

---

## ТЕОРИЯ И КОНСТРУИРОВАНИЕ

---

*Н.Т. Абдуллаев, К.Ш. Исмаилова*

### **ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ РАСПОЗНАВАНИЯ ПАТОЛОГИЧЕСКИХ ИЗМЕНЕНИЙ В СТИМУЛЯЦИОННОЙ ЭЛЕКТРОМИОГРАММЕ**

#### **Аннотация**

Рассмотрены возможности применения нейронной сети при регистрации стимуляционной электромиографии пациентов с нормальным состоянием нервно-мышечной системы и болезнями типа карпальный туннельный синдром, кубитальный туннельный синдром и демиелинизирующая полиневропатия. Определены входные параметры и оценена возможность диагностического анализа при обработке ЭМГ-сигналов для сетевого эмулятора Neuro Pro и перцептронной трехслойной сети с прямыми связями.

Компьютерный анализ биомедицинских сигналов, если он выполняется с использованием адекватной логики, потенциально способен усилить объективную составляющую интерпретации, даваемой экспертом, что позволяет усилить достоверность и точность диагностического заключения даже эксперта с многолетним опытом. Этот подход к повышению уровня диагностики, поддерживаемый компьютером, строится на двух уровнях. Первый уровень представляют инструментальные методы исследования состояния живого организма. На практике хорошо известны кардиографические, энцефалографические, изотопный, ультразвуковой и другие методы. Другой уровень формирования медицинского заключения строится на возможности врача дать некоторое словесное описание состояния организма.

По современным медицинским представлениям понятия «норма» или «не норма» формируются на основе большого количества реальных фактов. Это так называемый статистический показатель, который в определенных случаях может значительно изменяться. В связи с этим возникает проблема описания промежуточных состояний организма между данными крайними категориями, которые с учетом индивидуальных особенностей организма могут быть использованы при формировании диагностического заключения [1].

Диагностика нервно-мышечных заболеваний является одной из самых трудных проблем неврологии. Схожесть клинических симптомов различных нервно-мышечных заболеваний затрудняет постановку диагноза, поэтому решение задач топической диагностики во многом ложится на электромиографические (ЭМГ) методы исследования.

Анализ электромиограмм включает в себя оценку формы, амплитуды и длительности потенциалов действия отдельных мышечных волокон и двигательных единиц (ДЕ), характеристику интерференционной активности, возникающей при произвольном сокращении мышцы [2]. Среди электромиографических методов наиболее широкое применение нашла стимуляционная ЭМГ, в основе которой лежит регистрация суммарного ответа мышцы или нерва в ответ на стимуляцию импульсом электрического тока. При этом проводится анализ параметров вызванных биопотенциалов (ВП) мышц и нервов: потенциала двигательных единиц, М-ответа, Н-рефлекса, F-волны, латентного периода, формы, амплитуды, длительности ВП, динамики его изменения при постепенном нарастании силы раздражения; определение скорости проведения импульса; расчет ряда коэффициентов, специфичных для стимуляционного метода исследования [3], [4].

В отличие от других электрофизиологических методов функциональной диагностики (ЭКГ, ЭЭГ,

ЭОГ и др.) следует отметить ряд особенностей ЭМГ-исследования при диагностике состояния нервно-мышечной системы: большое количество объектов исследования (наличие в организме более 300 мышц) различного типа, исследование проводящей функции моторных, сенсорных и вегетативных аксонов периферических нервов, а также определение функционального состояния нервно-мышечной передачи. Наличие этих и ряда других особенностей ЭМГ-методов исследования создает сложности для реализации неинвазивных электромиографических компьютерных систем по сравнению с другими диагностическими системами.

Проведение ЭМГ-исследования предполагает в первую очередь выбор метода исследования и соответствующих электродов в зависимости от исследуемой мышцы. Выбор метода в каждом конкретном случае зависит от цели исследования и текущего состояния мышечной системы, которое врач определяет на основании проведенных исследований и личного опыта.

Стандартная схема проведения ЭМГ-исследований представлена на *рис. 1*.

Отсутствие детальной базы данных по патологиям нервно-мышечных заболеваний, а также необходимость учета возрастного фактора создают дополнительные трудности при постановке диагноза с помощью компьютерных систем. Учитывая эти трудности, при реализации компьютерной диагностической системы предлагается использовать нейронные сети для обработки измеряемых электромиографических параметров (*рис. 1*).

Нейросетевой подход к диагностике состояния человека находит широкое применение в электрокардиографии, электроэнцефалографии, генетике, при лечении раковых заболеваний и др. [5]-[8]. Весьма перспективным, на наш взгляд, является нейросетевой подход и в электромиографии.

Нейронные сети представляют собой нелинейные системы, позволяющие гораздо лучше классифицировать данные, чем обычно используемые линейные методы [9], [10]. В приложении к медицинской диагностике они дают возможность значительно повысить роль специфичности метода, не снижая его чувствительности [11].

Прежде чем приступить к диагностической процедуре, требуется найти информационные параметры изучаемого биологического объекта.

Анализ существующих медико-технических программно-аппаратных комплексов с применением

искусственных нейронных сетей [12]-[15] показывает, что имеющиеся системы, как правило, в качестве входных параметров используют целый ряд статистических показателей либо ставится задача разделения входных данных только на два класса (здоровые и с патологией соответствующих мышц).

Поскольку в нейросетевых приложениях исключительную важность приобретают вопросы отбора значимых входных переменных и сжатия информации в меньшее число переменных, предлагаются две структуры нейросетей различного типа, в разной степени соответствующие биологическому объекту. В первой структуре в качестве входных параметров использованы исходные симптомы, полученные при измерении ответных сигналов на электростимуляцию мышц, во второй структуре – флуктуационные индексы, полученные при вейвлет-анализе амплитудно-частотных характеристик ЭМГ-активности мышц. Определение значимости измеренных параметров и рассчитанных показателей флуктуационного анализа приводит к упрощению структур рассматриваемых искусственных нейросетей.

Любая непрерывная функция от  $n$  переменных может быть представлена в виде теоремы Колмогорова, которая подразумевает, что для реализации функций многих переменных достаточно операций суммирования и композиции функций одной переменной [16]:

$$F(x_1, x_2, \dots, x_n) = \sum_{j=1}^{2n+1} g_j \left( \sum_{i=1}^n h_{ij}(x_i) \right) \quad (1)$$

где  $g_j$  и  $h_{ij}$  – непрерывные функции, причем  $h_{ij}$  не зависят от функции  $F$ .

Если перевести выражение (1) на язык нейронной сети, то оно будет означать, что если известны функции  $h_{ij}$ , то любую непрерывную функцию от  $n$  переменных можно точно реализовать с помощью простой нейросети на основе трехслойного персептрона. Для этого достаточно подобрать  $2n + 1$  передаточных функций  $g_j$  нейронов скрытого слоя.

Вопрос прогнозирования с помощью нейросети в общем случае сводится к упорядочиванию полученных данных, и на основании анализа тенденций изменения влияющих факторов можно оценить последующие значения данных. Прогнозируемый коэффициент – это значение, находящееся во временном интервале  $[T(n+1), T(n+f)]$ , где  $T(n)$  – текущий момент времени;  $f$  – интервал прогнозирования.

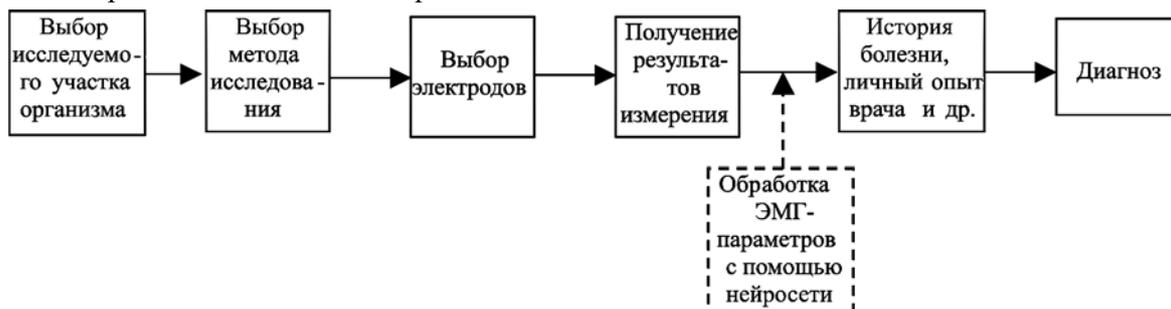


Рис. 1. Схема последовательности проведения ЭМГ-исследований

Для качественного решения задачи диагностики состояния обучающая выборка должна обладать свойством репрезентативности, что означает равномерность включения в нее описаний состояния различных типов [17]. Чем больше разнотипных ситуаций включено в обучающую выборку, тем большим примерам она будет обучена и тем больше вероятность правильного диагностирования состояния исследуемого органа. Следовательно, высокая репрезентативность обучающей выборки позволяет уменьшить средний риск принятия решения. Блок-схема алгоритма формирования репрезентативной обучающей выборки приведена на рис. 2.



Рис. 2. Алгоритм формирования репрезентативной обучающей выборки

Реализация алгоритма подразумевает выполнение следующих этапов:

- таблица примеров в соотношении, заданном экспертом, случайным образом разделяется на обучающую и контрольную выборку;
- на выделенной обучающей выборке настраиваются несколько нейросетей с различной структурой и параметрами;
- обученные нейросети тестируются на контрольной выборке: если ошибки, допускаемые всеми или большинством нейросетей, происходят на одних и тех же примерах, то осуществляется переход к следующему шагу алгоритма, в противном случае работа алгоритма завершается;
- объекты контрольной выборки, на которых допускается большое число ошибок, переносятся в обучающую выборку, а из обучающей выборки в контрольную переносится такое же количество случайно выбранных объектов.

Рассмотрим возможности применения метода обработки и анализа с использованием нейронной сети при регистрации стимуляционной ЭМГ пациентов с нормальным состоянием нервно-мышечной

системы и следующими мышечными синдромами: карпальным туннельным синдромом, кубитальным туннельным синдромом и демиелинизирующей полиневропатией. Карпальный туннельный синдром – это локальное сдавливание срединного нерва в карпальном канале (самый распространенный синдром). Кубитальный туннельный синдром – локальное сдавливание локтевого нерва на уровне локтя в кубитальном канале (распространенность синдрома очень высокая). При демиелинизации поражается или утрачивается миелиновая оболочка моторных или толстых сенсорных волокон, что может привести к невозможности формирования потенциала действия и возникновению блока проведения. Демиелинизирующее поражение нерва клинически проявляется развитием мышечной слабости [4].

Для ЭМГ-сигналов рассматриваемой совокупности заболеваний приведены примеры, полученные с электромиографа «VIASYS MEDELEC» с учетом пиковой амплитуды моторного ответа, латентного периода, скорости проведения сигнала и расстояния между электродами. По рекомендации Международной федерации клинической нейрофизиологии исследования проводились по амплитуде негативной фазы, так как ее форма более постоянна (в электрофизиологии общепринято считать негативным отклонение сигнала вверх от средней линии, а позитивным – вниз).

Отметим, что для исследования выбрана совокупность электромиограмм с указанными мышечными синдромами пациентов в возрастном диапазоне 45-55 лет.

При проведении эксперимента рассмотрены два варианта нейронных сетей в зависимости от типа входных сигналов сети: 1) результаты, полученные от измеряемого прибора; 2) вейвлет-пакетные коэффициенты, полученные на основе вейвлет-пакетного разложения ЭМГ-сигналов, используемые для анализа сложных нестационарных сигналов и несущие достаточно содержательную информацию об исследуемом сигнале.

**Первый вариант.** Реализация эксперимента проводилась на сетевом эмуляторе NeuroPro. NeuroPro0.25 бета-версия дает возможность реализовать следующие базовые операции:

- создание нейропроектов;
- соединение файлов данных нейропроектом;
- добавление в нейронные проекты слойных архитектур от 1 до 10 слоев, до 100 нейронов в каждом слое;
- обучение нейронной сети для решения задач прогнозирования и классификации;
- тестирование нейронной сети на основе файлов базы данных, вычисление показателей значимости входных сигналов;
- упрощение нейронной сети;
- выбор алгоритмов обучения, определение прогнозирования по заданной точности и др.

Эта программа обладает следующими преимуществами, которые относятся только к NeuroPro:

- небольшая емкость архива нагрузки (2124 кбайт);
- бесплатное распространение;

- простой интерфейс и наличие справочных материалов;
- наличие небольших компьютерных ресурсов;
- простота использования.

При стимуляционной ЭМГ в зависимости от типа измерительного эксперимента можно получить результаты о различных типах нервно-мышечной системы. В используемом приборе результаты измерения получают при отведениях минимум с 16 точек, число отведений можно увеличить в зависимости от тяжести патологии. В исследуемых мышцах измерялась проводимость нервов *n.medianus* и *n.ulnaris*.

С учетом следующих обозначений были выбраны измеряемые информативные параметры:

- сенсорный (sensor) – S;
- моторный (motor) – M;
- запястье (wrist) – W;
- локоть (elbow) – E;
- латентность (latency) – L;
- амплитуда (amplitude) – A;
- скорость (velocity) – V.

Таблица 1

№ п/п	Последовательность получения входных сигналов	Поля базы данных (исходные симптомы)	Поля базы данных (конечные синдромы)
1	Sensor-wrist-n.medianus-latency	SWML	OUTPUT
2	Sensor-wrist-n.medianus-amplitude	SWMA	
3	Sensor-wrist-n.medianus-velocity	SWMV	
4	Sensor-wrist-n.ulnaris-latency	SWUL	
5	Sensor-wrist-n.ulnaris-amplitude	SWUA	
6	Sensor-wrist-n.ulnaris-velocity	SWUV	
7	Motor-wrist-n.medianus-latency	MWML	
8	Motor-wrist-n.medianus-amplitude	MWMA	
9	Motor-wrist-n.ulnaris-latency	MWUL	
10	Motor-wrist-n.ulnaris-amplitude	MWUA	
11	Motor-elbow-n.medianus-latency	MEML	
12	Motor-elbow-n.medianus-amplitude	MEMA	
13	Motor-elbow-n.medianus-velocity	MEMV	
14	Motor-elbow-n.ulnaris-latency	MEUL	
15	Motor-elbow-n.ulnaris-amplitude	MEUA	
16	Motor-elbow-n.ulnaris-velocity	MEUV	

Исходные симптомы сети в зависимости от места проведения измерения, выбранного нерва и информативного параметра приведены в *табл. 1*.

Предобработка входных полей базы данных для подачи в сеть была рассчитана по формуле

$$I = (I - a_i) / b_i, \quad (2)$$

где  $I$  – входное число;  $a_i, b_i$  – коэффициенты, вычисленные для каждого входа. Таким образом, предобработка входных полей базы данных проводится по формулам

$$SWML = (SWML - 3,075) / 1,075;$$

$$SWMA = (SWMA - 11,8) / 4,400001;$$

$$SWMV = (SWMV - 40,75) / 14,25;$$

$$SWUL = (SWUL - 1,775) / 0,07499999;$$

$$SWUA = (SWUA - 11,65) / 3,15;$$

$$SWUV = (SWUV - 53,7) / 5,1;$$

$$MWML = (MWML - 4,575) / 2,025;$$

$$MWMA = (MWMA - 7,55) / 2,45;$$

$$MWUL = (MWUL - 2,5) / 0,2;$$

$$MWUA = (MWUA - 9,75) / 2,45;$$

$$MEML = (MEML - 8,675) / 2,075;$$

$$MEMA = (MEMA - 6,45) / 2,35;$$

$$MEMV = (MEMV - 54,95) / 4,35;$$

$$MEUL = (MEUL - 6,725) / 0,47499999;$$

$$MEUA = (MEUA - 9,25) / 2,15;$$

$$MEUV = (MEUV - 53,65) / 6,85.$$

Для скрытых слоев сети, которые содержат по 10 нейронов в каждом слое, использовались нейроны с сигмоидальной функцией активации, а их нелинейность была рассчитана по формуле

$$f(X) = X / (c + |X|), \quad (3)$$

где  $c$  – характеристика сети, равная 0,1.

Следовательно, по выражению (3) функциональные преобразователи рассчитываются как

$$\text{Сигмоида1}(A) = A / (0,1 + |A|);$$

$$\text{Сигмоида2}(A) = A / (0,1 + |A|);$$

$$\text{Сигмоида3}(A) = A / (0,1 + |A|).$$

Выход сети OUTPUT содержит четыре элемента:

- 1 – норма;
- 2 – полиневропатия;

- 3 – карпальный туннельный синдром;
- 4 – кубитальный туннельный синдром.

Конечные синдромы вычислены следующим образом:

$$\text{OUTPUT} = -0,4264991 \cdot \text{Синдром3\_1} + 0,09814772 \times \times \text{Синдром3\_2} - 0,0857696 \cdot \text{Синдром3\_3} + 0,2530626 \times \times \text{Синдром3\_4} + 0,1842339 \cdot \text{Синдром3\_5} + 0,5904834 \times \times \text{Синдром3\_6} - 0,182115 \cdot \text{Синдром3\_7} - 0,08779884 \times \times \text{Синдром3\_8} - 0,2971794 \cdot \text{Синдром3\_9} + 0,2773772 \times \times \text{Синдром3\_10} - 0,358493.$$

Постобработка конечных синдромов имеет вид  $\text{OUTPUT} = [(\text{OUTPUT} \cdot 3) + 5] / 2$ .

Полученный результат выходного параметра контрольного измерения после обучения сети приведен на рис. 3.

№	OUTPUT	Прогноз сети	Ошибка
1	1	0,8340689	0,1659311
2	2	2,289162	-0,2891622
3	3	2,765857	0,2341425
4	4	3,99793	0,00206995
5		0,8126549	

Рис. 3. Результаты тестирования после обучения сети

Из рисунка видно, что при сравнении результата контрольной выборки с результатами обучающей выборки полученное значение соответствует в большей степени выходу «1», т. е. состоянию «норма».

Как было отмечено выше, нейронные сети дают возможность оптимизировать число входных параметров, так как большое число отведений в медицинских экспериментах нежелательно, что связано с продлением времени эксперимента и возможностью появления чувства боли у пациента.

Полученные величины значимости входных параметров сети приведены на рис. 4.

Сигнал	Значимость
SWML	0,2876602
SWMA	0,130038
SWMV	0,1285869
SWUL	0,867874
SWUA	0,5318841
SWUV	0,3586732
MWML	0,2798353
MWMA	0,4700535
MWUL	0,3995281
MWUA	0,3391646
MEML	0,3424162
MEMA	0,08148972
MEMV	0,279988
MEUL	1
MEUA	0,6084953
MEUV	0,438398

Рис. 4. Степень значимости входных параметров

Из рис. 4 видно, что из 16 входных параметров сети только четыре – MEUL, SWUL, SWUA и MEUA имеют самые значимые величины для исследуемых объектов, что позволяет выделить самые

важные оценки из рассматриваемого количества входных параметров нейросетевой модели.

**Второй вариант.** Для вычислительного эксперимента была выбрана перцептронная трехслойная сеть с прямыми связями, стандартным алгоритмом обучения которой является алгоритм обратного распространения ошибки (Back Propagation), а в качестве входных параметров нейросети были выбраны флуктуационные индексы  $\sigma^{(n)}$ , характеризующие степень хаотичности исследуемой нервно-мышечной системы [18].

По значению этого показателя можно также классифицировать различные виды заболеваний нервной системы, поскольку графики функций  $\sigma^{(n)}$  в зависимости от  $n$  ( $n$  – количество сегментов, на которые разбивается негативная фаза реализации ЭМГ-сигнала) естественным образом разделяются и упорядочиваются. По результатам проведенных исследований была построена зависимость флуктуационного индекса  $\sigma^{(n)}$  от  $n$  для различных значений разрешающей способности  $m$  вейвлет-пакетного разложения ЭМГ-сигналов (табл. 2, рис. 5).

Таблица 2

Норма	Карпальный туннельный синдром	Кубитальный туннельный синдром	Полиневропатия
0,1049192	0,097014826	0,105811505	0,137681954
0,0078617	0,013601282	0,024258852	0,010557692
0,0108053	0,009436098	0,015074196	0,012498342
0,090638	0,089206841	0,07671701	0,090540411

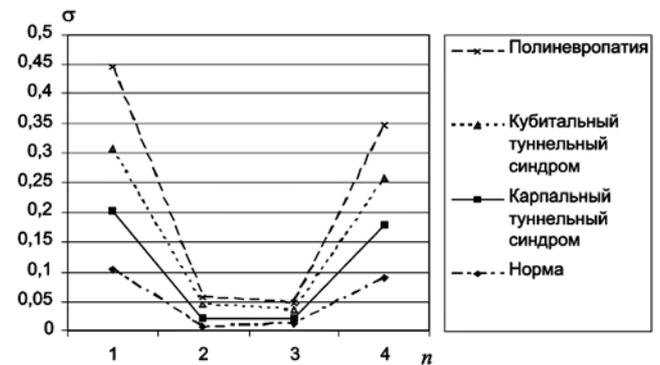


Рис. 5. Зависимость флуктуационного индекса  $\sigma^{(n)}$  от  $n$  для  $m = 5$  вейвлет-пакетного разложения ЭМГ-сигналов

В результате проведенных исследований было определено, что увеличение разрешающей способности  $m$  вейвлет-пакетного разложения увеличивает степень сепарации значений флуктуационного индекса для рассматриваемых заболеваний. Для рассматриваемой совокупности заболеваний наибольшее значение  $\sigma^{(n)}$  достигается для наиболее патологического заболевания (в нашем примере это – демиелинизирующая полиневропатия).

В вычислительном эксперименте в качестве входов сети выбраны флуктуационные индексы  $\sigma^{(n)}$ , рассчитанные для  $m = 5$ . В этом случае сеть имеет 4 входа, соответствующие значениям  $n = 1, 2, 3, 4$

(S1, S2, S3, S4), один выход N5 (табл. 3). Выход содержит четыре субвыхода: норма и выбранные типы заболеваний. Сеть имеет три скрытых слоя по 10 нейронов в каждом слое.

Таблица 3

№ п/п	Поля базы данных (исходные симптомы)	Поля базы данных (конечные синдромы)
1	S1	N5
2	S2	
3	S3	
4	S4	

Предобработка входных полей и постобработка конечных синдромов аналогична соответствующим процедурам для первого варианта нейросети.

Результаты тестирования после обучения сети показаны на рис. 6.

№	N5	Прогноз сети	Ошибка
1	1	1,286467	-0,2864673
2	2	1,800595	0,1994054
3	3	2,733182	0,2668183
4	4	3,746053	0,2539473
5		1,299243	

Рис. 6. Результат тестирования после обучения сети

Значение конечного синдрома в контрольной выборке соответствует в большей степени выходу «1», т. е. состоянию «норма». Из полученных результатов вычислительных экспериментов видно, что сеть с входными параметрами, где использованы флуктуационные индексы, дает возможность получить результаты с точностью  $\pm 0,01$ , а сеть с входными измеряемыми параметрами – с точностью  $\pm 0,02$ .

Значимость входных сигналов для второго варианта нейронной сети приведена на рис. 7.

Сигнал	Значимость
S1	1
S2	0,8459265
S3	0,2941461
S4	0,998985

Рис. 7. Значимость входных сигналов

Из рис. 7 видно, что значимость входа S3 мала; это связано с тем, что зависимость  $\sigma^{(n)}$  от  $n$  для  $n = 3$  (S3) почти совпадает со значением для  $n = 2$  (S2), см. рис. 5.

Сравнив результаты тестирования (рис. 4 и 7), можно сделать вывод, что значимые входные сигналы в первом варианте составляют всего 25 % от общего количества входных параметров. Флуктуационные коэффициенты, сохранившие все информативные свойства сигнала, дают 75 % значимости для входа.

В первом варианте время обучения составило порядка 240 с, во втором – 135 с. Максимальная

ошибка сети в обоих вариантах составила порядка 0,05, степень обучения – порядка 0,001.

Таким образом, по результатам проведенных измерительных и вычислительных экспериментов можно отметить, что применение нейронных сетей эффективно для диагностического анализа при обработке ЭМГ-сигналов и установления значимости входных параметров. Флуктуационный индекс, как достаточно информативный показатель хаотичности поведения нервно-мышечной системы, может быть использован в качестве входного параметра нейронной сети.

Поскольку использование искусственных нейронных сетей предполагает выбор оптимальной (обычно с точки зрения прогностической способности) структуры из множества моделей, то предлагаемые диагностически значимые показатели позволяют значительно упростить топологию обоих вариантов сетей для прогнозирования в условиях измерительно-вычислительных экспериментов при сохранении высокой точности предсказаний по данным обучающей выборки и при достаточно высокой скорости обучения.

Список литературы:

1. Рангайян Р.М. Анализ биомедицинских сигналов. Практический подход. – М.: Физматлит, 2007. 440 с.
2. Гехт Б.М., Ильина Н.А. Нервно-мышечные болезни. – М.: Медицина, 1982. 352 с.
3. Зайченко К.В., Жаринов О.О. и др. Съём и обработка биоэлектрических сигналов. – СПб.: СПбГУАП, 2001. 140 с.
4. Касаткина Л.Ф., Гильванова О.В. Электромиографические методы исследования в диагностике нервно-мышечных заболеваний. Игольчатая электромиография. – М.: Медика, 2010. 416 с.
5. Neural Network Projects in Medicine / www.emsl.pnl.gov:2080/docs/cie/neural/projects/medicine.html.
6. Artificial Neural Networks in Medicine / www.dsclab/ece.ntua.gr/~kblekas/medical2.html.
7. Neural Networks in Medicine / www.dse.doc.ic.ac.uk/~nd/.../journal/vol2/ds12/article1.html.
8. Абдуллаев Н.Т., Дышин О.А., Самедова Х.З. Применение нейронных сетей для выявления артефактов электроэнцефалографического сигнала, представленного вейвлет-пакетным отображением // Медицинская техника. 2009. № 4. С. 42-46.
9. Галушкин А.И. Теория нейронных сетей. – М.: ИПРЖР, 2000. 416 с.
10. Головкин В.А. Нейронные сети: обучение, организация и применение. – М.: ИПРЖР, 2001. 256 с.
11. Ежов А.А., Четкин В.Р. Нейронные сети в медицине. // Открытые системы. 1997. № 4. С. 34-37.
12. Боровиков В.П. Нейронные сети. Statistika Neural Networks. Методология и технологии современного анализа. – М.: Горячая линия-Телеком, 2008. 392 с.
13. Евдокименков В.Н. Компьютерные технологии сбора, обработки и анализа данных медико-биологических исследований. – М.: МАИ, 2005. 436 с.
14. <http://www.airportal.ru/articles/neural-networks/back-propagation.html>.

15. Богинич А.В., Морнев М.Л., Попов В.Ю. Построение высокопроизводительного сервиса интеллектуальной обработки медицинской информации для оценки электромиографических исследований поперечно-полосатых мышц / Материалы IX Международной конференции-семинара «Высокопроизводительные параллельные вычисления на кластерных системах». – Владимир, 2009.
16. Медицинская компьютерная диагностика / <http://dvo.sut.ru/libr/biomed>.
17. Богомолов А.В., Гридин Л.А., Кукушкин Ю.А., Ушаков И.Б. Диагностика состояния человека: математические подходы. – М.: Медицина, 2003. 464 с.
18. Сидоренко А.В., Селицкий А.П., Казакевич В.Б., Леончик Ю.Л. Нелинейный анализ стимуляционных электромиограмм на основе вейвлет-преобразования // Биомедицинская радиоэлектроника. 2009. № 1. С. 56-63.

Абдуллаев Намик Таир оглы,  
канд. техн. наук, зав. кафедрой,  
Исмайлова Кямаля Ширин кызы,  
ассистент,  
кафедра «Биотехнические и  
медицинские приборы»,  
Азербайджанская государственная академия,  
г. Баку,  
e-mail: anatik46@mail.ru

Д.В. Тельшев

## АДАПТИВНЫЙ КОМПЛЕКСНЫЙ АЛГОРИТМ ОПРЕДЕЛЕНИЯ ШОКОВЫХ РИТМОВ СЕРДЦА ДЛЯ ИСПОЛЬЗОВАНИЯ В АВТОМАТИЧЕСКИХ НАРУЖНЫХ ДЕФИБРИЛЛЯТОРАХ

### Аннотация

Параметры чувствительности и специфичности алгоритма определения шоковых ритмов сердца в автоматических наружных дефибрилляторах должны находиться на уровне, близком к 100 %. Для достижения данных значений предложен метод синтеза алгоритмов на основе использования весовых коэффициентов и коэффициентов эффективности. Алгоритмы тестировались на аннотированных базах данных сигналов ЭКГ (АНА, MIT, CU).

Россия занимает одно из ведущих мест в мире по количеству смертей от сердечно-сосудистых заболеваний [1]. Смерть от внезапной остановки сердца наступает более чем в 80 % случаев за пределами клиники. Автоматические наружные дефибрилляторы (АНД) предназначены для устранения жизнеугрожающих аритмий при внезапной остановке сердца. АНД применяются для проведения сердечно-легочной реанимации как внутри, так и за пределами клиники, поскольку не требует присутствия квалифицированного медицинского персонала. Во время процедуры дефибрилляции через грудную клетку пациента пропускают мощный электрический импульс продолжительностью несколько миллисекунд. С каждой минутой задержки дефибрилляции вероятность успешного восстановления сердечного ритма снижается приблизительно на 7...10 %. Основным элементом процессора АНД является алгоритм определения шоковых ритмов сердца (ШРС). От параметров чувствительности и специфичности алгоритма интегрированного в программное обеспечение дефибриллятора зависит, насколько точно будет определен ритм сердца, а значит, и насколько эффективна процедура дефибрилляции. Существует большое количество алгоритмов определения ШРС [2], [3]. Развитие вычислительной техники позволило использовать несколько методов определе-

ния ШРС в комплексе [4], [5], при этом итоговая эффективность алгоритмов возросла. Возможность применения нескольких методов в комплексе ставит перед исследователями актуальный вопрос их комбинирования в результирующем алгоритме для увеличения результирующих показателей чувствительности и специфичности [6]. Целью данной работы являлось создание комплексного алгоритма определения ШРС, основанного на адаптации алгоритма к изменению исследуемых параметров в выбранных методиках. Данный подход основан на том, что каждая методика вносит свой вклад в результирующий алгоритм и этот вклад напрямую зависит от изменения сигнала ЭКГ.

### Методика

Основными параметрами, определяющими достоверность работы алгоритма распознавания ШРС, являются чувствительность и специфичность. Чувствительность задается отношением  $TP / AP$ , где  $TP$  – число правильно распознанных эпизодов ШРС;  $AP$  – общее число эпизодов ШРС в анализируемом сигнале. Специфичность задается отношением  $TN / AN$ , где  $TN$  – число правильно распознанных эпизодов нешокового ритма сердца (НШРС);  $AN$  – общее число эпизодов НШРС в анализируемом сигнале.