

中图法分类号: 文献标识码: 文章编号: 1006-8961(XXXX)XX-0001-31

论文引用格式: Wei Yuanwang, Du Xinyue, Jie Ouyang, Wang Chaochao, Wang Sheng, Zhang Xianchao. A Review of Non-contact Blood Pressure Measurement Technology Based on Remote Photoplethysmography[J/OL]. Journal of Image and Graphics, XXXX:1-31. DOI: 10.11834/jig.260268.
(魏远旺, 杜欣悦, 欧阳杰, 王超超, 王胜, 张先超. 远程光电容积描记的非接触血压测量技术综述[J/OL]. 中国图象图形学报, XXXX:1-31. DOI: 10.11834/jig.260268.)[DOI:10.11834/jig.260268]

远程光电容积描记的非接触血压测量技术综述

魏远旺^{1,2,3}, 杜欣悦^{1,2}, 欧阳杰¹, 王超超^{1,2,3}, 王胜⁴, 张先超^{1,2,3}

1. 嘉兴大学 全省多模态感知与智能系统重点实验室, 浙江 嘉兴 314001; 2. 嘉兴大学 信息科学与工程学院, 浙江 嘉兴 314001;
3. 嘉兴大学 生命健康智能感知浙江省工程研究中心, 浙江 嘉兴 314001; 4. 嘉兴大学附属中医医院, 浙江 嘉兴 314001

摘要: 基于远程光电容积描记(remote photoplethysmography, rPPG)的非接触式血压测量技术,利用普通摄像头捕捉面部皮肤的光容积变化,经图像处理与信号分析提取脉搏波信息,实现收缩压与舒张压的连续估计。相较于传统袖带式及接触式光电容积描记法,rPPG在舒适性、便利性和长期监测方面具有显著优势,已成为远程医疗与日常健康监测的重要研究方向。本文系统综述了rPPG血压估计的生理基础、信号预处理、特征提取策略及估算模型。详细梳理了面部检测与ROI提取、信号去噪、运动伪影抑制及光照鲁棒性等关键技术;从脉搏波传导时间、脉搏波速度及多维度特征阐述了血压估算的生理机制;归纳了传统机器学习与深度学习方法的原理、架构与性能,并总结了公开数据集与评价指标。尽管rPPG血压估计前景广阔,仍面临个体生理差异与校准需求、跨场景/跨设备泛化不足、边缘计算实时性及隐私伦理等挑战。本文展望了自监督学习、多模态融合和边缘AI部署等方向,旨在为rPPG无创血压测量技术的发展提供系统性参考。

关键词: 远程光电容积描记(rPPG);非接触式血压测量;深度学习;信号处理;脉搏波传导时间;多模态融合

A Review of Non-contact Blood Pressure Measurement Technology Based on Remote Photoplethysmography

Wei Yuanwang^{1,2,3}, Du Xinyue^{1,2}, Jie Ouyang¹, Wang Chaochao^{1,2,3}, Wang Sheng⁴, Zhang Xianchao^{1,2,3}

1. Provincial Key Laboratory of Multimodal Perceiving and Intelligent Systems, Jiaxing University, Jiaxing Zhejiang 314001, China; 2. College of Information Science and Engineering, Jiaxing University, Jiaxing Zhejiang 314001, China; 3. Engineering Research Center of Intelligent Human Health Situation Awareness of Zhejiang Province, Jiaxing University, Jiaxing Zhejiang 314001, China; 4. Jiaxing Hospital of Traditional Chinese Medicine, Jiaxing University, Jiaxing, 314001, China

Abstract: Hypertension remains a major global public health burden and the leading modifiable risk factor for cardiovascular diseases, cerebrovascular accidents, and chronic kidney disease. Continuous, non-invasive, and long-term blood pressure (BP) monitoring is paramount for early diagnosis and screening, therapeutic efficacy evaluation, and personalized cardiovascular risk stratification. Traditional cuff-based sphygmomanometers, while widely adopted as clinical gold standards, induce physical discomfort, cause sleep disturbance, and provide only discrete, intermittent measurements that fail to capture intra-individual BP variability, nocturnal dips, or transient hypertensive crises. Although contact photoplethysmography (PPG) sensors offer continuous monitoring capabilities, they remain susceptible to motion artifacts and can cause skin erythema, irritation, or compromise of skin integrity—particularly in vulnerable populations such as neonates,

收稿日期: 2026-05-14; 修回日期: 2026-09-01

基金项目: 国家重点研发计划资助(2025YFF0515400); 浙江省重点基金项目(ZCLZ25F0201); 浙江省中医药科技计划项目(2026ZL0867)

Supported by: National Key R&D Program of China (Grant No. 2025YFF0515400); Zhejiang Provincial Natural Science Foundation of China (Grant Nos. ZCLZ25F0201); Zhejiang TCM Science and Technology Initiative (Grant No. 2026ZL0867)

burn patients, and intensive care unit (ICU) cohorts. Remote photoplethysmography (rPPG) has emerged as a transformative, non-contact optical sensing paradigm. By capturing subtle facial skin color variations induced by cardiac-driven hemodynamic changes via ambient-light digital cameras, rPPG enables continuous estimation of systolic blood pressure (SBP) and diastolic blood pressure (DBP) without physical contact. This paper presents a systematic and comprehensive review of the entire rPPG-based BP measurement pipeline, encompassing physiological foundations, optical sensing mechanisms, video preprocessing protocols, feature extraction strategies, machine learning and deep learning modeling paradigms, public benchmark datasets, evaluation metrics, and barriers to clinical translation. The physiological rationale of rPPG hinges on microvascular hemodynamics and modern skin optics. During each ventricular ejection, a pressure pulse propagates through the systemic arterial tree, causing periodic blood volume fluctuations in dermal microvascular beds. These micro-circulatory variations alter the spectral absorption coefficient of hemoglobin, generating subtle, periodic intensity changes in diffusely reflected light from the facial skin surface. Converting these minute optical signals into continuous BP estimates relies on vascular biomechanics and hemodynamic principles. The classical pulse transit time (PTT) framework—derived from the Moens-Korteweg equation—establishes a mathematical relationship between arterial compliance, vessel elasticity, pulse wave velocity (PWV), and blood pressure. PTT-based models directly map the propagation delay—measured between the ECG R-wave peak (or a proximal PPG fiducial point) and a distal rPPG peak—to arterial pressure. To overcome the requirement of dual-site measurement, single-site pulse wave morphology (PWM) analysis has gained prominence. PWM strategies extract multi-dimensional morphometric features—such as pulse wave area ratios, maximal systolic upstroke slope, reflection index, augmentation index, and diastolic decay time constants—from a single facial rPPG waveform to characterize systemic vascular resistance, arterial stiffness, and cardiac contractility. Acquiring high-fidelity, hemodynamically valid rPPG signals in unconstrained environments demands rigorous signal preprocessing to isolate subtle physiological variations from severe background noise. The primary stage involves face detection, facial landmark alignment, and region-of-interest (ROI) tracking. Modern deep learning architectures (e.g., MTCNN, MediaPipe, YOLO) enable robust facial tracking, maintaining spatiotemporal ROI alignment even under subject motion. However, raw ROI temporal signals remain vulnerable to three main environmental distortions: voluntary and involuntary head motion, ambient illumination fluctuations, and video compression artifacts. Motion artifact suppression algorithms utilize time-frequency filtering, adaptive filtering, empirical mode decomposition (EMD), blind source separation (BSS) and skin-color projection models (e.g., POS, CHROM, PBV) to isolate the blood volume pulse (BVP) vector from motion-induced noise. To combat severe quantization noise and high-frequency spatial distortion introduced by video compression codecs, recent rPPG-oriented compression algorithms dynamically reallocate bitrate budgets, prioritize quantization parameters within highly perfused facial ROIs, and utilize temporal motion-compensated frame reconstruction to preserve subtle hemodynamic signals at ultra-low bitrates. Feature engineering and predictive modeling represent the core analytical engine for non-contact BP estimation. Early methodologies extracted handcrafted temporal, spectral, and morphological parameters (e.g., heart rate variability, harmonic power ratios, pulse envelope decay time constants), coupling them with traditional regression models such as Support Vector Regression (SVR), Random Forests, Gaussian Process Regression, and Gradient Boosted Decision Trees (XGBoost). While highly interpretable and computationally lightweight, handcrafted feature engineering often fails to represent complex, non-linear arterial compliance changes across variable physiological states. Consequently, deep learning paradigms have become the predominant modeling approach. End-to-end Convolutional Neural Networks (CNNs) extract spatiotemporal feature maps directly from video frame stacks or spatiotemporal maps (STMaps), effectively bypassing handcrafted feature extraction. Recurrent Neural Networks (RNNs), Long Short-Term Memory (LSTM) networks, and spatiotemporal Transformers capture long-range temporal dependencies and sequential dynamics inherent in continuous pulse wave trains. Furthermore, multi-task joint learning frameworks simultaneously optimize rPPG signal reconstruction and BP parameter regression, significantly mitigating cascading error propagation across multi-step pipelines. Despite substantial advances on benchmark datasets evaluated under AAMI and ISO 81060-2 clinical standards, critical bottlenecks impede real-world clinical translation. First, individual physiological heterogeneity—including pigmentation variations across skin types, age-related vessel wall calcification, obesity, and autonomic nervous system tone—demands subject-specific baseline calibration, limiting universal model zero-shot transferability. Second,

environmental and hardware domain shifts—such as low-light conditions, multi-source mixed lighting in ICUs, camera sensor noise, and facial occlusions (e. g., medical dressings, oxygen masks)—cause severe signal degradation. Third, the high computational complexity of 3D-CNNs and vision Transformers limits real-time execution on resource-constrained edge computing devices. Finally, continuous facial video capture raises stringent data privacy, biometric security, and ethical compliance issues that must be carefully governed. To bridge the gap between proof-of-concept laboratory research and reliable clinical integration, future research must focus on three strategic domains: 1) Self-supervised learning and cross-domain generalization. Self-supervised pre-training on massive unlabeled video repositories enables the learning of feature representations that are robust to variations in illumination, motion, and skin pigmentation, thereby reducing reliance on scarce clinically annotated BP data. When combined with meta-learning, domain-adversarial networks, and zero-shot calibration frameworks, such approaches allow models to adapt to diverse demographic characteristics and varying optical environments without requiring invasive individual baseline recalibration, substantially enhancing cross-scenario generalization capability. 2) Multimodal fusion and edge-AI deployment. The synergistic integration of rPPG with thermal imaging, near-infrared (NIR) sensing, ballistocardiography (BCG), or wearable sensors preserves signal integrity under conditions of facial occlusion or extreme illumination, accommodating both high-precision and lightweight application scenarios. Concurrently, model compression techniques—including pruning, quantization, knowledge distillation, and hardware-aware neural architecture search (NAS)—reduce inference latency to the millisecond level, enabling real-time continuous BP inference on mobile or embedded devices to meet the urgent alerting requirements in neonatal intensive care and postoperative monitoring. 3) Privacy-preserving computation and ethical compliance. Federated learning paradigms and on-device processing pipelines safeguard patient biometric privacy and ensure compliance with global healthcare data regulations, promoting the responsible and trustworthy development of the technology. In summary, rPPG-based non-contact blood pressure estimation represents a paradigm shift in cardiovascular healthcare technology. By systematically addressing current physiological, algorithmic, and operational challenges, this technology holds immense potential to realize ubiquitous, unobtrusive, and continuous cardiovascular monitoring across smart home care, clinical ICUs, telemedicine, and digital health ecosystems.

Key words: remote photoplethysmography (rPPG); non-contact blood pressure measurement; deep learning; signal processing; pulse transit time; multimodal fusion

2 中图法分类号: TP391

文献标识码: A 文章编号: 1006-8961(2026年) -

论文引用格式: [DOI: 10. 11834/jig. 260268]

0 引言

心血管疾病严重威胁人类健康, 高血压是全球心血管发病和死亡的主要可调控风险因素, 也是冠心病、脑卒中及心力衰竭的关键危险因素(Cheng等, 2025)。血压水平与心脑血管事件发生风险呈连续正相关: 收缩压(systolic blood pressure, SBP)每升高 20 mmHg 或舒张压(diastolic blood pressure, DBP)每升高 10 mmHg, 心脑血管病风险倍增(Fang等, 2018)。在诊室条件下, 非同日三次测量 SBP $\geq$ 140 mmHg 或 DBP $\geq$ 90 mmHg 可诊断为高血压(Taha等, 2017)。由于高血压常被称为“沉默杀手”, 早期往往无明显症状, 因此血压测量是评估血压

水平、诊断高血压及评价降压治疗效果的基石(Lu等, 2020)。

常见血压测量方法可分为接触式与非接触式两大类。接触式方法分为有创和无创两种: 有创测量(如动脉置管法)精度高、可连续监测, 通常用于重症监护室(intensive care unit, ICU)等场景; 无创测量包括袖带式血压计和光电容积描记法(photoplethysmography, PPG)。袖带式血压计通过袖带充气加压, 检测动脉搏动引起的压力振荡计算 SBP 和 DBP; PPG 利用光电传感器检测周围皮下毛细血管血容量变化, 需传感器直接接触皮肤获取脉搏波信号(Chen等, 2024)。然而, 接触式 PPG 长期贴合易引起不适或皮肤刺激, 且在运动状态下易产生伪影, 限制了其在新生儿监护、烧伤护理及居家长期监测等场景中的应用。为克服上述局限, 非接触式血压测量基于 rPPG、雷达等技术采集面部或身体表面生理信号, 结合信号处理与机器学习方法进行血压估计,

在舒适性、用户依从性和连续监测方面具有显著优势。

rPPG 技术利用普通摄像头(如智能手机或电脑摄像头)采集数据,大幅降低设备成本,且可提取心率、呼吸频率、血氧饱和度及血压等多参数生理指标(Salim 和 Khidhir, 2024),在早期筛查和日常健康管理中展现独特价值。基于视频的 rPPG 无需直接接触,可降低交叉感染风险(Dasari 等, 2025),适用于个人健康管理及远程医疗场景。鉴于摄像头的广泛普及,基于 rPPG 的被动高血压筛查有望通过优化血压控制降低心血管并发症,带来显著的临床与卫生经济学价值。此外,现有研究表明(Alić 等, 2023; Curran 等, 2023; Selvaraju 等, 2022),rPPG 技术因其非接触、可连续监测的特点,有望弥补传统袖带式血压计在普通病房及 ICU 患者中无法实现连续、无感监测的不足,为临床护理提供新的技术手段。

近年来,基于 rPPG 的血压估计方法已涌现多篇综述。Lu 等人(2020)虽较早提出了 rPPG 波形测量、特征提取、血压估计的三步分析框架,但未能涵盖深度学习方法。El Boussaki 等人(2022)探讨了基于视频的心率、呼吸频率和血压估计,但对血压估计环节的技术分析较为简略,未深入探讨各环节演进规律与性能瓶颈。Curran 等人(2023)系统评估了 rPPG 在真实临床场景中的可行性与局限性,侧重于临床应用框架,未涉及技术实现细节。Chen 等(2024)系统涉及 rPPG 技术在心率、心率变异性、血压等七项生理参数的应用进展,并梳理了信号质量评估、无袖带血压估计方法以及昼夜节律对血压的影响,但重点在于算法层面梳理,未将感兴趣区域(region of interest, ROI)选择与追踪策略作为独立分析维度。

上述综述从算法优化、临床应用和技术架构等角度进行了梳理,但鲜有从 ROI 选择与追踪这一信号获取环节对技术路线进行系统分析。ROI 选择与追踪直接决定 rPPG 信号的输入质量,是连接原始视频与血压估计模型的关键环节,其空间定位与追踪精度直接影响后续信号处理与估计准确性,然而已有综述对该环节的生理基础、方法演进及临床适应边界的分析尚不充分。基于上述分析,已有综述虽各有侧重,但仍存在以下关键空白,故本文提出专门针对血压估计的文献综述。

本文面向人脸视频非接触式血压测量技术,系统梳理 rPPG 方法的研究进展、关键技术问题及应用

前景。区别于已有综述侧重算法归纳的范式,本文以临床应用为导向,将影响测量精度的多源因素及其生理学基础作为贯穿全文的分析主线。首先阐述 rPPG 工作原理及其与血压的关联机制;进而从临床痛点出发,分析影响信号质量的关键因素及生理学机制,并在此基础上讨论血压估计的生理基础、特征提取方法及从传统机器学习到深度学习的估计方法;汇总公开数据集与评估指标,对比不同方法的性能;最后总结关键挑战并展望未来方向。此外,本文以 ROI 选择与追踪策略的演进脉络为组织主线,将面部血管解剖特征与信号质量量化评估贯穿于技术分析,系统梳理了从固定 ROI 到动态自适应多区域策略的演进路径,明确了各类方法的适用场景与局限性,旨在为 rPPG 非接触式血压测量研究提供系统的技术参考与临床决策依据。

1 rPPG 技术基础

1.1 rPPG 原理与信号来源

rPPG 是一种非接触式光学测量技术,通过分析人体皮肤表面血容量变化引起的细微颜色变化提取远程光电容积描记信号(Imai 等, 2025)。其生理基础源于心脏泵血活动引发的皮下血容量周期性变化,导致皮肤组织对入射光的吸收和散射特性发生同步改变,使经皮肤组织散射后的漫反射光携带血容量的脉动信息。摄像头捕捉上述波动后,再利用信号处理方法提取反映心血管活动的 rPPG 信号(Pirzada 等, 2024)。多数研究选择绿色通道作为主信号源,因为绿光(波长约 550 nm)在皮肤中的穿透深度(0.5~2 mm)与浅表微血管分布层匹配,且 RGB 相机 Bayer 滤波阵列中绿色通道采样率最高,信噪比优于其他通道。

1.2 rPPG 与血容量变化、脉搏波传导的关系

rPPG 通过光学方式探测皮下血容量变化,这是其信号产生的直接生理基础。图 1 展示了血容量变化与光吸收反射波动关系图。心脏收缩时,左心室泵血使外周微血管床血容量瞬时增加;舒张时,主动脉瓣关闭,血管弹性回缩,血容量相应减少。该周期性变化导致皮肤对入射光的光吸收总量及反射光强度发生微小波动,使 rPPG 信号成为血容量脉搏波的光学表现形式。

此外,心脏搏动产生的压力波沿动脉系统传播

形成脉搏波,其传播速度称为脉搏波速度(pulse wave velocity, PWV)(Zeng 等, 2025)。PTT 指脉搏在动脉系统两个不同部位间的传播时间间隔。基

于多部位同步采集的 rPPG 信号,或 rPPG 与心电信号(electrocardiogram, ECG)的联合分析,可估算脉搏波传导特性,进而实现血压估计。




图1 血容量变化与光吸收反射波动关系图

Fig. 1 Relationship between blood volume change and light absorption reflection fluctuation

2 rPPG 信号预处理技术

从原始面部视频中获取高质量的 rPPG 脉搏波信号,是实现高精度非接触式血压估计的基础与前提。由于视频信号在采集过程中易受受试者运动、环境光照及视频压缩失真等多种因素的干扰,导致信号质量显著退化。因此,需采取系统性的预处理策略,对原始信号进行增强与伪影抑制,是保障后续血压估计算法性能的关键环节。如图 2 所示,该预处理流程主要包含面部检测与 ROI 提取、信号去噪

两大阶段,下文将对上述各个步骤的关键技术进行详细阐述。

2.1 面部检测与感兴趣区域提取

2.1.1 面部检测方法

面部检测是 rPPG 信号提取的第一步,旨在从视频帧中准确定位人脸区域。面部检测算法可分为传统方法和现代方法。传统算法如 Viola-Jones 算法 (Viola 和 Jones, 2004),通过级联分类器快速检测图像中的人脸区域,为后续 ROI 选择提供初始边界框,计算效率高且适合资源受限。现代方法主要包括多任务级联卷积网络 (multi-task cascaded convolu-




图2 rPPG信号预处理总体流程图

Fig. 2 Overall flowchart of rPPG signal preprocessing

tional networks, MTCNN) (Zhang 等, 2016)、RetinaFace、YOLO 系列及 Dlib 库等。其中, MTCNN 通过三阶段级联卷积神经网络精确输出面部关键点; Dlib 库提供高质量的人脸检测和关键点定位功能, 其内置检测器涵盖传统 HOG 与深度学习两种方案; YOLO 系列作为实时目标检测框架, 经适当训练后可快速识别图像中的人脸。总体而言, 基于深度学习的现代方法在检测精度与定位准确性上显著优于传统方法, 但对计算资源要求也更高。

2.1.2 ROI选择与追踪

在完成面部检测后, 需从面部区域中筛选出血液灌注丰富、运动伪影较少的皮肤区域作为 ROI, 以提取高质量的 rPPG 信号。早期研究多采用固定 ROI, 近年来动态跟踪和自适应 ROI 选择逐渐成为主流。表 1 总结了典型文献中采用的 ROI 区域及跟踪方法, 如图 3 展示了常见 ROI 选取策略的示意图。

从表 1 可以看出, 全脸区域是早期 rPPG 研究常用的 ROI, 通过对大量像素空间平均可有效抑制随

机噪声。然而, 全脸包含眼部、嘴部、毛发等非皮肤区域, 且面部表情活动(如眨眼、说话)会引入显著运动伪影, 在重症监护、新生儿监测等场景中稳定性不足。此类 ROI 的定位以手动标注、Viola-Jones 检测和 KLT 光流跟踪为主, 缺乏面部关键点精确定位, 难以适应头部转动引起的透视变形。

鉴于上述局限, 研究者逐步转向选取面部局部区域(如前额、脸颊、鼻子)乃至手掌作为 ROI。前额血管走行平直、受表情肌活动影响最小, 信号波形规整 (Lewandowska 等, 2011; Hou 等, 2025); 脸颊血管密度高且与表情肌存在一定分离, 受咀嚼等活动影响较小 (Bondarenko 等, 2025); 鼻子血管丰富但软骨较多, 易受呼吸调制且镜面反射严重 (Kossack 等, 2021); 手掌皮肤薄、血管网密集, 适用于面部遮挡场景 (Wuerich 等, 2021)。

局部 ROI 的精确提取依赖面部地标检测技术。Dlib 库提供基于 HOG 的传统方案与基于 CNN 的深度学习方案, 后者在精度与速度间取得平衡; MediaPipe 采用轻量化 CNN 每帧预测 468 个三维面部地

表 1 总结 ROI 及追踪方法

Table 1 Summary of ROI and tracking methods

感兴趣区域(ROI)	文献	ROI 追踪方法	通道
全脸区域	Poh 等人(2010); Wei 等人(2013); De Haan 等人(2013); Tran 等人(2015); Haque 等人(2016)	手动/Viola-Jones 人脸检测/Kanade-Lucas-Tomasi (KLT)光流法追踪器	R,G,B
前额/前额与脸颊/ 前额、脸颊和鼻子/ 前额与手掌区域	Scalise 等人(2012); Yan 等人(2015); Ryu 等人(2021);Casalino 等人(2023); Su 等人(2023); Ponmani 等人(2025); Barhate 等人(2025); Dasari 等人(2025)	手动/混合面部地标检测	R,G,B/R,G,B(选择 G)
眼睛和嘴唇之间的 区域(双颊合并)	Yu 等人(2013); Huang 等人(2021)	基于几何约束的 ROI 定位/ Dlib 和核相关滤波器 (KCF)追踪	R,G,B/R,G,B(选择 G)
动态/自适应 ROI 选择	Pirzada 等人(2022); Gao 等人(2023); Qian 等人(2023); Zhao 等人(2024); Hao Lu 等人(2024); Si-Qi Liu 等人(2024)	基于信噪比动态选择/基 于密集空间划分/基于融 合策略/基于完全自适应	R,G,B, IR, 深度/R,G,B(选 择 G)/R,G,B

标,可动态剔除遮挡或运动剧烈区域,显著提升鲁棒性,但在深肤色人群中的检测精度仍需验证(Zeng 等, 2025)。

在局部固定区域中,双颊因血流灌注丰富和双侧对称性常被单独提取。Yu 等人(2013)采用基于两眼间距的几何约束估算 ROI,实现简单但依赖眼部检测精度,对佩戴眼镜或眼罩场景鲁棒性差;Huang 等人(2021)采用 Dlib 结合核相关滤波器(kernelized correlation filter, KCF)跟踪器,以检测与跟踪分离的架构兼顾定位精度与计算效率。

进一步地,动态自适应多区域选择策略以数据驱动方式实时评估各候选区域信号质量,动态确定最优 ROI 配置。现有方法主要包括:基于信噪比(signal noise ratio, SNR)或脉动强度的信号质量优选、基于密集空间划分的子单元加权融合、多区域信号互补融合,以及不依赖预定义模板的全自适应方法。总体而言,ROI 提取的准确性直接影响 rPPG 信号质量,未来研究将朝向动态、自适应、多区域融合的方向发展。

2.1.3 rPPG 信号提取

选定 ROI 后,需从像素时序变化中提取脉搏波(blood volume pulse, BVP)信号。根据处理范式,rPPG 信号提取方法可分为空间平均法、投影分离法、色度模型法、超像素聚合法及深度学习方法。表

2 归纳了各类方法的代表性工作及其核心思想。

空间平均法通过计算 ROI 内像素的平均值或加权平均值获得原始信号,计算效率高,但对运动伪影等系统性干扰敏感。投影分离法利用主成分分析(principal component analysis, PCA)或独立成分分析(independent component analysis, ICA)对 RGB 多通道时序信号进行盲源分离(blind source separation, BSS),无需先验知识即可分离出脉搏波成分,但在运动场景下性能下降。色度模型法通过构建颜色通道的线性组合抑制干扰,代表性方法包括基于色度的方法(chrominance-based method, CHROM)和皮肤正交平面法(plane orthogonal to skin method, POS),后者将 RGB 信号投影到与肤色正交的平面,已成为传统方法中应用最广泛的方案。超像素聚合法将 ROI 分割为多个超像素分别提取后再聚合,可在保留空间细节的同时提高信噪比。深度学习方法以端到端方式从视频帧中学习时空特征,自动关注最优区域和关键时段,在复杂环境下表现优异,但依赖大规模标注数据。

近年来,基于信号质量评估的自适应融合策略(如基于 SNR 的动态 ROI 选择、多头交叉注意力机制)进一步提升了提取鲁棒性。未来研究将探索轻量化、自监督的深度提取框架,以适应移动端和实时应用需求。

表 2 常见 rPPG 信号提取方法

Table 2 Common rPPG signal extraction methods

文献	年份	方法类型	代表方法	核心思想	计算公式
Vekruysse 等人	2008	简单平均	像素平均	ROI 内所有像素权重平均	$\overline{C_t} = \frac{1}{N} \sum_{i=1}^N C_{t,i}$
Vekruysse 等人	2008	加权平均	高斯加权平均	中心区域权重高, 边缘权重低	$w_i = -\frac{(x_i - x_c)^2 + (y_i - y_c)^2}{2\sigma^2}$ $\overline{C_t} = \frac{\sum w_i C_{t,i}}{\sum w_i}$
Poh 等人	2010	投影分离	ICA	盲源分离, 提取独立生理信号	$S = W \cdot [R, G, B]^T$
Lewandowska 等人	2011	投影分离	PCA	提取 RGB 信号中的主成分	$S = PCA_1([R, G, B]^T)$
De Haan 等人	2013	色度模型	CHROM	利用色度信号抑制运动伪影	$X_s = 3R - 2G$ $Y_s = 1.5R + G - 1.5B$ $S = \frac{X_s - \alpha Y_s}{\sigma(Y_s)}$
Wang 等人	2017	色度模型	POS	投影到与肤色平面正交方向	$S = \frac{G - B}{G + B - 2R}$
Bobbia 等人	2018	超像素聚合	超像素平均	超像素内平均后再聚合	$S = \sum_{m=1}^M \frac{1}{N_m} \sum_{i \in SP_m} C_{t,i}$
Bobbia 等人	2019	皮肤概率加权	皮肤分割加权	基于皮肤概率加权平均	$\overline{C_t} = \frac{\sum P_{skin}(i) C_{t,i}}{\sum P_{skin}(i)}$
Lu 等人	2021	深度学习	CNN 特征提取	端到端学习时空特征	$S = CNN(ROI_{patch})$
Duan 等人	2023	自适应追踪	动态 ROI 选择	基于 SQI/SNR 动态选择可用 ROI	$S = \frac{\sum_{i \in \nu} SQI_i \cdot C_i}{\sum SQI_i}$ $w_k = f(SNR_k)$
Qian 等人	2023	注意力机制	时空注意力	动态选择重要区域与帧	$\alpha = Attention(C)$ $S = \sum \alpha_i t C_{t,i}$
Li 等人	2024	子区域融合	多区域加权融合	多个生理区域信号加权组合	$S = \sum_{k=1}^K w_k S_k$
Gansan 等人	2025	频域分析	快速傅里叶变换	主要用于面部视频分析中的噪声识别	$X[k] = \sum_{n=0}^{N-1} x[n] e^{-j\frac{2\pi}{N}kn}$
Barhate 等人	2025	色度模型	CHROM	利用色度信号抑制光照变化	$X_s = R - G$ $Y_s = R + G - 2B$ $S = X_s - \alpha Y_s$
Roha 等人	2025	注意力机制	多头交叉注意力融合	自动识别关键区域, 跨模态信息交互	$Q_{PPG} = X_{PPG} W^Q, K_{VPPG} = X_{VPPG} W^K,$ $V_{aPPG} = X_{aPPG} W^V$ $Att(Q_{PPG}, K_{VPPG}, V_{aPPG}) = \text{soft max} \left(\frac{Q_{PPG} K_{VPPG}^T}{\sqrt{d_k}} \right)$ $MHCA(Q_{PPG}, K_{VPPG}, V_{aPPG}) = \text{Concat}(\text{head}_1, \dots, \text{head}_h) W^O$

注: $\overline{C_t}$ 为 ROI 内所有像素在 t 时刻的颜色通道平均值; N 为 ROI 内的像素总数; $C_{t,i}$ 为第 i 个像素在 t 时刻的颜色通道值; w_i 为第 i 个像素的权重系数; (x_i, y_i) 为第 i 个像素的坐标; (x_c, y_c) 为 ROI 中心坐标; σ 为高斯核的标准差; S 为提取的脉冲信号; $PCA_1(\cdot)$ 为提取第一主成分的操作; $[R, G, B]^T$ 为 RGB 三通道信号构成的列向量; W 为独立成分分析求解的分离矩阵; X_s 和 Y_s 为 CHROM 模

型中的色度信号; $\alpha = \frac{\sigma(X_s)}{\sigma(Y_s)}$ 为标准差比值; $\sigma(\cdot)$ 为标准差函数; SP_m 为第 m 个超像素区域; N_m 为第 m 个超像素内的像素总数; M 为超像素的总数; $CNN(\cdot)$ 为卷积神经网络的特征提取函数; ROI_{patch} 为从视频中提取的 ROI 图像块; w_k 为第 k 个 ROI 的融合权重; S_k 为第 k 个 ROI 提取的信号; K 为 ROI 总数; $\alpha_{i,t}$ 为第 i 个像素在 t 时刻的注意力权重; $X[k]$ 为频域信号; $x[n]$ 为时域离散信号序列; j 为虚数单位; X_s 和 Y_s 为改进 CHROM 模型中的色度信号; R, G, B 分别为红、绿、蓝三通道信号值; X_{PPG} 为 PPG 信号特征; X_{vPPG} 为速度 PPG 信号特征; X_{aPPG} 为加速度 PPG 信号特征; W^Q, W^K, W^V 分别为查询、键、值的权重矩阵; Q_{PPG} 为查询矩阵; K_{vPPG} 为键矩阵; V_{aPPG} 为值矩阵; $Att(\cdot)$ 为注意力函数; d_k 为键向量的维度; $soft\ max(\cdot)$ 为归一化指数函数; $MHCA(\cdot)$ 为多头交叉注意力函数; $head_i$ 为第 i 个注意力头的输出; h 为注意力头的数量; $Concat(\cdot)$ 为拼接操作; W^O 为输出权重矩阵。

进一步分析可知, 固定区域方法计算量低、实现



((a) using the forehead region to extract signals (Verkruijsse et al , 2008) ; (b) setting a 4040 pixel ROI covering the entire face to extract signals (Imai et al , 2025) ; (c) template-based ROI tracking algorithm (Zhang et al , 2017) ; (d) selection of left cheek, right cheek and chin regions (W. Xing et al , 2024) ; (e) ROI selection using neural network (Egorov et al , 2025) ; (f) selection of the region with the best signal-to-noise ratio (Pirzada et al , 2022) ; (g) selection of cheek region as ROI and tracking using KLT (Yang et al , 2025) ; (h) selection of forehead, left cheek and right cheek regions (Barhate et al , 2025) ; (i) recognition and tracking of forehead and palm regions using Google Mediapipe (Dasari et al , 2025) ; (j) face detection using CNN combined with Dlib, with eyes, eyebrows, nose and mouth as ROIs (Ponmani et al , 2025) ; (k) forehead and cheek based on pupil positioning (Favilla et al , 2019) ; (l) dividing the whole face into small patches, tracking with KLT, and selecting the optimal patch based on illumination, light variation and signal-to-noise ratio (Song et al , 2022) ; (m) using Mediapipe to identify 31 facial ROI candidate regions (Kim et al , 2021))

图3 ROI选取示意图

Fig. 3 Schematic diagram of ROI selection

简单,适用于静止受控环境,但受试者位移易导致ROI偏移至非皮肤区域。动态跟踪与多区域选择可实时适应运动干扰,但显著增加计算开销。基于信号质量的优化方法通过计算SNR评估区域信号质量,但需一定信号长度,实时性受限。深度学习方法可动态融合多ROI信息并自适应调整权重,增强复杂条件下的泛化能力,但依赖大量标注数据。ROI提取准确性直接影响rPPG信号质量,未来需探索更精准的ROI选择与处理方法以应对复杂应用场景。

2.2 信号去噪

由于采用非接触采集方式,rPPG信号极易受到运动伪影、光照变化及视频压缩失真等因素干扰。信号去噪是rPPG处理的关键环节,常用技术包括带通滤波、BSS、经验模态分解(empirical mode decomposition, EMD)及其变体,以及小波变换(wavelet transform, WT)。

带通滤波是最基础的去噪方法,通过允许特定频率范围内的信号通过并抑制带外成分实现分离(Qin等, 2022)。滤波器设计需确定类型、截止频率和阶数,Butterworth滤波器因其平坦的通带响应被广泛采用。常见截止频率范围包括0.5–8 Hz、0.7–5 Hz、0.75–8.0 Hz及更窄的0.7–3.0 Hz。Zeng等人(2025)使用四阶带通滤波器(1–4 Hz)抑制低频漂移;Huang等人(2017)采用有限脉冲响应带通滤波器(0.75–3 Hz)增强脉搏波质量。带通滤波简单高效、实时性好,但其假设信号与噪声在频域可分离,在临床复杂场景中往往不成立。运动伪影与脉搏信号频域重叠,尤其在新生儿心率可达160–180 bpm(对应基频约2.7–3.0 Hz)时,心率基频已接近运动伪影主要频率(1–5 Hz),简单带通滤波难以有效分离。

BSS假设观测信号由多个统计独立的源信号线性混合而成,通过变换将其还原为独立源信号(Lin和De Haan, 2014)。ICA属于BSS,通过最大化统计独立性分离出脉搏波成分,无需先验知识,但在运动场景下性能下降。Poh等人(2011)率先将ICA应用于rPPG提取,证明其在运动鲁棒性方面的优势。PCA通过正交变换将相关变量转换为线性不相关主成分,常用于预处理与特征压缩;Lewandowska等人(2012)将PCA应用于rPPG提取,在准确性和计算速度上均优于ICA。BSS基于统计独立性的假设在临床中面临挑战:血流动力学变化与运动干扰并非完

全独立,例如咳嗽或说话时肌肉活动与血流脉动同时发生,统计依赖性增强导致分离效果下降。此外,BSS通常依赖多通道输入,在单通道场景中应用受限。

EMD是一种数据驱动的自适应时频分析方法,将信号按局部时频特性分解为一系列本征模态函数(intrinsic mode function, IMF)(Lu等, 2020),有效分离不同频率成分和噪声。为解决模态混叠问题,研究者开发了集成经验模态分解(ensemble empirical mode decomposition, EEMD)、变分模态分解(variational mode decomposition, VMD)和完全集成经验模式分解(complex complete ensemble empirical mode decomposition with adaptive noise, Complex CEEMDAN)等改进方法(Fang等, 2024; Jiang等, 2023; Ma等, 2025)。EEMD通过添加高斯白噪声并多次分解取平均抑制模态混叠(Fang等, 2024)。VMD将信号分解为具有特定中心频率和有限带宽的准正交模态函数,可根据信号自身特性自适应分解,在处理非平稳噪声方面优于传统滤波器。Yang等人(2025)发现VMD可有效去除基线漂移,将信号质量指标从0.1534提升至0.4022。Complex CEEMDAN适合分解复杂、非线性和非平稳信号;Ma等人(2025)利用其对雷达信号分解提取心跳相关IMF,输入神经网络估计连续血压波形。然而,EMD及其改进方法计算复杂度较高,在实时报警的场景中可能引入延迟;IMF选择仍需人工经验,限制了其在自动化系统中的应用。

WT将信号分解为不同频率和时间尺度的分量,在保留局部信息的同时处理非平稳性(Leonardis等, 2025)。通过对小波系数进行阈值处理或选择性重构去除噪声,保留信号关键特征。Cheng等人(2025)在rPPG-LUH数据集中采用Db8小波去除低频噪声;Chen等(2024)指出连续小波变换可用于减少运动伪影。WT提供了灵活的多尺度分析能力,在处理非线性、非平稳生理信号方面具有独特优势。

信号去噪是实现准确可靠非接触式血压测量的关键步骤。从带通滤波到ICA、EMD及其变体,研究者不断优化去噪技术以应对生理信号的复杂性和噪声干扰,与多波长采集、图像增强及机器学习算法相结合,共同推动非接触式血压测量技术的发展。

2.2.1 运动伪影抑制

运动伪影由受试者自主或不自主运动(如说话、
© 中国图象图形学报版权所有

头部旋转)引起,导致皮肤区域光反射变化,干扰rPPG信号。为抑制伪影,研究者开发了检测与跟踪算法及运动补偿技术,表3列举了运动伪影抑制方法。

检测与跟踪算法通过识别并持续跟踪 ROI,补偿运动引起的像素位移,分离生理信号与运动干扰(Fan 等, 2020)。根据实现方式,可分为基于特征、基于区域和基于深度学习的跟踪算法。基于特征的跟踪算法通过检测并跟踪特定特征点估计 ROI 位移,如 KLT 算法通过跟踪特征点间接稳定 ROI,常用于面部地标跟踪;Zaza 等人(2025)利用 MediaPipe 实现实时人脸地标跟踪。基于区域的跟踪算法直接跟踪特定区域,如 Minimum Output Sum of Squared Error 算法在头部跟踪方面表现稳定(Wuerich 等,

2022); Viola-Jones 算法则常用于初始人脸检测定位。基于深度学习的跟踪算法利用深度神经网络进行特征学习,精度优于传统方法,已成为该领域主流。

运动补偿利用跟踪信息对 rPPG 信号进行校正,可分为基于自适应滤波、盲源分离和深度学习的方法。自适应滤波通过动态调整系数抑制噪声,Kalman 滤波器结合运动模型与观测数据估计并补偿像素位移。盲源分离利用生理信号与运动干扰在统计特性上的差异进行分离,如 ICA 将混合信号分解为独立成分去除运动伪影(De Haan 等, 2014)。深度学习方法通过端到端学习从含噪观测到生理信号的映射,如 DeepPhys 利用注意力机制学习空间掩膜抑制运动干扰(Chen 等, 2025)。

表 3 运动伪影抑制方法总结
Table 3 Summary of motion artifact suppression methods

序号	方法	方法类型	代表方法	核心原理	文献
1	跟踪算法	基于特征跟踪算法	KLT(Kanade-Lucas-Tomasi)算法、MediaPipe 框架	检测图像中的特定特征点,通过跟踪这些点在连续帧中的运动来估计 ROI 位移,间接稳定 ROI 区域。	Zaza 等人(2025)
2	跟踪算法	基于区域跟踪算法	Minimum Output Sum of Squared Error (MOSSE)算法、Viola-Jones 算法	跟踪图像中的一个区域,通过最小化误差或计算 Haar-like 特征来定位和跟踪目标区域。	Wuerich 等人(2022)
3	跟踪算法	基于深度学习跟踪算法	Siamese 网络	利用深度神经网络自动学习目标特征表示,在复杂场景下实现高精度跟踪。	Pflugfelder(2018)
4	运动补偿	基于滤波方法	自适应滤波器、Kalman 滤波器	将运动补偿视为噪声估计与滤除的信号处理问题,根据运动信息动态调整滤波器系数,估计并抵消噪声分量。	Fang 等人(2024)
5	运动补偿	基于信号处理方法	ICA、PCA	将观测到的 RGB 信号分解为统计独立的源信号,利用 BVP 信号与运动噪声在统计特性上的差异进行分离。	Wang 等人(2025)
6	运动补偿	基于深度学习方法	DeepPhys、2D-CNN	端到端学习从含噪观测到纯净生理信号的复杂映射关系,利用运动和外观模型以及注意力机制自动学习空间掩膜来检测 ROI。	Chen 等人(2025)

不同场景下运动伪影的抑制策略各异。静息临床场景中,被测者偶有体位微调,可采用 MediaPipe 面部地标跟踪和 BSS 提取可靠信号。驾驶监测场景中,头部相对固定但伴随路面颠簸振动,可结合特征跟踪和自适应滤波抑制干扰。运动监测场景中,运动者产生周期性体位变化,头部呈节律性运动,可采用深度学习方法进行跟踪和运动补偿,自适应学习复杂运动模式。剧烈运动和复杂真实环境中的运动

伪影抑制性能仍需提升,未来应发展多算法模型融合及更精细的运动模型,以增强 rPPG 监测的鲁棒性。

2.2.2 压缩与光照鲁棒性处理

视频压缩和光照鲁棒性处理是 rPPG 面临的两个关键挑战,它们直接影响生理信号的质量和后续测量的准确性。为解决这些问题,研究者提出了多种方法(Uhrina 等, 2024)。

视频压缩在保证主观视觉质量的前提下,大幅减少视频数据量,以便存储和传输。传统视频压缩算法(如 H. 264、H. 265、VP9、MJPEG)以去除人眼不易察觉的冗余信息为目标,这导致 rPPG 信号在压缩过程中可能出现幅度衰减、高频噪声和脉搏轨迹不连续等伪影,严重损害信号质量(Seepers 等, 2017)。为此,Wang 等人(2025)提出了专门针对 rPPG 信号设计的视频压缩方法,通过重新分配 ROI 编码比特资源、优化量化参数并结合时域下采样与运动补偿插值重建帧,可将视频压缩至原尺寸的 1/60 而保持信号质量。Zhao 等人(2018)较早探索了压缩视频上的 rPPG 脉冲提取框架,为后续生理信号导向的压缩研究奠定了基础。此外,Zhou 等人(2025)提出在复杂运动场景下优先使用帧内压缩以优化 BVP 提取质量。研究表明,不同视频编码器和比特率控制策略对 rPPG 信号质量的影响存在显著差异:在动态场景下,H. 265 编码通常在动态场景下恢复 BVP 信号优于 H. 264,无损压缩在保留 BVP 信号质量方面优于有损压缩。

光照变化是 rPPG 信号质量下降的主要原因之一。强光下皮肤表面反射光增强,血容量引起的漫反射分量相对减弱;弱光下信号幅值降低,信噪比下降,脉动信号易被噪声淹没。为此,研究者采用多波长成像与光谱分析、图像增强和颜色空间变换等技术加以应对。Xi 等人(2022)提出了基于加权组合与奇异谱分析的 rPPG 脉冲信号提取方法,在低光照条件下有效提取 rPPG 脉冲信号。多光谱相机利用不同波长的光穿透皮肤深度不同的特性,捕获不同深度血管层的信息,从而增强对光照变化的鲁棒性。此外,研究者采用窄带滤光片以减轻不同通道间的光谱重叠(Zeng 等, 2025)。基于 Retinex 理论的图像增强模型将图像分解为反射率分量和光照分量,从而分离皮肤组织漫反射信号与光照强度。Xi 等人(2020)进一步将图像增强技术应用于低光照 rPPG 测量,验证了预处理对信号质量的改善作用。在颜色空间变换方面,POS 算法通过将 RGB 分量投影到与标准化肤色矢量正交的平面上,有效滤除强度变化以提高信号稳定性(Kossack 等, 2021)。

上述方法在受控实验条件下效果良好,但在 ICU 等复杂环境中的有效性仍需进一步验证。ICU 病房常采用混合光源(日光灯、设备指示灯、自然光),其光谱组成和强度随时间变化,常规的颜色空

间变换方法难以有效抑制。此外,重症患者面部常覆盖有医用敷料、监测电极或留置导管等遮挡物,这些遮挡物不仅影响 ROI 的完整性,还可能引入额外的镜面反射噪声。针对这一问题,多光谱成像(结合近红外光)虽可改善不同光照条件下的信号质量,但需要额外的硬件支持,与其利用普通摄像头实现非接触监测的初衷相悖。未来需在算法层面探索无需硬件改动的光照鲁棒性方案,以适应真实临床环境的复杂性。

视频压缩和光照鲁棒性是 rPPG 实际应用的两个关键问题。通过 rPPG 导向的视频压缩方法,在保证生理信号质量的前提下显著降低视频码率;结合多波长成像、图像增强、颜色空间变换等技术,可有效提升 rPPG 信号在复杂光照条件下的质量。未来研究将继续致力于开发更集成化、更智能的方法,以推动 rPPG 技术在医疗保健领域的广泛应用。

3 血压估算的生理机制与特征提取

血压是反映心血管状态的核心生理参数。基于 rPPG 的非接触式估计通过分析视频中的脉搏波特征,建立与血压的映射关系。本节从脉搏波传播时间、脉搏波速度及特征提取三个维度,阐述其生理基础与技术路径。

3.1 脉搏波传播时间与血压关系

脉搏波传导时间(pulse transit time, PTT)与血压之间存在物理和生理关联(Lu 等, 2020)。PTT 指同一心动周期中脉搏波在两个不同动脉部位间的传播时间间隔(Dasari 等, 2025)。研究表明,PTT 与血压在低血压范围内呈准线性负相关,在高血压范围内呈非线性关系(Callaghan 等, 1984; Pruett 等, 1988)。

目前,PTT 测量通常采用两种方法: ECG 与 PPG 信号结合(图 4a),以及双部位 PPG 信号结合(图 4b)。第一种方法通过测量 ECG 的 R 波峰值到 PPG 信号特定特征点之间的时间延迟计算 PTT,是最早采用的测量方法。但严格意义上,该时间延迟为脉搏波到达时间(pulse arrival time, PAT),包含射血前期(pre-ejection period, PEP)和 PTT 两部分(Wu 等, 2022);PEP 指心室电激活至实际射血的短暂延迟。为消除 PEP 干扰并避免心电电极接触,第二种方法更为常用,即在身体两个不同部位(如额头和手掌)

提取两路 rPPG 信号, 测量其时间延迟计算 PTT。例如, Wuerich 等 (2021) 利用 RGB 相机从额头和手掌

提取 rPPG 信号, 通过线性回归实现了血压预测。




图4 PTT测量说明图

Fig. 4 PTT measurement instruction diagram

PTT 与血压的映射关系受血管壁弹性动态调节。随着年龄增长或动脉粥样硬化进展, 血管弹性模量升高, PTT 对血压变化的敏感度下降。因此, 基于 PTT 的血压估计模型若未经个体化校准, 在老年心血管疾病患者中可能因敏感度下降而产生系统性低估误差。这也解释了为何多数 rPPG 血压估计研究在年轻健康人群中表现良好, 却在老年、高血压或糖尿病等临床人群中泛化能力显著下降。

尽管 PTT 与血压存在强相关性, 但由于个体生理参数差异, 基于 PTT 的估计仍需个体化校准。此外, 身体活动会改变血管张力并引入噪声, 严重影响 rPPG 信号质量, 导致 PTT 计算误差。未来应通过多技术融合与算法优化, 构建更稳健的血压估计模型。

3.2 脉搏波速度估算方法

脉搏波速度 (pulse wave velocity, PWV) 是衡量动脉僵硬度的重要指标, 与血压呈强相关性 (Dasari 等, 2025)。Moens-Korteweg 方程 (Moens, 1878; Korteweg, 1878) 描述了动脉僵硬程度与 PWV 的物理关系, 如式 (1) 所示。

$$PWV = \sqrt{\frac{Eh}{\rho D}} \quad (1)$$

其中, E 为血管的杨氏模量 (代表血管壁的弹性), h 为血管壁厚度, ρ 为血液密度, D 为血管直径。其中 E 与血压关系, 如式 2 所示。

$$E = E_0 e^{\alpha BP} \quad (2)$$

其中, E_0 为动脉壁的零压弹性模量, α 为常数, BP 为血压。将式 (1) 和式 (2) 联立可得式 (3)。

$$PWV = \sqrt{\frac{E_0 h e^{\alpha BP}}{\rho D}} \quad (3)$$

PWV 是压力脉冲沿动脉壁传播的速度, 即通过利用 PTT 和两个位置的动脉长度差 L (Ding and Zhang, 2019; Kim 和 Kim, 2019), 其关系表示如式 (4) 所示。

$$PWV = \frac{L}{PTT} \quad (4)$$

将式 (3) 和式 (4) 联立, 可得出 BP 表示关系, 如式 (5) 所示。

$$BP = -\frac{2}{\alpha} \ln PTT + \frac{1}{\alpha} \left(\ln \frac{\rho L^2 D}{E_0 h} \right) \quad (5)$$

由于受信号质量、运动干扰等因素影响, PTT 测量误差和动脉路径长度估计误差难以避免, 这两个参数测量的准确性间接影响血压估计精度。未来应突破基于单一 PTT 和估算路径长度的物理模型的局限, 转向融合人口统计学信息 (年龄、性别、身高、体重) 与脉搏波形特征的多参数机器学习模型, 以补偿个体间血管结构与解剖差异对路径长度估算的固有误差; 同时, 发展多部位 ROI 的 PTT 联合估计方法, 通过多路径冗余测量降低单一路径测量误差对血压估计的干扰, 从而显著提升 PWV 估算在老年、新生儿及重度肥胖等不同临床人群中的准确性与泛化能力。

3.3 特征提取方法

在血压监测中, 特征提取旨在从复杂、高维的原始生理信号中识别并量化与血压显著相关的信息,

实现数据降维并抑制噪声冗余,从而提升血压估计模型的效率与准确性。如图5所示,特征提取方法

可分为时域特征、频域特征、非线性特征以及深度特征。




图5 特征提取方法示意图

Fig. 5 Schematic diagram of feature extraction methods

时域特征直接从rPPG信号时间序列中提取,包括峰值/谷值、心率及脉搏波面积比等,可量化脉搏波的周期性与形态特征。研究表明,在特定校准条件下,SBP和DBP可通过rPPG峰值与谷值估算(Fleischhauer等, 2022);心率变化影响舒张期时长,进而改变舒张压与脉压;脉搏波面积比则与总外周阻力(total peripheral resistance, TPR)相关,TPR升高会导致SBP和DBP同时上升。

频域特征通过傅里叶变换将信号转换至频域,常用指标包括低频(low frequency, LF)、高频(high frequency, HF)及LF/HF比值。LF(0.04 - 0.15 Hz)主要反映交感神经活动,其增强与血压升高相关(Kim等, 2021);HF(0.15 - 0.4 Hz)反映副交感神经活动;LF/HF比值则用于评估自主神经平衡状态,对血压监测具有重要意义。

非线性特征用于刻画生理信号中的复杂动力学特性。熵衡量信号的复杂性与随机性,分形维数描述信号的自相似性与几何复杂度,二者均能提供超越线性特征的血压相关信息(Ma等, 2025)。

深度学习特征通过端到端网络自动提取高维抽象表示。三维卷积神经网络(three-dimensional con-

volutional neural network, 3D-CNN)擅长时空特征提取(Niu等, 2023);长短期记忆网络(long short-term memory, LSTM)可捕捉长期时间依赖(Kamanditya等, 2024);Transformer网络则利用注意力机制建模长程依赖与全局信息(Arjomand等, 2024)。

四类特征各有优劣:时域特征计算简单,但依赖精确的特征点检测;频域特征适用于趋势分析,但需较长信号片段;非线性特征能刻画复杂动力学,但计算开销大;深度学习特征鲁棒性强,但"黑箱"特性限制了高可信度场景的应用。未来需针对不同临床场景发展差异化的特征提取方案,包括抗干扰时域检测、短时频域估计、轻量化非线性计算及可解释深度学习技术。

4 血压估算方法

血压估计方法将rPPG脉搏波特征映射为具体血压值(SBP和DBP)。根据建模思路,可分为传统机器学习与深度学习两大类:前者依赖人工特征工程,结构简单、可解释性强;后者通过端到端学习自动提取特征,可捕捉复杂非线性模式。本节将从理

论基础、典型架构、训练策略和应用特点等方面系统阐述。

4.1 传统机器学习方法

机器学习方法通过非线性模型处理高维特征,在血压估计中应用广泛。本节阐述以线性回归(Carbonell 等, 1983)、随机森林(random forest, RF)(Qiao, 2025)、XGBoost(Jordan 和 Mitchell, 2015)和LightGBM(Seftian 等, 2025)为代表的机器学习方法。其中,线性回归模型结构简单、可解释性强;RF通过集成多棵决策树降低过拟合风险;XGBoost和LightGBM作为梯度提升框架,在训练效率和预测精度上表现优异。

1)传统回归方法

传统回归方法依赖手动提取的生理特征构建数学映射。线性回归假设特征与血压值呈线性关系,通过最小化误差拟合权重。Zeng 等人(2025)利用多元线性回归建立新生儿血压与多部位 PTT 及多波长 PTT 特征的映射,SBP 和 DBP 的平均绝对误差(mean absolute error, MAE)分别为 7.65 ± 7.48 mmHg 和 6.31 ± 5.58 mmHg。Jain 等人(2016)结合 PPG 时频特征进行血压预测,SBP 和 DBP 的 MAE 分别为 3.9 mmHg 和 3.7 mmHg。线性回归简单且可解释,但血压与生理信号的关系通常呈非线性,单纯线性模型难以捕捉复杂生理变化(Van 和 Bamford, 2023)。

支持向量回归(support vector regression, SVR)通过寻找最优超平面处理回归任务,能够建模非线性关系。在新生儿血压估计中,SVR 取得 SBP 和 DBP 的 MAE 分别为 6.90 ± 6.39 mmHg 和 6.30 ± 5.86 mmHg。Liu 等人(2017)从 MIMIC 数据集中提取 14 个二阶导数 PPG 特征,采用 SVR 进行血压估计。SVR 在处理小样本、高维数据方面具有优势,但对特征噪声较敏感,且面临个性化校准时精度受限,在极端血压值预测上表现。因此,传统回归方法更适合作为复杂模型的性能基准(Liu 等, 2023)。

2)随机森林

随机森林通过构建多棵决策树并综合其预测结果以提高准确性和鲁棒性。Thambiraj 等人(2020)提取 43 个特征比较 5 种机器学习方法,随机森林结合特征选择取得最优性能,SBP 和 DBP 的 MAE 分别为 9.54 mmHg 和 5.48 mmHg。Slapničar 等人(2024)采用留一法交叉验证的随机森林模型,SBP 和 DBP

的 MAE 分别为 3.59 mmHg 和 2.63 mmHg。随机森林能够处理高维数据并评估特征重要性,但在训练数据不足时易发生过拟合。

3) XGBoost

XGBoost 是一种基于梯度提升框架的高效可扩展决策树系统,通过串行训练多棵决策树,每棵新树学习前一棵树的残差,最终累加所有树的预测结果。Yang 等人(2025)使用 XGBoost 构建血压回归模型,SBP 和 DBP 的 MAE 分别为 4.8893 ± 6.6237 mmHg 和 4.0805 ± 5.5821 mmHg,达到美国医疗器械协会标准,并获英国高血压学会 A 级评估。XGBoost 能够自动评估特征重要性并引入正则化机制防止过拟合,但对异常血压值和特征噪声较敏感。

4) LightGBM

LightGBM 是基于决策树的梯度提升框架,采用直方图算法等策略优化训练速度并降低内存占用。González 等人(2023)在面向非侵入式血压估计的机器学习基准测试中发现,LightGBM 在训练效率和泛化能力方面表现突出,适合处理大规模数据。

机器学习方法凭借处理复杂数据和多特征融合的能力,在非接触式血压估计中展现出较好的预测准确性和鲁棒性。未来研究需进一步解决数据多样性、模型泛化及个性化校准等挑战,以实现更精确可靠的非接触式血压监测。

4.2 深度学习方法

深度学习方法通过多层非线性网络自动学习从原始数据到血压值的复杂映射,主要技术范式可分为端到端网络与混合模型两大类。图 6 为基于机器学习与深度学习方法的血压估计流程。

4.2.1 端到端网络

端到端网络通常将视频帧作为输入,直接输出血压值,无需复杂的中间步骤或手工特征提取,从而简化了模型优化过程并提高了自动化水平。该类网络的核心优势在于自动学习时空特征,近年已被逐步探索应用于血压估计任务。

PhysNet 是 Yu 等人(2019)提出的首个用于从面部视频中提取 rPPG 信号的端到端网络。该研究提出了三种架构变体:基于 3D-CNN 的 PhysNet3D、带时间编码器-解码器的 3D-CNN,以及结合带循环神经网络(recurrent neural network, RNN)的二维卷积神经网络(two-dimensional convolution neural network, 2D-CNN)。其中 PhysNet3D 利用 3D-CNN 层提

取时空特征,并通过反卷积层恢复时间细节,以负皮尔逊相关系数作为损失函数进行训练。PhysNet最

初面向心率估计任务,但其架构已被后续研究迁移至血压估计领域。




图6 基于传统机器学习和深度学习血压估计流程图

Fig. 6 Flowchat of blood pressure estimation based on traditional machine learning and deep learning

DeepPhys 是 Chen 和 McDuff (2018) 提出的端到端卷积注意力网络 (convolutional attention network, CAN), 同样最初面向心率估计任务。该网络采用双分支结构: 外观分支处理原始帧, 运动分支处理帧差信息, 并通过门控注意力机制引导网络关注皮肤区域, 以抑制运动伪影并增强生理信号质量。DeepPhys 以标准化 PPG 波形作为监督信号进行训练。

上述模型虽非专门针对血压估计设计, 但其端到端学习框架和时空特征提取能力为后续研究提供了重要的技术基础。在此基础上, 研究者进一步探索 Transformer 架构在 rPPG 血压估计中的应用, 通过嵌入空间和时间注意力模块, 自动识别面部视频中与血压变化相关的时空区域, 实现端到端的血压值直接回归。Arjomand 等人 (2024) 提出了 Transfo-Rhythm 框架, 基于 Transformer 的多头注意力机制, 从单路 PPG 信号中捕获数据片段间的依赖关系与相似性, 实现无袖带血压估计。Shao 等人 (2025) 提出了端到端视频 Transformer 模型, 通过全局干扰共享、

背景扰动参考和自监督解耦策略, 在极端光照和复杂户外场景下实现鲁棒的 rPPG 信号提取, 并验证了其在血压等生理参数估计上的有效性。此外, Li 等人 (2026) 提出的 ACFA 框架中, 集成了 xLSTM 与 Transformer 的混合架构, 在 PPG-BP 数据集上取得了 SBP 的 MAE 为 2.21 mmHg、DBP 的 MAE 为 3.48 mmHg 的性能, 进一步验证了 Transformer 架构在血压估计任务中的适用性。

4.2.2 混合模型与多模态融合

深度学习混合模型通过融合多源特征与异构网络架构, 克服单一模型或特征的局限性。特征融合是其核心环节, 旨在将不同来源的特征整合为联合表示, 以提升血压回归性能。常见策略包括特征拼接、加权求和及注意力融合: 拼接直接将特征向量串联; 加权求和通过可学习权重整合; 注意力融合则动态计算各特征的重要性权重。

除输入层融合外, 模型也常采用多模块架构。Fang 等人 (2024) 集成 CNN、双向长短期记忆网络

(bidirectional long short-term memory, BiLSTM)和门控循环单元(gated recurrent unit, GRU)构建混合网络估计血压。Chen 等人(2025)提出 rU-Net 与多尺度融合架构,将时序、时频和人口统计特征融合后,通过多头注意力映射为血压值。Hwang 和 Lee (2024)提出两阶段框架 DRP-Net 与 BBP-Net,前者提取 rPPG 信号,后者分析时间差异并融合时序特征进行估计。

表 4 总结了深度学习方法在血压估计中的应用。尽管深度学习在血压估计中取得显著进展,但仍面临多种挑战。混合模型的"黑箱"特性限制其在高可信度临床决策中的应用;新生儿、老年及重症患者的血管弹性与健康成人差异显著,通用模型在这些重点人群中的预测精度不足,亟需个性化校准策略。未来应构建覆盖多肤色、全年龄层及广泛疾病谱的大规模异构数据集,发展兼具生理可解释性与轻量化部署能力的模型,融合多模态自适应校准策略,推动 rPPG 在高血压筛查、术后监测和新生儿监护等场景的实质性应用。

4.2.3 训练策略

深度学习模型训练策略主要包括损失函数设计、正则化和迁移学习,共同决定模型的学习方向、泛化能力和收敛效率。

损失函数量化模型预测与真实血压值的偏差,是模型优化的直接目标。常用函数包括均方误差(mean squared error, MSE)、MAE 及组合损失函数。MSE 优化稳定但对异常值敏感;MAE 对异常值更具鲁棒性,但梯度计算相对复杂。Parashiva 等人(2023)采用 MSE 训练 LSTM 进行血压估计;Jiang 等人(2023)以 MAE 优化 Transformer 网络;Chen 等人(2025)结合负 Pearson 相关系数与标签分布损失提升 PhysFormer 性能。

正则化技术通过在损失函数中添加约束限制模型复杂度,防止过拟合。主要方法包括 L1/L2 正则化、Dropout 及早停等。Hou 等人(2025)采用 L2 正则化(参数 0.04)和 Dropout(丢弃率 0.2);Arjomand 等人(2024)在 TransfoRhythm 中使用 Dropout(丢弃率为 0.15);Fang 等人(2024)在回归层加入 Dropout(丢弃率为 0.3)。Ma 等人(2025)指出 L2 正则化通过惩罚大权重控制模型复杂度,对深度网络尤为重要,有助于抑制噪声记忆并提升泛化能力。

迁移学习通过将大规模通用数据集上的预训练

知识迁移至数据有限的 rPPG 血压估计任务,缓解数据稀缺问题。Cheng 等人(2025)利用 PPG 基准数据集预训练模型,再迁移至 rPPG 信号;Omer 等人(2024)将一维 PPG 信号转换为二维图像,利用预训练视觉模型增强泛化能力;Chen 等人(2025)通过微调预训练图像增强模型适应特定任务,避免从零训练的性能损失。

综上所述,精细设计损失函数、运用正则化技术及迁移学习,可有效应对数据稀缺、噪声干扰和分布不平衡等挑战,提升 rPPG 血压估计模型的准确性与泛化能力。

4.3 深度学习 VS 传统方法的优势与劣势

本节对 rPPG 非接触式血压估计中深度学习方法与传统方法的优劣势进行总结。表 5 汇总了深度学习方法与传统方法在 rPPG 血压估计中的优势与劣势对比。

如图 7 所示,近 5 年来深度学习方法在 rPPG 血压估计研究中的占比显著上升,其优势在于自动学习复杂非线性特征,无需人工设计,在处理多模态、高维生理信号及运动伪影、光照变化等复杂噪声时表现出色,并可有效融合多源数据,通过迁移学习与个性化校准适应不同个体与环境。然而,该方法依赖大量高质量标注数据,医学领域数据获取困难,数据多样性不足易导致模型泛化能力差。此外,深度学习模型通常被视为"黑箱",缺乏可解释性,限制了其在高可信度临床决策中的应用。

尽管深度学习方法取得显著进展,传统方法在特定场景下仍具优势。传统回归与信号处理方法(如线性回归、SVR)基于明确数学假设,决策透明、可解释性强,在小样本和资源受限场景下可达到可接受精度;但其依赖人工特征设计,耗时且难以全面捕捉非线性模式,对运动伪影、光照变化及皮肤色素沉着等干扰较为敏感,性能易下降。

综上,深度学习方法以自动特征学习能力在性能上超越传统方法,但其对数据量、可解释性及血压极端值预测能力仍需提升。传统方法在模型透明度与小样本处理方面保持优势。未来研究应融合两者优势,开发混合模型,并利用可解释人工智能技术增强深度学习在医疗领域的适用性。

4.4 不同方法的性能对比

rPPG 血压估计已成为活跃的研究方向,涌现出传统机器学习与深度学习等多种方法。表 6 对比了

不同方法在多个数据集上对 SBP 和 DBP 预测的 MAE 及标准差 (standard deviation, SD)。

表 4 深度学习方法在血压估计中的应用

Table 4 Application of deep learning method in blood pressure estimation

文献	网络	损失函数	数据集	血压计算方法	研究目的
Bousefsaf 等人(2021)	U-Net	MSE	自建数据集	PWA	建立 iPPG 与 cPPG 信号映射, 验证成像式 PPG 的可靠性
Iuchi 等人 (2022)	ResNet,CBAM	MSE	自建数据集	PWA	利用面部脉搏波空间传播动态信息估计连续血压
Wu 等人 (2022)	ResNet	MSE	Morph-II, 自建数据集	PTT	构建大规模数据集评估 rPPG 血压估计算法的有效性
Lin 等人 (2023)	-	RMSE, MAPE	自建数据集	PTT	改善 rPPG 信号质量、抑制运动伪影并提升有限数据下的泛化能力
Xing 等人 (2023)	ResNet50,ResNet18, GoogleNet,VGG16	MAE	自建数据集	PWA	筛选最优血压预测模型并评估面部 ROI 选择对预测性能的影响
Joung 等人 (2023)	1D-CNN,MLP,FCL	-	VitalDB	PWA	实现跨受试者的连续血压估计
Hamoud 等人(2023)	Xception,DenseNet121, VGG16, Resnet50V2, Inception V3,EfficientNet, FCL, LSTM	MSE	V4V,自建数据集	PWA	探索仅使用手机摄像头进行血压估算的可行性, 比较多种 CNN 及 LSTM 架构的性能
Wu 等人 (2023)	Multitask cascade CNN,Info-GAN	-	rPPG, Dynamic, TVGH, 自建数据集	PWA	比较多种 CNN 及 LSTM 架构在手机视频血压估算中的性能
Cheng 等人 (2023)	1D-CNN,BiGRU	CCE	自建数据集	PWA	建模舒张期与收缩期的生理依赖关系以提升血压估计精度
Hwang 和 Lee(2024)	BBP-Net	MAE, RMSE	MMSE-HR, V4V	PTT	通过 DRP-Net 从面部视频提取肢端和面部两个 rPPG 信号, 分析 PTT, 并结合 VPG 和 APG 导数特征, 经 BBP-Net 估计 SBP 和 DBP
Omer 等人 (2024)	ResNet101,VGG16,AlexNet, DenseNet, MobileNet	MSE	MIMIC II, 自建数据集	PWA	基于逐搏的 2D 图像化 PPG/ rPPG 信号, 通过预训练图像分类网络进行迁移学习, 微调后直接估计 SBP 和 DBP
Chen 等人 (2025)	rUnet,BiGRU	MSE	PulseDB	PTT	基于同步 ECG 和 PPG 信号, 提取时序、STFT 时频及人口统计学特征, 经 rU-Net 与多头注意力融合后, 通过双通道回归网络分别估计 SBP 和 DBP。

表 4 续表

文献	网络	损失函数	数据集	血压计算方法	研究目的
Mohammadi 等人(2025)	CNN,BiLSTM	MSE	MIMIC-II	PWA	基于单通道 PPG, 采用 CNN-BiLSTM-注意力机制提取时空特征, 直接回归估计 SBP 和 DBP
Roha 等人 (2025)	ResNet,MHCA	R ² ,RMSE, MAE,ME, SD	PTTPGG, Cabrini, MIMIC-II	PWA	基于单点 PPG 图像化与多头交叉注意力融合的 ResNet-50 血压估计框架
Zaza 等人 (2025)	MTTS-CAN,LSTM	负皮尔逊相关系数	自建数据集	PWA	基于面部 rPPG 和深度学习的无校准连续血压估计, 面向环境辅助生活系统
Akamatsu 等人(2026)	U-FaceBP	NLL	MSPM,自建数据集	PWA	利用贝叶斯深度学习估计预测不确定性以指导多模态融合
Roha 和 Yuce(2026)	AttentiveConvRegNet, ConvolutionalPoolingRegNet, NeuralRegressionNet	MSE	PTTPGG, Cabrini, MINIC-II	PTT	无需校准的 PTT-深度学习框架, 实现跨人群高精度可穿戴 SBP 和 DBP 估计
Hong 等人 (2026)	MLP,CNN,ResNet,Encoder	交叉熵	VitalDB	基于 PPG 波形与 sdPPG 波形的端到端深度学习分类	基于 PPG 深度学习的血压方向性变化实时分类
Naskinova 等人(2026)	ResNet,Transformer	MSE	MIMIC-III Waveform	基于特征提取的回归估计	比较传统机器学习模型、集成学习方法与深度学习架构在无袖带收缩压估计中的性能
Li 等人 (2026)	DyCASNet,xLSTM,Transformer,FKAN	MAE	MIMIC-III Waveform, PPG-BP	端到端回归	提出 ACFA 端到端混合深度学习框架, 实现高精度、强泛化的连续无创血压监测, 适用于可穿戴与临床部署
Son 和 Choi (2026)	Encoder,Decoder,Transformer	RMSE	VV,V4V	端到端回归	基于对比学习和双分支融合的无标签视频 rPPG 表征学习, 实现跨域、数据高效的血压估计

注:DL, 深度学习;BNN, 贝叶斯神经网络;CNN, 卷积神经网络;RNN, 循环神经网络;GAN, 生成对抗网络;LSTM, 长短期记忆网络;PWA, 脉搏波分析;PTT, 脉搏波传输时间;CBAM, 卷积块注意力模块;MLP, 多层感知器;FCL, 全连接层;BiGRU, 双向门控循环单元;CCE, 分类交叉熵;DRP-Net, 双远程光电体积描记网络;BBP-Net, 有界血压网络;STFT, 短时傅里叶变换;BiLSTM, 双向长短期记忆网络;MHCA, 多头交叉注意力;MTTS-CAN, 多任务时间转移注意力网络;DyCASNet, 动态信道感知频谱网络;xLSTM, 扩展长短期记忆网络;FKAN, 快速 Kolmogorov Arnold 网络;MAE, 平均绝对误差;MSE, 均方误差;RMSE, 均方根误差;MAPE, 平均绝对百分比误差;NLL, 负对数似然;R2, 决定系数;MSPM, 多点生理监测;TVGH, 台北荣民总医院;VV, Vital Video;VPG, 速度体积描记法;APG, 加速度体积描记。

从上述对比可以看出,深度学习方法在血压估计精度上整体优于传统方法。Jiang 等人(2023)的 TRCCBP 模型在自建数据集上 SBP 和 DBP 的 MAE 分别为 4.73 mmHg 和 4.49 mmHg;Zeng 等人(2025)结合 ResNet 与 MS-CAM 在 6 名受试者数据集上取得了 SBP 和 DBP 的 MAE 分别为 4.86 mmHg 和 4.42

mmHg。传统方法中,Haddad 等人(2022)使用多元线性回归(multiple linear regression, MLR)在 MIMIC-I 数据集上取得了 SBP 和 DBP 的 MAE 分别为 6.76 mmHg 和 5.32 mmHg;而 González 等人(2023)使用 SVR 在 Sensors 数据集上 SBP 的 MAE 达 15.60 mmHg,可能与数据集规模及受试者多样性不足有关。

深度学习方法 MAE 通常在 4 - 10 mmHg 之间,
© 中国图象图形学报版权所有

表 5 深度学习方法与传统方法在 rPPG 血压估计中的优势与劣势对比

Table 5 Comparison of advantages and disadvantages between deep learning method and traditional method in rPPG blood pressure estimation

特征	深度学习方法	传统方法
优势	高精度和自动特征提取能力	模型可解释性强
	对复杂数据和噪声具有较强鲁棒性	适用于小规模数据集
	支持多模态数据融合	计算资源需求相对较低
	良好的适应性和个性化能力	-
劣势	高度依赖大规模和高质量数据	依赖人工进行特征工程
	模型可解释性差	建模复杂非线性关系的能力有限
	对异常值和血压边缘范围的鲁棒性有待提高	对噪声和伪影(如运动、光照、肤色)较为敏感




图 7 公开发表的有关血压估计文献数量变化趋势

Fig. 7 Trends in the number of published articles on blood pressure estimation

但其性能受模型架构与数据质量影响;传统方法虽原理清晰,却高度依赖信号质量与个体校准。

5 数据集与评价指标

5.1 数据集

公开数据集是推动 rPPG 血压估计技术发展的关键基础,为算法开发、性能验证及跨方法比较提供了标准化评估平台。早期研究多基于自建数据集,因采集条件与评价标准不一,难以实现公平的算法对比。随着领域发展,研究者陆续发布了涵盖多肤色、多光照及不同运动状态下的公开数据集。表 7 概述了 rPPG 血压估计研究的公开数据集。

5.2 评估指标

研究人员普遍采用 MAE、均方根误差(root

mean square error, RMSE)、皮尔逊相关系数(r)及 Bland-Altman 图量化血压预测准确性。表 8 列举了常用的评价指标。

MAE 和 RMSE 是最基本的误差指标:MAE 表示预测误差的平均绝对值,RMSE 对异常值更为敏感。Cheng 等人(2025)在临床数据集上取得 SBP 和 DBP 的 MAE 分别为 8.721 mmHg 和 8.653 mmHg;Ma 等人(2025)的 CCNN-BP 算法 MAE 为 4.79 mmHg, RMSE 为 7.13 mmHg。

皮尔逊相关系数衡量预测值与真实值的线性相关强度,越接近 1 表示相关性越强。Bland-Altman

图通过绘制差值与均值的散点图评估两种测量方法的一致性,若 95% 的数据点落在差值均值 ± 1.96 倍标准差范围内,则认为两者具有良好的一致性。

6 挑战与未来方向

6.1 生理差异与个体校准问题

生理差异与个体校准是阻碍 rPPG 血压估计临床应用的核心挑战。生理差异主要体现在脉搏波形变异性、肤色差异及基础生理状态:个体脉搏形态因年龄、心血管疾病等因素而异,直接影响 rPPG 信号与血压的关联性;深色皮肤因黑色素含量较高,吸收更多光线,减弱漫反射光中的脉动信息,降低信号质量(Seepers 等, 2017; Dasari 等, 2021)。此外,个体静息血压由遗传、生活习惯及血管状况共

表 6 rPPG 血压估计方法性能对比

Table 6 Performance comparison of rPPG blood pressure estimation estimation methods

文献	年份	方法	数据集	SBP MAE (mmHg)	SBP SD(mmHg)	DBP MAE(mmHg)	DBP SD(mmHg)
Ruiz-Rodríguez 等人	2013	受限玻尔兹曼机模型	自建数据集(11 人)	8.37	10.35	6.13	8.69
Zhang 和 Feng	2017	SVM 模型	昆士兰大学生命体征数据集	11.64	8.20	7.67	6.78
Hasanzadeh 等人	2020	ANN 模型	UCI 数据集	8.22	10.38	4.58	5.53
Fan 等人	2020	物理数学模型	Vicar 和 VideoBP 数据集	8.42	8.81	12.34	7.01
Haddad 等人	2022	MLR	MIMIC I 数据集	6.76	8.51	5.32	6.92
Wuerich 等人	2022	多层感知器模型	自建数据集(5 人, 录制 150 个视频包括正常血压、高血压前期和高血压血压值的数据集)	5.50	4.52	3.73	2.86
Jiang 等人	2023	TRCCBP	自建数据集(36 人)	4.73	5.52	4.49	5.25
Liu 等人	2023	校准型 AdaBoost	CAS-BP 数据集	2.31	9.57	1.33	6.43
González 等人	2023	SVR 模型	Sensors 数据集	15.60	19.68	7.50	9.81
		ResNet 模型	UCI 数据集	16.59	20.65	8.30	10.84
		AdaBoost 模型	BCG 数据集	11.42	16.44	8.06	10.73
		LightGBM 模型	PPG-BP 数据集	13.06	16.65	8.16	10.30
Omer 等人	2024	2D Resnet101	MIMIC-II 数据集	7.05	8.03	5.62	6.01
Qiu 等人	2024	RSD-Net	汉堡工业大学开源数据集	7.05	8.03	5.62	6.01
Imai 等人	2025	基于 ResNet 和 MS-CAM 的卷积神经网络模型	自建数据集(6 名受试者)	4.86	6.14	4.42	5.50
Zeng 等人	2025	基于 MS-PTT 和 MW-PTT 的 MLR 模型		7.65	7.48	6.31	5.58
		基于 MS-PTT 和 MW-PTT 的 SVR 模型	自建数据集(40 名新生儿 NICU)	8.62	6.47	6.89	4.95
		基于 MS-PTT 和 MW-PTT 的 RFR 模型		8.48	6.64	6.90	5.58
Cheng 等人	2025	使用 PPG 信号到 rPPG 信号的迁移学习	rPPG-LUH 数据集	8.72	-	8.65	-
Ma 等人	2025	使用雷达信号集成 CCNN-BP 算法和一维卷积 U-Net、双向 LSTM 和 Transformer 编码器神经网络	汉堡工业大学开源数据集	4.91	6.97	4.17	5.41
Zaza 等人	2025	LSTM 模型	自建数据集(25 人)	9.20	11.30	8.60	9.10
Dasari 等人	2025	V-BPE(融合人口统计学信息)	Face-Hand 数据集	17.10	-	13.20	-

表 6 续表

文献	年份	方法	数据集	SBP MAE (mmHg)	SBP SD(mmHg)	DBP MAE(mmHg)	DBP SD(mmHg)
Yang 等人	2025	XGBoost 模型	昆士兰大学生命体征数据集和自建面部视频和血压数据集	4.89	6.62	4.08	5.58
		Linear 模型		9.46	14.39	7.42	10.48
		SVM 模型		7.43	8.58	5.75	7.20
Roha Yuce 和	2026	带有特征融合和注意力机制的 MultiPatterns 框架	PTT PPG 数据集	1.31	1.86	0.98	1.65
			MIMIC-II 数据集	2.12	3.79	1.14	2.15
			自建数据集(43 人,含运动和药物干预)	6.45	7.08	2.92	2.97
Naskinova 等人	2026	XGBoost 模型	MIMIC-III Waveform 数据集	7.32	11.60	—	—
Li 等人	2026	ACFA 模型	MIMIC-III Waveform 数据集	7.32	11.60	—	—
			PPG-BP 数据集	2.21	3.37	3.48	4.24
Son 和 Choi	2026	双分支融合架构	Vital Video 数据集	2.49	3.52	3.16	4.58
			V4V 数据集	11.61	—	6.59	—

注:SVM, 支持向量机;ANN, 人工神经网络;MLR, 多元线性回归;TRCCBP, 基于雷达的非接触式连续血压监测变压器网络;SVR, 支持向量回归器;LightGBM, 轻量级梯度提升机;RSD-Net, 基于雷达的堆叠可变形卷积网络;ResNet, 残差网络;MS-CAM, 多尺度通道注意力模块;MS-PTT, 多部位脉搏波传导时间;MW-PTT, 多波长脉搏波传导时间;RFR, 随机森林回归;CCNN-BP, 基于复值完全自适应噪声集合经验模态分解和神经网络的血压监测算法;LSTM, 长短期记忆网络;V-BPE, 基于视频的血压估计;XGBoost, 极端梯度上升;ACFA, 自适应跨域融合架构;CAS-BP, 中国科学院血压数据集;UCI, 加州大学欧文分校机器学习数据库;BCG, 床置式心冲击图数据集;PPG-BP, 光电容积描记血压数据集;NICU, 新生儿重症监护室;rPPG-LUH, 吕贝克大学远程光电容积描记数据集;V4V, 视频到生命体征挑战数据集。

表 7 rPPG 血压估计公开数据集

Table 7 Public datasets for rPPG-based blood pressure estimation

数据集	年份	描述	主要摄像头	帧率 (fps)	分辨率	所用信号 (真值/参考)	多模态	适用场景
MMSE-HR	2016	不同肤色与表情受试者的高清视频	Di3D 动态成像系统, FLIR A655sc 热成像相机	25	1040 × 1392	心率信号、血压信号	可见光、热成像	高精度面部分析, 肤色与微表情影响研究
MIMIC-II/III	2010、2016	ICU 患者的生理信号与临床数据	/	/	/	动脉血压信号(arterial blood pressure, ABP)、ECG 信号、PPG 信号	纯生理信号	临床模型训练, 为 rPPG 提供 PPG→BP 映射基础
UbiHeart	2024	通过移动端面部视频实现无创血压监测的评估数据集	iPhone 14 Pro 前置摄像头	30	1080 × 1920	血压信号(SBP/DBP, 来自标准数字血压计测量的单值)	可见光	移动端实时血压监测应用开发
Face-Hand Dataset	2025	包含印度和塞拉里昂两个国家受试者, 拍摄面部和手部视频	Google Pixel 6	60	1920 × 1080	血压信号(SBP/DBP, 来自 OMRON BP7000 袖带测量的单值)	可见光	拥有完整人口统计学信息, 支持个体化校准;面部与手部同框, 支持 PTT 计算

表 7 续表

数据集	年份	描述	主要摄像头	帧率 (fps)	分辨率	所用信号 (真值/参考)	多模态	适用场景
UCI	2015	数据来自ICU患者,取自MIMIC-II的子集	/	/	/	ECG信号、PPG信号、ABP信号	纯生理信号	包含大规模数据,适合数据驱动的深度学习模型训练
昆士兰大学生命体征数据集	2012	来自麻醉/手术患者,覆盖麻醉、脊髓麻醉、镇静等多种场景	/	/	/	ECG信号、无创血压信号(non-invasive blood pressure, NIBP)、ABP信号	纯生理信号	麻醉监测研究,多参数生理信号分析
Sensors	2022	数据来自ICU患者,取自MIMIC-III子集	/	/	/	PPG信号、ABP信号	纯生理信号	适用于深度学习方法基准测试
BCG	2018	受试者处于实验室环境,平躺于传感器床上采集数据	/	/	/	PPG信号、ABP信号	纯生理信号	适用于训练血压估计模型,多模态融合研究
PPG-BP	2022	包含20-89岁年龄范围和包括高血压和糖尿病在内的疾病记录,且在标准实验条件下进行采集	/	/	/	PPG信号、血压信号(SBP/DBP,来自OMRON HEM-7201袖带测量的单值)	纯生理信号	基于PPG血压估计研究及高血压筛查研究
汉堡工业大学开源数据集	2020	使用24GHz雷达向胸部发射电磁波采集数据,包含静息、屏气、倾斜台上升下降等场景	/	/	/	雷达信号、连续无创动脉血压信号(continuous non-invasive arterial pressure, CNAP)、ECG信号、阻抗心动图信号(impedance cardiography, ICG)	纯生理信号	适合雷达信号出来、多模态融合、连续血压波形估计等研究
rPPG-LUH	2021	记录ICU术后患者面部及上半身视频	IDS UI-3040CP	32	/	rPPG信号、血压信号(SBP/DBP,来自ICU床边监护仪每分钟1次测量)	可见光	适用于非接触血压估计的迁移学习、小样本深度学习和临床环境验证研究
MSPM	2024	包含全身视频和多部位接触式PPG信号,覆盖18-58岁103人受试者	RGB摄像头,NIR摄像头,iPhone 13 Pro Max	30-90	1920 × 1080	PPG信号、血压信号(SBP/DBP,来自OMRON EVOLV袖带测量的单值)	RGB、NIR	适用于多部位rPPG研究、PTT分析、血压估计
CLBP-300	2026	包含300名受试者的面部视频,覆盖不同室内室外的光照环境	iPhone 16 Pro Max, Nikon D5300	60	/	rPPG信号、血压信号(SBP/DBP,来自Rossmax和Omron电子血压计)	可见光	适用于真实室内外光照环境下的无袖带血压估计算法开发
BP4D+	2016	包含多种情绪诱发任务的人脸视频,涵盖白人、亚洲人、黑人和拉丁裔	Di3D、FLIR A655sc	25	1040 × 1392	rPPG信号、ABP信号、心率信号、呼吸率信号、皮肤电活动、面部动作单元	可见光、热成像	适用于多模态情绪识别、面部动作单元检测及生理-表情关联分析

同决定,通用模型易以训练数据均值为先验,导致对血压偏高或偏低个体产生系统性偏差。个体校准是提高准确性的关键策略。将人口统计信息纳入模型并进行周期性袖带校准,可显著减少个体偏差(Liu等,2023)。迁移学习通过预训练知识迁移与少量个体数据微调,也可有效提升泛

表 8 常见评价指标分析
Table 8 Analysis of common evaluation indicators

评价指标	指标含义	计算公式	文献
平均绝对误差(MAE)	衡量预测误差的平均绝对值	$MAE = \frac{1}{n} \times \sum_{i=1}^n y_i - \hat{y}_i $	Cheng 等人(2025); Bondarenko 等人(2025)
均方根误差(RMSE)	衡量预测误差的标准差	$RMSE = \sqrt{\frac{1}{n} \times \sum_{i=1}^n (y_i - \hat{y}_i)^2}$	Zeng 等人(2025); Ma 等人(2025)
皮尔逊相关系数(r)	衡量预测值与真实值之间线性相关程度	$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}$	Liu 等人(2023); Wuerich 等人(2022); Zeng 等人(2025); Leonardis 等(2025)
Bland-Altman 图	衡量预测于真实值之间一致性	横坐标: $\frac{y_i + \hat{y}_i}{2} (i = 1, 2, \dots, n)$ 纵坐标: $y_i - \hat{y}_i (i = 1, 2, \dots, n)$	Jiang 等人(2023); Qin 等人(2023); Omer 等人(2024); Sakib 等人(2025)

注: n 为样本总数; y_i 为第 i 个样本的真实值; $\hat{y}_i$ 为第 i 个样本的预测值; x_i 为第 i 个样本的预测值; $\bar{x}$ 为预测值的平均值; $\bar{y}$ 为真实值的平均值; MAE 为平均绝对误差; RMSE 为均方根误差。

化能力。
然而,校准步骤的便利性限制阻碍大规模部署。未来应探索无校准方案,例如结合心率变异性、呼吸模式等多生理指标,利用大规模数据驱动模型隐式学习血压与生理信号的映射关系。同时,需建立包含不同生理状态与人口统计学特征的大规模多样性数据集,以增强模型泛化能力。

6.2 跨场景、跨设备泛化能力

跨场景、跨设备泛化是 rPPG 技术走向日常应用的关键挑战。

跨场景泛化要求模型适应光照变化与环境噪声差异。光照变化会引入显著伪影, Huang 等人(2023)和 Hou 等人(2025)采用多波长 rPPG 技术,结合可见光与近红外光从不同皮肤深度获取信息,以增强光照鲁棒性。不同应用场景(如医院 ICU 与实验室)的环境条件差异,对模型泛化能力提出更高要求;跨设备泛化需克服采集硬件的系统性差异。不同摄像头的光谱响应、分辨率、帧率及采样率差异均会影响 rPPG 信号质量,低帧率甚至会导致 BVP 峰值与参考信号错位。

6.3 边缘计算与实时性要求

边缘计算与实时性是实现 rPPG 血压监测可穿戴化和智能家居应用的关键。连续监测要求系统实时处理视频并输出血压值,但传统深度学习模型参数量大、计算复杂度高,难以在计算、存储和电池受限的边缘设备上部署。针对该问题,通常采用设备

端、边缘端和云端三级架构(Zhang 等, 2026):低复杂度模型在设备端本地运行,中等复杂度模型部署于智能手机或网关,高复杂度模型则将计算任务转移至云端。

未来研究需探索轻量级模型架构、高效信号处理及优化视频压缩技术,在保证准确性与实时性的前提下,推动非接触式血压监测的实用化。

6.4 隐私保护与伦理合规

现有研究指出, rPPG 技术广泛应用前须解决隐私保护与伦理合规问题(Elgendi 等, 2025)。rPPG 通过摄像头采集面部视频提取生理信号,带来多重隐私风险:人脸视频属于敏感生物识别信息,泄露可能导致身份冒充;连续提取的血压、心率等健康数据可能被用于就业或保险歧视;视频背景还可能暴露地理位置、家庭环境等情境信息。

伦理层面,研究须确保公平性并避免偏见。涉及人类受试者的研究应获得书面知情同意,明确告知数据用途及风险,并在结束后按规定销毁或匿名化处理原始视频,研究协议须经伦理委员会审查批准。技术层面,应对数据进行去识别化处理,如面部模糊或仅上传皮肤 ROI 的颜色空间值而非原始视频(Zhou 等, 2025; Dasari 等, 2021),并采取加密存储、访问控制等安全措施。

6.5 未来趋势:自监督学习、多模态融合、边缘 AI 部署

未来 rPPG 血压估计将重点聚焦自监督学习、多
© 中国图象图形学报版权所有

模态融合及边缘人工智能(artificial intelligence, AI)部署,以应对生理差异、个体校准、泛化能力及实时性等挑战。

自监督学习利用大量无标注视频数据进行预训练,学习rPPG信号的内在特征,降低对昂贵标注数据的依赖。通过设计时空周期性等自监督任务,模型可学习到对光照、运动、肤色等变异更具鲁棒性的特征表示,从而提升跨场景迁移能力(Chen等, 2024)。

多模态融合通过整合rPPG、ECG、接触式PPG等不同源信号,有助于提升抗运动干扰能力和血压估计的生理可信度。在已部署多参数监护仪的场景中可融合多源信号实现高精度估计,在仅依赖摄像头的轻量化场景中仍可单独使用rPPG完成初步筛查,显著提升技术在不同资源配置下的适应性。

边缘AI部署通过在设备本地进行实时处理,减少云端传输延迟,实现即时分析(Egorov等, 2025)。通过模型剪枝、量化和知识蒸馏等轻量化技术,可在保证精度的同时将推理延迟压缩至毫秒级,满足新生儿监护、术后监测等场景对实时报警的迫切需求。

总之,未来rPPG血压估计将通过自监督学习提升泛化能力、借助多模态融合增强鲁棒性、利用边缘AI部署满足实时性需求,并将隐私保护和伦理合规作为核心考量,推动技术安全、负责任地发展。

7 结 论

本文系统综述了基于rPPG的非接触式血压测量技术。区别于已有综述侧重算法归纳的视角,本文以临床应用为导向,将生理机制与信号质量分析贯穿全文。首先阐述了rPPG信号的生理基础及与血容量变化的关联,分析了面部检测、信号去噪及光照鲁棒性等预处理关键技术,探讨了PTT/PWV等血压估算生理机制。研究表明,尽管非接触式血压监测在受控环境中取得进展,但在复杂现实场景中的鲁棒性与准确性仍是制约其大规模应用的主要瓶颈。

其次,梳理了当前主要公开数据集,对比分析了多种血压估算方法的性能。结果表明,深度学习方法在建模复杂非线性关系方面具有显著优势,但其跨场景泛化能力仍需提升。

最后,讨论了生理差异与个体校准、跨场景/跨

设备泛化、边缘计算实时性、隐私与伦理等四项主要挑战。展望未来,应着力构建覆盖多肤色、多年龄、多疾病状态的大规模基准数据集,推动从实验室向多中心临床验证过渡;发展具有生理可解释性的轻量级模型,兼顾精度与效率;建立专项评估标准与验证框架,为技术监管审批提供依据,推动rPPG血压估计在高血压筛查、术后监测及新生儿监护等场景的实质性应用。

参考文献(References)

- Akamatsu Y, Ebihara A F and Umematsu T. U-FaceBP: Uncertainty-Aware Bayesian Ensemble Deep Learning for Face Video-Based Blood Pressure Estimation [J/OL]. *IEEE Transactions on Instrumentation and Measurement*, 2026, 75: 4008515-4008515. <https://ieeexplore.ieee.org/document/11494851/>. [DOI: 10.1109/TIM.2026.3687304]
- Alić B, Zauber T, Wiede C and Seidl K. 2023. Current methods for contactless optical patient diagnosis: a systematic review [J]. *BioMedical Engineering OnLine*, 22(1): #61. [DOI:10.1186/s12938-023-01125-8]
- Arjomand A, Boudesh A, Bayatmakou F, Kent K B and Mohammadi A. 2024. TransfoRhythm: a transformer architecture conducive to blood pressure estimation via solo PPG signal capturing [J]. *arXiv preprint arXiv:2404.15352*.
- Barhate M Y, Mishra A S, Mehar V N, Mishra P J, Mhashakhetri K M and More K K, et al. 2025. Non-invasive blood pressure and heart rate estimation using remote photoplethysmography and machine learning models [C]// 2025 IEEE International Conference on Intelligent Signal Processing and Effective Communication Technologies (INSPECT). Gwalior, India: IEEE: 1-6. [DOI: 10.1109/INSPECT67393.2025.11350617]
- Bobbia S, Luguern D, Benezeth Y, Nakamura K, Gomez R and Dubois J. 2018. Real-time temporal superpixels for unsupervised remote photoplethysmography [C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Salt Lake City, UT, USA: IEEE: 1422-14227. [DOI: 10.1109/CVPRW.2018.00182]
- Bobbia S, Macwan R, Benezeth Y, Mansouri A and Dubois J. 2019. Unsupervised skin tissue segmentation for remote photoplethysmography [J]. *Pattern Recognition Letters*, 124: 82-90. [DOI:10.1016/j.patrec.2017.10.017]
- Bondarenko M, Menon C and Elgendi M. 2025. The role of face regions in remote photoplethysmography for contactless heart rate monitoring [J]. *npj Digital Medicine*, 8(1): 479. [DOI:10.1038/s41746-025-01814-9]
- Bousefsaf F, Djedjli D, Ouzar Y, Maaoui C and Pruski A. 2021. iPPG

- 2 cPPG: reconstructing contact from imaging photoplethysmographic signals using U-Net architectures[J]. *Computers in Biology and Medicine*, 138: 104860. [DOI: 10.1016/j.combiomed.2021.104860]
- Callaghan F J, Babbs C F, Bourland J D and Geddes L A. 1984. The relationship between arterial pulse-wave velocity and pulse frequency at different pressures[J]. *Journal of Medical Engineering & Technology*, 8(1): 15-18. [DOI: 10.3109/03091908409032067]
- Carbonell J G, Michalski R S and Mitchell T M. 1983. An overview of machine learning[M]// *Machine Learning*. Elsevier: 3-23. [DOI: 10.1016/B978-0-08-051054-5.50005-4]
- Casalino G, Castellano G and Zaza G. 2023. Evaluating the robustness of a contact-less mHealth solution for personal and remote monitoring of blood oxygen saturation[J]. *Journal of Ambient Intelligence and Humanized Computing*, 14(7): 8871-8880. [DOI: 10.1007/s12652-021-03635-6]
- Chen G, Zou L and Ji Z. 2024. A review: blood pressure monitoring based on PPG and circadian rhythm [J]. *APL Bioengineering*, 8(3).
- Chen J, Zhou X, Feng L, Ling B W K, Han L and Zhang H. 2025. rU-Net, multi-scale feature fusion and transfer learning: unlocking the potential of cuffless blood pressure monitoring with PPG and ECG [J]. *IEEE Journal of Biomedical and Health Informatics*, 29(1): 166-176. [DOI: 10.1109/JBHI.2024.3483301]
- Chen S, Wong K L, Chan T T, Wang Y, So R H Y and Chin J W. 2025. An image enhancement based method for improving rPPG extraction under low-light illumination [J]. *Biomedical Signal Processing and Control*, 100: 106963.
- Chen W and McDuff D. 2018. DeepPhys: video-based physiological measurement using convolutional attention networks [M]// Ferrari V, Hebert M, Sminchisescu C and Weiss Y. *Computer Vision - ECCV 2018*: Vol. 11206. Cham: Springer International Publishing: 356-373. [DOI: 10.1007/978-3-030-01216-8_22]
- Chen W, Yi Z, Lim L J R, Lim R Q R, Zhang A and Qian Z, et al. 2024. Deep learning and remote photoplethysmography powered advancements in contactless physiological measurement [J]. *Frontiers in Bioengineering and Biotechnology*, 12: 1420100. [DOI: 10.3389/fbioe.2024.1420100]
- Chen Y, Zhuang J, Li B, Zhang Y and Zheng X. 2023. Remote blood pressure estimation via the spatiotemporal mapping of facial videos [J]. *Sensors*, 23(6): 2963.
- Cheng C H, Chin J W, Wong K L, Chan T T, Lo H C and Pang K L, et al. 2025. Remote blood pressure estimation from facial videos using transfer learning: leveraging PPG to rPPG conversion [C]// 2025 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV). Tucson, AZ, USA: IEEE: 4225-4236.
- Cheng H, Xiong J, Chen Z and Chen J. 2023. Deep learning-based non-contact iPPG signal blood pressure measurement research [J]. *Sensors*, 23(12): 5528. [DOI: 10.3390/s23125528]
- Curran T, McDuff D, Liu X, Narayanswamy G, Ma C and Patel S, et al. 2023. Camera-based remote photoplethysmography for blood pressure measurement: current evidence, clinical perspectives, and future applications[J]. *Connected Health and Telemedicine*, 2(2): N-A.
- Dasari A, Jeni L A and Tucker C S. 2025. Video-based estimation of blood pressure[J]. *PLOS ONE*, 20(1): e0311654. [DOI: 10.1371/journal.pone.0311654]
- Dasari A, Prakash S K A, Jeni L A and Tucker C S. 2021. Evaluation of biases in remote photoplethysmography methods [J]. *NPJ Digital Medicine*, 4(1): 91.
- De Haan G and Jeanne V. 2013. Robust pulse rate from chrominance-based rPPG[J]. *IEEE Transactions on Biomedical Engineering*, 60(10): 2878-2886. [DOI: 10.1109/TBME.2013.2266196]
- De Haan G and Van Leest A. 2014. Improved motion robustness of remote-PPG by using the blood volume pulse signature [J]. *Physiological Measurement*, 35(9): 1913.
- Ding X and Zhang Y T. 2019. Pulse transit time technique for cuffless unobtrusive blood pressure measurement: from theory to algorithm [J]. *Biomedical Engineering Letters*, 9(1): 37-52.
- Duan Y, He C and Zhou M. 2023. Anti-motion imaging photoplethysmography via self-adaptive multi-ROI tracking and selection [J]. *Physiological Measurement*, 44(11): 115003. [DOI: 10.1088/1361-6579/ad071f]
- Egorov K, Botman S, Blinov P, Zubkova G, Ivashchenko A and Kolsanov A. Gaze into the heart: a multi-view video dataset for rPPG and health biomarkers estimation [C/OL]// *Proceedings of the 33rd ACM International Conference on Multimedia*. New York, NY, USA: Association for Computing Machinery, 2025: 13053-13059. <https://doi.org/10.1145/3746027.3758255>. [DOI: 10.1145/3746027.3758255]
- El Boussaki H, Latif R and Saddik A. 2022. A review on video-based heart rate, respiratory rate and blood pressure estimation [C]// *International Conference of Machine Learning and Computer Science Applications*. Springer: 129-140.
- Elgendy M, Yu A, Bhutani S and Menon C. 2025. Balancing cardiac privacy with quality in video recordings [J]. *Communications Medicine*, 5(1): 486. [DOI: 10.1038/s43856-025-01175-0]
- Fan X, Ye Q, Yang X and Choudhury S D. 2020. Robust blood pressure estimation using an RGB camera [J]. *Journal of Ambient Intelligence and Humanized Computing*, 11(11): 4329-4336. [DOI: 10.1007/s12652-018-1026-6]
- Fang H, Xiong J and He L. 2024. Fair non-contact blood pressure estimation using imaging photoplethysmography [J]. *Biomedical Optics Express*, 15(4): 2133-2151.
- Fang Y F, Huang P W, Chung M L and Wu B F. 2018. A feature selection method for vision-based blood pressure measurement [C]// 2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC). Miyazaki, Japan: IEEE: 2158-2163.

- Favilla R, Zuccala V C and Coppini G. 2019. Heart rate and heart rate variability from single-channel video and ICA integration of multiple signals[J]. *IEEE Journal of Biomedical and Health Informatics*, 23(6): 2398-2408. [DOI:10.1109/JBHI.2018.2880097]
- Fleischhauer V, Feldheiser A and Zaunseder S. 2022. Beat-to-beat blood pressure estimation by photoplethysmography and its interpretation[J]. *Sensors*, 22(18): 7037.
- Gao H, Zhang C, Pei S and Wu X. 2024. Region of interest analysis using Delaunay triangulation for facial video-based heart rate estimation[J]. *IEEE Transactions on Instrumentation and Measurement*, 73: 1-12. [DOI:10.1109/TIM.2024.3363786]
- González S, Hsieh W T and Chen T P C. 2023. A benchmark for machine-learning based non-invasive blood pressure estimation using photoplethysmogram[J]. *Scientific Data*, 10(1): 149. [DOI: 10.1038/s41597-023-02020-6]
- Haddad S, Boukhayma A and Caizzone A. 2022. Continuous PPG-based blood pressure monitoring using multi-linear regression[J]. *IEEE Journal of Biomedical and Health Informatics*, 26(5): 2096-2105. [DOI:10.1109/JBHI.2021.3128229]
- Hamoud B, Kashevnik A, Othman W and Shilov N. 2023. Neural network model combination for video-based blood pressure estimation: new approach and evaluation[J]. *Sensors*, 23(4): 1753.
- Haque M A, Irani R, Nasrollahi K and Moeslund T B. 2016. Heartbeat rate measurement from facial video[J]. *IEEE Intelligent Systems*, 31(3): 40-48. [DOI:10.1109/MIS.2016.20]
- Hasanzadeh N, Ahmadi M M and Mohammadzade H. 2020. Blood pressure estimation using photoplethysmogram signal and its morphological features[J]. *IEEE Sensors Journal*, 20(8): 4300-4310. [DOI:10.1109/JSEN.2019.2961411]
- Hong J, Jin W, Nandi M and Alastruey J. 2026. Real-time classification of blood pressure changes using photoplethysmography and deep learning[J]. *Biomedical Signal Processing and Control*, 112: 108380. [DOI:10.1016/j.bspc.2025.108380]
- Hou Z, Huang D, Huang Y, Huang J, Zhao N and Pan L, et al. 2025. Exploiting multiwavelength morphological features of camera-PPG for blood pressure estimation[J]. *IEEE Transactions on Instrumentation and Measurement*, 74: 1-12. [DOI: 10.1109/TIM. 2025. 3551005]
- Huang B, Lin C L, Chen W H, Juang C F and Wu X M. 2021. A novel one-stage framework for visual pulse rate estimation using deep neural networks[J]. *Biomedical Signal Processing and Control*, 66: # 102387. [DOI:10.1016/j.bspc.2020.102387]
- Huang P W, Lin C H, Chung M L, Lin T M and Wu B F. 2017. Image based contactless blood pressure assessment using pulse transit time [C]// 2017 International Automatic Control Conference (CACS). Pingtung, China: IEEE: 1-6. [DOI: 10.1109/CACS. 2017. 8284275]
- Huang Y, Huang D, Huang J, Lu H, He M and Wang W. 2023. Camera wavelength selection for multi-wavelength pulse transit time based blood pressure monitoring[C]// 2023 45th Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC). Sydney, Australia: IEEE: 1-5. [DOI:10.1109/EMBC40787.2023.10340068]
- Hwang G and Lee S J. Phase-shifted remote photoplethysmography for estimating heart rate and blood pressure from facial video[J/OL]. *Measurement*, 2026, 275: 121240. <https://www.sciencedirect.com/science/article/pii/S0263224126009498>. [DOI: 10.1016/j.measurement.2026.121240]
- Imai R, Kawasaki S, Ishiguro R, Toyama K, Takahashi M and Tsumura N. 2025. Noninvasive blood pressure estimation based on spatial remote photoplethysmography using an attentional feature fusion module[J]. *Artificial Life and Robotics*: 1-6. [DOI:10.1007/s10015-025-01055-9]
- Iuchi K, Miyazaki R, Cardoso G C, Ogawa-Ochiai K and Tsumura N. 2022. Blood pressure estimation by spatial pulse-wave dynamics in a facial video[J]. *Biomedical Optics Express*, 13(11): 6035. [DOI:10.1364/BOE.473166]
- Jain M, Deb S and Subramanyam A V. 2016. Face video based touchless blood pressure and heart rate estimation[C]// 2016 IEEE 18th International Workshop on Multimedia Signal Processing (MMSP). Montreal, QC, Canada: IEEE: 1-5. [DOI:10.1109/MMSP.2016. 7813389]
- Jiang X, Zhang J, Mu W, Wang K, Li L and Zhang L. 2023. TRCCBP: transformer network for radar-based contactless continuous blood pressure monitoring[J]. *Sensors*, 23(24): 9680.
- Jordan M I and Mitchell T M. 2015. Machine learning: trends, perspectives, and prospects[J]. *Science*, 349(6245): 255-260.
- Joung J, Jung C W, Lee H C, Chae M J, Kim H S and Park J, et al. 2023. Continuous cuffless blood pressure monitoring using photoplethysmography-based PPG2BP-net for high intrasubject blood pressure variations[J]. *Scientific Reports*, 13(1): 8605. [DOI:10.1038/s41598-023-35492-y]
- Kamanditya B, Fuadah Y N, Mahardika T N Q and Lim K M. 2024. Continuous blood pressure prediction system using Conv-LSTM network on hybrid latent features of photoplethysmogram (PPG) and electrocardiogram (ECG) signals[J]. *Scientific Reports*, 14(1): 16450.
- Kim D Y, Lee K and Sohn C B. 2021. Assessment of ROI selection for facial video-based rPPG[J]. *Sensors*, 21(23): 7923. [DOI:10. 3390/s21237923]
- Kim H L and Kim S H. 2019. Pulse wave velocity in atherosclerosis[J]. *Frontiers in Cardiovascular Medicine*, 6: 41. [DOI:10.3389/fcvm. 2019.00041]
- Korteweg von D. 1878. Ueber die Fortpflanzungsgeschwindigkeit des Schalles in elastischen Röhren[J]. *Annalen der Physik*, 241(12): 525-542.
- Kossack B, Wisotzky E, Hilsmann A and Eisert P. 2021. Automatic region-based heart rate measurement using remote photoplethys-

- mography[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision. Montreal, Canada: IEEE: 2755-2759.
- Leonardis A, Ricci E, Roth S, Russakovsky O, Sattler T and Varol G. 2025. Computer Vision – ECCV 2024: 18th European Conference, Milan, Italy, September 29 – October 4, 2024, Proceedings, Part LIV[M]. Cham: Springer Nature Switzerland. [DOI:10.1007/978-3-031-72949-2]
- Lewandowska M and Nowak J. 2012. Measuring pulse rate with a webcam[J]. Journal of Medical Imaging and Health Informatics, 2(1): 87-92. [DOI:10.1166/jmhi.2012.1064]
- Li B, Zhang P P, Peng J Y and Fu H. 2023a. Non-contact PPG signal and heart rate estimation with multi-hierarchical convolutional network[J]. Pattern Recognition, 139: #109421. [DOI:10.1016/j.patcog.2023.109421]
- Li F, Li L, Wang L and Xu H. 2026. ACFA: a hybrid deep learning framework for cuffless continuous blood pressure estimation using time – frequency adaptive PPG features [J]. IEEE Access, 14: 20839-20855. [DOI:10.1109/ACCESS.2026.3657471]
- Li K, Cardoso C, Moctezuma-Ramirez A, Elgalad A and Perin E. 2023b. Heart rate variability measurement through a smart wearable device: another breakthrough for personal health monitoring? [J]. International Journal of Environmental Research and Public Health, 20(24): #7146. [DOI:10.3390/ijerph20247146]
- Li S, Elgendi M and Menon C. 2024. Optimal facial regions for remote heart rate measurement during physical and cognitive activities[J]. npj Cardiovascular Health, 1(1): 33. [DOI:10.1038/s44325-024-00033-7]
- Lin B, Tao J, Xu J J, He L, Liu N R and Zhang X Z. 2023. Estimation of vital signs from facial videos via video magnification and deep learning[J]. iScience, 26(10): #107845. [DOI:10.1016/j.isci.2023.107845]
- Liu L, Yu D F, Lu H Z, Shan C F and Wang W J. 2024a. Camera-based seismocardiogram for heart rate variability monitoring [J]. IEEE Journal of Biomedical and Health Informatics, 28(5): 2794-2805. [DOI:10.1109/JBHI.2024.3370394]
- Liu M, Po L M and Fu H. 2017. Cuffless blood pressure estimation based on photoplethysmography signal and its second derivative [J]. International Journal of Computer Theory and Engineering, 9(3): 202-206. [DOI:10.7763/IJCTE.2017.V9.1138]
- Liu P, Song Y Z, Yang X, Li D J and Khosravi M. 2024b. Medical intelligence using PPG signals and hybrid learning at the edge to detect fatigue in physical activities [J]. Scientific Reports, 14(1): #16149. [DOI:10.1038/s41598-024-66839-8]
- Liu S Q and Yuen P C. 2024. Robust remote photoplethysmography estimation with environmental noise disentanglement[J]. IEEE Transactions on Image Processing, 33: 27-41. [DOI:10.1109/TIP.2023.3330108]
- Liu Z D, Li Y, Zhang Y T, Zeng J, Chen Z X, Cui Z W, et al. 2023. Cuffless blood pressure measurement using smartwatches: a large-scale validation study[J]. IEEE Journal of Biomedical and Health Informatics, 27(9): 4216-4227.
- Lu H, Han H and Zhou S K. 2021. Dual-GAN: joint BVP and noise modeling for remote physiological measurement [C]// 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville, TN, USA: IEEE: 12399-12408. [DOI:10.1109/CVPR46437.2021.01222]
- Lu Y, Wang C and Meng M Q H. 2020. Video-based contactless blood pressure estimation: a review[C]// 2020 IEEE International Conference on Real-Time Computing and Robotics (RCAR). IEEE: 62-67.
- Ma K, Zhang Y and Shan B. 2025. A novel contactless approach to continuous blood pressure monitoring using complex CEEMDAN and neural networks[J]. IEEE Access, 13: 152046-152062. [DOI:10.1109/ACCESS.2025.3594570]
- Moens A I. 1878. Die pulscurve[M]. EJ Brill.
- Mohammadi H, Tarvirdizadeh B, Alipour K and Ghamari M. 2025. Cuffless blood pressure monitoring via PPG signals using a hybrid CNN-BiLSTM deep learning model with attention mechanism[J]. Scientific Reports, 15(1): 22229. [DOI:10.1038/s41598-025-07087-2]
- Naskinova I, Kolev M, Milev M and Mitev P. 2026. Signal-derived feature analysis for cuffless blood pressure estimation: comparing machine learning and deep learning on ICU physiological waveforms [J]. AI, 7(3): 98. [DOI:10.3390/ai7030098]
- Niu L, Speth J, Vance N, Sporrer B, Czajka A and Flynn P. 2023. Full-body cardiovascular sensing with remote photoplethysmography [C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver, Canada: IEEE: 5994-6004.
- Omer O A, Salah M, Hassan L, Abdelreheem A and Hassan A M. 2024. Video-based beat-by-beat blood pressure monitoring via transfer deep-learning [J]. Applied Intelligence, 54(6): 4564-4584. [DOI:10.1007/s10489-024-05354-9]
- Pflugfelder R. 2018. An in-depth analysis of visual tracking with Siamese neural networks[EB/OL]. <http://arxiv.org/abs/1707.00569>. [DOI:10.48550/arXiv.1707.00569]
- Pirzada P, Morrison D, Doherty G, Dhamsana D and Harris-Birtill D. 2022. Automated remote pulse oximetry system (ARPOS)[J]. Sensors, 22(13): #4974. [DOI:10.3390/s22134974]
- Pirzada P, Wilde A and Harris-Birtill D. 2024. Remote photoplethysmography for heart rate and blood oxygenation measurement: a review[J]. IEEE Sensors Journal, 24(15): 23436-23453.
- Poh M Z, McDuff D J and Picard R W. 2010. Non-contact, automated cardiac pulse measurements using video imaging and blind source separation[J]. Optics Express, 18(10): 10762-10774 [DOI:10.1364/OE.18.010762]
- Poh M Z, McDuff D J and Picard R W. 2011. Advancements in noncontact, multiparameter physiological measurements using a webcam

- [J]. IEEE Transactions on Biomedical Engineering, 58(1): 7-11. [DOI:10.1109/TBME.2010.2086456]
- Pruett J D, Bourland J D and Geddes L A. 1988. Measurement of pulse-wave velocity using a beat-sampling technique[J]. Annals of Biomedical Engineering, 16(4): 341-347. [DOI: 10.1007/BF02364622]
- Qian W, Guo D, Li K, Zhang X, Tian X and Yang X. Dual-Path Token-Learner for remote photoplethysmography-based physiological measurement with facial videos[J/OL]. IEEE Transactions on Computational Social Systems. 2024, 11(3): 4465-4477. [DOI: 10.1109/TCSS.2024.3356713]
- Qiao S. 2025. A comparative study of random forest and K-nearest neighbors for predicting hypertension and diabetes[C]// 2025 IEEE 3rd International Conference on Image Processing and Computer Applications (ICIPCA). IEEE: 326-331. [DOI: 10.1109/ICIPCA65645.2025.11138843]
- Qin C, Li Y, Liu C and Ma X. 2023. Cuff-less blood pressure prediction based on photoplethysmography and modified ResNet[J]. Bioengineering, 10(4): 400.
- Qin C, Wang X, Xu G and Ma X. 2022. Advances in cuffless continuous blood pressure monitoring technology based on PPG signals[J]. BioMed Research International, 2022(1): 8094351.
- Qiu Y, Ma X, Li X, Fan S, Deng Z and Huang X. 2024. Non-contact blood pressure estimation from radar signals by a stacked deformable convolution network [J]. IEEE Journal of Biomedical and Health Informatics, 28(8): 4553-4564.
- Roha V S and Yuce M R. 2026. Unraveling blood pressure estimation with a deep learning approach using multiple embeddings[J]. Computers in Biology and Medicine, 200: 111377. [DOI: 10.1016/j.combiomed.2025.111377]
- Roha V S, Ranjan R and Yuce M R. 2025. Evolving blood pressure estimation: from feature analysis to image-based deep learning models [J]. Journal of Medical Systems, 49(1): 97. [DOI: 10.1007/s10916-025-02228-6]
- Ryu J, Hong S, Liang S, Pak S, Chen Q and Yan S. 2021. A new framework for robust heart rate measurement based on the head motion state estimation[J]. IEEE Journal of Biomedical and Health Informatics, 25(9): 3428-3437. [DOI:10.1109/JBHI.2021.3083917]
- Sakib S, Hasan Z and Roy N. 2025. A state-of-the-art survey of remote photoplethysmography for contactless health parameters sensing [J]. WIREs Data Mining and Knowledge Discovery, 15(3): e70039. [DOI:10.1002/widm.70039]
- Scalise L, Bernacchia N, Ercoli I and Marchionni P. 2012. Heart rate measurement in neonatal patients using a webcam [C]// 2012 IEEE International Symposium on Medical Measurements and Applications Proceedings. Budapest, Hungary: IEEE: 1-4. [DOI: 10.1109/MeMeA.2012.6226654]
- Seepers R M, Wang W, De Haan G, Sourdis I and Strydis C. 2017. Attacks on heartbeat-based security using remote photoplethysmography[J]. IEEE Journal of Biomedical and Health Informatics, 22(3): 714-721.
- Selvaraju V, Spicher N, Wang J, Ganapathy N, Warnecke J M and Leonhardt S, et al. 2022. Continuous monitoring of vital signs using cameras: a systematic review[J]. Sensors, 22(11): #4097. [DOI: 10.3390/s22114907]
- Septian E, Khaefi M R, Athoillah A, Aisyah D N, Hardhantyo M, Rahman F M, et al. 2025. Prediction of personalised hypertension using machine learning in Indonesian population [J]. Journal of Medical Systems, 49(1): 137. [DOI: 10.1007/s10916-025-02253-5]
- Shao H, Luo L, Qian J J, Yan M K, Chen S and Yang J. 2025. Remote photoplethysmography in real-world and extreme lighting scenarios [C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville, TN, USA: IEEE: 10858-10867. [DOI:10.1109/CVPR52734.2025.01014]
- Slapničar G, Wang W and Luštrek M. 2024. Feasibility of remote blood pressure estimation via narrow-band multi-wavelength pulse transit time [J]. ACM Transactions on Sensor Networks, 20(4): 1-21. [DOI:10.1145/3597302]
- Son J, Choi Y S. Non-Contact Blood Pressure Estimation from Face Videos via Physiology-Aware Contrastive Learning[C/OL]//2026 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV). Tucson, AZ, USA: IEEE, 2026: 2414-2423. [DOI:10.1109/WACV61042.2026.00238]
- Taha Z, Shirley L and Razman M A M. 2017. A review on non-invasive hypertension monitoring system by using photoplethysmography method[J]. Malaysian Journal of Movement, Health & Exercise, 6(1): 47-57.
- Thambiraj G, Gandhi U, Mangalanathan U, Jose V J M and Anand M. 2020. Investigation on the effect of Womersley number, ECG and PPG features for cuff less blood pressure estimation using machine learning [J]. Biomedical Signal Processing and Control, 60: 101942. [DOI:10.1016/j.bspc.2020.101942]
- Tran D N, Lee H and Kim C. 2015. A robust real time system for remote heart rate measurement via camera[C]// 2015 IEEE International Conference on Multimedia and Expo (ICME). Turin, Italy: IEEE: 1-6. [DOI:10.1109/ICME.2015.7177484]
- Uhrina M, Sevcik L, Bienik J and Smatanova L. 2024. Performance comparison of VVC, AV1, HEVC, and AVC for high resolutions [J]. Electronics, 13(5): 953. [DOI: 10.3390/electronics13050953]
- Van Es V A A, Lopata R G P, Scilingo E P and Nardelli M. 2023. Contactless cardiovascular assessment by imaging photoplethysmography: a comparison with wearable monitoring[J]. Sensors, 23(3): #1505. [DOI:10.3390/s23031505]
- Van Putten L D and Bamford K E. 2023. Improving systolic blood pressure prediction from remote photoplethysmography using a stacked ensemble regressor[C]// Proceedings of the IEEE/CVF Conference

- on Computer Vision and Pattern Recognition. Vancouver, Canada: IEEE: 5957-5964.
- Verkruysse W, Svaasand L O and Nelson J S. 2008. Remote plethysmographic imaging using ambient light[J]. *Optics Express*, 16(26): 21434-21445. [DOI:10.1364/OE.16.021434]
- Viola P and Jones M. 2004. Robust real-time face detection[J]. *International Journal of Computer Vision*, 57(2): 137-154.
- Wang J, Shan C, Liu Z, Zhou S and Shu M. 2025. Physiological information preserving video compression for rPPG[J]. *IEEE Journal of Biomedical and Health Informatics*, 29(5): 3563-3575. [DOI:10.1109/JBHI.2025.3526837]
- Wang W J, Albertus C, Sander S and Gerard de H. 2017. Algorithmic principles of remote PPG[J]. *IEEE Transactions on Biomedical Engineering*, 64(7): 1479-1491. [DOI:10.1109/TBME.2016.2609282]
- Wu B F, Chiu L W, Wu Y C, Lai C C and Chu P H. 2022. Contactless blood pressure measurement via remote photoplethysmography with synthetic data generation using generative adversarial network[C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. New Orleans, LA, USA: IEEE: 2130-2138.
- Wu B F, Wu B J, Tsai B R and Hsu C P. 2022. A facial-image-based blood pressure measurement system without calibration[J]. *IEEE Transactions on Instrumentation and Measurement*, 71: 1-13. [DOI:10.1109/TIM.2022.3165827]
- Wu Y C, Chiu L W, Wu B F, Lin L L C, Ho T H and Chung M L, et al. 2023. Motion robust remote photoplethysmography measurement during exercise for contactless physical activity intensity detection[J]. *IEEE Transactions on Instrumentation and Measurement*, 72: 1-14. [DOI:10.1109/TIM.2023.3256470]
- Wuerich C, Humm E M, Wiede C and Schiele G. 2022. A feature-based approach on contact-less blood pressure estimation from video data[C]// *2022 30th European Signal Processing Conference (EUSIPCO)*. Belgrade, Serbia: IEEE: 1343-1347. [DOI:10.23919/EUSIPCO55093.2022.9909563]
- Wuerich C, Rademacher R, Wiede C and Grabmaier A. 2021. PTT-based contact-less blood pressure measurement using an RGB-camera[J]. *Current Directions in Biomedical Engineering*, 7(2): 375-378.
- Xi L, Chen W H, Zhao C C, Wu X M and Wang J H. Image enhancement for remote photoplethysmography in a low-light environment[C]// *Proceedings of 15th IEEE International Conference on Automatic Face and Gesture Recognition (FG 2020)*. Buenos Aires, Argentina: IEEE, 2020: 1-7. [DOI:10.1109/FG47880.2020.00076]
- Xi L, Wu X M, Chen W H, Wang J H and Zhao C C. Weighted combination and singular spectrum analysis based remote photoplethysmography pulse extraction in low-light environments[J]. *Medical Engineering and Physics*, 2022, 105: 103822. [DOI:10.1016/j.medengphy.2022.103822]
- Xing W, Shi Y, Wu C, Wang Y and Wang X. 2023. Predicting blood pressure from face videos using face diagnosis theory and deep neural networks technique[J]. *Computers in Biology and Medicine*, 164: 107112.
- Yan Y, Ma X, Yao L and Ouyang J. 2015. Noncontact measurement of heart rate using facial video illuminated under natural light and signal weighted analysis[J]. *Bio-Medical Materials and Engineering*, 26(s1): S903-S909. [DOI:10.3233/BME-151383]
- Yang L, Gu S, Liu B, Zhao Z, Qiao Y and Yang G, et al. 2025. A non-contact blood pressure measurement method based on face video[J]. *Physical and Engineering Sciences in Medicine*. [DOI:10.1007/s13246-025-01645-8]
- Yang Z, Wang H F, Liu B and Lu F. 2024. cbPPGGAN: a generic enhancement framework for unpaired pulse waveforms in camera-based photoplethysmography[J]. *IEEE Journal of Biomedical and Health Informatics*, 28(2): 598-608. [DOI:10.1109/JBHI.2023.3314282]
- Yu Y P, Kwan B H, Lim C L, Wong S L and Raveendran P. 2013. Video-based heart rate measurement using short-time Fourier transform[C]// *2013 International Symposium on Intelligent Signal Processing and Communication Systems*. Naha, Japan: IEEE: 704-707. [DOI:10.1109/ISPACS.2013.6704640]
- Yu Z T, Li X B and Zhao G Y. 2019. Remote photoplethysmograph signal measurement from facial videos using spatio-temporal networks[EB/OL]. <http://arxiv.org/abs/1905.02419>. [DOI:10.48550/arXiv.1905.02419]
- Zaza G, Casalino G, Caputo S and Castellano G. 2025. Estimating blood pressure using video-based PPG and deep learning[J]. *Image and Vision Computing*, 162: 105683. [DOI:10.1016/j.imavis.2025.105683]
- Zeng Y S, Yu D F, Song X Y, Wang Q Q, Pan L P, Lu H Z and Wang W J. 2024. Camera-based cardiorespiratory monitoring of preterm infants in NICU[J]. *IEEE Transactions on Instrumentation and Measurement*, 73: #5019813. [DOI:10.1109/TIM.2024.3395314]
- Zeng Y, Zhu Y, Song X, Wang Q, Yang J and Wang W. 2025. Camera-based neonatal blood pressure estimation from multisite and multi-wavelength pulse transit time — a proof of concept in NICU[J]. *IEEE Internet of Things Journal*, 12(13): 24775-24788. [DOI:10.1109/JIOT.2025.3557771]
- Zhang C, Wu X, Zhang L, He X and Lv Z. 2017. Simultaneous detection of blink and heart rate using multi-channel ICA from smart phone videos[J]. *Biomedical Signal Processing and Control*, 33: 189-200. [DOI:10.1016/j.bspc.2016.11.022]
- Zhang G, Shan C, Kirenko I, De Haan G and Kirenko I. 2017. Hybrid optical unobtrusive blood pressure measurements[J]. *Sensors*, 17(7): 1541.
- Zhang K, Zhang Z, Li Z and Qiao Y. 2016. Joint face detection and alignment using multitask cascaded convolutional networks[J].

- IEEE Signal Processing Letters, 23(10): 1499-1503. [DOI: 10.1109/LSP.2016.2603342]
- Zhang X X, Hu M H, Zhang Y D, Zhai G T and Zhang X P. 2023. Recent progress of optical imaging approaches for noncontact physiological signal measurement: a review [J]. Advanced Intelligent Systems, 5(9): #2200345. [DOI: 10.1002/aisy.202200345]
- Zhang Y and Feng Z. 2017. A SVM method for continuous blood pressure estimation from a PPG signal[C]// Proceedings of the 9th International Conference on Machine Learning and Computing. Singapore: ACM: 128-132. [DOI: 10.1145/3055635.3056634]
- Zhang Y, Qiu S, Du K, Wu S, Xiang T and Zheng K, et al. 2026. Artificial intelligence-enhanced wearable blood pressure monitoring in resource-limited settings: a co-design of sensors, model, and deployment[J]. Nano-Micro Letters, 18(1): 164. [DOI: 10.1007/s40820-025-02003-9]
- Zhao C C, Lin C L, Chen W H and Li Z G. A novel framework for remote photoplethysmography pulse extraction on compressed videos[C]// Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Salt Lake City, USA: IEEE, 2018: 1412-1421. [DOI: 10.1109/CVPRW.2018.00182]
- Zhao P, Sun Q, Tian X, Yang Y, Tao S and Cheng J, et al. 2024. Toward motion robustness: a masked attention regularization framework in remote photoplethysmography [C]// 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Seattle, WA, USA: IEEE: 7829-7838. [DOI: 10.1109/CVPRW63382.2024.00779]
- Zhou C, Ye X, Wei Y, De Florio V, Sun H and Zhan X, et al. 2025. A comprehensive evaluation of multiple video compression algorithms for preserving BVP signal quality[J]. Biomedical Signal Processing and Control, 103: 107445. [DOI: 10.1016/j.bspc.2024.107445]
- Zhou C Y, Zhan X L, Wei Y W, Zhang X C, Li Y G, Wang C C and Ye X L. 2025. Review of heart rate variability parameter estimation methods in facial video[J]. Journal of Image and Graphics, 30(4): 0953-0976. (周才英, 占新龙, 魏远旺, 张先超, 李永刚, 王超超, 叶晓朗. 2025. 人脸视频中心率变异性参数估计方法综述. 中国图象图形学报, 30(4): 0953-0976) [DOI: 10.11834/jig.240314]

作者简介

欧阳杰,男,博士研究生,主要研究方向为医学信号处理。E-mail: 6120220164@mail.jxust.edu.cn

王胜,男,硕士研究生,主要研究方向为中医学。E-mail: Kingshen@sohu.com

王超超,男,副教授,主要研究方向为毫米波/太赫兹非接触人体生理信息感知、SCG 信号智能处理等。E-mail: ccwang@zjxu.edu.cn