

基于预训练卷积神经网络的肺动脉压分类器研究

张 赛*, 马 佩[#]

上海理工大学光电信息与计算机工程学院, 上海

收稿日期: 2023年2月1日; 录用日期: 2023年2月21日; 发布日期: 2023年2月28日

摘要

肺动脉高压是一种肺血管系统的梗阻性持续性疾病,通常与先天性心脏病相关,可诱发右心室功能衰竭,影响患者的生活质量和生命。肺动脉压力(PAP)是判定肺动脉高压的直接指标,现有的肺动脉压力测量技术侵入性大,使用不便,不适合频繁使用。一种无创、方便和定期监测肺动脉压力的方法对于肺动脉高压的早期预防和诊断至关重要。本研究的目的是提出并评估一种深度学习方法,用于从无创的光电容积脉搏波(PPG)信号中分类和评估肺动脉高压。利用采集的肺动脉压力值提取肺动脉压力类别标签,PPG信号用于训练和测试模型。基于216条数据记录,使用预训练卷积神经网络进行分类,实验结果表明,该模型的分类准确率为97.78%,表明基于PPG信号提取特征训练的模型在PAP分类中具有良好的性能。随着可穿戴设备从指尖捕捉PPG信号的发展和深度学习模型的出现,无创和方便的PAP预测将极大地有助于心血管疾病的早期预防。

关键词

深度学习, 光电容积脉搏波, 肺动脉压, 卷积神经网络

Research on Pulmonary Artery Pressure Classifier Based on Pre-Trained Convolutional Neural Network

Qian Zhang*, Pei Ma[#]

School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai

Received: Feb. 1st, 2023; accepted: Feb. 21st, 2023; published: Feb. 28th, 2023

*第一作者。

[#]通讯作者。

Abstract

Pulmonary hypertension (PH) is an obstructive progressive disease of lung vascular system which is usually associated with congenital heart disease (CHD) and induces the right ventricle failure, adversely affecting quality of life and survival. Pulmonary arterial pressure (PAP) is a direct indicator of PH. The existing PAP measurement techniques are invasive and inconvenient, which are not suitable for frequent use. A noninvasive, convenient and regular monitoring PAP method is essential for the early prevention and diagnosis of PH. The aim of this study was to propose and evaluate a deep learning approach for the classification and evaluation of PH from noninvasive photoplethysmography (PPG) signals. The PAP signal was used to extract pulmonary artery pressure category label, the PPG signal was used to train and test model. A pre-trained convolutional neural network (GoogLeNet) was developed to learn features and classified PH based on the results from 216 data records, the experimental results showed that the classification accuracy of this model was 97.78%, which indicates that the GoogLeNet model trained on features extracted from PPG signals has excellent performance in PAP classification.

Keywords

Deep Learning, Photoplethysmography, Pulmonary Artery Pressure, Convolutional Neural Networks

Copyright © 2023 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

肺动脉压(PAP)是指血液通过肺循环在肺动脉血管上产生的侧压力，是临床血流动力学的重要指标[1]。与血压不同，血压是全身循环压力的指标，而PAP是肺循环压力的指标。它包括肺动脉收缩压和舒张压，分别反映右心室收缩功能和肺动脉血管阻力[2]。平均肺动脉压是指在完全收缩和舒张期间的平均肺动脉压力，通常用于评估肺动脉系统所经历的平均压力。作为右心室负荷后的指标，平均肺动脉压表示右心室在泵血时必须克服的阻力。由于平均肺动脉压增加，右心室负荷增加，导致右心室肥厚，最终导致右心衰[3]。根据美国国立卫生研究院的数据，诊断为特发性肺动脉高压(PH)后的平均生存时间为2.8年[4]。

随着肺动脉高压病例的逐渐增多，监测高危人群的肺动脉压力很重要，但这并不容易。肺动脉高压患者通常表现出呼吸困难、疲劳和胸痛的早期症状，这是许多其他疾病中常见的症状，如肺部感染和甲状腺功能减退[5]。此外，PAP的金标准测量方法——右心室导管插入术(RHC)是一种有创的且复杂的手术过程[6]。在执行该手术的过程中，利用X射线的透视，通过静脉将导管插入右心室和大血管[7]。显然，这种方法会给患者带来疼痛，并且很难预先进行评估疾病进展或治疗反应。此外，RHC有可能增加非心脏手术患者的心脏病风险[8]。因此，逐渐发展了肺动脉压监测的无创替代方案。例如，超声心动图已用于诊断肺动脉高压[9]。然而，超声心动图测量的准确性仍存在担忧[10]。对于肺动脉高压的早期诊断和监测疾病进展，仍然迫切需要一种非侵入性和方便的方法来预测和测量。

我们注意到光电容积脉搏波描记(PPG)在监测多种生理参数，特别是心血管参数方面的潜力[11]。PPG是一种非侵入性的皮肤表面测量方法，通过向组织发射绿光(500~560 nm)或低强度红外光，并用光电接

收器收集透射或反射光。当心脏周期性跳动时, PPG 测量血液光吸收的周期性变化, 并给出随时间变化的血容量曲线[12]。这种低成本和方便的技术提供了有关心血管系统功能的丰富生理信息[13]。特别是, 深度学习方法的最新发展提高了在疾病诊断中使用 PPG 的分类和预测准确性。Ward 等人使用基于连续小波变换和卷积神经网络的 PPG 信号测试了一种用于正常血压和高血压分类和评估的深度学习方法, 准确率达到 92.55% [14]。Lin 等人使用径向血压波形和 PPG 脉搏指数作为多层感知器(MLP)分析方法的特征, 该方法可以区分轻度、中度和重度阿尔茨海默病, 准确率约为 82.86% [15]。Radha 等人基于 PPG 信号和转移学习模型实现了 4 级睡眠阶段的分类。模型结构由域层、时间层和决策层组成。其中, 时间层由 LSTM 堆栈组成, 决策层由两层感知器组成。该模型表现出良好的性能, 精度为 $76.36\% \pm 7.57\%$ [16]。

众所周知, 人体的心血管系统在肺动脉高压的不同阶段会产生变化并带来某些影响, 而 PPG 信号包含着丰富的有关心血管循环过程中的生理信息, 这些生理参数蕴含着一定的内在联系。本文提出了一种利用光电容积脉搏波信号结合预训练卷积神经网络进行肺动脉压分类的新方法。它只需要从单个指尖位置采集的 PPG 信号作为输入, 并避免了侵入性有创的测量肺动脉压。该模型的输出是不同阶段的肺动脉压, 包括正常肺动脉压(NPP)、早期肺动脉高压(EPH)和肺动脉高压(PH)。PAP 的识别和分类通过以下步骤实现(图 1): 1) PPG 信号的筛选、提取和预处理; 2) PAP 信号提取对应阶段水平的标签; 3) 将经过时频转换后的 PPG 信号输入卷积神经网络模型进行训练; 4) 验证模型对不同阶段肺动脉高压的分类。该方法使用包含金标准 RHC 测量值的数据库进行评估, 测试准确率达到 97.78%。该方法使用 PPG 信号实现肺动脉高压的分类和诊断, 为确定 PAP 风险提供了一种非侵入性的替代方法。如果与可穿戴设备进一步结合, 将实现方便、频繁和长期的 PAP 监测。因此, 患者的疼痛和风险将显著降低。

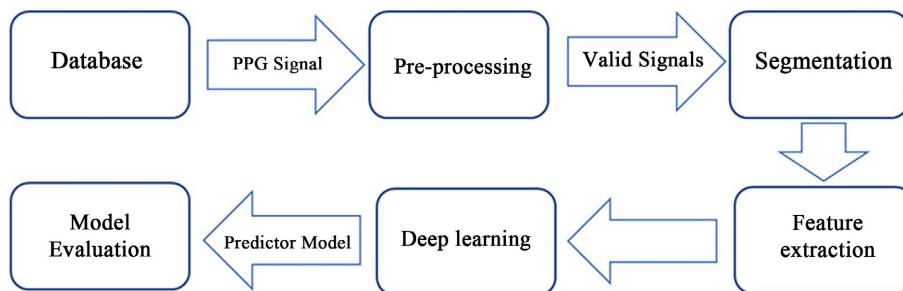


Figure 1. System workflow of the research methodology
图 1. 本研究方法的工作流程图

2. 模型与方法

卷积神经网络

卷积神经网络(CNN)是一种前馈神经网络, 通常由一个或多个卷积层(Convolutional layer)、池化层(Pooling layer)以及全连接层(Fully-Connected layer)等组成。与其他深度学习模型相比, 卷积神经网络在图像处理方面有着较好的表现。其中, 卷积层由若干卷积单元组成, 其作用是提取输入的不同特征, 更多层的网络能从低级特征中迭代提取更复杂的特征。通常在卷积层之后会得到维度很大的特征, 池化层主要对卷积层学习到的特征图进行亚采样处理, 有最大池化和平均池化两种, 将特征切成几个区域, 取其最大值或平均值, 得到新的、维度较小的特征。而全连接层即把所有局部特征结合变成全局特征, 用来计算每一类的概率。

自卷积神经网络问世以来, 出现过许多对其经典结构进行优化的 CNN 网络。GoogLeNet 就是其中一种, 是 Szegedy 在 2015 年提出的预训练卷积神经网络结构[17]。GoogLeNet 与 AlexNet 这类仅依靠加深

网络结构进而改进网络性能的思路不同, 它不仅在加深网络的同时, 也在网络结构上进行创新, 引入了 Inception 结构替代了传统卷积和激活函数的组合。这种网络结构的创新, 更加有效地改善模型的分类性能。本文章基于 GoogLeNet 进行了部分改进, 如添加 Dropout 层, 对部分全连接层进行替换, 以便更好匹配和训练本实验的数据, 网络参数详见模型训练部分。

3. 数据集与实验流程

3.1. 数据集

本研究从 PhysioNet 组织[18]提供的多参数智能监测(MIMIC) II 在线数据库中收集了 250 条记录的子集。MIMIC-II 数据库是一个免费提供的去识别数据库, 包含在重症监护室(ICU)治疗的成年患者的生理信号和多个参数记录。每项记录包括动脉血压、心电图、光电容积脉搏波、肺动脉压力等。通常, 这些信号以 8 位或 10 位精度的 125 Hz 采样。采用侵入性 RHC 法记录 PAP 信号, 指尖记录 PPG 信号。

用于模型训练的 PAP 类别标签是从 PAP 信号中提取出来的。根据世界肺动脉高压学术研讨会, 肺动脉压水平根据其数值分为正常肺动脉压、轻度、中度和重度肺动脉高压。由于中度和重度肺动脉高压都有明显的呼吸困难症状, 可归为一类。因此, 本研究中 PAP 类别为正常肺动脉压、肺动脉高压早期和肺动脉高压。最终, 共收集了 216 条记录, 其中 90 条为正常肺动脉压, 60 条为肺动脉高压早期, 66 条为肺动脉高压。在选定的数据子集中, 每个记录都包含同时从患者获得的 PPG 和 PAP 信号。图 2 显示了这两种信号的波形和用途。

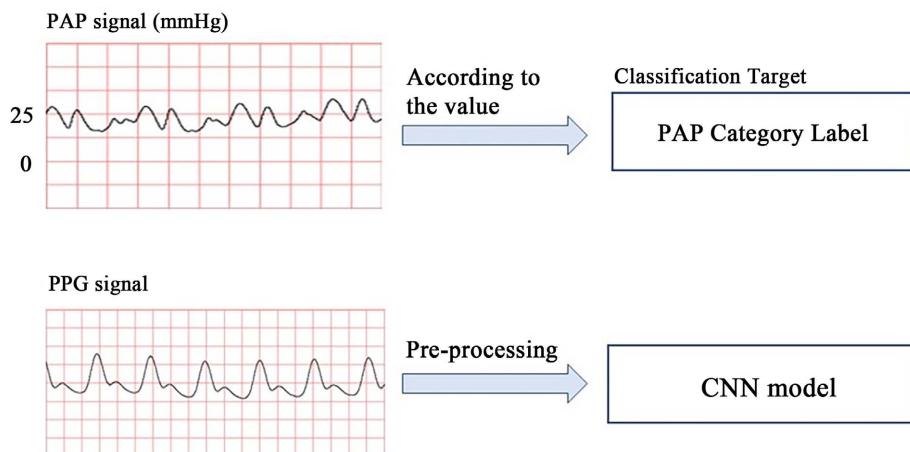


Figure 2. Waveform and purpose of the two signals
图 2. 两种信号的波形和用途

3.2. 信号预处理

原始 PPG 数据在输入预训练卷积神经网络模型之前进行了预处理。原始 PPG 信号波形通常包含基线漂移、不同程度的失真和受运动影响的不规则段以及异常段。因此, 为了最大化原始 PPG 信号中的有用信息, 执行了以下几个预处理步骤。

首先, 筛选并排除不正确和有缺陷的 PPG 片段。图 3 显示了合适的和排除掉不合适 PPG 片段的示例。然后, 我们使用 MATLAB (版本 2021b) 使用 0.5~12 Hz 四阶巴特沃斯带通滤波器进行滤波。这用于滤除干扰和噪声, 并去除 PPG 的低频基线漂移。最后, 使用最小 - 最大归一化将 PPG 信号的幅度归一化为 [0, 1]。处理后的 PPG 信号被切成 30 s 段。图 4 显示了预处理前后 PPG 信号的比较。

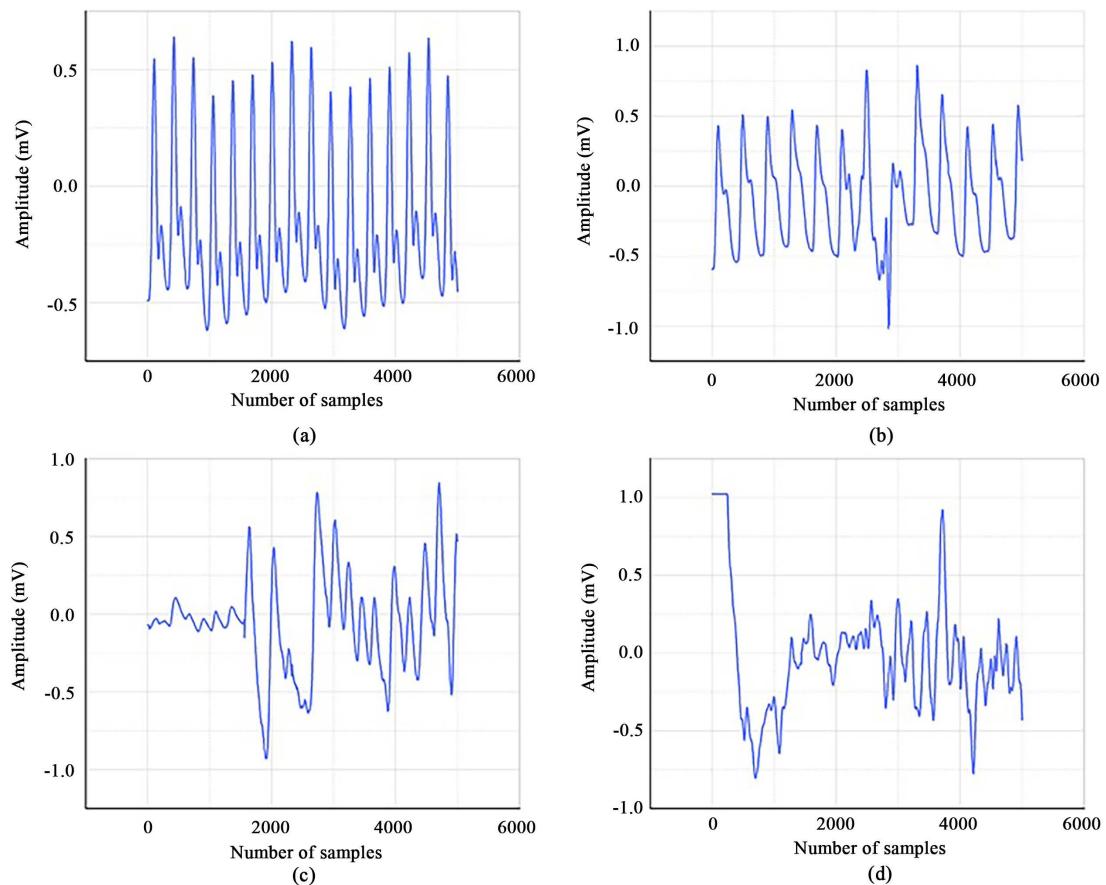


Figure 3. Example of (a) appropriate PPG segments. (b) (c) and (d) inappropriate PPG segments
图 3. 合适的 PPG 段(a)和不合适的 PPG 段(b) (c) (d)

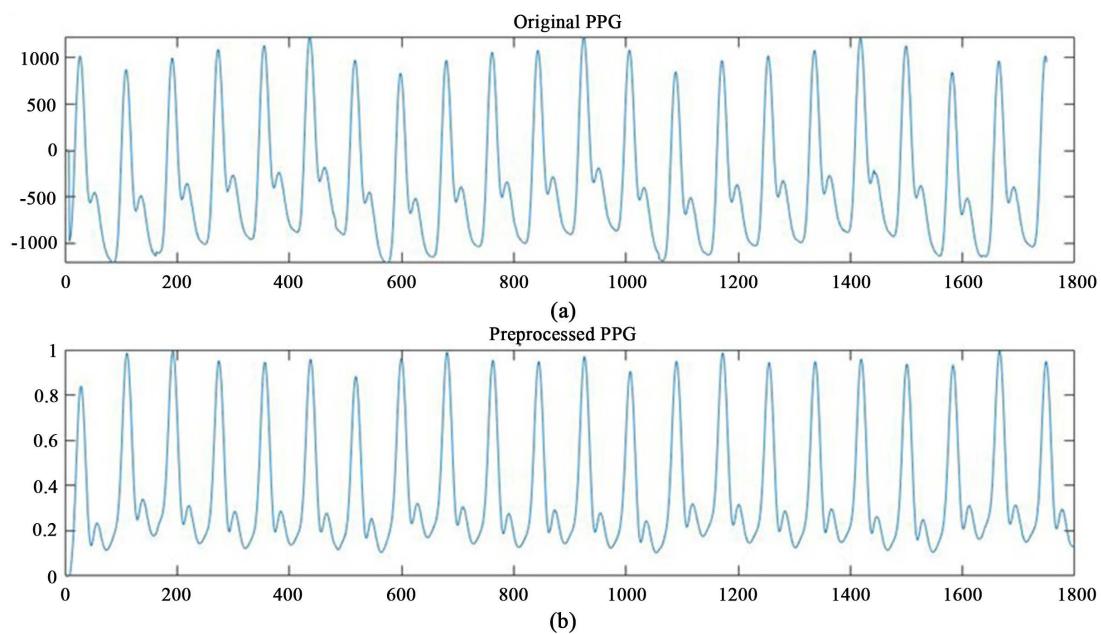


Figure 4. PPG signal before (a) and after (b) pre-processing
图 4. 预处理前后的 PPG 信号

由于预训练卷积神经网络的输入为 RGB 图像, 而预处理后的 PPG 信号为一维信号。因此, 需要利用时频转换将一维信号转换为二维图像, 通过连续小波变换将 PPG 信号转换为 RGB 图像, 连续小波变换可以获得信号更为清晰的时频表示, 每个 PPG 信号段转换为时频表示后称为尺度图, 如图 5 所示。其大小为 $224 \times 224 \times 3$ 。然后, 将这些尺度图作为神经网络的输入来进行训练。

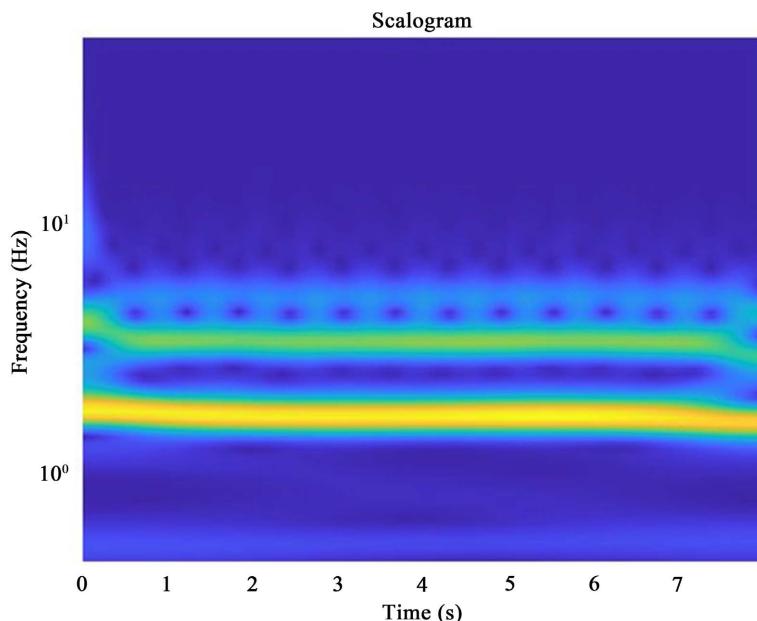


Figure 5. Example of Scalogram of PPG signal after time-frequency transformation
图 5. PPG 信号经时频变换后的尺度图

3.3. 模型训练

本研究的实验软硬件环境如下:CPU 为 AMD Ryzen5 4600H, GPU 为 Nvidia GTX, 运行内存为 16 G。系统为 Windows10 64 位。算法模型是基于 Matlab 的深度学习工具箱, 并对 GoogLeNet 网络的部分参数进行修改, 为了防止出现过拟合情况, 添加 dropout 层。网络的部分设置如下: MiniBatchSize 为 15, MaxEpochs 为 20, ValidationFrequency 为 10。本实验数据集的 75% 为训练集, 25% 为测试集, 均为随机抽选。

3.4. 评价指标

为了评估模型对三种不同阶段肺动脉压的分类效果, 使用以下几项被称为金标准的模型评价指标: 正确率(Accuracy, Acc)、敏感性(Sensitivity, Sen)、特异性(Specificity, Spe)、精确度(Precision, Pre)和 F1 分数。F1 分数越接近 1 代表模型的分类效果越好。这些评价指标使用以下公式来进行计算, 其中, TP (True Positive)是指正确识别阳性样本的个数; TN (True Negative)是指正确识别阴性样本的个数; FP (False Positive)是指错误识别阴性样本的个数, FN (False Negative)是指错误识别阳性样本的个数。TP、TN、FP、FN 之和为总样本数。与常见的二分类问题不同, 本实验为三分类, 其混淆矩阵如图 6 所示。

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

$$Sen = \frac{TP}{TP + FN} \quad (2)$$

$$Spe = \frac{TN}{TN + FP} \quad (3)$$

$$Pre = \frac{TP}{TP + FP} \quad (4)$$

$$F1 = \frac{2TP}{2TP + FP + FN} \quad (5)$$

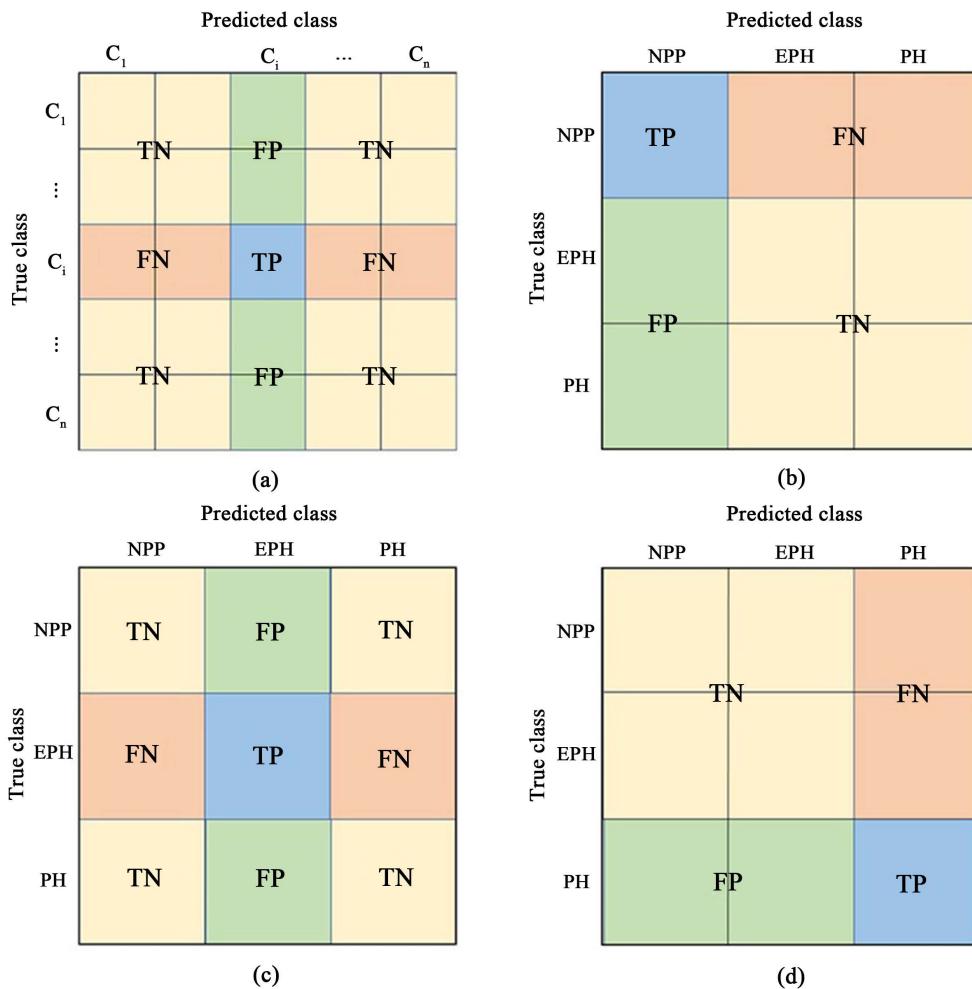


Figure 6. The confusion matrix of indicators for (a) Multiclassification; (b) NPP; (c) EPH; (d) PH
图 6. (a) 多分类问题; (b) 三分类中 NPP; (c) 三分类中 EPH; (d) 三分类中 PH 的混淆矩阵

4. 实验结果

为了体现模型的分类能力, 进行多次肺动脉压分类实验, 并对结果进行分析。混淆矩阵和数据见表 1 和图 7。

结果表明, 该模型具有较好的分类性能, 三种状态下肺动脉压分类的平均准确率分别为 100%、97.78% 和 97.78%。早期预测肺动脉高压的敏感性和特异性分别为 95.71% 和 98.47%。预测肺动脉高压的敏感性和特异性分别为 96.33% 和 98.32%, F1 评分分别为 0.9567 和 0.9638。F1 分数越高, 说明该分类模型的性能越好。从混淆矩阵可以看出, 该模型能够清晰地区分正常肺动脉压和肺动脉高压, 在对早期肺动脉高

压和肺动脉高压的分类上出现了部分错误。这可能是因为对于一些人来说, 早期肺动脉高压的症状与肺动脉高压相似, 这种情况应该是模型进一步改进的重点。

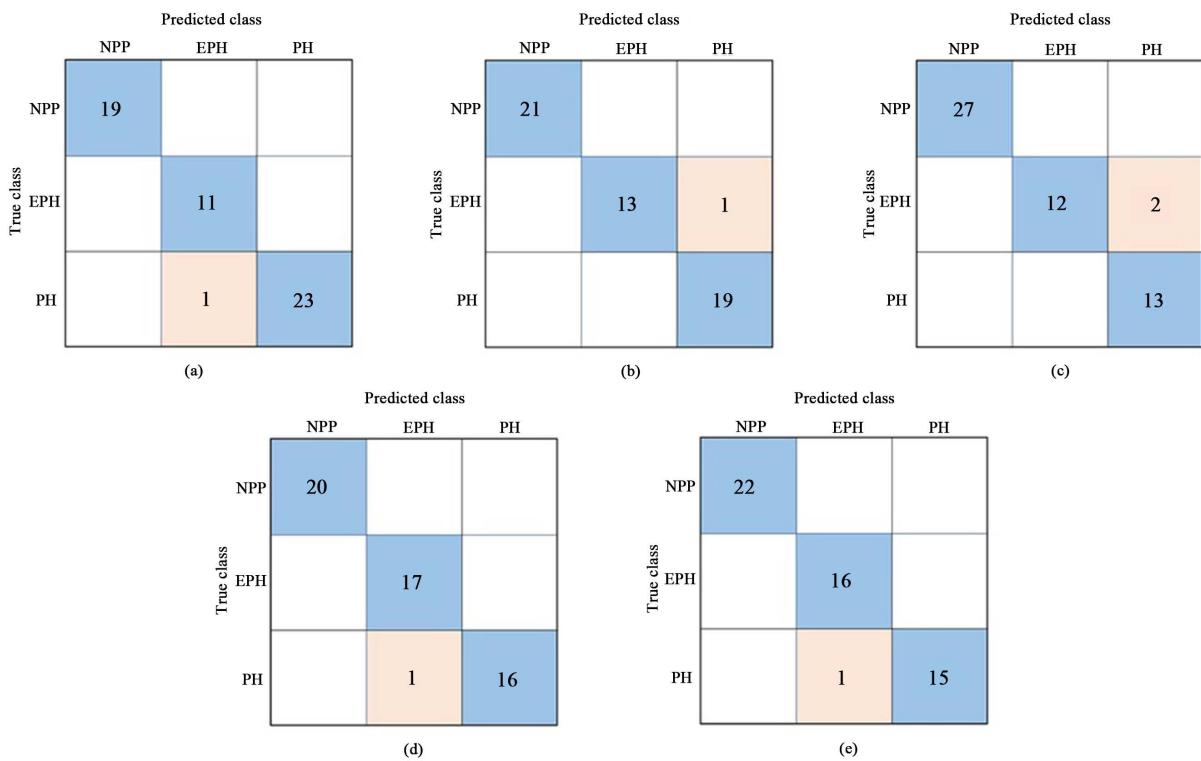


Figure 7. Confusion matrix of 5 independent training
图 7.5 次独立训练的混淆矩阵

Table 1. Results for each classification category from multiple experiments
表 1. 来自多个实验的每个分类类别的结果

实验次数	类别	Acc	Sen	Spe	Pre	F1-score
1	NPP	100%	100%	100%	100%	1
	EPH	98.15%	100%	97.67%	91.67%	0.9565
	PH	98.15%	100%	96.77%	95.83%	0.9787
2	NPP	100%	100%	100%	100%	1
	EPH	98.15%	100%	97.37%	94.12%	0.9697
	PH	98.15%	100%	97.44%	93.75%	0.9677
3	NPP	100%	100%	100%	100%	1
	EPH	96.3%	85.71%	100%	100%	0.9231
	PH	96.3%	86.67%	100%	100%	0.9286
4	NPP	100%	100%	100%	100%	1
	EPH	98.15%	92.86%	100%	100%	0.963
	PH	98.15%	95%	100%	100%	0.9744

Continued

	NPP	100%	100%	100%	100%	1
5	EPH	98.15%	100%	97.3%	94.44%	0.9714
	PH	98.15%	100%	97.37%	94.12%	0.9697
	NPP	100%	100%	100%	100%	1
Average	EPH	97.78%	95.71%	98.47%	96.05%	0.9567
	PH	97.78%	96.33%	98.32%	96.74%	0.9638

本研究结果表明, PPG 信号与肺动脉压密切相关, 肺循环压力受肺血流、肺血管容积、肺血管张力控制。病理上, 肺动脉压升高与心血管疾病[19]相关。如上所述, PPG 可以实时准确地反映心血管循环系统的关系, 为两者之间的关系提供了可靠的生理背景依据。同样, 模型的结果也验证了这种关系。

本文提出了一种基于光电容积脉搏波信号和预训练卷积神经网络的肺动脉压自动分类方法。该方法为无创、实时评估肺动脉压提供了有效工具。它尤其适用于持续监测肺动脉压, 而不会给患者带来疼痛和风险。此外, 这种方法可以很容易地应用于临床, 这是下一步的工作。一旦在更大的数据集中进行演示, 就可以更准确地训练模型。该模型还将与可穿戴设备相结合, 实现无创、连续、低成本、使用方便的肺动脉高压监测系统, 具有成为家庭监测设备的巨大潜力。

5. 结论

综上所述, 本文提出了一种基于光电容积脉搏波和预训练卷积神经网络的肺动脉压分类预测新方法。基于 MIMICII 的数据, 仅使用脉搏波信号, 使用 GoogLeNet 网络模型对肺动脉压进行分类, 显示出较高的准确率。通过分析脉搏波信号的生理意义及其特征, 建立了脉搏波信号与肺动脉压之间的内在联系。这种精度和灵敏度都是令人满意的。该方法在无创、方便诊断肺动脉高压事件方面具有广阔的应用前景。此外, 可以开发更复杂的技术, 从脉搏波信号中提取特征并优化深度学习模型, 以提高肺动脉高压预测的性能, 甚至可以与其他参数结合, 实现对更复杂疾病的诊断。

基金项目

国家自然科学基金 61805143、81700548。

参考文献

- [1] Obokata, M., Kane, G.C., Sorimachi, H., et al. (2020) Noninvasive Evaluation of Pulmonary Artery Pressure during Exercise: The Importance of Right Atrial Hypertension. *European Respiratory Journal*, **55**, Article ID: 1901617. <https://doi.org/10.1183/13993003.01617-2019>
- [2] Simonneau, G., Montani, D., Celermajer, D.S., et al. (2019) Haemodynamic Definitions and Updated Clinical Classification of Pulmonary Hypertension. *European Respiratory Journal*, **53**, Article ID: 1801913. <https://doi.org/10.1183/13993003.01913-2018>
- [3] Ryan, J.J., Huston, J., Kutty, S., et al. (2015) Right Ventricular Adaptation and Failure in Pulmonary Arterial Hypertension. *Canadian Journal of Cardiology*, **31**, 391-406. <https://doi.org/10.1016/j.cjca.2015.01.023>
- [4] Sakao, S., Tanabe, N., Kasahara, Y. and Tatsumi, K. (2014) Long-Term Survival of Japanese Patients with Pulmonary Arterial Hypertension Treated with Beraprost Sodium. An Oral Prostacyclin Analogue. *Internal Medicine*, **53**, 1913-1920. <https://doi.org/10.2169/internalmedicine.53.2573>
- [5] Badescu, D.B., Champion, H.C., Gomez Sanchez, M.A., et al. (2009) Diagnosis and Assessment of Pulmonary Arterial Hypertension. *Journal of the American College of Cardiology*, **54**, S55-S66. <https://doi.org/10.1016/j.jacc.2009.04.011>
- [6] D'Alto, M., Dimopoulos, K., Coghlan, J.G., et al. (2018) Right Heart Catheterization for the Diagnosis of Pulmonary Hypertension. *Heart Failure Clinics*, **14**, 467-477. <https://doi.org/10.1016/j.hfc.2018.03.011>

- [7] Rosenkranz, S. and Preston, I.R. (2015) Right Heart Catheterisation: Best Practice and Pitfalls in Pulmonary Hypertension. *European Respiratory Review*, **24**, 642-652. <https://doi.org/10.1183/16000617.0062-2015>
- [8] Shah, S., Boyd, G., Pyne, C.T., et al. (2014) Right Heart Catheterization Using Antecubital Venous Access: Feasibility, Safety and Adoption Rate in a Tertiary Center. *Catheterization and Cardiovascular Interventions*, **84**, 70-74. <https://doi.org/10.1002/ccd.25249>
- [9] Di Maria, M.V., Burkett, D.A., Younoszai, A.K., et al. (2015) Echocardiographic Estimation of Right Ventricular Stroke Work in Children with Pulmonary Arterial Hypertension: Comparison with Invasive Measurements. *Journal of the American Society of Echocardiography*, **28**, 1350-1357. <https://doi.org/10.1016/j.echo.2015.07.017>
- [10] Naeije, R., D'Alto, M. and Forfia, P.R. (2015) Clinical and Research Measurement Techniques of the Pulmonary Circulation: The Present and the Future. *Progress in Cardiovascular Diseases*, **57**, 463-472. <https://doi.org/10.1016/j.pcad.2014.12.003>
- [11] Rybynok, V., May, J.M., Budidha, K. and Kyriacou, P.A. (2013) Design and Development of a Novel Multi-Channel Photoplethysmographic Research System. 2013 IEEE Point-of-Care Healthcare Technologies (PHT), Bangalore, 16-18 January 2013, 267-270. <https://doi.org/10.1109/PHT.2013.6461336>
- [12] Tabara, Y., Igase, M., Okada, Y., et al. (2016) Usefulness of the Second Derivative of the Finger Photoplethysmogram for Assessment of End-Organ Damage: The J-SHIPP Study. *Hypertension Research*, **39**, 552-556. <https://doi.org/10.1038/hr.2016.18>
- [13] Hosseini, Z.S., Zahedi, E., Movahedian Attar, H., et al. (2015) Discrimination between Different Degrees of Coronary Artery Disease Using Time-Domain Features of the Finger Photoplethysmogram in Response to Reactive Hyperemia. *Biomedical Signal Processing and Control*, **18**, 282-292. <https://doi.org/10.1016/j.bspc.2014.12.011>
- [14] Liang, Y., Chen, Z., Ward, R. and Elgendi, M. (2018) Hypertension Assessment Using Photoplethysmography: A Risk Stratification Approach. *JCM*, **8**, 12. <https://doi.org/10.3390/jcm8010012>
- [15] Lin, S.-K., Hsiu, H., Chen, H.-S. and Yang, C.-J. (2021) Classification of Patients with Alzheimer's Disease Using the Arterial Pulse Spectrum and a Multilayer-Perceptron Analysis. *Scientific Reports*, **11**, Article No. 8882. <https://doi.org/10.1038/s41598-021-87903-7>
- [16] Radha, M., Fonseca, P., Moreau, A., et al. (2021) A Deep Transfer Learning Approach for Wearable Sleep Stage Classification with Photoplethysmography. *NPJ Digital Medicine*, **4**, 135. <https://doi.org/10.1038/s41746-021-00510-8>
- [17] Szegedy, C., Wei, L., Yangqing, J., et al. (2015) Going Deeper with Convolutions. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston, 7-12 June 2015, 1-9. <https://doi.org/10.1109/CVPR.2015.7298594>
- [18] Goldberger, A.L., Amaral, L.A.N., Glass, L., et al. (2000) PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. *Circulation*, **101**, e215-e220. <https://doi.org/10.1161/01.CIR.101.23.e215>
- [19] Brida, M. and Gatzoulis, M.A. (2018) Pulmonary Arterial Hypertension in Adult Congenital Heart Disease. *Heart*, **104**, 1568-1574. <https://doi.org/10.1136/heartjnl-2017-312106>