

DOI: 10.17725/rensit.2024.16.239

Диагностика сигналов ЭКГ на основе их цифровой обработки и оптимизированной модели трансформера

¹Анас Фуад Ахмед, ²Халида С. Риджаб, ¹Ахмед Талаал Камил

¹Университет Аль-Иракия, Инженерный колледж, факультет электротехники, <https://en.aliraqia.edu.iq/>
Аль-Адмия-Хайба Хатон, 6029, Багдад, Ирак

²Технологический университет, факультет электротехники, <https://uotechnology.edu.iq/>
Аль-Вехад, 19006, Багдад, Ирак

E-mail: anas.abmed@aliraqia.edu.iq, khalida.s.rijab@uotechnology.edu.iq, abmed.talal@aliraqia.edu.iq

Поступила 13.02.2024, рецензирована 29.02.2024, принята 04.03.2024, опубликована 25.04.2024

Представлена действительным членом РАЕН В.В. Колесовым

Аннотация: Дилемма массивных параметров сигналов ЭКГ является проблемой для современных методов их классификации. Большинство современных методов демонстрируют недостаточную эффективность диагностики сигналов ЭКГ в межпациентном режиме. В попытке справиться с вышеуказанными ограничениями данное исследование предлагает модель, которая использует оптимизированную структуру преобразователя для классификации сердечных сокращений в соответствии с требованиями «Ассоциации по развитию медицинского оборудования, ААМІ» и подчиняется условиям приема пациентов. Построена архитектура, названная оптимизированной сетью, для замены блока самообслуживания (SAU) в кодирующей части модели трансформера. Предлагаемая модель, включающая оптимизированную сеть, превосходит модель трансформера на основе SAU и требует меньше вычислений. Представлена надежная архитектура внедрения, основанная на сверточной нейронной сети со схемой реализации на основе сети сжатия и возбуждения, которая использовалась для взвешивания функций шаблона формы локального сердцебиения. Проведено обширное тестирование для сравнения предложенной модели с существующими схемами. Тесты показали близость их результатов.

Ключевые слова: концы с концами; классификация ЭКГ; трансформерная архитектура; сжатие и возбуждение; глубинная свертка)

УДК 53.047:57(075.8)

Для цитирования: Анас Фуад Ахмед, Халида С. Риджаб, Ахмед Т. Камил. Диагностика сигналов ЭКГ на основе их цифровой обработки и оптимизированной модели трансформера. РЭНСИТ: Радиоэлектроника. наносистемы. Информационные технологии, 2024, 16(2):239-248. DOI: 10.17725/rensit.2024.16.239.

A Novel and Efficient Framework for Diagnosing ECG Signals Based on the Digital Signal Processing and Optimized Transformer Model

Anas Fouad Ahmed

Al-Iraqia University, College of Engineering, Electrical Engineering Department, <https://en.aliraqia.edu.iq/>
Al Adhmia-Haiba Khaton, 6029, Baghdad, Iraq

E-mail: anas.abmed@aliraqia.edu.iq

Khalida S. Rijab

University of Technology, Electrical Engineering Department, <https://uotechnology.edu.iq/>
Al wehada-Neighborhood, 19006, Baghdad, Iraq

E-mail: khalida.s.rijab@uotechnology.edu.iq

Ahmed Talal Kamil

Al-Iraqia University, College of Engineering, Computer Engineering Department,
Al Adhmia - Haiba Khaton, 6029, Baghdad, Iraq

E-mail: ahmed.talal@aliraqia.edu.iq

Received February 13, 2024, peer-reviewed February 29, 2024, accepted March 04, 2024, published April 25, 2024

Abstract: Heartbeat disorders are considered one of the main maladies that cause mortality. Therefore, their precocious diagnosis via ECG signal is critical for introducing prompt therapy. The advanced automatic classification of ECG signals has the potential to save cardiologists a tremendous amount of time while simultaneously decreasing the chance of misdiagnosis. The dilemma of massive parameters is troubling the current methods of ECG signal classification. Most recent methods exhibit inadequate performance for diagnosing ECG signals in the inter-patient mode. In an attempt to deal with the above limitations, this study offers an innovative, efficient, and end-to-end model. The suggested model uses the optimized transformer framework to classify the heartbeats according to the "Association for the Advancement of Medical Instrumentation, AAMI," and obeys the inter-patient setting. We constructed an efficient architecture called the optimized network to substitute the Self Attention Unit (SAU) in the encoder part of the transformer model. The suggested model, which includes an optimized network, outperforms the SAU-based transformer model and requires fewer computations. A robust embedding architecture based on a Convolutional Neural Network (CNN) with a Squeeze and Excitation (SE) network-based attention scheme that has been used for weighting the Local Heartbeat Shape Pattern (LHSP) features is presented. The introduced model exceeds the state-of-the-art. An extensive test has been done to compare the achievements of the suggested model with those of the cardiologists. The results proved the closeness of their performances.

Keywords: End-to-End; ECG Classification; Transformer Architecture; Squeeze and Excitation (SE); Depth Wise Convolution (DWC)

UDC 53.047:57(075.8)

For citation: Anas Fouad Ahmed, Khalida S. Rijab, Talal K. Ahmed. A Novel and Efficient Framework for Diagnosing ECG Signals Based on the Digital Signal Processing and Optimized Transformer Model. *RENSIT: Radioelectronics. Nanosystems. Information Technologies*, 2024, 16(2):239-248e. DOI: 10.17725/j.rensit.2024.16.239.

СОДЕРЖАНИЕ

1. ВВЕДЕНИЕ (240)
 2. ПРЕДЛАГАЕМАЯ МОДЕЛЬ (241)
 - 2.1 ВСТРАИВАНИЕ ВХОДНЫХ ДАННЫХ (242)
 - 2.2 ПОЗИЦИОННОЕ КОДИРОВАНИЕ (243)
 - 2.3 УРОВЕНЬ 2 ВНИМАНИЯ НА ОСНОВЕ ОПТИМИЗИРОВАННОЙ СЕТИ (243)
 3. ЭКСПЕРИМЕНТАЛЬНЫЕ НАСТРОЙКИ (244)
 4. РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ (244)
 - 4.1 ВЛИЯНИЕ АРХИТЕКТУРНЫХ ЧАСТЕЙ ПРЕДЛАГАЕМОЙ МОДЕЛИ (245)
 - 4.2 СОКРАЩЕНИЕ ПАРАМЕТРОВ (246)
 - 4.3 СРАВНЕНИЕ ДОСТИЖЕНИЙ ПРЕДСТАВЛЕННОЙ МОДЕЛИ И ВРАЧЕЙ (246)
 5. ЗАКЛЮЧЕНИЕ (247)
- ЛИТЕРАТУРА (247)

1. ВВЕДЕНИЕ

Электрокардиограмма (ЭКГ) является популярным инструментом для наблюдения за электрическими показателями сердца и имеет решающее значение для выявления сердечно-сосудистых нарушений [1,2]. Типичный сигнал ЭКГ состоит из серии комплексов, включающих набор последовательных волн [3,4]. Из этих волн можно извлечь медицинские данные о различных участках сердечной мышцы [5–8]. На **Рис. 1** показан стандартный образец сигнала ЭКГ. Для диагностики проблем с сердцем сигнал ЭКГ должен наблюдаться и оцениваться врачом-экспертом [9]. Эта цель труднодостижима, поскольку требует привлечения большого количества врачей-кардиологов и требует длительного

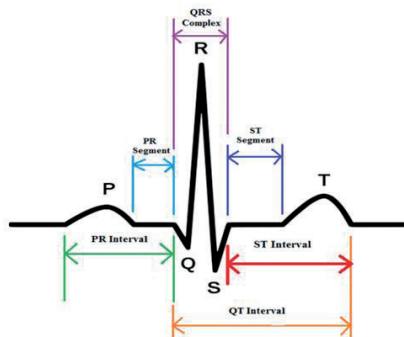


Рис. 1. Стандартная картина сигнала ЭКГ.

времени, а также не исключает возможности врачебных ошибок в диагностике, которые могут привести к летальному исходу [10]. Чтобы решить вышеуказанные проблемы, исследователи представили множество усовершенствованных автоматических классификаторов сердцебиения. Есть два основных направления. Первый основан на классических методах, которые используют ручные функции и требуют ручного вмешательства. Кроме того, также требуется процесс выбора функций. Однако они имеют ограниченное самообучение и требуют много времени [11–14]. Второй зависит от схем глубокого обучения (DL), которые комплексно объединяют извлечение и классификацию признаков [15]. Подходы DL включают три модели: первая основана на сверточной нейронной сети (CNN) [16,17], вторая зависит от рекуррентной нейронной сети (RNN) [18,19], и третья представляет собой гибрид, сочетающий в себе CNN и RNN [20,21]. С другой стороны, методы на основе DL также имеют определенные ограничения. Например, многие схемы на основе DL требуют большого количества сложных операций свертки и рекуррентных архитектур; это часто приводит к серии скрытых состояний, каждое из которых зависит от предыдущего. В результате такие архитектуры имеют низкий уровень параллельных вычислений. В настоящее время структура трансформера, включающая в себя параллельный блок самообслуживания (SAU), обеспечивает более высокую производительность в области техники перевода [22,23]. Однако обычная модель-трансформер имеет масштабируемое пространство. Помимо крупномасштабных

переменных для обучения, САУ преобразователя контурирует существенные препятствия из-за размерности контекста, например, квадратичный член размера входных данных [24]. При этом сложные методы требуют тяжелых вычислений со многими переменными, потребляют большую мощность и требуют оптимизации перед внедрением на портативных устройствах ЭКГ в реальном времени. Кроме того, их производительность требует улучшения при применении в соответствии с правилами ассоциации ААМІ и в условиях приема пациентов, когда сигналы обучения и тестирования разделены. В попытке решить вышеуказанные проблемы в данной статье предлагается новая комплексная модель, основанная на адаптированной и оптимизированной архитектуре трансформера для задачи диагностики сигналов ЭКГ. Наш существенный вклад заключается в следующем:

- Мы предлагаем новую, эффективную, комплексную модель, подходящую для устройств ЭКГ с ограниченными ресурсами, на основе модифицированной и оптимизированной структуры трансформера. Кроме того, мы улучшаем более сокращенную и надежную структуру, используя технику двойного подхода (attention). Во-первых, это локальный подход к встраиванию входных данных ЭКГ. Второй – всеобщий подход, основанный на оптимизированной сети для решения сложных вычислений и большом количестве переменных.
- Результаты представленной модели, которая соответствовала предписаниям ААМІ и условиям стационарного лечения, превзошли другие схемы, описанные в литературе.
- В этом исследовании представлены эксклюзивные эксперименты, которые включают сравнение производительности, полученной в результате предложенной модели, с аналогичными результатами, полученными по решениям кардиологов, где результаты показали небольшое превосходство предлагаемой модели.

2. ПРЕДЛАГАЕМАЯ МОДЕЛЬ

После нормализации и обнаружения пика R (на основе метода, описанного в [25]) для




Рис. 2. Структурная схема предлагаемой модели.

ЭКГ-сигнала MIT-BIH-ARR-DB (база данных аритмий MIT-BIH) проводится сегментация сердцебиений. Длина каждой доли составляет 280 семплов. Предлагаемая модель зависит от структуры преобразователя, предложенной в [22] для приложений языковой обработки. Представленная модель использует только часть кодировщика структуры преобразователя, как показано на Рис. 2. Было внесено множество модификаций и разработок в части кодера и внедрения входных данных. На входе мы представляем новую архитектуру подхода, основанную на CNN и сети сжатия и возбуждения (Squeeze and Excitation, SE) [26], чтобы усилить возможности извлечения признаков. Чтобы преодолеть дилемму большого количества параметров, представлена более эффективная и надежная схема замены CAU обычной модели [22]. Кроме того, предлагаемая модель включает в себя методы двойного подхода, как показано на Рис. 2. Локально уровень подхода 1 использует сеть SE, а универсальный уровень подхода 2 использует оптимизированную сеть. Пусть последовательность $Q = (q_1, q_2, \dots, q_1)$, L – длина тактового импульса, тогда выходные данные модели $M = (m_1, m_2, m_3, m_4)$, где m_1 – вероятность Q , присвоенная классу j .

2.1 Встраивание входных данных

Основным шагом в предлагаемой структуре является внедрение входных данных. Предлагается архитектура, основанная на сетях CNN и SE, для повышения эффективности захвата функций LHSP с помощью CNN и для взвешивания функций образца формы локального сердцебиения (Local Heartbeat Shape Pattern, LHSP) с помощью сети SE, которая представляет уровень 1 подхода, как показано на Рис. 3. Каждый сегмент пульса переконфигурирован в вектор признаков $Q = (q_1, q_2, \dots, q_1) \in \mathbb{R}^{1 \times F \times O}$, где O – количество каналов, размерность каждого канала – $1 \times F$. Процесс реконфигурации включает




Рис. 3. Предлагаемая структура модели входного блока встраивания.

установку $F = 10$ и $O = 28$. Q последовательно передается трем архитектурам с подходом уровня 1, а затем выходной сигнал G представляет собой вектор с подключением признака LHSP в тактах сигнала ЭКГ. Более того, первые две архитектуры включают одну операцию свертки, G_{conv} , и одну операцию глобального максимального пула (GMP), G_{max} . Третья архитектура не включает GMP, как показано на Рис. 3. Предлагаемая модель реализует последовательность эффективных процессов для увеличения ее мощности при извлечении функций LHSP. Сеть SE используется для повторного расчета функций свертки и взвешивания функций LHSP. Другими словами, чтобы сосредоточиться на важных функциях LHSP и исключить бесполезные функции, такие как шум, подход уровня 1 используется для взвешивания функций LHSP. Этот уровень подхода развивает чувствительность предлагаемой модели к информации LHSP. Сеть SE состоит из глобального среднего уровня пула (GAPL) и двух полносвязных уровней (FCL), как показано на Рис. 4. После последовательности

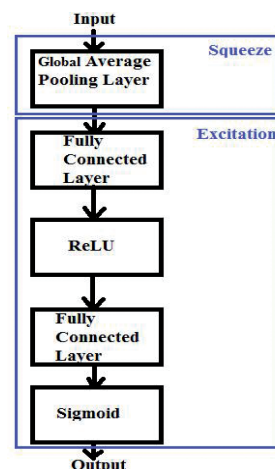


Рис. 4. Детальная структура сети SE.

процессов вес $E \in \mathbb{R}^{1 \times O'}$ каждого канала, соответствующего признаку V' , определяет вес E признака V' на основе процесса взвешивания. Эти архитектуры и процессы обеспечивают взвешивание функций LHSP, привлекают подход к важным функциям LHSP и усиливают связь между функциями LHSP. GAPL применяется для сохранения связей между функциями и создания функций канала.

$$H = G_{\text{GAPL}}(v') = \text{Concat}_{j=1}^{O'} \left(\frac{1}{B} \sum_{a=1}^B v'_a \right) \in \mathbb{R}^{1 \times O'}. \quad (1)$$

Размер функции H минимизируется, а затем размер функций максимизируется, при этом FCL настраивают О'Н для каналов на O'/CoF (CoF — коэффициент сжатия) для минимизации вычислений.

Значения CoF указаны последовательно как 4, 8 и 16.

$$E = \text{sigmoid}(\omega_2 \text{ReLU}(\omega_1 H^T)) \in \mathbb{R}^{O' \times 1}, \quad (2)$$

$$\omega_1 \in \mathbb{R}^{\frac{O'}{\text{CoF}} \times O'}, \omega_2 \in \mathbb{R}^{O' \times \frac{O'}{\text{CoF}}}.$$

ReLU используется для фиксации нелинейной взаимосвязи между функциями LHSP сердечного ритма. Сигмовидная функция используется для определения релевантности между функциями LHSP.

$$\text{ReLU}(H) = \max(0, H), \quad (3)$$

$$\text{sigmoid}(H) = \frac{1}{1 + e^{-H}}. \quad (4)$$

Полное уравнение приведено ниже:

$$V'_a = G_{\text{scale}}(V', E) = E \cdot V' \in \mathbb{R}^{O' \times \frac{F'}{2}}. \quad (5)$$

2.2 ПОЗИЦИОННОЕ КОДИРОВАНИЕ

Необходимо передать позиционные данные сигнала ЭКГ через кодер и смонтировать его с помощью предусмотренного на предыдущем шаге встраивания. Встраивание синусоидальной позиции (SPE) используется, поскольку оно обрабатывает более длинные последовательности с меньшим временем на этапе обучения. SPE описывается формулами, приведенными ниже [22]:

$$\text{PoEn}(PO, 2n) = \sin\left(PO / 10000^{2n/z_{\text{model}}}\right), \quad (6)$$

$$\text{PoEn}(PO, 2n+1) = \cos\left(PO / 10000^{2n/z_{\text{model}}}\right), \quad (7)$$

где n — размерность, PO — позиция, z_{model} — размерность выходного встраивания.

2.3. УРОВЕНЬ 2 ПОДХОДА НА ОСНОВЕ ОПТИМИЗИРОВАННОЙ СЕТИ

В этом разделе обсуждается применение подхода уровня 2 и архитектура оптимизированной сети. Новая оптимизированная архитектура применяется для замены SAU исходной модели, представленной в [22]. Оптимизированная сеть в основном зависит от оптимизированной свертки (OC). Вначале, чтобы понять OC, необходимо объяснить глубину мудрой свертки (DWC). DWC реализует свертку по каждому каналу индивидуально. Количество параметров можно минимизировать от $z^2 w$ до zw , где w — ширина ядра. Выход $T \in \mathbb{R}^{t \times z}$ (t — количество временных шагов) DWC с весом $\omega \in \mathbb{R}^{w \times z}$ для p^{th} -го элемента и размером вывода o можно рассчитать с помощью уравнения (8):

$$T_{p,o} = \text{Depthwise Conv}(Q, \omega_o, :, p, o) = \sum_{a=1}^w \omega_{o,a} \cdot Q_{\left(p+a-\frac{[w+1]}{2}, o\right)}. \quad (8)$$

OC можно определить с помощью уравнения (9):

$$\begin{aligned} OC\left(Q, \omega_{\left[\frac{oY}{z}\right]}, :, p, o\right) &= \\ &= \text{DWC}\left(Q, \text{soft max}\left(\omega_{\left[\frac{oY}{z}\right]}, :\right), p, o\right). \end{aligned} \quad (9)$$

Каналы z сегментируются на наборы Y , а затем параметры каждого канала z/Y объединяются. Следовательно, параметры № минимизируются до z/Y , например, классическая свертка требует $1310720 (z^2 \times w)$ весов для $z = 512$ и $w = 5$, тогда как DWC имеет $2560 (z \times w)$ весов, и свойство распределения веса $Y = 8$, т.е. мы получаем только 40 ($Y \times w$); веса $\omega \in \mathbb{R}^{Y \times w}$ нормализуются с использованием функции softmax .

OC — это глубинная свертка (Depth Wise Convolution, DWC), которая использует функцию softmax для нормализации своих весов и совместно использует определенные выходные каналы. В отличие от SAU, OC имеет постоянное окно контекста и использует веса, которые не меняются во время временных шагов, для оценки релевантности компонентов контекста.

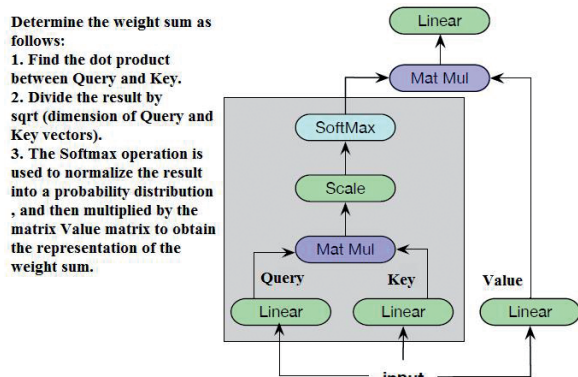


Рис. 5. Архитектура SAU.




Рис. 6. Структура оптимизированной сети.

Рис. 5 иллюстрирует архитектуру SAU, а Рис. 6 демонстрирует структуру оптимизированной сети. Вход оптимизированной сети отображается от z до $2z$. После этого применяются сети GLU, ОС и SE соответственно. Gated Linear Unit (GLU) использует 50% входов в качестве вентилях с использованием сигмовидных модулей, а затем определяет поточечное произведение с оставшимися входами. DropConnect считается эффективным регуляризатором для ОС. Более того, DropConnect предполагает игнорирование некоторых промежуточных данных внутри канала [24]. Оптимизированная сеть отвечает за сбор и оценку функций Global Heartbeat (GH).

3. ЭКСПЕРИМЕНТАЛЬНЫЕ НАСТРОЙКИ

Эксперименты для этого исследования проводились с использованием MIT-BIH-ARR-DB [27], следуя рекомендациям ААМІ (как показано в Таблице 1) и стратегии взаимодействия с пациентами. Чтобы соответствовать методу между пациентами, наборы данных сигналов обучающего теста делятся на DS1 и DS2, как объяснено в [28].

Таблица 1
Переименование ритмов MIT-BIH на основе рекомендаций ААМІ.

AAMI Classes with Explanation	MIT-BIH Beats with Labels	
Normal beats (N)	N	Normal beat
	L	Left bundle branch block beat
	R	Right bundle branch block beat
	e	Atrial escape beat
Supraventricular ectopic beats (SVEB)	j	Nodal (junctional) escape beat
	A	Atrial premature beat
	a	Aberrated atrial premature beat
Ventricular ectopic beats (VEB)	J	Nodal (junctional) premature beat
	S	Supraventricular premature beat
	V	Premature Ventricular contraction
Fusion beats (F)	E	Ventricular escape beat
	F	Fusion of ventricular and normal beat
Unknown beats (Q)	/	Paced beat
	f	Fusion of paced and normal beat
	Q	Unclassified beat

DS1 увеличивается с помощью SMOTE [29] для решения дилеммы несбалансированных данных.

Чтобы определить оптимальные переменные для модели, мы используем подход управляющих переменных. Поиск фокусируется на четырех важнейших переменных, а именно: z_{model} , уровнях подхода, количестве ОС в каждой голове и циннере. Хотя три переменные остаются постоянными, мы исследуем влияние остальных переменных на результаты. Оптимальное сочетание переменных показано в Таблице 2.

4. РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

Сравнение представленной модели и подходов конкурентов в литературе представлено путем определения следующих показателей: показатель F1, положительная прогностическая ценность (PPV), чувствительность (SEN) и точность (ACC), как указано в уравнениях 10-13.

$$F1 - Score = \frac{2 \cdot PPV \cdot SEN}{PPV + SEN}, \quad (10)$$

$$PPV = \frac{TP}{TP + FP}, \quad (11)$$

$$SEN = \frac{TP}{TP + FN}, \quad (12)$$

$$ACC = \frac{TP + TN}{TN + FN + TP + FP}, \quad (13)$$

Таблица 2
Оптимальное объединение переменных для предлагаемой модели

Переменные	Численная величина
Размерность вывода встраивания (z_{model})	64
Слои подхода	7
Размер партии (BS)	64
№ ОС в каждой голове	7
Выходной размер линейного модуля (z_{inner})	512

Таблица 3

Сравнение достижений представленной модели и современной модели.

Reference	N (%)				S (%)				V (%)				Overall (%)
	PPV	SEN	ACC	F1-score	PPV	SEN	ACC	F1-score	PPV	SEN	ACC	F1-score	ACC _o
[30]	99.90	99.10	-	99.49	75.70	100	-	86.16	100	95.40	-	97.11	98.10
[31]	98.17	99.42	-	98.79	89.54	74.65	-	81.37	93.25	95.65	-	94.43	-
[32]	98.00	94.00	-	95.96	53.00	62.00	-	57.15	59.40	87.30	-	70.70	-
[19]	97.60	99.80	97.80	98.68	95.70	66.90	98.30	78.74	98.20	92.30	99.20	95.15	98.40
[33]	97.60	97.50	-	97.54	59.40	83.80	-	69.52	90.20	80.40	-	85.01	95.10
[34]	98.50	97.60	96.80	98.64	74.00	76.80	97.50	75.37	92.40	93.80	98.60	93.09	97.60
[35]	93.33	94.54	-	93.33	65.88	35.22	-	45.90	79.86	88.35	-	83.89	88.99
Our model	99.89	99.93	99.76	99.91	99.79	99.88	99.80	99.83	99.85	99.94	99.95	99.89	99.94

где FN – ложноотрицательный результат, FP – ложноположительный результат, TP – истинно положительный результат.

Результаты предлагаемой структуры и новейших исследований в современной литературе показаны в Таблице 3. В целом, современные методы обеспечивают разумные достижения в идентификации V-класса. Но их достижения в признании S-класса заметно снизились. По сути, это результат отличительных особенностей LHSP для V-категории. Класс S обычно имеет LHSP, который похож на класс N, что затрудняет различие между ними. Результаты показывают, что наша модель превосходит самые современные модели, особенно в обнаружении S-класса. Во всех категориях наша модель превосходит существующие методологии, демонстрируя эффективность представленной архитектуры структуры. Ссылаясь на [30], которое является лучшим из опубликованных исследований, наша модель увеличила показатель F1 для обнаружения классов S и V на 13.67% и 2.78% соответственно. Однако авторы работы [30] смогли получить оптимальные PPV и SEN для классов V и S, но сделали это за счет снижения SEN для V и плохого PPV для классов S. Кроме того, подход, предложенный в [30], не является сквозным, как наша модель. По сравнению с [35], самой новой из опубликованных работ, представленная модель повысила показатель F1 для S, V и N на 53.93%, 16% и 6.58% соответственно. Поскольку

большинство предыдущих исследований были сосредоточены на классификации классов N, V и S, обнаружение класса F в предложенной схеме сравнивалось только с результатами кардиологов.

4.1 Влияние архитектурных частей предлагаемой модели

Чтобы проверить, может ли введенная структура ускорить процесс обнаружения, мы провели следующие тесты: (результаты представлены в Таблице 4)

- Уровень подхода 2 на основе оптимизированной сети и уровень подхода 1 на основе сети SE (уровень Wi 2 и уровень Wi 1): предлагаемая модель.
- Уровень подхода 2, основанный только на оптимизированной сети (уровень Wi 2 и уровень Wo 1): представленная структура без уровня подхода 1.
- Уровень подхода 1, основанный только на сети SE (уровень Wo 2 и уровень Wi 1): предлагаемая модель без подхода, часть оптимизированной сети.

Трансформерная структура (типичная модель трансформера): типичная трансформирующая структура, требующая подхода к себе [22].

Результаты испытаний показали, что оптимизированная сеть может заменить технику самообслуживания. Таким образом, схема самообслуживания может оказаться ненужной архитектурой. Особенно с использованием второго уровня техники подхода эффективность модели была значительно повышена, особенно

Таблица 4

Результаты внедрения модели с различными структурами

Architecture	Overall (%)	N (%)				S (%)				V (%)			
	ACC	SEN	PPV	ACC	F1-score	SEN	PPV	ACC	F1-score	SEN	PPV	ACC	F1-score
Wi level 2 and Wi level 1	99.94	99.93	99.89	99.76	99.91	99.88	99.79	99.80	99.83	99.94	99.85	99.95	99.89
Wi level 2 and Wo level 1	98.72	91.84	99.58	98.63	95.55	90.00	99.86	98.59	94.67	98.84	95.83	98.93	97.31
Wo level 2 and Wi level 1	98.82	99.33	99.65	98.48	99.49	91.03	88.18	98.52	89.58	99.96	99.44	98.89	99.70
Typical transformer model	97.53	99.11	99.34	97.42	99.22	85.33	93.21	97.37	89.09	99.98	99.73	97.88	99.85

для S-класса. Использование сети SE в этой архитектуре играет значительную роль в взвешивании функций GN. Архитектура встраивания входных данных с подходом уровня 1 также может усилить ритмическую информацию и, таким образом, повысить производительность представленной модели. Мы можем заметить небольшие изменения в обоих типах сердечных сокращений (N-класса и V-класса), особенно в V-классе, что подтверждает нашу предыдущую оценку, поскольку форма сердечных сокращений V-класса значительно отличается от формы сердечных сокращений N-класса.

4.2 СОКРАЩЕНИЕ ПАРАМЕТРОВ

Одна из наших целей — разработать вычислительно эффективную модель классификации сигналов ЭКГ. Для этой задачи мы настраиваем тест сравнения переменных. **Таблица 5** иллюстрирует сравнение № параметров предложенной модели и модели трансформера. Заметим, что число параметров для всей представленной модели на 17.79% меньше, чем для типовой конструкции трансформера, а его значение для 2-го уровня подхода на основе оптимизированной сети на 44% меньше, чем для SAU (это связано с использованием ОК). В результате наш метод дает отличный результат. Предлагаемая новая архитектура служит оптимизированной основой для будущих устройств классификации сигналов ЭКГ в реальном времени. Полученные результаты показывают потенциал преобразовательной

структуры для обработки сигналов ЭКГ. Представленная архитектура подхода устраняет недостатки экспоненциального роста параметров SAU и обеспечивает более высокую производительность, поскольку представленная модель использует иерархическую архитектуру; это серьезная проблема, поскольку данные синхронизации оказывают сильное влияние на ритм сердечных сокращений для данного сигнала ЭКГ.

4.3 СРАВНЕНИЕ ДОСТИЖЕНИЙ ПРЕДСТАВЛЕННОЙ МОДЕЛИ И ВРАЧЕЙ

В начале этого раздела важно отметить, что группа экспертов-кардиологов обсудила и единогласно отметила сердцебиения MIT-BIH-ARR-DB [36]. Мы считаем это "Основной истинной классификацией" (GTC) для сравнения достижений предлагаемой модели с достижениями врачей, специализирующихся в кардиологии. Данные тестирования сигналов ЭКГ были переданы в модель и предоставлены трем отдельным (с разными залами и разными рабочими местами [37,38]) врачам для диагностики сердечных сокращений. Чтобы обеспечить идентичность процедуры маркировки, всем врачам были даны конкретные указания по стилю обозначений переходов между сокращениями сердца, а затем рассчитывались F1-Score, PPV, SEN и ACC как для предложенной модели, так и для врачей. Чтобы определить эффективность врачей, решения как минимум двух врачей должны совпадать для диагностики сердцебиения. Результаты показаны в **Таблице 6**. Результаты показывают, что предложенная модель и врачи работают одинаково, но модель имеет небольшой прирост, особенно в обнаружении S-класса (4.77%); это могло быть связано со значительной аналогией в морфологии между классами N и S. Кроме того, близость результатов указывает на то, что предложенная система надежна в выявлении заболеваний сердца.

Таблица 5

Сравнение № параметров предложенной модели и модели трансформера.

Architecture	No. Parameters	Parameter Decrease (%)
Transformer model	3.26 M	17.79
Presented model	2.68 M	
Only SAU	0.1114 M	44
Only level 2 attention Based on the optimized network	0.0623 M	

Таблица 6

Сравнение достижений предлагаемой модели и результатов кардиологов

	N (%)			S (%)			V (%)			F (%)			Overall (%) ACC _o
	PPV	SEN	F1-Score	PPV	SEN	F1-Score	PPV	SEN	F1-Score	PPV	SEN	F1-Score	
Cardiologists	98.97	98.66	98.81	95.13	95.01	95.06	98.18	98.79	98.48	97.88	99.54	98.70	98.92
Our model	99.89	99.93	99.91	99.79	99.88	99.83	99.85	99.94	99.89	98.65	99.61	99.12	99.94

Таблица 7

Разделение сердечных сокращений для внутрибольничных условий

	N (%)			S (%)			V (%)			F (%)			Overall (%) ACCo
	PPV	SEN	F1-Score	PPV	SEN	F1-Score	PPV	SEN	F1-Score	PPV	SEN	F1-Score	
Presented model	99.90	99.95	99.92	98.87	97.04	97.94	99.85	99.95	99.99	99.93	99.97	99.95	99.96

Таблица 8

Результаты предлагаемой модели в условиях стационара

	N (%)			S (%)			V (%)			F (%)			Overall (%) ACCo
	PPV	SEN	F1-Score	PPV	SEN	F1-Score	PPV	SEN	F1-Score	PPV	SEN	F1-Score	
Presented model	99.90	99.95	99.92	98.87	97.04	97.94	99.85	99.95	99.99	99.93	99.97	99.95	99.96

Представленная модель может использоваться в условиях стационара и давать выдающиеся результаты. Распределение сердечных сокращений показано в Таблице 7, а результаты проиллюстрированы в Таблице 8. Эта схема менее надежна, реалистична и универсальна, чем интер-пациентская схема.

5. ЗАКЛЮЧЕНИЕ

В этом исследовании была представлена улучшенная, сквозная, мощная и эффективная в вычислительном отношении модель преобразователя для классификации заболеваний сердца с использованием сигналов ЭКГ, соответствующих стандартам ААМІ и межпациентному режиму. Представленная структура использует методы подхода. Уровень 1 подхода предполагает использование сети SE, которая отвечает за взвешивание функций LHSP, захватываемых CNN. Уровень 2 подхода включает замену САУ традиционной трансформенной схемы предлагаемой оптимизированной сетью. Оптимизированная сеть отвечает за взвешивание функций GH и включает в себя недорогой ОС. Результаты показали, что достижения представленной модели превосходят современные и сопоставимы с достижениями кардиологов. Будущим горизонтом этой работы является реализация предложенной модели с использованием FPGA.

ЛИТЕРАТУРА

1. Rasti-Meymandi A, Ghaffari A. A deep learning-based framework For ECG signal denoising based on stacked cardiac cycle tensor. *Biomedical Signal Processing and Control*, 2022, 71:103275.
2. Jovanović B, Milenković S, Pavlović M. VT/VF detection method based on ECG signal quality assessment. *Journal of Circuits, Systems and Computers*, 2018, 27(11):1850169.
3. Zhao T, Wang XA, Qiu C. An Early Warning of Atrial Fibrillation Based on Short-Time ECG Signals. *Journal of Healthcare Engineering*, 2022:2022.
4. Silva JHBD, Cortez PC, Jagatheesaperumal SK, de Albuquerque VHC. ECG Measurement Uncertainty Based on Monte Carlo Approach: An Effective Analysis for a Successful Cardiac Health Monitoring System. *Bioengineering*, 2023. 10(1):115.
5. Chandra S, Sharma A, Singh GK. Feature extraction of ECG signal. *Journal of Medical Engineering & Technology*, 2018, 42(4):306-316.
6. Sahoo S, Kanungo B, Behera S, Sabut S. Multiresolution wavelet transform based feature extraction and ECG classification to detect cardiac abnormalities. *Measurement*, 2017, 108:55-66.
7. Gupta V, Mittal M, Mittal V, Saxena NK. A critical review of feature extraction techniques for ECG signal analysis. *Journal of The Institution of Engineers (India): Series B*, 2021, 102(5):1049-1060.
8. Patro KK, Kumar PR. Effective feature extraction of ECG for biometric application. *Procedia computer science*, 2017, 115:296-306.
9. Ramesh GP, Kumar NM. Design of RZF antenna for ECG monitoring using IoT. *Multimedia Tools and Applications*, 2020, 79(5):4011-4026.
10. Gómez-Clapers J, Casanella R. A fast and easy-to-use ECG acquisition and heart rate monitoring system using a wireless steering wheel. *IEEE Sensors Journal*, 2011, 12(3):610-616.
11. Mondéjar-Guerra V, Novo J, Rouco J, Penedo MG, Ortega M. Heartbeat classification fusing temporal and morphological information of ECGs via ensemble of classifiers. *Biomedical Signal Processing and Control*, 2019, 47:41-48.
12. Abdulbaqi AS, Al-din S. Feature Extraction and Classification of ECG Signal Based on The Standard Extended Wavelet Transform Technique: Cardiology Based Telemedicine. *InIOP Conference Series: Materials Science and Engineering*, 2020, 928(3):032029. IOP Publishing.

13. Basu S, Khan YU. On the aspect of feature extraction and classification of the ECG signal. *In 2015 Communication, Control and Intelligent Systems (CCIS)*, 2015, pp. 190-193. IEEE.
14. Li H, Yuan D, Wang Y, Cui D, Cao L. Arrhythmia classification based on multi-domain feature extraction for an ECG recognition system. *Sensors*, 2016, 16(10):1744.
15. Xu SS, Mak MW, Cheung CC. Towards end-to-end ECG classification with raw signal extraction and deep neural networks. *IEEE journal of biomedical and health informatics*, 2018, 23(4):1574-1584.
16. Shaker AM, Tantawi M, Shedeed HA, Tolba MF. Generalization of convolutional neural networks for ECG classification using generative adversarial networks. *IEEE Access*, 2020, 8:35592-35605.
17. Wang T, Lu C, Sun Y, Yang M, Liu C, Ou C. Automatic ECG classification using continuous wavelet transform and convolutional neural network. *Entropy*, 2021, 23(1):119.
18. Singh S, Pandey SK, Pawar U, Janghel RR. Classification of ECG arrhythmia using recurrent neural networks. *Procedia computer science*, 2018, 132:1290-1297.
19. Saadatnejad S, Oveisi M, Hashemi M. LSTM-based ECG classification for continuous monitoring on personal wearable devices. *IEEE journal of biomedical and health informatics*, 2019, 24(2):515-523.
20. Cheng J, Zou Q, Zhao Y. ECG signal classification based on deep CNN and BiLSTM. *BMC medical informatics and decision making*, 2021, 21(1):1-2.
21. Zhang P, Cheng J, Zhao Y. Classification of ECG Signals Based on LSTM and CNN. *International Conference on Artificial Intelligence and Security*, 2020, pp. 278-289. Springer, Singapore.
22. Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez AN, Kaiser Ł, Polosukhin I. Attention is all you need. *Advances in neural information processing systems*, 2017:30.
23. Li B, Jing Y, Tan X, Xing Z, Xiao T, Zhu J. TranSFormer: Slow-Fast Transformer for Machine Translation. *arXiv preprint 2023*, arXiv:2305.16982.
24. Wu F, Fan A, Baevski A, Dauphin YN, Auli M. Pay less attention with lightweight and dynamic convolutions. *arXiv preprint 2019*, arXiv:1901.10430.
25. Pan J, Tompkins WJ. A real-time QRS detection algorithm. *IEEE transactions on biomedical engineering*, 1985:230-236.
26. Hu J, Shen L, Sun G. Squeeze-and-excitation networks. *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018, pp. 7132-7141.
27. <https://physionet.org/content/mitdb/1.0.0/>.
28. De Chazal P, O'Dwyer M, Reilly RB. Automatic classification of heartbeats using ECG morphology and heartbeat interval features. *IEEE transactions on biomedical engineering*, 2004, 51(7):1196-11206.
29. Chawla NV, Bowyer KW, Hall LO, Kegelmeyer WP. SMOTE: synthetic minority over-sampling technique. *Journal of artificial intelligence research*, 2002, 16:321-357.
30. Yang P, Wang D, Zhao WB, Fu LH, Du JL, Su H. Ensemble of kernel extreme learning machine based random forest classifiers for automatic heartbeat classification. *Biomedical Signal Processing and Control*, 2021, 63:102138.
31. Wang T, Lu C, Sun Y, Yang M, Liu C, Ou C. Automatic ECG Classification Using Continuous Wavelet Transform and Convolutional Neural Network. *Entropy*, 2021, 23(1):119.
32. Garcia G, Moreira G, Menotti D, Luz E. Inter-patient ECG heartbeat classification with temporal VCG optimized by PSO. *Scientific reports*, 2017, 7(1):1-1.
33. He J, Rong J, Sun L, Wang H, Zhang Y. An advanced two-step DNN-based framework for arrhythmia detection. *Advances in Knowledge Discovery and Data Mining*, 2020, 12085:12422.
34. Zhai X, Tin C. Automated ECG classification using dual heartbeat coupling based on convolutional neural network. *IEEE Access*, 2018, 6:27465-27472.
35. Li Y, Qian R, & Li K. Inter-patient arrhythmia classification with improved deep residual convolutional neural network. *Computer Methods and Programs in Biomedicine*, 2023, 214:106582.
36. <https://physionet.org/physiobank/database/html/mitdbdir/intro.htm>.
37. Baghdad Heart Disease Center, Baghdad Medical City Hospital, Baghdad, Iraq.
38. Ibn Al-Nafees Cardiology Hospital, Baghdad, Iraq.

Анас Фуад Ахмед

доцент

Университет Аль-Иракия, факультет электротехники
Аль-Адмия-Хайба Хатон, Багдад 6029, Ирак
E-mail: anas.ahmed@aliraqia.edu.iq

Халида С. Риджаб

PhD

Технологический ун-т, факультет электротехники
Аль-Вегада, Багдад 19006, Ирак
E-mail: khalida.s.rijab@uotechnology.edu.iq

Ахмед Талаал Камил

магистр

Университет Аль-Иракия, факультет
 компьютерной инженерии
Аль-Адмия-Хайба Хатон, Багдад 6029, Ирак
E-mail: ahmed.talal@aliraqia.edu.iq