

МЕТОД ПОВЫШЕНИЯ КАЧЕСТВА ИДЕНТИФИКАЦИИ ПОЛЬЗОВАТЕЛЕЙ ЭЛЕКТРОННЫХ СИСТЕМ НА ОСНОВЕ ИХ ЭКГ

METHOD OF INCREASING THE QUALITY OF IDENTIFICATION OF USERS OF ELECTRONIC SYSTEMS BASED ON IH ECG

**S. Blyagoz
D. Shtennikov**

Summary. The article is devoted to improving the accuracy of identification of users of electronic systems based on their electrocardiogram. In this work, an improved algorithm for the functioning of the developed prototype system for user identification based on ECG is used, which differs from the existing ones in the use of three signs of ECG signals. These include: cepstral coefficients, ZCR and entropy. Then they are combined into one input descriptor, which increases the speed of recognition. SVM and implementations of a neural network (multilayer perceptron) using the SciKit Learn and TensorFlow modules were considered as possible options for a decision model for classification. In this case, to improve the quality of the identifier, the result of the classification of all segments of the ECG recording is used.

Keywords: identification, ECG, cepstral coefficients, ZCR, entropy, SVM, neural network.

Блягоз Софиет Хазретовна

ФГАОУ ВО «Национальный исследовательский университет ИТМО»
sofa.2101@mail.ru

Штенников Дмитрий Геннадьевич

К.т.н., доцент, ФГАОУ ВО «Национальный исследовательский университет ИТМО»

Аннотация. Статья посвящена повышению точности идентификации пользователей электронных систем на основе их электрокардиограммы. В данной работе используется усовершенствованный алгоритм функционирования разработанного прототипа системы для идентификации пользователей на основе ЭКГ, отличающийся от существующих использованием трех признаков сигналов ЭКГ. К ним относятся: кепстральные коэффициенты, ZCR и энтропия. Далее происходит объединение их в один входной дескриптор, что повышает скорость распознавания. В качестве возможных вариантов решающей модели для классификации были рассмотрены SVM и реализации нейронной сети (многослойного перцептрона) средствами модулей SciKit Learn и TensorFlow. При этом для улучшения качества идентификатора используется результат классификации всех сегментов записи ЭКГ.

Ключевые слова: идентификация, ЭКГ, кепстральные коэффициенты, ZCR, энтропия, SVM, нейронная сеть.

Введение

В настоящее время отечественные и зарубежные исследователи сосредоточены на разработке новых видов систем биометрического распознавания, а именно, основанных физиологических характеристиках человека, таких как электрическая активность сердца (электрокардиограмма), мозга (электроэнцефалограмма) и скелетных мышц (электромиограмма) [1]. В частности, электрокардиограмма видится подходящим методом для приложений, требующих защиты средней степени, в связи с простотой получения сигнала и его дешевизной, а также сложностью подделки и недобровольного извлечения [2].

Целью данной работы является создание программного продукта для идентификации человека по записи сигнала его электрокардиограммы (далее — ЭКГ).

В связи с поставленной целью требуется выполнить следующие задачи:

1. Разработать структурную схему и алгоритм функционирования прототипа системы идентификации пользователей на основе ЭКГ.
2. Выбрать средства реализации прототипа системы.
3. Описать процедуры сборки и подготовки датасета.
4. Исследовать варианты и выбрать решающую модель.



Рис. 1. Архитектура системы для идентификации пользователей

5. Провести комплексное тестирование и оценку точности решающей модели.

Реализация метода идентификации пользователей на основе ЭКГ

Архитектура прототипа системы для идентификации пользователей на основе ЭКГ представлена на рисунке 1.

На рисунке 2 представлена блок-схема алгоритма функционирования системы для идентификации пользователей на основе ЭКГ.

Разрабатываемая система функционирует по трем основным этапам:

1. Этап разбиения указанной записи ЭКГ на сегменты.

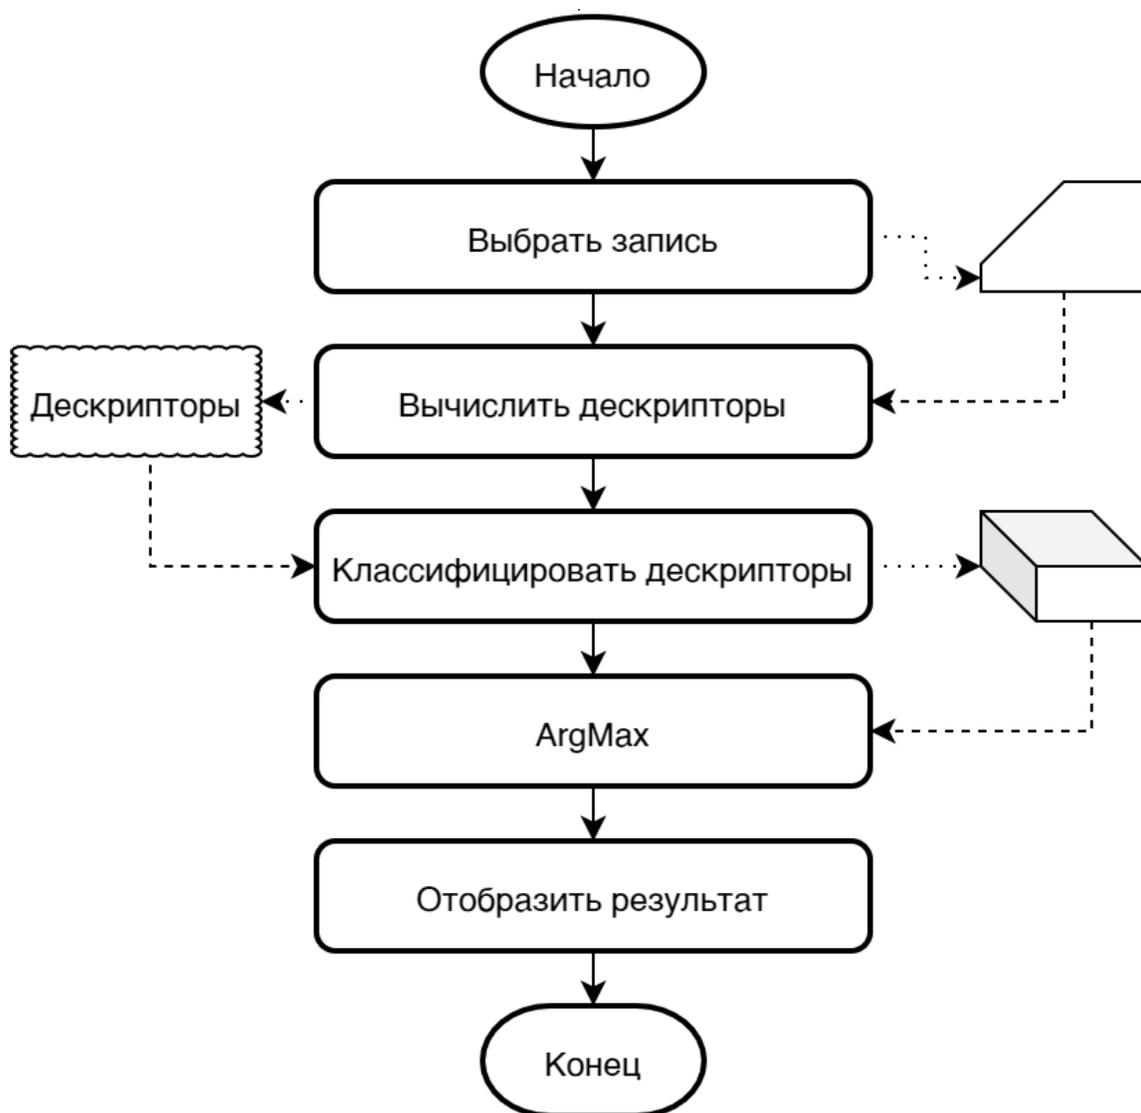


Рис. 2. Блок-схема алгоритма функционирования системы для идентификации пользователей на основе ЭКГ

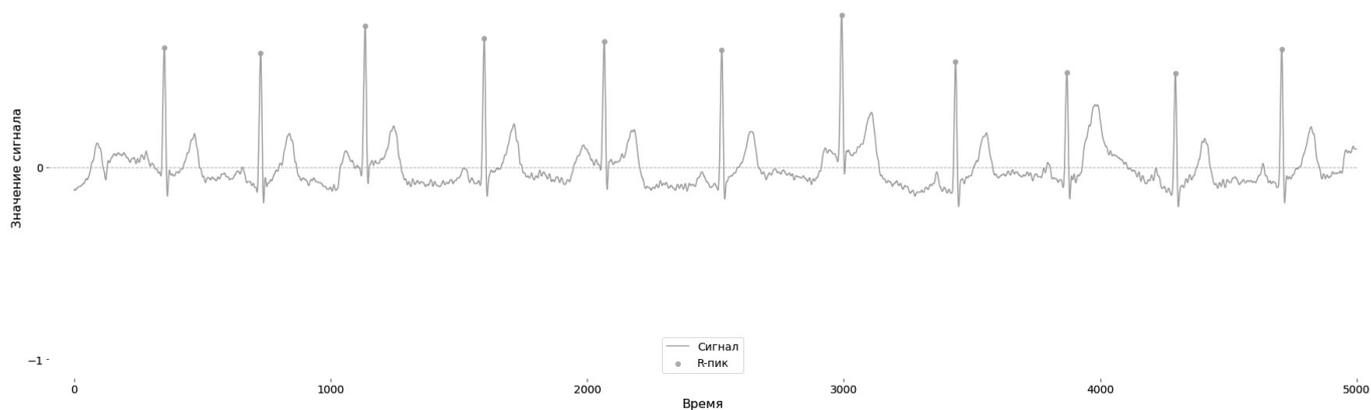


Рис. 3. Временной ряд сигнала ЭКГ с отмеченными R-пиками

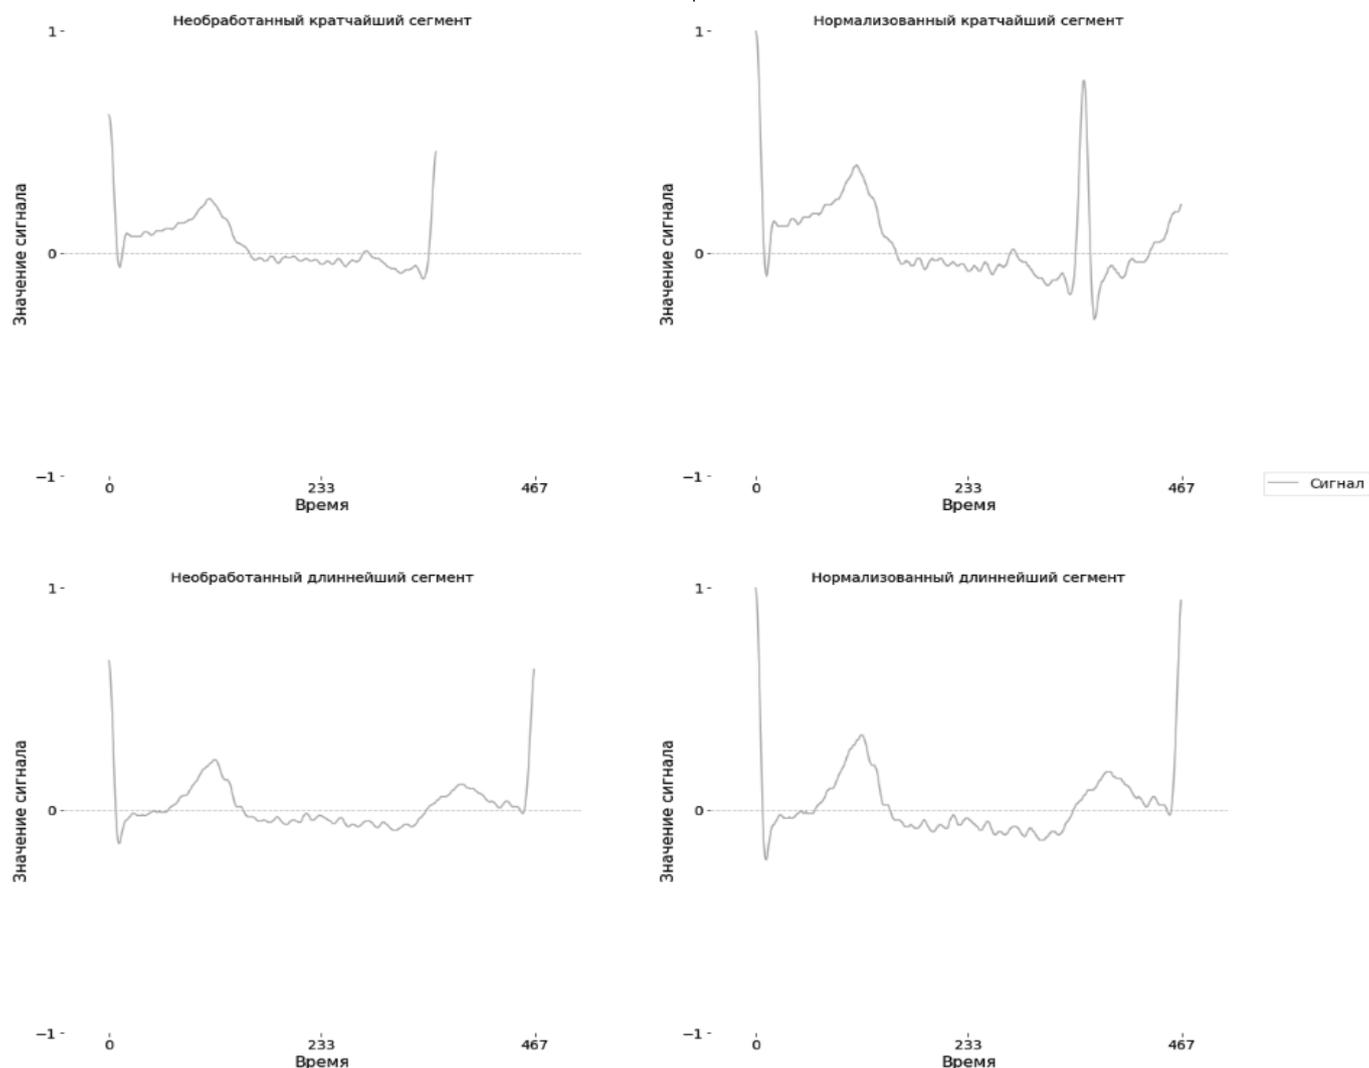


Рис. 4. Нормализация сегментов

2. Этап выявления признаков из полученных сегментов.
3. Этап классификации набора признаков.

В качестве датасета взята база данных ECG-ID, содержащая записи ЭКГ 90 пациентов, полученные в разные моменты времени [3].

Использование записи целиком нерационально, поэтому требуется разбить запись на сегменты. Каждый сегмент представляет собой срез сигнала между двумя соседними R-пиками. R-пик же представляет собой высшую точку импульса сердечного сокращения. Используя модуль BioSPPy [4] находим индексы массива сигналов, в которых находятся R-пики (рисунок 3).

Для того, чтобы получить сегменты, возьмем срез записи между каждыми двумя соседними R-пиками.

Так как сегменты имеют разную длину, предлагается уравнивать длины сегментов по максимальной длине среди всех сегментов, а также нормализовать значения сигнала внутри каждого сегмента следующим образом (рисунок 4).

Для сокращения количества данных, выделим следующие признаки для каждого сегмента:

1. Кепстральные коэффициенты.
2. ZCR.
3. Энтропия.

Для получения кепстральных коэффициентов используем алгоритм поиска MFCC — Мел-частотных кепстральных коэффициентов. Сигнал преобразуется с помощью быстрого преобразования Фурье (FFT), от него вычисляется логарифм, который преобразуется с помощью обратного преобразования Фурье (IFFT). После это-

Таблица 1. Пример дескриптора

Кепстральные коэффициенты	ZCR	Энтропия
-16.20 3.69 0.57-0.85 0.02 0.87 0.67 0.05-0.13 0.19 0.28 0.06	11	1.551

Таблица 2. Правильность обученных моделей SVM

Ядро	Правильность, %
Линейное	45.29
Полиномиальное	41.42
RBF	38.94
Сигмоидальное	7.31

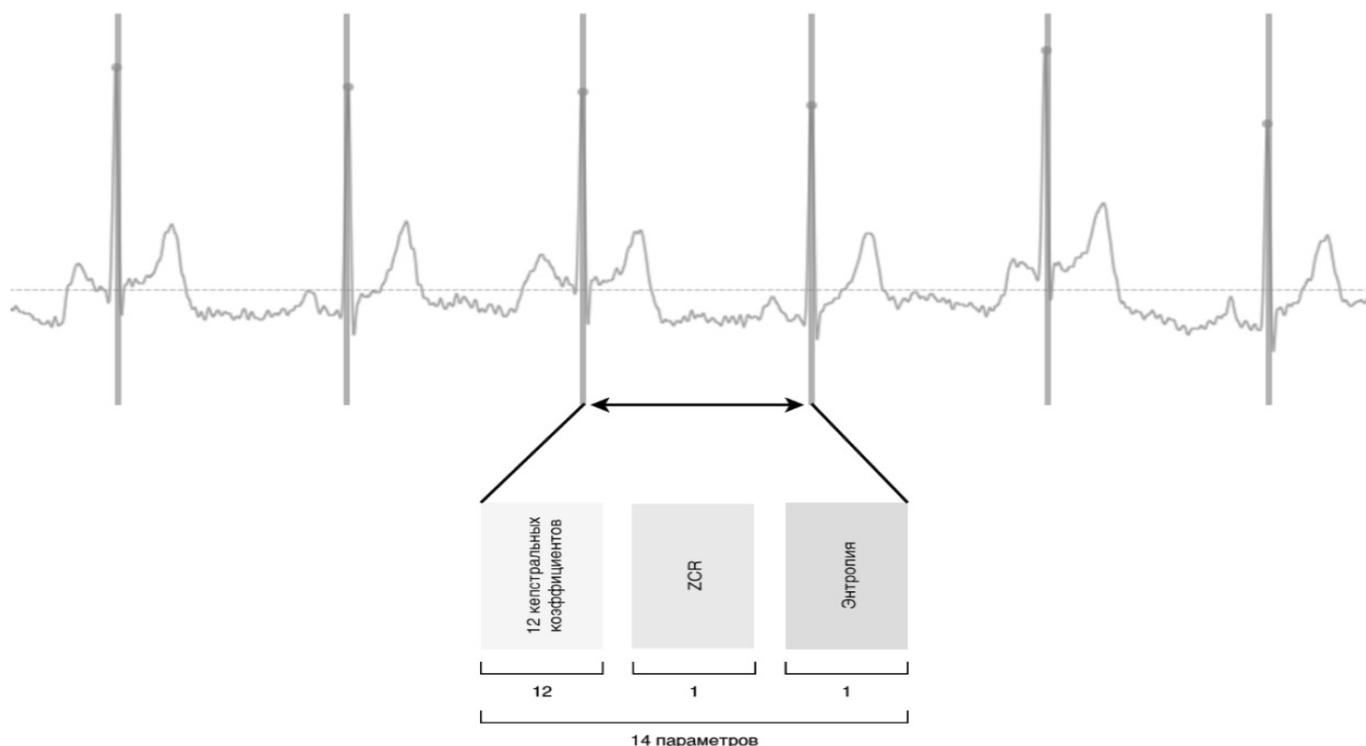


Рис. 5. Структура дескриптора

го полученное значение преобразовывается с помощью прямого косинусового преобразования (DCT).

Для задач классификации обычно достаточно 12–20 кепстральных коэффициентов. В данной работе ограничимся 12-ю.

ZCR (англ. Zero-Crossing Rate — частота пересечения нуля) — признак, обозначающий количество раз, в кото-

рых сигнал переходит базовую линию (в нашем случае = 0) [5].

Объединение признаков. Все полученные признаки объединяем в один общий дескриптор сегмента (рисунок 5). Он содержит 14 значений:

- ◆ 12 кепстральных коэффициентов
- ◆ 1 значение ZCR
- ◆ 1 значение энтропии.

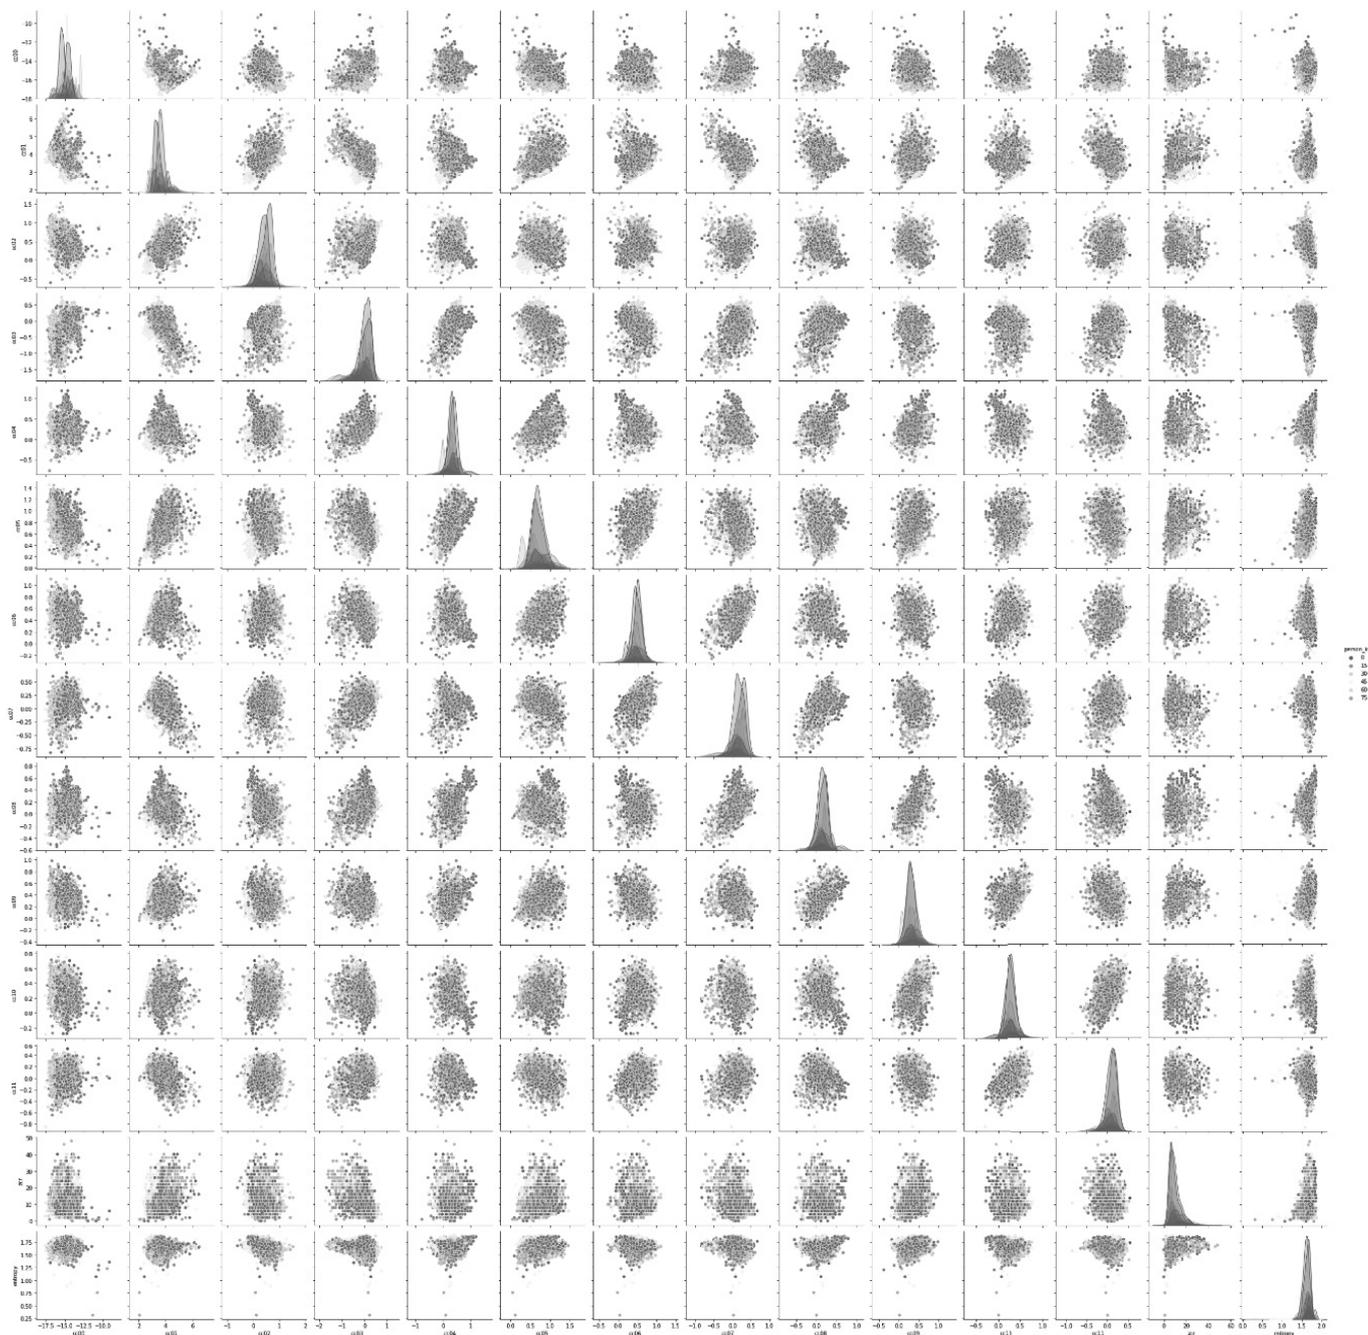


Рис. 6. Матрица корреляции пар компонентов дескрипторов

Для решения задачи классификации человека необходима решающая модель. В качестве возможных методов были рассмотрены SVM и реализации нейронной сети (многослойного перцептрона) средствами модулей SciKit Learn и TensorFlow.

SVM

Метод опорных векторов довольно часто используется для в качестве решающей модели [6]. Используя

класс SVC модуля SciKit Learn, составим решающие модели для этих четырех функций ядра. Проведем обучение моделей на 10 000 итерациях и оценим их правильность методом кросс-валидации.

В результате оценки были получены следующие результаты (таблица 2).

Как видно из данных таблицы 2, правильность моделей SVM слишком низкая, при этом основной причи-

Таблица 3. Архитектура нейронной сети

Слой	Выходная размерность	Количество параметров
Распрямление	(_,14)	0
Полносвязный 1	(_,64)	960
Полносвязный 2	(_,256)	16640
Полносвязный 3	(_,64)	16448
Классификатор	(_,90)	5850

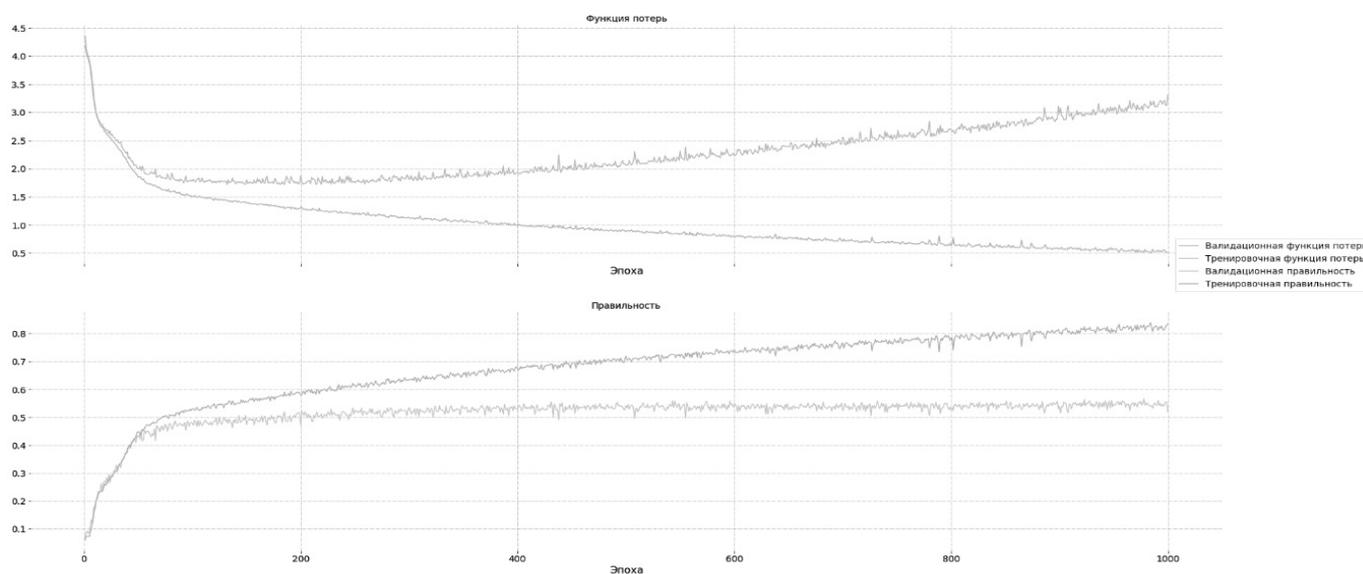


Рис. 7. Лог обучения

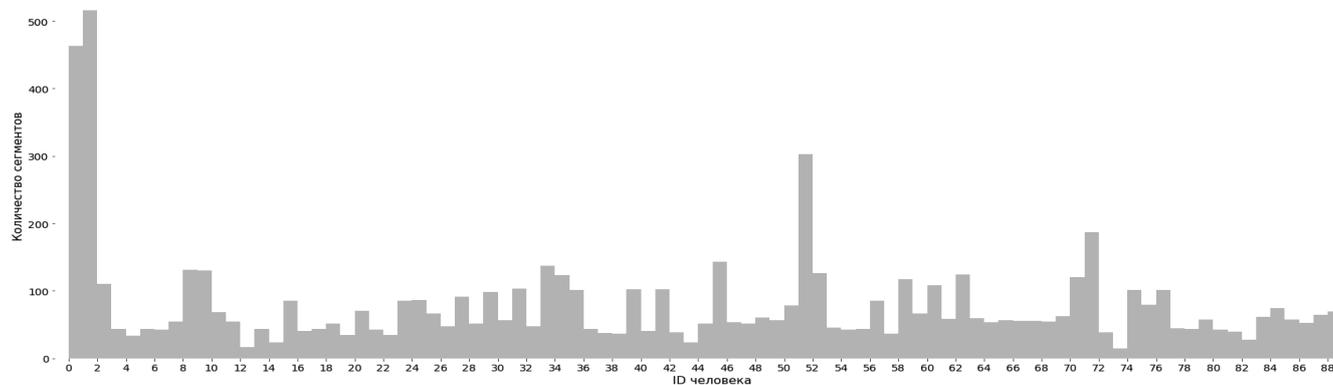


Рис. 8. Распределение количества сегментов по людям

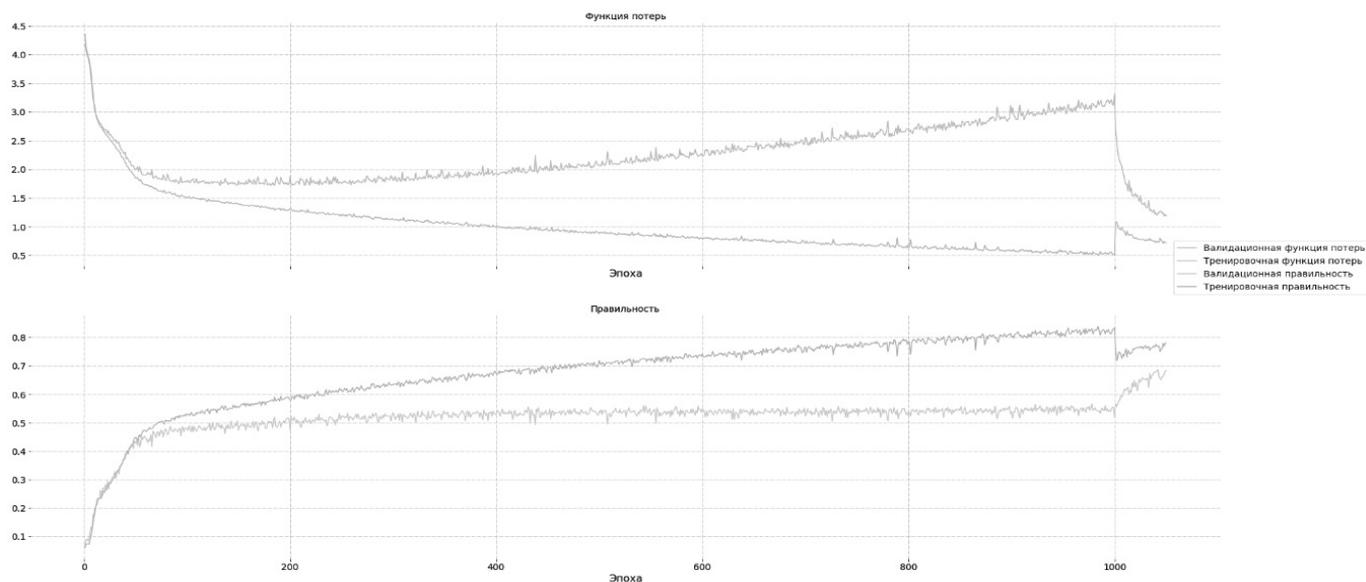


Рис. 9. Лог обучения после второй фазы обучения

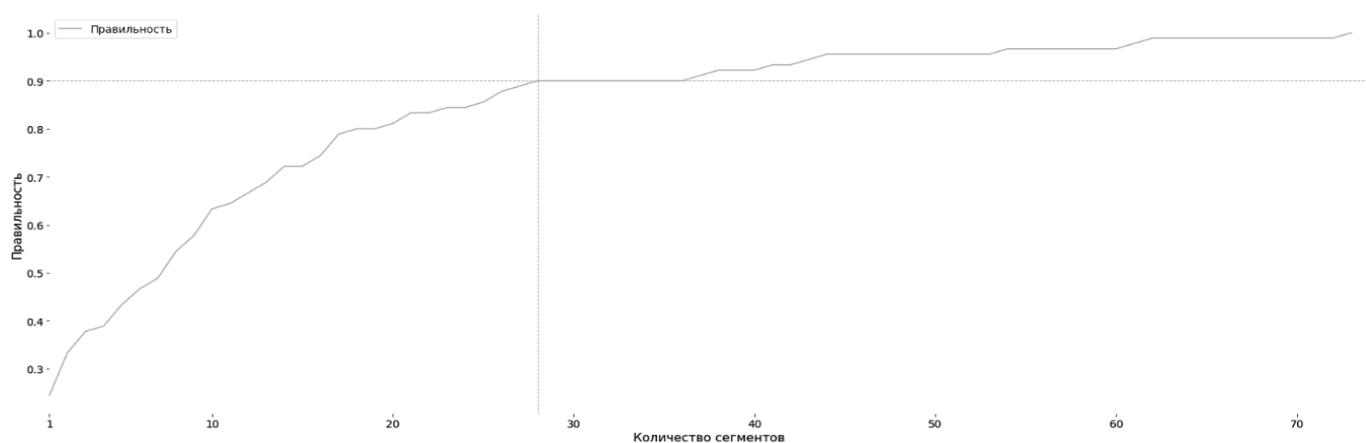


Рис. 10. Зависимость правильности идентификатора от количества сегментов

ной является высокая кучность данных. Кепстральные коэффициенты сегментов разных людей схожи и не позволяют моделям SVM подобрать подходящие параметры гиперплоскостей, успешно разбивающих данные на классы (рисунок б).

Нейросеть SciKit Learn

Попытаемся улучшить правильность модели, используя нейронную сеть вместо SVM. Для этого воспользуемся классом MLPClassifier модуля SciKit Learn. Модель будет состоять из трех полносвязных слоев с 64, 256 и 64 нейронами. Последним слоем нейросети будет еще один полносвязный слой с количеством нейронов,

равным количеству классов. Обучим модель на 1000 итерациях и оценим с помощью метода кросс-валидации.

В результате правильность модели составила 43.89%. Такой результат не превосходит максимальной правильности, полученной с помощью модели SVM.

Нейросеть TensorFlow

Создадим собственную нейронную сеть с помощью модуля Keras пакета TensorFlow. Архитектура модели будет такой же, как и в предыдущей нейронной сети (таблица 3).

Общее количество обучаемых параметров = 39.898.

В качестве функции активации после каждого полносвязного слоя используем ReLU. Для последнего полносвязного слоя функцией активации используем SoftMax. Обучим модель на 1000 итерациях, улучшая валидационную правильность оптимизатором Adam. В качестве функции потерь используем категориальную кросс-энтропию [7].

На графике обучения, представленном на рисунке 7 можно заметить, что тренировочные показатели со временем становятся гораздо лучше валидационных — имеет место переобучение. Однако, веса модели сохраняются лишь для эпохи с максимальной валидационной правильностью.

Правильность модели составила 56.67%, что уже лучше любой из предыдущих моделей, но все еще не является приемлемым результатом.

Разбиение данных на тренировочную и валидационную выборку ухудшает качество модели. Изначально данные в датасете распределены неравномерно. Так, для некоторых людей количество сегментов ЭКГ не доходит до 50, в то время как для некоторых людей их количество превышает 300. Данная особенность используемого датасета представлена на рисунке 8.

Хорошей практикой является обучение модели на тренировочной выборке (возможность добраться до необходимых экстремумов) с ее последующим дообучением на всех данных (добавление данных для финальной подстройки весов) [8]. Дообучим модель на 50 итерациях с использованием всех данных (рисунок 9). После второй фазы обучения правильность модели составила 68.58%.

Повышение качества

На предыдущем шаге получена модель нейросети, способная классифицировать отдельные сегменты. Чтобы улучшить качество идентификатора, используем результат классификации всех сегментов записи.

Результатом работы идентификатора будет класс, имеющий наибольшую частоту присутствия в массиве ответов модели. Для определения уверенности (confidence) модели в результате, посчитаем процент присутствия результирующего класса в массиве ответов (рисунок 10).

Исходя из графика выше, для достижения правильности результата в 90% достаточно ~30 сегментов, что при средней частоте сердечных сокращений (80 уд/мин) соответствует ~22.5 секундам записи ЭКГ.

Заключение

По итогам выполнения исследований в работе можно сделать следующие выводы:

1. Система для идентификации пользователей на основе ЭКГ функционирует по трем основным этапам, включающим в себя этап разбиения указанной записи ЭКГ на сегменты (проводятся процедуры фильтрации, сегментации и определения R пиков), этап выявления признаков из полученных сегментов (процедуры определения кепстральных коэффициентов, ZCR и энтропии, а также их объединение) и этап классификации набора признаков [9].
2. В качестве датасета взята база данных ECG-ID, содержащая записи ЭКГ 90 пациентов, полученные в разные моменты времени. Данная база данных содержит несколько записей ЭКГ для каждого пациента, полученные в разные моменты времени. Проведены процедуры очистки и фильтрации записей, разбиения записи на сегменты, а также выделение признаков из сегмента. Все полученные признаки объединяются в один общий дескриптор сегмента, содержащий 14 значений: 12 кепстральных коэффициентов, одно значение ZCR и одно значение энтропии.
3. Для модели SVM [10] использовались четыре различные функции ядра (линейная, полиномиальная, RBF и сигмоидальная), правильность составила от 7.31% (для сигмоидальной) до 45.29% (для линейной). Можно отметить, что правильность моделей SVM слишком низкая, при этом основной причиной является высокая кучность данных. Кепстральные коэффициенты сегментов разных людей схожи и не позволяют моделям SVM подобрать подходящие параметры гиперплоскостей, успешно разбивающих данные на классы.
4. Решающая модель на базе многослойного перцептрона модуля SciKit Learn состоит из трех полносвязных слоев с 64, 256 и 64 нейронами. Последним слоем нейросети является еще один полносвязный слой с количеством нейронов, равным количеству классов. Модель была обучена на 1000 итерациях, правильность составила 43.89%.
5. Для решающей модели на базе многослойного перцептрона модуля TensorFlow используются те же параметры, что и для модели на базе SciKit Learn. В качестве функции активации после каждого полносвязного слоя используется ReLU. Для последнего полносвязного слоя функцией активации используется SoftMax. Модель была обучена на 1000 итерациях, правильность — 56.67%.
6. Модель нейросети TensorFlow способна классифицировать отдельные сегменты. Чтобы улуч-

шить качество идентификатора, используется результат классификации всех сегментов записи. Результатом работы идентификатора будет класс, имеющий наибольшую частоту присутствия в массиве ответов модели. Для определения уверенности модели в результате, посчитан

процент присутствия результирующего класса в массиве ответов. Для достижения правильности результата в 90% достаточно ~30 сегментов, что при средней частоте сердечных сокращений (80 уд/мин) соответствует ~22.5 секундам записи ЭКГ.

ЛИТЕРАТУРА

1. Астапов А.А., Д.В. Давыдов, А.И. Егоров, Д.В. Дроздов, Е.М. Глуховский Биометрическая идентификация, основанная на ЭКГ: некоторые современные подходы // Вестник РГМУ. 2016. № 1.
2. Богданов М.Р. и др. Идентификация личности, основанная на распознавании электрокардиограмм // Information Technologies for Intelligent Decision Making Support (ITIDS'2016). — 2016. — С. 41–45.
3. Немирко А.П., Луговая Т.С. Биометрическая идентификация личности по электрокардиограмме // Математические методы распознавания образов. — 2005. — Т. 12. — № 1. — С. 387–390.
4. Бенгфорт Б. Прикладной анализ текстовых данных на Python. Машинное обучение и создание приложений обработки естественного языка / Б. Бенгфорт // СПб.: Питер, 2019. — 368 с.
5. Mahapatra S. et al. A Neuro-fuzzy based model for analysis of an ECG signal using Wavelet Packet Tree // Procedia Computer Science. — 2016. — Т. 92. — С. 175–180.
6. Rezgui D., Lachiri Z. ECG biometric recognition using SVM-based approach // IEEJ Transactions on Electrical and Electronic Engineering. — 2016. — Т. 11. — С. 94–100.
7. Patro K.K., Kumar P.R. Machine learning classification approaches for biometric recognition system using ECG signals // Journal of Engineering Science & Technology Review. — 2017. — Т. 10. — № 6.
8. Wang D. et al. A novel heart rate robust method for short-term electrocardiogram biometric identification // Applied Sciences. — 2019. — Т. 9. — № 1. — С. 201.
9. Şahin I., Özkan K., Ergin S. Biometric person authentication framework using polynomial curve fitting-based ECG feature extraction // Turkish Journal of Electrical Engineering and Computer Science. — 2019. — Т. 27. — № 5. — С. 3682–3698.
10. Wang D. et al. A novel electrocardiogram biometric identification method based on temporal-frequency autoencoding // Electronics. — 2019. — Т. 8. — № 6. — С. 667.