

УДК 004.89, 537.87

**МЕТОДИКА ДИАГНОСТИКИ ЭКГ-СИГНАЛОВ НА ОСНОВЕ ДИФРАКЦИОННОГО  
ДЕСКРИПТОРА И ТЕХНОЛОГИЙ ГЛУБОКОГО ОБУЧЕНИЯ**

**Мигель А. С., Малый С. В., Черепанова Ю. В.**

*Белорусский государственный университет  
Минск, Республика Беларусь*

**Аннотация.** Предложена методика классификации ЭКГ-сигналов на основе спектра пространственных гармоник, образованных в результате рассеяния плоской электромагнитной волны на периодической решетке, профиль которой совпадает с репрезентативным комплексом электрокардиограммы для одного или нескольких стандартных отведений, и технологий глубокого обучения. Приведена оценка точности предложенной диагностической системы.

**Ключевые слова:** электрокардиограмма, дифракционный дескриптор, нейронная сеть, классификация.

**ECG SIGNAL DIAGNOSIS TECHNIQUE BASED ON DIFFRACTION DESCRIPTOR AND DEEP  
LEARNING TECHNOLOGIES**

**Migel A., Maly S., Cherepanova Y.**

*BelaRussian Federation State University  
Minsk, Republic of Belarus*

**Abstract.** A technique of ECG-signals classification based on the spectrum of spatial harmonics formed as a result of scattering of a plane electromagnetic wave on a periodic grating, the profile of which coincides with a representative electrocardiogram complex for one or several standard leads, and deep learning technologies is proposed. The accuracy of the proposed diagnostic system is evaluated.

**Key words:** electrocardiogram, diffraction descriptor, neural network, classification.

*Адрес для переписки: Мигель А. С., пр. Независимости, 4, Минск 220030, Республика Беларусь  
e-mail: MihelAS@bsu.by*

Разработка систем диагностики состояния сердечно-сосудистой системы является одной из актуальных проблем медицинского приборостроения.

Электрокардиография является важным и информативным методом неинвазивной диагностики. Анализ ЭКГ-сигналов позволяет получить информацию о состоянии сердечно-сосудистой системы человека. Широко используемая на практике ручная технология обработки ЭКГ-сигналов требует существенных временных затрат и зависит от квалификации врача. Поэтому разработка автоматизированных диагностических систем является важной и актуальной задачей.

Одним из перспективных направлений автоматизированного анализа и классификации ЭКГ-сигналов является использование технологии глубокого обучения искусственных нейронных сетей [1]. В качестве входной информации в таких системах используются ЭКГ-сигналы в графическом или оцифрованном виде. Эффективность обучения нейронных систем и точность диагностики зависит от выбора информационных признаков, характеризующих ЭКГ-сигналы.

В работе [2] предложен оригинальный подход к анализу ЭКГ-сигналов, основанный на использовании в качестве информационных параметров сигнала вектор (дифракционный дескриптор), состоящий из амплитуд распространяющихся гармоник, образованных при дифракции плоской электромагнитной волны на металлической периодической решетке, профиль периода которой совпадает с репрезентативным комплексом ЭКГ-сигнала.

Представляет интерес разработка автоматической диагностической системы на основе дифракционных дескрипторов и технологий глубокого обучения.

В качестве модели системы рассматривалась полносвязная нейронная сеть, ориентированная на разделение ЭКГ-сигналов на два класса: «Норма» или «Нарушение».

Нейронная сеть имела следующую архитектуру: входной слой; полносвязный слой (64 нейрона); dropout слой ( $p = 0,5$ ); полносвязный слой (128 нейрона); dropout слой ( $p = 0,5$ ); полносвязный слой (64 нейрона); dropout слой ( $p = 0,5$ ); выходной слой. В качестве функции активации использовалась «ReLU», а для выходного слоя – «Sigmoid». Метод оптимизации – «Adam». Функция потерь – бинарная кроссэнтропия.

На вход сети поступало 4 дифракционных дескриптора, соответствующих 4 отведениям ЭКГ-сигнала: II, AVF, V1 и V5.

Размерность выходного слоя равнялась единице: 0 – соответствовало «Норма», а 1 – «Нарушение».

Объем выборки данных, на которых проводилось обучение сети, составлял 24 800 объектов, причем 80 % этих данных использовалось для обучения, а 20 % – для оценки качества обучения сети. Нейронная сеть обучалась на протяжении 50 эпох.

Формирование набора данных для обучения, содержащего дифракционные дескрипторы, включало два этапа:

1. Формирование периодов решеток: обработка ЭКГ-сигналов и формирование

усредненных кардиоциклов. ЭКГ-сигналы загружались из открытых наборов данных электрокардиограмм, представленных в 12 отведениях [3–6].

2. Расчет дифракционных дескрипторов методом конечных элементов. Рассматривалась задача дифракции плоской электромагнитной волны ТЕ-поляризации на периодической решетке, профиль которой совпадает с ЭКГ-сигналом. Отношение периода решетки к длине волны равнялось  $d/\lambda = 3$ , а отношение высоты элементов решетки к длине волны  $h/\lambda = 1,5$ .

Для выбранных волновых размеров решетки и направления распространения падающей электромагнитной волны дифракционный дескриптор для каждого отведения включал в себя амплитуды распространяющихся пространственных гармоник 0-го,  $\pm 1$  и  $\pm 2$  порядков. В общем, для повышения чувствительности дифракционного дескриптора к особенностям ЭКГ-сигнала можно варьировать волновые размеры периода и режим возбуждения решетки, изменяя при этом количество элементов дескриптора.

На рисунке 1 представлены примеры периодов решеток, профили которых образованы из ЭКГ-сигналов II отведения.




Рисунок 1 – Периоды решеток, соответствующие «Норме» (а) и «Нарушению» (б)

На рисунке 2 представлены дифракционные дескрипторы сигналов, периоды которых представлены на рисунке 1.




Рисунок 2 – Дифракционные дескрипторы

В результате тестирования обученной нейронной сети получена оценка точности классификации 85 %.

К преимуществам предлагаемой технологии классификации следует отнести:

- системный подход к анализу информации, содержащейся в ЭКГ-сигналах всех или заданного набора отведений;
- радикальное уменьшение объема входной информации, на основе дифракционных дескрипторов, для обучения нейронных сетей.

Точность классификации может быть повышена за счет увеличения объема обучающей выборки, оптимизации режимов формирования и размерности дескрипторов.

**Благодарности.** Работа выполнена при финансовой поддержке Белорусского фонда фундаментальных исследований № Ф23М-043.

#### Литература

1. A systematic review and Meta-data analysis on the applications of Deep Learning in Electrocardiogram / N. Musa [et al.] // J Ambient Intell Human Comput. – 2023. – V. 14. – P. 9677–9750.
2. Maly, S. V. Diffraction analysis of ECG / S. V. Maly, M. M Liventseva // In IFMBE Proceedings, Health in the Information Society (MEDICON and HEALTH TELEMATICS 2004, X Mediterranean Conference on Medical and Biological Engineering, 31 July – 5 August, 2004, Ischia, Italy. – 2004. – V. 6.
3. An open access database for evaluating the algorithms of ECG rhythm and morphology abnormal detection / F. F. Liu [et al.] // Journal of Medical Imaging and Health Informatics. – 2018. – V. 8. – P. 1368–1373.
4. CODE-15%: a large scale annotated dataset of 12-lead ECGs / A. H. Ribeiro [et al.] – 2021.
5. MedalCare-XL: 16,900 healthy and pathological synthetic 12 lead ECGs from electrophysiological simulations / K. Gillette [et al.] // Sci Data. – 2023. – V. 10.
6. Wagner, P. PTB-XL, a large publicly available electrocardiography dataset / P. Wagner [et al.] // Sci Data. – 2020. – V. 7.