升. 这表明简单将多标记分类问题视作多个二分类问题存在局限性. 相较于 SOTA 方法, 本文方法在 3 个评价指标上依然一致取得了最佳结果. 具体而言, 与 ResU_Dense^[28]相比, Macro $F1$ 提高了 1.43%, AUPRC 提高了 1.61%, Kappa 提高了 1.52%. 尽管 SOTA 方法或采取了损失函数混合或改造神经网络的策略, 但却忽视了多标记 ECG 中固有的正负标记不平衡问题, 而本文的方法针对该问题提出了有

效的解决方案,故取得了更优的结果. 综上, 这些结果均表明了 BPNL 损失函数在处理多标记 ECG 数据中的正负标记不平衡问题时,可有效地提升模型的分类性能.

表 2 不同方法在 PhysioNet Challenge 2021 数据集上性能比较 (%)

Method	Macro F1	AUPRC	Kappa
DNN_ECG ^[8]	42.30	27.00	39.90
GBTE_ECG ^[21]	42.80	28.40	41.20
MVMS_ECG ^[16]	54.10	36.30	52.30
RCAM_ECG ^[40]	56.80	38.70	54.80
ResU_Dense ^[28]	61.50	43.60	60.10
BPNL	62.93	45.21	61.62

此外, 为了验证本文所提方法在跨数据集场景下的泛化性能, 与 ResU_Dense^[28]的设置相同, 下文实验从 PhysioNet Challenge 2021 数据集中挑选两个子数据集 G12EC 和 Chapman-Shaoxing 分别作为测试数据集进行验证. 具体而言, 实验采用交替测试的方式: 当 G12EC 被用作测试数据集时, 剩余数据集作为训练集; 类似地, 当 Chapman-Shaoxing 被用作测试数据集时, 其余数据集作为训练集. 通过这种设置, 以更全面地评估本文方法在处理跨数据集任务时的适应性.

表 3 展示了本文所提出的 BPNL 方法与 DNN_ECG^[8]、ResU_Dense^[28]、DNN_CAM^[41]、ALWR_ECG^[42]、CNN_RBA^[43]、SLLC^[44]的方法在 G12EC 和 Chapman-Shaoxing 测试数据集上的对比实验结果. 可以看出 BPNL 方法在跨数据集任务中的表现仍然优异, 在 G12EC 数据集上, Macro AP 和 Macro F1 指标分别达到了 49.20% 和 36.20%; 而在 Chapman-Shaoxing 数据集上, Macro AP 和 Macro F1 分别为 65.90% 和 35.30%, 均取得了最佳性能. 相较于 ResU_Dense^[28]而言, 本文方法在 G12EC 数据集上的 Macro AP 和 Macro F1 分别提高了 1.90% 和 1.10%; 在 Chapman-Shaoxing 数据集上, Macro AP 和 Macro F1 分别提升了 2.10% 和 0.70%. 这些实验结果表明, 尽管两个不同测试数据集的来源 (分别来自美洲和亚洲) 和正负标记不平衡度均有所差异, 本文方法依然在跨数据集场景下取得了当下最优的性能表现, 验证了其良好的适应性.

表 3 不同方法在 G12EC 和 Chapman-Shaoxing 数据集上性能比较 (%)

Method	G12EC		Chapman-Shaoxing	
	Macro AP	Macro F1	Macro AP	Macro F1
DNN_CAM ^[41]	16.30	13.00	20.20	11.90
ALWR_ECG ^[42]	31.50	22.60	37.80	22.60
DNN_ECG ^[8]	29.30	20.30	43.00	34.00
CNN_RBA ^[43]	27.50	20.60	39.10	21.20
SLLC ^[44]	36.90	28.80	45.90	27.80
ResU_Dense ^[28]	47.30	35.10	63.80	34.60
BPNL	49.20	36.20	65.90	35.30

3.5 不同损失函数比较

本节实验将本文提出的 BPNL 损失函数与其他常用于缓解多标记不平衡问题的损失函数进行比较, 以进一步展现其优势. 具体而言, 实验涉及的损失函数包括 BCE、Focal^[45]和 ASY^[46]这 3 个常用的损失函数, 其中 BCE 损失函数作为基准方法, 而 Focal 和 ASY 损失函数则为正负样本分配不同的权重以应对标记不平衡问题, 其中 Focal 损失函数包括 1 个需调节的超参数, ASY 损失函数则包括 3 个需要调节的超参数.

如表 4 所示, 实验结果表明使用 BCE 损失函数训练时, 模型性能最差, 验证了 BCE 难以解决不平衡问题. 而本文提出的 BPNL 损失函数在所有评估指标上均表现最佳. 具体而言, BPNL 损失函数较 BCE 损失函数在 Macro F1 指标上提升了 1.43%, 在 AUPRC 指标上提升了 1.61%, 在 Kappa 指标上, 提升了 1.46%. 由于 Focal 和 ASY 损

失函数都包含了需要调节的超参数, 因而会付出额外的训练代价, 即需要多轮的交叉验证来选择最优的超参数. 综上所述, 与 BCE 损失函数相比, BPNL 损失函数训练代价与之相当, 但性能表现明显更加优异, 与 Focal 和 ASY 损失函数相比, BPNL 损失函数性能小幅胜出, 且训练代价明显小于二者.

表 4 在 PhysioNet Challenge 2021 数据集上不同损失函数的性能指标对比 (%)

Method	Macro F1	AUPRC	Kappa
BCE	61.50	43.60	60.10
Focal	62.31	44.24	60.93
ASY	62.73	44.58	61.36
BPNL	62.93	45.21	61.56

此外, 本节还展示了分别采用 BCE 和 BPNL 损失函数在 PhysioNet Challenge 2021 数据集上训练 35 轮的 Macro F1 曲线变化图. 如图 4 所示, 横坐标表示训练轮数, 纵坐标表示模型 Macro F1 性能指标, 可以看出使用 BPNL 损失函数时, 模型 Macro F1 值在整个训练过程中始终都高于采用 BCE 损失函数训练的模型. 特别地, Macro F1 值在第 26 轮有一个较为明显的提升, 这是因为在第 26 轮采用了阶梯式衰减策略, 使学习率逐步衰减的同时更精细地调整参数, 从而进一步提升了模型的性能.




图 4 使用 BPNL 和 BCE 损失函数时 Macro F1 值随训练轮数变化的曲线图

最后, 本节给出了间隔 (margin) 随训练轮次 (epoch) 变化的曲线, 如图 5 所示, 可以看出, 间隔随着训练轮次的增加不断变大, 意味着随着训练的进行, 正负标记的判别性也在逐渐增强. 注意到, 间隔值在第 26 轮有较为明显的提升, 与 Macro F1 曲线变化图观察到的现象一致. 这是因为在第 26 轮采用了阶梯式衰减策略.




图 5 间隔随训练轮次变化的曲线图

3.6 收敛性和运行时间

本节展示了 BPNL 损失函数的收敛性及运行时间. 由于本文采用的是深度神经网络, 而深度神经网络严格的

收敛性证明至今仍具有很大挑战性, 因而此处提供训练过程中损失函数变化的曲线图以直观地描述其收敛性. 如图 6 所示, 横坐标表示训练轮数, 纵坐标表示训练过程中的损失值. 可以看出, 曲线在第 26 轮后因 step decay 学习策略的应用, 下降速率发生显著变化, 并最终在 35 轮后趋于收敛.




图 6 PhysioNet Challenge 2021 数据集训练轮数随 Loss 变化曲线

此外, 本节还给出了不同损失函数训练 1 个 epoch 的运行时间比较. 如表 5 所示, 使用本文所提出 BPNL 损失函数与其他 3 个损失函数训练 1 个 epoch 的运行时间相当. 这表明本文提出的每次仅推开一对标记的优化策略所导出的 BPNL 损失函数并未给训练优化带来额外负担, 不会产生任何额外的时间开销.

表 5 不同损失函数训练 1 个 epoch 的时间及超参数个数

统计项	BCE	Focal	ASY	BPNL
运行时间	5 min 41 s	5 min 40 s	5 min 41 s	5 min 39 s
超参数个数	0	1	3	1

3.7 TSR 方法可解释性分析

为验证本文引入的 TSR 方法在解释 ECG 异常方面的合理性, 本节从 PhysioNet Challenge 2021 数据集中选取了一名患者的 ECG 数据作为样例展示. 该患者的 12 导联 ECG 如图 7 所示, 医学专家标注其同时存在心房颤动和 ST 段下降.




图 7 诊断为心房颤动和 ST 段压低的患者临床 12 导联心电图

此处将该 10 s 心电信号按 R 波划分为多个心拍周期, 每个周期约 600 个时间戳, 并输入以本文的 BPNL 方法作为损失函数训练的模型中, 最后用 TSR 方法生成了不同心拍周期的疾病类型热力图, 如图 8 和图 9 所示. 横坐标表示时间戳, 纵坐标表示 12 导联通道. 特征重要性由颜色梯度量化, 取值范围为 0–1: 值越接近 1 (黄色), 表示模

型判定该特征越重要; 值越接近 0 (蓝色), 表示模型判定该特征越不重要。

在图 8 中, 黄色区域主要集中在 QRS 波和颤动波附近, 尤以 V1 导联最为明显。这与心房颤动的诊断标准一致: 即正常 P 波消失, 代以大小不一、形态各异的颤动波, 通常以 V1 导联最为显著。在图 9 中, 黄色区域主要出现在 V1 和 V4 导联的 ST 段, 且呈现出 ST 段压低特征: 即 ST 段水平型或下斜型下移超过 0.1 mV, 与 ST 下降的诊断标准一致。可视化结果进一步验证了由 TSR 方法生成的热力图不仅能够准确关联模型认为重要的心跳区域与诊断类别, 还能在特定导联区域内进行定位, 反映出心脏不同部位的健康状况。这为临床医生提供了可靠的诊断辅助工具, 帮助其更精准地判断患者的病情, 从而有效减轻医生的临床诊断负担。




图 8 诊断为心房颤动的 12 导联心电图模型可解释性图

4 总 结

ECG 的自动分类可辅助医生诊断, 在临床研究中具有重要的意义。本文聚焦于多标记 ECG 分类任务, 主要解决了正负标记不平衡问题以及模型的可解释性问题。针对前一问题, 本文提出了每次仅选择一对正负标记进行优化的策略, 并由此导出一个全新的损失函数 BPNL, 梯度分析和在标准 ECG 数据集上的实验均验证了 BPNL 在解决正负标记不平衡问题时的有效性。针对后一问题, 本文从时间域和空间域两个维度同时考虑特征的重要性, 并引

入了 TSR 方法以帮助定位疾病并解释诊断依据. 在患者真实 ECG 数据上的热力图分析验证了 TSR 方法在解释 ECG 异常时的合理性. 未来工作拟进一步探索 ECG 异常的多标记层次化自动分类, 如 BBB 心律失常可进一步细分为左束支传导异常 (LBBB) 以及右束支传导异常 (RBBB), 以实现更精细、更准确的临床诊断.




图 9 诊断为 ST 段下降的 12 导联心电图模型可解释性图

References

[1] Mensah GA, Roth GA, Fuster V. The global burden of cardiovascular diseases and risk factors: 2020 and beyond. *Journal of the American College of Cardiology*, 2019, 74(20): 2529–2532. [doi: 10.1016/j.jacc.2019.10.009]

[2] Siontis KC, Noseworthy PA, Attia ZI, Friedman PA. Artificial intelligence-enhanced electrocardiography in cardiovascular disease management. *Nature Reviews Cardiology*, 2021, 18(7): 465–478. [doi: 10.1038/s41569-020-00503-2]

[3] Sarki R, Ahmed K, Wang H, Zhang YC. Automated detection of mild and multi-class diabetic eye diseases using deep learning. *Health Information Science and Systems*, 2020, 8(1): 32. [doi: 10.1007/s13755-020-00125-5]

[4] He JY, Rong J, Sun L, Wang H, Zhang YC, Ma JG. A framework for cardiac arrhythmia detection from IoT-based ECGs. *World Wide Web*, 2020, 23(5): 2835–2850. [doi: 10.1007/s11280-019-00776-9]

[5] Pandey D, Yin XX, Wang H, Zhang YC. Accurate vessel segmentation using maximum entropy incorporating line detection and phase-preserving denoising. *Computer Vision and Image Understanding*, 2017, 155: 162–172. [doi: 10.1016/j.cviu.2016.12.005]

- [6] Houssein EH, Kilany M, Hassanien AE. ECG signals classification: A review. *Int'l Journal of Intelligent Engineering Informatics*, 2017, 5(4): 376–396. [doi: [10.1504/IJIEI.2017.087944](https://doi.org/10.1504/IJIEI.2017.087944)]
- [7] Goovaerts G, Padhy S, Vandenberk B, Varon C, Willems R, van Huffel S. A machine-learning approach for detection and quantification of QRS fragmentation. *IEEE Journal of Biomedical and Health Informatics*, 2019, 23(5): 1980–1989. [doi: [10.1109/JBHI.2018.2878492](https://doi.org/10.1109/JBHI.2018.2878492)]
- [8] Ribeiro AH, Ribeiro MH, Paixão GMM, Oliveira DM, Gomes PR, Canazart JA, Ferreira MPS, Andersson CR, Macfarlane PW, Meira Jr W, Schön TB, Ribeiro ALP. Automatic diagnosis of the 12-lead ECG using a deep neural network. *Nature Communications*, 2020, 11(1): 1760. [doi: [10.1038/s41467-020-15432-4](https://doi.org/10.1038/s41467-020-15432-4)]
- [9] Ebrahimi Z, Loni M, Daneshlab M, Gharehbaghi A. A review on deep learning methods for ECG arrhythmia classification. *Expert Systems with Applications: X*, 2020, 7: 100033. [doi: [10.1016/j.eswx.2020.100033](https://doi.org/10.1016/j.eswx.2020.100033)]
- [10] Liu XW, Wang H, Li ZJ, Qin L. Deep learning in ECG diagnosis: A review. *Knowledge-based Systems*, 2021, 227: 107187. [doi: [10.1016/j.knsys.2021.107187](https://doi.org/10.1016/j.knsys.2021.107187)]
- [11] Peng XD, Pan CC, Ke ZJ, Zhu HQ, Zhou X. Classification method for electrocardiograph signals based on parallel architecture model and spatial-temporal attention mechanism. *Journal of Zhejiang University*, 2022, 56(10): 1912–1923 (in Chinese with English abstract). [doi: [10.3785/j.issn.1008-973X.2022.10.003](https://doi.org/10.3785/j.issn.1008-973X.2022.10.003)]
- [12] Lü H, Jiang MF, Li Y, Zhang JC, Wang ZK. Research on arrhythmia classification by using convolutional neural network with mixed time-frequency domain features. *Acta Electronica Sinica*, 2023, 51(3): 701–711 (in Chinese with English abstract). [doi: [10.12263/DZXB.20211181](https://doi.org/10.12263/DZXB.20211181)]
- [13] Huang SJ, Zhou ZH. Multi-label learning by exploiting label correlations locally. In: *Proc. of the 26th AAAI Conf. on Artificial Intelligence*. Toronto: AAAI, 2021. 949–955. [doi: [10.1609/aaai.v26i1.8287](https://doi.org/10.1609/aaai.v26i1.8287)]
- [14] Zhu Y, Kwok JT, Zhou ZH. Multi-label learning with global and local label correlation. *IEEE Trans. on Knowledge and Data Engineering*, 2018, 30(6): 1081–1094. [doi: [10.1109/TKDE.2017.2785795](https://doi.org/10.1109/TKDE.2017.2785795)]
- [15] Luo CS, Jiang HX, Li QC, Rao NN. Multi-label classification of abnormalities in 12-lead ECG using 1D CNN and LSTM. In: *Proc. of the 1st Int'l Workshop and the 8th Joint Int'l Workshop on Machine Learning and Medical Engineering for Cardiovascular Health and Intravascular Imaging and Computer Assisted Stenting*. Shenzhen: Springer, 2019. 55–63. [doi: [10.1007/978-3-030-33327-0_7](https://doi.org/10.1007/978-3-030-33327-0_7)]
- [16] Yang SX, Lian C, Zeng ZG, Xu BR, Zang JB, Zhang ZD. A multi-view multi-scale neural network for multi-label ECG classification. *IEEE Trans. on Emerging Topics in Computational Intelligence*, 2023, 7(3): 648–660. [doi: [10.1109/TETCI.2023.3235374](https://doi.org/10.1109/TETCI.2023.3235374)]
- [17] Zhou DH, Chen PF, Wang Q, Chen GY, Heng PA. Acknowledging the unknown for multi-label learning with single positive labels. In: *Proc. of the 17th European Conf. on Computer Vision*. Tel Aviv: Springer, 2022. 423–440. [doi: [10.1007/978-3-031-20053-3_25](https://doi.org/10.1007/978-3-031-20053-3_25)]
- [18] Guermur Y. VC theory of large margin multi-category classifiers. *The Journal of Machine Learning Research*, 2007, 8: 2551–2594.
- [19] Selvaraju RR, Cogswell M, Das A, Vedantam R, Parikh D, Batra D. Grad-CAM: Visual explanations from deep networks via gradient-based localization. In: *Proc. of the 2017 IEEE Int'l Conf. on Computer Vision*. Venice: IEEE, 2017. 618–626. [doi: [10.1109/ICCV.2017.74](https://doi.org/10.1109/ICCV.2017.74)]
- [20] Ismail AA, Gunady M, Corrada Bravo H, Feizi S. Benchmarking deep learning interpretability in time series predictions. In: *Proc. of the 34th Int'l Conf. on Neural Information Processing Systems*. Vancouver: Curran Associates Inc., 2020. 540.
- [21] Wong AW, Sun WJ, Kalmady SV, Kaul P, Hindle A. Multilabel 12-lead electrocardiogram classification using gradient boosting tree ensemble. In: *Proc. of the 2020 Computing in Cardiology*. Rimini: IEEE, 2020. 1–4. [doi: [10.22489/CinC.2020.128](https://doi.org/10.22489/CinC.2020.128)]
- [22] Jiang ZH, Almeida TP, Schlindwein FS, Ng GA, Zhou HY, Li X. Diagnostic of multiple cardiac disorders from 12-lead ECGs using graph convolutional network based multi-label classification. In: *Proc. of the 2020 Computing in Cardiology*. Rimini: IEEE, 2020. 1–4. [doi: [10.22489/CinC.2020.135](https://doi.org/10.22489/CinC.2020.135)]
- [23] Ge ZY, Jiang XH, Tong Z, Feng PP, Zhou B, Xu ML, Wang ZM, Pang YW. Multi-label correlation guided feature fusion network for abnormal ECG diagnosis. *Knowledge-based Systems*, 2021, 233: 107508. [doi: [10.1016/j.knsys.2021.107508](https://doi.org/10.1016/j.knsys.2021.107508)]
- [24] Du N, Cao Q, Yu L, Liu N, Zhong EH, Liu ZZ, Shen Y, Chen K. FM-ECG: A fine-grained multi-label framework for ECG image classification. *Information Sciences*, 2021, 549: 164–177. [doi: [10.1016/j.ins.2020.10.014](https://doi.org/10.1016/j.ins.2020.10.014)]
- [25] Li YW, Zhang ZM, Zhou F, Xing YT, Li JQ, Liu CY. Multi-label classification of arrhythmia for long-term electrocardiogram signals with feature learning. *IEEE Trans. on Instrumentation and Measurement*, 2021, 70: 2512611. [doi: [10.1109/TIM.2021.3077667](https://doi.org/10.1109/TIM.2021.3077667)]
- [26] Ran SL, Li X, Zhao BZ, Jiang YN, Yang XY, Cheng C. Label correlation embedding guided network for multi-label ECG arrhythmia diagnosis. *Knowledge-based Systems*, 2023, 270: 110545. [doi: [10.1016/j.knsys.2023.110545](https://doi.org/10.1016/j.knsys.2023.110545)]
- [27] Qin YZ, Sun L, Chen H, Yang WM, Zhang WQ, Fei JT, Wang GJ. MVKT-ECG: Efficient single-lead ECG classification for multi-label arrhythmia by multi-view knowledge transferring. *Computers in Biology and Medicine*, 2023, 166: 107503. [doi: [10.1016/j.combiomed.2023.107503](https://doi.org/10.1016/j.combiomed.2023.107503)]

- [28] Hwang S, Cha J, Heo J, Cho S, Park Y. Multi-label ECG abnormality classification using a combined ResNet-DenseNet architecture with ResU blocks. In: Proc. of the 2023 IEEE EMBS Special Topic Conf. on Data Science and Engineering in Healthcare, Medicine and Biology. IEEE, 2023. 111–112. [doi: [10.1109/IEEECONF58974.2023.10404234](https://doi.org/10.1109/IEEECONF58974.2023.10404234)]
- [29] Zhou FY, Chen LZ. Leadwise clustering multi-branch network for multi-label ECG classification. Medical Engineering & Physics, 2024, 130: 104196. [doi: [10.1016/j.medengphy.2024.104196](https://doi.org/10.1016/j.medengphy.2024.104196)]
- [30] Huang W, Wang N, Feng PP, Wang HY, Wang ZM, Zhou B. A multi-resolution mutual learning network for multi-label ECG classification. In: Proc. of the 2024 IEEE Int'l Conf. on Bioinformatics and Biomedicine. Lisbon: IEEE, 2024. 3303–3306. [doi: [10.1109/BIBM62325.2024.10822741](https://doi.org/10.1109/BIBM62325.2024.10822741)]
- [31] Sadeghi A, Hajati F, Rezaee A, Sadeghi M, Argha A, Alinejad-Rokny H. 3DECG-Net: ECG fusion network for multi-label cardiac arrhythmia detection. Computers in Biology and Medicine, 2024, 182: 109126. [doi: [10.1016/j.combiomed.2024.109126](https://doi.org/10.1016/j.combiomed.2024.109126)]
- [32] Hwang S, Cha J, Heo J, Cho S, Park Y. Multi-label abnormality classification from 12-lead ECG using a 2D residual U-Net. In: Proc. of the 2024 IEEE Int'l Conf. on Acoustics, Speech and Signal Processing (ICASSP). Seoul: IEEE, 2024. 2265–2269. [doi: [10.1109/ICASSP48485.2024.10448259](https://doi.org/10.1109/ICASSP48485.2024.10448259)]
- [33] Li Y, Zeng JB, Shan SG. Learning representations for facial actions from unlabeled videos. IEEE Trans. on Pattern Analysis and Machine Intelligence, 2022, 44(1): 302–317. [doi: [10.1109/TPAMI.2020.3011063](https://doi.org/10.1109/TPAMI.2020.3011063)]
- [34] Alday EAP, Gu AN, Shah AJ, Robichaux C, Ian Wong AK, Liu CY, Liu FF, Bahrami Rad A, Elola A, Seyedi S, Li Q, Sharma A, Clifford GD, Reyna MA. Classification of 12-lead ECGs: The PhysioNet/computing in cardiology challenge 2020. Physiological Measurement, 2020, 41(12): 124003. [doi: [10.1088/1361-6579/abc960](https://doi.org/10.1088/1361-6579/abc960)]
- [35] Cabello-Solorzano K, Ortigosa de Araujo I, Peña M, Correia L, Tallón-Ballesteros AJ. The impact of data normalization on the accuracy of machine learning algorithms: A comparative analysis. In: Proc. of the 18th Int'l Conf. on Soft Computing Models in Industrial and Environmental Applications. Salamanca: Springer, 2023. 344–353. [doi: [10.1007/978-3-031-42536-3_33](https://doi.org/10.1007/978-3-031-42536-3_33)]
- [36] Strodthoff N, Wagner P, Schaeffter T, Samek W. Deep learning for ECG analysis: Benchmarks and insights from PTB-XL. IEEE Journal of Biomedical and Health Informatics, 2021, 25(5): 1519–1528. [doi: [10.1109/JBHI.2020.3022989](https://doi.org/10.1109/JBHI.2020.3022989)]
- [37] Schapire RE, Singer Y. BoostTexter: A boosting-based system for text categorization. Machine Learning, 2000, 39(2): 135–168. [doi: [10.1023/A:1007649029923](https://doi.org/10.1023/A:1007649029923)]
- [38] Ge R, Kakade SM, Kidambi R, Netrapalli P. The step decay schedule: A near optimal, geometrically decaying learning rate procedure for least squares. In: Proc. of the 33rd Int'l Conf. on Neural Information Processing Systems. Vancouver: Curran Associates Inc., 2019. 1341.
- [39] Paszke A, Gross S, Massa F, Lerer A, Bradbury J, Chanan G, Killeen T, Lin ZM, Gimelshein N, Antiga L, Desmaison A, Köpf A, Yang E, DeVito Z, Raison M, Tejani A, Chilamkurthy S, Steiner B, Fang L, Bai JJ, Chintala S. PyTorch: An imperative style, high-performance deep learning library. In: Proc. of the 33rd Int'l Conf. on Neural Information Processing Systems. Vancouver: Curran Associates Inc., 2019. 721.
- [40] Nejedly P, Ivora A, Smisek R, Viscor I, Koscova Z, Jurak P, Plesinger F. Classification of ECG using ensemble of residual CNNs with attention mechanism. In: Proc. of the 2021 Computing in Cardiology (CinC). Brno: IEEE, 2021. 1–4. [doi: [10.23919/CinC53138.2021.9662723](https://doi.org/10.23919/CinC53138.2021.9662723)]
- [41] Goodfellow SD, Shubin D, Greer RW, Nagaraj S, McLean C, Dixon W, Goodwin AJ, Assadi A, Jegatheeswaran A, Laussen PC, Mazwi M, Eytan D. Rhythm classification of 12-lead ECGs using deep neural networks and class-activation maps for improved explainability. In: Proc. of the 2020 Computing in Cardiology. Rimini: IEEE, 2020. 1–4. [doi: [10.22489/CinC.2020.353](https://doi.org/10.22489/CinC.2020.353)]
- [42] Zhao ZB, Fang H, Relton SD, Yan RQ, Liu YH, Li ZJ, Qin J, Wong DC. Adaptive lead weighted ResNet trained with different duration signals for classifying 12-lead ECGs. In: Proc. of the 2020 Computing in Cardiology. Rimini: IEEE, 2020. 1–4. [doi: [10.22489/CinC.2020.112](https://doi.org/10.22489/CinC.2020.112)]
- [43] Singstad BJ, Tronstad C. Convolutional neural network and rule-based algorithms for classifying 12-lead ECGs. In: Proc. of the 2020 Computing in Cardiology. Rimini: IEEE, 2020. 1–4. [doi: [10.22489/CinC.2020.227](https://doi.org/10.22489/CinC.2020.227)]
- [44] Vázquez CG, Breuss A, Gnarr O, Portmann J, Madaffari A, Da Poian G. Label noise and self-learning label correction in cardiac abnormalities classification. Physiological Measurement, 2022, 43(9): 094001. [doi: [10.1088/1361-6579/ac89cb](https://doi.org/10.1088/1361-6579/ac89cb)]
- [45] Lin TY, Goyal P, Girshick R, He KM, Dollár P. Focal loss for dense object detection. In: Proc. of the 2017 IEEE Int'l Conf. on Computer Vision. Venice: IEEE, 2017. 2999–3007. [doi: [10.1109/ICCV.2017.324](https://doi.org/10.1109/ICCV.2017.324)]
- [46] Ridnik T, Ben-Baruch E, Zamir N, Noy A, Friedman I, Protter M, Zelnik-Manor L. Asymmetric loss for multi-label classification. In: Proc. of the 2021 IEEE/CVF Int'l Conf. on Computer Vision. Montreal: IEEE, 2021. 82–91. [doi: [10.1109/ICCV48922.2021.00015](https://doi.org/10.1109/ICCV48922.2021.00015)]

附中文参考文献

- [11] 彭向东, 潘从成, 柯泽浚, 朱华强, 周肖. 基于并行架构和时空注意力机制的心电分类方法. 浙江大学学报, 2022, 56(10): 1912–1923. [doi: 10.3785/j.issn.1008-973X.2022.10.003]
- [12] 吕杭, 蒋明峰, 李杨, 张鞠成, 王志康. 基于混合时频域特征的卷积神经网络心律失常分类方法的研究. 电子学报, 2023, 51(3): 701–711. [doi: 10.12263/DZXB.20211181]

附录 A

首先, 本节给出 $\log \sum \exp$ 函数可作为 $\max$ 函数近似的数学推导. 令 $\mathbf{x} = (x_1, x_2, \dots, x_k)$, 其中 $x_{\max} = \max(x_1, x_2, \dots, x_k)$, 易得公式 (A1):

$$e^{x_{\max}} < \sum_{i=1}^k e^{x_i} \leq \sum_{i=1}^k e^{x_{\max}} \quad (\text{A1})$$

对公式 (A1) 的每一个不等式两边同时取对数, 可得公式 (A2):

$$x_{\max} < \log \sum_{i=1}^k e^{x_i} \leq \log \sum_{i=1}^k e^{x_{\max}} = x_{\max} + \log k \quad (\text{A2})$$

由 $\log \sum \exp$ 函数的定义可知, $\log \sum \exp(\mathbf{x}) = \log \sum_{i=1}^k e^{x_i}$, 即可得 $\log \sum \exp$ 函数是 $\max$ 函数的近似.

然后, 本节给出正文公式 (9) 的推导. 首先易得 BCE 损失中两部分的导数分别如公式 (A3) 与公式 (A4) 所示:

$$\begin{cases} \frac{\partial \mathcal{L}_{\text{BCE}}}{\partial g} = \frac{\partial}{\partial g} (-\log g) = -\frac{1}{g}, & y_{ij} = 1 \\ \frac{\partial \mathcal{L}_{\text{BCE}}}{\partial g} = \frac{\partial}{\partial g} (-\log(1-g)) = \frac{1}{1-g}, & y_{ij} = 0 \end{cases} \quad (\text{A3})$$

$$\frac{\partial g}{\partial h} = \frac{\partial}{\partial h} \left(\frac{1}{1+e^{-h}} \right) = \frac{e^{-h}}{(1+e^{-h})^2} \quad (\text{A4})$$

然后结合公式 (A3) 与公式 (A4), 由链式法则, 则可得公式 (9) 的结果.

$$\begin{cases} \frac{\partial \mathcal{L}_{\text{BCE}}}{\partial h} = \frac{\partial \mathcal{L}_{\text{BCE}}}{\partial g} \frac{\partial g}{\partial h} = -\frac{1}{g} \cdot \frac{e^{-h}}{(1+e^{-h})^2} = \frac{-e^{-h}}{1+e^{-h}}, & y_{ij} = 1 \\ \frac{\partial \mathcal{L}_{\text{BCE}}}{\partial h} = \frac{\partial \mathcal{L}_{\text{BCE}}}{\partial g} \frac{\partial g}{\partial h} = \frac{1}{1-g} \cdot \frac{e^{-h}}{(1+e^{-h})^2} = \frac{1}{1+e^{-h}} = \frac{e^h}{1+e^h}, & y_{ij} = 0 \end{cases} \quad (\text{A5})$$

作者简介

李想, 博士, 讲师, 主要研究领域为机器学习, 多标记学习, 多视图学习.

操思源, 硕士生, 主要研究领域为机器学习, 心电图异常分类.

陈松灿, 博士, 教授, 博士生导师, CCF 高级会员, 主要研究领域为模式识别, 机器学习.