



Международный журнал информационных технологий и энергоэффективности

Сайт журнала:

<http://www.openaccessscience.ru/index.php/ijcse/>



УДК 004.056.52

ОБЗОР СУЩЕСТВУЮЩИХ РЕШЕНИЙ НА ОСНОВЕ МЕТОДОВ МАШИННОГО И ГЛУБОКОГО ОБУЧЕНИЯ ДЛЯ ЗАДАЧ АУТЕНТИФИКАЦИИ ПРИ ПОМОЩИ ЭКГ-ПАТТЕРНОВ

¹ Сидоркин А.Д., ² Панчехин Н. И., ³ Десятов А. Г.

ФГБОУ ВО «Московский государственный технический университет имени Н. Э. Баумана, Москва, Россия (105005, Москва, ул. 2-я Бауманская, д.5, стр.1), e-mail: ¹ Sidorkin1556@gmail.ru, ² 000256789@yandex.ru, ³ Desyatov.a001@yandex.ru

Традиционные методы аутентификации, такие как пароли, токены, отпечатки пальцев сильно подвержены кражам и фальсификации. На замену им разрабатываются новые подходы. Одним из таких подходов является аутентификация при помощи паттернов сердцебиения. Электрическая активность сердца уникальна у каждого человека. Кроме того электрокардиограмму сложно подделать. Эти факты побуждают использовать ЭКГ в биометрических системах. Машинное и глубокое обучение являются наиболее эффективными методами для решения задач аутентификации по ЭКГ. В данной статье рассмотрены современные исследования, в которых применяется машинное и глубокое обучение. Аутентификация, инструментами которой являются эти два метода, включает в себя следующие основные стадии: сбор данных, их обработка, извлечение признаков, классификация. Описание стадий и используемых алгоритмов на каждой из них приведено в этой работе. По результатам литературного обзора сделаны выводы.

Ключевые слова: Аутентификация, ЭКГ, машинное обучение, глубокое обучение, фильтрация, извлечение признаков, классификация, биометрия.

OVERVIEW OF EXISTING SOLUTIONS BASED ON MACHINE AND DEEP LEARNING METHODS FOR AUTHENTICATION TASKS USING ECG PATTERNS

¹ Sidorkin A.D., ² Panchekhin N. I., ³ Desyatov A. G.

Moscow State Technical University named after N. E. Bauman, Moscow, Russia (105005, Moscow, 2nd Baumanskaya st., 5, building 1), e-mail: ¹ Sidorkin1556@gmail.ru, ² 000256789@yandex.ru, ³ Desyatov.a001@yandex.ru

Traditional authentication methods such as passwords, tokens, and fingerprints are highly susceptible to theft and falsification. New approaches are being developed to replace them. One of these approaches is authentication using heartbeat patterns. The electrical activity of the heart is unique for each person. In addition, an electrocardiogram is difficult to fake. These facts encourage the use of ECG in biometric systems. Machine learning and deep learning are the most effective methods for solving ECG authentication tasks. This article discusses modern research that uses machine learning and deep learning. Authentication, the tools of which are these two methods, includes the following main stages: data collection, processing, feature extraction, classification. A description of the stages and the algorithms used on each of them is given in this paper. Based on the results of the literary review, conclusions are drawn.

Keywords: Authentication, ECG, machine learning, deep learning, filtering, feature extraction, classification, biometrics.

Введение

Биометрические данные, а именно: изображения радужной оболочки глаза, лица или запись голоса, как методы аутентификации, имеют недостатки. Запись голоса нетрудно подделать, а, например, изображения лиц или радужной оболочки глаза, полученные видеокамерами, могут быть повреждены из-за угла наблюдения, а также освещения, разрешения камеры и других параметров. Поэтому рассматриваются новые методы аутентификации, такие как паттерны сердцебиения. В свою очередь, сигналы электрокардиограммы демонстрируют уникальные характеристики строения записи, которые трудно подделать, поскольку основные биометрические параметры скрыты во время аутентификации и могут быть получены только из физических измерений субъекта. С развитием технологий сбора данных появились портативные устройства для снятия электрической активности сердца, такие как смарт-часы Apple, Samsung и т.п. Это облегчает снятие электрокардиограммы для аутентификации.

Аутентификация по ЭКГ не исследована в полной мере. Предлагаемые для аутентификации алгоритмы часто разрабатываются на основе сигналов ЭКГ диагностического класса [1, 2]. Такие сигналы имеют относительно низкий уровень шума. Также на практике для аутентификации необходимо собрать несколько шаблонов электрокардиограммы: в спокойствии, во время физической активности и т.п. На основании изложенных фактов современные методы не могут быть легко адаптированы для практической аутентификации личности. Однако исследуемая область перспективна, и с каждым годом выходит множество работ, предлагаемые решения в которых становятся более точными и оптимизированными.

Стоит отметить, что для аутентификации перспективно использовать и другие биометрические сигналы, например, ЭЭГ или ФКГ, прежде всего из-за их уникального строения у каждого человека, а также из-за высокой трудности воссоздать их искусственно.

Биометрические системы, как правило, состоят из двух основных фаз: регистрация сигнала и фаза аутентификации. На этапе регистрации ЭКГ субъекта записывается для создания шаблона. Далее на этапе аутентификации снимается новое ЭКГ, которое сравнивается с шаблоном для определения разрешения на доступ. Наиболее эффективными инструментами такого сравнения являются модели машинного обучения и модели глубокого обучения. В данной статье приведен литературный обзор таких моделей.

Литературный обзор

1. Электрокардиограмма

Электрокардиограмма представляет собой запись биопотенциалов, связанных с сокращениями сердечной мышцы. Любая ЭКГ состоит из зубцов, сегментов и интервалов (рисунок 1), отражающих процесс небольших электрических изменений, которые являются следствием деполяризации сердечной мышцы с последующей реполяризацией во время каждого сердечного цикла.

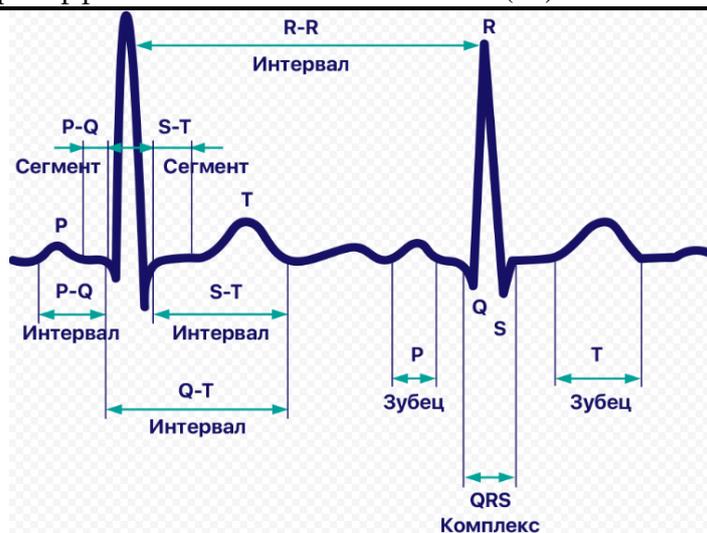


Рисунок 1 – Структурные элементы записи ЭКГ.

Строение записи ЭКГ сильно варьируется у людей из-за различий в размере и расположении сердца, возраста, пола и других факторов. Такая информация, как угол, амплитуда и частота сердечных сокращений, описывает уникальность человека.

2. Предварительная обработка данных

Как для подхода аутентификации по ЭКГ при помощи моделей машинного обучения, так и для подхода, в основе которого лежат модели нейронных сетей, свойственно наличие этапа предварительной обработки данных. Цель предварительной обработки – отделить требуемые биометрические признаки от фонового шума. Сигналы ЭКГ могут быть искажены различными видами шумов. Эти виды включают в себя дрейф изолинии из-за дыхания, возникающий шум из-за движения электродов, а также шумы, создаваемые электронными устройствами, которые используются при снятии ЭКГ. Эти компоненты должны быть удалены или уменьшены до выделения признаков и классификации, поскольку они могут повлиять на биометрическую информацию сигнала. В контексте ЭКГ рассматриваются высокочастотные и низкочастотные компоненты шума. Фильтры нижних частот способны удалять высокочастотный шум. Фильтры высоких частот наоборот.

Для фильтрации ЭКГ сигналов популярны вейвлет-преобразования. В работе [3] сравниваются вейвлеты Хаара и Добеши, а также фильтр нижних частот LPF. Результаты работы показывают, что вейвлет Добеши лучшим образом среди перечисленных сохраняет структурные элементы записи ЭКГ, отделяя ее от шума.

Кроме этого для удаления шума в ЭКГ записи используют фильтр Калмана, фильтр Винера, БИХ-фильтр Баттерворта [4, 5]. В [5] также используется Симлет вейвлет. Аргументируется это тем, что функция похожа на ЭКГ сигнал.

В качестве предварительной обработки во многих работах, например, [5], сегментируют сигналы ЭКГ на удары или интервалы различной продолжительности (например, 2 с и 5 с) перед извлечением признаков.

3. Модели машинного обучения

3.1. Извлечение признаков

Извлечение признаков из сигнала ЭКГ можно разделить на две категории: условно ручное и неручное. Условно ручное извлечение представляет собой интерактивный процесс, включающий ряд автоматических процедур преобразования данных. В свою очередь, условно ручное извлечение делится на нахождение реперных признаков, целостный анализ ЭКГ, гибридный метод. Последний метод является комбинацией первых двух.

Зубцы P, Q, R, S, T, разница во времени между пиками Q и T, а также интервал Q-T, например, считаются реперными признаками. Суть алгоритмов, основанных на таких признаках, состоит в точном обнаружении P, Q, R, S, T зубцов для получения их относительной амплитуды, характерных временных интервалов между ними и ряда других морфологических особенностей. В работах [6-7] использовались некоторые подмножества этих реперных признаков. Временные интервалы и амплитуда пиков каждого отдельного субъекта аутентификации индивидуальны. Однако точное обнаружение структурных элементов записи ЭКГ является очень сложной задачей, поскольку они очень чувствительны к шуму. Более того, алгоритмы, основанные на реперных признаках, не являются универсальными, поскольку у людей с заболеваниями сердца могут отсутствовать те или иные реперные точки, что приводит к значительным ошибкам. Поэтому условно ручное извлечение признаков на основе целостного анализа записи ЭКГ является более предпочтительным.

В основе целостного анализа записи ЭКГ лежит временной или частотный анализ для получения других статистических признаков. Распространенными инструментами для такого анализа являются вейвлет-преобразования [5, 8] и дискретное косинусное преобразование [9].

3.2. Классификация

Перед классификацией нередко производят уменьшение размерности выявленных признаков. Линейный дискриминантный анализ (LDA) [6], анализ главных компонент (PCA) [6] являются примерами методов уменьшения набора признаков для классификации.

Классификация – это основная составляющая аутентификации субъекта доступа по ЭКГ. Большинство алгоритмов машинного обучения в этой категории реализуют вычисления оценок соответствия на основе сходства и различия между вектором признаков запроса и шаблоном. Во время аутентификации полученная оценка сравнивается с предопределенным порогом. Если оценка сходства предъявленной записи ЭКГ с шаблоном выше некоторого порога, то доступ предоставляется. В современных работах используются различные алгоритмы, такие как метод опорных векторов (SVM) [9-10], наивный байесовский классификатор [11], деревья решений [11], лес решений [8], k-ближайших соседей [12].

Стоит отметить инкрементный метод обучения классификатора SVM [10], при котором сохраняется ранее обученная модель и эффективно обновляется по мере поступления дополнительных входных данных.

4. Модели глубокого обучения

Условно ручные подходы извлечения признаков включают дополнительный этап, а именно нахождение реперных точек или временной и (или) частотный анализ для получения ключевой информации. Нейронные сети способны извлекать признаки автоматически, что

позволяет обходить дополнительные этапы. Это повышает производительность, а также надежность биометрических систем. Надежность повышается в виду того, что при условно ручном извлечении признаков перед исследователями стоит задача оптимизации и правильного подбора механизмов извлечения, при необходимости уменьшения набора признаков. Правильно подобранный комплекс механизмов может хорошо работать на одном наборе данных ЭКГ, но это не означает, что он будет так же работать на другом отличном наборе. В свою очередь, условно ручное извлечение признаков из нескольких наборов данных или при наборе с разными отведениями ЭКГ делает метод еще более сложным.

Распространенными и эффективными моделями нейронных сетей для задачи аутентификации являются сверточная нейронная сеть CNN [1-2, 13-15] и тип рекуррентных нейронных сетей, способный обучаться долгосрочным зависимостям – нейронная сеть с долгой краткосрочной памятью LSTM [13, 16-17].

В работе [18] описываются две модели нейронных сетей, CNN и ResNet. ResNet представляет собой остаточную сеть. Идея заключается в том, чтобы взять несколько сверточных слоев и добавить к ним дополнительные связи, которые проходят мимо этих слоев, пропускают один или несколько слоев. Таким образом решается проблема затухающего градиента. В [18] передавали моделям сигналы ЭКГ без какой-либо обработки и фильтрации. При этом предложенные модели показали высокую точность на тестовых данных. Этот факт говорит о том, что обе модели показывают высокую производительность и хорошую способность к обобщению данных.

В [19] предложили модель BiGRU для задачи аутентификации по ЭКГ. BiGRU представляет собой двунаправленную LSTM с управляемыми рекуррентными блоками. Двунаправленная LSTM запускает входные данные как вперед, так и назад во времени, таким образом, сохраняя контекст как из будущего, так и из прошлого. Это позволяет повышать качество классификации. А управляемые рекуррентные блоки содержат меньше параметров, чем у LSTM, а значит обучать такую сеть можно быстрее. Точность классификации при этом у BiGRU сравнима с BiLSTM [19].

В [20] GRU вводится в сочетании с CNN. Извлечение признаков для классификации в обычной CNN происходит независимо в каждый момент времени. В CNN происходит пространственная корреляция признаков. GRU в сочетании с CNN позволяет лучше извлекать признаки из временного ряда записи ЭКГ. Использование такого сочетания повышает производительность и точность классификации.

В некоторых работах используются ранее обученные известные модели нейронных сетей. Так, например, в работе [14] используется сверточная нейронная сеть Inception, а в [21] используется сверточная нейронная сеть VGG-Net.

5. Результаты литературного обзора

В таблице 1 приведены результаты ранее проделанных работ. В таблице указывается название базы данных, проводили ли в работе фильтрацию, если да, то каким способом. Как выделялись признаки из ЭКГ записи, как происходила классификация, а также метрики для оценки предложенных решений. В Таблице 2 расшифрованы аббревиатуры, используемые в Таблице 1. В обзор вошли работы за последние 5 лет. При этом точность аутентификации

предлагаемых решений свыше 90%, то есть модели перспективно применимы к использованию в биометрических системах.

Таблица 1 – Обзор решений из литературных источников

Источник	Год	База данных	Фильтрация	Выделение признаков	Метод	Метрика
[17]	2017	ECG-ID MITDB	– –	LSTM GRU	LSTM GRU	Acc: 100%, EER: 0 Acc: 96%, EER: 3.5%
[8]	2017	MITDB NSRDB ECG-ID	BP BP BP	НПП/DWT НПП/DWT НПП/DWT	Random Forest Random Forest Random Forest	Acc: 98% Acc: 99% Acc: 91%
[7]	2017	РТВ	BW	НПП	SVM	Acc: 97.45%, FAR: 5.71%
[9]	2017	Частная БД	SG	DCT	SVM	Acc: 94.9%, EER: 2.66%
[6]	2017	Частная БД	–	НПП	LDA	Acc: 91.6%
[22]	2018	SIAT-ECG РТВ	BW BW	НПП НПП	SVM SVM	Acc: 93.15%, FAR: 11.58% Acc: 100%, FAR: 0
[25]	2018	ТЕОАЕ	BP	AC/LDA	SVM	EER: 6.9%
[28]	2018	MIT-BIH	WT	DBLSTM-WS	DBLSTM-WS	Acc: 99,39%
[21]	2019	РТВ СУВНi	– –	CNN VGG-Net CNN VGG-Net	QG-MSVM QG-MSVM	Acc: 96.83%, FAR: 3.1% Acc: 97.15%, EER: 2.8
[24]	2019	UofTDB СУВНi	– –	CNN CNN	CNN CNN	EER: 7.86% EER: 15.37%
[2]	2019	MWM-HIT	MD	CNN	CNN	Acc: 96.96%, EER: 4.86%

Продолжение Таблицы 1						
[14]	2019	PTB	–	CNN Inception	CNN Inception	Acc: 98.1%
[1]	2019	PTB	BW	CNN	CNN	EER: 2.9%
[15]	2019	PTB	BP	CNN	CNN	Acc: 98.45%
		MIT-BIH	BP	CNN	CNN	Acc: 99.2%
[26]	2019	ECG-ID	–	CNN	SVM	Acc: 98.24%
		MIT-BIH	–	CNN	SVM	Acc: 95.99%
[19]	2019	ECG-ID	BW	BiGRU	BiGRU	Acc: 98.6%
		MITDB	BW	BiGRU	BiGRU	Acc: 98.4%
[31]	2019	PTB	CWT	AlexNet	AlexNet	Acc: 92.50%
		PTB	CWT	GoogLeNet	GoogLeNet	Acc: 100%
[16]	2020	NSRDB	DF+MAF	BiLSTM	BiLSTM	Acc: 100%, F1-score: 1
		MITDB	DF+MAF	BiLSTM	BiLSTM	Acc: 99.8%, F1-score: 0.99
[27]	2020	NSRDB	BP	Cascaded CNN	Cascaded CNN	Acc: 91.4%
		FANTASIA	BP	Cascaded CNN	Cascaded CNN	Acc: 99.9%
[29]	2020	FANTASIA	MAF	TCNN	TCNN	Acc: 100%
		MIT-BIH	MAF	TCNN	TCNN	Acc: 96%
		CYBHi	MAF	TCNN	TCNN	Acc: 90%
[30]	2021	ECG-ID	–	HT/FT + PCANet	SVM	Acc: 99.44%
		MIT-BIH	–	HT/FT + PCANet	SVM	Acc: 99.66%
		PTB	–	HT/FT + PCANet	SVM	Acc: 99.77%
[18]	2021	CYBHi	–	CNN	CNN	Acc: 99.72%, EER: 0.27%
		CYBHi	–	ResNet-Attention	ResNet-Attention	Acc: 99.27%, EER: 0.68%

Продолжение Таблицы 1						
[20]	2021	MIT-BIH	WT	CNN-GRU	CNN-GRU	Acc: 99.61%, F1-score: 0.99
[10]	2021	MIT-BIH СУВНi	BP BP	НПП НПП	Инкрементный SVM	Acc: 97.7% Acc: 99.4%
[23]	2022	MIT-BIH + CinC_2017	WT	FRRNet	FRRNet	Acc: 98.97%, F1-score: 0.98
[32]	2022	AFDB NSRDB ECG-ID	BW BW BW	BERT BERT BERT	BERT BERT BERT	Acc: 96.2% Acc: 99.91% Acc: 96.35%
[33]	2022	MIT-BIH	BW	HBF	LS-SVM	Acc: 95%

Таблица 2 – Используемые сокращения

Сокращение	Расшифровка	Сокращение	Расшифровка
Acc	Accuracy	AC	Normalized Autocorrelation
BERT	Bidirectional Encoder Representations from Transformers	DBLSTM-WS	Deep Bidirectional LSTM network-based Wavelet Sequences
EER	Equal Error Rates	LS-SVM	Least Square Support Vector Machine
FAR	False Acceptance Rate	LDA	Linear Discriminant Analysis
CNN	Convolutional Neural Network	QG-MSVM	Q-Gaussian multi support vector machine
BP	Band Pass filter	MD	Median filter
DWT	Discrete Wavelet Transform	CWT	Continuous Wavelet Transform
LSTM	Long Short-Term Memory network	DF	Derivative Filter
GRU	Gated Recurrent Units	MAF	Moving average filter
WT	Wavelet Transform	TCNN	Temporal Convolutional Neural Network
НПП	Нахождение реперных признаков	PCANet	Principal Component Analysis Network

Продолжение Таблицы 2			
SVM	Support Vector Machine	FT	Fourier Transform
BW	Butterworth low-pass filter	HT	Hilbert Transform
SG	Savitzky-Golay filter	FFRNet	Feature Reuse Residual Network
DCT	Discrete Cosine Transform	HBF	Half-Band Filter

В работах, приведенных в таблице 1, используются разные базы данных. Кроме того берутся различные количества записей из этих баз. Некоторые наборы данных содержат только здоровые сигналы ЭКГ, некоторые с различными аритмиями. В некоторых работах используют только одно отведение ЭКГ, в других – несколько. Некоторые авторы используют в своих работах ЭКГ записи, снятые в покое, после физической активности и т.п. Некоторые – только ЭКГ диагностического класса. Исходя из вышеперечисленных фактов, нельзя перечислить решения из Таблицы 1, которые являются наиболее точными и производительными. Для однозначного превосходства одних алгоритмов над другими необходимы равные условия, а также необходимо определить значимость таким критериям, как оценочные метрики, скорость работы и способность адаптации под программное обеспечение. Однако на основе литературного обзора можно подчеркнуть следующие факты:

- 1) за последние годы в доминирующем количестве работ используют глубокое обучение, в частности для задачи аутентификации наиболее популярными являются сверточные нейронные сети;
- 2) модели, в основе которых лежат нейронные сети, характеризуются более высокой скоростью аутентификации, поскольку содержат в своей структуре меньше механизмов;
- 3) сочетание сверточных нейронных сетей для выделения признаков и моделей машинного обучения для классификации дает хорошие результаты;
- 4) алгоритмы, не использующие предварительную фильтрацию сигнала ЭКГ, показывают хорошие результаты. При этом такие алгоритмы имеют более высокую производительность, а также они более устойчивы к шуму;
- 5) полосовой фильтр, фильтр Баттерворта, а также вейвлет-преобразования являются популярными методами фильтрации сигнала ЭКГ;
- 6) в большинстве работ используют базы данных, содержащие сигналы ЭКГ диагностического класса. Эти сигналы сняты в медицинских учреждениях и содержат относительно низкий уровень фонового шума. Алгоритмы, обученные на таких сигналах, менее применимы в биометрических системах. В связи с этим остается актуальной задача сбора записей ЭКГ теми же методами, с помощью которых сигнал будет сниматься в биометрических системах. А также сбора записей ЭКГ в различных состояниях человека.

Заключение

В данной работе приведен литературный обзор методов машинного и глубокого обучения для задач аутентификации при помощи ЭКГ-паттернов. Приведены основные алгоритмы, которые используются в исследуемой теме, и результаты их применения. Описаны основные стадии аутентификации по ЭКГ при помощи нейронных сетей и машинного обучения. На основе литературного обзора сделаны выводы.

Список литературы

1. R. D. Labati, E. Muñoz, V. Piuri, R. Sassi, F. Scotti, Deep-ECG: Convolutional Neural Networks for ECG biometric recognition, *Pattern Recognition Letters*, Volume 126, 2019, Pages 78-85.
2. M. Hammad, S. Zhang, K. Wang, A novel two-dimensional ECG feature extraction and classification algorithm based on convolution neural network for human authentication, *FGCS*, Volume 101, 2019, Pages 180-196.
3. A. B. Patwary, M. T. I. Chowdhury and N. Mamun, Comparison Among ECG Filtering Methods for Non-linear Noise, *ICAEET*, 2018.
4. Manju B.R., Sneha M.R., ECG Denoising Using Wiener Filter and Kalman Filter, *Procedia Computer Science*, Volume 171, 2020, Pages 273-281.
5. M. Ingale, R. Cordeiro, S. Thentu, Y. Park and N. Karimian, ECG Biometric Authentication: A Comparative Analysis, *IEEE Access*, vol. 8, pp. 853-866, 2020.
6. V. Krasteva, I. Jekova, R. Abächerli, Biometric verification by cross- correlation analysis of 12-lead ECG patterns: Ranking of the most reliable peripheral and chest leads, *Electrocardiology*, vol. 50, pp. 847-854, 2017.
7. J. S. Paiva, D. Dias and J. P. S. Cunha, Beat-ID: Towards a computationally low-cost single heartbeat biometric identity check system based on electrocardiogram wave morphology, *PLoS ONE*, vol. 12, no 7, 2017.
8. Tan R., Perkowski M., Toward Improving Electrocardiogram (ECG) Biometric Verification using Mobile Sensors: A Two-Stage Classifier Approach. *Sensors*, vol. 17, pp. 410, 2017.
9. J. Pinto, J. Cardoso, A. Lourenço and C. Carreiras, "Towards a continuous biometric system based on ECG signals acquired on the steering wheel", *Sensors*, vol. 17, no. 10, pp. 2228, 2017.
10. Kim J., Yang G., Lee S., Kim K., Park C. Efficiently Updating ECG- Based Biometric Authentication Based on Incremental Learning. *Sensors*, vol. 21, no 5, pp. 1568, 2021
11. Ergin S., Uysal A.K., Gunal E.S., Gunal S., Gulmezoglu M.B. ECG based biometric authentication using ensemble of features; *Proceedings of the 9th CISTI*, Barcelona. 18–21 June 2014; pp. 1–6.
12. K. A. Sidek, I. Khalil and H. F. Jelinek, ECG biometric with abnormal cardiac conditions in remote monitoring system, *IEEE*, vol. 44, pp. 1498-1509, 2014.
13. Коннова Н.С., Сафина Д., Биометрическая аутентификация по ЭКГ на основе машинного обучения, *ИИТТ* 2020, № 48, С. 17 – 24.
14. P.L. Hong, J.Y. Hsiao, C.H. Chung, Y.M. Feng and S.C. Wu, ECG biometric recognition: Template-free approaches based on deep learning, *Proc. 41st Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. (EMBC)*, pp. 2633-2636, 2019.

15. J. S. Kim, S. H. Kim and S. B. Pan, Personal recognition using convolutional neural network with ECG coupling image, *J. Ambient Intell. Humanized Comput.*, pp. 1-10, 2019.
16. Kim B.H., Pyun J.Y., ECG Identification For Personal Authentication Using LSTM-Based Deep Recurrent Neural Networks. *Sensors*. 2020; 20(11):3069.
17. R. Salloum, C.C.J. Kuo, ECG-based biometrics using recurrent neural networks, *Proc. IEEE-ICASSP*, pp. 2062-2066, 2017.
18. Hammad M., Pławiak P., Wang K., Acharya U.R., ResNet-Attention model for human authentication using ECG signals. *Expert Syst.* 2021, 38, E12547.
19. Lynn H.M., Pan S.B., Kim P., A Deep Bidirectional GRU Network Model for Biometric Electrocardiogram Classification Based on Recurrent Neural Networks. *IEEE Access* 2019,7, 395–405.
20. Yao G., Mao X., Li N., Xu H., Xu X., Jiao Y., Ni J., Interpretation of Electrocardiogram Heartbeat by CNN and GRU. *Comput Math Methods Med.* Aug 29 2021:6534942.
21. M. Hammad, Y. Liu and K. Wang, Multimodal biometric authentication systems using convolution neural network based on different level fusion of ECG and fingerprint, *IEEE Access*, vol. 7, pp. 527-542, 2019.
22. J. Liu, L. Yin, C. He, B. Wen, X. Hong and Y. Li, A multiscale autoregressive model-based electrocardiogram identification method, *IEEE Access*, vol. 6, pp. 251-263, 2018.
23. Yang Z., Liu L., Li N., Tian J., ECG Identity Recognition Based on Feature Reuse Residual Network. *Processes*. 2022; 10(4): 676.
24. J. Pinto and S. J. Cardoso, A end-to-end convolutional neural network for ECG based biometric authentication, *IEEE-BTAS*, pp. 1-8, 2019.
25. M. Komeili, W. Louis, N. Armanfard and D. Hatzinakos, Feature selection for nonstationary data: Application to human recognition using medical biometrics, *IEEE Trans. Cybern.*, vol. 48, no. 5, pp. 1446-1459, 2018.
26. Y. Chu, H. Shen and K. Huang, ECG authentication method based on parallel multi-scale one-dimensional residual network with center and margin loss, *IEEE Access*, vol. 7, pp. 598-607, 2019.
27. Y. Li, Y. Pang, K. Wang and X. Li, Toward improving ECG biometric identification using cascaded convolutional neural networks, *Neurocomputing*, vol. 391, pp. 83-95, 2020.
28. Yildirim Ö. A novel wavelet sequence based on deep bidirectional LSTM network model for ECG signal classification. *Comput. Boil. Med.* 2018, 189–202.
29. Belo D., Bento N., Silva H., Fred A., ECG Biometrics Using Deep Learning and Relative Score Threshold Classification. *Sensors* 2020, 20, 4078.
30. Liu X., Si Y., Yang W., A Novel Two-Level Fusion Feature for Mixed ECG Identity Recognition. *Electronics* 2021, 10, 2052.
31. Byeon Y.H., Pan S.B., Kwak K.C., Intelligent Deep Models Based on Scalograms of Electrocardiogram Signals for Biometrics. *Sensors* 2019, 19, 935.
32. Chee K.J., Ramli D.A., Electrocardiogram Biometrics Using Transformer's Self-Attention Mechanism for Sequence Pair Feature Extractor and Flexible Enrollment Scope Identification. *Sensors*. 2022 Apr 30; 22(9):3446.

33. Majeed R.R., Alkhafaji S.K.D., ECG classification system based on multi-domain features approach coupled with least square support vector machine (LS-SVM). *Comput Methods Biomech Biomed Engin.* 2022 May 13, pp.1-8.

References

1. R. D. Labati, E. Muñoz, V. Piuri, R. Sassi, F. Scotti, Deep-ECG: Convolutional Neural Networks for ECG biometric recognition, *Pattern Recognition Letters*, Volume 126, 2019, Pages 78-85.
2. M. Hammad, S. Zhang, K. Wang, A novel two-dimensional ECG feature extraction and classification algorithm based on convolution neural network for human authentication, *FGCS*, Volume 101, 2019, Pages 180-196.
3. A. B. Patwary, M. T. I. Chowdhury and N. Mamun, Comparison Among ECG Filtering Methods for Non-linear Noise, *ICAEET*, 2018.
4. Manju B.R., Sneha M.R., ECG Denoising Using Wiener Filter and Kalman Filter, *Procedia Computer Science*, Volume 171, 2020, Pages 273-281.
5. M. Ingale, R. Cordeiro, S. Thentu, Y. Park and N. Karimian, ECG Biometric Authentication: A Comparative Analysis, *IEEE Access*, vol. 8, pp. 853-866, 2020.
6. V. Krasteva, I. Jekova, R. Abächerli, Biometric verification by cross- correlation analysis of 12-lead ECG patterns: Ranking of the most reliable peripheral and chest leads, *Electrocardiology*, vol. 50, pp. 847-854, 2017.
7. J. S. Paiva, D. Dias and J. P. S. Cunha, Beat-ID: Towards a computationally low-cost single heartbeat biometric identity check system based on electrocardiogram wave morphology, *PLoS ONE*, vol. 12, no 7, 2017.
8. Tan R., Perkowski M., Toward Improving Electrocardiogram (ECG) Biometric Verification using Mobile Sensors: A Two-Stage Classifier Approach. *Sensors*, vol. 17, pp. 410, 2017.
9. J. Pinto, J. Cardoso, A. Lourenço and C. Carreiras, "Towards a continuous biometric system based on ECG signals acquired on the steering wheel", *Sensors*, vol. 17, no. 10, pp. 2228, 2017.
10. Kim J., Yang G., Lee S., Kim K., Park C. Efficiently Updating ECG- Based Biometric Authentication Based on Incremental Learning. *Sensors*, vol. 21, no 5, pp. 1568, 2021
11. Ergin S., Uysal A.K., Gunal E.S., Gunal S., Gulmezoglu M.B. ECG based biometric authentication using ensemble of features; *Proceedings of the 9th CISTI*, Barcelona. 18–21 June 2014; pp. 1–6.
12. K. A. Sidek, I. Khalil and H. F. Jelinek, ECG biometric with abnormal cardiac conditions in remote monitoring system, *IEEE*, vol. 44, pp. 1498-1509, 2014.
13. Коннова Н.С., Сафина Д., Биометрическая аутентификация по ЭКГ на основе машинного обучения, *ИИТТ 2020*, № 48, С. 17 – 24.
14. P.L. Hong, J.Y. Hsiao, C.H. Chung, Y.M. Feng and S.C. Wu, ECG biometric recognition: Template-free approaches based on deep learning, *Proc. 41st Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. (EMBC)*, pp. 2633-2636, 2019.
15. J. S. Kim, S. H. Kim and S. B. Pan, Personal recognition using convolutional neural network with ECG coupling image, *J. Ambient Intell. Humanized Comput.*, pp. 1-10, 2019.

16. Kim B.H., Pyun J.Y., ECG Identification For Personal Authentication Using LSTM-Based Deep Recurrent Neural Networks. *Sensors*. 2020; 20(11):3069.
 17. R. Salloum, C.C.J. Kuo, ECG-based biometrics using recurrent neural networks, *Proc. IEEE-ICASSP*, pp. 2062-2066, 2017.
 18. Hammad M., Pławiak P., Wang K., Acharya U.R., ResNet-Attention model for human authentication using ECG signals. *Expert Syst.* 2021, 38, E12547.
 19. Lynn H.M., Pan S.B., Kim P., A Deep Bidirectional GRU Network Model for Biometric Electrocardiogram Classification Based on Recurrent Neural Networks. *IEEE Access* 2019,7, 395–405.
 20. Yao G., Mao X., Li N., Xu H., Xu X., Jiao Y., Ni J., Interpretation of Electrocardiogram Heartbeat by CNN and GRU. *Comput Math Methods Med.* Aug 29 2021:6534942.
 21. M. Hammad, Y. Liu and K. Wang, Multimodal biometric authentication systems using convolution neural network based on different level fusion of ECG and fingerprint, *IEEE Access*, vol. 7, pp. 527-542, 2019.
 22. J. Liu, L. Yin, C. He, B. Wen, X. Hong and Y. Li, A multiscale autoregressive model-based electrocardiogram identification method, *IEEE Access*, vol. 6, pp. 251-263, 2018.
 23. Yang Z., Liu L., Li N., Tian J., ECG Identity Recognition Based on Feature Reuse Residual Network. *Processes*. 2022; 10(4): 676.
 24. J. Pinto and S. J. Cardoso, A end-to-end convolutional neural network for ECG based biometric authentication, *IEEE-BTAS*, pp. 1-8, 2019.
 25. M. Komeili, W. Louis, N. Armanfard and D. Hatzinakos, Feature selection for nonstationary data: Application to human recognition using medical biometrics, *IEEE Trans. Cybern.*, vol. 48, no. 5, pp. 1446-1459, 2018.
 26. Y. Chu, H. Shen and K. Huang, ECG authentication method based on parallel multi-scale one-dimensional residual network with center and margin loss, *IEEE Access*, vol. 7, pp. 598-607, 2019.
 27. Y. Li, Y. Pang, K. Wang and X. Li, Toward improving ECG biometric identification using cascaded convolutional neural networks, *Neurocomputing*, vol. 391, pp. 83-95, 2020.
 28. Yildirim Ö. A novel wavelet sequence based on deep bidirectional LSTM network model for ECG signal classification. *Comput. Boil. Med.* 2018, 189–202.
 29. Belo D., Bento N., Silva H., Fred A., ECG Biometrics Using Deep Learning and Relative Score Threshold Classification. *Sensors* 2020, 20, 4078.
 30. Liu X., Si Y., Yang W., A Novel Two-Level Fusion Feature for Mixed ECG Identity Recognition. *Electronics* 2021, 10, 2052.
 31. Byeon Y.H., Pan S.B., Kwak K.C., Intelligent Deep Models Based on Scalograms of Electrocardiogram Signals for Biometrics. *Sensors* 2019, 19, 935.
 32. Chee K.J., Ramli D.A., Electrocardiogram Biometrics Using Transformer's Self-Attention Mechanism for Sequence Pair Feature Extractor and Flexible Enrollment Scope Identification. *Sensors*. 2022 Apr 30; 22(9):3446.
 33. Majeed R.R., Alkhafaji S.K.D., ECG classification system based on multi-domain features approach coupled with least square support vector machine (LS-SVM). *Comput Methods Biomech Biomed Engin.* 2022 May 13, pp.1-8.
-