

基于深度迁移学习和机器学习的ECG图像分类

黎婉婷, 吴佳美*, 徐 华, 覃学恒, 王建伟, 郭 濛

辽宁科技大学理学院, 辽宁 鞍山

收稿日期: 2026年3月22日; 录用日期: 2026年4月12日; 发布日期: 2026年4月24日

摘 要

心肌梗死是威胁人类生命健康的心血管疾病之一, 为了进一步提升心肌梗死的诊断效果, 本文提出一种基于深度迁移学习与传统机器学习融合的心电图图像分类方法。具体来讲, 将4种主流卷积神经网络的分类性能进行对比, 并筛选出最优特征提取模型, 再结合传统机器学习分类器构建混合分类模型。实验结果显示, 基于DenseNet121深度特征的SVM混合模型展现出最佳性能, 测试准确率为86.43%, AUC为0.9762, 该模型在测试集中对心肌梗死(MI)类别的识别未出现误判, 展现出了极高的区分能力。本方法可有效提升心电图图像分类精度, 为心肌梗死的智能辅助诊断提供了可靠的技术方案。

关键词

心肌梗死, 心电图, 深度学习, 特征提取, 支持向量机

ECG Image Classification Based on Deep Transfer Learning and Machine Learning

Wanting Li, Jiamei Wu*, Hua Xu, Xueheng Qin, Jianwei Wang, Meng Guo

School of Science, University of Science and Technology Liaoning, Anshan Liaoning

Received: March 22, 2026; accepted: April 12, 2026; published: April 24, 2026

Abstract

Myocardial infarction is one of the cardiovascular diseases threatening human life and health. To further improve the diagnostic efficacy of myocardial infarction, this paper proposes an electrocardiogram image classification method based on the fusion of deep transfer learning and traditional machine learning. Specifically, the classification performance of four mainstream convolutional neural networks is compared to select the optimal feature extraction model, which is then combined with traditional machine learning classifiers to construct a hybrid classification model. Experimental results

*通讯作者。

文章引用: 黎婉婷, 吴佳美, 徐华, 覃学恒, 王建伟, 郭濛. 基于深度迁移学习和机器学习的 ECG 图像分类[J]. 图像与信号处理, 2026, 15(2): 302-308. DOI: 10.12677/jisp.2026.152026

show that the hybrid model combining DenseNet121-based deep features with SVM achieves the best performance, with a test accuracy of 86.43% and an AUC of 0.9762. This model achieves perfect discrimination for the myocardial infarction (MI) category on the test set, demonstrating a high level of discriminative ability. The proposed method can effectively improve the accuracy of ECG image classification and provide a reliable technical solution for intelligent assisted diagnosis of myocardial infarction.

Keywords

Myocardial Infarction, Electrocardiogram, Deep Learning, Feature Extraction, Support Vector Machine

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

心肌梗死是由冠状动脉急性阻塞引发心肌缺血坏死的心血管疾病[1], 具有起病急、进展快、致死率高等特点。统计数据显示, 心血管疾病死亡人数占有所有死亡人数的 33.7%, 心肌梗死是心血管疾病中常见的急危病症, 早期精准诊断对患者的预后至关重要[2] [3]。心电图作为心肌梗死无创诊断的核心工具, 具有便捷、可靠、低成本的优势[4], 但是人工判读耗时费力, 诊断准确性高度依赖医师临床经验, 容易出现漏诊误诊, 所以研发心电图诊断算法具有重要的临床价值。

早期心肌梗死智能诊断多采用传统机器学习方法, 需要人工设计特征提取器来完成特征提取、筛选与分类[5] [6], 虽然有一定效果, 但存在先验知识依赖度高、泛化能力有限的短板, 很难适配心电信号的个体差异与复杂波形特点[7]。近年来, 深度学习方法凭借强大的自动特征提取能力, 已广泛应用于心电信号分析领域[8] [9], 国内外学者都开展了大量的相关研究: 张宏坡等[7]融合 CNN 与 LSTM 网络, 心肌梗死检测准确率达 99.99%; 刘建华等[4]通过集成 CNN 与数据重采样解决类别不平衡问题, 准确率达 99.8%; Acharya 等[10]、高轩瑞等[11]基于深度学习优化方法, 均取得了优异的分类效果。

虽然如上所述提出了很多方法, 但是对基于心电图的心肌梗死诊断问题来说, 依然有很大的改进空间。比如, 大多数研究只依赖单一的深度学习模型, 缺少对主流 CNN 模型在心电图像分类任务上的系统性比较。同时, “深度特征提取 + 传统机器学习分类器”这种混合策略, 在心电图分类中的应用尚不多见。

本研究提出了融合深度迁移学习和传统机器学习的心电图图像分类方法, 对比 4 种主流 CNN 模型的性能, 并从中筛选出最优特征提取模型, 再结合传统分类器构建出一个混合分类模型。实验结果表明, 本研究模型能够准确地检测心肌梗死, 为心肌梗死的智能辅助诊断提供了可靠的技术支撑。

2. 材料与方法

2.1. 数据来源与预处理

本研究选取的心电图像数据集来源于 Mendeley Data 公开数据库, 该数据集由 Khan 与 Hussain 于 2021 年发布, 名称为《ECG Images dataset of Cardiac Patients》(第 2 版, <https://doi.org/10.17632/gwbz3fsgp8.2>)。旨在为心血管疾病的计算机辅助诊断研究提供标准化数据支撑, 共包含 928 张心电图图像(含 MI、History_MI、Abnormal、Normal 4 个类别), 心电图各类别示例如图 1 所示, 数据集详情如表 1 所示。

该数据集包含了 4 个类别，分别是：

- 1) ECG Images of Myocardial Infarction Patients (MI)
- 2) ECG Images of Patient that have History of MI (History_MI)
- 3) ECG Images of Patient that have abnormal heartbeat (Abnormal)
- 4) Normal Person ECG Images (Normal)

借助 Python PIL 库，我们将原始图像尺寸设置为 224×224 像素，以满足模型输入尺寸的规范。同时采用图像的单通道灰度格式，利用 `ImageOps.equalize` 函数进行直方图均衡化处理，增强图像的局部对比度。这样突出了 ECG 信号的关键波形特征，提高了模型对 ECG 波形细微变化的识别灵敏度。之后，图像像素值从 $[0, 255]$ 归一化到 $[0.0, 1.0]$ 的浮点区间，降低了模型训练的计算成本，加快了模型的收敛。最后按照分层抽样的方法，以 7:1.5:1.5 的比例将样本分为训练集、验证集和测试集。

Table 1. EICP dataset details

表 1. EICP 数据集详情

心电图数据类别	标签	心电图图片数量
心肌梗死患者(MI)	0	239
有心肌梗死病史患者(History_MI)	1	172
心跳异常患者(Abnormal)	2	233
正常人(Normal)	3	284




Figure 1. Examples of various ECG categories

图 1. 心电图各类别示例

2.2. 深度学习模型

本研究选用 ResNet18/34、DenseNet121 和 EfficientNet-B0 四种主流卷积神经网络，ResNet 系列所采用的残差结构能很好地缓解深度网络中梯度消失的问题，很自然地有利于提取 ECG 波形的全局特征；DenseNet121 的密集连接机制在提取 P 波、QRS 波群诸种细粒度波形特征时有明显优势；而 EfficientNet-B0 模型由于用复合缩放的方法做了缩放，其所采取的策略在轻量化、特征提取两者间有极好的平衡。

在训练过程中，我们选取交叉熵损失作为优化目标，使用 Adam 优化器。初始学习率设置为 1×10^{-3} ，其依据为预实验经验；为了防止训练振荡，还设置了 `ReduceLROnPlateau` 策略来自动衰减学习率。同时，为了避免过拟合，增加了提前停止机制，最大训练轮次控制在 20 轮以内。

2.3. 特征提取与传统分类器对比

为了验证深度特征与传统机器学习方法相结合的分类效果，本研究设计了两步实验框架，即优先进行深度特征提取工作，再做二级分类，故而先要在验证集上选出性能最好的深度模型，去掉其顶层全连

接层,把主干网络冻结。把权重作为固定的特征提取器来处理 ECG 图像,先得到高维深度特征向量,然后就高维特征本身的特点合理地加以处理。

由于要解决稀疏性、冗余性问题,本研究采用主成分分析对特征做了降维处理,继而选用支持向量机(SVM)、随机森林(RF)和极端梯度提升树(XGBoost)三个经典的机器学习分类器,先用网格搜索对各分类器做超参数调优,然后再用降维后的特征予以训练。最后在独立测试集上从准确率、精确率、召回率诸方面对分类性能客观、合理地予以评价。

2.4. 性能评估指标

为了评估分类器的性能,计算了以下几种性能评价指标,来验证模型分类结果:

准确率(Accuracy, ACC):

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

精确率(Precision):

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

召回率(Recall):

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

F1 值(F1-Score):

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

曲线下面积(Area Under the Curve, AUC): ROC 曲线与横坐标轴在[0, 1]区间内围成的面积。

3. 结果

3.1. 模型性能评估结果

Table 2. Performance indicators of different models on the test set

表 2. 不同模型在测试集上的性能指标

模型	验证准确率	测试准确率	精确率	召回率	F1 值	AUC
SVM	0.9375	0.8643	0.8628	0.8643	0.8631	0.9762
XGBoost	0.8357	0.8357	0.8339	0.8357	0.8345	0.9599
随机森林	0.8143	0.8286	0.8383	0.8286	0.8253	0.9577
DenseNet121	0.9143	0.8214	0.8347	0.8214	0.8119	0.9574
EfficientNet-B0	0.8500	0.7714	0.7821	0.7714	0.7630	0.9461
ResNet18	0.8286	0.7286	0.7482	0.7286	0.7218	0.9236
ResNet34	0.7929	0.6786	0.7073	0.6786	0.6467	0.9019

根据表 2 与图 2 的结果可知, DenseNet121 的分类性能最优,测试准确率为 0.8214, AUC 为 0.9574,整体优于 ResNet 系列模型与 EfficientNet-B0,验证了其密集连接结构在心电图像深层特征提取上的优势。再基于 DenseNet121 提取的深度特征,训练 3 种传统机器学习分类器,其中支持向量机(SVM)分类表现

最为突出，测试准确率为 0.8643，AUC 为 0.9762；XGBoost 和随机森林也取得了优异的分类效果，测试准确率分别为 0.8357 和 0.8286。因此，本研究得出最优分类模型为基于 DenseNet121 深度特征的 SVM 分类器，其分类准确率比最优端到端深度学习模型提升了 4.29 个百分点，证明了混合策略的有效性。

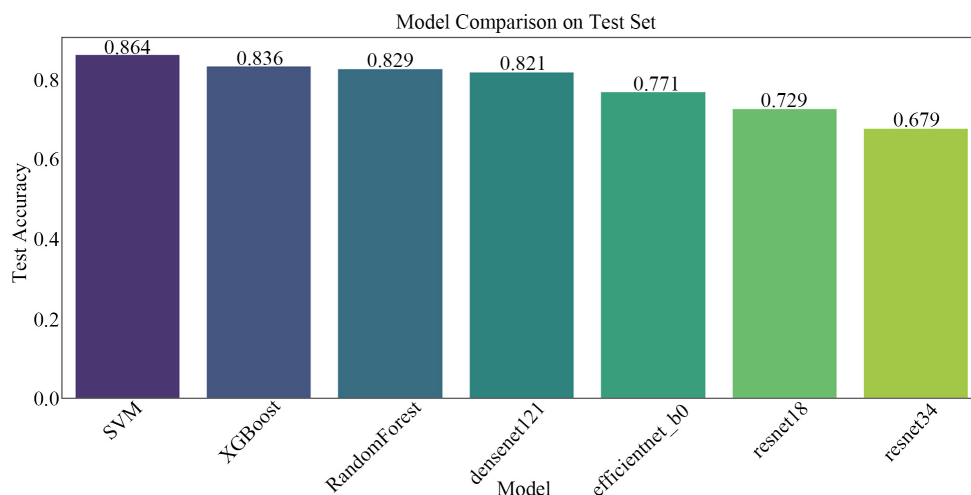


Figure 2. Comparison of accuracy of different models on the test set
图 2. 不同模型在测试集上的准确率对比

3.2. 最佳模型分析

为进一步分析最佳模型(SVM)的分类性能，绘制了其在测试集上的混淆矩阵和各类别的 ROC 曲线，如图 3、图 4 所示。

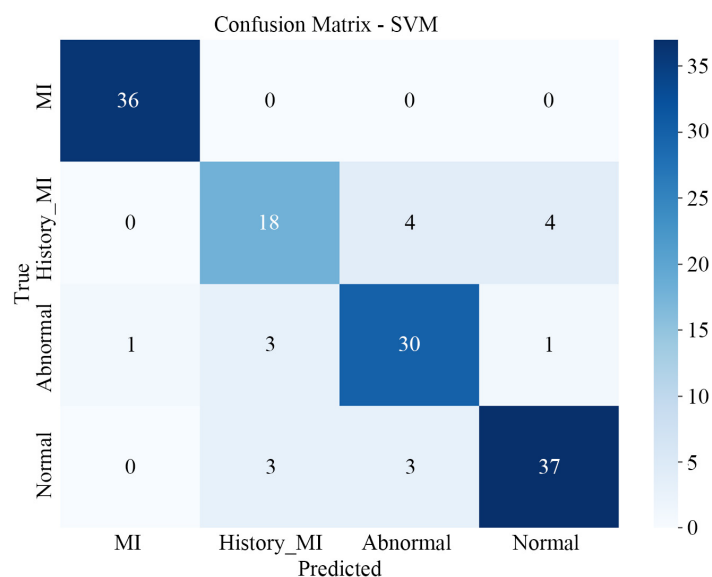


Figure 3. Confusion matrix of the optimal model (SVM)
图 3. 最佳模型(SVM)的混淆矩阵

模型对心肌梗死(MI)心电信号的识别准确率达到 100%，AUC 为 1.00，表明算法对 ST 段抬高等心梗标志性心电特征具有很高的识别敏感性与特异性，能够实现对急性心梗心电的精准检出。

该模型在区分旧心肌梗死(History_MI)病例方面存在局限性；在 26 个相关样本中，仅有 18 个被正确分类，其余 8 例被错误地归类为“异常”和“正常”类别。在旧心肌梗死患者中，急性期出现的病理性 Q 波和 ST 段抬高等典型特征已基本消失，只剩下非特异性的 ST-T 段改变。这些波形难以与正常心电图及轻度心律失常区分，从而增加了模型分类的难度。

对于心律失常和正常心电图样本，整体分类性能相对较好，误分类主要集中在特征不明显的样本中。在 35 个心律失常样本中绝大多数病例都正确分类，只有少数分类错误，而其原因很清楚：早搏易与轻度传导阻滞的波形混淆。正常心电图样本中共有 37 例被正确分类，分类错误的样本多为轻度 ST 段压低的非典型病例，错误地归类为陈旧性心肌梗死或心律失常。

从 ROC 曲线分析的结果可以十分清楚地看到，各分类所得的 AUC 值都不低于 0.94，其中心肌梗死分类的 AUC 为 1.00、心律失常分类准确率是 0.97、正常心电图分类准确率是 0.98，与单纯的深度神经网络分类模型相比，本研究所提出的融合传统机器学习分类器的方案有利于提高模型的泛化能力，适用于用自动心电图分类方法解决急性心肌梗死的鉴别诊断问题。

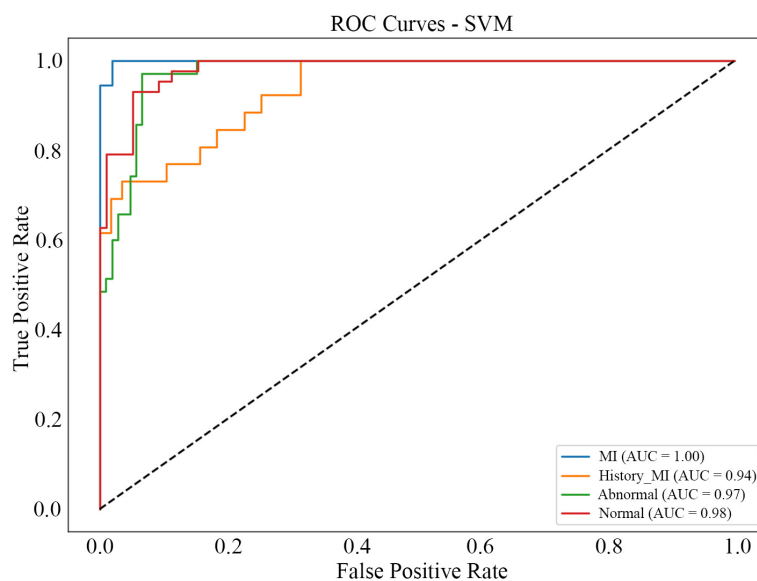


Figure 4. ROC curve of the optimal model (SVM)

图 4. 最佳模型(SVM)的 ROC 曲线

4. 结语

本研究提出了一种将深度迁移学习与机器学习相结合的混合模型。具体来说，就是确定性能最佳的特征提取网络并以此为基础构建多种分类模型，评估选出分类性能最佳的模型。该方法在心肌梗死心电图分类任务中表现优异，展现了其在临床诊疗领域的实际价值。本研究存在一些局限性，数据集规模相对较小可能导致实验结论存在偏差，目前验证的性能仅基于内部测试集，模型在外部数据集上的泛化能力尚不明确。未来研究可引入更大规模的数据集和多中心、跨设备的外部验证集，全面评估模型的泛化能力与鲁棒性。整合注意力机制或 Transformer 架构以提升模型捕捉关键波形特征的能力并开发多模态融合模型，为心血管疾病的诊疗提供更全面的技术支持。

基金项目

本研究系 2026 年辽宁科技大学大学生创新训练计划立项资助成果。

参考文献

- [1] Thygesen, K., Alpert, J.S., Jaffe, A.S., Chaitman, B.R., Bax, J.J., Morrow, D.A., *et al.* (2019) Fourth Universal Definition of Myocardial Infarction (2018). *European Heart Journal*, **40**, 237-269. <https://doi.org/10.1093/eurheartj/ehy462>
- [2] 林春, 陈关海, 吴柱国. 急性心肌梗死预后的影响因素[J]. 海南医学, 2020, 31(2): 227-230.
- [3] Frampton, J., Ortengren, A.R. and Zeitler, E.P. (2023) Arrhythmias after Acute Myocardial Infarction. *The Yale Journal of Biology and Medicine*, **96**, 83-94. <https://doi.org/10.59249/lswk8578>
- [4] 刘建华, 吕建峰, 蔡金丹. 基于卷积神经网络和长短时记忆网络的心肌梗死检测[J]. 中国医学物理学杂志, 2022, 39(11): 1448-1452.
- [5] Sharma, L.N., Tripathy, R.K. and Dandapat, S. (2015) Multiscale Energy and Eigenspace Approach to Detection and Localization of Myocardial Infarction. *IEEE Transactions on Biomedical Engineering*, **62**, 1827-1837. <https://doi.org/10.1109/tbme.2015.2405134>
- [6] Banerjee, S. (2017) Identification of Elevated ST Segment and Deep Q Type MI Variant Using Cross Wavelet Transform and Hierarchical Classification from ECG Signals. *Journal of Medical and Biological Engineering*, **37**, 492-507. <https://doi.org/10.1007/s40846-017-0280-y>
- [7] 张宏坡, 王震, 董忠仁, 等. 基于 CNN 和 LSTM 融合心肌梗死检测和识别[J]. 计算机应用与软件, 2023, 40(11): 201-207.
- [8] LeCun, Y., Bengio, Y. and Hinton, G. (2015) Deep Learning. *Nature*, **521**, 436-444. <https://doi.org/10.1038/nature14539>
- [9] Strodthoff, N. and Strodthoff, C. (2019) Detecting and Interpreting Myocardial Infarction Using Fully Convolutional Neural Networks. *Physiological Measurement*, **40**, Article ID: 015001. <https://doi.org/10.1088/1361-6579/aaf34d>
- [10] Acharya, U.R., Fujita, H., Oh, S.L., Hagiwara, Y., Tan, J.H. and Adam, M. (2017) Application of Deep Convolutional Neural Network for Automated Detection of Myocardial Infarction Using ECG Signals. *Information Sciences*, **415**, 190-198. <https://doi.org/10.1016/j.ins.2017.06.027>
- [11] 高轩瑞, 曹进德, 张金壬. 一种基于深度学习的心电图分类方法[J]. 南通大学学报(自然科学版), 2023, 22(3): 17-25.