

Для цитирования: Качаева Г.И., Мустафаев А.Г. Использование нейросетевых методов для автоматического анализа электрокардиограмм при диагностике заболеваний сердечно-сосудистой системы. Вестник Дагестанского государственного технического университета. Технические науки. 2018; 45 (2): 114-124. DOI:10.21822/2073-6185-2018-45-2-114-124

For citation: Kachaeva G.I., Mustafayev A.G. The use of neural networks for the automatic analysis of electrocardiograms in diagnosis of cardiovascular diseases. Herald of Daghestan State Technical University. Technical Sciences. 2018; 45 (2): 114-124. (in Russ.) DOI:10.21822/2073-6185-2018-45-2-114-124

ТЕХНИЧЕСКИЕ НАУКИ ИНФОРМАТИКА, ВЫЧИСЛИТЕЛЬНАЯ ТЕХНИКА И УПРАВЛЕНИЕ

УДК 004.032.26

DOI: 10.21822/2073-6185-2018-45-2-114-124

ИСПОЛЬЗОВАНИЕ НЕЙРОСЕТЕВЫХ МЕТОДОВ ДЛЯ АВТОМАТИЧЕСКОГО АНАЛИЗА ЭЛЕКТРОКАРДИОГРАММ ПРИ ДИАГНОСТИКЕ ЗАБОЛЕВАНИЙ СЕРДЕЧНО-СОСУДИСТОЙ СИСТЕМЫ

Качаева Г.И.,² Мустафаев А.Г.¹

¹⁻²Дагестанский государственный технический университет,

¹⁻²367026, г. Махачкала, пр. Имама Шамиля, 70, Россия,

¹e-mail: arslan_mustafayev@mail.ru, ²e-mail: providetc@mail.ru

Резюме. Цель. Цель работы состоит в использовании нейронных сетей для обнаружения характерных ЭКГ сигналов, определяющих аномалии сердечного ритма и выявления соответствующего заболевания сердца. Одним из важнейших факторов для своевременного оказания медицинской помощи является быстрое и точное получение информации о состоянии здоровья пациента. Своевременность постановки диагноза нередко является основным фактором, определяющим прогноз больного. В последние годы в кардиологии значительно увеличилась точность диагностики благодаря широкому применению, как инструментальных, так и лабораторных методов исследований. Тем не менее, процент диагностических ошибок в кардиологии достаточно высок. Электрокардиография (ЭКГ) представляет собой неинвазивный процесс интерпретации электрической активности сердца, позволяющий оценивать скорость и регулярность сердечных сокращений. Эти данные используются для определения поврежденных и патологий сердца. Автоматический анализ ЭКГ является непростой теоретической и практической задачей. **Метод.** При проектировании был использован пакет Neural Network Toolbox из MATLAB 8.6 (R2015b) моделирующий аппарат искусственных нейронных сетей. При обучении нейронной сети использовался алгоритм обратного распространения ошибки. Эффективность разработанной нейросетевой модели для анализа ЭКГ была исследована с использованием базы данных аритмий MIT-BIH. **Результат.** Точность обнаружения и извлечения компонентов сигнала ЭКГ показывает, что разработанная нейросетевая модель может быть использована для выявления заболеваний сердца у пациентов. Чувствительность модели составила 71%, специфичность 89%. Развитие существующих и разработка новых методов обработки электрокардиографических данных позволяют решить проблему своевременной диагностики и профилактики сердечно-сосудистых заболеваний на ранних этапах их выявления. **Вывод.** Точность обнаружения и извлечения компонентов сигнала ЭКГ, показывает, что разработанная нейросетевая модель может быть использована для выявления заболеваний сердца у пациентов.

Ключевые слова: электрокардиограмма, искусственная нейронная сеть, компьютерная диагностика, обратное распространение ошибки, обучение с учителем, QRS комплекс

TECHNICAL SCIENCE
COMPUTER SCIENCE, COMPUTER ENGINEERING AND MANAGEMENT

THE USE OF NEURAL NETWORKS FOR THE AUTOMATIC ANALYSIS OF
ELECTROCARDIOGRAMS IN DIAGNOSIS OF CARDIOVASCULAR DISEASES

*Gyulkhanum I.Kachayeva*², *Arslan G.Mustafayev*¹

¹⁻²Daghestan State Technical University,

¹⁻²70 I. Shamilya Ave., Makhachkala 367026, Russia,

¹e-mail: arslan_mustafayev@mail.ru, ²e-mail: providetc@mail.ru

Abstract Objectives The aim of the work is to use neural networks to detect characteristic ECG signals that determine heart rhythm abnormalities and detect the corresponding heart disease. One of the most important factors for the timely provision of medical care is the rapid and accurate obtaining of information about the patient's state of health. The timeliness of diagnosis is often the main factor determining the patient's prognosis. While the accuracy of cardiological diagnosis has significantly increased in recent years due to the wide application of both instrumental and laboratory research methods, the percentage of diagnostic errors in cardiology remains high. Electrocardiography (ECG) consists in a non-invasive process of interpreting the electrical activity of the heart, allowing the speed and regularity of the heartbeat to be assessed. These data are then used to determine any heart defects or pathologies. However, automatic ECG analysis remains a challenging theoretical and practical task. **Methods** A MATLAB 8.6 (R2015b) Neural Network Toolbox was used to simulate artificial neural networks during the design. A backpropagation algorithm was used for training the neural network. The efficiency of the developed neural network model for ECG analysis was investigated using the MIT-BIH arrhythmia database. **Results** The accuracy of detection and extraction of the components of the ECG signal shows that the developed neural network model can be successfully used to detect heart diseases among patients. The sensitivity of the model was 71%, with a specificity of 89%. The elaboration of existing and development of new methods for processing electrocardiographic data allow the problem of timely diagnosis and prevention of cardiovascular diseases to be solved at early stages of their detection. **Conclusion** The accuracy of detection and extraction of the ECG signal components shows that the developed neural network model can be used to detect heart diseases among patients.

Keywords: electrocardiogram, artificial neural network, computer diagnostics, backpropagation, training with the teacher, QRS complex

Введение. По данным Всемирной организации здравоохранения [1] заболевания сердечно-сосудистой системы уносят свыше 17 миллионов жизней в год. Сердечная аритмия и нарушение сердечного ритма могут свидетельствовать о возможности серьезных сердечно-сосудистых заболеваний, инсульта или внезапной сердечной смерти. Ранняя диагностика нарушений сердечного ритма позволяет выбрать соответствующее медикаментозное лечение.

Большинство клинических исследований сердечно-сосудистой системы основаны на анализе электрокардиограмм (ЭКГ) и изучении ряда других регистрируемых сигналов, иллюстрирующих биоэлектрическую активность сердца. К числу несомненных преимуществ такого подхода можно отнести относительную простоту, доступность, неинвазивность и достаточно высокую информативность. ЭКГ – функциональный метод исследования, суть которого заключается в определении состояния сердца и сердечно-сосудистой системы по изменениям в их электрической активности. Этот метод исследования на сегодняшний день является самым распространенным и проводится практически во всех медицинских учреждениях.

Наибольший интерес для практического здравоохранения представляют системы для диагностики заболеваний. Работы в данной области ведутся российскими и зарубежными исследователями [2-7].

Задачи диагностики и прогнозирования, встречающиеся в медицинской практике как,

правило не учитывают все реально имеющиеся условия, от которых зависит результат, а только выделяют некоторый набор наиболее важных условий.

Постановка задачи. Целью данной работы является разработка нейросетевой системы для автоматического анализа электрокардиограмм при диагностике заболеваний сердечно-сосудистой системы.

Методы исследования. Электрокардиография до сих пор остается наиболее распространенным методом функциональной диагностики в кардиологии. В то же время, существующие компьютерные средства анализа и интерпретации ЭКГ все еще не обеспечивают требуемую достоверность результатов диагностики. Изображение эталонной ЭКГ и обозначение ее элементов показано на рис. 1.

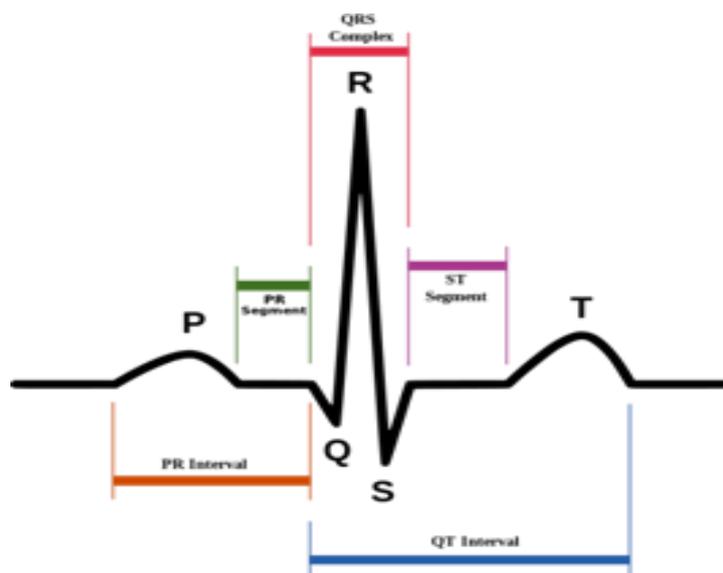


Рис.1. Эталонная электрокардиограмма

Fig.1. Reference electrocardiogram

На реальных ЭКГ нет четких границ между информативными фрагментами, что затрудняет их автоматическое распознавание. Реальная ЭКГ обычно наблюдается в условиях разного рода возмущений, которые далеко не всегда могут быть сведены лишь к аддитивной помехе. При повышении соотношения сигнал-шум, происходит «размытие» информативных фрагментов из-за неравномерных изменений их продолжительности от цикла к циклу что приводит к ошибкам в измерении диагностических признаков, сосредоточенных на этих фрагментах [8].

Автоматический анализ ЭКГ является непростой теоретической и практической задачей. Физиологическое происхождение сигнала ЭКГ, обуславливает его недетерминированность, разнообразие, изменчивость, нестационарность и подверженность многочисленным видам помех. Увеличение эффективности методов автоматического анализа ЭКГ сдерживается ограничениями, связанными с вычислительной мощностью используемых процессоров [9]. Это в наибольшей степени относится к аппаратуре непрерывного наблюдения, так как обработка сигналов в ней должна выполняться в реальном масштабе времени. Производительность вычислительных средств постоянно повышается, поэтому становятся востребованными такие методы обработки и анализа сигналов, применение которых в системах реального времени ранее представлялось сложно реализуемым.

Нейронная сеть – математическая парадигма моделирования поведения биологических нейронных систем. Искусственная нейронная сеть состоит из нескольких простых нелинейных элементов – нейронов, соединенных между собой взвешенными связями – синапсами, формирующими сеть.

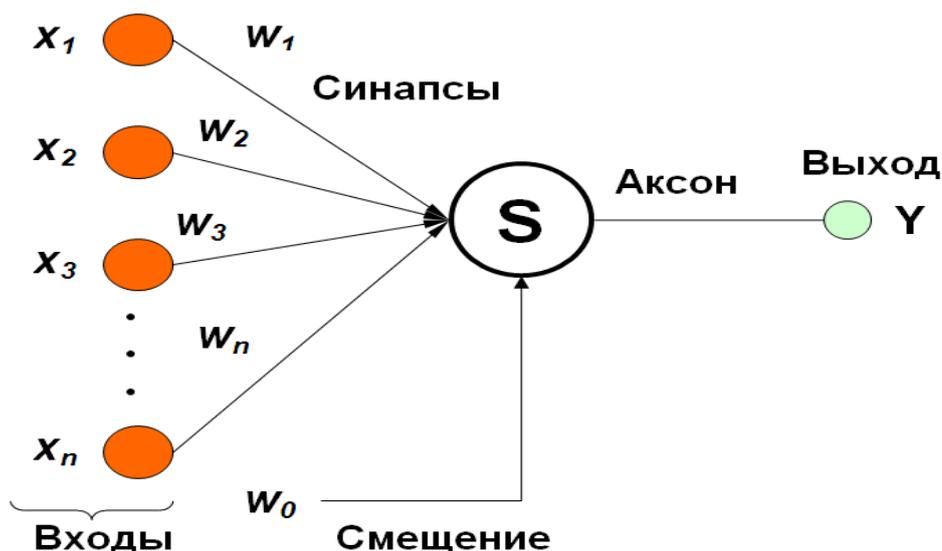


Рис. 2. Модель искусственного нейрона [10]
Fig. 2. Model of an artificial neuron [10]

Искусственный нейрон является структурной единицей искусственной нейронной сети и представляет собой аналог биологического нейрона (рис. 2).

Обсуждение результатов. С математической точки зрения искусственный нейрон – это сумматор входных сигналов, применяющий к полученной сумме простую, в общем случае, нелинейную функцию, непрерывную на всей области определения. Полученный результат посылается на единственный выход.

Искусственные нейроны могут объединяются между собой определенным образом, образуя искусственную нейронную сеть. Каждый нейрон характеризуется своим текущим состоянием по аналогии с нервными клетками головного мозга, которые могут быть возбуждены или заторможены. Нейрон обладает группой синапсов – однонаправленных входных связей, соединенных с выходами других нейронов, а также имеет аксон – выходную связь данного нейрона, с которой сигнал поступает на синапсы следующих нейронов.

Каждый синапс характеризуется величиной синаптической связи (весом связи) W_i . Текущее состояние нейрона определяется, как взвешенная сумма его входов:

$$S = \sum_{i=1}^n x_i W_i + W_0, \quad (1)$$

где: w_0 — коэффициент смещения нейрона (вес единичного входа)

Выход нейрона есть функция его состояния:

$$Y = F(S).$$

Нелинейная функция F называется активационной и может иметь различный вид. Если нейроны сгруппированы в слои и их синапсы связаны только с нейронами в соседних слоях, то подобная структура является многослойным персептроном. Модель многослойного персептрона является наиболее популярной и широко изученной. Многослойный персептрон состоит из одного входного и одного выходного слоя, с одним или несколькими скрытыми слоями.

При обнаружении и обработке ЭКГ сигнала, в основном используются многослойные персептроны и радиально-базисные нейронные сети [11-12].

При формировании исходных данных был использован архив, содержащий структурированный массив оцифрованных записей реальных физиологических сигналов и связанных с ними данных для применения биомедицинским сообществом в исследованиях [13]. Данные записи были получены Холтеровским мониторингом в условиях стационара и независимо проанализированы двумя практикующими врачами. Пример записи показан на рис. 3 (фрагмент ЭКГ этой записи показан на рис. 4).

Record 109 (MLII, V1; male, age 64)

Medications: Quinidine

Beats	Before 5:00	After 5:00	Total
Left BBB	425	2067	2492
PVC	6	32	38
Fusion PVC	2	-	2
Total	433	2099	2532

Ventricular ectopy

- 40 isolated beats

Rhythm	Rate	Episodes	Duration
Normal sinus rhythm	77-101	1	30:06

Signal quality	Episodes	Duration
Both clean	2	29:52
Lower noisy	1	0:14

Notes:
There is first degree AV block. The PVCs are multiform.

Points of interest:

- 0:13 Fusion PVC
- 1:28 PVC
- 3:36 Normal sinus rhythm with left bundle branch block
- 4:46 PVC
- 5:27 Noise
- 14:01 PVC
- 17:13 PVC
- 19:21 PVC
- 26:09 Noise
- 28:03 PVC
- 28:28 Normal sinus rhythm with left bundle branch block
- 29:10 PVC

Рис. 3. Образец записи №109 из базы MIT-BIH
 Fig. 3. Sample Record № 109 from the MIT-BIH database

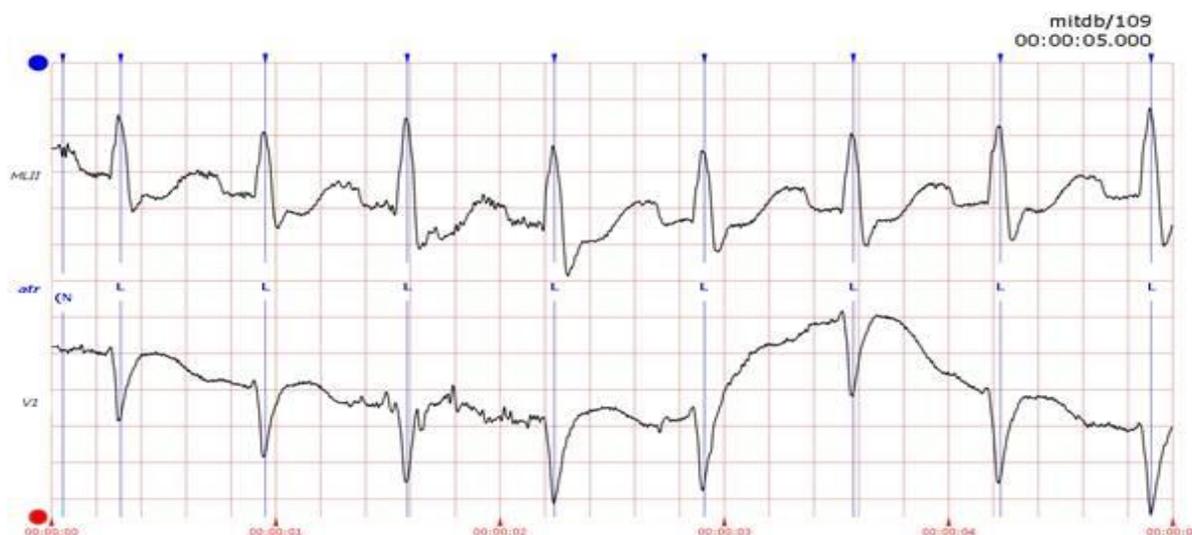


Рис.4. Фрагмент ЭКГ записи №109
 Fig.4. Fragment of ECG recording number 109

При анализе ЭКГ учитывают следующие нормальные значения интервалов и комплексов [14]:

1. Ширина комплекса QRS в интервале 60- 100 мс.
2. Длительность интервала QT составляет 390- 450 мс.
3. Длительность интервалов R-R одинакова или имеет разброс до 10%.
4. Длительность интервала PQ составляет 120- 200 мс.
5. Амплитуда зубца S не более 20 мм.
6. Зубец T направлен вверх в отведении I и II, но в aVR отведении – всегда будет отрицательный.
7. Зубец P по амплитуде не более 2,5 мм, а по длительности 0,1 сек.

8. Зубец Q не шире 20- 40 мс и не глубже 1/3 зубца R.

Вопрос нахождения оптимального числа нейронов скрытого слоя не имеет однозначного решения по причине отсутствия устоявшейся методики [15-17].

Например, в [18] рекомендуется число нейронов скрытого слоя определять эмпирическим путем, но в большинстве случаев используется правило, $N_{\text{скр}} \leq N_{\text{вх}} + N_{\text{вых}}$, где $N_{\text{скр}}$, $N_{\text{вх}}$, $N_{\text{вых}}$ – число нейронов соответственно в скрытом, входном и выходном слое.

В [19] предлагается правило геометрической пирамиды. Число нейронов скрытого слоя в трехслойном персептроне вычисляется из выражения $N_{\text{скр}} = \sqrt{N_{\text{вх}}N_{\text{вых}}}$, где $N_{\text{скр}}$, $N_{\text{вх}}$, $N_{\text{вых}}$ – число нейронов в скрытом, входном и выходном слое.

Выбор правильного количества нейронов в скрытых слоях является очень важным. Недостаточное число нейронов не позволит сети обучиться. Большое число нейронов приведет к увеличению времени обучения сети, до неприемлемого значения, и к эффекту переобучения сети – сеть будет прекрасно работать на обучающей выборке, и очень плохо на входных примерах, не входящих в нее. Это происходит из-за того, что сеть будет обладать избыточными способностями к обучению и наряду со значительными для данной задачи факторами будет учитывать черты, характерные лишь для данной обучающей выборки.

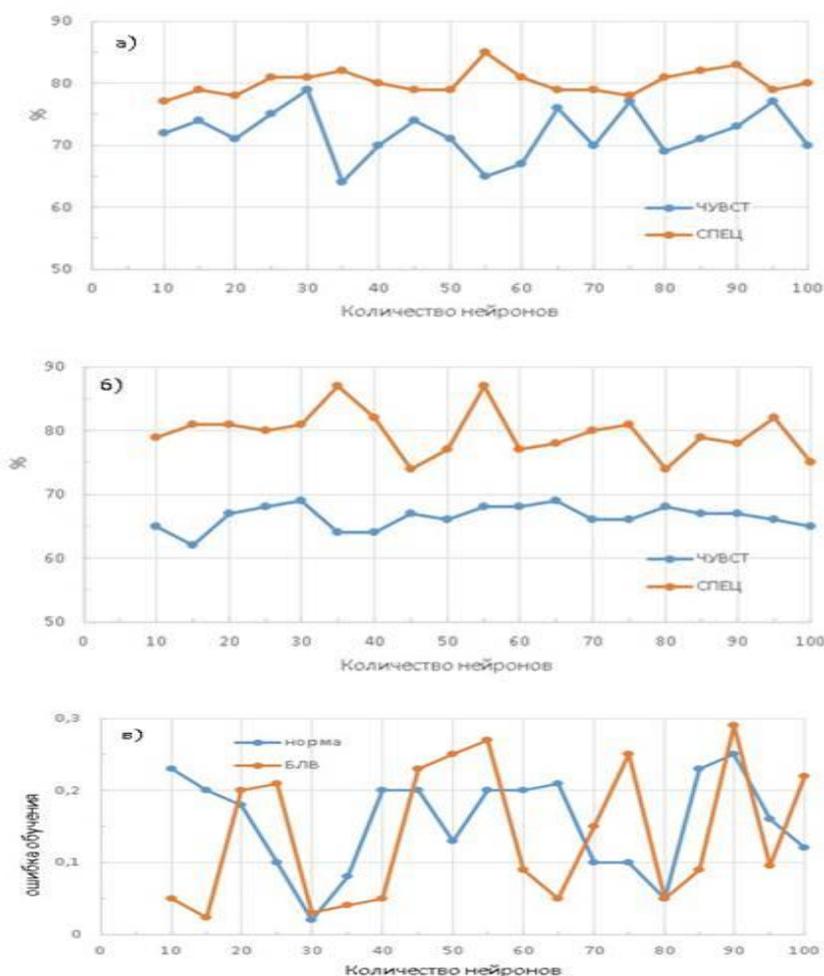


Рис. 5. Значения чувствительности, специфичности для выхода «Норма» (а) и выхода «БЛВ» (б) и ошибки обучения (в)
Fig. 5. The values of sensitivity, specificity for the output «Norma» (a) and the output «BLV» (b) and learning errors (c)

По этой причине в работе использован метод, в основе которого лежит учет критериев оценки эффективности работы искусственной нейронной сети: чувствительность, специфичность и ошибка обучения.

От параметров чувствительности и специфичности алгоритма зависит достоверность классификации ритмов сердца. Чувствительность характеризует достоверность определения аномальных эпизодов, а специфичность характеризует достоверность определения эпизодов нормального сердечного ритма.

Для нахождения оптимального числа нейронов скрытого слоя нейронной сети со структурой многослойного персептрона, необходимо произвести исследование показателей чувствительности и специфичности всех выходов сети.

Показатели чувствительности и специфичности в идеальном случае должны стремиться к 100%. В реальных условиях при решении задач диагностики система должна выбрать один из нескольких вариантов диагноза. При этом по всем вариантам диагноза желательно иметь значения критериев чувствительности и специфичности системы по всем вариантам диагноза равномерно распределенными, но не ниже порогового значения, при котором результат не может считаться достоверным [19].

На рис. 5 представлены значения чувствительности и специфичности, показанные нейронной сетью, при различном числе нейронов в скрытом для двух вариантов выхода.

Для обучения нейронной сети был подготовлен набор данных из 458 эпизодов ЭКГ (обучающая выборка 50%, валидационная выборка 30%, и тестовая выборка 20%).

Разработанная нейронная сеть содержит 9 входных нейронов, по числу учитываемых параметров, скрытый слой с 30 нейронами, и 5 нейронов в выходном слое (рис. 6).

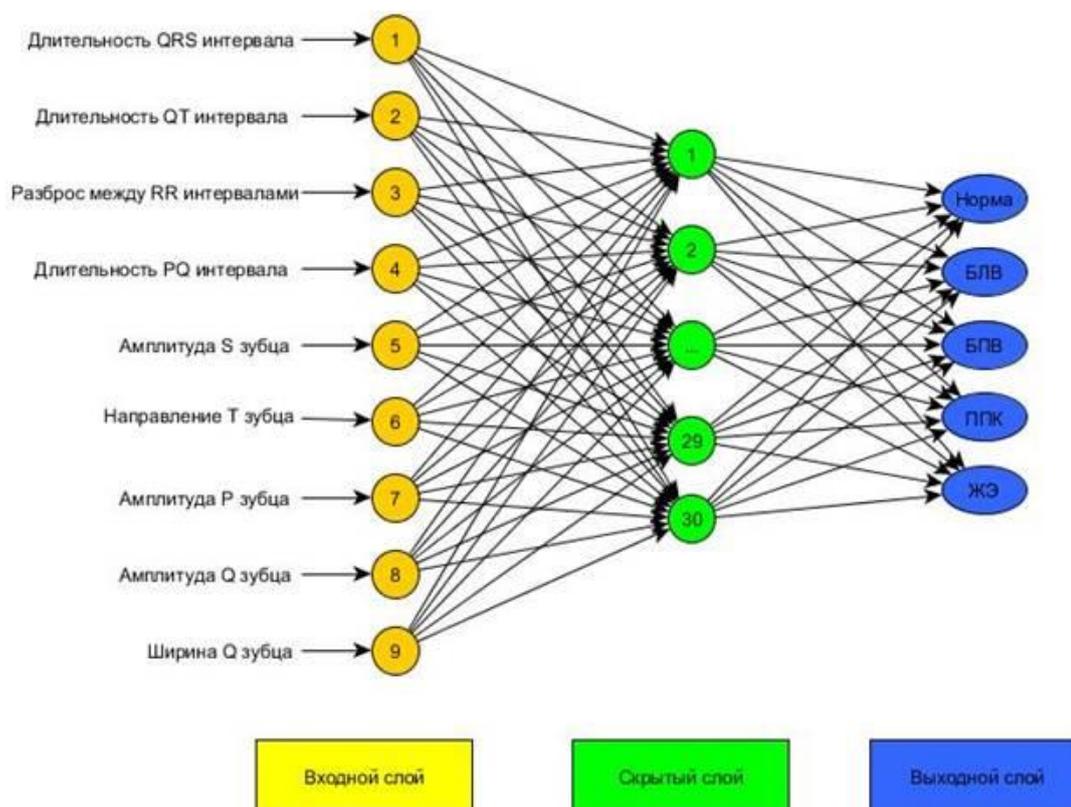


Рис. 6. Архитектура нейронной сети
Fig. 6. Neural Network Architecture

Подготовленные входные данные подаются на входной слой нейронной сети, выходной слой которой диагностирует состояние пациента как нормальное (здоров), блокада левой ножки пучка Гиса (БЛВ), блокада правой ножки пучка Гиса (БПВ), преждевременный предсердный комплекс (ППК), желудочковая экстрасистола (ЖЭ).

В качестве активационной функции в выходном слое использовалась сигмоидальная логистическая функция (рис. 7):

$$F(Y) = \frac{1}{1 + \alpha Y}, \quad (2)$$

где: α – параметр наклона логистической функции.

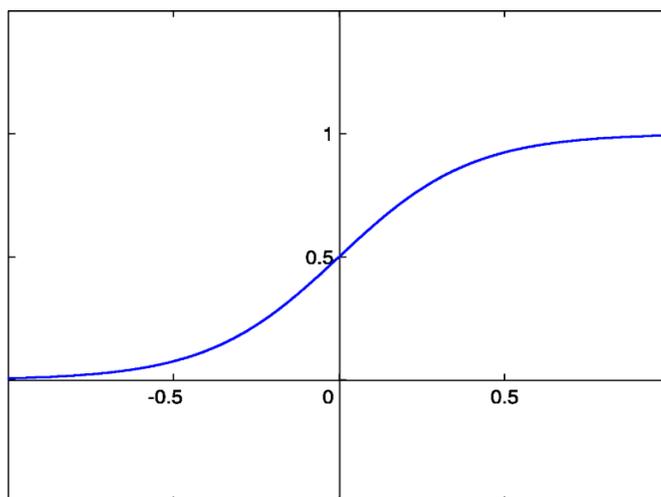


Рис.7. Функция активации нейрона
Fig.7. Neuron activation function

Для обучения искусственной нейронной сети был использован алгоритм обратного распространения ошибки [21].

Алгоритм обратного распространения ошибки (рис. 8) предполагает вычисление ошибки, как выходного слоя, так и каждого нейрона обучаемой сети, а также коррекцию весов нейронов в соответствии с их текущими значениями.

На первом шаге данного алгоритма веса всех межнейронных связей инициализируются небольшими случайными значениями (от 0 до 1).

После инициализации весов в процессе обучения нейронной сети выполняются следующие шаги: прямое распространение сигнала; вычисление ошибки нейронов последнего слоя; обратное распространение ошибки.

Прямое распространение сигнала производится послойно, начиная со входного слоя, при этом рассчитывается сумма входных сигналов для каждого нейрона, и при помощи функции активации генерируется отклик нейрона, который распространяется в следующий слой с учетом веса межнейронной связи.

В результате выполнения данного этапа мы получаем вектор выходных значений нейронной сети. Следующий этап обучения – вычисление ошибки нейронной сети как разницы между ожидаемым и действительным выходными значениями.

Полученные значения ошибок распространяются от последнего, выходного слоя нейронной сети, к первому. При этом вычисляются величины коррекции весов нейронов в зависимости от текущего значения веса связи, скорости обучения и ошибки, внесенной данным нейроном.

После завершения данного этапа шаги описанного алгоритма повторяются до тех пор, пока ошибка выходного слоя не достигнет требуемого значения.

При определении выходного результата учитывается максимальное значение одного из выходных нейронов (этот сигнал интерпретируется как единица, а остальные как 0). Например, один из выходных нейронов имеет значение 0,87, если это максимальное значение в выходном слое нейронов, то оно будет интерпретировано как «1», т.е. значения других нейронов выходного слоя интерпретируются как «0».

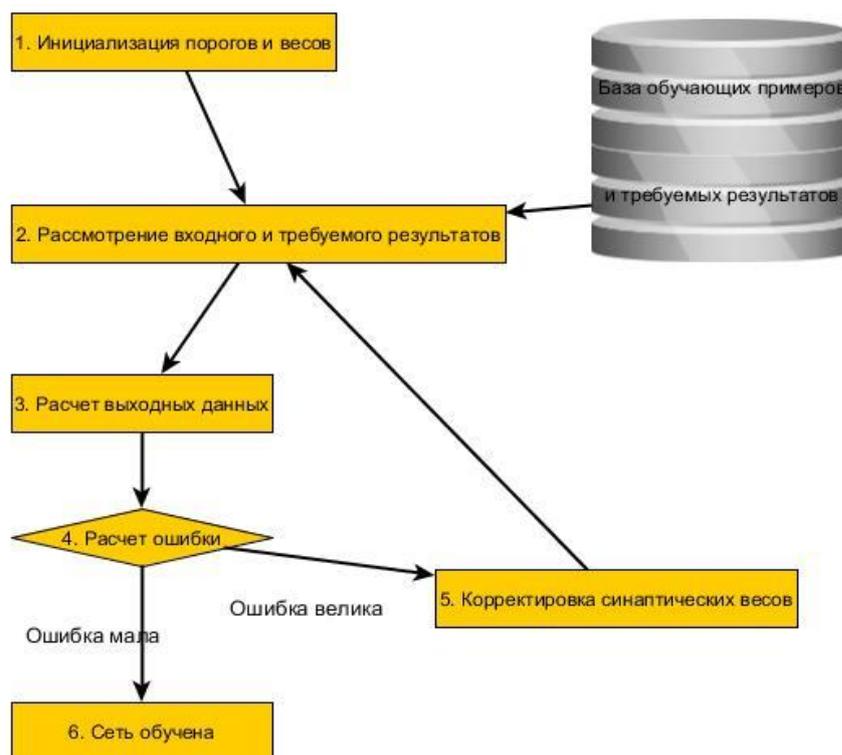


Рис. 8. Схема работы алгоритма обратного распространения ошибки

Fig. 8. The scheme of the algorithm back propagation of error

Вывод. Специфичность предложенной нейросетевой системы, проверена исследованием на контрольной группе без сердечно-сосудистых заболеваний, составила 81%. Чувствительность разработанной системы проверялась на контрольной группе с сердечно-сосудистыми заболеваниями, составила 79%. Точность обнаружения и извлечения компонентов сигнала ЭКГ, показывает, что разработанная нейросетевая модель может быть использована для выявления заболеваний сердца у пациентов.

Библиографический список:

1. Всемирная организация здравоохранения [Электронный ресурс]: Сердечно-сосудистые заболевания. URL: <http://www.who.int/mediacentre/factsheets/fs317/ru> (дата обращения: 25.10.2017).
2. Lee J.W., Lee G. Design of an Adaptive Filter with a Dynamic Structure for ECG Signal // Processing. International Journal of Control, Automation, and Systems, 2005, Vol. 3, No. 1, pp. 137-142.
3. Ince T., Kiranyaz S., Gabbouj M. A Generic and Robust System for Automated Patient-Specific Classification of ECG Signals // IEEE Transactions on Biomedical Engineering, 2009, Vol. 56, pp. 1415-1426.
4. Lin C.H., Du Y.C., Chen T. Adaptive wavelet network for multiple cardiac arrhythmias recognition // Expert Systems with Applications, 2008. No. 34, pp. 2601-2611.
5. Мустафаев А.Г. Нейросетевая модель прогнозирования уровня глюкозы в крови у больных сахарным диабетом // Кибернетика и программирование. 2016. № 3. С. 1-5.
6. Мустафаев А.Г. Применение искусственных нейронных сетей для ранней диагностики заболевания сахарным диабетом // Кибернетика и программирование. 2016. - № 2. - С.1-7.
7. Никитин В.М., Ломакин В.В., Анохин Д.А., Кайдалова И.К., Иванов И.И. Информационная система поддержки принятия решений слабоструктурированных задач в кардиологии // Научные ведомости БелГУ серия «История. Политология. Экономика. Информатика». 2010. № 19(90). Вып. 16/1. с. 112–119.
8. Файнзильберг Л.С., Лебедушко Т.Ю. Исследование диагностической ценности фазовых портретов ЭКГ по данным специализированных баз // Кибернетика и вычислительная техника. 2012. Вып. 169. С. 34-50.

9. Калиниченко А.Н. Оценка разделяющей способности методов классификации форм ЭКГ // Известия СПбГЭТУ "ЛЭТИ". Сер. Биотехнические системы в медицине и экологии. 2006. Вып. 1. С. 21-30.
10. Портал искусственного интеллекта [Электронный ресурс]: Искусственный нейрон. Структура искусственного нейрона. URL: <http://neuronus.com/theory/151-iskusstvennyj-nejron.html> дата обращения: 25.12.2017).
11. Guangying Y., Yue C. The Study of Electrocardiograph Based on Radial Basis Function Neural Network // Intelligent Information Technology and Security Informatics (IITSI), 2010, pp.143-145.
12. Gao D., Madden M. Bayesian ANN Classifier for ECG Arrhythmias Diagnostic System // Proceeding of IEEE International Joint Conference on Neural Network, 2003, pp. 2454-2459.
13. База данных аритмий Массачусетского технологического института [Электронный ресурс]: Описание. URL: <http://ecg.mit.edu/> (дата обращения: 20.09.2017).
14. Габриэль Хан М. Быстрый анализ ЭКГ // М.: Бином, 2009. - 408 с.
15. Trenn S. Multilayer perceptrons: approximation order and necessary number of hidden units // IEEE Transactions on Neural Networks, vol. 19, no. 5, pp. 836–844, 2008.
16. Xu S., Chen L. A novel approach for determining the optimal number of hidden layer neurons for FNN's and its application in data mining // Proceedings of the 5th International Conference on Information Technology and Applications (ICITA '08), 2008, pp. 683–686.
17. Sun J. Learning algorithm and hidden node selection scheme for local coupled feedforward neural network classifier // Neurocomputing, vol. 79, 2012, pp. 158–163.
18. Назаров А.В., Лоскутов А.И. Нейросетевые алгоритмы прогнозирования и оптимизации систем // – СПб: Наука и техника, 2003. – 380 с.
19. Masters T. Practical Neural Network Recipes in C++ // Academic Press, 1993. -504 p.
20. Салех М.А., Исаков Р.В. Оценка эффективности применения искусственных нейронных сетей для анализа сегментированных электрокардиокомплексов // Биомедицинская радиоэлектроника. № 6, 2012, с.21-27.
21. Галушкин А.И. Теория нейронных сетей. - М.: ИПРЖР, 2000. - 348 с.

References:

1. Vsemirnaya organizatsiya zdravookhraneniya [Elektronnyi resurs]: Serdechno-sosudistye zabolevaniya. URL: <http://www.who.int/mediacentre/factsheets/fs317/ru> (data obrashcheniya: 25.10.2017). [World Health Organization [Electronic resource]: Cardiovascular diseases. URL: <http://www.who.int/mediacentre/factsheets/fs317/ru> (access date: 25.10.2017). (in Russ.)]
2. Lee J.W., Lee G. Design of an adaptive filter with a dynamic structure for ECG signal. Processing. International Journal of Control, Automation, and Systems. 2005;3(1):137-142.
3. Ince T., Kiranyaz S., Gabbouj M. A generic and robust system for automated patient-specific classification of ECG signals. IEEE Transactions on Biomedical Engineering. 2009;56:1415-1426.
4. Lin C.H., Du Y.C., Chen T. Adaptive wavelet network for multiple cardiac arrhythmias recognition. Expert Systems with Applications. 2008;34:2601-2611.
5. Mustafaev A.G. Neirosetevaya model' prognozirovaniya urovnya glyukozy v krovi u bol'nykh sakharnym diabetom. Kibernetika i programmirovaniye. 2016;3:1-5. [Mustafaev A.G. Neural network model for predicting the level of glucose in the blood in patients with diabetes mellitus. Cybernetics and programming. 2016;3:1-5. (in Russ.)]
6. Mustafaev A.G. Primeneniye iskusstvennykh neironnykh setei dlya rannei diagnostiki zabolevaniya sakharnym diabetom. Kibernetika i programmirovaniye. 2016;2:1-7. [Mustafaev A.G. The use of artificial neural networks for early diagnosis of diabetes mellitus. Cybernetics and programming. 2016;2:1-7. (in Russ.)]
7. Nikitin V.M., Lomakin V.V., Anokhin D.A., Kaidalova I.K., Ivanov I.I. Informatsionnaya sistema podderzhki prinyatiya reshenii slabostrukturirovannykh zadach v kardiologii. Nauchnye vedomosti BelGU. Seriya "Istoriya. Politologiya. Ekonomika. Informatika". 2010;19(90):112–119. [Nikitin V.M., Lomakin V.V., Anokhin D.A., Kaidalova I.K., Ivanov I.I. Information system for decision support of weakly structured tasks in cardiology. Belgorod State University Scientific bulletin. Series "History. Political science. Economics. Information technologies". 2010;19(90):112–119. (in Russ.)]
8. Fainzil'berg L.S., Lebedushko T.Yu. Issledovaniye diagnosticheskoi tsennosti fazovykh portretov EKG po dannym spetsializirovannykh baz. Kibernetika i vychislitel'naya tekhnika. 2012;169:34-50.

- [Fainzil'berg L.S., Lebedushko T.Yu. Study of the diagnostic value of ECG phase portraits according to the data of specialised bases. Cybernetics and Computer Engineering. 2012;169:34-50. (in Russ.)]
9. Kalinichenko A.N. Otsenka razdelyayushchei sposobnosti metodov klassifikatsii form EKG. Izvestiya SPbGETU "LETI". Ser. Biotekhnicheskie sistemy v meditsine i ekologii. 2006;1:21-30. [Kalinichenko A.N. Evaluation of the separating ability of ECG form classification methods. Izvestiya SPbGETU "LETI". Ser. Biotekhnicheskie sistemy v meditsine i ekologii. 2006;1:21-30. (in Russ.)]
 10. Portal iskusstvennogo intellekta [Elektronnyi resurs]: Iskusstvennyi neiron. Struktura iskusstvennogo neirona. URL: <http://neuronus.com/theory/151-iskusstvennyj-nejron.html>. (data obrashcheniya: 25.12.2017). [Portal of artificial intelligence [Electronic resource]: Artificial neuron. Structure of an artificial neuron. URL: <http://neuronus.com/theory/151-iskusstvennyj-nejron.html>. (access date: 25.12.2017). (in Russ.)]
 11. Guangying Y., Yue C. The study of electrocardiograph based on radial basis function neural network. Intelligent Information Technology and Security Informatics (IITSI). 2010:143-145.
 12. Gao D., Madden M. Bayesian ANN classifier for ECG arrhythmias diagnostic system. Proceeding of IEEE International Joint Conference on Neural Network. 2003. P. 2454-2459.
 13. Baza dannykh aritmii Massachusetskogo tekhnologicheskogo instituta [Elektronnyi resurs]: Opisanie. URL: <http://ecg.mit.edu/> (data obrashcheniya: 20.09.2017). [The database of arrhythmias of the Massachusetts Institute of Technology [Electronic resource]: Description. URL: <http://ecg.mit.edu/> (access date: 20.09.2017). (in Russ.)]
 14. Gabriel' Khan M. Bystryi analiz EKG. M.: Binom; 2009. 408 s. [Gabriel' Khan M. Quick analysis of the ECG. M.: Binom; 2009. 408 p. (in Russ.)]
 15. Trenn S. Multilayer perceptrons: approximation order and necessary number of hidden units. IEEE Transactions on Neural Networks. 2008;19(5):836–844, 2008.
 16. Xu S., Chen L. A novel approach for determining the optimal number of hidden layer neurons for FNN's and its application in data mining. Proceedings of the 5th International Conference on Information Technology and Applications (ICITA '08). 2008. P. 683–686.
 17. Sun J. Learning algorithm and hidden node selection scheme for local coupled feedforward neural network classifier. Neurocomputing. 2012;79:158–163.
 18. Nazarov A.V., Loskutov A.I. Neurosetevye algoritmy prognozirovaniya i optimizatsii sistem. SPb: Nauka i tekhnika; 2003. 380 s. [Nazarov A.V., Loskutov A.I. Neural network algorithms for forecasting and optimisation of systems. SPb: Nauka i tekhnika; 2003. 380 p. (in Russ.)]
 19. Masters T. Practical Neural Network Recipes in C++. Academic Press; 1993. 504 p.
 20. Salekh M.A., Isakov R.V. Otsenka effektivnosti primeneniya iskusstvennykh neironnykh setei dlya analiza segmentirovannykh elektrokardiokompleksov. Biomeditsinskaya radioelektronika. 2012;6:21-27. [Salekh M.A., Isakov R.V. Effectiveness evaluation of the application of artificial neural networks for the analysis of segmented electrocardiocomplexes. Biomedical radioelectronics. 2012;6:21-27. (in Russ.)]
 21. Galushkin A.I. Teoriya neironnykh setei. M.: IPRZhR; 2000. 348 s. [Galushkin A.I. The theory of neural networks. M.: IPRZhR; 2000. 348 p. (in Russ.)]

Сведения об авторах:

Качаева Гюльханум Ибадулаховна – кандидат экономических наук, заведующая кафедрой информационных технологий и информационной безопасности.

Мустафаев Арслан Гасанович – доктор технических наук, профессор, кафедра информационных технологий и информационной безопасности.

Information about the authors.

Gyulkhanum I. Kachaeva– Cand. Sci. (Economics), Department of Information Technology and Information Security.

Arslan G. Mustafayev - Dr.Sci. (Technical), Prof., Department of Information Technology and Information Security.

Конфликт интересов

Авторы заявляют об отсутствии конфликта интересов.

Поступила в редакцию 02.02.2018.

Принята в печать 30.05.2018.

Conflict of interest.

The authors declare no conflict of interest.

Received 02.02.2018.

Accepted for publication 30.05.2018.