

DOI: 10.15514/ISPRAS-2022-34(4)-16



## Методы определения элементов PQRST-комплекса электрокардиограммы

<sup>1,3</sup> О.А. Машкова, ORCID: 0000-0002-4916-1660 <mashkova@ispras.ru>

<sup>2</sup> В.В. Шаклеин, ORCID: 0000-0002-4239-0807 <shaklein@ispras.ru>

<sup>1,4</sup> Ю.В. Маркин, ORCID: 0000-0003-1145-5118 <ustas@ispras.ru>

<sup>1</sup> Е.А. Карпулевич, ORCID: 0000-0002-6771-2163 <karpulevich@ispras.ru>

<sup>1,2</sup> В.В. Ананьев, ORCID: 0000-0002-5070-8117 <novisp53@ispras.ru>

<sup>1,5</sup> А.А. Асатрян, ORCID: 0000-0002-2529-0169 <arianasat@ispras.ru>

<sup>1,5</sup> Ш.Т. Тигранян, ORCID: 0000-0003-1536-9954 <shigranyan@ispras.ru>

<sup>1,4</sup> С.Н. Скорик, ORCID: 0000-0002-8316-7302 <skorik@ispras.ru>

<sup>1,3</sup> Д.Ю. Турдаков, ORCID: 0000-0001-8745-0984 <turdakov@ispras.ru>

<sup>1</sup> Институт системного программирования им. В.П. Иванникова РАН, 109004, Россия, г. Москва, ул. А. Солженицына, д. 25

<sup>2</sup> Новгородский государственный университет им. Ярослава Мудрого, 173003, Россия, г. Великий Новгород, ул. Большая Санкт-Петербургская, д. 41

<sup>3</sup> Московский государственный университет имени М.В. Ломоносова, 119991, Россия, Москва, Ленинские горы, д. 1

<sup>4</sup> Московский физико-технический институт, 141700, Россия, Московская область, г. Долгопрудный, Институтский пер., 9

<sup>5</sup> Российско-Армянский университет, ул. Овсена Эмина 123, Ереван, 119991 РА

**Аннотация.** Электрокардиограмма (ЭКГ) является одним из наиболее распространенных медицинских исследований. Качественная расшифровка 12-канальной электрокардиограммы важна для последующей постановки диагноза и назначения лечения. Один из важных шагов при расшифровке ЭКГ – определение границ элементов PQRST-комплекса. В статье рассматриваются математические методы определения границ волн P, T и комплекса QRS, а также пиков R, P и T, приводятся недостатки математических методов определения элементов PQRST-комплекса. Кроме того, приводятся значения метрик, полученных в результате обучения нейросетевой модели сегментации PQRST-комплекса. Проведенные эксперименты показывают актуальность использования нейросетевых и комбинированных подходов к анализу комплекса PQRST.

**Ключевые слова:** классификация ЭКГ; сверточная нейронная сеть; PQRST-комплекс; вейвлет-преобразование

**Для цитирования:** Машкова О.А., Шаклеин В.В., Маркин Ю.В., Карпулевич Е.А., Ананьев В.В., Асатрян А.А., Тигранян Ш.Т., Скорик С.Н., Турдаков Д.Ю. Методы определения элементов PQRST-комплекса электрокардиограммы. Труды ИСП РАН, том 34, вып. 4, 2022 г., стр. 229-240. DOI: 10.15514/ISPRAS-2022-34(4)-16

**Благодарности:** Исследование выполнено при финансовой поддержке РФФИ и МНТИ в рамках научного проекта № 19-51-06001

## Methods for determining the elements of the PQRST-complex of the electrocardiogram

<sup>1,3</sup> O.A. Mashkova, ORCID: 0000-0002-4916-1660 <mashkova@ispras.ru>

<sup>2</sup> V.V. Shaklein, ORCID: 0000-0002-4239-0807 <shaklein@ispras.ru>

<sup>1,4</sup> Yu.V. Markin, ORCID: 0000-0003-1145-5118 <ustas@ispras.ru>

<sup>1</sup> E.A. Karpulevich, ORCID: 0000-0002-6771-2163 <karpulevich@ispras.ru>

<sup>1,2</sup> V.V. Ananov, ORCID: 0000-0002-5070-8117 <novisp53@ispras.ru>

<sup>1,5</sup> A.A. Asatryan, ORCID: 0000-0002-2529-0169 <arianasat@ispras.ru>

<sup>1,5</sup> S.T. Tigranyan, ORCID: 0000-0003-1536-9954 <shigranyan@ispras.ru>

<sup>1,4</sup> S.N. Skorik, ORCID: 0000-0002-8316-7302 <skorik@ispras.ru>

<sup>1,3</sup> D.Yu. Turdakov, ORCID: 0000-0001-8745-0984 <turdakov@ispras.ru>

<sup>1</sup> Ivannikov Institute for System Programming of the RAS, 25, Alexander Solzhenitsyn Str., Moscow, 109004, Russia

<sup>2</sup> Yaroslav-the-Wise Novgorod State University,

173003, Russia, Veliky Novgorod, st. Bolshaya St. Petersburg, 41

<sup>3</sup> Lomonosov Moscow State University,

GSP-1, Leninskie Gory, Moscow, 119991, Russian Federation

<sup>4</sup> Moscow Institute of Physics and Technology,

9, Institutskiy per., Dolgoprudny, 141701, Russia

<sup>5</sup> Russian-Armenian University,

123 Hovsep Emin str., Yerevan, 0051 Armenia

**Abstract.** An electrocardiogram (ECG) is one of the most common medical examinations. High-quality interpretation of a 12-channel electrocardiogram is important for subsequent diagnosis and treatment. One of the important steps in deciphering an ECG is to determine the boundaries of the elements of the PQRST complex. The article discusses mathematical methods for determining the boundaries of the P, T waves and the QRS complex, as well as the R, P and T peaks, presents the shortcomings of mathematical methods for determining the elements of the PQRST complex. And also the values of the metrics obtained as a result of training the neural network segmentation model of the PQRST-complex are given. The experiments performed show the relevance of using neural network and combined approaches to the analysis of the PQRST complex.

**Keywords:** ECG classification; convolutional neural network; PQRST complex; wavelet transform

**For citation:** Mashkova O.A., Shaklein V.V., Markin Yu.V., Karpulevich E.A., Ananov V.V., Asatryan A.A., Tigranyan Sh.T., Skorik S.N., Turdakov D.Yu. Methods for determining the elements of the PQRST-complex of the electrocardiogram. Trudy ISP RAN/Proc. ISP RAS, vol. 34, issue 4, 2022. pp. 229-240 (in Russian). DOI: 10.15514/ISPRAS-2022-34(4)-16

**Acknowledgements.** The reported study was funded by RFBR and MOST according to the research project № 19-51-06001

### 1. Введение

Сигнал электрокардиограммы (ЭКГ) является одним из наиболее известных биологических сигналов. Сигнал ЭКГ широко используется для диагностики здоровья людей.

ЭКГ представляет собой результат регистрации электрической активности сердца при помощи электродов на теле человека, фиксирующих разность потенциалов. Данное исследование является одним из важнейших в определении нарушения электролитного баланса, острых патологий сердца, физического состояния сердечной мышцы и т. д. Анализ ЭКГ включает в себя определение положения комплексов QRS и волн P и T.

Обнаружение комплекса QRS является одним из наиболее важных шагов, выполняемых при анализе сигнала ЭКГ. Обнаружение QRS-комплекса, в частности определение зубца R в

сигнале ЭКГ, легче, чем определение других элементов сигнала ЭКГ из-за его структурной формы и большой амплитуды.

Поставленная в исследовании задача – определить начало и конец волн P, T и комплекса QRS, а также пиков R, P и T (см. рис. 1) по заданному ЭКГ-сигналу.

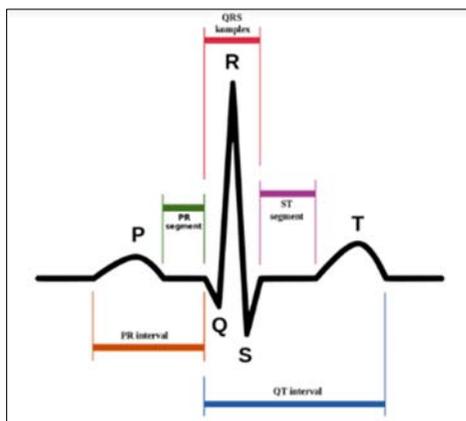


Рис. 1. Зубцы и интервалы ЭКГ  
Fig. 1. ECG waves and intervals

В исследованиях применяются различные методы обнаружения комплекса QRS, например, скрытые марковские модели [3], методы дифференцирования [6], а также методы, основанные на нейронных сетях [5].

У большинства представленных методов присутствует фундаментальная проблема, известная как чувствительность к шуму. Для решения этой проблемы могут быть предложены вейвлет-фильтры [1], однако проблема чувствительности к шуму не решается полностью.

В данной статье рассмотрены два подхода к определению элементов PQRST комплекса: на основе математических преобразований и с использованием нейронных сетей.

Работа логически разделена на четыре блока. В первой части статьи описаны математические методы получения начала и конца волн P, T и комплекса QRS, а также пиков R, P и T и приведены результаты их применения к набору данных LUDB [8, 9]. Во второй части публикации приводится анализ недостатков математических методов применимо к анализу сигнала ЭКГ. Далее в статье предлагается использование нейросетевых методов анализа положения пиков и сегментов PQRST комплекса и в заключительной части приводятся результаты применения нейросетевых методов для анализа пиков, положения волн и комплекса QRS.

## 2. Математические методы определения элементов PQRST-комплекса

### 2.1 Методология исследования

Теоретической основой исследования явилось каскадное вычисление дискретных свёрток сигнала с вейвлетной функцией методами кратномасштабного анализа [11, 12] для получения коэффициентов детализации на 2-м и 3-м уровнях декомпозиции сигнала (см. рис. 2)

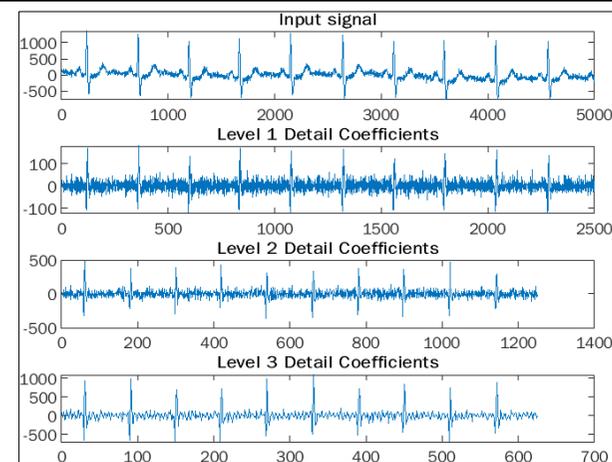


Рис. 2. Входной сигнал и коэффициенты детализации 1-3 уровней  
Fig. 2. Input signal and detail factors of 1-3 levels

### 2.2 Описание алгоритма

В качестве базового алгоритма был выбран алгоритм разметки одного отведения ЭКГ [4]. Выходной сигнал кардиографа передискретизируется к частоте 500 Гц и пропускается через полосовой фильтр Баттерворта 10-го порядка с частотами среза 3 и 30 Гц. Для обработанного сигнала считаются коэффициенты детализации дискретного вейвлет-преобразования для вейвлета Хаара 2-го и 3-го уровней. Нулевое пересечение данных коэффициентов соответствует точкам локального экстремума сглаженного исходного сигнала, а их максимальные абсолютные значения отвечают максимальным амплитудам сигнала [13]. Положение пика R рассчитывается на основе нулевых пересечений коэффициентов 2-го уровня и соответствующих максимальных амплитуд в плавающем окне размера 250 мс. Каждый кандидат проверяется с помощью превышения некоторых эмпирически полученных пороговых значений для коэффициентов 2-го и 3-го уровней в 100 мс-окрестности.

На следующем шаге алгоритма происходит удаление лишних и добавление пропущенных позиций на основе расстояния между соседними пиками, а также сопоставляются результаты по данной позиции по всем отведениям для получения лучшей разметки. Положение начала комплекса QRS определяется левее точки, соответствующей ближайшему слева максимуму модуля положения зубца R на 2-м уровне разложения. Максимумы модуля внутри окна 120 мс также ищутся на основе некоторых пороговых значений коэффициентов. Аналогично находится позиция конца комплекса QRS.

В завершение сегментации комплекса QRS его начало и конец усредняются по всем отведениям. Пик P определяется в окне размера 200 мс левее начала комплекса QRS с помощью нулевых пересечений коэффициентов 3-го уровня с наибольшей амплитудой. Для определения начала волны P используются нулевые пересечения слева от пика P в окне 100 мс, а также предшествующие им максимумы модуля, левее которых ищутся коэффициенты, превышающие некоторый порог. Конец волны P определяется симметрично относительно пика, но не дальше начала комплекса QRS, следующего за данной волной. Полученные координаты корректируются (удаляются лишние точки и добавляются пропущенные) на основе расстояний между соседними величинами, а также пик, начало и конец усредняются по всем отведениям. Блок-схема алгоритма представлена на рис. 3.

Аналогично ищутся параметры волны Т. На основе полученных данных считаются продолжительность и амплитуда волны Р и Т, средняя, минимальная и максимальная ЧСС и R-R расстояние, угол альфа во фронтальной плоскости для комплекса QRS, волн Р и Т, наклон сегмента ST, скорректированные QT интервалы и их дисперсия по формулам Базетта, Фридерика и Саги, а также корнельское произведение.

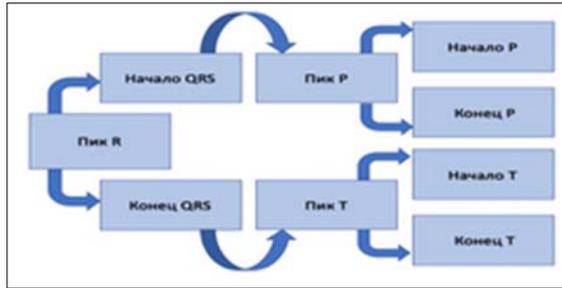


Рис. 3. Блок-схема алгоритма  
Fig. 3. Algorithm flowchart

### 2.3 Оценка работы алгоритма

Алгоритм тестировался на данных LUBD (Lobachevsky University Electrocardiography Database). Обозначим через  $TP$  (*true positive*) число точек, определенных корректно (т. е. тех, что попадали в симметричную 150 мс-окрестность точки аннотации), через  $FP$  (*false positive*) – число точек, найденных алгоритмом, но не присутствующих в аннотации, через  $FN$  (*false negative*) – число ошибочно отсутствующих точек. Для оценки работы алгоритма были взяты метрики из [14]:

$$SE = TP / (TP + FN)$$

$$PPV = TP / (TP + FP)$$

$$F1 = 2TP / (2TP + FP + FN)$$

Для TP-точек также были подсчитаны средняя ошибка и дисперсия ошибок в мс. Для оценки устойчивости работы алгоритма были посчитаны такие же метрики для симметричной 40 мс-окрестности.

40 мс	m ± d	Se	PPV	F1
Начало QRS	-21.5 ± 8.6	99.20 %	99.55 %	99.33 %
Пик QRS	1.8 ± 7.6	99.36 %	99.61 %	99.44 %
Конiec QRS	16.5 ± 10.1	99.23 %	99.60 %	99.32 %
Начало P	-21.2 ± 6.8	100.00 %	99.60 %	99.75 %
Пик P	-18.9 ± 5.2	100.00 %	99.74 %	99.85 %
Конiec P	0.8 ± 9.5	100.00 %	99.22 %	99.32 %
Начало T	-11.1 ± 10.6	98.15 %	99.58 %	98.33 %
Пик T	-5.2 ± 5.4	99.03 %	99.43 %	99.09 %
Конiec T	10.6 ± 10.2	98.06 %	98.70 %	98.51 %
150 мс	m ± d	Se	PPV	F1
Начало QRS	-23.5 ± 10	99.25 %	99.55 %	99.36 %
Пик QRS	0.8 ± 9.2	99.37 %	99.62 %	99.46 %
Конiec QRS	18.1 ± 13.4	99.36 %	99.59 %	99.44 %
Начало P	-64.1 ± 23	100.00 %	99.82 %	99.90 %
Пик P	-47.4 ± 17.9	100.00 %	99.82 %	99.90 %
Конiec P	0.8 ± 14.5	100.00 %	99.74 %	99.86 %
Начало T	-30 ± 18.5	99.11 %	99.78 %	99.34 %
Пик T	-11.2 ± 10.8	99.22 %	99.60 %	99.35 %
Конiec T	8.6 ± 17.7	99.16 %	99.07 %	98.99 %

Рис. 4. Полученные результаты  
Fig. 4. Results

На рис. 4 представлены результаты работы алгоритма. На рис. 5 представлен пример сегментации ЭКГ-сигнала.

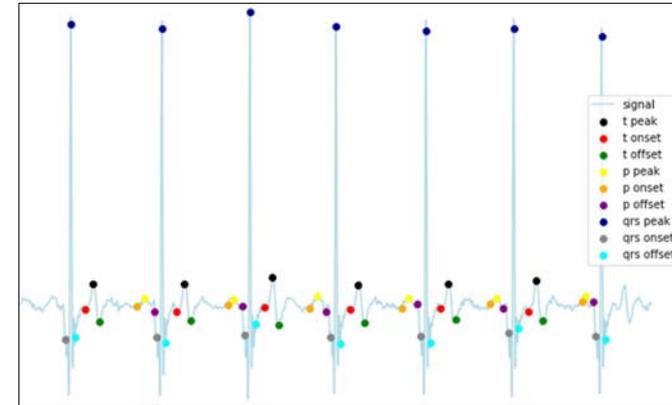


Рис. 5. Пример сегментации ЭКГ-сигнала  
Fig. 5. Example of ECG-signal segmentation

Отметим, что аналогичный подход также был применен для оценки качества обученных нейросетей.

### 3. Определение элементов PQRST-комплекса методами машинного обучения

Математические методы определения элементов PQRST-комплекса не всегда дают положительный результат вследствие зашумленности исходного ЭКГ-сигнала сетевыми помехами, мышечным тремором и т.д., а также искривления изолинии. Особенно трудной задачей является сегментация волны Р в силу малости ее амплитуды и, соответственно, совокупной энергии; более того, например, при фибрилляции предсердий, волны Р отсутствуют на ЭКГ, заменяясь на специфические волны фибрилляции f, которые не учитываются в стандартных алгоритмах разметки PQRST-комплекса. Сегментация комплекса QRS осложнена большим набором различий его морфологий в зависимости от характера сердечно-сосудистого заболевания (здесь в качестве примера можно привести острый инфаркт миокарда, эффект дигиталиса и блокады ножек пучка Гиса). Таким образом, математические методы сегментации PQRST-комплекса не всегда являются эффективными на реальных данных. Поэтому актуальным направлением для решения поставленной задачи является разработка и реализация алгоритмов глубокого обучения нейронных сетей, поскольку они имеют высокую обобщающую способность.

#### 3.1 Выбор архитектуры нейросети

На текущий момент передовой архитектурой нейронной сети, решающей поставленную задачу, является UNET-подобная архитектура [14]. В то же время, UNET не является единственной архитектурой, решающей подобные задачи, поэтому в рамках эксперимента дополнительно следует адаптировать и протестировать одну из архитектур, решающих задачу сегментации.

В [17] для выделения основных элементов использовалась нейросеть, имеющая архитектуру «автокодировщик» [2] (рис. 6). Как правило, подобные архитектуры используются для

сжатия с минимальными потерями. Также они могут использоваться для сегментации, однако их результаты не превосходят результатов архитектур, заточенных на сегментацию.

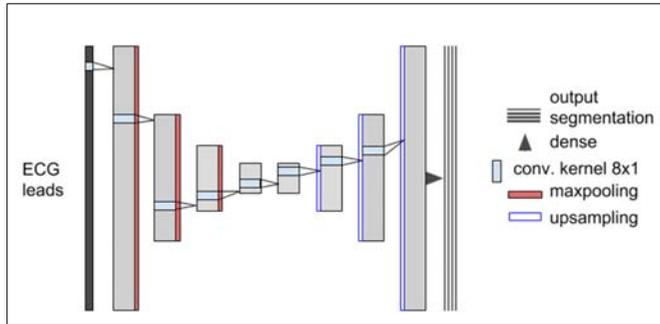


Рис. 6. Архитектура нейросети, использованная в статье [17]  
Fig. 6. The neural network architecture used in [17]

Результат, описанный в статье [14], на данный момент, является лучшим из опубликованных. В этой работе используется архитектура UNet1D (рис. 7), а в качестве обучающих данных – закрытый набор LUDB-extended. Воспроизвести результаты статьи [14] невозможно, поскольку веса модели не опубликованы, и получить доступ к использованному набору данных крайне затруднительно.

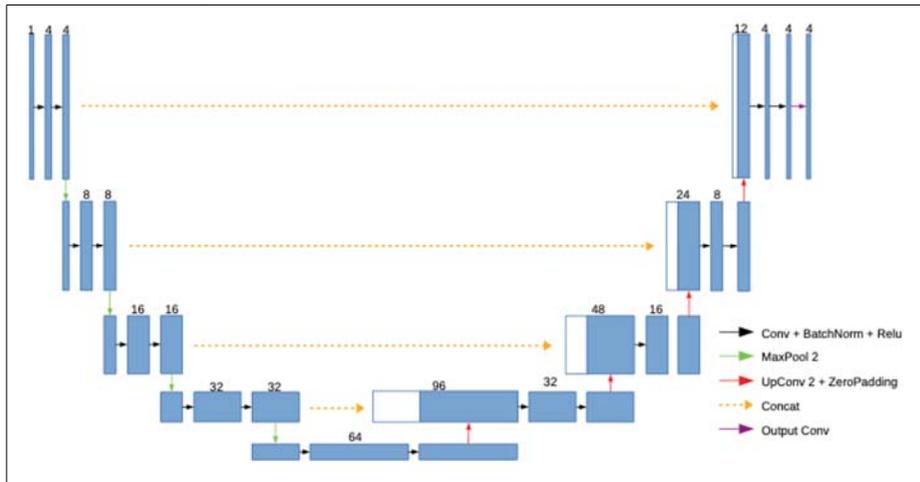


Рис. 7. Архитектура UNet1D  
Fig. 7. UNet1D architecture

Авторам рассмотренных исследований удалось добиться высоких результатов. В то же время воспроизвести эти результаты не представляется возможным, поскольку не были опубликованы исходные коды, обученные модели, наборы обучающих данных. Поэтому было решено самостоятельно подготовить обучающий набор данных, а также воспроизвести архитектуру UNet1D и адаптировать архитектуру YOHO, после чего выполнить обучение нейросетей и провести сравнительное тестирование на наборе данных LUDB. В рамках работы рассматриваются две адаптированные архитектуры:

- UNet1D [14] – UNet-подобная архитектура [16];
- YOHO [18] – YOLO-подобная архитектура [15].

### 3.2 Подготовка обучающего набора данных

Важнейшим фактором при обучении нейронных сетей является наличие большого объема размеченных данных. В рамках решения задачи выделения элементов ЭКГ существует всего несколько открытых наборов данных, причем только один из них содержит записи ЭКГ в 12 отведениях [10]. Для возможности сравнения полученных результатов с ранними работами этот набор будет использоваться в качестве тестовой выборки. В то же время, разделение данного набора на обучающую и тестовую выборки может привести к необъективным данным для сравнения - он содержит малое количество записей с патологиями, влияющими на ритм сердца: всего 4 записи с синусовой тахикардией, 2 записи с нерегулярным синусовым ритмом и 3 записи с типичным трепетанием предсердий [8]. Поэтому нужно было подготовить новый обучающий набор данных. При подготовке обучающего набора данных использовался следующий подход:

- из неразмеченного набора данных были выбраны 10000 записей ЭКГ, на которых присутствуют различные патологии, влияющие на ритм;
- выбранные записи ЭКГ были размечены с использованием математического алгоритма, представленного в начале статьи;
- на размеченных данных было проведено обучение нейросети;
- обученная нейросеть была дообучена на наборе данных LUDB;
- из неразмеченного набора данных были выбраны ещё 5000 записей ЭКГ, на которых присутствуют различные патологии, влияющие на ритм;
- дополнительно выбранные записи были размечены с использованием обученной нейросети.

Полученные 5000 размеченных данных использовались для обучения нейросетей в рамках проведенных экспериментов.

### 3.3 Метрики оценки качества нейросети

Найденные коммерческие решения, реализующие алгоритмы выделения основных элементов ЭКГ, не отображают эти элементы непосредственно, а используют их для подсчета отображаемых статистик или автоматической постановки диагноза.

Публикация	Начало P	Конец P	Начало QRS	Конец QRS	Начало T	Конец T	Среднее
Finding Morphology Points of Electrocardiographic-Signal Waves Using Wavelet Analysis	SE (%)	98,46	98,46	99,61	99,61	-	98,03
	PPV (%)	96,41	96,41	99,87	99,87	-	98,84
	F1 (%)	97,42	97,42	99,74	99,74	-	98,55
ECG Segmentation by Neural Networks: Errors and Correction	SE (%)	95,20	95,39	99,51	99,50	97,95	97,52
	PPV (%)	82,66	82,59	98,17	97,96	94,81	94,96
	F1 (%)	88,49	88,53	98,84	98,72	96,35	94,53
Deep Learning for ECG Segmentation	SE (%)	98,05	98,01	100	100	99,68	99,77
	PPV (%)	97,73	97,69	99,93	99,93	99,37	99,46
	F1 (%)	97,89	97,85	99,97	99,97	99,52	99,61

Рис. 8. Метрики, полученные в других публикациях  
Fig. 8. Metrics in other publications

Такой подход является непрозрачным, поскольку врач не может оценить, насколько качественно были обнаружены элементы, на основе которых были рассчитаны статистики.

Поэтому для оценки разработанного решения выполнено сравнение с научными исследованиями, в рамках которых решалась схожая задача.

Работа по сравнению существующих открытых подходов [7, 17, 14] была проделана в статье [14] – результаты представлены на рис. 8. Указанные метрики посчитаны для данных из набора LUDB. На этом же наборе протестировано разработанное решение.

### 3.4 Оценка качества обученных нейросетей

Обученные нейросети архитектур UNet1D и YOHO были протестированы на наборе данных LUDB – результаты представлены на рисунке 9. При обучении и тестировании выполняется нормализация данных, включающая приведение ЭКГ-записей к одной частоте и заданной продолжительности – обрезка для записей большей продолжительности, дополнение нулевыми значениями для записей меньшей продолжительности.

Нейросеть / публикация		Начало Р	Конец Р	Начало QRS	Конец QRS	Начало Т	Конец Т	Среднее
Обученная нейросеть архитектуры UNet1D	SE (%)	96,25	97,70	98,69	98,69	96,84	98,06	97,70
	PPV (%)	97,61	99,17	96,57	96,57	97,51	98,64	97,68
	F1 (%)	96,75	98,25	97,29	97,29	97,57	98,24	97,56
Обученная нейросеть архитектуры YOHO	SE (%)	97,37	97,80	99,72	99,72	97,97	99,11	98,62
	PPV (%)	98,63	99,15	97,98	97,98	97,91	99,04	98,45
	F1 (%)	97,78	98,24	98,73	98,73	97,86	98,99	98,39
Deep Learning for ECG Segmentation	SE (%)	98,05	98,01	100	100	99,68	99,77	99,25
	PPV (%)	97,73	97,69	99,93	99,93	99,37	99,46	99,02
	F1 (%)	97,89	97,85	99,97	99,97	99,52	99,61	99,14

Рис. 9. Метрики, полученные при тестировании обученных нейросетей  
Fig. 9. Metrics obtained by testing trained neural networks

### 4. Заключение

В рамках исследования были разработаны, реализованы и протестированы методы определения элементов PQRST-комплекса электрокардиограммы. Математические методы сегментации PQRST-комплекса не всегда являются эффективными на реальных данных. Алгоритмы глубокого обучения нейронных сетей имеют высокую обобщающую способность, поэтому являются более перспективными.

### Список литературы / References

- [1] Alexandridi A., Panagopoulos I. et al. R-Peak Detection with Alternative Haar Wavelet Filter. In Proc. of the 3rd IEEE International Symposium on Signal Processing and Information Technology, 2003, pp. 219-222.
- [2] Bank D., Koenigstein N., Giryas R. Autoencoders. arXiv:2003.05991, 2020, 22 p.
- [3] Coast D.A., Stern R.M. et al. An Approach to Cardiac Arrhythmia Analysis Using Hidden Markov Models. IEEE Transactions on Biomedical Engineering, vol. 37, issue 9, 1990, pp. 826-836.
- [4] Di Marco L.Y., and Chiari L. A Wavelet-Based Ecg Delineation Algorithm for 32-Bit Integer Online Processing. Biomedical Engineering Online, vol. 10, issue 1, 2011, pp. 1-19
- [5] Fernández-Delgado M., Barro Ameneiro S. MART: A Multichannel Art-Based Neural Network. IEEE Transactions on Neural Networks, vol. 9, issue 1, 1998, pp. 139-150.
- [6] Fraden J., Neuman M.R. QRS Wave Detection. Medical and Biological Engineering and Computing, vol. 18, issue 2, 1980. Pp. 125-132.

- [7] Kalyakulina A.I., Yusipov I.I. et al. Finding Morphology Points of Electrocardiographic Signal Waves Using Wavelet Analysis. Radiophysics and Quantum Electronics, vol. 61, issue 8-9, 2019, pp. 689-703.
- [8] Kalyakulina A.I., Yusipov I.I. et al. Ladb: A New Open-Access Validation Tool for Electrocardiogram Delineation Algorithms. IEEE Access, vol. 8, 2020, pp. 186181-186190.
- [9] Kalyakulina A.I., Yusipov I.I. et al. Lobachevsky University Electrocardiography Database (Version 1.0.0). PhysioNet, 2020, URL: <https://physionet.org/content/ladb/1.0.0/>.
- [10] Kalyakulina A.I., Yusipov I.I. et al. Lobachevsky University Electrocardiography Database (Version 1.0.1). PhysioNet, 2021, URL: <https://physionet.org/content/ladb/1.0.1/>.
- [11] Mallat S. A Theory for Multiresolution Signal Decomposition: The Wavelet Representation. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 11, issue 7, 1989, pp. 674-693.
- [12] Mallat S. Zero-Crossings of a Wavelet Transform. IEEE Transactions on Information Theory, vol. 37 (4): 1991. “1019–33.
- [13] Martínez J.P., Almeida R. et al. A Wavelet-Based ECG Delineator: Evaluation on Standard Databases. IEEE Transactions on Biomedical Engineering, vol. 51, issue 4, 2004, pp. 570-581.
- [14] Moskalenko V., Zolotykh N., Osipov G. Deep Learning for ECG Segmentation. In International Conference on Neuroinformatics. Studies in Computational Intelligence, vol. 856, 2019, pp. 246-254.
- [15] Redmon J., Divvala S. et al. You Only Look Once: Unified, Real-Time Object Detection. In Proc. of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016, pp. 779-788.
- [16] Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. Lecture Notes in Computer Science, vol. 9351, 2015, pp. 234-241.
- [17] Sereida I., Alekseev S. et al. ECG Segmentation by Neural Networks: Errors and Correction. In Proc. of the International Joint Conference on Neural Networks (IJCNN), 2019, pp. 1-7.
- [18] Venkatesh S., Moffat D., and Reck Miranda E. You Only Hear Once: A YOLO-like Algorithm for Audio Segmentation and Sound Event Detection. Applied Sciences, vol. 12, issue 7, 2021, article no. 3293, 16 p.

### Информация об авторах / Information about authors

Ольга Анатольевна МАШКОВА, студентка магистратуры механико-математического факультета МГУ. Область научных интересов: анализ и разметка медицинских данных, глубокое обучение, компьютерное зрение и обработка изображений и сигналов.

Olga Anatolyevna MASHKOVA, Master's student of the Mechanics and Mathematics of Moscow State University. Research interests: analysis and labeling of medical data, deep learning, computer vision and image and signal processing.

Всеволод Владиславович ШАКЛЕИН, студент бакалавриата. Научные интересы: машинное и глубокое обучение, анализ данных.

Vsevolod Vladislavovich SHAKLEIN, undergraduate student. Research interests: machine and deep learning, data analysis.

Юрий Витальевич МАРКИН, к.т.н., научный сотрудник ИСП РАН. Научные интересы: машинное и глубокое обучение, анализ биомедицинских данных, информационные системы, обработка изображений и сигналов.

Yury Vitalievich MARKIN, PhD in Technical Sciences, Researcher at ISP RAS. Research interests: machine and deep learning, biomedical data analysis, information systems, image and signal processing.

Евгений Андреевич КАРПУЛЕВИЧ является специалистом отдела «Информационные системы». Сфера научных интересов: применение алгоритмов анализа данных к биомедицинскому домену, разработка систем распределенного хранения и анализа данных.

Evgeny Andreevich KARPULEVICH is a specialist of the Information Systems Department. Research interests: application of data analysis algorithms to the biomedical domain, development of systems for distributed data storage and analysis.

Владислав Валерьевич АНАНЬЕВ – выпускник и ассистент кафедры информационных технологий и систем НовГУ, аспирант ИСП РАН. Сфера научных интересов: анализ и

разметка данных из различных сфер деятельности, глубокое обучение, компьютерное зрение и обработка изображений.

Vladislav Valerievich ANANEV is a graduate and assistant of the Department of Information Technologies and Systems, Novgorod State University, postgraduate student of ISP RAS. Area of research interests: data labeling and analysis for various fields of activity, deep learning, computer vision and image processing.

Ариана Арменовна АСАТРЯН, научный сотрудник. Научные интересы: машинное обучение, анализ данных, обработка изображений и сигналов.

Ariana Armenovna ASATRYAN, researcher. Research interests: machine learning, data analysis, image and signal processing.

Шагане Тиграновна ТИГРАНЯН, магистрант. Научные интересы: машинное обучение, анализ данных, обработка изображений и сигналов.

Shagane Tigranovna TIGRANYAN, graduate student. Research interests: machine learning, data analysis, image and signal processing.

Сергей Николаевич СКОРИК, студент магистратуры МФТИ и сотрудник ИСП РАН. Научные интересы: машинное обучение, методы оптимизации, обработка изображений и сигналов.

Sergej Nikolaevich SKORIK, Master's student at MIPT and an employee of the ISP RAS. Research interests: machine and deep learning, optimization methods, image and signal processing.

Денис Юрьевич ТУРДАКОВ – к.ф.-м.н., заведующий отделом «Информационные системы» ИСП РАН, доцент МГУ. Сфера научных интересов: машинное обучение, интеллектуальный анализ данных, извлечение информации, обработка естественного языка, сложные сети, анализ социальных сетей, большие данные.

Denis Yuryevich TURDAKOV, PhD in Physics and Mathematics, Head of the Information Systems Department at ISP RAS, Associate Professor of the System Programming Department of Moscow State University. Research interests: natural language processing, machine learning, data mining, social network analysis, distributed data processing.