

doi: 10.17586/2226-1494-2026-26-2-236-249

УДК 004.8

Обзор методов глубокого обучения для обработки видеоданных в фотоплетизмографии

Иван Максимович Рубин¹✉, Максим Александрович Волинский²

^{1,2} Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация

¹ imrubin@itmo.ru✉, <https://orcid.org/0000-0001-6273-5094>

² maxim.volynsky@itmo.ru, <https://orcid.org/0000-0003-1679-4450>

Аннотация

Введение. Представлен обзор современных методов глубокого обучения для обработки данных удаленной фотоплетизмографии. Рассмотрены архитектуры сверточных нейронных сетей, трансформеров, рекуррентных и генеративных моделей для предобработки видеосигнала, а также извлечения физиологически значимых параметров в условиях с артефактами, вызванными движением, изменением освещения или низким качеством видео. Выполнен анализ перспектив внедрения алгоритмов глубокого обучения в реальных медицинских сценариях на основе предложенных критериев с учетом существующих проблем интеграции, востребованности решений и валидации результатов. **Метод.** Выполнен обзор существующих методов глубокого обучения, которые используют видеосигнал для оценки сигнала фотоплетизмографии с использованием новых критериев для оценки методов, включая многомерность выходного сигнала фотоплетизмографии, открытость исходного кода и наличие информации о временных затратах, что является важным для их практического применения в реальном времени в медицинских учреждениях. **Основные результаты.** Показано, что методы глубокого обучения значительно превосходят традиционные подходы в задачах оценки физиологических параметров, в процессах диагностики сердечно-сосудистых заболеваний, а также предобработке видеосигнала. Выявлено, что большинство существующих решений, основанных на глубоком обучении, ограничиваются одномерным выходным сигналом из-за сложности получения многомерной разметки для обучения с учителем. Дополнительный анализ показал дефицит информации о временных и вычислительных затратах, что ограничивает практическое применение методов глубокого обучения в реальном времени. Представленная систематизация раскрывает ключевые термины, связанные с обработкой сигналов фотоплетизмографии: контактная фотоплетизмография, фотоплетизмография на основе видео, удаленная фотоплетизмография, визуализация фотоплетизмографии. Представлено описание подходов к сбору наборов данных, учитывающих концепции многомерности, многоканальности и мультимодальности сигналов. **Обсуждение.** Полученные результаты могут быть применены при разработке систем удаленного мониторинга здоровья, включая медицинские и бытовые устройства. Обзор будет полезен специалистам в области биомедицинской инженерии, медицинской информатики, а также разработчикам решений для анализа физиологических сигналов.

Ключевые слова

фотоплетизмография, визуализирующая фотоплетизмография, удаленная фотоплетизмография, многомерная фотоплетизмография, глубокое обучение, нейронные сети

Благодарности

Работа выполнена при поддержке государственного задания № FSER-2025-0020 в рамках национального проекта «Наука и университеты».

Ссылка для цитирования: Рубин И.М., Волинский М.А. Обзор методов глубокого обучения для обработки видеоданных в фотоплетизмографии // Научно-технический вестник информационных технологий, механики и оптики. 2026. Т. 26, № 2. С. 236–249. doi: 10.17586/2226-1494-2026-26-2-236-249

Review of deep learning methods for imaging photoplethysmography data processing

Ivan M. Rubin¹✉, Maxim A. Volynsky²

^{1,2} ITMO University, Saint Petersburg, 197101, Russian Federation

¹ imrubin@itmo.ru✉, <https://orcid.org/0000-0001-6273-5094>

² maxim.volynsky@itmo.ru, <https://orcid.org/0000-0003-1679-4450>

Abstract

This paper presents a review of contemporary deep learning methods for processing remote photoplethysmography data. Architectures of convolutional neural networks, transformers, recurrent, and generative models are examined for video signal preprocessing and for extracting physiologically significant parameters under conditions involving artifacts caused by motion, illumination changes, or low video quality. An analysis of the prospects for implementing deep learning algorithms in real-world medical scenarios is conducted based on the proposed criteria, considering existing integration challenges, the demand for such solutions, and issues related to result validation. The study includes a review of existing deep learning approaches that utilize video signals to estimate imaging photoplethysmography. The methods are evaluated using newly proposed criteria, including the multidimensionality of the photoplethysmography output signal, the availability of open-source code, and the reporting of computational time costs, which is essential for their practical real-time application in medical institutions. It is shown that deep learning methods significantly outperform traditional approaches in physiological parameter estimation, cardiovascular disease diagnosis, and video signal preprocessing. However, most existing deep learning-based solutions are limited to one-dimensional output signals due to the complexity of obtaining multidimensional annotations required for supervised learning. Additional analysis revealed a lack of information regarding temporal and computational costs, which restricts the practical real-time implementation of these methods. The proposed systematization clarifies key terms related to photoplethysmography signal processing: contact photoplethysmography, imaging photoplethysmography, remote photoplethysmography, and photoplethysmographic imaging. Approaches to dataset collection are also described, considering the concepts of multidimensionality, multichannel, and multimodal signals. The results may be applied in the development of remote health monitoring systems, including medical and consumer devices. The review will be of interest to specialists in biomedical engineering, medical informatics, and developers of physiological signal analysis solutions.

Keywords

photoplethysmography, imaging photoplethysmography, remote photoplethysmography, spatial photoplethysmography, deep learning, neural networks

Acknowledgements

This work was supported by the State Assignment No. FSER-2025-0020 under the national project “Science and Universities”.

For citation: Rubin I.M., Volynsky M.A. Review of deep learning methods for imaging photoplethysmography data processing. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2026, vol. 26, no. 2, pp. 236–249 (in Russian). doi: 10.17586/2226-1494-2026-26-2-236-249

Введение

Фотоплетизмография (Photoplethysmography, PPG) представляет собой метод мониторинга физиологических параметров, основанный на анализе изменений в поглощении света, вызванных пульсирующим характером тканевой перфузии [1]. Этот метод активно используется для измерения таких показателей, как частота сердечных сокращений (ЧСС), уровень кислорода в крови, артериальное давление (АД) и других физиологических параметров. Основной принцип работы PPG заключается в том, что источник света излучает свет на кожные ткани, а фотодетектор измеряет количество поглощенного и рассеянного света [2].

Существует два основных типа PPG-датчиков, которые определяют способ регистрации сигнала: на пропускание и на отражение. В случае применения датчика на пропускание свет проходит через ткань и достигает фотодетектора с противоположной стороны относительно источника света, в то время как датчики на отражение регистрируют отраженный световой поток фотодетектором, расположенным рядом с источником света. Оба типа фиксируют изменения поглощения света, вызванные пульсирующим кровотоком,

что позволяет проводить анализ физиологических параметров.

Взаимодействие света с тканями определяется длиной волны света, что является важным аспектом для получения физиологической информации. Широкий спектр длин волн, включая инфракрасный диапазон (780–2400 нм), красный цвет (622–780 нм) и зеленый свет (500–570 нм), широко используется в этих целях [3–6]. Было определено, что зеленый свет демонстрирует особенно высокую эффективность в условиях движения, благодаря своей способности минимизировать воздействие артефактов. Это делает его предпочтительным выбором для использования во многих приложениях мониторинга здоровья [7].

Схема классификации методов PPG и соответствующих характеристик сигнала представлена на рис. 1. Методы делятся на два основных типа: контактная фотоплетизмография (contact Photoplethysmography, cPPG) [8] и бесконтактная на основе видеосигнала (imaging Photoplethysmography, iPPG) [9].

cPPG включает сенсоры, которые непосредственно контактируют с кожей, например, в смарт-часах и медицинских устройствах. На выходе контактного метода ожидается одномерный сигнал. Одномерные методы




Рис. 1. Классификация методов фотоплетизмографии

Fig. 1. Classification of photoplethysmography methods

фиксируют временной сигнал из одной точки контакта, что делает их уязвимыми к локальным изменениям, например, из-за давления или положения сенсора.

iPPG включает в себя все методы, измеряющие параметры без физического контакта и используют пространственно-временной анализ изображений [10]. Неконтактные методы можно условно разделить на две подгруппы: (remote Photoplethysmography, rPPG), основанные на анализе сигналов в цветовых каналах (RGB), и методы, работающие с видео в определенном спектре [11].

Большинство описанных в работах методов подразумевают одномерный выходной сигнал, соответствующий определенному физиологическому параметру. Однако также существуют исследования по получению выходного многомерного сигнала для гомогенной визуализации (Photoplethysmographic Imaging (PPGI), PPG mapping, Spatial PPG).

В [12] выделены преимущества PPGI над традиционными методами измерения перфузионных карт крови, такие как сложные протоколы измерений и высокая стоимость оборудования. Ранние алгоритмы построения таких карт основывались на разбиении изображения на области и последующем применении Фурье-преобразования [13].

В [14] представлен инструмент PulseCam, который сравнивает сигнал каждого пикселя с эталонным PPG-сигналом от пальцевого датчика, позволяя создавать перфузионные карты с полным пространственным

разрешением камеры. Исследование [15] показало, что динамика амплитуды пульсации крови, измеренная с помощью PPGI, может служить перспективным биомаркером мигрени. Кроме того, технологии PPGI используются в сочетании с электрокардиографией для оценки времени распространения пульсовой волны и ее пространственного распределения [16]. Обзор широкого спектра систем PPGI и их применения в физиологических исследованиях представлен в [17], где описаны внедряемые на тот момент методы. Алгоритмы PPGI в [18, 19] включают видеозахват, извлечение области интереса, фильтрацию и анализ интенсивностей, что позволяет рассчитывать частоту и амплитуду пульса в режиме реального времени. Для диагностики кожных заболеваний предлагаются оптические методы, использующие портативные устройства [20]. Метод на основе преобразования Эйлера [21] демонстрирует улучшенное разрешение и повышенную чувствительность карт микроциркуляции, что расширяет возможности неинвазивного мониторинга.

Сигналы PPG могут классифицироваться по способам формирования и структуры получаемого набора данных, что определяет подход к сбору и обработке данных (рис. 2). Во-первых, возможно различие по числу каналов: одноканальный сигнал формируется с одного датчика или камеры, что упрощает сбор данных, но может ограничивать детализацию. В противоположность этому, многоканальные данные создаются с использованием нескольких датчиков [22] или камер,

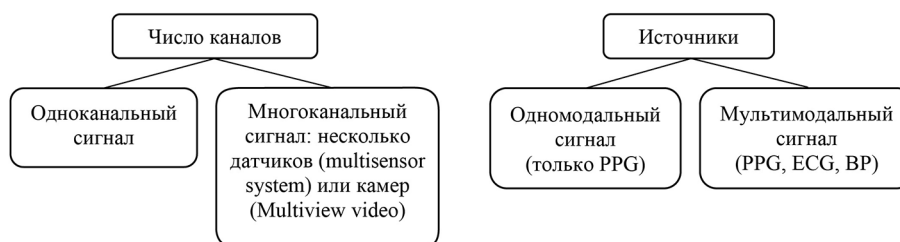


Рис. 2. Классификация подходов формирования набора данных PPG

Fig. 2. Classification of approaches to PPG dataset collection

что позволяет получить более полное представление о пространственном распределении физиологических параметров. Во-вторых, сигналы делятся по источникам: одномодальные данные содержат только PPG-сигнал, предоставляя узконаправленную информацию, тогда как мультимодальные наборы данных объединяют PPG с другими типами данных [23], такими как электрокардиография (ЭКГ) или АД, обеспечивая комплексный подход к анализу. Такая классификация методов получения данных позволяет адаптировать выбор оборудования и протоколов под конкретные задачи исследования.

Методы обработки сигналов фотоплетизмографии

Традиционные методы обработки сигналов PPG включают алгоритмы, основанные на цифровых фильтрах [24], адаптивных порогах [25] и вейвлет-преобразованиях [26], которые широко применялись для выделения ключевых характеристик одномерного сигнала. Помимо анализа одномерных временных рядов, значительное внимание уделяется методам обработки видео, которые позволяют извлекать информацию о физиологических параметрах с использованием видеозаписей кожи человека (iPPG). Такие методы, как AutoSparsePPG [27] и SparsePPG [28], применяют подходы к сжатию данных для выделения ключевых сигналов из видеоряда, в то время как DistancePPG [29] использует пространственную информацию для повышения точности измерений. Метод независимых компонент [30] эффективно разделяет источники сигналов в многомерных данных, что делает его полезным при наличии сложных артефактов. Методы CHROM [31] и POS [32] основаны на анализе цветовых каналов RGB, где их комбинации используются для улучшения извлечения пульсовых волн, снижая влияние движений и изменений освещения.

В настоящее время существует ряд решений с открытым исходным кодом на Python, включающие следующие методы: HeartPy [33], pyPPG [34], pyVHR [35].

В последние годы в обработке сигналов PPG все чаще используются методы искусственного интеллекта, включая методы глубокого обучения (Deep Learning, DL). Методы DL продемонстрировали превосходство в различных приложениях PPG, таких как обнаружение фибрилляции предсердий [36] и оценка АД [37–39]. Примеры также включают инструмент ActiPPG [40], использующий данные умных часов для классификации активности, и метод на основе DeepConvLSTM [41], анализирующий мультимодальные данные с разных сенсоров, протестированный на наборах Opportunity¹ и Skoda². Для биометрического распознавания применяются стратегии с архитектурами 1D-CNN [42], обрабатывающие мультимодальные данные для определения

долгосрочных зависимостей. PP-Net [43] с архитектурой CNN-LSTM, обученный на базе MIMIC-II³, применяется для оценки ЧСС и АД, тогда как инструмент Q-PPG [44], ориентированный на работу в реальном времени, сочетает каскад Neural Architecture Search и Hardware-Friendly Quantizer для создания оптимальных моделей, анализирующих PPG и акселерометрические данные.

В настоящей работе рассматриваются возможности и перспективы применения глубокого обучения для обработки сигналов iPPG, а также их преимущества по сравнению с традиционными методами. Предметом исследования являются современные методы DL, позволяющие улучшить качество видеосигнала, повысить точность и устойчивость анализа данных iPPG, несмотря на их подверженность шуму и артефактам, характерным для дистанционных многомерных измерений. При этом задачи обработки и применения алгоритмов могут варьироваться и включать в себя: определение физиологических параметров из исходных данных, повышение разрешения, удаление шума, обнаружение и отслеживание области интереса (Region of interest, ROI) (рис. 3).

Методология поиска, отбора и анализа публикаций

Для настоящей работы применялись следующие сочетания запросов на платформах Google Scholar, Semantic Scholar и PubMed: («deep learning» или «DL») и («remote photoplethysmography» или «rPPG», или «imaging photoplethysmography» или «iPPG») для поиска работ по обработке видеосигнала; («deep learning» или «DL») и («photoplethysmography» или «PPG») для описания работ по обработке одномерного сигнала; («PPGI» или «PPG Imaging», или «spatial PPG», или «PPG mapping») для описания работ по оценке крово-




Рис. 3. Алгоритм извлечения сигнала iPPG из видеоданных
Fig. 3. Algorithm for extracting iPPG signals from video data

¹ [Электронный ресурс]. Режим доступа: <https://archive.ics.uci.edu/dataset/226/opportunity+activity+recognition> (дата обращения: 15.01.2025).

² [Электронный ресурс]. Режим доступа: <http://har-dataset.org/doku.php?id=wiki:dataset> (дата обращения: 15.01.2025).

³ [Электронный ресурс]. Режим доступа: <https://archive.physionet.org/mimic2/> (дата обращения: 15.01.2025).




Рис. 4. Структура поиска и отбора публикаций

Fig. 4. Structure of literature search and selection

обращения и перфузии тканей. Подробный алгоритм отбора публикаций представлен на рис. 4.

Необходимо определить ряд существующих проблем, связанных с применением алгоритмов DL в области обработки медицинских изображений и извлечении сигнала iPPG.

В работе [45] было отмечено, что значительные улучшения в области обработки медицинских изображений тесно связаны с прогрессом в области архитектур нейронных сетей. В период пандемии COVID-19 было разработано множество подходов на основе DL для обеспечения точной и быстрой диагностики заболеваний. После анализа более 200 предсказательных моделей из 169 исследований, опубликованных до 1 июля 2020 года, в [46] был сделан вывод, что все эти модели имели высокий или неопределенный риск систематических ошибок из-за переобучения, некорректной валидации и использования неподходящих данных. Таким образом, ни одна из моделей не была пригодна для клинического использования, в то время как результаты предсказаний были относительно высокими. В связи с этим необходимо учитывать открытость исходного кода и документации представленного метода.

Существует также проблема использования открытых наборов данных. Поскольку научное сообщество стремится достичь лучшей производительности, су-

ществует вероятность переобучения на этом наборе данных на уровне сообщества [47]. При применении нескольких наборов данных предвзятость снижается, но не до уровня, достаточного для широкомасштабных клинических приложений. Также не редкость, когда различные исследования выбирают разные подмножества образцов из одного и того же публичного набора данных. Исходя из этого, важно фиксировать, какие наборы данных применялись для тестирования модели, а также их количество.

В медицинской сфере существует запрос на оценку кровообращения и перфузии тканей, которая играет ключевую роль в хирургических вмешательствах [48]. Изменения в кровоснабжении органов могут происходить как в результате патологических процессов, так и вследствие хирургических манипуляций. В этих условиях важность количественной оценки перфузии тканей заключается в предоставлении хирургу дополнительных данных для более точного планирования и корректировки хода операции. В настоящее время большинство исследований сосредоточено на извлечении одномерного сигнала, что не дает такой подробной информации и не покрывает описанную потребность.

К ряду параметров, которые могут быть использованы для оценки физиологических состояний и диагностики заболеваний, относятся частота пульса и его

вариабельность, уровень насыщения крови кислородом, АД, частота дыхания, артериальная жесткость, центральное венозное давление, лодыжечно-плечевой индекс, микроциркуляция [49] и другие. Однако большинство работ и соответствующих обзоров сфокусированы только на некоторых из них.

Существует ряд работ, описывающих современные методы и архитектуры DL, применяемых для обработки видеосигнала iPPG (табл. 1), однако они не обладают достаточной информацией о временных и ресурсных затратах алгоритма, доступности исходного кода, сосредоточены только на некоторых физиологических параметрах и не затрагивают области PPGI. Данные аспекты являются критически важными для использования алгоритмов в реальных медицинских сценариях.

Данный обзор охватывает следующий исследовательский вопрос: насколько применимы существующие архитектуры и алгоритмы DL для обработки видеосигнала и извлечения различных физиологических параметров в реальных медицинских сценариях на основе сформулированных критериев, касающихся решаемой задачи, используемых методов и данных, временных затрат, открытости решений и возможности визуализации.

Критерию «задача» соответствует определение и формализация проблемы, которую необходимо решить с помощью анализа сигналов PPG. Это может быть извлечение физиологических параметров, классификация состояния пациента, выявление аномалий, оценка активности пользователя или задачи, связанные с преобразованием данных.

При описании методов подразумеваются решения и алгоритмы, используемые для обработки видеосигналов iPPG с применением технологий DL. Среди них: сверточные нейронные сети (Convolutional Neural Networks, CNN), предназначенные для извлечения пространственных и временных признаков из видеопоследовательности; рекуррентные сети (Recurrent Neural Network, (RNN), Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU)), применяемые для анализа временных зависимостей в видеофрагментах; комби-

нированные архитектуры для интеграции различных типов нейронных сетей и улучшения производительности; механизмы внимания, помогающие фокусироваться на важных временных и пространственных признаках в видеопотоке; автокодировщики, используемые для снижения размерности видеоданных и выделения значимых характеристик; трансформеры, которые эффективны при работе с видеосигналами, особенно в случае длительных видеопоследовательностей; генеративные модели, которые применяются для синтеза и улучшения качества видеосигналов, устранения шумов.

Критерий «данные» описывает наборы данных, которые используются для обучения и тестирования моделей DL для анализа видеосигналов iPPG, могут включать необработанные видеопоследовательности, полученные с камер в условиях лабораторных экспериментов или реального мира, где видеоряд может быть одно- или многоканальным, например, видеосигналы с разных камер. Также применяются мультимодальные данные, включающие видеосигналы и данные с других датчиков, таких как акселерометры и гироскопы, что позволяет учитывать дополнительные физические параметры для более точного анализа физиологических сигналов. Важную роль играют аннотированные данные, метки которых указывают на определенные состояния (например, здоровые/патологические) или события (сердечный ритм, дыхательные циклы), что помогает в обучении и тестировании моделей.

Критерию «временные затраты» соответствует оценка временных затрат при применении алгоритмов DL для обработки видеосигналов iPPG, а также способность модели работать в реальном времени, что является критически важным аспектом для практических приложений.

Доступность исходного кода и описание технической реализации моделей DL для обработки видеосигналов iPPG описаны с помощью критерия «открытая реализация». Это может включать библиотеки, фреймворки и примеры кода, которые позволяют воспроиз-

Таблица 1. Существующие обзоры iPPG

Table 1. Existing iPPG reviews

Ссылка на источник	Временные затраты	Задача	PPGI	Информация об открытости кода	Данные
[10]	+	Определение ЧСС	–	+	+
[50]	–	Определение перфузии тканей, ЧСС, насыщения крови кислородом, частоты дыхания, АД, вариабельности сердечного ритма	+	–	+
[51]	–	Определение ЧСС	–	+	+
[52]	–	Определение АД	–	–	+
[53]	–	Определение перфузии тканей, ЧСС, насыщения крови кислородом, частоты дыхания, АД, сосудистых нарушений, вариабельности сердечного ритма	+	–	–

Примечание. «+» — информация представлена в обзоре, «–» — информация отсутствует в обзоре.

Comment. ‘+’ means that information is presented in the review; ‘–’ means that information is missing.

вести или адаптировать решения для различных сценариев и устройств.

Выходные данные моделей могут быть как многомерными — карты распределения физиологических параметров по лицу или другим частям тела (PPGI), так и одномерными — извлеченные параметры сердечного ритма или другие агрегированные показатели, поэтому был введен критерий «выходной многомерный сигнал».

Применение глубокого обучения для обработки многомерного сигнала iPPG

Современные подходы на основе DL демонстрируют значительный прогресс в обработке данных iPPG. Развитие методов обработки позволяет достигать высокой точности оценки физиологических параметров даже в сложных условиях.

Так, архитектура IPPGResNet18 показала высокую точность оценки ЧСС на многоспектральных видео, обеспечивая устойчивость к движениям [54]. Разработка U-Net с добавлением GRU для работы с временными рядами на основе NIR-видео позволила улучшить извлечение сигналов в сложных условиях [55].

Для повышения точности rPPG предлагается модель ESA-rPPGNet, которая использует 3D-свертки и блоки внимания для анализа вариабельности сердечного ритма [56]. Аналогично методы, основанные на глубоких пространственно-временных архитектурах, показали свою эффективность в восстановлении rPPG-сигналов, применяемых для анализа ЧСС и диагностики аритмий [57, 58].

Современные архитектуры, включая X-iPPGNet и BiFormer, демонстрируют значительное превосход-

ство над традиционными методами, предлагая более высокую точность оценки пульса и устойчивость к артефактам, вызванным движением или сжатием видео [59, 60]. Применение трансдуктивного мета-обучения для адаптации моделей к изменениям в распределении данных улучшает производительность в реальных сценариях [61].

Кроме того, комбинированные подходы, такие как STVEN + rPPGNet, объединяющие улучшение видео с анализом сигналов rPPG, показали высокую эффективность даже на сжатых данных [62]. В ряде исследований используются методы увеличения данных и гибридные архитектуры для дальнейшего повышения точности и снижения вычислительных затрат [63, 64].

В работе [65] предложена rPPGRNet в сочетании с рекуррентной сетью для суперразрешения лицевых изображений с улучшенными и восстановленными rPPG сигналами из видеозаписей лица с низким разрешением. В [66] представлен новый подход для iPPG с использованием шага предварительной обработки суперразрешения изображений, который может снизить среднюю абсолютную ошибку в предсказании ЧСС более чем на 30 %.

В [67] рассмотрен метод физиологических измерений на основе rPPG с использованием Dual-GAN, где BVP-GAN восстанавливает пульсовый сигнал, а Noise-GAN моделирует шум. Взаимодействие сетей улучшает разделение пульсовой волны кровенаполнения и шумов, повышая точность измерений. Метод AND-rPPG, предложенный в работе [68], представляет собой также подход для подавления шума в rPPG, эффективно устраняющий помехи, вызванные мимикой лица.

Таблица 2. Методы глубокого обучения для анализа видеосигнала iPPG

Table 2. Deep learning methods for iPPG video signal analysis

Задача	Метод	Данные	Временные затраты	Открытая реализация	Выходной многомерный сигнал
Определение ЧСС	IPPGResNet18 [54]	мультиспектральный видео набор данных, RGB видео набор данных	+	—	—
Определение ЧСС	Turnip: time-series U-Net [55]	MERL-Rice Near-Infrared Pulse (MR-NIRP) набор данных, записанный в автомобиле	—	—	—
Определение ЧСС	EVM-CNN [69]	MMSE-HR	+	—	—
Определение ЧСС	ESA-rPPGnet [56]	UBFC-rPPG, PURE	+	—	—
Определение вариабельности сердечного ритма	3D-CNN [57]	MAHNOB-HCI	—	—	—
Сегментация кожи	U-Net [70]	—	—	—	—
Определение физиологических параметров	На основе CNN [71]	HNU PURE	—	—	—
Определение ЧСС и частоты дыхания	DeepPhys [72]	MAHNOB-HCI	—	+ ¹	—

¹ [Электронный ресурс] Режим доступа: <https://github.com/terbed/Deep-rPPG> (дата обращения: 15.01.2025).

Таблица 2. Продолжение

Table 2. Continuation

Задача	Метод	Данные	Временные затраты	Открытая реализация	Выходной многомерный сигнал
Определение ЧСС	На основе CNN [73]	PPG-DaLiA	—	—	—
Определение ЧСС	HeartTrack [74]	UBFC-RPPG, MoLi-ppg-1, MoLi-ppg-2	—	—	—
Определение ЧСС	3D-CNN [63]	Синтетические данные	—	—	+
Определение ЧСС	Meta-rPPG [61]	MAHNOB-HCI, UBFC-RPPG	—	+ ¹	—
Определение сигнала PPG	3 D C N N - b a s e d PhysNet RNN-based PhysNet [58]	MAHNOB-HCI	—	—	—
Определение сигнала PPG	DeepRPPG [64]	MAHNOB-HCI, PURE	—	—	—
Определение ЧСС	X-iPPGNet [59]	MMSE-HR, UBFC-rPPG, MAHNOB-HCI	—	—	—
Определение ЧСС	BiFormer [60]	PURE, UBFC	—	—	—
Предобработка, определение ЧСС	STVEN_rPPGNet [62]	OBF, MAHNOB-HCI	—	+ ²	—
Определение АД	OVAR-BPnet [75]	два закрытых набора данных (PPWg and iPPG), один публичный (MIMIC III)	—	—	—
Генерация сигнала PPG, определение физиологических параметров	PulseGAN [76]	UBFC-RPPG	—	+ ³	—
Суперразрешение, определение ЧСС	rPPGRNet, THRNet [65]	DEAP, MMVS	—	—	—
Суперразрешение, определение сигнала PPG	DRCN [66]	Набор данных из [77]	—	—	—
Сегментация кожи, отслеживание ROI	LinkNet [78]	PURE, CCUHR	—	—	—
Фильтрация	Dual-GAN [67]	UBFC-rPPG, VIPL-HR, PURE	—	—	—
Фильтрация	AND-rPPG [68]	UBFC-rPPG, CONFACE	—	—	—

Примечание. «+» — информация представлена в обзоре, «—» — информация отсутствует в обзоре.

Comment. ‘+’ means that information is presented in the review; ‘—’ means that information is missing.

¹ [Электронный ресурс] Режим доступа: <https://github.com/eugenelet/Meta-rPPG> (дата обращения: 15.01.2025).

² [Электронный ресурс]. Режим доступа: https://github.com/ZitongYu/STVEN_rPPGNet (дата обращения: 15.01.2025).

³ [Электронный ресурс]. Режим доступа: <https://pulsegan.readthedocs.io/> (дата обращения: 15.01.2025).

Вышеописанные методы представлены в сводной табл. 2.

Следует отметить, что большинство исследований не уделяет должного внимания анализу временных и вычислительных затрат, что играет ключевую роль в возможности применения таких методов в медицинских учреждениях для работы в режиме реального времени. Кроме того, открытый исходный код представлен не всегда, что затрудняет воспроизведение и дальней-

шее развитие этих подходов. Многомерный выходной сигнал в основном не встречается в работах с DL.

Заключение

Современные методы глубокого обучения демонстрируют значительный прогресс в обработке данных сигнала фотоплетизмографии, обеспечивая высокую точность извлечения физиологических параметров

даже в сложных условиях. Пространственно-временные архитектуры доказали свою эффективность в задачах оценки частоты сердечных сокращений, вариабельности сердечного ритма и других физиологических параметров. Например, архитектура IPPGResNet18 продемонстрировала высокую устойчивость к движениям и изменениям освещения при анализе многоспектральных данных, а U-Net с добавлением Gated Recurrent Unit значительно улучшила извлечение сигналов в условиях низкого качества видео. Модели с использованием 3D-сверток и блоков внимания подтвердили свою эффективность для задач, связанных с анализом частоты сердечных сокращений. Комбинированные подходы, такие как STVEN + rPPGNet, успешно объединяют улучшение качества видео с анализом физиологических сигналов, обеспечивая высокую точность даже при работе со сжатыми данными. Архитектуры X-iPPGNet и BiFormer выделяются своей устойчивостью к артефактам, вызванным движением. Модели для предобработки, фильтрации, суперразрешения, сегментации видеосигнала позволяют не только улучшить точность измерений, но и повысить устойчивость методов к внешним помехам, делая дистанционный мониторинг более надежным и применимым в реальных условиях. Традиционные алгоритмы, такие как метод независимых компонент и CHROM, остаются полезными в условиях ограниченных вычислительных ресурсов, но их эффективность снижается в сложных сценариях, где глубокое обучение становится более предпочтительным.

Однако, несмотря на значительный прогресс, текущие исследования сталкиваются с рядом ограничений. Одним из ключевых вызовов остается высокая вычис-

лительная стоимость современных моделей, что затрудняет их интеграцию в системы реального времени. Кроме того, большинство исследований ограничивается извлечением одномерных сигналов, в то время как многомерные данные обладают потенциалом для решения более сложных задач, таких как гемодинамическая визуализация. Проблемой остается и недостаточная открытость: исходный код и данные для воспроизведения результатов часто недоступны, что замедляет прогресс в этой области.

Глубокое обучение зарекомендовало себя как мощный инструмент для обработки iPPG данных, однако остается значительный потенциал для его улучшения. Для дальнейшего развития рекомендуется сосредоточиться на создании легких моделей, способных работать в реальном времени без потери точности, и увеличении открытости исходного кода. Перспективным направлением является разработка архитектур, способных осуществлять предобработку видеосигнала, которая позволит повысить качества извлекаемого сигнала iPPG. Методы увеличения обучающего набора данных и генерация синтетических видео помогут повысить обобщающую способность моделей, включая создание усложненных наборов данных с эмуляцией реальных сценариев, таких как движения пациентов, изменяющиеся условия освещения, вариации углов обзора и другие артефакты, характерные для сложных условий. Однако основное внимание необходимо уделить разработке технологий для практического применения с учетом реальных потребностей медицины, где важно обеспечивать возможность извлечения различных физиологических параметров в многомерном формате для более комплексного анализа и диагностики.

Литература

1. Nie G., Zhu J., Tang G., Zhang D., Geng S., Zhao Q., et al. A Review of deep learning methods for photoplethysmography data // arXiv. 2024. arXiv:2401.12783. <https://doi.org/10.48550/arXiv.2401.12783>
2. Ray D., Collins T., Woolley S., Ponnappalli P. A review of wearable multi-wavelength photoplethysmography // IEEE Reviews in Biomedical Engineering. 2021. V. 16. P. 136–151. <https://doi.org/10.1109/rbme.2021.3121476>
3. Vavrinsky E., Esfahani N.E., Hausner M., Kuzma A., Rezo V., Donoval M., et al. The current state of optical sensors in medical wearables // Biosensors. 2022. V. 12. N 4. P. 217. <https://doi.org/10.3390/bios12040217>
4. Chang C.-C., Wu C.-T., Choi B.I., Fang T.-J. MW-PPG sensor: An on-chip spectrometer approach // Sensors. 2019. V. 19. N 17. P. 3698. <https://doi.org/10.3390/s19173698>
5. Sugita N., Noro T., Yoshizawa M., Ichiji K., Yamaki S., Homma N. Estimation of absolute blood pressure using video images captured at different heights from the heart // Proc. of the 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). 2019. P. 4458–4461. <https://doi.org/10.1109/embc.2019.8856362>
6. Kamshilin A.A., Margaryants N.B. Origin of photoplethysmographic waveform at green light // Physics Procedia. 2017. V. 86. P. 72–80. <https://doi.org/10.1016/j.phpro.2017.01.024>
7. Alharbi S., Hu S., Mulvaney D., Blanos P. An applicable approach for extracting human heart rate and oxygen saturation during physical movements using a multi-wavelength illumination optoelectronic sensor system // Proceedings of SPIE. 2018. V. 10486. P. 104860S. <https://doi.org/10.1117/12.2287854>
8. Bousefsaf F., Djeldjli D., Ouzar Y., Maaoui C., Pruski A. iPPG 2 cPPG: reconstructing contact from imaging photoplethysmographic signals using U-Net architectures // Computers in Biology and Medicine. 2021. V. 138. P. 104860. <https://doi.org/10.1016/j.compbiomed.2021.104860>

References

1. Nie G., Zhu J., Tang G., Zhang D., Geng S., Zhao Q., et al. A Review of deep learning methods for photoplethysmography data. *arXiv*, 2024. arXiv:2401.12783. <https://doi.org/10.48550/arXiv.2401.12783>
2. Ray D., Collins T., Woolley S., Ponnappalli P. A review of wearable multi-wavelength photoplethysmography. *IEEE Reviews in Biomedical Engineering*, 2021, vol. 16, pp. 136–151. <https://doi.org/10.1109/rbme.2021.3121476>
3. Vavrinsky E., Esfahani N.E., Hausner M., Kuzma A., Rezo V., Donoval M., et al. The current state of optical sensors in medical wearables. *Biosensors*, 2022, vol. 12, no. 4, pp. 217. <https://doi.org/10.3390/bios12040217>
4. Chang C.-C., Wu C.-T., Choi B.I., Fang T.-J. MW-PPG sensor: An on-chip spectrometer approach. *Sensors*, 2019, vol. 19, no. 17, pp. 3698. <https://doi.org/10.3390/s19173698>
5. Sugita N., Noro T., Yoshizawa M., Ichiji K., Yamaki S., Homma N. Estimation of absolute blood pressure using video images captured at different heights from the heart. *Proc. of the 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2019, pp. 4458–4461. <https://doi.org/10.1109/embc.2019.8856362>
6. Kamshilin A.A., Margaryants N.B. Origin of photoplethysmographic waveform at green light. *Physics Procedia*, 2017, vol. 86, pp. 72–80. <https://doi.org/10.1016/j.phpro.2017.01.024>
7. Alharbi S., Hu S., Mulvaney D., Blanos P. An applicable approach for extracting human heart rate and oxygen saturation during physical movements using a multi-wavelength illumination optoelectronic sensor system. *Proceedings of SPIE*, 2018, vol. 10486, pp. 104860S. <https://doi.org/10.1117/12.2287854>
8. Bousefsaf F., Djeldjli D., Ouzar Y., Maaoui C., Pruski A. iPPG 2 cPPG: reconstructing contact from imaging photoplethysmographic signals using U-Net architectures. *Computers in Biology and Medicine*, 2021, vol. 138, pp. 104860. <https://doi.org/10.1016/j.compbiomed.2021.104860>

9. Goudarzi R.H., Mousavi S.S., Charimi M. Using imaging photoplethysmography (iPPG) signal for blood pressure estimation // *Proc. of the International Conference on Machine Vision and Image Processing (MVIP)*. 2020. P. 1–6. <https://doi.org/10.1109/mvip49855.2020.9116902>
10. Ni A., Azarang A., Kehtarnavaz N. A review of deep learning-based contactless heart rate measurement methods // *Sensors*. 2021. V. 21. N 11. P. 3719. <https://doi.org/10.3390/s21113719>
11. Sokolov A.Y., Volynsky M.A., Potapenko A.V., Iurkova P.M., Zaytsev V.V., Nippolainen E., et al. Duality in response of intracranial vessels to nitroglycerin revealed in rats by imaging photoplethysmography // *Scientific Reports*. 2023. V. 13. N 1. P. 11928. <https://doi.org/10.1038/s41598-023-39171-w>
12. Volkov I.Y., Sagaidachnyi A.A., Fomin A.V. Photoplethysmographic imaging of hemodynamics and two-dimensional oximetry // *Optics and Spectroscopy*. 2022. V. 130. N 7. P. 452–469. <https://doi.org/10.1134/s0030400x22080057>
13. Wieringa F.P., Mastik F., van der Steen A.F.W. Contactless multiple wavelength photoplethysmographic imaging: A first step toward “SpO₂ Camera” technology // *Annals of Biomedical Engineering*. 2005. V. 33. N 8. P. 1034–1041. <https://doi.org/10.1007/s10439-005-5763-2>
14. Kumar M., Suliburk J.W., Veeraraghavan A., Sabharwal A. PulseCam: a camera-based, motion-robust and highly sensitive blood perfusion imaging modality // *Scientific Reports*. 2020. V. 10. N 1. P. 4825. <https://doi.org/10.1038/s41598-020-61576-0>
15. Kamshilin A.A., Volynsky M.A., Khayrutdinova O., Nurkhametova D., Babayan L., Amelin A.V., et al. Novel capsaicin-induced parameters of microcirculation in migraine patients revealed by imaging photoplethysmography // *The Journal of Headache and Pain*. 2018. V. 19. P. 43. <https://doi.org/10.1186/s10194-018-0872-0>
16. Volynsky M.A., Mamontov O.V., Sidorov I.S., Kamshilin A.A. Pulse wave transit time measured by imaging photoplethysmography in upper extremities // *Journal of Physics: Conference Series*. 2016. V. 737. N 1. P. 012053. <https://doi.org/10.1088/1742-6596/737/1/012053>
17. Sun Y., Thakor N. Photoplethysmography revisited: from contact to noncontact, from point to imaging // *IEEE Transactions on Biomedical Engineering*. 2015. V. 63. N 3. P. 463–477. <https://doi.org/10.1109/tbme.2015.2476337>
18. Rubins U., Upmalis V., Rubenis O., Jakovels D., Spigulis J. Real-time photoplethysmography imaging system // *IFMBE Proceedings*. 2011. V. 34. P. 183–186. https://doi.org/10.1007/978-3-642-21683-1_46
19. Rubins U., Miscuks A., Qawqzeh Y., Marcinkevics Z., Grabovskis A. Photoplethysmography imaging algorithm for real-time monitoring of skin perfusion maps // *Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*. 2023. P. 5950–5956. <https://doi.org/10.1109/cvprw59228.2023.00633>
20. Spigulis J. Multispectral, fluorescent and photoplethysmographic imaging for remote skin assessment // *Sensors*. 2017. V. 17. N 5. P. 1165. <https://doi.org/10.3390/s17051165>
21. Rubins U., Spigulis J., Miščuks A. Photoplethysmography imaging algorithm for continuous monitoring of regional anesthesia // *Proc. of the 14th ACM/IEEE Symposium on Embedded Systems for Real-Time Multimedia*. 2016. P. 67–71. <https://doi.org/10.1145/2993452.2994308>
22. Kyung J., Yang J.-Y., Choi J.-H., Chang J.-H., Bae S., Choi J., et al. Deep-learning-based blood pressure estimation using multi channel photoplethysmogram and finger pressure with attention mechanism // *Scientific Reports*. 2023. V. 13. N 1. P. 9311. <https://doi.org/10.1038/s41598-023-36068-6>
23. Mehrgardt P., Khushi M., Poon S., Withana A. Deep learning fused wearable pressure and PPG data for accurate heart rate monitoring // *IEEE Sensors Journal*. 2021. V. 21. N 23. P. 27106–27115. <https://doi.org/10.1109/jsen.2021.3123243>
24. Jang D.-G., Park S., Hahn M., Park S.-H. A real-time pulse peak detection algorithm for the photoplethysmogram // *International Journal of Electronics and Electrical Engineering*. 2014. V 2. N 1. P. 45–49. <https://doi.org/10.12720/ijeee.2.1.45-49>
25. Argüello-Prada E.J. The mountaineer’s method for peak detection in photoplethysmographic signals // *Revista Facultad de Ingeniería Universidad de Antioquia*. 2019. N 90. P. 42–50. <https://doi.org/10.17533/udea.redin.n90a06>
26. Vadrevu S., Manikandan M.S. A robust pulse onset and peak detection method for automated PPG signal analysis system // *IEEE*
9. Goudarzi R.H., Mousavi S.S., Charimi M. Using imaging photoplethysmography (iPPG) signal for blood pressure estimation. *Proc. of the International Conference on Machine Vision and Image Processing (MVIP)*, 2020, pp. 1–6. <https://doi.org/10.1109/mvip49855.2020.9116902>
10. Ni A., Azarang A., Kehtarnavaz N. A review of deep learning-based contactless heart rate measurement methods. *Sensors*, 2021, vol. 21, no. 11, pp. 3719. <https://doi.org/10.3390/s21113719>
11. Sokolov A.Y., Volynsky M.A., Potapenko A.V., Iurkova P.M., Zaytsev V.V., Nippolainen E., et al. Duality in response of intracranial vessels to nitroglycerin revealed in rats by imaging photoplethysmography. *Scientific Reports*, 2023, vol. 13, no. 1, pp. 11928. <https://doi.org/10.1038/s41598-023-39171-w>
12. Volkov I.Y., Sagaidachnyi A.A., Fomin A.V. Photoplethysmographic imaging of hemodynamics and two-dimensional oximetry. *Optics and Spectroscopy*, 2022, vol. 130, no. 7, pp. 452–469. <https://doi.org/10.1134/s0030400x22080057>
13. Wieringa F.P., Mastik F., van der Steen A.F.W. Contactless multiple wavelength photoplethysmographic imaging: A first step toward “SpO₂ Camera” technology. *Annals of Biomedical Engineering*, 2005, vol. 33, no. 8, pp. 1034–1041. <https://doi.org/10.1007/s10439-005-5763-2>
14. Kumar M., Suliburk J.W., Veeraraghavan A., Sabharwal A. PulseCam: a camera-based, motion-robust and highly sensitive blood perfusion imaging modality. *Scientific Reports*, 2020, vol. 10, no. 1, pp. 4825. <https://doi.org/10.1038/s41598-020-61576-0>
15. Kamshilin A.A., Volynsky M.A., Khayrutdinova O., Nurkhametova D., Babayan L., Amelin A.V., et al. Novel capsaicin-induced parameters of microcirculation in migraine patients revealed by imaging photoplethysmography. *The Journal of Headache and Pain*, 2018, vol. 19, pp. 43. <https://doi.org/10.1186/s10194-018-0872-0>
16. Volynsky M.A., Mamontov O.V., Sidorov I.S., Kamshilin A.A. Pulse wave transit time measured by imaging photoplethysmography in upper extremities. *Journal of Physics: Conference Series*, 2016, vol. 737, no. 1, pp. 012053. <https://doi.org/10.1088/1742-6596/737/1/012053>
17. Sun Y., Thakor N. Photoplethysmography revisited: from contact to noncontact, from point to imaging. *IEEE Transactions on Biomedical Engineering*, 2015, vol. 63, no. 3, pp. 463–477. <https://doi.org/10.1109/tbme.2015.2476337>
18. Rubins U., Upmalis V., Rubenis O., Jakovels D., Spigulis J. Real-time photoplethysmography imaging system. *IFMBE Proceedings*, 2011, vol. 34, pp. 183–186. https://doi.org/10.1007/978-3-642-21683-1_46
19. Rubins U., Miscuks A., Qawqzeh Y., Marcinkevics Z., Grabovskis A. Photoplethysmography imaging algorithm for real-time monitoring of skin perfusion maps. *Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 2023, pp. 5950–5956. <https://doi.org/10.1109/cvprw59228.2023.00633>
20. Spigulis J. Multispectral, fluorescent and photoplethysmographic imaging for remote skin assessment. *Sensors*, 2017, vol. 17, no. 5, pp. 1165. <https://doi.org/10.3390/s17051165>
21. Rubins U., Spigulis J., Miščuks A. Photoplethysmography imaging algorithm for continuous monitoring of regional anesthesia. *Proc. of the 14th ACM/IEEE Symposium on Embedded Systems for Real-Time Multimedia*, 2016, pp. 67–71. <https://doi.org/10.1145/2993452.2994308>
22. Kyung J., Yang J.-Y., Choi J.-H., Chang J.-H., Bae S., Choi J., et al. Deep-learning-based blood pressure estimation using multi channel photoplethysmogram and finger pressure with attention mechanism. *Scientific Reports*, 2023, vol. 13, no. 1, pp. 9311. <https://doi.org/10.1038/s41598-023-36068-6>
23. Mehrgardt P., Khushi M., Poon S., Withana A. Deep learning fused wearable pressure and PPG data for accurate heart rate monitoring. *IEEE Sensors Journal*, 2021, vol. 21, no. 23, pp. 27106–27115. <https://doi.org/10.1109/jsen.2021.3123243>
24. Jang D.-G., Park S., Hahn M., Park S.-H. A real-time pulse peak detection algorithm for the photoplethysmogram. *International Journal of Electronics and Electrical Engineering*, 2014, vol 2, no. 1, pp. 45–49. <https://doi.org/10.12720/ijeee.2.1.45-49>
25. Argüello-Prada E.J. The mountaineer’s method for peak detection in photoplethysmographic signals. *Revista Facultad de Ingeniería Universidad de Antioquia*, 2019, no. 90, pp. 42–50. <https://doi.org/10.17533/udea.redin.n90a06>
26. Vadrevu S., Manikandan M.S. A robust pulse onset and peak detection method for automated PPG signal analysis system. *IEEE Transactions*

- Transactions on Instrumentation and Measurement, 2019, V. 68, N 3, P. 807–817. <https://doi.org/10.1109/tim.2018.2857878>
27. Nowara E.M., Marks T.K., Mansour H., Veeraraghavan A. Near-infrared imaging photoplethysmography during driving // *IEEE Transactions on Intelligent Transportation Systems*, 2022, V. 23, N 4, P. 3589–3600. <https://doi.org/10.1109/tits.2020.3038317>
 28. Nowara E.M., Marks T.K., Mansour H., Veeraraghavan A. SparsePPG: Towards driver monitoring using camera-based vital signs estimation in near-infrared // *Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 2018, P. 1353–1362. <https://doi.org/10.1109/cvprw.2018.00174>
 29. Kumar M., Veeraraghavan A., Sabharwal A. DistancePPG: Robust non-contact vital signs monitoring using a camera // *Biomedical Optics Express*, 2015, V. 6, N 5, P. 1565–1588. <https://doi.org/10.1364/boe.6.001565>
 30. Poh M.-Z., McDuff D.J., Picard R.W. Non-contact, automated cardiac pulse measurements using video imaging and blind source separation // *Optics Express*, 2010, V. 18, N 10, P. 10762–10774. <https://doi.org/10.1364/oe.18.010762>
 31. de Haan G., Jeanne V. Robust pulse rate from chrominance-based rPPG // *IEEE Transactions on Biomedical Engineering*, 2013, V. 60, N 10, P. 2878–2886. <https://doi.org/10.1109/tbme.2013.2266196>
 32. Wang W., den Brinker A.C., Stuijk S., de Haan G. Algorithmic principles of remote PPG // *IEEE Transactions on Biomedical Engineering*, 2016, V. 64, N 7, P. 1479–1491. <https://doi.org/10.1109/tbme.2016.2609282>
 33. van Gent P., Farah H., van Nes N., van Arem B. HeartPy: A novel heart rate algorithm for the analysis of noisy signals // *Transportation Research Part F: Traffic Psychology and Behaviour*, 2019, V. 66, P. 368–378. <https://doi.org/10.1016/j.trf.2019.09.015>
 34. Goda M.Á., Charlton P.H., Behar J.A. pyPPG: A Python toolbox for comprehensive photoplethysmography signal analysis // *Physiological Measurement*, 2024, V. 45, N 4, P. 045001. <https://doi.org/10.1088/1361-6579/ad33a2>
 35. Boccignone G., Conte D., Cuculo V., D'Amelio A., Grossi G., Lanzarotti, R., et al. pyVHR: a Python framework for remote photoplethysmography // *PeerJ Computer Science*, 2022, V. 8, P. e929. <https://doi.org/10.7717/peerj-cs.929>
 36. Kwon S., Hong J., Choi E.K., Lee E., Hostallero D.E., Kang W.J., et al. Deep learning approaches to detect atrial fibrillation using photoplethysmographic signals: algorithms development study // *JMIR mHealth and uHealth*, 2019, V. 7, N 6, P. e12770. <https://doi.org/10.2196/12770>
 37. Chen Y., Zhang D., Karimi H.R., Deng C., Yin W. A new deep learning framework based on blood pressure range constraint for continuous cuffless BP estimation // *Neural Networks*, 2022, V. 152, P. 181–190. <https://doi.org/10.1016/j.neunet.2022.04.017>
 38. Maqsood S., Xu S., Springer M., Mohawesh R. A benchmark study of machine learning for analysis of signal feature extraction techniques for blood pressure estimation using photoplethysmography (PPG) // *IEEE Access*, 2021, V. 9, P. 138817–138833. <https://doi.org/10.1109/access.2021.3117969>
 39. Kim M., Lee H., Kim K.-Y., Kim K.-H. Deep learning model for blood pressure estimation from PPG signal // *Proc. of the IEEE International Conference on Metrology for Extended Reality, Artificial Intelligence and Neural Engineering (MetroXRaine)*, 2022, P. 1–5. <https://doi.org/10.1109/metroxraine54828.2022.9967606>
 40. Boukhechba M., Cai L., Wu C., Barnes L.B. ActiPPG: Using deep neural networks for activity recognition from wrist-worn photoplethysmography (PPG) sensors // *Smart Health*, 2019, V. 14, P. 100082. <https://doi.org/10.1016/j.smhl.2019.100082>
 41. Ordóñez F.J., Roggen D. Deep convolutional and lstm recurrent neural networks for multimodal wearable activity recognition // *Sensors*, 2016, V. 16, N 1, P. 115. <https://doi.org/10.3390/s16010115>
 42. Wang D., Hu Q., Yang C. Biometric recognition based on scalable end-to-end convolutional neural network using photoplethysmography: A comparative study // *Computers in Biology and Medicine*, 2022, V. 147, P. 105654. <https://doi.org/10.1016/j.compbmed.2022.105654>
 43. Panwar M., Gautam A., Biswas D., Acharyya A. PP-Net: A deep learning framework for PPG-based blood pressure and heart rate estimation // *IEEE Sensors Journal*, 2020, V. 20, N 17, P. 10000–10011. <https://doi.org/10.1109/jsen.2020.2990864>
 44. Burrello A., Pagliari D.J., Rizzo M., Benatti S., Macii E., Benini L., et al. Q-ppg: Energy-efficient ppg-based heart rate monitoring on wearable devices // *IEEE Transactions on Biomedical Circuits and on Instrumentation and Measurement*, 2019, vol. 68, no. 3, pp. 807–817. <https://doi.org/10.1109/tim.2018.2857878>
 27. Nowara E.M., Marks T.K., Mansour H., Veeraraghavan A. Near-infrared imaging photoplethysmography during driving. *IEEE Transactions on Intelligent Transportation Systems*, 2022, vol. 23, no. 4, pp. 3589–3600. <https://doi.org/10.1109/tits.2020.3038317>
 28. Nowara E.M., Marks T.K., Mansour H., Veeraraghavan A. SparsePPG: Towards driver monitoring using camera-based vital signs estimation in near-infrared. *Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 2018, pp. 1353–1362. <https://doi.org/10.1109/cvprw.2018.00174>
 29. Kumar M., Veeraraghavan A., Sabharwal A. DistancePPG: Robust non-contact vital signs monitoring using a camera. *Biomedical Optics Express*, 2015, vol. 6, no. 5, pp. 1565–1588. <https://doi.org/10.1364/boe.6.001565>
 30. Poh M.-Z., McDuff D.J., Picard R.W. Non-contact, automated cardiac pulse measurements using video imaging and blind source separation. *Optics Express*, 2010, vol. 18, no. 10, pp. 10762–10774. <https://doi.org/10.1364/oe.18.010762>
 31. de Haan G., Jeanne V. Robust pulse rate from chrominance-based rPPG. *IEEE Transactions on Biomedical Engineering*, 2013, vol. 60, no. 10, pp. 2878–2886. <https://doi.org/10.1109/tbme.2013.2266196>
 32. Wang W., den Brinker A.C., Stuijk S., de Haan G. Algorithmic principles of remote PPG. *IEEE Transactions on Biomedical Engineering*, 2016, vol. 64, no. 7, pp. 1479–1491. <https://doi.org/10.1109/tbme.2016.2609282>
 33. van Gent P., Farah H., van Nes N., van Arem B. HeartPy: A novel heart rate algorithm for the analysis of noisy signals. *Transportation Research Part F: Traffic Psychology and Behaviour*, 2019, vol. 66, pp. 368–378. <https://doi.org/10.1016/j.trf.2019.09.015>
 34. Goda M.Á., Charlton P.H., Behar J.A. pyPPG: A Python toolbox for comprehensive photoplethysmography signal analysis. *Physiological Measurement*, 2024, vol. 45, no. 4, pp. 045001. <https://doi.org/10.1088/1361-6579/ad33a2>
 35. Boccignone G., Conte D., Cuculo V., D'Amelio A., Grossi G., Lanzarotti, R., et al. pyVHR: a Python framework for remote photoplethysmography. *PeerJ Computer Science*, 2022, vol. 8, pp. e929. <https://doi.org/10.7717/peerj-cs.929>
 36. Kwon S., Hong J., Choi E.K., Lee E., Hostallero D.E., Kang W.J., et al. Deep learning approaches to detect atrial fibrillation using photoplethysmographic signals: algorithms development study. *JMIR mHealth and uHealth*, 2019, vol. 7, no. 6, pp. e12770. <https://doi.org/10.2196/12770>
 37. Chen Y., Zhang D., Karimi H.R., Deng C., Yin W. A new deep learning framework based on blood pressure range constraint for continuous cuffless BP estimation. *Neural Networks*, 2022, vol. 152, pp. 181–190. <https://doi.org/10.1016/j.neunet.2022.04.017>
 38. Maqsood S., Xu S., Springer M., Mohawesh R. A benchmark study of machine learning for analysis of signal feature extraction techniques for blood pressure estimation using photoplethysmography (PPG). *IEEE Access*, 2021, vol. 9, pp. 138817–138833. <https://doi.org/10.1109/access.2021.3117969>
 39. Kim M., Lee H., Kim K.-Y., Kim K.-H. Deep learning model for blood pressure estimation from PPG signal. *Proc. of the IEEE International Conference on Metrology for Extended Reality, Artificial Intelligence and Neural Engineering (MetroXRaine)*, 2022, pp. 1–5. <https://doi.org/10.1109/metroxraine54828.2022.9967606>
 40. Boukhechba M., Cai L., Wu C., Barnes L.B. ActiPPG: Using deep neural networks for activity recognition from wrist-worn photoplethysmography (PPG) sensors. *Smart Health*, 2019, vol. 14, pp. 100082. <https://doi.org/10.1016/j.smhl.2019.100082>
 41. Ordóñez F.J., Roggen D. Deep convolutional and lstm recurrent neural networks for multimodal wearable activity recognition. *Sensors*, 2016, vol. 16, no. 1, pp. 115. <https://doi.org/10.3390/s16010115>
 42. Wang D., Hu Q., Yang C. Biometric recognition based on scalable end-to-end convolutional neural network using photoplethysmography: A comparative study. *Computers in Biology and Medicine*, 2022, vol. 147, pp. 105654. <https://doi.org/10.1016/j.compbmed.2022.105654>
 43. Panwar M., Gautam A., Biswas D., Acharyya A. PP-Net: A deep learning framework for PPG-based blood pressure and heart rate estimation. *IEEE Sensors Journal*, 2020, vol. 20, no. 17, pp. 10000–10011. <https://doi.org/10.1109/jsen.2020.2990864>
 44. Burrello A., Pagliari D.J., Rizzo M., Benatti S., Macii E., Benini L., et al. Q-ppg: Energy-efficient ppg-based heart rate monitoring on wearable devices. *IEEE Transactions on Biomedical Circuits and*

- Systems. 2021. V. 15. N 6. P. 1196–1209. <https://doi.org/10.1109/tbcas.2021.3122017>
45. Chen X., Wang X., Zhang K., Fung K.-M., Thai T.C., Moore K., et al. Recent advances and clinical applications of deep learning in medical image analysis // *Medical Image Analysis*. 2022. V. 79. P. 102444. <https://doi.org/10.1016/j.media.2022.102444>
 46. Wynants L., Van Calster B., Collins G.S., Riley R.D., Heinze G., Schuit E., et al. Prediction models for diagnosis and prognosis of covid-19: systematic review and critical appraisal // *British Medical Journal*. 2020. V. 369. P. m1328. <https://doi.org/10.1136/bmj.m1328>
 47. Roberts M., Driggs D., Thorpe M., Gilbey J., Yeung M., Ursprung S., et al. Common pitfalls and recommendations for using machine learning to detect and prognosticate for COVID-19 using chest radiographs and CT scans // *Nature Machine Intelligence*. 2021. V. 3. N 3. P. 199–217. <https://doi.org/10.1038/s42256-021-00307-0>
 48. Kamshilin A.A., Zaytsev V.V., Lodygin A., Kashchenko V.A. Imaging photoplethysmography as an easy-to-use tool for monitoring changes in tissue blood perfusion during abdominal surgery // *Scientific Reports*. 2022. V. 12. N 1. P. 1143. <https://doi.org/10.1038/s41598-022-05080-7>
 49. Almarshad M.A., Islam M.S., Al-Ahmadi S., BaHammam A.S. Diagnostic features and potential applications of PPG signal in healthcare: A systematic review // *Healthcare*. 2022. V. 10. N 3. P. 547. <https://doi.org/10.3390/healthcare10030547>
 50. Chen W., Yi Z., Lim L.J.R., Lim R.Q.R., Zhang A., Qian Z., et al. Deep learning and remote photoplethysmography powered advancements in contactless physiological measurement // *Frontiers in Bioengineering and Biotechnology*. 2024. V. 12. P. 1420100. <https://doi.org/10.3389/fbioe.2024.1420100>
 51. Cheng C.-H., Wong K.-L., Chin J.-W., Chan T.-T., So R.H.Y. Deep learning methods for remote heart rate measurement: a review and future research agenda // *Sensors*. 2021. V. 21. N 18. P. 6296. <https://doi.org/10.3390/s21186296>
 52. Schrumpp F., Frenzel P., Aust C., Osterhoff G., Fuchs M. Assessment of non-invasive blood pressure prediction from ppg and rppg signals using deep learning // *Sensors*. 2021. V. 21. N 18. P. 6022. <https://doi.org/10.3390/s21186022>
 53. Волков И.Ю., Сагайдачный А.А., Фомин А.В. Фотоплетизмографическая визуализация гемодинамики и двухмерная оксиметрия // *Известия Саратовского университета. Новая серия. Серия: Физика*. 2022. Т. 22. № 1. С. 15–45. <https://doi.org/10.18500/1817-3020-2022-22-1-15-45>
 54. Wang Y., Ren Y., Wang T., Li D., Cai H., Ji B. High-accuracy heart rate detection using multispectral IPPG technology combined with a deep learning algorithm // *Journal of Biophotonics*. 2024. V. 17. N 9. P. e202400119. <https://doi.org/10.1002/jbpo.202400119>
 55. Comas A., Marks T.K., Mansour H., Lohit S., Ma Y., Liu X. Turnip: Time-series U-Net with recurrence for NIR imaging PPG // *Proc. of the IEEE International Conference on Image Processing (ICIP)*. 2021. P. 309–313. <https://doi.org/10.1109/icip42928.2021.9506663>
 56. Kuang H., Lv F., Ma X., Liu X. Efficient spatiotemporal attention network for remote heart rate variability analysis // *Sensors*. 2022. V. 22. N 3. P. 1010. <https://doi.org/10.3390/s22031010>
 57. Luguev T., Seuß D., Garbas J.U. Deep learning based affective sensing with remote photoplethysmography // *Proc. of the 54th Annual Conference on Information Sciences and Systems (CISS)*. 2020. P. 360–363. <https://doi.org/10.1109/ciss48834.2020.1570617362>
 58. Yu Z., Li X., Zhao G. Remote photoplethysmograph signal measurement from facial videos using spatio-temporal networks // *arXiv*. 2019. arXiv:1905.02419. <https://doi.org/10.48550/arXiv.1905.02419>
 59. Ouzar Y., Djeldjli D., Bousefsaf F., Maaoui C. X-iPPGNet: A novel one stage deep learning architecture based on depthwise separable convolutions for video-based pulse rate estimation // *Computers in Biology and Medicine*. 2023. V. 154. P. 106592. <https://doi.org/10.1016/j.combiomed.2023.106592>
 60. Liu S., Yang Y., Jing X., Li B., Liu H., Zhu S. BiFormer: An End-to-End Deep Learning Approach for Enhanced Image-Based Photoplethysmography and Heart Rate Accuracy // *Frontiers in Artificial Intelligence and Applications*. 2024. P. 205–214. <https://doi.org/10.3233/faia231195>
 61. Lee E., Chen E., Lee C.-Y. Meta-rppg: Remote heart rate estimation using a transductive meta-learner // *Lecture Notes in Computer Science*. 2020. V. 12372. P. 392–409. https://doi.org/10.1007/978-3-030-58583-9_24
 - Systems, 2021, vol. 15, no. 6, pp. 1196–1209. <https://doi.org/10.1109/tbcas.2021.3122017>
 45. Chen X., Wang X., Zhang K., Fung K.-M., Thai T.C., Moore K., et al. Recent advances and clinical applications of deep learning in medical image analysis. *Medical Image Analysis*, 2022, vol. 79, pp. 102444. <https://doi.org/10.1016/j.media.2022.102444>
 46. Wynants L., Van Calster B., Collins G.S., Riley R.D., Heinze G., Schuit E., et al. Prediction models for diagnosis and prognosis of covid-19: systematic review and critical appraisal. *British Medical Journal*, 2020, vol. 369, pp. m1328. <https://doi.org/10.1136/bmj.m1328>
 47. Roberts M., Driggs D., Thorpe M., Gilbey J., Yeung M., Ursprung S., et al. Common pitfalls and recommendations for using machine learning to detect and prognosticate for COVID-19 using chest radiographs and CT scans. *Nature Machine Intelligence*, 2021, vol. 3, no. 3, pp. 199–217. <https://doi.org/10.1038/s42256-021-00307-0>
 48. Kamshilin A.A., Zaytsev V.V., Lodygin A., Kashchenko V.A. Imaging photoplethysmography as an easy-to-use tool for monitoring changes in tissue blood perfusion during abdominal surgery. *Scientific Reports*, 2022, vol. 12, no. 1, pp. 1143. <https://doi.org/10.1038/s41598-022-05080-7>
 49. Almarshad M.A., Islam M.S., Al-Ahmadi S., BaHammam A.S. Diagnostic features and potential applications of PPG signal in healthcare: A systematic review. *Healthcare*, 2022, vol. 10, no. 3, pp. 547. <https://doi.org/10.3390/healthcare10030547>
 50. Chen W., Yi Z., Lim L.J.R., Lim R.Q.R., Zhang A., Qian Z., et al. Deep learning and remote photoplethysmography powered advancements in contactless physiological measurement. *Frontiers in Bioengineering and Biotechnology*, 2024, vol. 12, pp. 1420100. <https://doi.org/10.3389/fbioe.2024.1420100>
 51. Cheng C.-H., Wong K.-L., Chin J.-W., Chan T.-T., So R.H.Y. Deep learning methods for remote heart rate measurement: a review and future research agenda. *Sensors*, 2021, vol. 21, no. 18, pp. 6296. <https://doi.org/10.3390/s21186296>
 52. Schrumpp F., Frenzel P., Aust C., Osterhoff G., Fuchs M. Assessment of non-invasive blood pressure prediction from ppg and rppg signals using deep learning. *Sensors*, 2021, vol. 21, no. 18, pp. 6022. <https://doi.org/10.3390/s21186022>
 53. Volkov I.Y., Sagaidachnyi A.A., Fomin A.V. Photoplethysmographic imaging of hemodynamics and two-dimensional oximetry. *Izvestiya of Saratov University. Physics*, 2022, vol. 22, no. 1, pp. 15–45. (in Russian). <https://doi.org/10.18500/1817-3020-2022-22-1-15-45>
 54. Wang Y., Ren Y., Wang T., Li D., Cai H., Ji B. High-accuracy heart rate detection using multispectral IPPG technology combined with a deep learning algorithm. *Journal of Biophotonics*, 2024, vol. 17, no. 9, pp. e202400119. <https://doi.org/10.1002/jbpo.202400119>
 55. Comas A., Marks T.K., Mansour H., Lohit S., Ma Y., Liu X. Turnip: Time-series U-Net with recurrence for NIR imaging PPG. *Proc. of the IEEE International Conference on Image Processing (ICIP)*, 2021, pp. 309–313. <https://doi.org/10.1109/icip42928.2021.9506663>
 56. Kuang H., Lv F., Ma X., Liu X. Efficient spatiotemporal attention network for remote heart rate variability analysis. *Sensors*, 2022, vol. 22, no. 3, pp. 1010. <https://doi.org/10.3390/s22031010>
 57. Luguev T., Seuß D., Garbas J.U. Deep learning based affective sensing with remote photoplethysmography. *Proc. of the 54th Annual Conference on Information Sciences and Systems (CISS)*, 2020, pp. 360–363. <https://doi.org/10.1109/ciss48834.2020.1570617362>
 58. Yu Z., Li X., Zhao G. Remote photoplethysmograph signal measurement from facial videos using spatio-temporal networks. *arXiv*, 2019. arXiv:1905.02419. <https://doi.org/10.48550/arXiv.1905.02419>
 59. Ouzar Y., Djeldjli D., Bousefsaf F., Maaoui C. X-iPPGNet: A novel one stage deep learning architecture based on depthwise separable convolutions for video-based pulse rate estimation. *Computers in Biology and Medicine*, 2023, vol. 154, pp. 106592. <https://doi.org/10.1016/j.combiomed.2023.106592>
 60. Liu S., Yang Y., Jing X., Li B., Liu H., Zhu S. BiFormer: An End-to-End Deep Learning Approach for Enhanced Image-Based Photoplethysmography and Heart Rate Accuracy. *Frontiers in Artificial Intelligence and Applications*, 2024, pp. 205–214. <https://doi.org/10.3233/faia231195>
 61. Lee E., Chen E., Lee C.-Y. Meta-rppg: Remote heart rate estimation using a transductive meta-learner. *Lecture Notes in Computer Science*, 2020, vol. 12372, pp. 392–409. https://doi.org/10.1007/978-3-030-58583-9_24

62. Yu Z., Peng W., Li X., Hong X., Zhao G. Remote heart rate measurement from highly compressed facial videos: an end-to-end deep learning solution with video enhancement // *Proc. of the IEEE/CVF International Conference on Computer Vision (ICCV)*. 2019. P. 151–160. <https://doi.org/10.1109/iccv.2019.00024>
63. Bousefsaf F., Pruski A., Maaoui C. 3D convolutional neural networks for remote pulse rate measurement and mapping from facial video // *Applied Sciences*. 2019. V. 9. N 20. P. 4364. <https://doi.org/10.3390/app9204364>
64. Liu S.-Q., Yuen P.C. A general remote photoplethysmography estimator with spatiotemporal convolutional network // *Proc. of the 15th IEEE International Conference on Automatic Face and Gesture Recognition (FG 2020)*. 2020. P. 481–488. <https://doi.org/10.1109/fg47880.2020.00109>
65. Yue Z., Ding S., Yang S., Yang H., Li Z., Zhang Y., et al. Deep super-resolution network for rPPG information recovery and noncontact heart rate estimation // *IEEE Transactions on Instrumentation and Measurement*. 2021. V. 70. P. 2513511. <https://doi.org/10.1109/tim.2021.3109398>
66. McDuff D. Deep super resolution for recovering physiological information from videos // *Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*. 2018. P. 1448–1455. <https://doi.org/10.1109/cvprw.2018.00185>
67. Lu H., Han H., Zhou S.K. Dual-GAN: Joint bvp and noise modeling for remote physiological measurement // *Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 2021. P. 12399–12408. <https://doi.org/10.1109/cvpr46437.2021.01222>
68. Lokendra B., Puneet G. AND-rPPG: A novel denoising-rPPG network for improving remote heart rate estimation // *Computers in Biology and Medicine*. 2022. V. 141. P. 105146. <https://doi.org/10.1016/j.combiomed.2021.105146>
69. Qiu Y., Liu Y., Arteaga-Falconi J., Dong H., El Saddik A. EVM-CNN: Real-time contactless heart rate estimation from facial video // *IEEE Transactions on Multimedia*. 2019. V. 21. N 7. P. 1778–1787. <https://doi.org/10.1109/tmm.2018.2883866>
70. Paracchini M., Marcon M., Villa F., Zappa F., Tubaro S. Biometric signals estimation using single photon camera and deep learning // *Sensors*. 2020. V. 20. N 21. P. 6102. <https://doi.org/10.3390/s20216102>
71. Zhan Q., Wang W., de Haan G. Analysis of CNN-based remote-PPG to understand limitations and sensitivities // *Biomedical Optics Express*. 2020. V. 11. N 3. P. 1268–1283. <https://doi.org/10.1364/boe.382637>
72. Chen W., McDuff D. DeepPhys: video-based physiological measurement using convolutional attention networks // *Lecture Notes in Computer Science*. 2018. V. 11206. P. 356–373. https://doi.org/10.1007/978-3-030-01216-8_22
73. Reiss A., Indlekofer I., Schmidt P., Van Laerhoven K. Deep PPG: Large-scale heart rate estimation with convolutional neural networks // *Sensors*. 2019. V. 19. N 14. P. 3079. <https://doi.org/10.3390/s19143079>
74. Perepelkina O., Artemyev M., Churikova M., Grinenko M. HeartTrack: Convolutional neural network for remote video-based heart rate monitoring // *Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*. 2020. P. 1163–1171. <https://doi.org/10.1109/cvprw50498.2020.00152>
75. Cen Y., Luo J., Wang H., Chen L., Zhu X., Guo S., et al. OVAR-BPnet: a general pulse wave deep learning approach for cuffless blood pressure measurement // *IEEE Journal of Biomedical and Health Informatics*. 2024. V. 28. N 10. P. 5829–5841. <https://doi.org/10.1109/jbhi.2024.3423461>
76. Song R., Chen H., Cheng J., Li C., Liu Y., Chen X. PulseGAN: Learning to generate realistic pulse waveforms in remote photoplethysmography // *IEEE Journal of Biomedical and Health Informatics*. 2021. V. 25. N 5. P. 1373–1384. <https://doi.org/10.1109/jbhi.2021.3051176>
77. Estep J.R., Blackford E.B., Meier C.M. Recovering pulse rate during motion artifact with a multi-imager array for non-contact imaging photoplethysmography // *Proc. of the IEEE International Conference on Systems, Man, and Cybernetics (SMC)*. 2014. P. 1462–1469. <https://doi.org/10.1109/smc.2014.6974121>
78. Lie W.-N., Le D.-Q., Lai C.-Y., Fang Y.-S. Heart rate estimation from facial image sequences of a dual-modality RGB-NIR camera // *Sensors*. 2023. V. 23. N 13. P. 6079. <https://doi.org/10.3390/s23136079>
62. Yu Z., Peng W., Li X., Hong X., Zhao G. Remote heart rate measurement from highly compressed facial videos: an end-to-end deep learning solution with video enhancement. *Proc. of the IEEE/CVF International Conference on Computer Vision (ICCV)*, 2019, pp. 151–160. <https://doi.org/10.1109/iccv.2019.00024>
63. Bousefsaf F., Pruski A., Maaoui C. 3D convolutional neural networks for remote pulse rate measurement and mapping from facial video. *Applied Sciences*, 2019, vol. 9, no. 20, pp. 4364. <https://doi.org/10.3390/app9204364>
64. Liu S.-Q., Yuen P.C. A general remote photoplethysmography estimator with spatiotemporal convolutional network. *Proc. of the 15th IEEE International Conference on Automatic Face and Gesture Recognition (FG 2020)*, 2020, pp. 481–488. <https://doi.org/10.1109/fg47880.2020.00109>
65. Yue Z., Ding S., Yang S., Yang H., Li Z., Zhang Y., et al. Deep super-resolution network for rPPG information recovery and noncontact heart rate estimation. *IEEE Transactions on Instrumentation and Measurement*, 2021, vol. 70, pp. 2513511. <https://doi.org/10.1109/tim.2021.3109398>
66. McDuff D. Deep super resolution for recovering physiological information from videos. *Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 2018, pp. 1448–1455. <https://doi.org/10.1109/cvprw.2018.00185>
67. Lu H., Han H., Zhou S.K. Dual-GAN: Joint bvp and noise modeling for remote physiological measurement. *Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2021, pp. 12399–12408. <https://doi.org/10.1109/cvpr46437.2021.01222>
68. Lokendra B., Puneet G. AND-rPPG: A novel denoising-rPPG network for improving remote heart rate estimation. *Computers in Biology and Medicine*, 2022, vol. 141, pp. 105146. <https://doi.org/10.1016/j.combiomed.2021.105146>
69. Qiu Y., Liu Y., Arteaga-Falconi J., Dong H., El Saddik A. EVM-CNN: Real-time contactless heart rate estimation from facial video. *IEEE Transactions on Multimedia*, 2019, vol. 21, no. 7, pp. 1778–1787. <https://doi.org/10.1109/tmm.2018.2883866>
70. Paracchini M., Marcon M., Villa F., Zappa F., Tubaro S. Biometric signals estimation using single photon camera and deep learning. *Sensors*, 2020, vol. 20, no. 21, pp. 6102. <https://doi.org/10.3390/s20216102>
71. Zhan Q., Wang W., de Haan G. Analysis of CNN-based remote-PPG to understand limitations and sensitivities. *Biomedical Optics Express*, 2020, vol. 11, no. 3, pp. 1268–1283. <https://doi.org/10.1364/boe.382637>
72. Chen W., McDuff D. DeepPhys: video-based physiological measurement using convolutional attention networks. *Lecture Notes in Computer Science*, 2018, vol. 11206, pp. 356–373. https://doi.org/10.1007/978-3-030-01216-8_22
73. Reiss A., Indlekofer I., Schmidt P., Van Laerhoven K. Deep PPG: Large-scale heart rate estimation with convolutional neural networks. *Sensors*, 2019, vol. 19, no. 14, pp. 3079. <https://doi.org/10.3390/s19143079>
74. Perepelkina O., Artemyev M., Churikova M., Grinenko M. HeartTrack: Convolutional neural network for remote video-based heart rate monitoring. *Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 2020, pp. 1163–1171. <https://doi.org/10.1109/cvprw50498.2020.00152>
75. Cen Y., Luo J., Wang H., Chen L., Zhu X., Guo S., et al. OVAR-BPnet: a general pulse wave deep learning approach for cuffless blood pressure measurement. *IEEE Journal of Biomedical and Health Informatics*, 2024, vol. 28, no. 10, pp. 5829–5841. <https://doi.org/10.1109/jbhi.2024.3423461>
76. Song R., Chen H., Cheng J., Li C., Liu Y., Chen X. PulseGAN: Learning to generate realistic pulse waveforms in remote photoplethysmography. *IEEE Journal of Biomedical and Health Informatics*, 2021, vol. 25, no. 5, pp. 1373–1384. <https://doi.org/10.1109/jbhi.2021.3051176>
77. Estep J.R., Blackford E.B., Meier C.M. Recovering pulse rate during motion artifact with a multi-imager array for non-contact imaging photoplethysmography. *Proc. of the IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, 2014, pp. 1462–1469. <https://doi.org/10.1109/smc.2014.6974121>
78. Lie W.-N., Le D.-Q., Lai C.-Y., Fang Y.-S. Heart rate estimation from facial image sequences of a dual-modality RGB-NIR camera. *Sensors*, 2023, vol. 23, no. 13, pp. 6079. <https://doi.org/10.3390/s23136079>

Авторы

Рубин Иван Максимович — аспирант, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, <https://orcid.org/0000-0001-6273-5094>, rubin_ivan@outlook.com, ivan.rubin.ru@yandex.ru

Волынский Максим Александрович — кандидат технических наук, доцент, директор научно-образовательной лаборатории, доцент, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, <https://orcid.org/0000-0003-1679-4450>, sc 23006901100, maxim.volynsky@gmail.com

Authors

Ivan M. Rubin — PhD Student, ITMO University, Saint Petersburg, 197101, Russian Federation, <https://orcid.org/0000-0001-6273-5094>, imrubin@itmo.ru

Maxim A. Volynsky — PhD, Associate Professor, Director of Technical Vision Laboratory, ITMO University, Saint Petersburg, 197101, Russian Federation, <https://orcid.org/0000-0003-1679-4450>, sc 23006901100, maxim.volynsky@itmo.ru

*Статья поступила в редакцию 26.01.2026
Одобрена после рецензирования 18.02.2026
Принята к печати 22.03.2026*

*Received 26.01.2026
Approved after reviewing 18.02.2026
Accepted 22.03.2026*



Работа доступна по лицензии
Creative Commons
«Attribution-NonCommercial»