

基于梯度幅值方向调整的心电信号多任务分类算法

张雪, 田岚, 曾鸣, 刘俊晖, 宗绍国

引用本文

张雪, 田岚, 曾鸣, 刘俊晖, 宗绍国. 基于梯度幅值方向调整的心电信号多任务分类算法[J]. 计算机科学, 2024, 51(12): 174-180.

ZHANG Xue, TIAN Lan, ZENG Ming, LIU Junhui, ZONG Shaoguo. [Multitask Classification Algorithm of ECG Signals Based on Radient Magnitude Direction Adjustment](#) [J]. Computer Science, 2024, 51(12): 174-180.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于多任务学习的复杂城市遥感图像道路提取](#)

Road Extraction from Complex Urban Remote Sensing Images Based on Multi-task Learning
计算机科学, 2024, 51(11A): 240300095-8. <https://doi.org/10.11896/jsjcx.240300095>

[基于位置交互感知网络的多任务情绪原因对抽取方法](#)

Multi-task Emotion-Cause Pair Extraction Method Based on Position-aware Interaction Network
计算机科学, 2024, 51(11A): 231000086-9. <https://doi.org/10.11896/jsjcx.231000086>

[对话场景下的情感引导问题生成模型](#)

Emotion Elicited Question Generation Model in Dialogue Scenarios
计算机科学, 2024, 51(11): 265-272. <https://doi.org/10.11896/jsjcx.231000002>

[基于AU的多任务学生情绪识别方法研究](#)

Study on Multi-task Student Emotion Recognition Methods Based on Facial Action Units
计算机科学, 2024, 51(10): 105-111. <https://doi.org/10.11896/jsjcx.240300059>

[基于多模态视频分类任务的模态融合策略研究](#)

Modality Fusion Strategy Research Based on Multimodal Video Classification Task
计算机科学, 2024, 51(6A): 230300212-5. <https://doi.org/10.11896/jsjcx.230300212>

基于梯度幅值方向调整的心电信号多任务分类算法

张雪¹ 田岚¹ 曾鸣¹ 刘俊晖¹ 宗绍国²

¹ 山东大学微电子学院 济南 250101

² 山东省厚德测控技术股份有限公司 济南 250000

(202212332@mail.sdu.edu.cn)

摘要 心血管疾病对人类生命健康安全的威胁日益严重,通过心电信号可进行相关疾病的诊断分类。现有的心电分类算法大多采用单任务学习模型,无法综合利用多个任务中的互补特征,而多任务学习模型可同时学习多个相关任务,共享相关任务特征,有助于提高多任务的分类表现。结合深度学习和多任务学习两种方法,提出了一种基于损失优化的心电信号多任务分类算法,将心电信号的多分类任务分解为多个二分类任务,从任务梯度的幅值和方向两方面进行损失优化,避免手动设置任务损失权重以及任务损失相互抵消而产生的负迁移,从而提升心电信号多分类任务的性能。在 PTB-XL 数据库上将心电信号 23 类分类任务分解为 23 个二分类任务来评估所提出的算法。实验结果表明,所提算法的宏观曲线下平均面积(AUC)达到 0.950,准确率达到 96.50%,基于标签的宏观 F1 分数达到 0.583,基于样本的 F1 分数达到 0.777。与单任务学习算法相比,所提算法在心电信号的多分类方面表现出良好的性能。

关键词: 心电信号分类;多任务学习;损失优化

中图分类号 TP391.7

Multitask Classification Algorithm of ECG Signals Based on Radiant Magnitude Direction Adjustment

ZHANG Xue¹, TIAN Lan¹, ZENG Ming¹, LIU Junhui¹ and ZONG Shaoguo²

¹ School of Microelectronics, Shandong University, Jinan 250101, China

² Shandong Houde Measurement and Control Technology Co., LTD, Jinan 250000, China

Abstract Cardiovascular diseases are posing more and more serious threats to human health and safety. ECG signals can be used to diagnose and classify related diseases. Most existing ECG classification algorithms adopt single-task learning model, which can not make comprehensive use of complementary features in multiple tasks. However, multi-task learning model can learn multiple related tasks at the same time, share related task features, and help improve the classification performance of multiple tasks. Combining deep learning and multi-task learning, a multi-task classification algorithm for ECG signals based on loss optimization is proposed. The multi-classification task of ECG signals is decomposed into multiple binary classification tasks, and loss optimization is carried out from the aspects of the amplitude and direction of task gradient, so as to avoid the negative transfer caused by manual setting of task loss weights and the cancellation of task losses. The performance of ECG signal multi-classification task is improved. The model uses PTB-XL database to decompose 23 classification tasks into 23 binary classification tasks to evaluate the proposed algorithm. Experimental results show that the average area under the macro curve(AUC) reaches 0.950, the accuracy reaches 96.50%, the tag-based F1 score reaches 0.583, and the sample-based F1 score reaches 0.777. Compared with the single-task learning algorithm, the proposed algorithm shows good performance in the multi-classification of ECG signals.

Keywords ECG signal classification, Multi-task learning, Loss optimization

1 引言

据世界卫生组织统计,心血管疾病是世界范围内导致人类死亡的主要原因之一,全球每年有 30% 以上的死亡是由

心血管疾病造成的^[1]。心电图作为记录心脏电生理活动的生物医学信号,具有无创性和实时性的优点,被广泛应用于医疗领域^[2],是房颤和心室早搏等心血管疾病检测的金标准之一^[3-4]。同一种心脏疾病在同一患者的不同生理阶段,其心电

到稿日期:2023-08-15 返修日期:2024-03-01

基金项目:山东省自然科学基金(ZR2021MF065, ZR2021ZD40)

This work was supported by the Natural Science Foundation of Shandong Province, China(ZR2021MF065, ZR2021ZD40).

通信作者:田岚(tianlan65@sdu.edu.cn)

特征存在一定的差异,在不同患者间差异则更大。对于医生而言,在有限的时间分析大量的心电图数据可能会引发疲劳,从而影响病情诊断^[2],造成医疗资源浪费。由此可见,研究心电信号的计算机辅助诊断算法,辅助医生对心脏疾病的诊断,具有极为重要的现实意义。

深度学习是近年来在人工智能领域流行的一种学习能力强大的数据分析技术^[5-6],可以自动从原始数据中提取隐藏特征,在一定程度上提高了分类的效率和准确率。例如:Acharya等^[7]使用9层卷积神经网络实现5种心律失常的自动诊断分类,在MIT-BIH数据库上得到了94.03%的准确率;Yildirim等^[8]设计了一维卷积神经网络模型来实现心电信号的17分类,总体识别准确率为91.33%;Ullah等^[9]提出了基于预训练的深度残差网络ResNet-18,在MIT-BIH数据库上的准确率达到了99.93%。

多任务学习(Multi-task Learning, MTL)^[10]是一种使用单一模型同时学习多个任务的方法,其通过共享相关任务之间的特征以及优化多个任务的损失函数的方法来提高任务的性能。这种方法能够克服任务样本较少的缺点^[11],增强模型的泛化能力^[12],克服深度学习数据需求量大和计算量大的弱点^[13]。当前,多任务学习模型主要应用在计算机视觉^[14]、自然语言处理^[15]、文本分类^[16]、机器翻译^[17]等领域。

在心电信号分类方面,多任务学习也有所应用^[18-20]。Ji等^[18]将心电数据分析问题分解为多个任务,提出了一种深度多任务学习方案,准确率相比原本的单任务学习提高了约5.1%。将多分类任务分解为多个二分类任务再采用多任务学习方法进行相应的建模,是一种新的多任务深度学习的应用方向。例如:Liu等^[19]将一个9分类的心电分类任务分解为9个二分类任务,提出了一种成本敏感的多任务深度学习方案,样本分类准确率达到63.30%。多任务学习网络模型能够充分挖掘疾病之间的关联信息,获得更准确的结果,在心电信号多分类领域具有研究和应用价值。

多任务学习模型的损失函数是由不同的特定于任务的损失函数组合形成的,在训练过程中,需要对模型的损失函数进行优化,谨慎地平衡各个任务,避免某个或某些任务的梯度占主导地位而导致学习偏移^[21]。心电分类的多任务学习中都没有对多任务损失进行精细调整,只是对不同任务损失进行求和,或者手动设置不同任务的损失权重进行求和。这样做可能会因为每个任务的梯度幅值不同而出现学习偏移。同时,手动设置不同任务的损失权重既费时又费力。此外,不同任务梯度的方向可能会相互抵消,导致任务负迁移^[22]。

为了解决上述问题,本文提出了一种基于梯度幅值方向调整(Gradient Magnitude Direction Adjustment, GMDA)的心电信号多任务分类算法。该算法将任务梯度的幅值调整和方向调整结合起来进行损失优化,通过调整任务损失权重自动调整梯度幅值,并调整任务梯度方向以避免任务负迁移。在PTB-XL心电数据库上对基于GMDA的多任务分类算法进行了评估,将心脏病23分类任务分解为23类疾病二分类任务。实验结果表明,与单任务学习算法相比,所提算法提高了心电信号多分类任务的性能。

2 本文方法

本文提出了一种梯度幅值方向调整(GMDA)方法,利用多任务深度学习实现心电信号多分类任务。多任务深度学习方法的设计包括两个方面:模型结构和损失优化。

2.1 模型结构

多任务深度学习模型通常采用硬参数共享架构,通过在所有任务之间共享特征提取网络的参数,再结合独立的各个任务的分类器来实现多任务学习的模型构建。本文选用硬参数共享结构实现模型的搭建,基于GMDA的多任务分类算法模型结构如图1所示,其由1个卷积块Conv Block、3个残差块Res Block、1个Head模块以及最后的23个由全连接层FC2和Sigmoid层组成的分类器构成,对应的详细参数如表1所列。

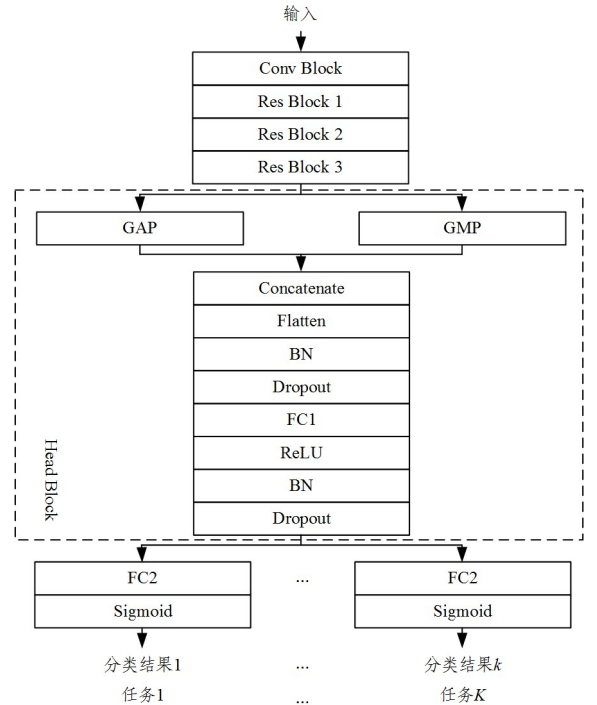


图1 基于GMDA的多任务分类模型结构示意图

Fig. 1 Structure diagram of multi-task classification model based on GMDA

表1 基于GMDA的多任务分类模型详细参数

Table 1 Detailed parameters of multi-task classification model based on GMDA

模块	类型	卷积核数量	卷积核大小	步长
Conv Block	Conv1d	128	7	1
Res Block 1	Conv1d	128	5	1
	Conv1d	128	3	1
Res Block 2	Conv1d	128	5	2
	Conv1d	128	3	1
Res Block 3	Conv1d	128	5	2
	Conv1d	128	3	1
Head Block	GAP/GMP	—	—	—
	Concatenate	—	—	—
	Flatten	—	—	—
	Dropout(0.25)	—	—	—
	FC1	128	—	—
	Dropout(0.5)	—	—	—
—	FC2	1	—	—
	Sigmoid	—	—	—

其中,卷积块、残差块和 Head 模块作为参数共享部分提取输入数据的共享特征。在 Head 模块中,连接层 (Concatenate) 沿着特征维度聚合全局平均池化层 (GAP) 和全局最大池化层 (GMP) 的输出,以保留数据的背景信息和边界信息。各个任务的输出部分由全连接层 FC2 和 Sigmoid 层组成。

2.2 损失优化

本文从任务损失梯度的幅值和方向两个方面着手进行研究,提出了一种梯度幅值方向调整 (GMDA) 优化方法,并通过实验测试模型的相关参数,确定最优的心电分类网络模型。

由于损失大小和学习速度可能因任务而异,因此,对损失直接求和不能很好地平衡多任务,甚至可能导致学习偏差。当不同任务学习的难易程度不同时,或者不同任务处于不同的学习阶段时,比如在任务 1 接近收敛时任务 2 仍然没训练好的情况下,固定的损失函数权重会限制对应任务的学习。更好的加权方式是根据学习阶段、任务难度或者不同任务的学习效果,动态调整任务损失权重。所提算法选用动态任务优先级 (Dynamic Task Prioritization, DTP)^[23] 的损失权重优化策略,这是一种以动态加权方式进行损失优化的方法,根据不同任务的学习效果自动调整任务损失权重从而调整梯度幅值。第 i 个任务的损失权重计算方法如式(1)所示:

$$\omega_i(t) = -(1 - e_i(t))^\gamma \log e_i(t) \quad (1)$$

其中, $e_i(t)$ 表示第 i 个任务在第 t 轮网络训练的性能指标,用来评价任务的学习效果; γ 为任务的聚焦参数,用来调整任务损失权重减小的速率。

任务的学习效果越不理想,性能指标 $e_i(t)$ 数值越小,网络模型分配给该任务的损失权重越大,这使得网络模型优先学习更困难的任务,从而平衡各任务之间学习程度的难易差别。动态加权后多任务网络模型的损失函数如式(2)所示:

$$L = \sum_{i=1}^K \omega_i(t) \cdot L_i \quad (2)$$

其中, $\omega_i(t)$ 表示任务 i 在第 t 轮的损失权重, L_i 表示任务 i 的损失, K 为所有任务的数量。这种方式可以根据每一个任务学习的阶段、难易程度或者效果来设置任务损失函数的权重,调整损失梯度的幅值,从而更好地实现各任务的学习平衡。

当多个任务梯度同时更新模型共享部分的参数时,由于梯度方向不同,可能会出现梯度方向冲突进而导致梯度相互抵消的情况,因此会出现任务的负迁移现象。为了避免任务间梯度冲突造成负迁移,所提算法中引入了投影冲突梯度 (Projecting Conflicting Gradients, PCGrad)^[24],从任务损失梯度方向来实现多任务学习的损失优化。设定一组 K 个任务 $T = \{T_1, T_2, \dots, T_K\}$,对每一个任务 T_i ,选取剩余任务中的一个任务 T_j ,计算两个任务梯度向量 \mathbf{g}_i 和 \mathbf{g}_j 之间的余弦相似度,如式(3)所示:

$$\cos(\theta) = \frac{\mathbf{g}_i \cdot \mathbf{g}_j}{\|\mathbf{g}_i\| \times \|\mathbf{g}_j\|} \quad (3)$$

若 $\cos(\theta) \geq 0$,则两个任务的梯度没有冲突,任务 T_i 和任务 T_j 保持各自的原有梯度进行更新训练。若 $\cos(\theta) < 0$,则两个任务的梯度相互冲突,通过将任务 T_i 的梯度 \mathbf{g}_i 投影到有冲突任务 T_j 的梯度 \mathbf{g}_j 的法向量平面上,将投影作为任务 T_i 的新梯度进行更新训练,避免任务梯度间的相互干扰,如式(4)所示:

$$\mathbf{g}_i = \mathbf{g}_i - \frac{\mathbf{g}_i \cdot \mathbf{g}_j}{\|\mathbf{g}_j\|^2} \mathbf{g}_j \quad (4)$$

3 实验与结果

本章描述了实验数据库和评价指标,并将所提算法与其他算法进行了比较。

3.1 数据库

将所提算法在 PTB-XL 心电数据库^[25]上进行实验测试。PTB-XL 心电数据库是临床 12 导联心电信号波形数据库,包括 18885 名患者的 21837 条 10s 长度的心电记录,采样频率为 100 Hz 和 500 Hz,其中女性患者占 48%,男性患者占 52%,年龄范围为 0~95 岁。每条心电记录可能对应多个注释标签,对于疾病诊断标签,PTB-XL 心电数据库提供了 5 个超类和 23 个子类的层次结构。由于 PTB-XL 心电数据库中疾病诊断标签的 5 个超类粒度过粗,不涉及具体疾病的诊断标签,因此实验数据样本选取含有 23 个疾病诊断子类标签的 100 Hz 心电信号数据样本共 21430 条。

在数据预处理阶段,对所选择的数据样本进行标准归一化处理。采用十折交叉验证的方法测试所提算法的准确性。PTB-XL 数据集被平均划分为 10 份,每份轮流用于测试,从剩余 9 份中随机选取一份用于验证,其余 8 份用于训练,最后计算 10 次实验评价指标的平均值作为最终结果。在验证和测试过程中,采用大小为 2.5s 且重叠 50% 的滑动窗口对每条数据样本进行切割分段,并将每条数据样本分段后的预测结果进行聚合得到 10s 的整条数据样本的预测分类结果,以提升模型的总体性能^[26]。

3.2 评价指标

由于 PTB-XL 心电数据库的数据具有不平衡性,因此本文使用基于标签的宏观平均曲线下面积 (Macro Area Under Curve, Macro AUC)、准确率 (Accuracy)、基于标签的宏观平均 F1 分数 (Macro F1_{label}) 和基于样本的 F1 分数 (F1_{exam}) 4 个分类评价指标来评估所提模型的心电信号分类性能。

受试者工作特征 (Receiver Operating Characteristic, ROC) 曲线是根据不同分类阈值下分类结果的真阳性率 (True Positive Rate, TPR) 和假阳性率 (False Positive Rate, FPR) 绘制的曲线,TPR 和 FPR 的计算方法如式(5)所示。AUC 表示 ROC 曲线下的面积,Macro AUC 为各标签 AUC 的宏观平均值。

$$TPR = \frac{TP}{TP + FN}, FPR = \frac{FP}{TN + FP} \quad (5)$$

其中, TP 为预测正确的正类数量, TN 为预测正确的负类数量, FP 为将负类预测为正类的数量, FN 为将正类预测为负类的数量。

Accuracy 表示总体中分类正确的数量占比,计算式如式(6)所示。F1 分数是精确率和召回率的调和平均数,Macro $F1_{label}$ 和 $F1_{exam}$ 分别衡量模型在标签方面的分类性能和样本方面的分类性能,如式(7)–式(12)所示。

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (6)$$

$$Precision = \frac{TP}{TP + FP} \quad (7)$$

$$Recall = \frac{TP}{TP + FN} \quad (8)$$

$$Macro F1_{label} = \frac{1}{L} \sum_{i=1}^L \frac{2 \times Precision_i \times Recall_i}{Precision_i + Recall_i} \quad (9)$$

$$Precision_{exam} = \frac{1}{N} \sum_{i=1}^N \frac{|Y_i \cap P_i|}{|P_i|} \quad (10)$$

$$Recall_{exam} = \frac{1}{N} \sum_{i=1}^N \frac{|Y_i \cap P_i|}{|Y_i|} \quad (11)$$

$$F1_{exam} = \frac{2 \times Precision_{exam} \times Recall_{exam}}{Precision_{exam} + Recall_{exam}} \quad (12)$$

其中, L 表示标签的数量, N 表示样本数据的数量。 Y 和 P 分别为标签真实值和预测结果值。上述指标数值越接近于 1, 表明模型的分类性能越好。

3.3 实验结果

本文设计的网络模型在训练过程中使用 AdamW^[27] 优化器进行网络优化,设置学习率为 0.01,每批训练选取的样本数量为 128 并使用每周周期学习率调度策略,网络模型训练轮数为 50,选用二值交叉熵损失函数作为各个任务的损失函数,保存验证损失最小的一次模型参数进行测试。

首先,为了确定所提出的基于 GMDA 的多任务分类算法中调整梯度幅值的任务性能指标和任务聚焦参数,本文对这两者进行实验以做出最优选择。不同的任务性能指标体现了任务在不同方面的学习程度,其对提出的任务损失梯度幅值调整策略存在影响,从而影响网络模型的性能,因此,对不同的任务性能指标设计了实验进行测试。由于梯度幅值调整策略主要依据各任务的学习效果进行调整,因此基于样本的 F1 分数 $F1_{exam}$ 指标不满足梯度幅值调整策略的要求,故设置任务性能指标分别为宏观曲线下面积 Macro AUC、准确率 Accuracy 和基于标签的宏观 F1 分数 $Macro F1_{label}$ 。任务聚焦参数 γ 设置为 1,所提算法其余参数依照模型所述参数设置。不同任务性能指标的实验结果对比如表 2 所列。

表 2 不同任务性能指标的实验结果对比

Table 2 Comparison of experimental results of different task performance indexes

任务性能指标	Macro AUC	Accuracy	Macro $F1_{label}$	$F1_{exam}$
Macro AUC	0.945	0.960	0.572	0.762
Accuracy	0.944	0.961	0.574	0.768
Macro $F1_{label}$	0.950	0.965	0.583	0.777

从表 2 中可以看出,相比宏观曲线下面积 Macro AUC 和准确率 Accuracy,基于标签的宏观 F1 分数 $Macro F1_{label}$ 作为梯度幅值调整策略的任务性能指标时,基于 GMDA 的多任务分类算法具有更好的分类性能。因此任务性能指标的最优

选择为基于标签的宏观 F1 分数 $Macro F1_{label}$ 。

任务聚焦参数 γ 通过调节任务损失权重减小的速率来影响梯度幅值的调整,从而影响网络模型的性能。本文对不同任务聚焦参数数值进行实验测试来确定任务聚焦参数的最优选择,设置数值分别为 1, 2, 3。任务性能指标设置为基于标签的宏观 F1 分数 $Macro F1_{label}$,所提算法其余参数依照模型参数设置以避免对网络模型分类性能产生其他影响。不同的任务聚焦参数数值的实验结果对比如表 3 所列。

表 3 不同任务聚焦参数的实验结果对比

Table 3 Comparison of experimental results of different task focusing parameters

任务聚焦参数	Macro AUC	Accuracy	Macro $F1_{label}$	$F1_{exam}$
1	0.950	0.965	0.583	0.777
2	0.945	0.961	0.580	0.774
3	0.943	0.961	0.577	0.773

从表 3 中可以看出,当任务聚焦参数 γ 设置为 1 时,所提算法具有更好的分类性能。任务聚焦参数越大,分配给各任务的损失权重的减小速率越快,这就导致任务损失梯度的幅值更快地减小,从而使网络模型在训练过程中难以达到最优的结果。因此,所提算法任务聚焦参数 γ 的最优设置为 1。

本文所提基于 GMDA 的多任务分类算法在 PTB-XL 心电数据库上实验得到的宏观平均 ROC 曲线和各类标签平均 ROC 曲线分别如图 2 和图 3 所示。

从图 2 和图 3 中可以看出,基于 GMDA 的多任务分类算法的评价指标宏观平均曲线下面积 AUC 达到了 0.950 且标准差为 0.01,各类标签的平均曲线下面积 AUC 基本稳定在 0.90 及以上,并且标准差最大为 0.02。这证明了该算法具有较好的分类性能。但是在 23 个子类疾病诊断标签的二分类任务中,IVCD 标签的平均曲线下面积 AUC 仅仅为 0.82,真阳性率较低,说明所提算法将 IVCD 标签中的部分正类错误地预测为负类。IVCD 全称为非特异性室内传导阻滞,在心电图上表现为无任何特异性的束支阻滞图形。IVCD 心电图的主要特征是 QRS 波群持续时间延长,大多数在 0.12 s 以上,少数持续时间可能刚好为 0.11 s,其在波形其余部分的特征与正常心电图的波形差别不大。如图 4 所示,图 4(a)为正常标签的心电图波形,图 4(b)为 IVCD 标签的心电图波形,图 4(c)为(a)与(b)中某两个心拍的重叠对比图,可以看出两者波形相仿,QRS 波群的波形相差也不大,从而导致模型错误地将部分 IVCD 标签样本预测为正常心电样本。




图 2 宏观平均 ROC 曲线

Fig. 2 Macro mean ROC curve

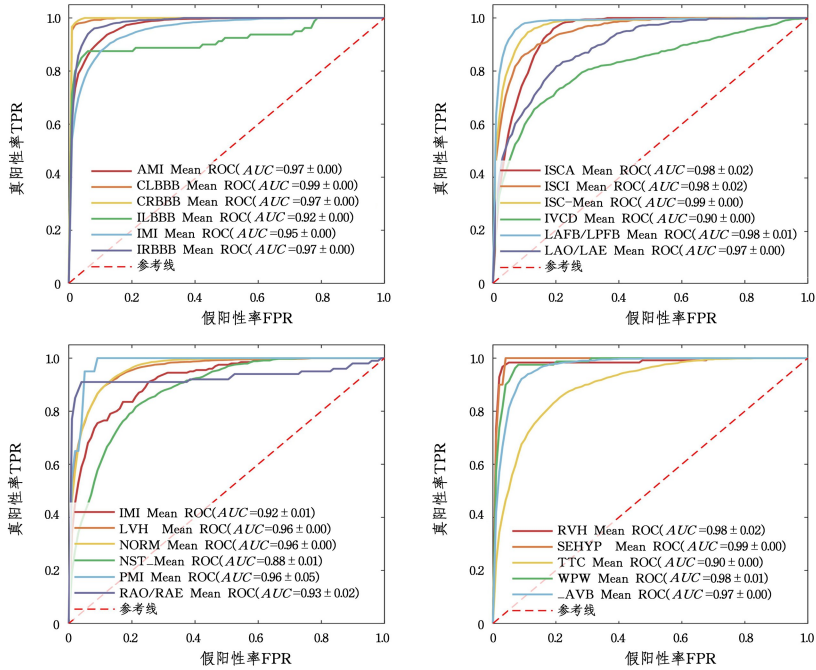


图3 各类标签平均 ROC 曲线

Fig. 3 Average ROC curve of various labels




图4 正常心电图与 IVCD 心电图对比

Fig. 4 Comparison of normal ECG and IVCD ECG

为了验证 GMDA 的有效性,对几种多任务学习的损失优化方法和 GMDA 展开了对比实验。其中,梯度归一化(Gradient Normalization, GradNorm)^[28]是通过动态调整各任务损失梯度的幅值来自动平衡多任务学习模型中各任务的训练;自适应加权方法动态权重平均(Dynamic Weight Average, DWA)^[29]是根据各任务损失的相对衰减率来设置任务损失

权重,从而实现对应任务的梯度幅值调整。实验结果如表 4 所列。

表4 多任务学习损失优化方法的实验结果对比

Table 4 Comparison of experimental results of multi-task learning loss optimization methods

模型	Macro AUC	Accuracy	Macro $F1_{label}$	$F1_{exam}$
GradNorm ^[28]	0.943	0.961	0.569	0.764
DWA ^[29]	0.935	0.949	0.559	0.762
DTP ^[23]	0.947	0.961	0.549	0.759
PCGrad ^[24]	0.951	0.964	0.567	0.773
GMDA	0.950	0.965	0.583	0.777

从表 4 中可以看出,所提出的将任务损失梯度的幅值调整和方向调整两方面相结合的 GMDA 整体上优于只从任务损失梯度的幅值进行损失优化的 GradNorm, DWA 和 DTP 方法以及只从任务损失梯度的方向进行损失优化的 PCGrad 方法。基于 GMDA 的多任务分类算法的宏观曲线下面积 Macro AUC 达到了 0.950,基于标签的宏观 F1 分数 Macro $F1_{label}$ 达到了 0.583,基于样本的 F1 分数 $F1_{exam}$ 达到了 0.777。基于 GMDA 的多任务分类算法的准确率 Accuracy 达到了 96.50%,与 DWA 方法相比提高了 1.6%,与其余 4 种模型方法相比,提高幅值较小但有所提升。

同时,文献[30]使用 PTB-XL 数据库进行心电信号多任务分类研究,其中的模型为 CoT Attention Mechanism。将本文提出的基于 GMDA 的多任务分类算法与上述多任务学习网络模型进行比较,实验结果如表 5 所列。

表5 多任务学习网络模型的实验结果对比

Table 5 Comparison of experimental results of multi-task learning network models

模型	Macro AUC	Accuracy	Macro $F1_{label}$	$F1_{exam}$
CoT AM ^[30]	0.925	0.887	—	—
GMDA	0.950	0.965	0.583	0.777

从表5中可以看出,与其余多任务学习网络模型相比,本文所提多任务分类算法宏观曲线下面积 *Macro AUC* 至少提高了2.5%,准确率 *Accuracy* 至少提高了7.8%。

使用本文的实验环境以及十折交叉验证方法复现了使用PTB-XL心电数据库进行研究的文献[26]中的6个模型:inception1d, xresnet1d101, resnet1d_wang, fcn_wang, lstm 和 lstm_bidir。将本文提出的基于GMDA的多任务分类算法与上述单任务学习网络模型进行比较,实验结果如图5所示。

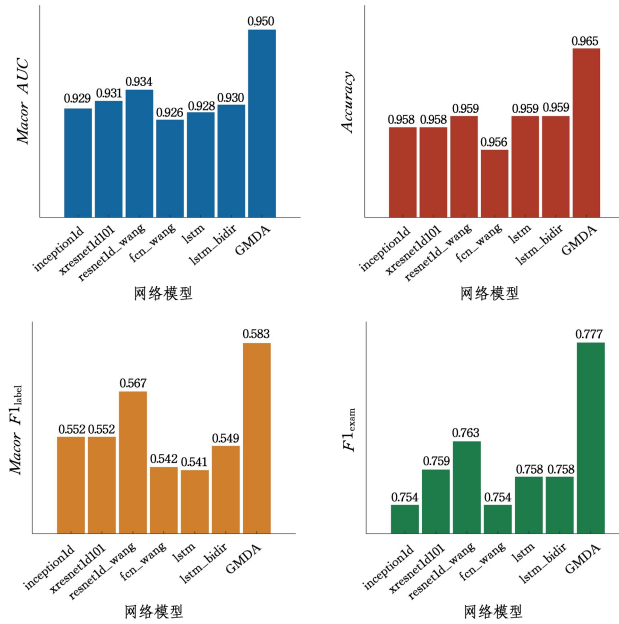


图5 不同网络模型的实验结果对比

Fig. 5 Comparison of experimental results of different network models

从图5中可以看出,与其余单任务学习网络模型相比,本文所提多任务分类算法宏观曲线下面积 *Macro AUC* 至少提高了1.6%,准确率 *Accuracy* 提高较小,最小仅提高了0.6%,基于标签的宏观 F1 分数 *Macro $F1_{label}$* 至少提高了1.6%,基于样本的 F1 分数 *F1_{exam}* 至少提高了1.4%。实验对比结果表明,基于GMDA的多任务分类算法具有良好的心电信号分类性能。

结束语 本文提出了一种基于多任务深度学习的心电信号分类算法。为了更好地优化多任务学习的损失,本文提出了一种将任务梯度的幅值和方向结合起来进行调整的损失优化方法。该方法可以自适应地调整不同任务梯度的幅值和方向,以避免手动设置任务损失权重和由于任务损失相互抵消而产生负迁移。该算法在PTB-XL心电数据库上展现出了较好的性能,宏观曲线下面积 *Macro AUC* 为0.950,准确率 *Accuracy* 为96.50%,基于标签的宏观 F1 分数 *Macro $F1_{label}$* 为0.583,基于样本的 F1 分数 *F1_{exam}* 为0.777。将所提多任务分类算法与其他单任务学习模型算法进行对比,实验结果表明所提算法的各项评价指标数值均有所提升,证实了该算法在心电信号分类任务上的有效性。

后续研究可集中于以下几个方面:

1)将适合分析时序数据的循环神经网络和可以选择性关注重要部分的注意力机制等网络模块引入网络模型,实现

网络模型的改进和心电信号分类任务结果的提升。

2)数据库方面,通过调整数据样本的数量或者选择合适的方法来解决数据不平衡的问题,使网络模型能够更好地学习心电信号分类任务。

3)使用其他心电数据库以及国内的心电数据库进行研究实验,提高网络模型对心电信号分类任务的泛化能力,设计出更符合国内心脏疾病诊断需求的心电分类网络模型。

参考文献

- [1] BENJAMIN E J, VIRANI S S, CALLAWAY C W, et al. Heart Disease and Stroke Statistics—2018 Update: A Report From the American Heart Association [J]. *Circulation*, 2018, 137(12): E67-E492.
- [2] LUZ E J D, SCHWARTZ W R, CAMARA-CHAVEZ G, et al. ECG-based heartbeat classification for arrhythmia detection: A survey [J]. *Computer Methods and Programs in Biomedicine*, 2016, 127: 144-164.
- [3] BERKAYA S K, UYSAL A K, GUNAL E S, et al. A survey on ECG analysis [J]. *Biomedical Signal Processing and Control*, 2018, 43: 216-235.
- [4] ZHAO R X, XU P J, LIU Y. ECG-based Atrial Fibrillation Detection Based on Deep Convolutional Residual Neural Network [J]. *Computer Science*, 2022, 49(5): 186-193.
- [5] HANNUN A Y, RAJPUKAR P, HAGPANAHI M, et al. Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network [J]. *Nature Medicine*, 2019, 25(1): 65-69.
- [6] AHMED A A, ALI W, ABDULLAH T A A, et al. Classifying Cardiac Arrhythmia from ECG Signal Using 1D CNN Deep Learning Model [J]. *Mathematics*, 2023, 11, 562: 1-16.
- [7] ACHARYA U R, OH S L, HAGIWARA Y, et al. A deep convolutional neural network model to classify heartbeats [J]. *Computers in Biology and Medicine*, 2017, 89: 389-396.
- [8] YILDIRIM O, PLAWIA P, TAN R S, et al. Arrhythmia detection using deep convolutional neural network with long duration ECG signals [J]. *Computers in Biology and Medicine*, 2018, 102: 411-420.
- [9] ULLAH H, HEYAT M, AKHTAR F, et al. An Automatic Premature Ventricular Contraction Recognition System Based on Imbalanced Dataset and Pre-Trained Residual Network Using Transfer Learning on ECG Signal [J]. *Diagnostics*, 2023, 13(1): 1-20.
- [10] CARUANA R. Multitask learning [J]. *Machine Learning*, 1997, 28(1): 41-75.
- [11] ZHANG Y, YANG Q. An overview of multi-task learning [J]. *National Science Review*, 2018, 5(1): 30-43.
- [12] SHAHI M, OO E, AHMED B, et al. Adversarial Multi-Task Learning for Robust End-to-End ECG-based Heartbeat Classification [C]// *Proceedings of the 42nd Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Montreal, Canada, 2020: 341-344.
- [13] ZHANG Y, YANG Q. A Survey on Multi-Task Learning [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2022,

- 34(12):1-20.
- [14] HUANG Z C, LI W, XIA X G, et al. A Novel Nonlocal-Aware Pyramid and Multiscale Multitask Refinement Detector for Object Detection in Remote Sensing Images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60:1-20.
- [15] LU G Q, ZHAO X S, YIN J, et al. Multi-task learning using variational auto-encoder for sentiment classification [J]. *Pattern Recognition Letters*, 2020, 132:115-122.
- [16] LU G Q, GAN J Z, YIN J, et al. Multi-task learning using a hybrid representation for text classification [J]. *Neural Computing and Applications*, 2020, 32(11):6467-6480.
- [17] BANAIAT L H, PARK S, PARK S B. A Neural Machine Translation Model for Arabic Dialects That Utilizes Multitask Learning(MTL) [J]. *Computational Intelligence and Neuroscience*, 2018, 2018:1-11.
- [18] JI J L, CHEN X H, LUO C Q, et al. A Deep Multi-task Learning Approach for ECG Data Analysis [C]//*Proceedings of the 2018 IEEE EMBS International Conference on Biomedical and Health Informatics*. Las Vegas, USA, 2018:124-127.
- [19] LIU Y, LI Q C, WANG K Q, et al. Automatic Multi-Label ECG Classification with Category Imbalance and Cost-Sensitive Thresholding [J]. *Biosensors-Basel*, 2021, 11(11):1-17.
- [20] LIU J H, ZENG M, SHAN K, et al. Loss Optimization Based Algorithm for Multi-classification of ECG Signal [C]//*ISAIMS 2022: 2022 3rd International Symposium on Artificial Intelligence for Medicine Sciences*. 2022:537-541.
- [21] UBEYLI E D. ECG beats classification using multiclass support vector machines with error correcting output codes [J]. *Digital Signal Processing*, 2007, 17(3):675-684.
- [22] OBERMEYE Z, EMANUEL E J. Predicting the Future – Big Data, Machine Learning, and Clinical Medicine [J]. *New England Journal of Medicine*, 2016, 375(13):1216-1219.
- [23] GUO M, HAQUE A, HUANG D A, et al. Dynamic Task Prioritization for Multitask Learning [C]//*Proceedings of the 15th European Conference on Computer Vision*. 2018:282-299.
- [24] YU T H, KUMAR S, GUPT A, et al. Gradient surgery for multi-task learning [C]//*Proceedings of the 34th Conference on Neural Information Processing Systems*. 2020:1-27.
- [25] WAGNER P, STRODTHOFF N, BOUSSELJO R-D, et al. PTB-XL, a large publicly available electrocardiography dataset [J]. *Scientific Data*, 2020, 7(1):1-15.
- [26] STRODTHOFF N, WAGNER P, et al. Deep Learning for ECG Analysis: Benchmarks and Insights from PTB-XL [J]. *IEEE Journal Biomedical and Health Informatics*, 2021, 25(5):1519-1528.
- [27] LOSHCILLO I, HUTTER F. Fixing Weight Decay Regularization in ADAM [C]//*Proceedings of the 2018 International Conference on Learning Representations*. 2018:1-10.
- [28] CHEN Z, BADRINARAYANA V, LEE C Y, et al. GradNorm: Gradient Normalization for Adaptive Loss Balancing in Deep Multitask Networks [C]//*Proceedings of the 35th International Conference on Machine Learning*. Stockholm, Sweden, 2018:1-27.
- [29] LIU S K, JOHNS E, DAVISON A J. End-To-End Multi-Task Learning with Attention [C]//*Proceedings of the 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Long Beach, USA, 2019:1871-1880.
- [30] CENG Q C, LIU H, GAO T L, et al. An ECG Classification Method Based on Multi-Task Learning and CoT Attention Mechanism [J]. *Healthcare*, 2023, 11(7):1-13.



ZHANG Xue, born in 2000, postgraduate, is a member of CCF (No. T3347G). Her main research interests include biological signal processing and intelligent healthcare.



TIAN Lan, born in 1965, professor, Ph.D supervisor. Her main research interests include brain-computer interface, brain-like computing and deep learning, biological signal processing and light regulation of neural activity.

(责任编辑:何杨)