

**НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ ТОМСКИЙ  
ПОЛИТЕХНИЧЕСКИЙ УНИВЕРСИТЕТ**

На правах рукописи

**ДЕВЯТЫХ ДМИТРИЙ ВЛАДИМИРОВИЧ**

**МОДЕЛЬ, АЛГОРИТМЫ И КОМПЛЕКС ПРОГРАММ ДЛЯ  
НЕИНВАЗИВНОЙ ФЕТАЛЬНОЙ ЭЛЕКТРОКАРДИОГРАФИИ**

Специальность 05.13.18 – «Математическое моделирование, численные  
методы и комплексы программ»

**ДИССЕРТАЦИЯ**

на соискание ученой степени  
кандидата технических наук

Научный руководитель:  
кандидат технических наук, доцент  
Гергет Ольга Михайловна

**ТОМСК – 2016**

Список сокращений .....	4
Введение.....	5
Глава 1. Обзор методов выделения электрокардиограммы плода.....	11
1.1 Состояние неинвазивной, фетальной электрокардиографии .....	11
1.2 Способ регистрации абдоминальной электрокардиограммы.....	12
1.3 Частотно-временной анализ частоты сердечных сокращений плода.	13
1.4 Адаптивная линейная фильтрация абдоминальных электрокардиограмм .....	19
1.5 Применение вейвлет анализа для обработки абдоминальных электрокардиограмм .....	24
1.6 Модель слепого разделения источников и анализ независимых компонент .....	31
1.7 Применение аппарата искусственных нейронных сетей для выделения электрокардиограммы плода .....	38
1.8 Выбор метода моделирования на основе анализа преимуществ и недостатков рассмотренных методов .....	45
1.9 Выводы по главе.....	49
Глава 2. Модель и численная реализация оценки состояние сердечной активности плода.....	50
2.1 Модель электрокардиограммы плода на основе синтеза слепого разделения источников и нейронных сетей .....	50
2.2 Неявное представление времени в нейронной сети с краткосрочной памятью .....	53
2.3 Обратное распространение ошибки во времени для обучения развернутой нейронной сети.....	60
2.4 Проблемы обучения динамических сетей .....	65
2.5 Численный метод Resilient propagation и его модификация для глубокого, динамического обучения развернутой нейронной сети .....	69
2.6 Выводы по главе.....	75
Глава 3. Результаты вычислительных экспериментов .....	76

3.1 Формирование обучающей и тестирующей выборок .....	76
3.2 Влияние свободных параметров сети на качество выделения ЭКГ ....	78
3.3 Проверка адекватности модели .....	90
3.4 Программный комплекс для неинвазивного выделения электрокардиограммы плода .....	96
3.5 Сравнение с аналогами слепого разделения источников, анализ независимых компонент.....	104
3.6 Сравнительный анализ эффективности алгоритмов обучения .....	109
3.7 Выводы по главе.....	111
Заключение .....	113
Список литературы: .....	116

## Список сокращений

BSS – Blind Source Separation, слепое разделение источников

ICA – Independent component analysis, анализ независимых компонент

NARX – Non-linear autoregressive model with exogenous inputs, модель нелинейной авторегрессии с внешними входами

FTDNN – Focused time delay neural network, нейронная сеть с фокусированной задержкой времени

DTDNN – Distributed time delay neural network, нейронная сеть с распределенной задержкой времени

RProp – Resilient propagation

RPTT – Resilient propagation through time

LVM – Levenberg-Marquardt, метод Левенберга-Марквардта

SCG – Scaled conjugate gradients, метод сопряжённых градиентов

ЭКГ – Электрокардиограмма

ЭКГП – Электрокардиограмма плода

АЭКГ – Абдоминальная электрокардиограмма

АМП – Отношение амплитуды R-зубцов матери и плода в АЭКГ

## Введение

Актуальной проблемой антенатальной диагностики является оценка состояния сердечной активности плода. Необходимость в мониторинге плода во время антенатального периода возникает достаточно часто, особенно в случае, когда течение беременности сопряжено с проблемами и осложнениями. Общепринятой мерой оценки функции сердечно-сосудистой системы является изучение частоты и вариабельности сердечных сокращений.

Ультразвуковая доплерография, основанная на регистрации механических движений сердца плода, при своей достаточной простоте и относительной доступности, имеет ряд серьезных недостатков. Такой тип воздействия на плод нельзя считать абсолютно нейтральным. Результат ультразвукового исследования не является отражением первичных биоэлектрических процессов. В ходе проведения процедуры необходимо постоянно отслеживать положение и перемещение плода, периодически изменяя положение датчика. Эти и другие особенности ограничивают как частоту, так и длительность ультразвукового исследования плода.

Альтернативным способом исследования сердечной активности плода является электрокардиография. Инвазивная форма исследования обеспечивает получение достоверных результатов, но требует наложения электродов на головку плода и поэтому может использоваться только при родах. Неинвазивная электрокардиография плода основывается на регистрации материнских кардиосигналов в абдоминальных отведениях с последующим разделением сигналов на источники. Такой подход является абсолютно безвредным, что позволяет проводить даже суточное мониторирование. Выделение фетальной (плодовой) составляющей осложняется низкой, относительно материнской, амплитудой QRS-комплексов. Преобладание материнской составляющей в совокупности с помехами, вносимыми измерительной аппаратурой и респираторной активностью матери, снижает соотношение сигнал-шума анализируемого сигнала.

Вопросы моделирования биомедицинских сигналов и слепого разделения источников рассмотрены в работах ученых: Засов В.А., Никоронов Е.Н. (Самарский государственный университет путей сообщения) [1-2]; Фролов А.В., Мрочек А.Г., (РНПЦ «Кардиология», Минск, Беларусь), Войтович А.П., Войтикова М.В. (Институт физики, Минск, Беларусь) [3]; Савостьянов Д.В., Оселедец И.В. (Институт вычислительной математики РАН) [4]; Самородов А.В., Захаров И.В. (каф. «Биомедицинские технические системы», МГТУ им. Н.Э. Баумана) [5]; Пеккер Я.С., Толмачев И.В. (кафедра медицинской и биологической кибернетики СибГМУ) [6]; Кодкин В.Л., Дубель А.М., Цывьян П.Б. (Национальный аэрокосмический университет «ХАИ». - Харьков) [7]; и др. В том числе и зарубежных: G.D. Clifford (Institute of Biomedical Engineering, University of Oxford) [8-9]; M.A. Hasan (Dept. of Electrical and Computer Engineering, Ryerson University) [10]; M. Reaz (Department of Electrical, Electronic and Systems Engineering, University Kebangsaan Malaysia) [11]; A. Kam, A. Cohen (Dept. of Electr. & Comput. Eng., Ben-Gurion Univ. of the Negev, Beer-Sheva, Israel) [12]; и др.

### **Цель исследования**

Целью исследования является разработка модели электрокардиограммы плода, алгоритма слепого разделения источников абдоминального сигнала и комплекса программ неинвазивной электрокардиографии для повышения надежности определения сердечной активности плода.

Для достижения цели решается ряд **задач**:

1. Обзор существующих моделей электрокардиограмм и алгоритмов неинвазивной диагностики сердечной активности плода;
2. Разработка модели электрокардиограммы и численного метода решения описывающих ее уравнений;
3. Разработка программного обеспечения, в рамках которого проводились исследования и реализовывались математическая модель и численный метод;
4. Получение собственных экспериментальных результатов на основе биомедицинских данных беременных женщин с различными сроками

беременности; анализ синхронизированных абдоминальных сигналов с различных отведений и электрокардиограмм плода, полученных через инвазивную электрокардиографию;

5. Статистический и корреляционный анализ RR-интервалов плода, полученных инвазивным способом и выделенных из абдоминальных сигналов;
6. Исследование влияния длительности анализируемого сигнала, вариабельности сердечного ритма и выбора точки отчета на адекватность модели.

### **Научная новизна**

1. Новая нелинейная, динамическая модель электрокардиограммы плода, полученная посредством синтеза модели слепого разделения источников и глубокой нейронной сети с перекрестными связями;
2. Модифицированный численный метод минимизации целевой функции нейронной сети, определяющий коррекцию весового коэффициента в зависимости от динамики знака суммы частных производных по всем моментам времени;
3. Программный комплекс для неинвазивной электрокардиографии на основе предложенных в работе оригинальной модели и численного метода, новизну которого определяет взаимосвязь между подсистемой обучения нейронной сети и краткосрочной памятью.

### **Методы исследования**

Проведенные в диссертационной работе исследования основаны на использовании методов вычислительной математики, теории вероятностей и математической статистики, а также прикладного программирования.

### **Степень достоверности результатов**

Исследования адекватности модели подтверждают достоверность полученных результатов. Это было установлено: путем сравнения реакции предложенной модели и известного аналога разделения источников на реальные сигналы; большим количеством экспериментальных данных; проверкой

статистических гипотез о равенстве распределения RR-интервалов выходного сигнала модели и желаемого отклика.

### **Объект исследования**

Исследуемым объектом является электрокардиограмма плода.

### **Предмет исследования**

Модель слепого разделения источников абдоминальной электрокардиограммы и численные методы определения параметров модели.

### **Практическая значимость**

Модель выполняет разделение источников абдоминального сигнала в «слепом» режиме, при котором используется минимум информации о типе источников и характере их смешивания. Для оценки сердечной активности плода достаточным является наличие сигналов, зарегистрированных лишь в абдоминальном отведении. В отличие от известных подходов к слепому разделению источников, разработанная модель не предъявляет принципиальных требований, как к размерности входного сигнала, так и к равенству размерностей векторов источников и наблюдений. Это определяет возможность выделения электрокардиограммы плода из абдоминальных сигналов, зарегистрированных как в одном, так и в нескольких отведениях.

Разработанный алгоритм обучения позволяет находить весовые коэффициенты динамических нейронных сетей в зависимости от динамики знака суммы производных целевой функции по всем весам, совместно используемым нейронами, полученными в результате развертывания. Таким образом, решаются проблемы, вызванные линейностью обратного распространения – обучение глубоких слоев долгосрочным зависимостям сети и обращение градиентов в ноль.

Примененный в работе параллельный способ развертывания позволяет динамическим нейронным сетям использовать реальные предыдущие выходные сигналы при обучении. Параллельно развернутая обученная нейронная сеть является более устойчивой к вариабельности морфологических характеристик QRS-комплексов относительно сетей, обученных в режиме параллельно-последовательного развертывания.



## **Положения, выносимые на защиту**

1. Модель электрокардиограммы плода позволяет выделить источники абдоминальной электрокардиограммы, полученной в результате нелинейного и нестационарного смешивания, вне зависимости от выборка точки отсчета и длительности сигнала;

*Разработка новых математических методов моделирования объектов и явлений (п.1 паспорта специальности)*

2. При обучении параллельно развернутой динамической нейронной сети с использованием предложенного в работе численного метода достигается значение среднеквадратичной ошибки порядка  $10^{-2}$ , что на порядок меньше по сравнению с алгоритмами обучения Левенберга-Марквардта, сопряженных-градиентов и Rprop;

*Разработка, обоснование и тестирование эффективных вычислительных методов с применением современных компьютерных технологий (п.3 паспорта специальности)*

3. Программный комплекс решает задачу неинвазивной электрокардиографии эффективнее известных аналогов: выделение R-зубцов плода происходит на 20% точнее; среднеквадратичная ошибка частоты сердечных сокращений ниже в среднем на 118 (ударов в мин.)<sup>2</sup>; корень среднеквадратичной ошибки RR-интервалов ниже в среднем на 5 мс.

*Реализация эффективных численных методов и алгоритмов в виде комплексов проблемно-ориентированных программ для проведения вычислительного эксперимента (п.4 паспорта специальности)*

## **Внедрение результатов**

Разработанные модель и программное обеспечение для неинвазивной электрокардиографии плода включены в состав программного обеспечения: Лечебно-оздоровительного центра «Здоровая мама – крепкий малыш»; ОГАУЗ «1-ая детская городская больница города Томска»;

**Апробация**

По материалам диссертации опубликовано 14 работ, из них 5 статей в журналах, входящих в перечень рецензируемых научных журналов и изданий, 4 публикации в материалах международных и всероссийских научных конференций.

## **Глава 1. Обзор методов выделения электрокардиограммы плода**

### **1.1 Состояние неинвазивной, фетальной электрокардиографии**

Впервые электрокардиограмма плода была получена немецким ученым М. Кремером в 1906 г. [13], использовавшим в качестве инструментов гальванометры. Эффективность такого подхода ограничивалась малой амплитудой выделенных R-волн плода. С развитием измерительной и усилительной техники фетальная электрокардиография начала постепенно получать все большее распространение [14,15]. Основным фактором, ограничивавшим ее развитие, было низкое соотношение сигнала-шума в условиях преобладания материнской составляющей. Стоит отметить, что данная проблема актуальна до сих пор [16]. Впервые был предложен электрод [17], позволявший неинвазивно регистрировать электрокардиограмму плода.

С развитием информационных технологий, автоматизации обработки и адаптивной фильтрации сигналов связано появление работ по выделению электрокардиограммы плода (ЭКГП) из абдоминальной электрокардиограммы (АЭКГ) матери [18-20]. Однако, подходы того времени позволяли лишь приблизительно определить частоту сердечных сокращений плода.

На рисунке 1а показана диаграмма, отображающая общее количество работ по теме фетальной электрокардиографии, опубликованных в англоязычной текстовой базе данных медицинских и биологических публикаций PubMed (США), созданной Национальным центром биотехнологической информации. Как видно из рисунка, в 60-х произошел резкий скачок интереса к данной проблеме, вплоть до конца 90-х количество публикаций постепенно уменьшалось. Сегодня данная проблема вновь привлекает внимание ученых, что выражается в увеличении количества публикаций.

Динамика роста количества публикаций по электрокардиографии, не предназначенной для неинвазивной диагностики плода, приведена на рисунке 1б. Сравнение объемов публикаций позволяет сделать вывод об относительно слабой изученности фетальной электрокардиографии.




Рис.1 Количество публикаций по теме а) фетальной электрокардиографии; б) общей электрокардиографии

## 1.2 Способ регистрации абдоминальной электрокардиограммы

Использованные в работе абдоминальные сигналы были получены с помощью прибора КОМПОРЕЛ [21], разработанным в институте медицинских технологий и приборостроения (Забже, Польша). Внедрение прибора проходило на кафедре акушерства медицинского университета Силезии (Польша). Способ наложения электродов представлен на рисунке 2.




Рис. 2 Способ наложения электродов для регистрации АЭКГ с помощью прибора КОМПОРЕЛ

Тип электродов – хлоридосеребряный, модель – 3M Red Dot 2271. Измерительный канал имел полосу пропускания от 1 до 150 Гц. Частота дискретизации 1 кГц с разрешением в 16 бит.

Абдоминальные электроды, обозначенные на рисунке «1-4» были расположены следующим образом: первый электрод – 5см правее пупка; второй электрод – 10см правее пупка; третий электрод – 5см выше пупка; четвертый электрод – 1см левее пупка. Выравнивающий электрод, обозначенный на рисунке

«5» располагался на 10см ниже пупка. Референтный электрод располагался на внешней стороне бедра, его положение на теле обозначено как «6».

### **1.3 Частотно-временной анализ частоты сердечных сокращений плода**

В статье [22] был предложен метод определения частоты сердечных сокращений (ЧСС) плода, который основывался на дискретном преобразовании Фурье абдоминальной электрокардиограммы. Вместо гармонических функций авторы использовали последовательности прямоугольных импульсов, характеризующихся шириной, периодичностью и фазой. Это обосновывалось тем, что прямоугольные волны имеют большую корреляцию с сигналом ЭКГ. После фильтрации материнской составляющей ЧСС плода определялась как максимальное значение функции, полученной в результате интегрирования произведения значений сигнала и анализирующей функции.

Для определения ЧСС авторы рассматривали два подхода: обнаружение пиков; применение преобразования.

В первом случае, рассматривался небольшой отрезок абдоминального сигнала, в котором и происходил поиск плодового R-зубца. Успешность поиска зависела, как от специфики алгоритма поиска R-пиков, так и от соотношения сигнала-шума отрезка АЭКГ. Поскольку абдоминальный сигнал является нестационарным, локальное соотношение сигнал-шума отличается от соотношения, характеризующего весь сигнал, что приводило к пропуску R-пиков плода.

Во втором случае, для определения ЧСС выполнялось преобразование всего абдоминального сигнала. Реальному сигналу ставилась в соответствие некая функция с несколькими параметрами, значение которой в каждый момент времени характеризовало весь сигнал. Это позволило решить проблему пропусков R-пиков плода, вызванную вариабельностью локального соотношения сигнал-шума.

Стандартным преобразованием для выделения скрытых периодических составляющих в сигнале является преобразование Фурье. Из-за очень малого

коэффициента заполнения сигнала ЭКГ наблюдалось низкое значение корреляции между абдоминальным сигналом и анализирующей гармонической функцией, что затрудняло выделение периодических характеристик ЭКГП с использованием классического способа спектрального анализа.

Были выделены некоторые особенности сигнала ЭКГ: имеет малое значение коэффициента заполнения (величина обратная скважности); представляет собой последовательность импульсов, в виде коротких R-волн с высокой амплитудой; является квазипериодическим.

Исходя из вышеперечисленного, авторы пришли к выводу, что обнаружение периодичности с помощью спектрального анализа может быть улучшено при использовании анализирующих функций, отличающихся от гармонических, как в случае с Фурье-преобразованием. Критерием отбора стала корреляция между фетальным сигналом и анализирующей функцией.

### *1.3.1 Исходные данные для неинвазивной электрокардиографии через частотно-временной анализ*

Исходные абдоминальные ЭКГ-сигналы были сняты с женщин на различных сроках беременности. Выбранные для анализа сигналы АЭКГ характеризовались слабо различимыми R-волнами плода на фоне материнской и шумовой составляющих. Частота дискретизации составляла 300 Гц. Работа [22] проводилась в Медицинском центре имени Ицхака Рабина (Израиль).

Тестирование метода проводилось на реальных сигналах, длительность которых составляла от 5-ти до 20-ти секунд. Наивысшая точность определения ЧСС достигалась при длительности сигналов в 10-11 секунд.

Авторы разделили сигналы на 2 группы: в первую входили сигналы АЭКГ, в которых R-волна плода была визуально различима; во вторую были отнесены сигналы со слабо видимой фетальной составляющей.

### 1.3.2 Предварительная обработка исходных данных

На стадии предварительной обработки из абдоминального сигнала была удалена его скользящая средняя с шириной окна равной 60. Данная операция позволила очистить сигнал от низкочастотной шумовой составляющей, приводящей к блужданию базовой линии ЭКГ.

Для удаления материнской составляющей из анализируемого сигнала использовалась сигнал-усредненная материнская ЭКГ. Наложив друг на друга несколько материнских QRS-комплексов таким образом, чтобы их R-пики совпали, был получен усредненный QRS-комплекс. Вычитание искусственно полученного QRS-комплекса матери из реальных сигналов АЭКГ позволило успешно удалить материнскую составляющую из абдоминального сигнала, что показано на рисунке 3.




Рис. 3 Абдоминальная ЭКГ а) до удаления материнской составляющей б) после

### 1.3.3 Анализирующая функция прямоугольных волн

Анализирующая функция  $q(A, T, \Phi, t)$  представляет собой последовательность прямоугольных волн и изображена на рисунке 4. Функция зависит от времени  $t$  и имеет три параметра:  $A$  – ширина;  $T$  – период;  $\Phi$  – фаза.

Каждая функция нормализуется согласно (1):

$$\int_0^{\tau} q(A, T, \Phi, t) dt = 1, \quad (1)$$

где  $\tau$  – определяет ширину окна. Если  $N$  это число полных колебаний, совершаемых  $q$  за время  $\tau$ , то нормализующий коэффициент будет примерно равен  $1/NA$ . Таким образом, авторы [22] пришли к трехпараметрическому преобразованию (2):

$$c(A, T, \Phi) = \int_0^{\tau} f(t) \cdot q(A, T, \Phi, t) dt. \quad (2)$$




Рис. 4 Анализирующая функция  $q(A, T, \Phi, t)$

#### 1.3.4. Определение частоты сердечных сокращений плода

После проведения преобразований исходного сигнала при различных параметрах анализирующей функции, осуществлялся поиск максимального значения (2). Наибольшее значение достигалось, когда число квадратных волн, совпадающих с R-волнами плода, было максимальным, и когда частота анализирующей функции максимально точно совпадала со средней частотой сердечных сокращений плода. Таким образом, решалась задача определения ЧСС плода на основе анализа абдоминального материнского сигнала.

Заметное влияние на периодограмму оказывал выбор параметра  $A$ . С одной стороны, малые значения параметра ширины приводили к более высоким пикам в периодограмме, с другой, это усиливало ее шумовую составляющую. Высокие значения оказывали на функцию сглаживающий эффект и уменьшали амплитуду пиков. На рисунке 5 показан результат выполнения операций при  $A = 4$ , как видно из рисунка, средняя длина RR-интервала в фетальной ЭКГ равна 473 миллисекундам.



Примеры периодограмм для других сигналов из обеих групп представлены на рисунке 6. Рассматриваемый метод позволил определить ЧСС плода даже при слабой визуальной различимости QRS-комплексов плода.




Рис. 5  $c(A, T, \Phi)$  при  $A=4$ , пик обозначает, что средний RR интервал равняется 142 отсчетам, примерно 473 миллисекундам.

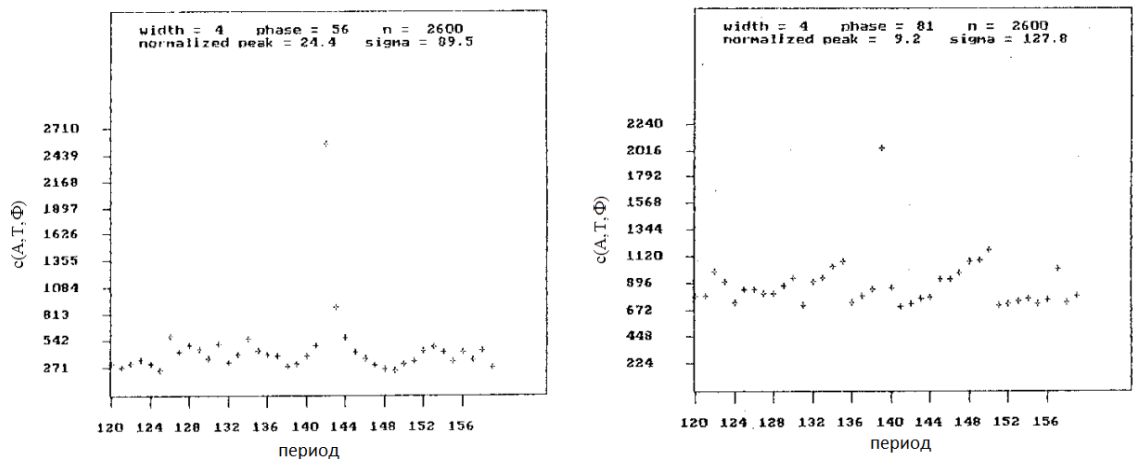


Рис. 6 Периодограммы ЭКГ с: а) с сильной; б) слабой; визуальной различимостью плодовой составляющей

Также авторы [22] предложили метод оценки качества выделения фетальной составляющей в зависимости от среднеквадратичного отклонения RR-интервалов. Качество выделения периода определялось следующим образом: для периодограммы рассчитывалось среднеквадратичное отклонение, которое не

учитывало 3 значения: максимум; два соседних. Отношение максимума периодограммы и среднеквадратичного отклонения определяло качество обнаружения частоты сердечных сокращений плода. Как видно из рисунка 7, если вариабельность RR-интервалов не превышает 11%, то метод, позволяет получить точные результаты. Было смоделировано множество сигналов с известными соотношениями сигнала-шума и вариабельностью RR-интервалов. Проверка адекватности метода проводилась как при больших, так и малых значениях параметра  $A$ . Однако найти оптимальное для всех сигналов значение данного параметра не удалось.

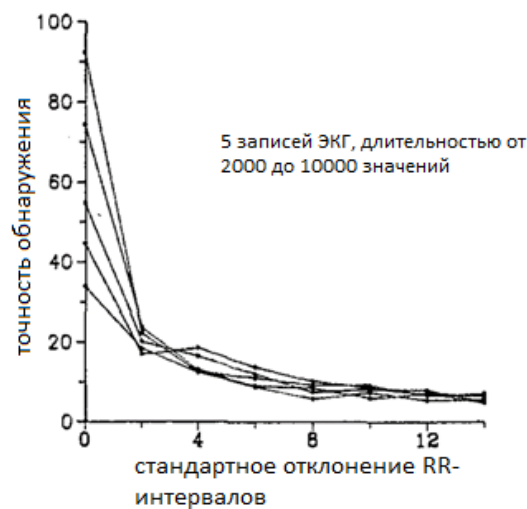


Рис. 7 Зависимость точности определения частоты сердечных сокращений плода от среднеквадратичного отклонения RR-интервалов

Основное предположение, лежащее в основе метода, заключается в том, что сигнал АЭКГ содержит квазипериодический сигнал плода. Если его период совпадает с периодом анализирующей функции прямоугольных волн, то значение интеграла (2) в момент возникновения фетального R-пика будет достаточно велико. Если временной ряд, представляющий ЭКГ-сигнал, содержит квазипериодический сигнал, средняя периодичность которого отличается от периодичности анализирующей функции, то совпадения прямоугольных волн и сигнала не произойдет, а значение интеграла в (2) будет стремиться к нулю.

Предложенный метод трехпараметрического преобразования ЭКГ-сигнала чувствителен к вариабельности RR-интервалов плода в АЭКГ. Точность зависит

от длительности анализируемого сигнала и значения параметра  $A$ —ширины прямоугольных волн. Применение алгоритма возможно только после предварительной обработки, в ходе которой из АЭКГ удаляется усредненный QRS-комплекс матери, получаемый в результате моделирования. Следовательно, метод не решает задачу выделения источников АЭКГ сигнала, а предназначен лишь для обработки ЭКГП и определения частоты сердечных сокращений плода.

#### **1.4 Адаптивная линейная фильтрация абдоминальных электрокардиограмм**

##### *1.4.1 Анализ фетальных тонов сердца с помощью линейного адаптивного фильтра*

Недостатки ультразвуковой диагностики сердечной активности плода побудили авторов [24] создать портативную, неинвазивную систему фонокардиографического мониторинга, которая основывалась на технологиях адаптивных линейных фильтров.

Фетальные тоны сердца были получены у группы обследуемых, срок гестации варьировался от 35-ти до 39-ти недель. Акустический сигнал с частотой дискретизации 2кГц снимали с помощью PVF2-датчика, чувствительного к слабым акустическим сигналам. За разработку прибора отвечал Научно-исследовательский центр НАСА Ленгли. Выявление текущего сердечного ритма основывалось на обнаружении сигнатур деятельности митрального клапана сердца в акустическом сигнале с помощью адаптивного предиктора.

Желаемый отклик для подбора коэффициентов авторы получили, выполнив обратное Фурье преобразование спектра, полученного в результате усреднения 50-ти спектров акустических сигнатур деятельности митрального клапана. На рисунке 8 приведены примеры входного акустического сигнала и акустической сигнатуры, полученной в результате моделирования.

Входной сигнал  $x(k)$  обрабатывался нерекурсивным адаптивным фильтром порядка  $L$ . Для выделения фетальных тонов сердца использовали адаптивные линейные предикторы различных порядков. Длины векторов весовых

коэффициентов соответствовали значениям от  $L=5$  до  $L=12$ . Обучающая выборка состояла из 50-ти образов, длиной  $N=141$  отсчетов каждый. Оптимальная длина вектора весовых коэффициентов по эмпирическим наблюдениям составила  $L=8$ . Для достижения критерия остановки обучения требовалось в среднем от 50 до 100 итераций.




Рис. 8 а) пример входного акустического сигнала б) искомая сигнатура фетального тона сердца

Работа [24] позволила авторам получить экспериментальные доказательства своей теории, что линейная адаптивная фильтрация способна находить фетальные тоны сердца в условиях зашумленности и присутствия в сигнале материнской составляющей. Также ее преимуществом являлось то, что сердечная активность плода оценивалась по акустическим, а не электрическим сигналам, так как качество получения таких данных во многом зависит от удачного расположения множества электродов на теле.

#### 1.4.2 Выделение электрокардиограммы плода с помощью линейных адаптивных фильтров и вейвлет-анализа

Авторы [25] предложили использование комплекса адаптивных фильтров, каждый из которых в качестве входного и опорного сигнала использовал коэффициенты детализации, полученные в результате дискретного вейвлет-

преобразования сигналов ЭКГ, зарегистрированных с абдоминального и грудного отведений.

Выделение ЭКГ плода включало несколько этапов:

1. получение коэффициентов детализации 5-ти уровней с помощью базового bior1.5 вейвлета, реализованного в Matlab Wavelet Toolbox 2009;
2. коэффициенты одного уровня разложения использовались в качестве входного и опорного сигнала адаптивного фильтра в зависимости от отведения;
3. фильтрация выходных сигналов фильтров с помощью алгоритма Spatial Selective Noise Filtration (SSNF) [26];
4. получение электрокардиограммы плода с помощью обратного вейвлет-преобразования выходов фильтров.

Подобные нововведения позволили получить ЭКГП с более высоким соотношением сигнал-шума, по сравнению с классическими подходами адаптивной фильтрации, что показано на рисунке 9.

В ходе работ [27-29] использовались два типа АЭКГ: модельные и реальные. Модельные сигналы были получены с помощью программы UG DigiScore [30], амплитуда материнской R-волны превышала фетальную в 2 раза. Реальные данные были получены из открытой базы медицинских данных [31]. Частота дискретизации сигналов составляла 250 Гц, а длительность: 10-30с.

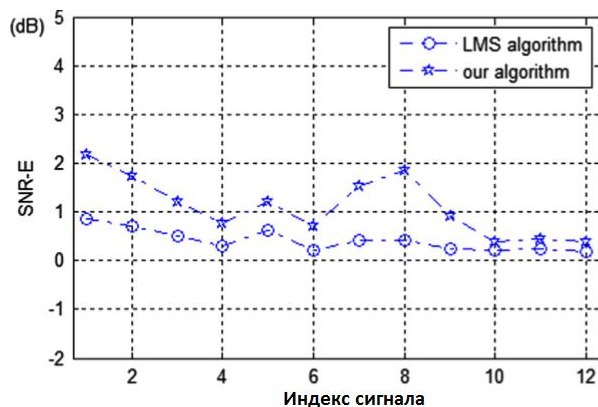


Рис. 9 Соотношения сигнала-шума ЭКГ плода, полученные с помощью разных методов

На рисунке 10 приведены результаты выделения ЭКГП из модельного сигнала. На рисунке 10г обозначены 3 материнских R-пика, ложно принятых за плодовые при адаптивной фильтрации без применения вейвлет-анализа.




Рис. 10 Сравнение эффективности выделения ЭКГП а) входной абдоминальный сигнал; б) опорный сигнал, снятый с грудного отведения; в) ЭКГ плода, полученная с помощью комбинации адаптивной фильтрации и вейвлет-анализа; г) ЭКГП, полученная только с помощью адаптивной фильтрации.

Комбинация адаптивной фильтрации и вейвлет-анализа позволяет получать ЭКГП с более высоким соотношением сигнал-шума. Исключение вейвлет-анализа из обработки АЭКГ приводит к снижению точности, так как в результате адаптивной фильтрации выходной сигнал содержит материнские R-пики, неверно классифицируемые системой как плодовые. Недостатками метода, препятствующими его внедрению в клиническую практику, являются высокая вычислительная сложность и неспособность алгоритма обрабатывать сигналы в реальном времени.

### 1.4.3 Выделение электрокардиограммы плода с помощью рекурсивных адаптивных фильтров

В [32] предлагалось использование фильтров с бесконечной импульсной характеристикой (БИХ), которая выражается в реакции системы на входной сигнал в виде единичного импульса при нулевых начальных условиях. Наличие обратных связей в БИХ-фильтрах позволяет принимать на вход предыдущие выходные сигналы.

Поиск полюсов и нулей с помощью градиентного спуска подвержен попаданию в локальный минимум [33]. Для поиска оптимальных коэффициентов фильтра на основе [34] был разработан гибридный алгоритм, сочетающий в себе градиентный и генетический подход.

Эффективность гибридного алгоритма была продемонстрирована на примере выделения ЭКГП с использованием, как различных архитектур фильтров, так и алгоритмов поиска их коэффициентов:

1. Нерекурсивный адаптивный фильтр с конечной импульсной характеристикой (КИХ) порядка  $L=20$ . Поиск коэффициентов осуществлялся методом градиентного спуска с коэффициентом скорости обучения  $\mu = 4 \cdot 10^{-5}$ ;
2. Рекурсивный адаптивный фильтр с порядком входного сигнала и обратной связи  $N=M=3$ . Для обучения использовался алгоритм градиентного спуска с коэффициентом скорости обучения  $\mu = 4 \cdot 10^{-5}$ ;
3. БИХ-фильтр с порядком входного сигнала и обратной связи  $N=M=3$ . Поиск коэффициентов осуществлялся с помощью комбинации градиентного спуска и генетического алгоритма со следующими параметрами: коэффициент скорости обучения  $\mu = 4 \cdot 10^{-5}$ ; размер популяции  $K=50$ ; параметр мутации  $D=0.5$ ;
4. Рекурсивный адаптивный фильтр, коэффициенты которого определялись только генетическим алгоритмом со следующими

параметрами: размер популяции  $K=50$ , параметр мутации  $D=0.05$ , вероятность скрещивания  $p = 0.8$ .

Формирование входного и опорного сигналов проводилось на основе двух сигналов, снятых с грудного отведения у разных людей. Для моделирования фетальной составляющей использовался сигнал с более высокой частотой сердечных сокращений. Второй сигнал выступал в качестве материнской составляющей, он был предварительно преобразован следующим образом (3):

$$H(z) = \frac{0.05 - 0.4z^{-1}}{1 - 1.1314z^{-1} + 0.25z^{-2}}. \quad (3)$$

В результате преобразования материнский сигнал обладал амплитудой R-волн, превышающей фетальную в 5 раз. Гибридный метод подбора весовых коэффициентов БИХ-фильтра показал наилучшую скорость сходимости, что показано на рисунке 11.




Рис. 11 Сходимость БИХ-фильтров, верхний график-МНК, нижний-гибрид МНК и ГА

## 1.5 Применение вейвлет анализа для обработки абдоминальных электрокардиограмм

### 1.5.1 Кратномасштабный анализ и метод сопоставления с эталоном

В работах [35,36], авторы рассматривали абдоминальный ЭКГ сигнал матери как (4):

$$s(t) = r(t)[f(t) + m(t) + n(t)] \quad (4)$$



где  $f(t)$ ,  $m(t)$ ,  $n(t)$  обозначают соответственно фетальную и материнскую составляющую, а также гауссовский шум. Фактор  $r(t)$  воздействовал на все составляющие и отвечал за блуждание базовой линии или низкочастотный шум [37]. Для удаления высоко и низкочастотных шумовых составляющих в работах применялось вейвлет-преобразование. Удаление материнской составляющей осуществлялось через метод распознавания изображений – сопоставление с эталоном.

Для исследования были отобраны 5 сигналов, длительность каждого составляла одну минуты, гестационный период варьировался от 30 до 35 недель. QRS-комплексы, полученные в результате наложения материнских и фетальных, обозначались как «конфликтные». Составив выборку из «неконфликтных», т.е. отдельно расположенных QRS-комплексов матери и плода, осуществлялся поиск материнского вейвлета. В результате была выбрана сплайн-функция, доставляющая максимальную корреляцию.

Вещественнозначная функция  $\psi(t)$  называется базисным сплайн-вейвлетом, если она удовлетворяет условиям (5):

$$\int_{-\infty}^{+\infty} |\psi(t)|^2 < \infty, \int_{-\infty}^{+\infty} \psi(t) < 0, \quad (5)$$

и допускает представление в виде обобщенного сплайна конечной областью определения [38].

Как видно из рисунка 12, в результате кратномасштабного анализа изначальный сигнал был успешно очищен от высокочастотной шумовой составляющей.

Для решения задачи нахождения материнских QRS-комплексов, изображенных на рисунке 13, использовался метод сопоставления с эталоном [39], который заключается в сравнении эталонного объекта со всеми неизвестными объектами, присутствующими в изображении. Наличие шумов и искажений делает невозможным полное совпадение между эталоном и отрезком изображения.




Рис. 12 а) исходный сигнал АЭКГ; б) после фильтрации

Мера отличия  $D(m,n)$  эталона от изображения в точке  $(m,n)$  определяет наличие выделенного объекта там, где это значение не превышает некоторый установленный порог  $L_D(m,n)$ . Значение порога является неизменным для всего изображения. Значение среднеквадратической ошибки может быть использовано как мера различия (6):

$$D(m,n) = \sum_j \sum_k [F(j,k) - T(j-m, k-n)]^2, \quad (6)$$

где  $F(j,k)$  – элемент изображения, в котором осуществляется поиск, а  $T(j,k)$  – элемент множества эталонных значений. Поиск ограничивается областью перекрытия смещенного эталона и изображения. Решение о сходстве с эталоном в точке  $(m,n)$  принимается при выполнении (7):

$$D(m,n) < L_D(m,n). \quad (7)$$

Теперь представим равенство (6) в виде (8):

$$D(m,n) = D_1(m,n) - 2D_2(m,n) + 3D_3(m,n), \quad (8)$$

где

$$D_1(m,n) = \sum_j \sum_k [F(j,k)]^2, \quad (9)$$

$$D_2(m,n) = \sum_j \sum_k F(j,k) \cdot T(j-m, k-n), \quad (10)$$

$$D_3(m,n) = \sum_j \sum_k [T(j-m, k-n)]^2. \quad (11)$$

Слагаемое  $D_3(m,n)$  – это энергия эталона, является неизменной и не зависит от координат. Первое слагаемое  $D_1(m,n)$  обозначает энергию изображения в пределе окна. Второе слагаемое обозначает взаимную корреляцию  $R_{FT}(m,n)$  изображения и эталона. Совпадение изображения и эталона характеризуется высокой взаимной корреляцией и малым значением среднеквадратической ошибки. Взаимная корреляция не всегда адекватно характеризует отличие между изображением и эталоном, так как слагаемое  $D_1(m,n)$  зависит от координат. Увеличение взаимной корреляции может наблюдаться даже при несоответствии эталону, например при слишком высокой яркости окрестности точки с координатами  $(m,n)$ . Эту проблему можно решить, сравнив нормированную взаимную корреляцию (12):

$$\tilde{R}_{FT}(m,n) = \frac{D_2(m,n)}{D_1(m,n)} \quad (12)$$

с порогом  $L_R(m,n)$ . Решение о сходстве с эталоном принимается при выполнении (13):

$$\tilde{R}_{FT}(m,n) > L_R(m,n). \quad (13)$$

Максимальная величина нормированной взаимной корреляции, равная единице, достигается только при полном совпадении изображения в окне и эталона. Недостатком метода является необходимость в использовании многочисленных эталонов для повышения устойчивости к изменению объектов, получаемых в результате поворотов и изменений масштабов. Сопоставление с эталоном должно ограничиваться признаками, не зависящими от изменений формы и размеров.

Также авторами [35] был смоделирован сигнал абдоминальной электрокардиограммы, который включал в себя 202 фетальных и 72 материнских QRS-комплексов. Согласно критерию Стьюдента ( $\alpha > 0.05$ ), отличия эталонного QRS-комплекса плода от выделенного носили случайный характер.




Рис. 13 Результат распознавания фетальных QRS-комплексов методом сравнения с эталоном

### *1.5.2 Применение вейвлет-зум процедуры для выделения электрокардиограммы плода*

Процедура приближения и удаления объектов (вейвлет-зум) с постепенно уменьшающимся масштабным параметром позволяет сфокусировать вейвлет-преобразование на локальные структуры сигналов, главная информация о которых содержится в особенностях и негладких структурах. В электрокардиограммах полезные сведения лежат именно в области резких переходов. В [40] показана взаимосвязь между локальной гладкостью сигнала и убыванием амплитуды вейвлет-преобразования при уменьшении масштаба. Исследования локальных максимумов вейвлет-преобразований при малых масштабах выделяют особенности и перепады сигналов.

Гладкость сигнала  $f(t)$ , будучи количественно определенной, может охарактеризовать структуру с особенностями. Показатель Липшица позволяет определить равномерную гладкость на временном интервале и в произвольной точке  $v$ . При наличии особенности в  $f(t)$  при  $t=v$  функция является недифференцируемой, а ее сингулярное поведение определяется показателем Липшица.

Взаимосвязь между равномерной гладкостью Липшица на интервале с амплитудой и вейвлет-преобразованием при малых масштабах показана в [41].

Функция удовлетворяет равномерному условию Липшица  $\alpha$  в окрестности  $\nu$  тогда и только тогда, когда существует такое  $A > 0$ , что каждая точка максимума модуля  $(u, s)$  в конусе  $|u - \nu| \leq Cs$  удовлетворяет неравенству (14):

$$|Wf(u, s)| < As^{\alpha+1/2}, \quad (14)$$

которое эквивалентно (15):

$$\log_2 |Wf(u, s)| \leq \log_2 A + \left( \alpha + \frac{1}{2} \right) \log_2 s. \quad (15)$$

Гладкость Липшица в точке  $\nu$  определяется как максимальный наклон  $\log_2 |Wf(u, s)|$ , как функции  $\log_2 s$ , вдоль линий максимумов, сходящихся к  $\nu$ .

В работе [42] для нахождения фетальных QRS-комплексов в абдоминальной ЭКГ применялся вейвлет-зум метод. Сигнал АЭКГ был взят у женщины 27-ми лет, срок гестации составлял 38 недель.

Целью первого этапа обработки абдоминальной ЭКГ являлось удаление низкочастотной шумовой составляющей, оказывающей эффект блуждания базовой линии, для этого использовались вейвлеты Добеши с параметром масштабирования  $N=12$ . Коэффициенты аппроксимации 12-го уровня были удалены из исходного сигнала, что позволило выровнять базовую линию ЭКГ, как показано на рисунке 14.




Рис. 14 Материнская ЭКГ, 38ая неделя гестации, ЧСС матери - 92 удара/мин, ЧСС плода - 143 удара/мин а) в сигнале присутствует блуждание базовой линии б) базовая линия выровнена

На втором этапе сигнал очищался от высокочастотных шумов, для вейвлет преобразования использовался вейвлет-койфлет (Coiflet24). Для коэффициентов 1-3, 4-5, 6, 7, 8 уровней использовались соответственно значения порога обрезания в 4, 2.5, 2, 1.5, 0.6 раз превышающие стандартное отклонение вейвлет-коэффициентов данного уровня.

На рисунке 15 для участка ЭКГ сигнала показаны локальные максимумы модуля вейвлет преобразования. На рисунке 16 изображено убывание  $\log_2 |Wf(u, s)|$  вдоль кривых максимумов, пунктирная линия определяет кривую максимумов материнской составляющей сигнала, а две сплошные относятся к плоду.




Рис. 15 Максимумы модуля двоичного вейвлет-преобразования

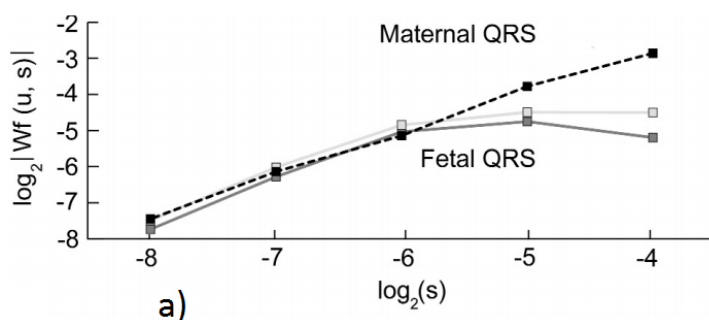


Рис. 16 Убывание  $\log_2 |Wf(u, s)|$  вдоль кривых максимумов

Таким образом, авторами была показана схожесть точек разрыва при данных масштабах, что говорит о том, что максимумы отражают наличие фетальных и материнских QRS-комплексов, а не шум.

### **1.6 Модель слепого разделения источников и анализ независимых компонент**

Для подбора оптимальных коэффициентов адаптивных фильтров требуется эталонный сигнал. Возможен и иной вариант адаптации, при котором желаемый отклик неизвестен. Поиск значений параметров модели осуществляется через слепую адаптацию или обучение без учителя. В данных условиях необходимо наличие некоторой информации о структуре полезного входного сигнала, например – знание типа и параметра модуляции. Слепая адаптация является более сложной вычислительной задачей, чем обучение с учителем при известных эталонных сигналах.

Сигнал электрокардиограммы матери (ЭКГМ), будучи измеренным в любой точке тела, может быть представлен линейной суперпозицией трех ортогональных сигналов - подпространства источников. Аналогичным образом можно определить подпространство источников электрокардиограммы плода (ЭКГП). Данное предположение сделано на основе векторной модели сердечной активности Бергера и Ван Милана. Согласно модели, поле трехмерного диполя, пространственное положение которого зафиксировано, а амплитуда и ориентация меняются во времени, может представить биоэлектрическую активность сердца в первом приближении.

Определим вектор источников в момент времени  $t$  как (16):

$$s(t) = [s_1(t), s_2(t), \dots, s_q(t)], \quad (16)$$

где  $s_i(t)$ ,  $i=1,2,\dots,q$  – источник.

Регистрация активности сердца с поверхности тела матери осуществляется с использованием нескольких датчиков. Результатом измерения является разность потенциалов между парами электродов, закреплённых на теле.

Определим вектор наблюдений в момент времени  $t$  как (17):

$$x(t) = [x_1(t), x_2(t), \dots, x_p(t)], \quad (17)$$

где  $p$  – количество ЭКГ отведений.

Вектор источников сигнала применяется к линейной системе, характеристики которой задаются матрицей смещения  $A$ . Значение вектора наблюдений можно представить как линейную комбинацию источников и аддитивных помех (18):

$$\begin{aligned} x_1(t) &= a_{11}s_1(t) + a_{1q}s_q(t) + n_1(t) \\ x_2(t) &= a_{21}s_1(t) + a_{2q}s_q(t) + n_2(t) \\ &\dots \\ x_p(t) &= a_{p1}s_1(t) + a_{pq}s_q(t) + n_p(t). \end{aligned} \quad (18)$$

Значения коэффициентов матрицы  $A$ , модели распространения сигналов от сердца к датчикам, а также вид сигналов отдельных источников неизвестны. Сигналы источников не могут наблюдаться непосредственно, а могут быть рассмотрены в форме сложного сигнала.

Физическая независимость биоэлектрических процессов сердцебиения матери и плода определяет статистическую независимость сигналов источников. Аналогичным образом делается предположение о статистической независимости от источников шумовых компонент  $n_j(t)$  в разных каналах.

Рассмотрим решение задачи выделения сигналов отдельных источников, из наблюдаемой смеси  $x(t) = [x_1(t), x_2(t), \dots, x_p(t)]$ . В случае отсутствия шумов, оно состоит в нахождении разделяющей матрицы  $W$  с такими коэффициентами, что

$$\begin{aligned} s_1(t) &= w_{11}x_1(t) + w_{12}x_2(t) + \dots + w_{1p}x_p(t) \\ s_2(t) &= w_{21}x_1(t) + w_{22}x_2(t) + \dots + w_{2p}x_p(t) \\ &\dots \\ s_q(t) &= w_{q1}x_1(t) + w_{q2}x_2(t) + \dots + w_{qp}x_p(t) \end{aligned} \quad (19)$$



Эта матрица является обратной смешивающей матрице  $A$ , если коэффициенты  $a_{ij}$  известны, то определить значения  $w_{ij}$  не составляет труда, однако коэффициенты матрицы смешивания неизвестны.

Задачу слепого разделения источников материнской электрокардиограммы можно сформулировать следующим образом: по нескольким, независимым, наблюдаемым значениям  $x(t)$  определить коэффициенты смешивающей и разделяющей матриц, а также сигналы источников  $s(t)$ .

Сформулированная таким образом задача называется задачей "слепого разделения источников". Под формулировкой "слепое" в данном случае понимается то, что информация о характере разделяемых источников, свойствах регистрируемых сигналов и параметрах предоставляется в минимальном количестве. Эта минимальная информация обычно состоит в предположении о статистической независимости источников сигналов, неизменности коэффициентов смешивающей матрицы  $A$  на интервале наблюдения, и о том, что плотность вероятности распределения амплитуд источников описывается определенным классом вероятностного распределения.

### *1.6.1 Анализ независимых компонент*

Во многих работах по разделению источников медицинских сигналов используется метод fastICA (Fast Independent Component Analysis), являющийся одной из множества разновидностей алгоритмов слепого разделения источников [43].

Центральная предельная теорема говорит о том, что сумма независимых случайных значений стремится к нормальному распределению. Следовательно, чем больше слагаемых в данной сумме, тем больше она похожа на гауссиану. Априорным утверждением метода независимых компонент является отличное от нормального распределение статистически независимых источников.

Таким образом, линейная комбинация источников, будет максимально негауссовой, если в точности представляет собой одну из независимых

компонент. Для максимизации «негауссовости» необходимо определить меру количественной оценки степени разности распределений, например обратная дифференциальная энтропия, которая представляет «упорядоченность» распределения случайной величины – негэнтропии.

В условиях заданного математического ожидания и дисперсии нормальное распределение характеризуется максимальной энтропией. При четкой кластеризации переменной и сосредоточении возле определенных значений мера ее неоднородности стремится к минимуму. Негэнтропия, напротив, будет стремиться к максимуму, в связи с этим она может быть использована как оптимальная мера оценки степени отличия источников сигнала.

Негэнтропия  $J(y)$  задается формулой (20):

$$J(y) = H(y_{gauss}) - H(y) = H(y_{gauss}) - \left(-\int f(y) \log f(y) dy\right), \quad (20)$$

где  $H(y_{gauss})$  – энтропия гауссовой случайной переменной с таким же математическим ожиданием и отклонением как у наблюдаемой переменной.  $H(y)$  – энтропия случайной переменной, которая представляет собой один из источников в наблюдаемом сигнале ЭКГ, зарегистрированном в абдоминальном отведении.

Поскольку при вычислении негэнтропии возникает необходимость оценивать функцию плотности вероятности, Хюверинен [44] предложил использовать ее аппроксимацию (21):

$$J(w^T X) \approx \left[ E\{G(w^T X)\} - E\{G(v)\} \right]^2 \quad (21)$$

где  $E$  – оператор математического ожидания,  $v$  - стандартизированная случайная переменная с нормальным распределением.

Дивергенция – удаленность друг от друга двух вероятностных распределений оценивалась по формуле неквадратичной логарифмической функции (22):

$$G(w^T X) = \log \cosh(w^T X). \quad (22)$$

Алгоритм анализа независимых компонент осуществляет поиск таких значений вектора  $w$ , что в пространстве, где он является единичным, проецируемые вдоль него наблюдаемые данные  $w^T X$  максимизируют негэнтропию. Оптимум  $E\{G(w^T X)\}$  достигается в точках приближения, где выполняется условие (23):

$$E\{XG(w^T X) - \beta w\} = 0, \quad (23)$$

где  $\beta = E\{w_0^T x g(w_0^T x)\}$ .

Для решения уравнения можно использовать метода Ньютона, обозначив левую часть (23) как  $F$ , получим градиент:

$$f(w) = \frac{\partial F}{\partial w} = E\{XX^T g(w^T X)\} + \beta I = E\{XX^T (1 - \tanh^2(w^T X))\}, \quad (24)$$

где функция  $g(w^T X)$  является производной функции  $G(w^T X)$ , то есть гиперболическим тангенсом.

Чтобы упростить обращение матрицы, необходимо прибегнуть к приближению первого слагаемого уравнения (24), которое принимает вид (25):

$$E\{XX^T g(w^T X)\} \approx E\{XX^T E\{g(w^T X)\}\} = E\{g(w^T X)\} I. \quad (25)$$

Нахождение численного решения уравнения (25) после всех преобразований сводится к итерационной процедуре (26):

$$w \leftarrow w - \frac{F(w)}{f(w)} = w - \frac{E\{XG(w^T X)\}}{E\{g(w^T X)\} + \beta}. \quad (26)$$

### 1.6.2 Слепое разделение источников абдоминальных электрокардиограмм

В работе [45] предложена модель слепого разделение источников АЭКГ. Источниками сигналов являлись: ЭКГП, ЭКГМ, электромиография матери (ЭМГМ). В качестве входного сигнала для системы разделения использовались сигналы АЭКГ с трех абдоминальных отведений. На рисунке 17 представлена модель абдоминальных ЭКГ-сигналов в различных отведениях.

Сигналы, полученные с электродов, прикрепленных к животу матери, описываются (27):

$$X_i(j) = H_{1i}(FECG(j) + H_{2i}(MECG(j) + H_{3i}(EMG(j)) + N_i(j), \quad (27)$$

где номер отсчета  $j \in [1, 2, \dots, n]$ ; номер отведения  $i \in [1, 2, 3]$ ;  $H_{1i}(FECG)$ ,  $H_{2i}(MECG)$  и  $H_{3i}(EMG)$  – произведения элементов смешивающей матрицы и значений сигналов плода и матери.

Смесь различных типов шумов, описывается (28):

$$N_i(j) = N_{i,50Hz}(j) + N_{i,amp}(j) + N_{i,therm}(j) + N_{i,art}(j), \quad (28)$$

где  $N_{i,50Hz}$  – шумовая составляющая, вносимая линией электропередачи;  $N_{i,amp}$  – шум усилительной аппаратуры;  $N_{i,therm}$  – термальный шум, генерируемый телом;  $N_{i,art}$  – шум производимый движением тела.

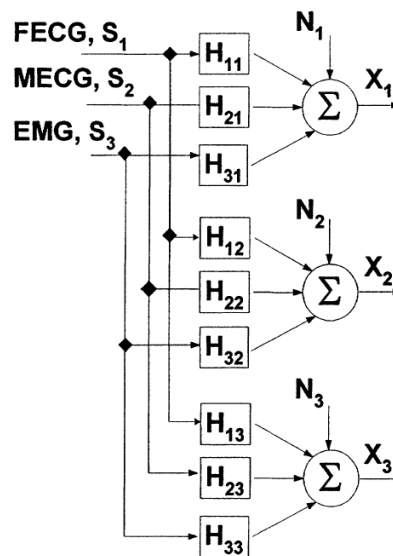


Рис. 17 Модель входного сигнала (абдоминального ЭКГ)

Вычисления были проведены с использованием пакета ICALab [46], разработанным в научно-исследовательском институте физико-химических исследований Японии.

В качестве критерия оценки работы алгоритма использовались значения соотношения сигнала-шума (29), где в качестве сигнала рассматривалась ЭКГ плода, всё остальное рассматривалось как шум:

$$SNR_i = 10 \log_{10} \frac{\sum_{j \in n} (h_{j,1} \cdot FECG[j])^2}{\sum_{j \in n} (h_{j,2} \cdot MECG[j] + \sum_{j \in n} h_{j,3} \cdot EMG[j])^2} \quad (29)$$

где  $h_{j,1}, h_{j,2}, h_{j,3}$  – коэффициенты смешивающей матрицы.

На рисунках 18а, 18б, 18в показаны сигналы, принятые за источники абдоминального сигнала. Смоделированные сигналы абдоминальной ЭКГ, которые подлежат разделению, представлены на рисунках 18г, 18д, 18е. Результаты разделения представлены на рисунке 19, за исключением масштаба не существует сколько-нибудь значимых различий между 18а и 19в.

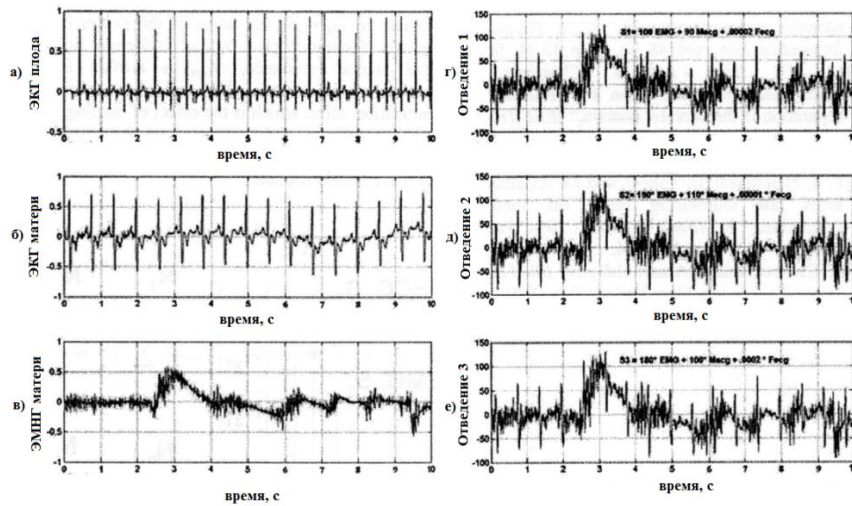


Рис. 18 Исходные сигнала и сигналы с отведений а) ЭКГП; б) ЭКГМ; в) ЭМГМ; г) АЭКГ с отведения 1; д) АЭКГ с отведения 2; е) АЭКГ с отведения 3




Рис. 19 Сигналы, выделенные из смеси через метод анализа независимых компонент а) ЭКГ матери б) ЭМНГ матери в) ЭКГ плода

## 1.7 Применение аппарата искусственных нейронных сетей для выделения электрокардиограммы плода

Слабая формализация задачи выделения ЭКГ плода определила появление научных работ, в которых математическое решение строилось на основе теории искусственных нейронных сетей. Среди используемых архитектур в литературе [47-50] наиболее часто используются многослойные перцептроны и адаптивные нейросетевые фильтры.

### 1.7.1 Применение многослойного перцептрона для выделения источников абдоминальной электрокардиограммы

В работе [48] авторы выделили одно из основных преимуществ нейронных сетей – способность адаптироваться к нелинейным и динамическим свойствам сигналов ЭКГ. В качестве архитектуры использовался многослойный перцептрон, обучаемый с учителем. Элементы нейросетевой архитектуры и связи между ними изображены на рисунке 20.




Рис. 20 Структура многослойного перцептрона

Из рисунка видно, что на вход сеть принимает 6 значений. Так как такая модель сети является статической, она не может принимать на вход текущее и некоторое количество предыдущих значений ЭКГ сигнала. Для обработки временного ряда авторы предложили подавать на вход сети не только значение в текущий момент времени, но и некоторые значения, характеризующие значение временного ряда относительно всего рассматриваемого отрезка.

Выход сети принимает значения в диапазоне [0,1]. В случае 1 сеть предполагает, что значение сигнала в данный момент времени является амплитудой материнской R-волны.

Следующий этап предполагал удаление материнских QRS-комплексов из абдоминального сигнала. Для каждого сигнала моделировался материнский QRS-комплекс, получаемый в результате усреднения, как показано на рисунке 21.

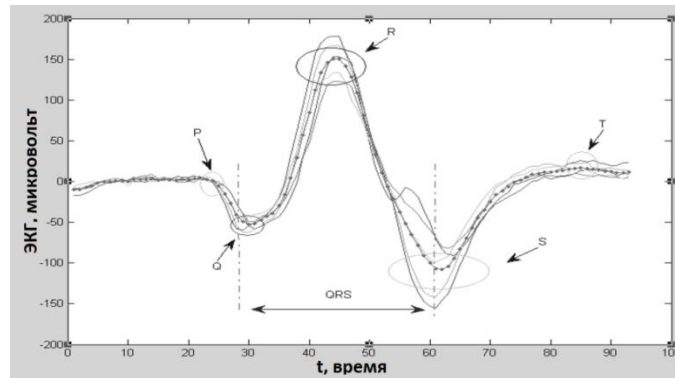


Рис. 21 Усредненный материнский QRS-комплекс

Удаление материнских QRS-комплексов из абдоминального сигнала проводилось путем вычитания модельного комплекса. Корректное наложение модельных и реальных QRS-комплексов стало возможным за счет нахождения R-пиков нейронной сетью. С помощью корреляционного анализа определялся корректирующий коэффициент  $k$ , применяемый ко всем значениям модельного QRS-комплекса [51]. Коэффициент  $k$  определялся согласно (30):

$$k = \sqrt{\frac{C_{mecg}}{A_{mecg}}}, \quad (30)$$

где  $C_{mecg}$  — значение кросс-корреляции абдоминального сигнала и модельного,  $A_{mecg}$  — значение автокорреляционной функции для модельного QRS-комплекса.

Результат выделения ЭКГ-плода из абдоминального сигнала матери, гестационный период которой составлял 38 недель, показан на рисунке 22. Частота дискретизации сигнала составляла 1кГц. Предложенный метод способен выделять ЭКГ плода без переобучения нейронной сети при изменении частоты дискретизации. Также преимущество данного подхода заключается в

возможности выделять источники сигналов АЭКГ, к которым не были применены алгоритмы выравнивания изолинии.




Рис. 22 Абдоминальный материнский сигнал, выход нейронной сети, ЭКГ плода

### 1.7.2 Самообучающаяся нейронная сеть для слепого разделения источников

В работе [52] авторы рассматривали абдоминальный ЭКГ сигнал матери, как линейную комбинацию источников, что полностью соответствует концепции слепого разделения источников. Для определения коэффициентов разделяющей матрицы использовалась комбинация обратного распространения ошибки и анализа независимых компонент. Максимизируемая целевая функция описывается как (31):

$$J(y) \approx \left[ E\{G(y)\} - E\{G(v)\} \right]^2, \quad (31)$$

где  $a \leq J(y) \leq b$ ;  $\|w\| = 1$ ;  $y = w^T x$ ;  $E$  – оператор математического ожидания;  $G(\cdot)$  – некоторая неквадратичная функция, среди множества [44] которых была выбрана (32):

$$G_2(y) = \frac{1}{a_2} \exp\left(-\frac{1}{2} a_2 y^2\right), \quad (32)$$

где  $a_2 \approx 1$ .

Применив метод штрафов к (31), было получено (33):



$$F(w, \sigma) = J(y)^2 + \sigma \left\{ \left[ \max \{0, -(k_4(w^T x) - a)\} \right]^2 + \left[ \max \{0, -(b - k_4(w^T x))\} \right]^2 \right\}, \quad (33)$$

где  $\sigma$  – штрафной параметр, а  $k_4(y)$  определялся как (34):

$$k_4(y) = \frac{E\{y^4\}}{(E\{y^2\})^2} - 3. \quad (34)$$

Дифференцируя  $F(w, \sigma)$  по  $w$ , получаем: при  $a \leq k_4(y) \leq b$  (35)

$$\frac{\partial F(w, \sigma)}{\partial w} = \frac{\partial J(w, \sigma)}{\partial w}, \quad (35)$$

при  $k_4(y) \leq a$  (36)

$$\frac{\partial F(w, \sigma)}{\partial w} = \frac{\partial J(w, \sigma)}{\partial w} - 2\sigma[a - k_4(y)] \frac{\partial k_4(y)}{\partial w}, \quad (36)$$

при  $k_4(y) \geq b$  (37)

$$\frac{\partial F(w, \sigma)}{\partial w} = \frac{\partial J(w, \sigma)}{\partial w} + 2\sigma[k_4(y) - b] \frac{\partial k_4(y)}{\partial w}, \quad (37)$$

где  $\frac{\partial k_4(y)}{\partial w}$  определяется как (38):

$$\frac{\partial k_4(y)}{\partial w} = \frac{4m_4}{m_2^3} \left[ \frac{m_2}{m_4} E\{xy^3\} - E\{xy\} \right], \quad (38)$$

где  $m_2$  и  $m_4$  моменты второго и четвертого порядка случайной величины  $y$ .

Таким образом, объединив обратное распространение ошибки и слепое разделение источников, была получена итеративная процедура получения коэффициентов разделяющей матрицы (39):

$$w(k+1) = w(k) + \mu \frac{\partial F(w, \sigma)}{\partial w}. \quad (39)$$

Проверка адекватности предложенного подхода проводилась на реальных данных, взятых из открытой базы данных [31].

### 1.7.3 Адаптивная нейросетевая фильтрация абдоминального сигнала

В работе [53] авторы исследовали потенциал адаптивной нейросетевой фильтрации абдоминальной электрокардиограммы. Материнские сигналы ЭКГ, зарегистрированные с грудного отведения, использовались в качестве опорных сигналов фильтра, а единственный абдоминальный сигнал выполнял функцию желаемого отклика.

Структура фильтра показана на рисунке 23, для подбора коэффициентов использовался алгоритм минимизации среднеквадратичной ошибки. Выходные значения нейронов вычислялись с помощью линейной активационной функции.

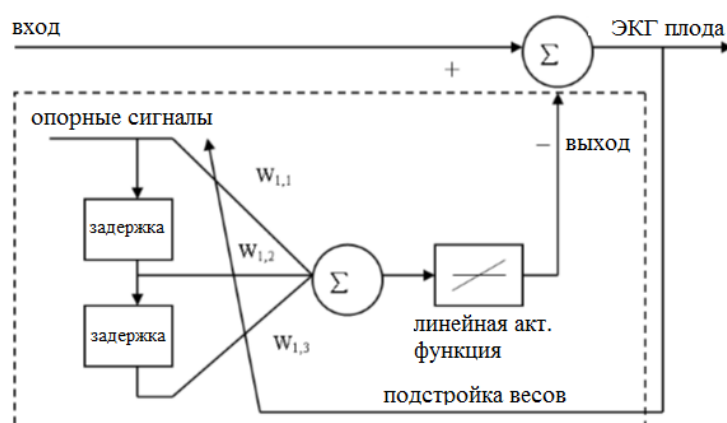


Рис. 23 Схема адаптивной линейной нейросетевой фильтрации

Научная новизна работы [53] заключалась в адаптивной фильтрации с использованием нейронной сети со скрытым слоем и нелинейной активационной функций. Примеры сигналов адаптивного фильтра, построенного на основе нейронных сетей, приведены на рисунке 24. Из него видно, что ЭКГП, полученная как выход фильтра без скрытого слоя, содержит неверно классифицированные материнские R-пики. В то время как нейронная сеть со скрытым слоем смогла выделить все R-пики плода, что представлено на рисунке 24г.

Разработанная в рамках работы [54] гибридная модель адаптивной фильтрации сочетала в себе как линейный адаптивный фильтр с конечной импульсной характеристикой, так и нейронную сеть с функциональной связью – Functional Link Artificial Neural Network (FLANN).




Рис. 24 Сигналы адаптивного линейного нейросетевого фильтра а) входной сигнал б) опорный в) выход нейросетевого фильтра без скрытого слоя г) выход нейросетевого фильтра со скрытым слоем

Структура предложенного фильтра показана на рисунке 25. Особенностью предложенного фильтра является наличие нескольких опорных сигналов, в качестве которых выступают сигналы с  $q$  грудных отведений, обозначаемые  $m_i$ ,  $i=1,2,\dots,q$ . На вход подается сигнал с одного абдоминального отведения.

Выход фильтра с конечной импульсной характеристикой определяется как (40):

$$y_i(n) = \sum_{j=0}^{M_1-1} w_{i,j} m_i(n-j), \quad (40)$$

где  $w_{i,j}$  – коэффициент фильтра;  $M_1$  – порядок фильтра;  $n$  – начальная точка отсчёта.

Выход FLANN-фильтра определяется суммой следующих компонентов:

$$z_{\sin,p,i}(n) = \sum_{j=0}^{M_2-1} h_{\sin,p,i,j} \sin[p\pi m_i(n-j)],$$

$$z_{\cos,p,i}(n) = \sum_{j=0}^{M_2-1} h_{\cos,p,i,j} \cos[p\pi m_i(n-j)],$$
(41)

где  $M_2$  – порядок FLANN-фильтра,  $p = 1, 2, \dots, P$ ,  $p$  – параметр активационной функции нейрона с функциональной связью,  $h$  – весовой коэффициент.

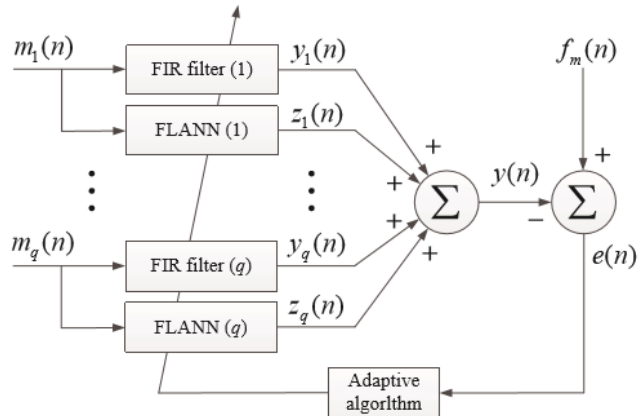


Рис. 25 Адаптивный FLANN фильтр

Обучение проводилось методом минимизации среднеквадратичной ошибки, для коэффициентов КИХ-фильтра коррекция определялась следующим образом:

$$w_{i,j}(n+1) = w_{i,j}(n) + \mu_{1,i} e(n) m_i(n-j),$$
(42)

где  $\mu_{1,i}$  – параметр, регулирующий скорость обучения. Для коэффициентов FLANN фильтра коррекция определялась следующим образом:

$$h_{\sin,p,i,j}(n+1) = h_{\sin,p,i,j}(n) + \mu_{2,i} e(n) \sin[p\pi m_i(n-j)],$$

$$h_{\cos,p,i,j}(n+1) = h_{\cos,p,i,j}(n) + \mu_{2,i} e(n) \cos[p\pi m_i(n-j)],$$
(43)

где  $\mu_{2,i}$  – параметр, регулирующий скорость обучения.

Тестирование проводилось на 10 секундных отрезках абдоминальных и грудных ЭКГ сигналов с частотой дискретизации 250 Гц, взятых из открытой базы данных [31]. Внедрение FLANN-фильтра в структуру адаптивного фильтра позволило повысить эффективность выделения ЭКГ по сравнению с линейной адаптивной фильтрацией. Варьируя количество опорных сигналов, авторы показали эффективность использования нескольких опорных сигналов по

сравнению с одним, но также выявили повышение вычислительной сложности при увеличении порядка FLANN-фильтра.

#### *1.7.4 Анализ сердечной активности плода с помощью различных типов нейронных сетей*

При анализе сердечной активности плода нейронные сети выполняли различные функции. В работах [55-56] была продемонстрирована эффективная классификация дородового и послеродового состояний плода. В качестве нейросетевых моделей использовались многослойные перцептроны и самоорганизующиеся карты, также исследовались классификаторы, основанные на принципах нечеткой логики. В качестве входных данных использовались кардиоотокографические сигналы.

В работе [57] исследовались возможности нейронных сетей для адаптивного шумоподавления фетальных кардиосигналов. Фильтрация, как для высокочастотных, так и низкочастотных шумов проводилась с использованием сетей прямого распространения. В [58] для решения задачи электрокардиографии была реализована простейшая форма динамической нейронной сети – с фокусированной задержкой во времени.

В [59] нейронные сети решали задачу выделения фетального сигнала из абдоминальной электрокардиограммы. В процессе обучения сеть выделяла материнскую составляющую из входного сигнала ЭКГ, зарегистрированного в абдоминальном отведении. Значение ошибки в каждый момент времени рассматривалось авторами как показатель сердечной активности плода.

### **1.8 Выбор метода моделирования на основе анализа преимуществ и недостатков рассмотренных методов**

Анализ ряда научных публикаций, посвященных неинвазивной фетальной электрокардиографии, позволяет сделать вывод о том, что в последнее десятилетие интерес научного сообщества к данной проблематике существенно

возрос. Об этом может свидетельствовать возросшее число научных публикаций относительно прошлых десятилетий.

Одной из проблем современной неинвазивной электрокардиографии является отсутствие единого информационного пространства, в рамках которого возможно исследовать адекватность предложенных моделей для выделения ЭКГП. Большое количество открытых баз данных, содержащих абдоминальные ЭКГ-сигналы, не позволяет сравнить эффективность множества методов в едином базисе. Отсюда и возникает отсутствие единого мнения о том, какой из существующих подходов является наилучшим.

По результатам литературного обзора существующие в настоящее время методы неинвазивной, фетальной электрокардиографии были разделены на 5 групп: частотно-временной анализ; кратномасштабный вейвлет анализ; адаптивная фильтрация; слепое разделение источников; нейросетевая обработка.

Основной проблемой частотно-временного анализа является то, что материнские и плодовые составляющие АЭКГ накладываются друг на друга, как во временной, так и в частотной областях. Это не позволяет выделить частотные характеристики ЭКГП и восстановить фетальную составляющую с помощью обратного преобразования. Удаление материнской составляющей из абдоминального сигнала с помощью усредненного материнского QRS-комплекса позволяет использовать алгоритм для определения частоты сердечных сокращений плода. Точность определения состояния сердечной активности зависит как от типа и параметров анализирующей функции, так и от варибельности RR-интервалов ЭКГП. Таким образом, методы частотно-временного анализа не позволяют непосредственно выделить ЭКГ плода из абдоминального сигнала матери, а способны лишь в ограниченных условиях оценить состояние сердечной активности плода.

Кратномасштабный вейвлет анализ позволяет эффективно решать задачу фильтрации и выравнивания базовой линии сигналов АЭКГ. Для удаления же материнской составляющей (в отличие от шумов) такое преобразование не подходит. Кратномасштабный анализ электрокардиограммы является

вспомогательным инструментом для облегчения выделения источников сторонними алгоритмами: сопоставление с эталоном; вейвлет-зум процедура; адаптивная фильтрация. В случае использования алгоритмов распознавания изображений точность во многом зависит от качества модельных материнских QRS-комплексов, что снижает устойчивость алгоритма к вариативности форм R-волн в сигналах. Вейвлет-зум процедура осуществляет выделение ЭКГП без использования эталонных QRS-комплексов, т.е. осуществляет слепое разделение источников АЭКГ, однако такой подход принципиально не позволяет разделять наложенные друг на друга R-пики матери и плода.

При адаптивной фильтрации на основе линейно независимых опорных сигналов происходит моделирование сигнала АЭКГ, со схожими морфологическими характеристиками желаемого отклика. Точность выделения ЭКГП при таком подходе зависит от удачного наложения электродов. Влияние на точность оказывает не только соотношение сигнала и шума, но и схожесть форм QRS-комплексов матери в абдоминальном и грудном отведениях. Существенным недостатком адаптивной фильтрации является ограничение размерности желаемого отклика, который должен быть исключительно одномерным. Современный тренд неинвазивной фетальной электрокардиографии [60-62] заключается в поиске алгоритмов, которые не требуют наличия опорных сигналов и выделяют ЭКГП именно из многомерных сигналов, снятых с нескольких абдоминальных отведений. Концепция адаптивной фильтрации не удовлетворяет этим требованиям.

Методы слепого разделения источников оказались востребованными в неинвазивной, фетальной электрокардиографии. Благодаря такому подходу стало возможным выделение электрокардиограммы плода в условиях отсутствия опорного сигнала, что является явным преимуществом по сравнению с адаптивной фильтрацией [63-64]. Слабым местом слепого разделения источников является априорное утверждение о том, что смешивание источников абдоминальной электрокардиограммы имеет линейный и стационарный характер. Размерность разделяющей матрицы определяется размерностью векторов

источников и наблюдений. Модель разделения источников в общем случае подразумевает, что матрица разделяющих коэффициентов является квадратной. В [65-67] продемонстрировано, что малого количества каналов записи абдоминального сигнала недостаточно для корректного выделения источников сигнала. Это также было подтверждено в ходе проведения собственных вычислительных экспериментов.

Искусственные нейронные сети за последнее десятилетие получили распространение в неинвазивной фетальной электрокардиографии. В большинстве случаев они представлены статическими моделями, на основе которых строятся адаптивные фильтры. Нейросетевая адаптивная фильтрация, по сравнению с линейной, позволяет более точно выделять ЭКГП. Неизменными остаются требования к наличию опорных сигналов и к размерности желаемого отклика.

Использование динамических, нелинейных, нейронных сетей для слепого разделения источников АЭКГ позволяет реализовать ряд преимуществ относительно всех вышеописанных подходов.

В отличие от частотного и кратномасштабного анализа нейронная сеть не оперирует частотными характеристиками ЭКГП, поэтому тот факт, что фетальная и материнская составляющие АЭКГ совпадают как во временной, так и в частотной области не является фактором, ограничивающим точность выделения источников.

Относительно линейных и нейросетевых адаптивных фильтров важным преимуществом предложенной модели является то, что в качестве входного сигнала могут быть использованы многомерные абдоминальные сигналы. При этом отсутствует необходимость в использовании опорных сигналов ЭКГ, снятых с грудного отведения. В отличие от адаптивных фильтров, динамическая нейронная сеть осуществляет выделение электрокардиограммы плода без удаления материнской составляющей из абдоминального сигнала.

По сравнению со слепым разделением источников нелинейная, динамическая, нейросетевая модель позволяет выделять источники



абдоминального сигнала, даже если характер смешивания носил нелинейный и динамический характер. При этом отсутствуют принципиальные ограничения размерности входного сигнала – нейросетевая модель позволяет осуществлять слепое разделение источников, как из одномерного, так и многомерного сигнала. Важным отличием от анализа независимых компонент является то, что нейронная сеть позволяет выделять только нужные нам источники из смеси, это позволяет алгоритмизировать процесс определения принадлежности выделенного сигнала ЭКГ матери или плоду.

### **1.9 Выводы по главе**

По результатам литературного обзора, существующие в настоящее время методы неинвазивной электрокардиографии были разделены на 5 групп: частотно-временной анализ; кратномасштабный вейвлет анализ; адаптивная фильтрация; слепое разделение источников; нейросетевая обработка.

Проанализировав их преимущества и недостатки, было принято решение разработать динамическую, нейросетевую модель слепого разделения источников абдоминальных электрокардиограмм.

Такая модель позволит осуществлять слепое разделение источников смеси сигналов, характер смешивания источников которой носил нелинейный и нестационарный характер. Разделение источников может осуществляться при любой размерности входного абдоминального сигнала без необходимости использования опорного сигнала, зарегистрированного с грудного отведения.

## Глава 2. Модель и численная реализация оценки состояние сердечной активности плода

### 2.1 Модель электрокардиограммы плода на основе синтеза слепого разделения источников и нейронных сетей

В соответствии с векторной моделью сердечной активности Бергера и Ван Милана биоэлектрическая активность сердца на некотором удалении от него может быть в первом приближении представлена как поле трехмерного диполя с фиксированным пространственным положением и изменяющимися во времени амплитудой и ориентацией. Это означает, что сигнал ЭКГМ, измеренный в любой точке на теле матери, может быть представлен как линейная суперпозиция трех ортогональных сигналов – подпространство источников ЭКГМ. Аналогичным образом можно определить подпространство источников ЭКГП, при этом его размерность не обязательно равна трем.

Таким образом, для любого момента времени вектор источников сигнала можно определить как (44):

$$s(t) = s[s_1(t), s_2(t), \dots, s_k(t)] \quad (44)$$

где  $s_i(t), i = 1, 2, \dots, k$  – источники сигнала АЭКГ.

Наблюдение этих сигналов на поверхности тела матери производится с использованием некоторого количества пространственно-разнесенных приемников. Вектор наблюдения записывается (45):

$$x(t) = [x_1(t), x_2(t), \dots, x_k(t)] \quad (45)$$

Наблюдаемое в каждой точке поверхности тела колебание может быть представлено как линейная комбинация (46) сигналов сердечных источников:

$$\begin{aligned} x_1(t) &= m_{11}s_1(t) + m_{12}s_2(t) + \dots + m_{1k}s_k(t) \\ x_k(t) &= m_{k1}s_1(t) + m_{k2}s_2(t) + \dots + m_{kk}s_k(t) \end{aligned} \quad (46)$$

или, в матричной форме:

$$X(t) = MS(t)$$

Задача слепого разделения источников, заключается в нахождении отдельных источников из наблюдаемой смеси  $x(t)$ . Решение задачи состоит в

нахождении разделяющей матрицы  $W$  с такими коэффициентами, что выполняется (47):

$$\begin{aligned} s_1(t) &= w_{11}x_1(t) + w_{12}x_2(t) + \dots + w_{1k}x_k(t) \\ s_k(t) &= w_{k1}x_1(t) + w_{k2}x_2(t) + \dots + w_{kk}x_k(t) \end{aligned} \quad (47)$$

Постановка и решение задачи слепого разделения источников в том виде, как это было сделано выше, к сожалению, оставляет открытыми множество вопросов.

Первый и очевидный вопрос – количество источников. Как следует из самой постановки задачи, ее строгое решение возможно лишь для числа независимых источников, совпадающего с числом наблюдаемых сигналов.

Второй вопрос – стационарность и линейность смешивания. Предполагаемая линейность, неизменность статистических характеристик источников и коэффициентов смешивающей матрицы на интервале наблюдения не отвечает свойствам большинства биомедицинских сигналов.

Третий вопрос – определение принадлежности выделенных источников. Согласно методу слепого разделения, значение конкретного источника смеси получается в результате линейной комбинации вектора наблюдения  $x(t)$  и строки матрицы разделяющих коэффициентов  $w(t)$ . Можно сказать, что каждому источнику соответствует своя строка в матрице разделяющих коэффициентов. Но специфика анализа независимых компонент такова, что при каждом новом получении матрицы разделяющих коэффициентов, строки матрицы соответствуют случайному источнику смеси.

Синтез модели слепого разделения источников и нейронной сети достигается объединением матрицы разделяющих и весовых коэффициентов.

Модель нейронной сети характеризуется гибкостью архитектуры. Возможность иметь разное количество нейронов во входном и выходном слоях позволит выделять источник смеси в условиях несоответствия размерностей векторов наблюдения и источников.

Значение вектора источников при слепом разделении получается в результате линейной комбинации, в то время как нейросетевой подход позволит использовать нелинейную функцию для описания состояния плода:

$$y(t) = f(w^T x(t)). \quad (48)$$

Динамические свойства некоторых нейросетевых моделей позволят ввести функциональную зависимость между выходом и временем, что позволит моделировать ЭКГП в условиях нестационарности процессов смешивания источников АЭКГ.

В ходе обучения весовые коэффициенты могут быть подобраны таким образом, что значения определенного источника разделяемого сигнала будут определяться выходными значениями определенного нейрона в выходном слое, что упрощает процедуру идентификации источников.

Структурная схема модели представлена на рисунке 26, для описания выхода модели может быть использовано уравнение:

$$y(t) = f(x(t), x(t-1), \dots, x(t-p), y(t-1), \dots, y(t-q), W), \quad (49)$$

где  $p$  и  $q$  обозначают емкость краткосрочной памяти нейронной сети.

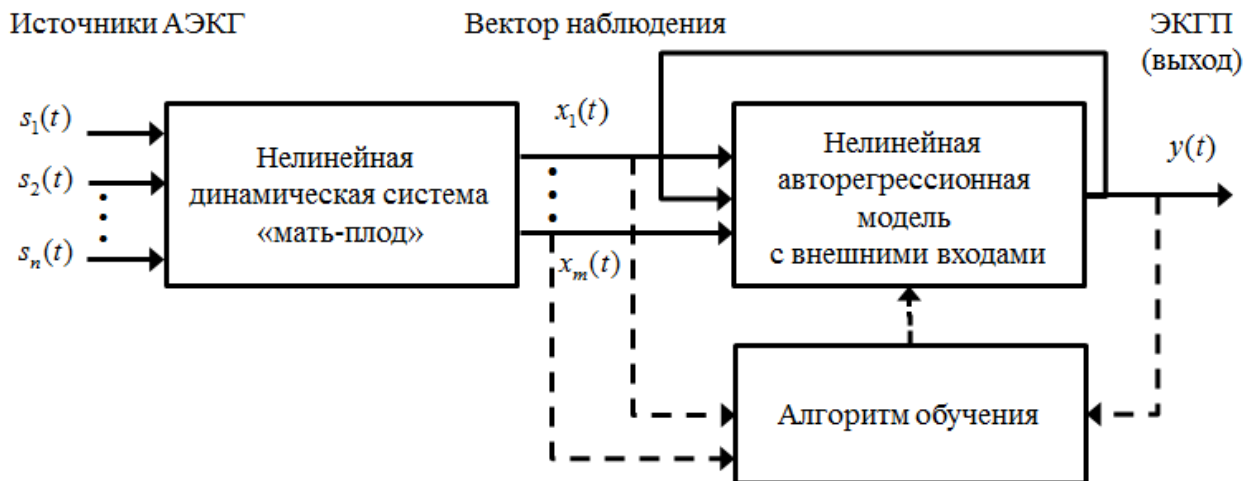


Рис. 26 Модель ЭКГП, полученная в результате синтеза моделей слепого разделения источников и искусственной нейронной сети

### 2.1.1 Ограничения нейронных сетей прямого распространения

Какой бы ни была сложной нейронная сеть прямого распространения, она не может учитывать временную структуру данных – расположение примеров

входного множества относительно друг друга. Множество нейронных сетей, в которых сигнал распространяется только прямым образом, не подходит для обработки временных рядов, в частности биомедицинских сигналов. К классу статических нейронных сетей можно отнести: многослойный перцептрон; радиально-базисные; сверточные и др.

Размерность входного вектора статической сети ограничена количеством входных нейронов. Если подавать весь временной ряд на вход сети, то:

1. необходимо большое количество весовых коэффициентов;
2. обучающее множество должно содержать сигналы одинаковой длительности.

Увеличение размерности скрытого слоя, изменение активационных функций, совместное использование весов и другие модификации многослойного перцептрона отражаются на скорости обучения, точности тестирования. Такие изменения носят количественный характер, для расширения же функциональных возможностей нейронных сетей необходимы качественные изменения их архитектуры, принимающие формы новых элементов.

## **2.2 Неявное представление времени в нейронной сети с краткосрочной памятью**

Временная структура данных – расположение элементов временного ряда относительно друг друга, является дополнительным источником информации[68]. Какую бы форму ни принимало время – непрерывную или дискретную, оно лежит в основе большинства задач распознавания временных образов и речи, обработки сигналов и управления. Встраивание времени в работу сети позволяет учесть статистические вариации нестационарного процесса[69-72]. Существуют явный и неявный подходы представления времени в сети

При неявном подходе за представление времени отвечает архитектура. В данном случае требуется существенное изменение принципов функционирования нейронной сети.

При явном подходе время имеет собственное конкретное представление [73], которое на каждой итерации подается на входной слой сети. Для такого представления можно использовать уже известные многослойные сети прямого распространения, в которых за время отвечают дополнительные нейроны во входном слое.

Наибольшее распространение получил неявный способ представления времени, так как только в таком случае учитывается временная структура данных – последовательность представления входных сигналов. Основой для создания такого типа сетей является многослойная сеть прямого распространения, однако для придания ей свойства динамичности требуется внедрение памяти.

В контексте нейроинформатики память может быть краткосрочной и долгосрочной. Последняя встраивается в сеть в процессе обучения, информация, содержащаяся в обучающей выборке, сохраняется в сети в виде весовых коэффициентов. Если решаемая задача имеет временную размерность, то для придания свойства динамичности используется краткосрочная память. Одним из базовых способов внедрения краткосрочной памяти в архитектуру нейронной сети является использование временных задержек, которые применяются к синаптическим весам и входным сигналам нейронов. Подобное решение является биологически мотивированным. Аналоги временных задержек встречаются в мозге и играют важную роль при обработке информации мозгом [74].

### *2.2.1 Структура кратковременной памяти на основе линий задержек*

Основная задача краткосрочной памяти заключается в преобразовании статической сети в динамическую. Внедрив память в архитектуру сети прямого распространения, мы получаем выходные сигналы, зависящие от времени. При таком подходе наблюдается разделение функций – статическая сеть отвечает за нелинейность, а память за время и динамику.

На рисунке 27 изображена блочная диаграмма базовой формы краткосрочной памяти, которая называется памятью на основе линии задержек с отводами [75]. При работе с дискретной формой времени полезным оказывается

Z-преобразование. Пусть  $\{x(n)\}$  – последовательность значений в дискретном времени. Преобразование такой последовательности определяется как:

$$X(z) = \sum_{n=-\infty}^{n=\infty} x(n)z^{-n}, \quad (50)$$

где  $z^{-1}$  – оператор единичной задержки. Это значит, что при применении оператора к  $x(n)$  формируется версия сигнала с задержкой  $x(n-1)$ .

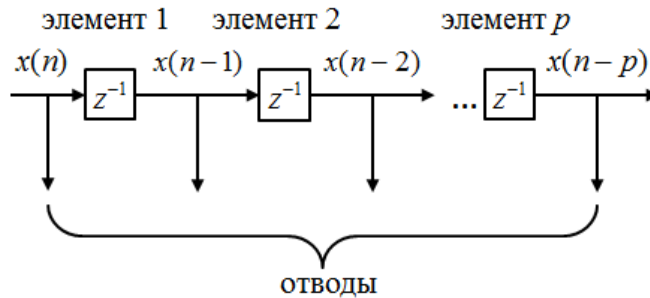


Рис. 27 Память на основе линии задержки с отводами

### 2.2.2 Память на основе обратных связей

Еще один способ неявного встраивания времени в нейростевую архитектуру подразумевает использование обратных связей. Обратные связи присутствуют в нейронной сети в двух видах: в виде локальной (на уровне текущего слоя) и глобальной (охватывающей всю сеть).

Наличие эффекта от таких связей расширяет традиционные области применения искусственных нейронных сетей. Также их использование может значительно сократить требование к памяти по сравнению с фокусированными или даже распределенными сетями.

Основой для сетей с обратными связями, также именуемых рекуррентными, является перцептрон. Применение обратных связей к данной модели может принимать различные формы. Можно замкнуть нейроны выходного слоя на нейроны входа. При наличии в сети одного или нескольких скрытых слоев, становится возможным создание множества отличных друг от друга архитектур сетей. Все это приводит к богатому спектру топологий динамических сетей.

### 2.2.3 Сеть с фокусированной временной задержкой

Использование памяти на основе задержек позволяет распознавать изменяющиеся во времени образы. Это достигается за счет использования не только текущего, но и некоторого количества предыдущих значений входного сигнала.

Объединенные многослойный перцептрон и память на основе линии задержек формирует динамическую архитектуру нейронной сети – фокусированную сеть прямого распространения с задержкой по времени, изображенную на рисунке 28.




Рис. 28 Фокусированная сеть прямого распространения с задержкой по времени

Временная информация, содержащаяся во входном сигнале, извлекается памятью, которая затем передает нейрону через весовые коэффициенты. Нейрон, содержащий в себе форму такой краткосрочной памяти, называется фокусированным. Под фокусировкой понимается концентрация всей памяти на переднем плане нейрона. Выход этого нейрона на входной сигнал  $x(n)$  и его предыдущие значения  $x(n-1), \dots, x(n-p)$  вычисляется по формуле:

$$y_j(n) = \varphi\left(\sum_{l=0}^p w_j(l)x(n-l) + b_j\right), \quad (51)$$



где  $\varphi(\cdot)$  – активационная функция нейрона  $j$ ;  $w_j(l)$  – весовые коэффициенты;  $b_j$  – смещение. Активационный потенциал получается через суммирование смещения и свертки последовательности входных сигналов и весовых коэффициентов.

Возможно и такое построение сети, при котором неявное представление времени распределено по всей сети, а не только на нейронах входного слоя.

#### 2.2.4 Нелинейная авторегрессионная модель с внешними входами

На рисунке 29 изображена структура обобщенной рекуррентной сети, в основе которой лежит многослойный перцептрон. У модели имеется единственный вход, к которому применена память на линиях задержки, включающей в себя  $q$  элементов. У сети единственный выход, замкнутый на вход памяти на линиях задержки, аналогично состоящей из  $q$  элементов. Содержимое этих двух блоков памяти используется для подачи входного сигнала на перцептрон. Вход модели обозначается как  $u(n)$ , а соответствующий выход как  $y(n+1)$ .

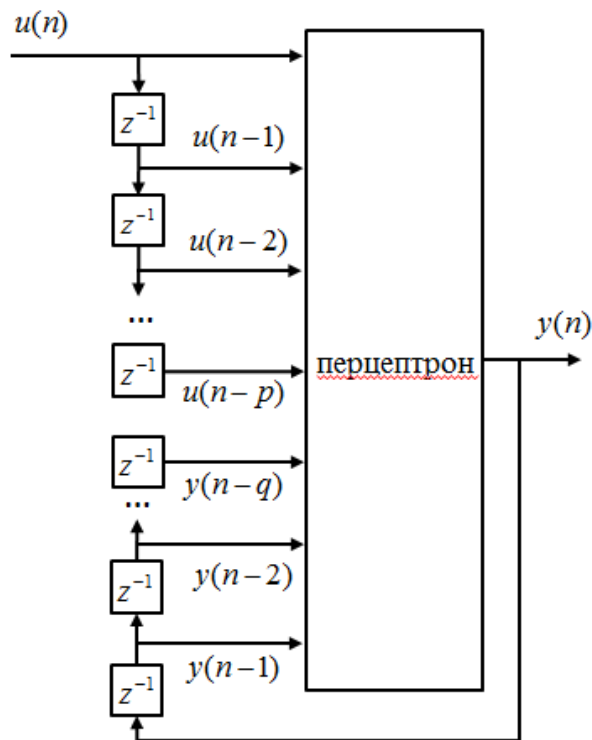


Рис. 29 Модель нелинейной авторегрессии с внешними входами

Таким образом, выходной сигнал сети опережает ее вход на одну единицу времени. Сигнал-вектор, подающийся на входной слой сети, состоит из окон данных, включающих в себя:

- Текущее значение входного сигнала  $u(n)$ ;
- Предыдущие значения входного и выходного сигналов  $u(n-1), u(n-2), \dots, u(n-p), y(n-1), y(n-2), \dots, y(n-q)$ .

Такая форма рекуррентной сети имеет название нелинейная авторегрессионная модель с внешними входами. Ее динамика описывается (52):

$$y(n) = F(y(n-1), \dots, y(n-q), u(n), \dots, u(n-p)), \quad (52)$$

где  $F$  – некая нелинейная функция своих аргументов. Модель предполагает одинаковую размерность двух типов памяти. В частном случае они могут отличаться.

### *2.2.5 Анализ эффективности динамических нейронных сетей для оценки сердечной активности плода*

Сети Хопфилда и Хэмминга, несмотря на то, что являются динамическими, по ряду причин не подходят для решения вышепоставленной задачи. Эти сети в основном решают задачи восстановления поврежденных образов или их классификации за счет автоассоциативной памяти [76-78]. Существенным ограничением этих сетей является размер памяти. Количество образов, которые могут запомнить сети, определяется (53):

$$M \approx \frac{N}{2 \log_2 N}, \quad (53)$$

где  $N$  – количество нейронов сети. Сеть Хэмминга работает с бинарными сигналами, определяя Хэммингово расстояние от классифицируемого образа до некоторого желаемого отклика, который находится в памяти.

Динамические сети с временными задержками, но без обратных связей могут решать задачи прогнозирования временных рядов. Однако сети с обратными связями решают эти задачи с более высокой точностью, что отражено

как в работах первооткрывателей рекуррентных нейронных сетей, так и в современных публикациях.

В работах [81,82] приводится анализ эффективности прогнозирования выработки электроэнергии с помощью статических и динамических нейросетевых архитектур. Сравнительная оценка осуществлялась по таким показателям как точность, скорость обучения, количество настраиваемых весов. В задачу сетей входило прогнозирование значения  $x(t+1)$  с использованием текущего и четырех предыдущих значений  $x$ . Обучающая выборка включала 500 значений, а критерием останова обучения являлось максимальное число эпох обучения – 30000. Показатели эффективности статической и динамической сети при работе с обучающими и валидационными данными были практически идентичными. Но при обработке тестовых данных рекуррентные сети доставляли вдвое меньшую среднеквадратичную ошибку, чем статические.

Многообразие рекуррентных моделей обусловлено рекуррентными связями, которые могут быть как локальными, так и глобальными. В ряде работ [83-84] проводились исследования эффективности моделирования динамических процессов с помощью различных рекуррентных нейронных сетей. Во всех случаях нелинейные авторегрессионные модели показали большую эффективность, нежели другие формы рекуррентных нейронных сетей. Преимущества этих сетей заключались в том, что при том же количестве скрытых нейронов, порядке обратных связей и активационных функциях минимум целевой функции ошибки достигался за меньшее число итераций. Среднеквадратичная ошибка на тестовых примерах была меньше на 2-3 порядка. Так же авторы независимо друг от друга отмечали более качественное обучение долгосрочным зависимостям при наличии у сетей обратных связей, замыкающих выход сети на ее вход. Проблема обращения градиентов в ноль не решалась полностью нелинейной авторегрессионной сетью, но была менее ярко выражена по сравнению с сетями Элмана и Джордана.

Таким образом, можно сделать вывод о целесообразности использования нелинейной авторегрессионной модели с внешними входами для оценки

сердечной активности плода. Такие сети обладают двумя типами краткосрочной памяти: на основе линий задержек и обратных связей. Объем этой памяти не ограничен как у сетей Хэмминга и Хопфилда. Обучение долгосрочным зависимостям и прогнозирование временных рядов происходит более качественно по сравнению с другими формами рекуррентных нейронных сетей.

### **2.3 Обратное распространение ошибки во времени для обучения развернутой нейронной сети**

Самым важным свойством нейронных сетей является их способность обучаться на основе данных окружающей среды и в результате обучения повышать свою производительность. Повышение производительности осуществляется с течением времени и в соответствии с определенными правилами. Обучение происходит посредством интерактивного процесса корректировки синаптических весов и порогов. В идеальном случае нейронная сеть получает знания об окружающей среде на каждой итерации процесса обучения. С позиций нейронной сети для обучения мы будем использовать следующее определение, приведенное в [85].

Обучение – это процесс, в котором свободные параметры нейронной сети настраиваются посредством моделирования среды, в которую эта сеть встроена. Тип обучения определяется способом подстройки этих параметров.

#### *2.3.1 Развертывание динамической сети*

Концептуальное отличие обучения динамических сетей от статических заключается в необходимости соблюдения последовательности представления примеров из обучающей выборки. При решении задач классификации эвристические рекомендации включают в себя случайное представление примеров и разделение выборки на обучающую, тестовую и валидационную. В динамических сетях такой подход не имеет смысла, так как важна последовательность значений.

В связи с тем, что множество динамических сетей может быть обобщено до рекуррентного перцептрона, возникает вопрос – возможно ли для обучения динамических сетей применить методы, используемые в обучении статических сетей? Алгоритм обратного распространения ошибки может быть применен к обучению динамической сети, при условии выполнения преобразований как архитектуры сети, так и алгоритма обучения статической сети.

Развертывание динамической сети в многослойную сеть прямого распространения происходит путем включения в перцептрон дополнительного слоя за каждый интервал времени. Обучение может происходить как в пакетном, так и в последовательном режиме.

Идея, которая заключается в алгоритме обратного распространения во времени, заключается в создании сети прямого распространения, которая бы обеспечивала такую же динамику через некоторый интервал времени, что и рекуррентная. Алгоритм обратного распространения во времени впервые был представлен в диссертационной работе Вербоса [86]. Этот подход независимо от него был описан в работе [87].

Этап, предшествующий вычислительному, представляет собой развертывание динамической сети в статическую. Этот процесс индивидуален для каждой динамической сети. В результате могут получаться как полносвязные, так и неполносвязные сети прямого распространения.

Пусть  $N^*$  – сеть прямого распространения, которая получилась через развёртывание временных операций динамической сети  $N$ . Развернутая сеть  $N^*$  получена из исходной сети  $N$  следующим образом:

- Каждый шаг времени из интервала  $[n_0, n]$  добавляет в сеть  $N^*$  слой, включающий в себя  $K$  нейронов, где  $K$  – множество нейронов в исходном слое сети  $N$ ;
- Каждый слой сети  $N^*$  содержит копии каждого нейрона сети  $N$ .
- Для каждого момента времени  $l \in [n_0, n]$  весовые коэффициенты нейрона  $i$ -го слоя в момент времени  $l$  до нейрона  $j$ -го слоя в момент

времени  $(l+1)$  сети  $N^*$  представляют собой копии весовых коэффициентов между этими же нейронами сети  $N$ .

Разворачивание рекуррентного нейрона сети  $N$  в соответствующую ему статическую сеть  $N^*$  изображено на рисунке 30.




Рис. 30 а) Нейрон с обратной связью  $N$ ; б) статическую сеть  $N^*$

Весовой коэффициент, характеризующий синапс, по которому поступает входной сигнал, обозначен как  $w$ . Обратная связь характеризуется весом  $w^*$ . В статической сети  $N^*$  все весовые коэффициенты, обозначенные как  $w$ , принимают одинаковые значения в любой момент времени. По сути это один вес, применяемый сразу к нескольким слоям. Подобным же образом используется вес  $w^*$ . Разворачивание полносвязной рекуррентной сети, в статический аналог показано на рисунке 31.

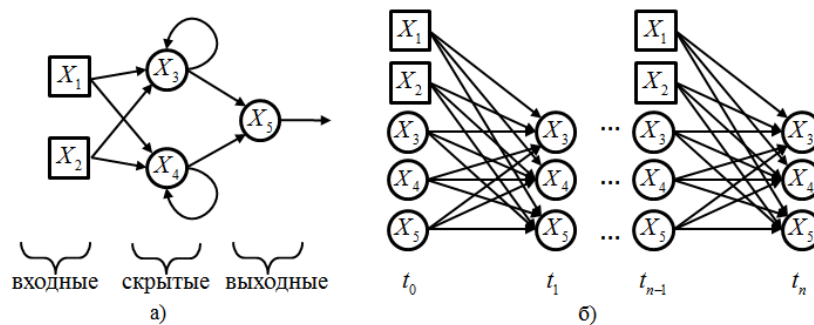


Рис. 31 а) Полносвязная динамическая сеть  $N$  в б) многослойный перцептрон  $N^*$

### 2.3.2 Обратное распространение ошибки во времени

Пусть множество данных, используемое в обучении динамической сети, разделено на независимые отрезки времени, каждый из которых является эпохой.

Обозначим  $n_0$  – момент начала эпохи;  $n^*$  – момент ее окончания. Рассмотрим такую эпоху, определим функцию ее стоимости как (54):

$$E_{\text{общ}}(n_0, n_1) = \frac{1}{2} \sum_{n=n_0}^{n^*} \sum_{j \in A} e_j^2(n), \quad (54)$$

где  $A$  – множество нейронов выходного слоя, для каждого из которых определен желаемый отклик;  $e_j(n)$  – сигнал ошибки на выходе этих нейронов, полученный относительно некоторого желаемого значения.

При обучении статических сетей желаемый отклик был известен только нейронам выходного слоя. Однако при обучении динамических сетей, ее развернутая статическая версия не должна классифицироваться как комбинация нескольких скрытых и выходного слоев. В такой сети отдельно взятый нейрон может являться как скрытым, в том плане, что выход его нейронов не формирует выход сети, так и выходным, в том плане, что для него известен желаемый отклик.

Вычисление значений локальных градиентов осуществляется посредством единичной обратной передачи через последнюю запись (55):

$$\delta_j(n) = -\frac{\partial E_{\text{общ}}(n_0, n_1)}{\partial v_j(n)}, \quad (55)$$

где для всех  $j \in A$  и  $n_0 \leq n \leq n_1$ . Для вычисления локальных градиентов нейронов сети, полученной в результате развертывания, мы ввели обобщенную формулу, которая учитывает принадлежность нейрона скрытому или выходному слою до развертывания (56):

$$\delta_i^k(n) = \begin{cases} \varphi'(v_i^k(n) e_i^k(n)), & k = NL \\ \varphi'(v_i^k(n)) \left[ e_i^k(n) + \sum_{j \in A} w_{ij}^k \delta_i^{k+1}(n+1) \right], & k \in O \\ \varphi'(v_i^k(n)) \left[ \sum_{j \in A} w_{ij}^k \delta_i^{k+1}(n+1) \right], & k \in H, \quad H \notin O, \end{cases} \quad (56)$$

где индекс  $k$  обозначает принадлежность нейрона слою;  $L$  – количество слоев развернутой сети;  $N$  длительность входного сигнала, соответственно, если индекс нейрона  $k = NL$ , то он относится к выходному слою развернутой сети. Нейроны, принадлежащие множеству  $H$ , были получены в результате развертывания скрытых нейронов, для них неизвестен желаемый отклик. Для нейронов, входящих во множество  $O$ , желаемый отклик известен, так как они были получены в результате разворачивания нейронов выходного слоя сети  $N$ . Вычисления по формуле (75) выполняются итеративно с момента времени  $n_1$  и завершается по достижению момента  $n_0$ .

Коррекция веса должна осуществляться таким образом, чтобы все веса, полученные в результате развертывания, были изменены на одну и ту же величину.

### *2.3.3 Параллельное, параллельно-последовательное развертывание*

В работе [88] описывается эффект усиления учителя, который возникает при обучении динамической сети выходной слой которой дополнен обратной связью. В основе усиления учителя лежит замещение реальных выходных сигналов желаемыми откликами во время обучения. Развернутая динамическая сеть становится параллельно-последовательной [89] и ее динамика при прямом проходе сигнала описывается как (57):

$$y(n) = F(y_o(n-1), \dots, y_o(n-q), u(n), \dots, u(n-q)), \quad (57)$$

где  $y_o$  – желаемый отклик сети, взятый из обучающей выборки.

При отсутствии прямой связи между текущим и фактическими предыдущими откликами сети можно сделать вывод о том, что динамическая нейронная сеть развертывается не в глубокую статическую сеть, а в перцептрон с одним скрытым слоем. Одно из преимуществ данного подхода заключается в том, что количество слоев динамической сети и соответствующей ей статической одинаково.



В диссертационной работе алгоритм обратного распространения во времени реализован таким образом, что желаемый отклик используется лишь для вычисления ошибок. Развертывание происходит в глубокую нейронную сеть, а при прямом и обратном проходе сигнала выходной нейрон берет фактические предыдущие значения из краткосрочной памяти, т.е. происходит параллельное развертывание.

## 2.4 Проблемы обучения динамических сетей

Обучение глубоких и динамических сетей сопряжено со схожими проблемами. Это происходит из-за того, что динамическая сеть в процессе развертывания дополняется новыми слоями, количество которых зависит от длительности входного сигнала.

Несмотря на наличие множества эвристик, направленных на упрощение процесса обучения, алгоритм обратного распространения менее эффективен при обучении сетей, у которых имеется несколько скрытых слоев. В работах [77-78] математически показана сходимости алгоритма обратного распространения для любой сети, при условии бесконечно малого изменения весов. На практике же эффект обучения не доходит до дальних слоев сети в связи с обращением градиентов в ноль.

На рисунке 32 показано изменение скорости обучения порогового смещения в зависимости от слоя. Значение скорости в данный момент времени определяется как значение локального градиента нейрона – произведения производной активационной функции на ошибку. В случае с производной целевой функции не по весу нейрона, а по смещению  $b$  мы можем поставить знак равенства между:

$$\frac{\partial E(n)}{\partial b_j^l(n)} = \frac{\partial E(n)}{\partial v_j^l(n)} = \delta_j^l(n), \quad (58)$$

где  $l$  – индекс слоя,  $j$  – индекс нейрона в слое. Длину вектора  $\delta_j^l(n)$  можно использовать как оценку скорость изменения весового коэффициента.

В качестве сети использовался многослойный перцептрон, обученный на базе данных рукописных изображений MNIST. Весовые коэффициенты инициализировали случайным образом в диапазоне  $[-1;1]$ . Как видно из графиков, чем дальше нейрон находится от выхода сети, тем меньше его изменение за итерацию. Порядок максимального изменения весов в 1-ом скрытом слое равен минимальному в 4-ом. Это свидетельствует о затухании градиента нейрона в 1-м скрытом слое.

Предположение о том, что малое изменение весовых коэффициентов свидетельствует о близости к минимуму функции, является ошибочным, так как весовые коэффициенты определены случайным образом.




Рис. 32 Коррекция веса в нейронной сети в зависимости от удаленности скрытого слоя от выходного слоя

#### 2.4.1 Затухание градиента вследствие долгосрочных зависимостей

Комбинированные нелинейности приводят к тому, что бесконечно малые изменения в удаленном во времени входном сигнале практически не оказывают воздействие на обучение сети, а большие изменения приводят к изменениям, но эффект не измерим градиентом. Описанная проблема делает обучение долгосрочным зависимостям градиентными алгоритмами чрезвычайно сложным.

В работе [80] для обобщённой модели динамической нейронной сети, было показано, что коррекция вектора весов в момент времени  $n$  определяется как:

$$\Delta w(n) = \eta \sum_i \frac{\partial y_i(n)}{\partial x_i(n)} \sum_{k=1}^n \frac{\partial x_i(n)}{\partial x_i(k)} \frac{\partial x_i(k)}{\partial w(k)} (d_i(n) - y_i(n)), \quad (59)$$

где  $i$  – обучающий пример из выборки;  $y_i(n)$  – фактический отклик сети;  $d_i(n)$  – желаемый отклик сети;  $x_i(n)$  – вектор состояния сети. Вектор состояния определяется по формуле (60):

$$x_i(n) = \varphi(x_i(k), u(n)), \quad 1 \leq k < n. \quad (60)$$

Таким образом,  $\partial x_i(n) / \partial x_i(k)$  интерпретируется как Якобиан нелинейной функции активации  $\varphi(\cdot, \cdot)$ , развернутой на  $(n-k)$  моментов времени,

$$\frac{\partial x_i(n)}{\partial x_i(k)} = \frac{\partial \varphi(x_i(k), u(n))}{\partial x_i(k)} = J_x(n, n-k). \quad (61)$$

Якобиан в свою очередь является экспоненциально убывающей функцией  $k$  (62):

$$\det(J_x(n, k)) \rightarrow 0 \text{ при } k \rightarrow \infty \text{ для всех } n. \quad (62)$$

Малое изменение вектора весов  $w$  сети ощущается в ближайшем прошлом (т.е. в значениях близких к текущему времени  $n$ ).

Обучение сети к выявлению долгосрочных зависимостей затрудняется прямой зависимостью величины коррекции веса от локального градиента. В ходе вычисления величины коррекции производные от функции стоимости вычисляются как в текущий момент времени  $n$ , так и в предыдущие моменты времени, пока не будет достигнут момент времени  $(n-k)$ . При суммировании этих величин краткосрочные зависимости оказывают преобладающее влияние на состояние сети

#### 2.4.2 Затухание градиента из-за линейности обратного распространения

Обратный проход вычислений при обучении нейронной сети в отличие от прямого является линейным. При обратном проходе локальный градиент нейрона можно интерпретировать как выход нейрона в другую сторону. Значение градиента веса нейрона более глубокого слоя пропорционально значению производной функции активации в точке, полученной на прямом проходе.

Рассмотрим определение производной в точке:

$$f_i(x) \equiv f(x_0) + f'(x_0)(x - x_0), \quad (63)$$

Значение в  $x_0$  вычисляется при прямом проходе. На обратном проходе вычисляется тангенс угла наклона касательной активационной функции в точке  $x_0$ . Так как значение тангенса лежит в интервале от минус до плюс бесконечности, то при многократной линейной комбинации весов и локальных градиентов мы имеем, так называемый, взрыв или затухание градиента при слишком большом или малом значении производной соответственно.

Рассмотрим простейшую модель глубокой нейронной сети, изображенную на рисунке 33.




Рис. 33 Глубокая нейронная сеть

Согласно обратному распространению, производная ошибки по смещению  $b_1$  определяется по следующей формуле (67):

$$\frac{\partial E}{\partial b_1} = f'(v_1)w_2 f'(v_2) \dots w_{n-1} f'(v_{n-1})w_n \frac{\partial E}{\partial v_n}, \quad (64)$$

где  $f'(v_1)$  производная активационной функции нейрона. Рассмотрим график производной сигмоидальной активационной функции, изображенной на рисунке 34. Максимум функции достигается в нуле и равняется 0.25. Стандартный подход к инициализации весовых коэффициентов предполагает использование нормального распределения. Таким образом, выполняется условие:  $|w_j| < 1$ , Следовательно, при обратном распространении ошибки  $|w_j f'(v_j)| < 0.25$ , а это значит, что существует перманентное затухание градиента из-за того, что наибольшее значение тангенса угла наклона касательной будет 0.25. Эти

значения, от слоя к слою перемножаются. Таким образом, причина затухание градиентов может быть описано следующей формулой (68):

$$\frac{\partial E}{\partial b_1} = f'(v_1) \overbrace{w_2}^{<0,25} f'(v_2) \dots \overbrace{w_{n-1}}^{<0,25} f'(v_{n-1}) w_n \frac{\partial E}{\partial v_n}. \quad (65)$$




Рис. 34 Производная сигмоидальной активационной функции

## 2.5 Численный метод Resilient propagation и его модификация для глубокого, динамического обучения развернутой нейронной сети

Выделим три пути решения проблемы обучения динамических сетей долгосрочным зависимостям.

Первый – предполагает использование предобучения ограниченными машинами Больцмана. В ряде работ [91-93] показана эффективность процесса предварительной настройки весов, отличающегося от случайного присвоения значений.

Второй – заключается в использовании усовершенствованных архитектур динамических нейронных сетей, примером которой может модель LSTM [94], эффективность которой продемонстрирована на примере онлайн распознавания рукописных изображений [95,96].

Третий – подразумевает разработку новых алгоритмов обучения нейронных сетей и усовершенствования существующих, в том числе и за счет внедрения различных методов регуляризации.

В диссертации делается акцент на последний путь развития как наиболее приоритетный. Эффективность предобучения на сегодняшний день носит лишь

эмпирическое подтверждение. Даже в случае удачной начальной инициализации некорректный алгоритм обучения может привести к обращению градиентов в ноль. Разработка новых архитектур часто приводит к созданию узкоспециализированных моделей, приспособленных к работе с ограниченным типом данных, например, сверточных нейронных сетей. К тому же, ни предобучение, ни разработка новых архитектур не решают фундаментальную проблему линейности обратного распространения.

Для эффективного обучения динамической нейронной сети долгосрочным зависимостям на основе данных с временной структурой мы разработали новый алгоритм обучения.

### *2.5.1 Обучение, основанное на изменении знака производной*

Недостатки обучения на основе обратного распространения дали импульс к развитию группы алгоритмов обучения, которые в той или иной форме использовали знак производной функции ошибки по весу для определения величины коррекции. Среди них наиболее эффективным на сегодняшний день является алгоритм Resilient propagation (Rprop) [97]. Автор доказал, что любой градиентный алгоритм обучения, в том числе и основанный на методах оптимизации второго порядка, подвержен негативному влиянию зависимости величины коррекции веса от величины производной ошибки по этому весу. Как показано на рисунке 35 алгоритм обучения может приводить как к попаданию в локальный минимум, так и к расходимости.

Для решения этой проблемы необходимо эмпирически подбирать как корректные параметры алгоритмы обучения, так и определять их динамику. Изначально, алгоритм разрабатывался для обучения перцептронов. Однако в ряде работ [98-99] была показана эффективность алгоритма Rprop при глубоком обучении. В связи с этим было решено исследовать эффективность обучения на основе знака производной для параллельно развернутой нелинейной авторегрессии с внешними входами.




Рис. 35 Геометрическая интерпретация проблемы градиентных алгоритмов обучения нейронных сетей

### 2.5.2 Алгоритм Resilient propagation во времени

В зависимости от знака частной производной и ее динамики величина коррекция может быть определена по формуле (66):

$$\Delta w_{ij}(t) = \begin{cases} -\Delta_{ij}^{(t)} \eta, \frac{\partial E^{(t)}}{\partial w_{ij}} > 0 \\ +\Delta_{ij}^{(t)} \eta, \frac{\partial E^{(t)}}{\partial w_{ij}} < 0 \\ 0, \frac{\partial E^{(t)}}{\partial w_{ij}} = 0 \end{cases} \quad (66)$$

где  $\Delta_{ij}$  – начальное значение коррекции, инициализируемое аналогично весовым коэффициентам;  $\eta$  определяется (67):

$$\eta = \begin{cases} \eta^+, \frac{\partial E^{(t)}}{\partial w_{ij}} \cdot \frac{\partial E^{(t-1)}}{\partial w_{ij}} > 0 \\ \eta^-, \frac{\partial E^{(t)}}{\partial w_{ij}} \cdot \frac{\partial E^{(t-1)}}{\partial w_{ij}} < 0 \end{cases}, \quad (67)$$

$$0 < \eta^- < 1 < \eta^+,$$

где  $t$  – эпоха обучения;  $\eta^+$ ,  $\eta^-$  – параметры скорости обучения.

Если знак частной производной не изменился, то нужно увеличить величину коррекции на  $\eta^+$  для достижения более быстрой сходимости. Если на текущем шаге частная производная по соответствующему весу поменяла свой знак, то это говорит о том, что последнее изменение было чрезмерным, и

алгоритм проскочил локальный минимум, следовательно, величину изменения необходимо уменьшить и вернуть предыдущее значение весового коэффициента.

Выражения (69), (70) применимы исключительно для обучения статических сетей. Алгоритм Resilient propagation не учитывает специфику динамических сетей, а именно влияние процесса развертывания на изменение величины коррекции. Научная новизна диссертационной работы, заключается в усовершенствовании алгоритма обучения Resilient propagation, которое бы позволило успешно обучать динамические нейронные сети.

В любой момент времени для веса  $w$  динамической, неразвернутой нейронной сети  $N$  и веса  $w^*$  сети  $N^*$ , полученной в результате развертывания должно соблюдаться условие (68):

$$w_{ij}^k = \begin{cases} w_{ij}^{*o}, & \forall o, k \in O \\ w_{ij}^{*h}, & \forall h, k \in H \end{cases} \quad (68)$$

где  $O, H$  – множества нейронов сети  $N^*$ , полученных в результате развертывания выходных и скрытых нейронов сети  $N$  соответственно. Выполнение условия (71) достигается, когда для всех слоев весовые коэффициенты с одинаковыми индексами  $i$  и  $j$ , полученные в результате развертывания динамической сети, равны между собой. Отсюда следует, что к ним необходимо применять одинаковую коррекцию. Обратное распространение ошибки во времени, выполняет (69) за счет суммирования коррекций весов с одинаковыми индексами со всех слоев, полученных в результате развертывания динамической сети:

$$\Delta w_{ij}^k = \begin{cases} \sum_{o \in O} \Delta w_{ij}^{*o}, \\ \sum_{h \in H} \Delta w_{ij}^{*h}. \end{cases} \quad (69)$$

Однако если применить подобный принцип к алгоритму Resilient propagation, то алгоритм обучения столкнется с двумя проблемами:

1. Значение множителя величины коррекции  $\eta^-$  перестает быть константой и ее значение линейно зависит от длительности входного



сигнала, что может привести к случаю, когда  $\eta^- \notin (0,1)$ , что противоречит (70);

2. В случае  $\frac{\partial E^{(t)}}{\partial w_{ij}} \frac{\partial E^{(t-1)}}{\partial w_{ij}} > 0$  многократное суммирование коррекций веса может привести к чрезмерно высокой коррекции веса, а это, в свою очередь, приведет к расходимости алгоритма обучения.

Геометрическая интерпретация проблем обучения динамических нейронных сетей с помощью стандартного алгоритма Rprop представлена на рисунке 36.

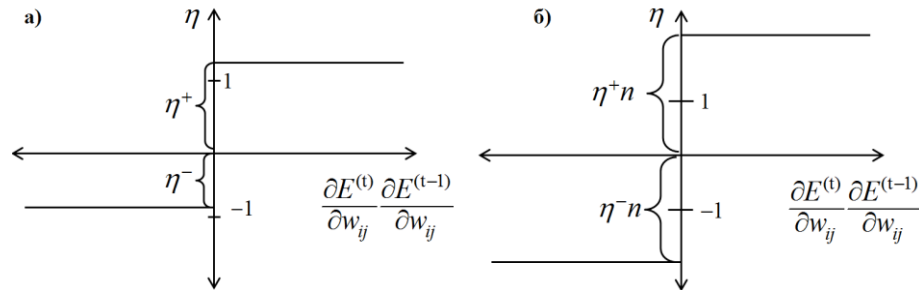


Рис. 36 Зависимость параметра  $\eta$  алгоритма Rprop от типа сети: а) статической; б) динамической, развернутой в статическую;

При обратном распространении ошибки во времени коррекция веса линейно зависит от длительности входного сигнала и производной ошибки по весу, а сумма линейных функций является линейной функцией:

$$\Delta w_{ij}^k = f \left( \sum \frac{\partial E}{\partial w_{ij}}, n, \Delta_{ij} \right) = \sum f \left( \frac{\partial E}{\partial w_{ij}}, n, \Delta_{ij} \right). \quad (70)$$

Алгоритм Rprop определяет величину коррекции нелинейно, а значит:

$$\sum_{k=1}^n \Delta w_{ij}^k \neq f \left( \sum_{k=1}^n \frac{\partial E^{(t)}}{\partial w_{ij}^k}, \sum_{k=1}^n \frac{\partial E^{(t-1)}}{\partial w_{ij}^k} \right). \quad (71)$$

Таким образом, для соблюдения условия  $\eta^- \in (0,1)$ , а также предотвращения расходимости алгоритма обучения при взрывном росте веса мы вводим следующее правило определения величины коррекции (72):

$$\eta = \begin{cases} \eta^+, \sum_{k=1}^n \frac{\partial E(k)^{(t)}}{\partial w_{ij}^k} \cdot \sum_{k=1}^n \frac{\partial E(k)^{(t-1)}}{\partial w_{ij}^k} > 0 \\ \eta^-, \sum_{k=1}^n \frac{\partial E(k)^{(t)}}{\partial w_{ij}^k} \cdot \sum_{k=1}^n \frac{\partial E(k)^{(t-1)}}{\partial w_{ij}^k} < 0 \end{cases}, \quad (72)$$

$$0 < \eta^- < 1 < \eta^+,$$

где  $n$  – длительность входного сигнала;  $t$  – эпоха обучения;  $k$  – индекс слоя нейрона;  $w$  – весовой коэффициент, соединяющий  $i$ -ый нейрона слоя  $k$  с  $j$ -ым нейроном слоя  $k+1$ .

Таким образом, мы получили алгоритм для обучения динамических нейронных сетей, который определяет величину коррекции веса в зависимости от изменения знака суммы частных производных целевой функции по этому весу для всех моментов времени  $n$ .

При вычислении локальных градиентов учитывается влияние параллельного развертывания динамической сети в статическую. Это достигается за счет использования обратного распространения во времени, которое вычисляет локальный градиент нейрона в зависимости от того, был ли он получен в результате развертывания скрытого или выходного нейрона.

Оценка временной и пространственной сложности алгоритма Rprop проводилась в [100], в отличие от алгоритмов: Левенберга-Марквардта; градиентного спуска и др. вычислительная сложность линейно зависит от количества настраиваемых параметров сети. Модификация, предложенная в работе, не привносит дополнительных вычислений, а меняет способ определения коррекции веса в зависимости от частных производных целевой функции по весу.

## 2.6 Выводы по главе

1. Предложена модель разделения источников абдоминальной электрокардиограммы, основанная на синтезе искусственных нейронных сетей и модели слепого разделения источников. Коэффициенты разделяющей матрицы модели слепого разделения источников представляются как весовые коэффициенты параллельно развернутой нелинейной авторегрессионной модели с внешними входами. Для поиска значений коэффициентов которой используется алгоритм обучения нейронной сети;
2. Выделена проблема обращения градиентов в ноль при обучении динамических нейронных сетей долгосрочным зависимостям, причиной возникновения которой является линейность обратного распространения ошибки;
3. Для обучения нейронной сети, полученной в результате параллельного развертывания нелинейной авторегрессионной модели с внешними входами, разработан алгоритм Resilient propagation во времени. Алгоритм определяет величину коррекции совместно используемого веса в зависимости от изменения знака суммы частных производных целевой функции по этому весу для всех моментов времени
4. Предложен обобщённый подход к вычислению локального градиента нейрона глубокой нейронной сети с перекрестными связями в зависимости от того, был ли он получен в результате развертывания скрытого или выходного нейрона.

### **Глава 3. Результаты вычислительных экспериментов**

#### **3.1 Формирование обучающей и тестирующей выборок**

Данные были получены из общедоступной электронной онлайн библиотеки “[physionet.org](http://physionet.org)”, находятся в сети в открытом доступе и были предоставлены научному сообществу Силезским медицинским университетом, Польша.

Пример реального сигнала плода и его версии с выровненной изолинией приведены на рисунке 37. Пример записи с абдоминального отведения и соответствующий ей желаемый отклик представлены на рисунке 38, базовые линии сигналов выровнены, значения приведены к безразмерной величине. Такие пары входных-выходных сигналов составляют обучающую и тестовую выборки.

Набор сигналов включал в себя пятиканальные записи длительностью 60 секунд с частотой дискретизации 1 кГц. Общее количество записей составляло 25, количество R-пиков – 4930.

Первый-четвертый каналы представляли собой записи материнских электрокардиограмм, снятых с абдоминального отведения. Эти сигналы подавались на вход нейронной сети. Причем для каждого человека формировалось два типа входных сигналов: одномерный и многомерный. Многомерный входной сигнал включал в себя АЭКГ из 4-ёх отведений. Пятый канал содержал электрокардиограмму плода, полученную инвазивным путем, которая использовалась в качестве желаемого отклика.

Для обучения нейронных сетей формировалась выборка, длительность которой составляла 120 секунд. В ее создании принимали участие 10-ти секундные отрезки сигналов, взятые у 12 из 25 человек. Тестовая выборка включала в себя все сигналы, кроме тех, которые принимали участие в формировании обучающей выборки.

Использование неполного набора сигналов при обучении позволяло оценить устойчивость модели к вариабельности частоты сердечных сокращений плода, изменению соотношения сигнала-шума, формы R-волн.

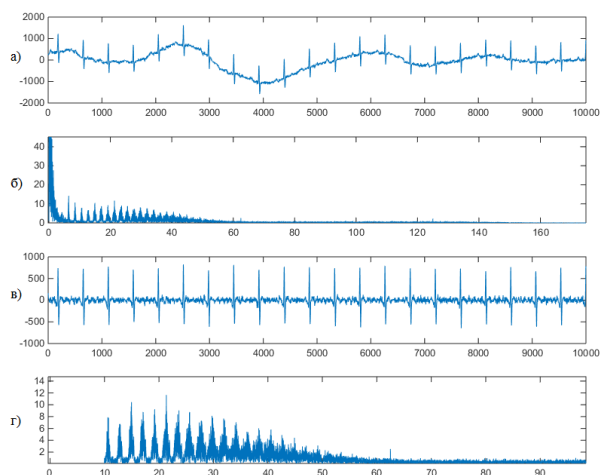


Рис. 37 ЭКГ плода: а) исходная версия сигнала; б) амплитудный спектр; в) фильтрованная версия сигнала; г) амплитудный спектр фильтрованной версии

Широко распространенным является подход к обучению, в ходе которого валидационная выборка служит для оценки качества обучения. Критерием остановки обучения является показатель среднеквадратичной ошибки, полученный на валидационных, а не обучающих примерах. Мы не использовали такую выборку, так как оценивали точность работы по количеству правильно распознанных R-пиков, что не является поддерживаемой формой оценки качества обучения нейронной сети в пакете Matlab Neural Network Toolbox.

Для оценки индивидуальной особенности сигнала мы ввели такую характеристику абдоминальной электрокардиограммы, как соотношение амплитуды R-пиков матери и плода (АМП). В ряде вычислительных экспериментов мы проводили обучение и тестирование нейронной сети на двух дополнительных выборках, сформированных с использованием данного показателя.

Первая дополнительная обучающая выборка включала в себя 10-ти секундную одноканальную АЭКГ от одного человека с показателем АМП равным 1.4, а тестовая выборка включала в себя 50-ти секундный отрезок АЭКГ от этого же человека. Вторая дополнительная обучающая выборка включала в себя 10-ти секундную одноканальную АЭКГ от одного человека с показателем АМП равным

б, а тестовая выборка включала в себя 50-ти секундный отрезок АЭКГ от этого же человека.




Рис. 38 Входной сигнал (абдоминальная ЭКГ матери) и соответствующий ему желаемый отклик (ЭКГ плода)

Использование нескольких наборов обучающих и тестовых выборок позволило оценить взаимосвязь между параметрами нейронной сети, при которых обучение и тестирование будет проведено успешно, отношением амплитуд R-пиков источников абдоминального сигнала и изменением разнородности выборки.

### 3.2 Влияние свободных параметров сети на качество выделения ЭКГ

Неизменными параметрами для всех сетей, используемых в экспериментах, являлись: количество скрытых слоев – 1; количество нейронов в выходном слое – 1. Добавление скрытых слоев не требуется, так как в процессе обучения динамическая сеть развертывается в аналог статической сети с большим количеством слоев, согласно методике, описанной во второй главе. Один нейрон в выходном слое соответствует одному источнику АЭКГ, который необходимо выделить.

Свободными параметрами, помимо весовых коэффициентов, являлись: типы активационных функций; количество нейронов во входном и скрытом слоях; порядок обратных связей и линий задержек.

Так как реальные входные сигналы и желаемые отклики содержат и положительные, и отрицательные значения, то количество типов активационных функций выходного нейрона ограничено. Для определения выходного значения нейрона возможно использование таких функций как: симметричная-ступенчатая; линейная; симметричная-линейная с насыщением; гиперболического тангенса. Для нейронов скрытого слоя использовалась функция гиперболического тангенса, так значение ее производной в нуле является максимальным среди других активационных функций, поддерживаемых Matlab Neural Network Toolbox, что компенсировало эффект затухания градиентов при использовании других обучающих алгоритмов.

Количество нейронов во входном слое определялось количеством независимых каналов наблюдения, из которых были сформированы входные сигналы. Исследовались нейронные сети, принимавшие на вход 1 и 4 сигнала, что и определяло количество входных нейронов.

Значения величин  $p$  и  $q$ , обозначающих количество предыдущих входных и выходных значений принимаемых на вход, определяли емкости двух типов краткосрочной памяти. Их начальные значения были минимальными – 1, в процессе поиска структуры сети проводилось постепенное увеличение значений, аналогичный подход применялся и для поиска количества нейронов скрытого слоя.

В качестве критерия точности работы нейронной сети выступало количество R-пиков, правильно распознанных нейронной сетью. Предварительно все R-пики были разделены на 3 группы: плодовый; материнский; наложение материнского на плодовый.

*3.2.1 Эксперимент 1: один входной нейрон, выборка включает сигнал от одного человека с отношением амплитуды матери и плода 1.4*

В данном эксперименте нейронная сеть ставилась в наиболее простые условия – для обучения и тестирования использовались отрезки АЭКГ одного человека с минимальным АМП в выборке – 1.4.

Результаты тестирования нейронной сети с линейной функцией активации выходного нейрона и минимальным количеством линий задержек и обратных связей приведены в таблице 1.

Таблица 1 Результат выделения ЭКГП в зависимости от количества скрытых нейронов, при  $p=1$  и  $q=1$  с линейной активационной функцией выходного нейрона

Скрытых нейронов	Количество распознанных R-пиков			
	плодовых (119)	материнских (74)	совмещенных (10)	итого (203)
1	0	0	0	0%
5	101	24	6	64%
10	105	30	6	69%
15	115	56	6	87%

На рисунке 39 изображены: входной сигнал; желаемый отклик; выходные сигналы нейронных сетей в зависимости от количества скрытых нейронов. Выход нейронной сети с одним скрытым нейроном практически идентичен входному сигналу, т.е. выделения ЭКГП не происходит. Сети с 5 и 10 скрытыми нейронами смогли выделить отдельно расположенные R-пики плода. Правильная классификация материнских пиков составляет лишь – 32% и 40%, что определяет низкую итоговую точность данных сетей.

Сеть с 15 нейронами показала более высокую точность удаления R-пиков матери, что позволило достичь общей точности в 87%. Дальнейшее повышение количества нейронов в скрытом слое не увеличило точность распознавания R-пиков плода и матери, наложенных друг на друга. Нейронная сеть с 20-ю скрытыми нейронами показала нулевую точность распознавания, как и нейронная сеть с единственным скрытым нейроном.

Следующим шагом стало исследование влияния типа активационной функции выходного нейрона на точность распознавания нейронной сети. Используя ту же выборку, был обучен и протестирован ряд нейронных сетей с активационной функцией типа гиперболический тангенс. Результаты приведены в



таблице 2. Из рисунка 40, на котором изображены сигналы нейронной сети, видно, что выход сети с одним скрытым нейроном повторяет входной сигнал, что позволяет определить точность такой сети как нулевую. Таким образом, изменение типа активационной функции не оказала эффекта на сеть с единственным нейроном в скрытом слое.




Рисунок 39 Сигналы нейронной сети с линейным выходным нейроном: а) входной, символами **F** и **M** обозначены R-пики плода и матери соответственно б)- д) выхода сети с 1,5,10,15 скрытыми нейронами соответственно

Нелинейная активационная функция позволила сетям с 5 и 10 скрытыми нейронами более точно классифицировать R-пики матери – 97% и 90%. Однако на несколько процентов снизилась точность распознавания отдельно расположенных пиков плода. При использовании нелинейной активационной функции точность распознавания наложенных друг на друга R-пилов увеличилась до 90% при 10-ти нейронах в скрытом слое.

Увеличение количества скрытых нейронов до 15 привело к ухудшению результатов распознавания. Негативный эффект чрезмерно высокого количества нейронов в скрытом слое оказался, однако, не таким явным, как при использовании линейной активационной функции. Наивысшая точность при линейной активационной функции была достигнута сетью с 15 нейронами в скрытом слое и составила 87%. Нелинейная активационная функция позволила

достичь максимальной точности в 93% при использовании меньшего количества нейронов в скрытом слое.




Рис. 40 Сигналы нейронной сети с нелинейной активационной функцией выходного нейрона: а) входной, символами **F**, **M** и **F+M** обозначены R-пики плода расположенные отдельно, так и совмещенные; б)-д) выхода сети с 1,5,10,15 скрытыми нейронами соответственно

Таблица 2 Результат выделения ЭКГП в зависимости от количества скрытых нейронов при  $p=1$  и  $q=1$  с нелинейной активационной функцией выходного нейрона

Скрытых нейронов	Количество распознанных R-пиков			итого (203)
	плодовых (119)	материнских (74)	совмещенных (10)	
1	0	0	0	0
5	99	72	6	87%
10	115	65	9	93%
15	81	38	9	63%

В таблице 3 приведены результаты тестирования нейронной сети с расширенной краткосрочной памятью, такая нейронная сеть принимает на вход два предыдущих входных и два предыдущих выходных значения. Повышение значений параметров  $p$  и  $q$  до 2 позволило нейронной сети с единственным нейроном в скрытом слое достичь более высокой итоговой точности, чем любая из ранее описанных сетей с  $p$  и  $q$  равными 1.

Дальнейшее изменение таких параметров, как количество скрытых нейронов, емкость краткосрочной памяти и тип активационной функции не оказало влияния на точность распознавания. Основная доля ошибок была совершена при распознавании R-пиков, которые были наложены друг на друга. При этом все ошибки совершались на одних и тех же временных отрезках сигнала. Таким образом, мы пришли к выводу, что дальнейшее повышение точности сети было бы возможным лишь при увеличении примеров в обучающей выборке, а не изменении параметров сети.

Таблица 3 Результат выделения ЭКГП в зависимости от количества скрытых нейронов при  $p=2$  и  $q=2$  с линейной активационной функцией выходного нейрона

Скрытых нейронов	Количество распознанных R-пиков			итого (203)
	плодовых (119)	материнских (74)	совмещенных (10)	
1	114	73	4	94%
5	118	70	5	95%
10	118	70	6	95%
15	118	72	6	97%

Увеличение емкости краткосрочной памяти приводит к повышению количества независимых коэффициентов. Тем не менее, это позволяет создавать более эффективные нейросетевые структуры, способные выделять ЭКГП более эффективно, при меньшем общем количестве весовых коэффициентов. В нейронной сети с  $p=q=2$  и единственным нейроном в скрытом слое содержится в общей сложности 8 весовых коэффициентов. Точность выделения ЭКГП такой сети оказалась выше, чем у сети с  $p=q=1$  и 10-ю скрытыми нейронами, которая включала в себя, в общей сложности, 51 весовой коэффициент. Таким образом, лучшим способом повышения качества работы нейронной сети является не увеличение количества скрытых нейронов, а создание более сложных связей между нейронами за счет использование обратных связей и задержек.

### 3.2.2 Эксперимент 2: один входной нейрон, выборка включает сигнал от одного человека с отношением амплитуды матери и плода 6

В данном эксперименте для формирования выборок использовался сигнал от одного человека с АМП равным 6. Отрезок сигнала изображен на рисунке 41, и если сравнить его с рисунком 40а, становится очевидной более сложная визуальная различимость R-пиков плода при более высоком значении АМП.




Рис.41 Входной сигнал нейронной сети с высоким соотношением амплитуды R-пиков плода и матери, обозначенных как **F** и **M**

Минимальное значение показателей  $p$  и  $q$ , при которых точность распознавания R-пиков не была нулевой, равнялось 6-ти. При этом все нейронные сети с единственным скрытым нейроном показывали нулевую эффективность вне зависимости от емкости краткосрочной памяти. Единичное повышение значений  $p$ ,  $q$  не оказывало того эффекта, который наблюдался при распознавании сигнала с АМП равным 1.4. Для каждой новой группы нейронных сетей значения  $p$ ,  $q$  увеличивались на 5.

В таблице 4 показана точность распознавания АЭКГ различными нейронными сетями с линейной активационной функцией выходного нейрона. Точность распознавания R-пиков матери и плода, наложенных друг на друга, составила 50%. Негативный эффект чрезмерного количества скрытых нейронов выразился в увеличенном количестве неправильно классифицированных материнских пиков.

Дальнейшее повышение значений показателей  $p$ ,  $q$  до 15 и 20, не дало улучшения точности. Об этом свидетельствуют данные, приведенные в таблице 5.

При любых параметрах нейронной сети ошибка при распознавании наложенных друг на друга R-пиков составляла 50%. Для выделения электрокардиограммы плода из абдоминального сигнала с показателем АМП равным 6 потребовалось значительно большее количество обратных связей и задержек, чем в предыдущем эксперименте.

Таблица 4 Результат выделения ЭКГП в зависимости от количества скрытых нейронов при  $p=10$  и  $q=10$  с линейной активационной функцией выходного нейрона

Скрытых нейронов	Количество распознанных R-пиков			итого (189)
	плодовых (111)	материнских (64)	совмещенных (14)	
5	102	52	7	85%
10	103	56	8	88%
15	105	30	7	75%

Таблица 5 Результат выделения ЭКГП в зависимости от количества скрытых нейронов при  $p=15$   $q=15$  с линейной активационной функцией выходного нейрона

Скрытых нейронов	Количество распознанных R-пиков			итого (189)
	плодовых (111)	материнских (64)	совмещенных (14)	
5	103	52	7	86%
10	104	54	8	88%
15	104	32	7	76%

### 3.2.3 Эксперимент 3: один входной нейрон, выборка состоит из сигналов от 25 человек

При обучении и тестировании нейронной сети на выборке, в которую входит сигнал от одного человека, основным фактором, влияющим на точность работы сети, является объем краткосрочной памяти. Количество скрытых нейронов должно лишь находиться в некотором диапазоне, выход за границы которого приводит к значительному снижению точности. Так как данные выводы были получены при анализе сетей, каждая из которых была обучена на сигнале от одного человека, то для их проверки необходимо провести обучение и

тестирование нейронных сетей на выборке, в которую входят сигналы от большего числа людей.

В таблице 6 содержится информация о точности распознавания R-пиков из всей тестовой выборки, содержащей одноканальные АЭКГ. Общим для всех нейронных сетей являлось низкое качество распознавания наложенных друг на друга пиков.

Таблица 6 Результат выделения ЭКГП в зависимости от количества скрытых нейронов при  $p=10$  и  $q=10$  с линейной активационной функцией выходного нейрона сетью, обученной на всей выборке.

Скрытых нейронов	Количество распознанных R-пиков			
	плодовых (2820)	материнских (1735)	совмещенных (375)	итого (4930)
5	2567	1510	175	86%
10	2581	1507	178	86%
15	2632	1462	203	87%

При 1-ом и 20-ти скрытых нейронах сеть показывала нулевую точность выделения R-пиков. В ряде случаев, при работе с выборкой, в которую входит сигнал от одного человека, нейронной сети достаточно одного скрытого нейрона для выделения R-пиков плода. При включении в выборку сигналов от 25-ти человек потребовалось повышение минимального объема скрытого слоя, при котором будет достигнута ненулевая точность.

Низкая точность работы сети наблюдалась при количестве скрытых нейронов, не принадлежащих интервалу [5-15]. Повышение объема краткосрочной памяти не исправляло негативный эффект от неверно подобранного количества скрытых нейронов. В случае принадлежности количества скрытых нейронов вышеуказанному интервалу максимальная точность достигалась сетью при значении параметров  $p=10$  и  $q=10$ , их дальнейшее повышение никак не влияло на точность.

На рисунке 42 показана гистограмма, отражающая точность распознавания R-пиков в зависимости от их принадлежности одной из 3-ех групп. И него видно,

что относительная точность распознавания наиболее низкая для R-пигов матери и плода, наложенных друг на друга.

Для АЭКГ одного и того же человека было проведено сравнение точности нахождения R-пигов плода в зависимости от того, была ли нейронная сеть обучена на выборке, включающей сигналы от всей людей, или только от данного человека. Оказалось, что при одних и тех же параметрах, нейронная сеть выделяет фетальную составляющую из одного и того же сигнала с одинаковой точностью, вне зависимости от объема и разнородности выборки.




Рис. 42 Доля неверно классифицированных R-зубцов в зависимости от их принадлежности матери или плоду

#### 3.2.4 Эксперимент 4: четыре входных нейрона, выборка состоит из сигналов от 25 человек

Дальнейшее увеличение точности распознавания может быть достигнуто за счет предоставления нейронной сети большего количества информации при обучении. При заданном соотношении обучающих и тестовых примеров единственным способом увеличения обучающей информации является использование многомерных обучающих данных.

Следующие результаты были получены с использованием нейронных сетей, принимающих на вход текущие и предыдущие значения АЭКГ с нескольких

синхронизированных отведений. Таким образом, количество нейронов входного слоя увеличивается до 4. Пример многомерного входного сигнала и соответствующего ему желаемого отклика показан на рисунке 43.




Рис. 43 Пример многомерного входного сигнала нейронной сети, символами **F** и **M** обозначены R-пики плода и матери

В таблице 7 приводятся результаты распознавания сигналов группой нейронных сетей с показателями  $p$  и  $q$  равными 1, т.е. при минимальном объеме краткосрочной памяти.

Таблица 7 Результат выделения ЭКГП в зависимости от количества скрытых нейронов при  $p=1$   $q=1$  с линейной активационной функцией выходного нейрона сетью, обученной на многомерных данных из всей выборки

Скрытых нейронов	Распознано R-пигов			итого (4930)
	плодовых (2820)	материнских (1735)	совмещенных (375)	
1	1164	681	130	40%
5	2532	1561	257	88%
10	2548	1646	271	91%
15	2547	1670	278	91%

В условиях многомерных данных нейронная сеть с единственным нейроном в скрытом слое произвела распознавание с точностью 40%. Низкая точность обуславливалось тем, что сигналы 15 из 25 человек не были распознаны. При



большем количестве скрытых нейронов были достигнуты результаты, на несколько процентов превышающие результаты лучшей из обученных на одномерных данных нейронных сетей.

Введение дополнительной обратной связи и временной задержки повысило точность для всех сетей, кроме той, у которой был 1 нейрон в скрытом слое. Улучшение точности достигается за счет правильного распознавания R-пиков из всех групп. Результат выделения ЭКГП в зависимости от количества скрытых нейронов при  $p=2$  и  $q=2$  в условиях многомерных входных данных приведен в таблице 8.

Таблица 8 Результат выделения ЭКГП в зависимости от количества скрытых нейронов при  $p=2$  и  $q=2$  с линейной активационной функцией выходного нейрона сетью, обученной на многомерных данных из всей выборки

Скрытых нейронов	R-пики распознано			итого из 4930
	плодовых из 2820	материнских из 1735	совмещенных из 375	
1	1151	663	131	39%
5	2505	1648	307	90%
10	2691	1537	332	92%
15	2687	1569	332	93%

Повышение объема краткосрочной памяти прекратило оказывать влияние на точность выделения ЭКГП после того, как значения величин  $p$  и  $q$  достигли 5-ти. Результат выделения источников АЭКГ нейронной сетью с данными параметрами показан в таблице 9.

Для выделения ЭКГП из многомерного входного сигнала нейронной сети потребовалось меньшее количество обратных связей, задержек и весовых коэффициентов чем из одномерного. Большее количество априорной информации позволяет использовать менее сложные, в плане количества весов, нейронные сети. Повышение количества независимых отведений АЭКГ позволило нейронным сетям показать более высокую точность распознавания R-пиков плода.

Количество скрытых нейронов определяет разнородность обучающей выборки на основе которой нейронная сеть способна корректно обучиться. Если обучающая и тестовая выборки состоят из отрезков АЭКГ, полученной от одного человека, то для выделения ЭКГП из сигнала достаточно использовать нейронную сеть с единственным скрытым нейроном.

Таблица 9 Результат выделения ЭКГП в зависимости от количества скрытых нейронов при  $p$  и  $q$  равных 5 сетью, обученной на многомерных данных из всей выборки

Скрытых нейронов	R-пики распознано			итого из
	плодовых из	материнских из	совмещенных из	
	2820	1735	375	4930
5	2718	1623	326	95%
10	2742	1602	336	95%
15	2767	1664	339	97%

При объединении сигналов от нескольких людей в одну выборку сеть должна быть обучена распознавать R-пики плода в сигналах с различными значениями АМП. Для корректного обучения в данных условиях необходимо увеличить объем именно скрытого слоя, а не краткосрочной памяти. Приведенные выводы справедливы для всех сетей, вне зависимости от размерности входного сигнала.

### 3.3 Проверка адекватности модели

В предыдущих разделах для подтверждения точности сети оценивалось количество R-пигов плода, обнаруженных нейронной сетью. Эта информация не является достаточной, для подтверждения надежности работы сети необходимо сравнить RR-интервалы ЭКГ плода, полученной в качестве выхода сети и в виде желаемого отклика. Это позволит доказать, что определено не только правильное количество R-пигов плода, но и их локализация во временной области.

### 3.3.1 Статистические критерии

На рисунке 44 изображены гистограммы RR-интервалов ЭКГП, полученной в качестве выхода сети при обработке сигнала из тестовой выборки и в качестве желаемого отклика.




Рис. 44 Гистограммы RR-интервалов а) выходного сигнала сети б) желаемого отклика

Для сравнения RR-интервалов использовался t-критерий Стьюдента. Обосновывается это тем, что распределение RR-интервалов у людей, находящихся в состоянии покоя, подчиняется нормальному закону распределения. В таблице 10 приведены значения, необходимые для расчета эмпирического значения критерия Стьюдента для проверки по выборочным данным нулевой гипотезы о равенстве математических ожиданий этих случайных величин.

Таблица 10 Характеристики RR-интервалов

RR-интервалы выхода сети			RR-интервалы желаемого отклика		
средн. ар.	станд. откл.	N	средн. Ар.	станд. Откл.	N
465.41	5.55	106	465.48	5.14	117

Сравнение эмпирического и критического значений критерия при уровне значимости 0.05 позволило подтвердить нулевую гипотезу о равенстве средних значений RR-интервалов. Это позволяет сделать вывод о том, что различия между RR-интервалами реальной ЭКГП и полученной в качестве выхода нейронной сети не являются статистически значимыми. Ошибки, которые может допустить нейронная сеть, заключаются в том, что материнские пики могут быть ошибочно приняты за плодовые, либо плодовые будут приняты за материнские и удалены. Если выходной сигнал сети содержит R-пик, то можно сделать вывод о том, что в

данный момент времени он действительно присутствовал во входном сигнале, и не был сгенерирован самой сетью.

Были выделены дискретные моменты времени появления R-пиков в реальном сигнале и выходе сети. Между этими векторами был посчитан коэффициент корреляции, который был близок к единице.

Совокупность этих тестов позволяет говорить о том, что RR-интервалы ЭКГП, выделенной нейронной сетью, соответствуют RR-интервалам реального сигнала, а любые отличия являются случайными.

### *3.3.2 Нестационарный ЭКГ сигнал*

Все сигналы, присутствовавшие в процессе обучения и тестирования нейронных сетей, не предполагали наличия в них значительной вариабельности. Вариационный размах RR-интервалов не превышал 20мс. На основе сигнала из тестовой выборки был смоделирован сигнал со значительной вариабельностью RR-интервалов. Вариационный размах RR-интервалов искусственного сигнала составлял 270 мс., морфологические характеристики QRS-комплексов оставались неизменными. На рисунке 45 изображены стационарные и нестационарные версии: исходного входного сигнал с одного из отведений; желаемого отклика сети; выходного сигнала сети со следующими параметрами – 10 скрытых нейронов; линейный выходной нейрон;  $p=q=5$ .

Вариабельность была смоделирована путем удаления близких к нулю значений между QRS-комплексами плода и матери. Из 10000 значений было удалено 2500. Как видно из рисунков 45д и 45е – вне зависимости от вариабельности сердечного ритма количество найденных и пропущенных пиков не меняется.

На рисунке 46 изображены гистограммы RR-интервалов для стационарной и нестационарной версии желаемого отклика, а также гистограмма RR-интервалов выходного сигнала сети.

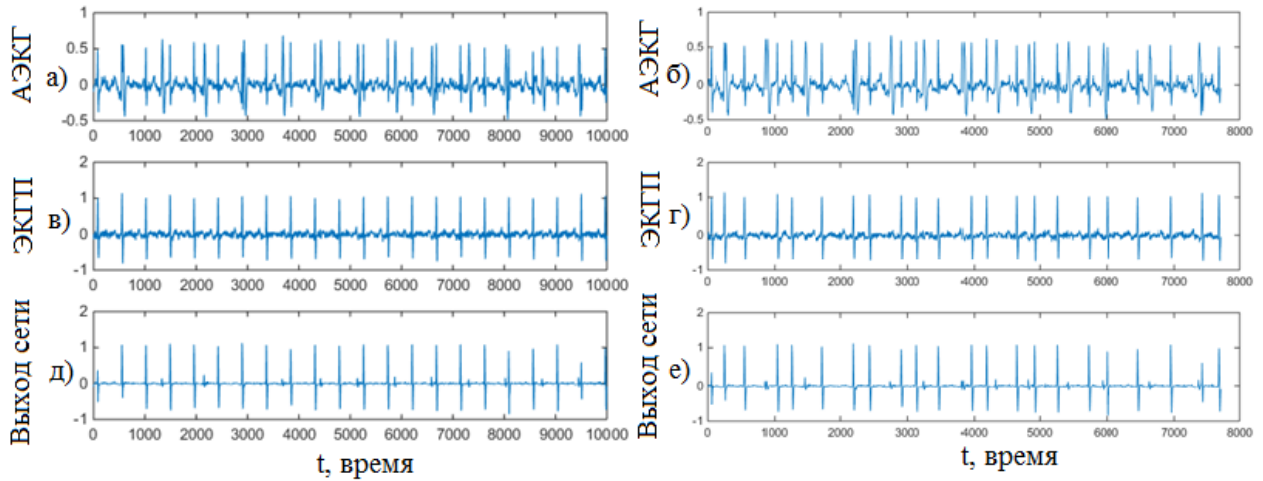


Рис. 45 Стационарные сигналы сети: а) входной; в) желаемый отклик; д) выход сети; и нестационарные сигналы сети: б) входной г) желаемый отклик е) выход сети

Представим RR-интервалы нестационарного выходного сигнала и соответствующего ему желаемого отклика, как независимые выборки. Для проверки гипотезы об их принадлежности одному закону распределения использовался непараметрический критерий Манна-Уитни. Вычисления представлены в таблице 11.




Рис. 46 Гистограммы RR-интервалов сигналов сети: а) стационарного желаемого отклика б) нестационарного желаемого отклика в) выхода сети

Эмпирическое значение критерия равно 158, при сравнении с критическим определяем, что значение находится в уровне незначимости. В результате мы принимаем нулевую гипотезу о равенстве законов распределения нестационарных RR-интервалов, т.е. различия между выходом сети и желаемым откликом носят случайный характер.

Таблица 11 Ранги для расчета U-критерия Манна-Уитни

№	RR выхода сети	Ранг	RR желаемого отклика	Ранг
1	299	14	297	13
2	469	21	468	19.5
3	215	1	218	2
4	470	23.5	468	19.5
5	470	23.5	471	27.5
6	240	5.5	240	5.5
7	475	36	473	31
8	246	7	247	8
9	328	15	329	16
10	474	34	473	31
11	224	3.5	224	3.5
12	474	34	473	31
13	265	9.5	265	9.5
14	341	17.5	341	17.5
15	470	23.5	471	27.5
16	275	11	277	12
17	474	34	471	27.5
18	470	23.5	471	27.5
Сумма:		337	Сумма:	329

Был вычислен коэффициент корреляции между векторами, элементами которых являлись дискретные моменты появления R-пигов в выходном сигнале сети и желаемом отклике. Значения коэффициента корреляции равнялось единице.

Результаты статистического анализа показали, что ЭКГП с вариабельным сердечными ритмом, полученная в качестве выхода нейронной сети, повторяет реальный сигнал не только количеством R-пигов, но и их расположением относительно друг друга, т.е. RR-интервалами. Нейронная сеть, обученная на стационарных ЭКГ сигналах, смогла выделять ЭКГП в условиях вариабельности сердечного ритма без потерь в точности и без дополнительного обучения.

### *3.3.3 Длительность сигнала и выбор точки отсчета*

При использовании классических методов анализа сигналов выбор начальной точки отсчета, длительность сигнала, ширина окна оказывают существенное влияние на результат. Осуществляя выделение ЭКГП

разработанным нами методом, мы получаем результаты, которые не зависят от вышеописанных параметров.

Для описанных ниже тестов была использована нейронная сеть с 10-ю скрытыми нейронами, значения показателей  $p$  и  $q$  равнялись 5-ти.

В ходе первого вычислительного эксперимента на вход сети поступала АЭКГ, сформированная из 6-ти одинаковых 10-ти секундных отрезков. После разделения выходного сигнала на шесть 10-ти секундных отрезков, были найдены значения линейных коэффициентов корреляции: между первым отрезком выходного сигнала и всеми остальными; между всеми отрезками кроме первого.

В первом случае, значение коэффициента было равно 0.9982, во втором случае – единице. На рисунке 47 показаны: зацикленная версия входного сигнала; желаемый отклик; отрезки выхода сети. Место соединения сигналов, а также искусственно созданный этим соединением пик обведены. Из рисунка видно, что из обоих отрезков выделено одинаковое количество R-пиков плода.

При многократной подаче на вход нейронной сети одного и того же отрезка АЭКГ точность выделения ЭКГП не изменяется со временем. Различия выхода сети в зависимости от значений, хранящихся в краткосрочной памяти, оказываются незначительными. Таким образом, мы можем сделать вывод о том, что длительность сигнала не оказывает негативного эффекта на качество выделения ЭКГП. Полученные выводы справедливы для всех сигналов из выборки, вне зависимости от размерности АЭКГ и стационарности.

В ходе второго эксперимента, сеть выделяла ЭКГП из полной и сокращенной версии АЭКГ. На вход сети подавался сигнал длительностью 60 с., затем в качестве входа использовались только последние 10 с. этого же входного сигнала. В результате было получено 2 выходных сигнала, длительность которых составляла 60 и 10 с. Из первого выходного сигнала был взят отрезок 50-51 сек., из второго выходного сигнала длительностью 10 секунд был взят отрезок 0-1 с. Значение коэффициента корреляции между ними составило 0.998. Из выходного сигнала длительностью 60 секунд был взят отрезок 59-60 с., из выходного сигнала

длительностью 10 с. был взят отрезок 9-10 с. Значение коэффициента корреляции составило 1.




Рис. 47 Сигналы сети: а) 0-20 сек. входа б) 0-20 сек. выхода в) 9.5-10.5 сек выхода г) 9.5-10.5 сек входа

Незначительные различия между выходными сигналами были локализованы в начальных значениях. Это происходило из-за того, что в первом случае, на момент подачи входного сигнала в кратковременной памяти сети уже присутствовала информация, во втором случае, кратковременная память в момент подачи входного сигнала была пустой.

Таким образом, точность выделения фетальной составляющей не зависит от того, в какой момент времени сигнал подается на вход сети. Различия выхода сети в зависимости от значений, хранящихся в краткосрочной памяти, оказываются незначительными.

### **3.4 Программный комплекс для неинвазивного выделения электрокардиограммы плода**

#### *3.4.1 Актуальность разработки программного обеспечения*

На сегодняшний день программно-аппаратные комплексы для анализа АЭКГ представлены исключительно зарубежными образцами:



- фетальный монитор *Monica AN24* от производителя *Monica Healthcare*, Великобритания;
- фетальный монитор *Sonicaid* модификаций *Team* от *Huntleigh Healthcare*, Великобритания;
- электрокардиограф *CardioLab*, производитель ХАИ-Медика, Украина;
- фетальные мониторы *AVALON FM30* и *FM20* от *Philips*.
- и др.

Все они предоставляют возможность неинвазивного выделения ЭКГП и оценки вариабельности сердечного ритма, в том числе и без использования ультразвука.

Решения, предлагаемые производителями приборов и программного обеспечения, являются коммерческими продуктами, сведения о математических методах, алгоритмах, а также их специфике остаются скрытыми от пользователя и сторонних разработчиков. Таким образом, отсутствует возможность внедрять новые алгоритмы в уже существующее программное обеспечение. Доступ к исходным биомедицинским сигналам, полученным с помощью таких приборов, которые могли бы быть использованы для проверки эффективности методов, тоже ограничен.

Это становится особенно заметным при анализе результатов, полученных участниками “*physionet-2013 challenge*” – международного проекта, организованного для привлечения математиков и программистов к конкретной медицинской проблеме. Каждый алгоритм для неинвазивного выделения ЭКГП был реализован в виде отдельного, несовместимого с другими приложениями. Ни одно из представленных решений не было интегрировано в любой из существующих программно-аппаратных комплексов.

Таким образом, было принято решение о разработке приложения для неинвазивного выделения ЭКГП, ориентированного на работу с АЭКГ сигналами, полученными из различных источников, и реализующего модель и численный метод, описанные во второй главе.

### 3.4.2 Функциональный состав программы

Программный комплекс предназначен для обработки АЭКГ математическим методом, предусмотренным разработчиком. По результатам внедрения комплекс должен использоваться в научно-исследовательском или медицинском учреждении.

Состав функций, выполняемых программным комплексом, следующий:

- чтение и предварительная обработка исходных данных в различных форматах, включая текстовые, *Microsoft Excel*, *European Data Format (.edf)*;
- выделение плодовой составляющей из одноканальных и многоканальных АЭКГ;
- построение и обучение новых нейронных сетей с заданным набором параметров, а также импорт уже существующих сетей из файлов *.mat*;
- визуализация результатов и сохранение выходных данных в текстовом, *Microsoft Excel*, графическом и *.mat* форматах.

Формат *.edf* это простой 16-ти битный формат, предназначенный для обмена и хранения многоканальных биологических и физических сигналов [101]. Расширение формата *edf*, названное *edf+*, было разработано в 2002 году и во многом совместимо с *edf*. При работе с текстовыми и *Microsoft Excel* форматами подразумевается, что каждое значение в файле соответствует значению ЭКГ сигнала с одного из отведений. Формат десятичного разделителя, способ табуляции выбирается пользователем. Соответствие строки или столбца отдельному отведению также определяется пользователем, предусмотрена возможность транспонирования данных. При импорте проводится проверка на равенство количества элементов во всех строках и столбцах. После импорта данных программа преобразует данные ЭКГ с каждого отведения в массив чисел удвоенной точности – *double*.

Результат работы программы представлен в двух видах: обученная нейронная сеть; выделенная ЭКГП. В первом случае данные экспортируются в

формат *.mat*. Файл содержит одно значение типа *network*, которое содержит информацию о нейронной сети. Во втором случае пользователь сам определяет, в какой форме (графика или таблицы) ему необходимо хранить информацию о ЭКГП.

### 3.4.3 Создание автономных приложений из программ *MATLAB*

Для создания автономного приложения использовался *MATLAB Compiler*, который позволяет обмениваться программами на базе *Matlab* как отдельными приложениями.

Все приложения, созданные с *MATLAB Compiler*, используют *MATLAB Runtime* библиотеку, что позволяет без дополнительных денежных затрат на лицензионные отчисления разрабатывать программы для пользователей, которые не нуждаются в *MATLAB*. Приложения и библиотеки, созданные с помощью *MATLAB Compiler*, используют исполняемое ядро, называемое *MATLAB Compiler Runtime (MCR)*. *MCR* поставляется вместе с *MATLAB Compiler* для распространения приложения.

*MATLAB Compiler* полностью поддерживает язык *MATLAB* и большинство пакетов расширения с некоторыми исключениями. Ключевые особенности используемой *Matlab* технологии следующие:

- программа, написанная на языке *MATLAB*, упаковывается в автономное приложение;
- создание надстройки *Microsoft Excel* для интеграции с электронными таблицами *Excel*;
- распространение приложений для пользователей, которые не нуждаются в *MATLAB*, не требующее лицензионных отчислений;
- шифрование кода *MATLAB* для защиты интеллектуальной собственности;
- возможность развертывания *MATLAB* кода на *HadooP*.

Системные требования для приложения, созданного с помощью MATLAB Compiler:

- Операционные системы – WinXP SP3, WinXPx64 SP2, Win2003Server R2 SP2, WinVista SP2, Win2008Server SP2 или R2, Win7, Win8, Win8.1, Win10;
- Процессор с поддержкой потокового SIMD-расширения (SSE2);
- Дисковое пространство: в среднем 2-4Гб (максимум 9Гб);
- Оперативная память: 1Гб;
- Для видеокарты рекомендована поддержка OpenGL 3.3 с 1 Гб оперативной памяти.

#### 3.4.4 Программная реализация

Каждый из компонентов программного комплекса, структура которого представлена на рисунке 48, реализован в виде отдельного файла-функции *MATLAB*.

Функция импорта позволяет загружать ЭКГ данные из внешних файлов формата *.edf*, *Microsoft Excel*, *.txt*, *.mat*. В зависимости от расширения импортируемого файла, операция осуществляется с помощью таких методов как: *edfread*, *MATLAB Toolstrip*.

Подсистема предварительной обработки содержит методы:

- *marginmax* для минимаксной нормализации данных. Аргументы: массив *double* или *cell* значений, *double* максимальное и минимальное возможное значение выхода. Метод возвращает *double* массив;
- *meanDel* для удаления среднего значения из сигнала. Аргументы: массив *double* или *cell* значений. Возвращает *double* массив;
- *remLowFreq* для выравнивания изолинии АЭКГ. Аргументы: массив *double* значений, *double* значение частоты дискретизации, *double* коэффициент фильтрации. Возвращает *double* массив;

- *crtVarFHR* для моделирования ЭКГ сигналов с переменными сердечными ритмами. Аргументы: массив *cell* или *double* ЭКГ-значений, массив *double* значений, определяющий новое положение QRS-комплексов. Возвращает *cell* или *double* массив.

Подсистема обучения нейронной сети позволяет заменить желаемые отклики, представленные в обучающей выборке, на предыдущие выходные сигналы нейронной сети. Это является следствием параллельного развертывания динамической сети в статическую, осуществляемого в подсистеме предварительной обработки с помощью метода *closeloop*. В структурной схеме программного комплекса данное нововведение представлено новой операцией «Наполнение краткосрочной памяти». Непосредственно к обучению сети относятся методы:

- *catsamples* для формирования входной и выходной выборки из сигналов, полученных от разных людей. Аргументы – массивы *double* значений ЭКГ, массив *double* значений для определения интервала;
- *narxnet* для инициализации нелинейной авторегрессионной модели с внешними входами. Аргументы: количество обратных связей и линий задержек, количество скрытых нейронов. Метод возвращает значения типа *network*;
- *preparets* для инициализации весовых значений и краткосрочной памяти. Аргументы: нейронная сеть в формате *network*, массив входных значений и желаемых откликов в виде массива *cell* элементов. Возвращает нейронную сеть в формате *network* и два массива *cell* значений;
- *train* для обучения нейронной сети. Включает набор аргументов типа *string*, определяющих способ вычисления весов и их локальных градиентов, и набор *cell* массивов входных значений и желаемых откликов, метод возвращает значения типа *network*.

Подсистема выделения ЭКГП, содержит методы для обработки АЭКГ с помощью нейронной сети, которую можно получить как выход файла-функции обучения, либо в результате импорта из *mat* файла. Содержит метод *net*, который принимает на вход значения, полученные в результате выполнения *preprets*. Выход нейронной сети является результатом выполнения данной функции.

Экспортируются результаты обучения нейронной сети и выделения ЭКГП в файлы таких форматов как *mat*, *txt*, *Microsoft Excel*, *edf*. Также содержит методы для визуализации ЭКГ сигналов и сохранения их в графическом формате данных, поддерживаемом MATLAB.

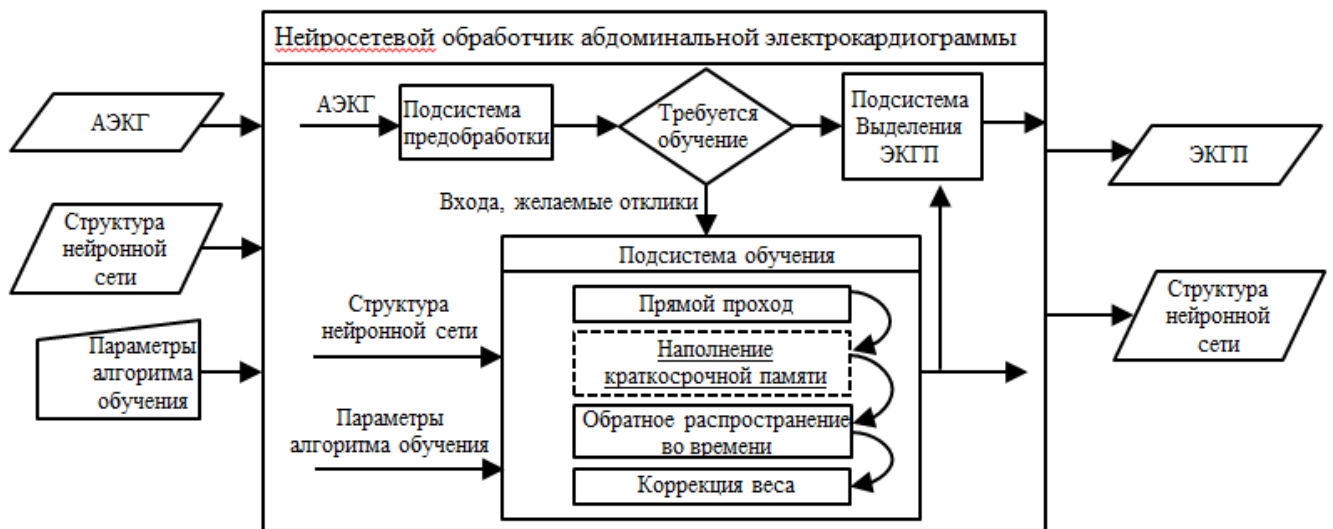


Рис. 48 Функциональная схема программного комплекса

Взаимодействие с программой осуществляется с помощью графического пользовательского интерфейса, созданного в среде визуального программирования MATLAB Guide.

### 3.4.5 Внедрение программного комплекса

Комплекс программ для неинвазивной фетальной электрокардиографии и обучения глубоких нейронных сетей с пересекающимися связями был внедрен в состав используемого программного обеспечения следующих организаций: ОГАУЗ «Детская городская больница №1» г. Томск; лечебно-оздоровительный центр «Здоровая мама – крепкий малыш» г. Томск.

Предложенные математическая модель и алгоритмы неинвазивной электрокардиографии оказались востребованными в связи с недостатками ультразвуковой кардиотокографии:

- Ультразвуковой сигнал захватывает кроме сердечных структур плода крупные сосуды, амплитуда сигнала отраженного от них может быть не меньше амплитуды сигнала отраженного от сердечных структур;
- Ультразвуковые сигналы, используемые кардиотокографами, не регламентированы и не сертифицируются (в отличие от ЭКГ);
- Для повышения достоверности измеренной ЧСС плода применяются автокорреляционные фильтры, которые исключают возможность зарегистрировать ритм по принципу «от удара к удару».

Выделение ЭКГ плода из материнских сигналов, зарегистрированных в абдоминальном отведении, в рамках программного комплекса:

- Может быть осуществлено при наличии от 1 до 4 электродов абдоминальной ЭКГ, что делает мониторинг более удобным и не препятствует внедрению в клиническую практику методов электрокардиографии плода, в то время как для получения результатов [7] было необходимо использовать 8 отведений;
- Не требует комбинаторного сложения отведений с фильтрацией, неизбежно сдвигающей и искажающей исходные сигналы ЭКГ, таким образом, предложенная модель повышает точность локализации R-зубца на 5мс, а P-зубца на 1 мс;
- В отличие от адаптивных фильтров осуществляет выделения ЭКГП без использования сигналов, зарегистрированных в грудном отведении, что в совокупности с малым количеством используемых абдоминальных электродов облегчает внедрение неинвазивной электрокардиографии в практику;

В период с 26 до 36 недель ЭКГ плода не регистрируется электрокардиографами, что ограничивает диагностику дородового состояния плода. Предложенная модель слепого разделения позволяет определять состояние сердечной активности плода в данном периоде, что расширяет временной

интервал гестационного срока для проведения электрокардиографии и диагностики сердечной активности плода на 12 недель.

Внедрение слепого разделения источников с использованием анализа независимых компонент осуществлялось в ФГБНУ «НИИ акушерства, гинекологии и перинатологии» СО РАМН [6]. В следующем разделе диссертации приводится численное сравнение результатов определения точности ЧСС, RR-интервалов и принадлежности R-зубца матери или плоду в зависимости от используемого метода.

### **3.5 Сравнение с аналогами слепого разделения источников, анализ независимых компонент**

#### *3.5.1 Выделение ЭКГП в зависимости от количества отведений АЭКГ и длительности сигнала-смеси*

Было проведено тестирование алгоритма слепого разделения источников на выборке, используемой при тестировании нейронных сетей. Для поиска коэффициентов разделяющей матрицы использовался метод анализа независимых компонент. Исследовалась эффективность разделения источников АЭКГ в зависимости от длительности и размерности входного сигнала.

На рисунке 49 показан результат выделения источников АЭКГ сигнала со следующими характеристиками: количество независимых отведений АЭКГ – 3; длительность сигнала – 10 секунд.

Одно из отведений АЭКГ изображено на рисунке 49а, а соответствующий ему желаемый отклик ЭКГП – на рисунке 49б. Очевидно, что ни один из выделенных источников на рисунках 49в, 49г и 49д не является ЭКГП. Успешным оказалось лишь выделение ЭКГМ, которая изображена на рисунке 49в.

При повышении количества независимых отведений АЭКГ до 4-ех, выделение ЭКГП оказалось успешным, что показано на рисунке 50. Длительность АЭКГ при этом составляла 10 секунд, как и в прошлом эксперименте, при увеличении длительности сигнала до минуты, выделение ЭКГП стало невозможным даже при использовании 4ех независимых отведений АЭКГ.






Рис. 49 Сигналы модели слепого разделения: а) один из входных б) желаемый отклик, в-д) выделенные источники




Рис. 50 ЭКГП выделенный с помощью слепого разделения из 4-ех канальной АЭКГ длительностью 10 секунд

Таким образом, способность слепого разделения находить источники в смеси определяется размерностью и длительностью входного сигнала.

### 3.5.2 Проблема оконной обработки сигнала с помощью анализа независимых компонент

Так как матрица разделяющих коэффициентов, полученная для выделения источников из одного отрезка сигнала, не может быть использована для обработки остальных отрезков того же самого сигнала, единственным способом выделения источников АЭКГ, длительность которых превышает 10 секунд, является оконная обработка.

При таком подходе результатом слепого разделения будет несколько матриц разделяющих коэффициентов. Каждая из этих матриц будет предназначена для выделения источников из конкретного временного отрезка АЭКГ.

При использовании нескольких разделяющих матриц для обработки одного сигнала обнаружился недостаток анализа независимых компонент – невозможность определения принадлежности выделенного источника матери или плоду.

Согласно методу слепого разделения, значение конкретного источника смеси получается в результате линейной комбинации вектора наблюдения  $x(t)$  и строки матрицы разделяющих коэффициентов  $w(t)$ . Можно сказать, что каждому источнику соответствует своя строка в матрице разделяющих коэффициентов. Но специфика анализа независимых компонент такова, что при каждом новом получении матрицы разделяющих коэффициентов, строки матрицы соответствуют случайному источнику смеси, т.е. при каждом новом получении вектора источников, его элементы будут случайно расположены относительно друг друга. Индекс элемента вектора источников  $s(t)$ , соответствующий ЭКГП, не будет соответствовать плоду в векторе  $s(t + \tau)$  если эти векторы были получены с помощью разных матриц разделяющих коэффициентов. Этот недостаток существенно затрудняет процесс определения принадлежности выделенных источников матери или плоду в условиях оконной обработки многомерных сигналов. Конечное решение о принадлежности выделенного источника сможет принять только медицинский эксперт. Нейросетевой подход не сталкивается с этой проблемой, так как каждый из нейронов выходного слоя отвечает за конкретный источник смеси.

### *3.5.3 Точность выделения ЭКГП из всей выборки*

Для получения результатов, представленных в таблице 12, все 25 сигналов из выборки длительностью в одну минуту были разделены на 10-ти секундные отрезки. Для выделения ЭКГ сигналов каждого отрезка использовалась модель

слепого разделения с матрицей разделяющих коэффициентов, найденной с помощью алгоритмов: fastICA, JADE, Infomax.

Таблица 12 Точность выделения источников АЭКГ в зависимости от алгоритма слепого разделения источников

Алгоритм	RMSE, RR-интервал, мс	MSE, ЧСС, (уд/мин) <sup>2</sup>	Точность выделения R-зубцов	
			Матери	Плода
ICA	26.085	380.853	98.3%	73.3%
JADE	28.201	278.755	99.1%	74.7%
Infomax	25.059	255.989	98.6%	81.4%
NARX	20.975	187.091	95.9%	96.9%

Выделение R-зубцов плода с использованием нейронной сети (обозначенной как NARX) происходит на 20% точнее; среднеквадратичное отклонение частоты сердечных сокращений ниже в среднем на 118 (ударов в мин.)<sup>2</sup>; корень среднеквадратичного отклонения RR-интервалов ниже в среднем на 5 мс.

На рисунке 51 показаны источники, выделенные с помощью слепого разделения, и выход нейронной сети. Сигналы были получены при обработке одного и того же входного сигнала, который включал в себя 4 синхронизированные АЭКГ.

Только нейронная сеть смогла выделить электрокардиограмму плода. Сокращение ширины окна до 1-ой секунды и даже до долей секунды все равно не позволило модели слепого разделения выделить ЭКГП.

Анализ независимых компонент позволяет выделять материнские компоненты АЭКГ с большей точностью, чем нейронные сети, но только при выполнении ряда условий: длительность сигнала не должна превышать 10 секунд; количество независимых отведений не должно быть меньше четырех. Обработка более длительных записей ЭКГ должна проходить в оконном режиме, но такой подход осложняется невозможностью алгоритмизировать процесс определения принадлежности источника матери или плоду.




Рис. 51 Источники АЭКГ: а-г) выделенные с помощью слепого разделения; д) нейронной сети; е) реальный АЭКГ с одного из отведений

Слепое выделение ЭКГМ происходило успешно при обработке любого сигнала. Выделение ЭКГП происходило удачно лишь при определенном количестве независимых отведений АЭКГ и при длительности АЭКГ. Проблему неудачного выделения ЭКГП в данных условиях можно было бы решить удалением из АЭКГ материнской составляющей, полученной в результате слепого разделения источников из смеси. Это является логичным, так как известно, что источников АЭКГ всего два: плод и мать. Однако такой подход сопряжен со следующими сложностями.

Во-первых, невозможно алгоритмизировать процесс определения принадлежности матери или плоду элементов вектора источников  $s(t)$ , так как строка разделяющей матрицы  $W$  соответствует случайному источнику смеси.

Во-вторых, даже если бы это было возможным, то остается открытым вопрос о том, из какого отведения АЭКГ необходимо удалять ЭКГМ, ведь разделение источников происходит в условиях исключительно многомерных данных.

В-третьих, амплитуда и форма R-пиков ЭКГМ, выделенной с помощью слепого разделения, не соответствует амплитуде и форме R-пиков в реальном сигнале. Соотношение амплитуд и форма отличается при каждом новом получении матрицы разделяющих коэффициентов.

### **3.6 Сравнительный анализ эффективности алгоритмов обучения**

Для подтверждения положения, выносимого на защиту, об эффективности предложенного численного метода для минимизации целевой функции нейронной сети выполнили ряд вычислительных экспериментов, в ходе которых сравнивалась скорость сходимости и достигнутый эффективный локальный минимум при различных объемах обучающей и тестирующей выборок. Список алгоритмов обучения включал: Левенберга-Марквардта; сопряженных градиентов; Resilient propagation; Resilient propagation through time.

Для обучения представлено 4 обучающих выборки: 10-ти секундный сигнал от одного человека с АМП 1.4; 10-ти секундный сигнал от одного человека с АМП 6; 120 секундный сигнал, сформированный из одноканальных записей АЭКГ от 12 из 25 человек; 120 секундный сигнал, сформированный из четырехканальных записей АЭКГ от 12 из 25 человек. Параметры нейронных сетей оставались неизменными во всех экспериментах: 10 скрытых нейронов;  $p=q=5$ . В таблице 13 приведены результаты обучения и тестирования алгоритмов в зависимости от выборки.

Чтобы исключить фактор влияния случайной инициализации весов, начальные значения генерировались единым образом для всех нейронных сетей. Зависимость ошибки от эпохи при обучении на различных выборках показана на рисунке 52.

Метод сопряженных градиентов оказался наименее эффективным вне зависимости от выборки. Применение к весам сети коррекций, вычисленных с использованием данного алгоритма, не приводило к минимизации целевой функции при обучении на первых двух выборках, выделение ЭКГП из тестовых сигналов выполнялось с нулевой точностью.

Предложенный в работе алгоритм обучения Resilient propagation through time оказался более эффективен, поскольку позволил достичь на порядок меньшего значения целевой функции, чем стандартный алгоритм Rprop. Начальные итерации алгоритма RProp характеризовались увеличением ошибки (расходимостью), исправление которой достигалось только при перезапуске обучения с использованием механизмов регуляризации, в то время как предложенный в работе алгоритм обучения уменьшает ошибку на каждой итерации обучающего процесса.

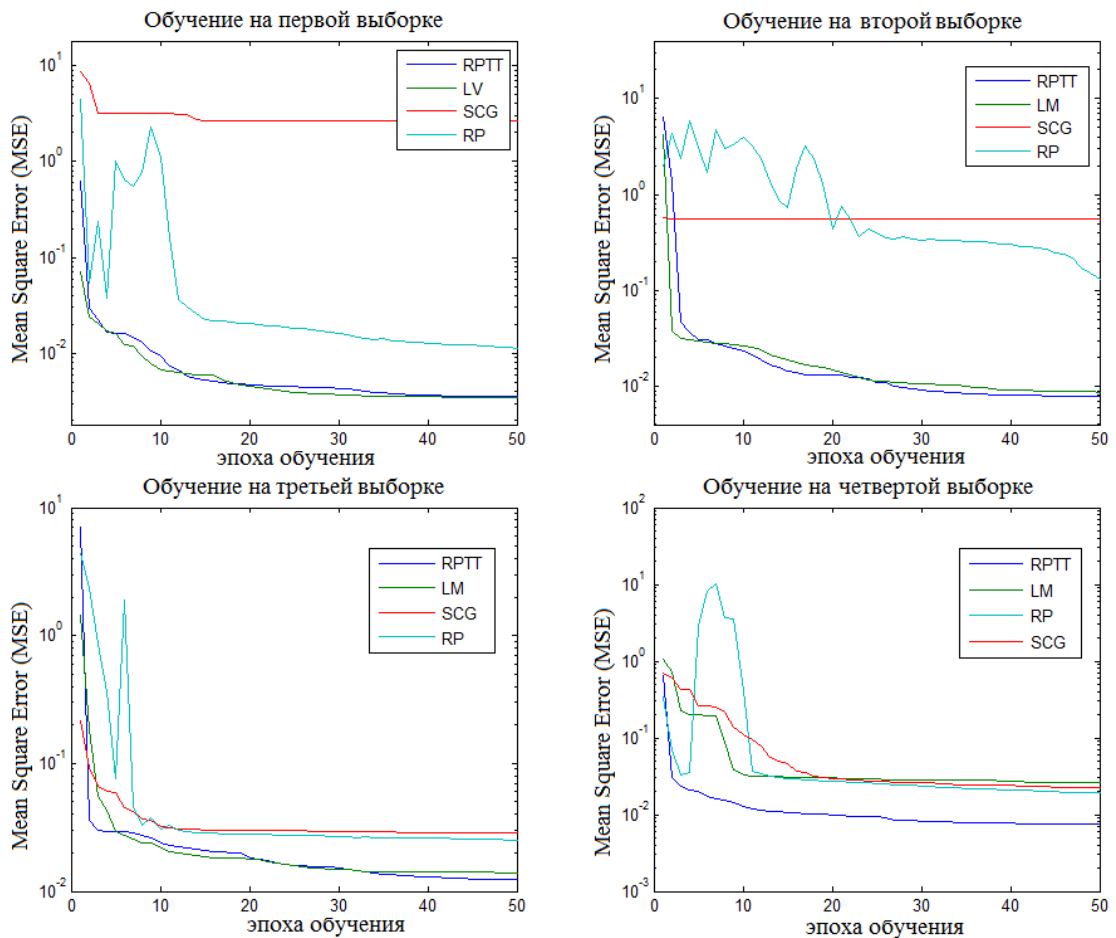


Рис. 52 Зависимость ошибки от эпохи алгоритмов обучения в 1-4 выборках

Разница в эффективности между алгоритмами Левенберга-Марквардта и Resilient propagation through time обнаружилась при обучении на выборке, состоящей из четырехканальных сигналов. Точность обучения и тестирования именно на этой выборке представляет наибольший интерес, так как многоканальная запись АЭК содержит максимум априорной информации о

состоянии сердечной активности плода. Resilient propagation во времени позволил достичь на порядок меньшей ошибки обучения, чем Левенберга-Марквардта.

Таблица 13 Точность тестирования и обучения в зависимости от выборки

Алгоритм обучения	Среднеквадратичная ошибка при обучении/тестировании на выборке			
	№1	№2	№3	№4
LVM	0.0033/0.0547	0.0075/0.0223	0.0121/0.0147	0.0161/0.0177
SCG	2.6627/2.6711	0.5611/0.5617	0.0251/0.0263	0.0189/0.0196
RP	0.0078/0.0194	0.0244/0.0252	0.0218/0.1782	0.0117/0.0139
RPTT	0.0031/0.0121	0.0074/0.1258	0.0134/0.0159	0.0086/0.0131

### 3.7 Выводы по главе

Анализ точности слепого разделения источников абдоминальной электрокардиограммы при различных параметрах архитектуры динамической нейронной сети показал что:

1. Более высокое соотношение амплитуд R-пиков матери и плода в АЭКГ предъявляет более высокие требования к объему краткосрочной памяти, т.е. количеству обратных связей и временных задержек;
2. Разнородность обучающей выборки, выражающаяся в вариабельности морфологических характеристик и соотношении амплитуд материнских и плодовых QRS-комплексов, требует увеличение количества скрытых нейронов для адекватного обучения на основе такой выборки;
3. Изменение вариабельности RR-интервалов при сохранении морфологических характеристик QRS-комплексов не оказывает влияния на точность тестирования и не требует переобучения сети;
4. Проверка адекватности модели показала, что точность выделения источников не зависит от длительности сигнала и выбора точки отсчета;
5. Выделение ЭКГП происходит с большей точностью при выделении источника из многомерного сигнала, однако нейросетевой подход, в отличие от анализа независимых компонент, позволят проводить операцию слепого разделения и с использованием одномерного АЭКГ сигнала;

6. В отличие от предложенной нейросетевой модели ЭКГП, слепое разделение источников с использованием матрицы разделяющих коэффициентов, определенных с помощью алгоритмов fastICA, JADE, Infomax, позволяет выделять ЭКГП из сигналов ограниченной длительности и размерности;
7. Предложенный в работе численный метод минимизации целевой функции нейронной сети оказался на порядок эффективнее по сравнению с такими методами как: Левенберга-Марквардта; сопряженных градиентов; Rprop.



## Заключение

Работа направлена на решение задачи неинвазивной электрокардиографии плода. Объединение идеи, заложенной в модели слепого разделения источников, и нейродинамики привело к созданию нелинейной динамической нейросетевой модели разделения источников электрокардиограммы, зарегистрированной в абдоминальном отведении. Теоретически обоснованы и экспериментально подтверждены преимущества модели, относительно известных аналогов.

Реакция модели определяется морфологическими, а не периодическими характеристиками QRS-комплексов плода, это решает проблемы, возникающие при обработке нестационарного сигнала и при наложении друг на друга фетальной и материнской компонент. Гибкость модели допускает использование входных сигналов произвольной размерности, вплоть до сигнала, зарегистрированного лишь в одном отведении, что выгодно отличает предложенную в работе модель от адаптивных фильтров и моделей слепого разделения.

Обучение динамической нейронной сети сопряжено с проблемами глубокого обучения. Линейность обратного распространения приводит к затуханию локальных градиентов нейронов, расположенных в глубоких слоях. Для обучения глубокой нейронной сети, полученной в результате параллельного развертывания нелинейной авторегрессионной модели с внешними входами, предложен алгоритм обучения, определяющий величину коэффициентов в зависимости от знака суммы производных по весу для всех моментов времени. Таким образом, согласуются ограничения коэффициента  $\eta$ , накладываемые стандартным алгоритмом Resilient propagation, и требования к равенству значений весовых коэффициентов для нейронов, полученных в результате развертывания, которые вытекают из обратного распространения ошибки во времени.

Собственные экспериментальные данные показали, что нейросетевая модель способна выделять вектор источников из вектора наблюдений любой размерности. Точность тестирования и обучения определяется рядом параметров:

размерность входного сигнала; объем краткосрочной памяти; разнородность выборки; количество нейронов в скрытом слое.

Для описания индивидуальной особенности абдоминального ЭКГ сигнала было использовано отношение амплитуд материнских и плодовых QRS-комплексов. Слабая визуальная различимость фетальной составляющей относительно материнской характеризуется высоким значением введенного нами показателя. Точность выделения плодовой составляющей в зависимости от ее визуальной различимости определяется количеством обратных связей и временных задержек модели.

Количество весов нейронов скрытого слоя может быть интерпретировано как долгосрочная память. Она определяет разнородность, в смысле вариабельности морфологических признаков QRS-комплексов, обучающей выборки, информацию из которой сеть извлекает в процессе обучения. Увеличение количества сигналов в выборке, приводит к повышению вариационного размаха отношения амплитуды QRS-комплекса матери и плода, и для корректного обучения на такой выборке необходимо увеличения нейронов в скрытом слое.

Проверка адекватности модели включала статистический анализ RR-интервалов выходных сигналов нейронной сети и желаемых откликов. Полученные результаты позволили сделать вывод о том, что QRS-комплексы плода, обнаруженные нейронной сетью верно локализованы. Искусственное повышение вариабельности сердечных ритмов выразилось в увеличении вариационного размаха RR-интервалов. Повышение вариабельности сердечного ритма не оказало влияния на точность разделения источников с использованием нейронной сети, обучение которой основывалось только на сигналах с незначительной вариабельностью сердечного ритма. Длительность входного сигнала и выбор точки отсчета не оказал никакого влияния на точность разделения источников данного сигнала. Это подтверждается реакцией модели на: зацикленную версию входного сигнала; сокращенную и полную версию входного сигнала.

Исследование возможностей слепого разделения источников абдоминальных сигналов через анализ независимых компонент выявило ряд недостатков стандартной модели. Достижение ненулевой точности оказалось возможным только при количестве независимых отведений, в которых был зарегистрирован входной сигнал, не меньше 4-ех. Длительность входного сигнала не должна превышать 10 секунд, при частоте дискретизации 1кГц. Решение проблем ограничения длительности через оконную обработку позволило обнаружить еще один фундаментальный недостаток стандартной модели слепого разделения – неспособность к определению принадлежности выделенного источника абдоминальной электрокардиограммы матери или плоду.

Для выполнения задачи неинвазивной электрокардиографии с использованием ядра *MATLAB Compiler Runtime* разработан программный комплекс. Решение о его разработке было мотивировано преобладанием зарубежных продуктов на рынке, а также их закрытостью от сторонних разработчиков, не позволяющей осуществлять внедрение новых алгоритмов.

Внедрение программного комплекса в учреждения: ОГАУЗ «Детская городская больница №1» г. Томск; лечебно-оздоровительный центр «Здоровая мама – крепкий малыш» г. Томск позволило добиться ряда преимуществ, по сравнению с ультразвуковой диагностикой сердечной активности плода и адаптивной фильтрацией абдоминальных электрокардиограмм. Расширен временной интервал гестационного срока для проведения электрокардиографии и диагностики сердечной активности плода на 12 недель (с 38-ой до 26-ой). Решена проблема сдвига отдельных R-зубцов при адаптивной фильтрации на 5мс. и P-зубцов на 1мс.

**Список литературы:**

1. Анализ устойчивости решения задачи разделения источников сигналов [Текст] / В. А. Засов, Е. Н. Никоноров, М. А. Тарабардин // Вестник транспорта Поволжья. - Самара: СамГУПС, 2010. - №1 (21). - С. 27-35
2. Программный комплекс для моделирования слепого разделения сигналов [Текст] / Е. Н. Никоноров ; рук. работы В. А. Засов // Дни студенческой науки: сб. материалов XXXVII научной конференции студентов и аспирантов. - Самара : СамГУПС, 2010. - Вып. 11. - С. 90
3. Анализ предсердной электрокардиограммы с целью диагностики мерцательной аритмии / А. В. Фролов, А. Г. Мрочек, А. П. Войтович, М. В. Войтикова, Т. Г. Вайханская, О. П. Мельникова, А. П. Воробьев // Клиническая информатика и телемедицина. - 2011. - Т. 7, вып. 8. - С. 65-69.
4. Савостьянов Д. В. Алгоритмы слепого разделения источников в пакетном режиме// Численные методы, параллельные вычисления и информационные технологии. - МГУ, 2008. – С. 199-228.
5. Самородов А.В., Захаров И.В. Компонентный анализ в задаче слепого разделения спонтанной электроэнцефалограммы. // Молодежный научно-технический вестник, 2013, - № 09.
6. Программный комплекс для оценки и мониторинга состояния матери и плода / Я. С. Пеккер, Е. Ю. Киселева, И. В. Толмачев // Известия Томского политехнического университета. - 2009. - Т. 314, № 05 : Управление, вычислительная техника и информатика. - С. 196-201.
7. Патент РФ № 2008108122/14, 03.03.2008, Кодкин В. Л., Дубель А. М.(RU), Цывьян П. Б., Устройство неинвазивной диагностики сердечной кативности плода и способы его применения, Патент России №2387370.
8. Behar J, Oster J, Clifford GD. Combining and Benchmarking Methods of Foetal ECG Extraction Without Maternal or Scalp Electrode Data. Accepted in Phys. Meas. 2014c

9. Behar J, Oster J, Clifford GD. Non Invasive FECG extraction from a set of abdominal channels. Comp. in Card. 2013; 22th–25th September, 2013; Zaragoza, Spain. 2013.
10. Asraful Ha, M., Ibn Ibrahi, M. and Ibn Reaz, M. (2009). An Efficient Method for Fetal Electrocardiogram Extraction from the Abdominal Electrocardiogram Signal. *J. of Computer Science*, 5(9), pp.619-623.
11. Reaz MBI, Wei LS. Adaptive linear neural network filter for fetal ECG extraction. Proceedings of international conference on intelligent sensing and information processing. Chennai. India; 4–7 January 2004. 2004. pp. 321–324.
12. Kam, A. and Cohen, A. (n.d.). Separation of twins fetal ECG by means of blind source separation (BSS). *21st IEEE Convention of the Electrical and Electronic Engineers in Israel. Proceedings*.
13. Cremer M. Über die Direkte Ableitung der Aktionströme des Menschlichen Herzens vom Oesophagus und Über das Elektrokardiogramm des Fetus. *Münchener Medizinische Wochenschrift*. 1906 April;53:811–813.
14. Goodyer AVN, Geiger AJ, Monroe WM. Clinical fetal electrocardiography. *Yale J Biol Med*. 1942;(no. 15):1–19. [[PMC free article](#)] [[PubMed](#)]
15. Lindsley DB. Heart and Brain Potentials of Human Fetuses in Utero. *The American Journal of Psychology*. 1942 July;55(no. 3):412–416.
16. Sameni, “A Review of Fetal ECG Signal Processing Issues and Promising Directions,” *The Open Pacing, Electrophysiology & Therapy Journal*, 2010.
17. Hon EH. The instrumentation of fetal heart rate and fetal electrocardiography i. a fetal heart rate monitor. *Conn Med*. 1960;24:289–293.
18. Farvet AG. Computer Matched Filter Location of Fetal R-Waves. *Medical & Biological Engineering*. 1968 September;6(no. 5):467–475. [[PubMed](#)]
19. Widrow B, Glover J, McCool J, Kaunitz J, Williams C, Hearn H, Zeidler J, Dong E, Goodlin R. Adaptive noise cancelling: principles and applications. *Proc IEEE*. 1975;63(no. 12):1692–1716.
20. van Oosterom A. Spatial filtering of the fetal electrocardiogram. *J Perinat Med*. 1986;14(no. 6):411–419. [[PubMed](#)]

21. Fuchs, T., Pomorski, M., Grobelak, K., Tomiałowicz, M. and Zimmer, M. (2014). Signal Loss During Fetal Heart Rate Monitoring Using Maternal Abdominal Surface Electrodes Between 28 and 42 Weeks of Pregnancy. *Advances in Clinical and Experimental Medicine*, 23, pp.813-819.
22. Tal, Y., Akselrod, S. (1989) Fetal heart rate detection by a special transformation method. *Proceedings of Computers in Cardiology* 275–278, Jerusalem, Israel.
23. Outram NJ, Ifeachor EC, Eetvelt PWJV, Curnow JSH. Techniques for optimal enhancement and feature extraction of fetal electrocardiogram. *IEE Proc-Sci Meas Technol.* 1995 November;142(no. 6):482–489.
24. Stoughton J. W., Weber G. N., Pretlow R. A. (1990) Fetal heart rate estimation via adaptive least mean square linear prediction methods. *Proc IEEE Southeastcon '90* 1:260–264 New Orleans, LA, USA.
25. Park Y, Lee K, Youn D, Kim N, Kim W, Park S. On detecting the presence of fetal R-wave using the moving averaged magnitude difference algorithm. *IEEE Trans Biomed Eng.* 1992 August;39(no. 8):868–871. [[PubMed](#)]
26. Shao M, Barner K, Goodman M. An interference cancellation algorithm for noninvasive extraction of transabdominal fetal electroencephalogram (TaFEEG) *IEEE Trans Biomed Eng.* 2004;51(no. 3):471–483.[[PubMed](#)]
27. Martens SMM, Rabotti C, Mischi M, Sluijter RJ. A robust fetal ECG detection method for abdominal recordings. *Physiol Meas.* Apr, 2007. pp. 373–388. [Online]. Available: <http://dx.doi.org/10.1088/0967-3334/28/4/004>. [[PubMed](#)]
28. Wu, S., Shen, Y., Zhou, Z., Lin, L., Zeng, Y. and Gao, X. (2013). Research of fetal ECG extraction using wavelet analysis and adaptive filtering. *Computers in Biology and Medicine*, 43(10), pp.1622-1627.
29. Y. Xu, J.B. Weaver, D.M. Healy, J. Lu, Wavelet transform domain filters: a spatially selective noise filtration technique, *IEEE Trans. Image Process.* 3 (1994) 747–758.
30. Tompkins, W.J., 2000, *BIOMEDICAL DIGITAL SIGNAL PROCESSING – C-Language Examples and Laboratory Experiments for the IBM® PC*, Prentice Hall, Englewood Cliffs, 359p.

31. B. De Moor, "Daisy: Database for the identification of systems," Department of Electrical Engineering, ESAT/SISTA, K.U.Leuven, Belgium, <http://www.esat.kuleuven.ac.be/sista/daisy/>
32. Kam, A., Cohen, A. (1999) Detection of fetal ECG with IIR adaptive filtering and genetic algorithms. IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP'99) 4, 2335– 2338. Phoenix, AZ, USA.
33. Srinivas, M., "Genetic Algorithms: A Survey," Computer, 17-26, June, 1994.
34. Tang, K.S., Man, K.F., Kwong, S. and He, Q., "Genetic Algorithms and Their Applications," IEEE Signal Processing Magazine, 22-37, November 1996.
35. Echeverria, J. C., Ramirez, N., Pimentel, A. B., et al. (1996) Fetal QRS extraction based on wavelet analysis and pattern matching. Engineering in medicine and biology society. Bridging disciplines for biomedicine. Proceedings of the 18th Annual International Conference of the IEEE. Amsterdam. Netherlands; 31 October–3 November 1996. vol. 4. p. 1656–1657.
36. Mochimaru F., Fujimoto Y. (2002) Detecting the fetal electrocardiogram by wavelet theory-based methods. Prog Biomed Res 7:185–193.
37. Bergveld P., Arjan J. K., Peuscher J. H. J. (1986) Real-time fetal ECG Recording. IEEE Trans Biomed Eng BME-33:505– 509.
38. Желудев В. А. О цифровой обработке сигналов при помощи сплайн-вейвлетов и вейвлет-пакетов // ДАН. 1997. Т. 355. № 5. С. 592-596.
39. Прэтт У. Цифровая обработка изображений: Пер. с англ. — М.: Мир, 1982. — Кн. 2 — 480 с.
40. Малла С. Вэйвлеты в обработке сигналов. — М.: Мир, 2005. — 672 с.
41. Jaffard, S. Pointwise smoothness, two-microlocalization and wavelet coefficients / S. Jaffard // Publications Mathematiques. – 1991. – V. 35. – № 1. – P. 155–168.
42. Mochimaru F., Fujimoto Y. (2002) Detecting the fetal electrocardiogram by wavelet theory-based methods. Prog Biomed Res 7:185–193.
43. P. Comon. Independent Component Analysis, a new concept/ Signal Processing, Vol. 36, No3, pp. 287-314, April 1994.

44. A. Hyvärinen and E. Oja. Independent Component Analysis: Algorithms and Applications. *Neural Networks*, 13(4-5):411-430, 2000.
45. Najafabadi, F. S., Zahedi, E., Ali, M. A. M. (2005) A novel model for abdominal electrocardiography of a pregnant woman. *Sensors and the international conference on new techniques in pharmaceutical and biomedical research* 64–68. Kuala Lumpur, Malaysia.
46. A. Cichocki and S. Amari, *Adaptive Blind Signal and Image Processing*, New York: Wiley, 2002.
47. Reaz, M. B. I., Wei, L. S. (2004) Adaptive linear neural network filter for fetal ECG extraction. *Proceedings of international conference on intelligent sensing and information processing*. Chennai. India; 4–7 January 2004, p. 321–324.
48. Hasan, M., Reaz, M. and Ibrahimy, M. (2011). Fetal electrocardiogram extraction and R-peak detection for fetal heart rate monitoring using artificial neural network and Correlation. *The 2011 International Joint Conference on Neural Networks*.
49. Warrick, P., Hamilton, E., Macieszczak, M. (2005) Neural network based detection of fetal heart rate patterns. *Proceedings of International Joint Conference on Neural Networks*. Montreal. Canada; 31 July–4 August 2005. vol. 4. p. 2400–2405.
50. Hasan, M. A., Ibrahimy, M. I., Reaz, M. B. I.: Development of R-peak Detection Technique in Abdominal ECG signal using Neural Network, *Proceedings of the 2nd International Conference on Advancement in Science and Technology*, 13-15 June 2008, 180-82
51. Azad, K. A. K.: Fetal QRS Complex Detection from Abdominal ECG: A Fuzzy approach, *Proceedings of IEEE Nordic Signal Processing Symposium*, 2000, 275-78
52. Ye, Y., Yao, X., Zhang, Z. and Mo, Q. (2007). A Non-Invasive Fetal Electrocardiogram Extraction Algorithm Based on ICA Neural Network. *2007 1st International Conference on Bioinformatics and Biomedical Engineering*.
53. Jia, W., Yang, C., Zhong, G., Zhou, M. and Wu, S. (2010). Fetal ECG extraction based on adaptive linear neural network. *2010 3rd International Conference on Biomedical Engineering and Informatics*.



54. Ma, Y., Xiao, Y., Wei, G. and Sun, J. (2014). Fetal ECG extraction using adaptive functional link artificial neural network. *Signal and Information Processing Association Annual Summit and Conference (APSIPA), 2014 Asia-Pacific*.
55. Liszka-Hackzell, J. (1994) Categorization of fetal heart rate patterns using neural networks. *Comput Cardiol* 97–100. Bethesda, Maryland, USA.
56. Marques de Sa, J. P., Reis, L. P., Lau, J. N. et al. (1994) Estimation and classification of fetal heart rate baselines using artificial neural networks. *Comput Cardiol* 541–544. Bethesda, Maryland, USA.
57. Magenes. G., Signorini, M. G., Arduini, D. (1999) Detection of normal and pathological fetal states by means of neural and fuzzy classifiers applied to CTG parameters. *Engineering in Medicine and Biology. 21st Annual Conference and the 1999 Annual Fall Meeting of the Biomedical Engineering Soc. BMES/EMBS Conference. Atlanta, GA, USA; 13–16 October 1999. vol. 2. p. 936–936.*
58. Camps, G., Martinez, M., Soria, E. (2001) Fetal ECG extraction using an FIR neural network. *Comput Cardiol* 249–252. Rotterdam, Netherlands.
59. Warrick, P., Hamilton, E., Macieszczak, M. (2005) Neural network based detection of fetal heart rate patterns. *Proceedings of International Joint Conference on Neural Networks. Montreal. Canada; 31 July–4 August 2005. vol. 4. p. 2400–2405.*
60. Sameni R, Shamsollahi MB, Jutten C, Clifford GD. A Nonlinear Bayesian Filtering Framework for ECG Denoising. *IEEE Trans Biomed Eng.* 2007 Dec;54(no. 12):2172–2185. [PubMed]
61. Sameni R, Shamsollahi MB, Jutten C. Model-based Bayesian filtering of cardiac contaminants from biomedical recordings. *Physiological Measurement.* 2008 May;29(no. 5):595–613. [PubMed]
62. Li C, Zheng C, Tai C. Detection of ECG characteristic points using wavelet transforms. *Biomedical Engineering, IEEE Transactions on.* 1995 January;42(no. 1):21–28. [PubMed]
63. Zarzoso V, Nandi AK. Comparison between blind separation and adaptive noise cancellation techniques for fetal electrocardiogram extraction. *IEE Colloq Medical Applications for Signal Processing.* 1999:1/1–1/6.

64. Zarzoso V, Nandi A. Noninvasive fetal electrocardiogram extraction: blind separation versus adaptive noise cancellation. *Biomedical Engineering, IEEE Transactions on*. 2001 January;48(no. 1):12–18.[PubMed]
65. Abboud, S., Barkai, G., Mashiach, S. and Sadeh, D., Quantification of the fetal electrocardiogram using averaging technique. *Comput. Biol. Med.* v20. 147-155.
66. M. Kotas, J. Jezewski, “Spatio-temporal Filtering for Fetal QRS Enhancement”, *World Congress on Medical Physics and Biomedical Engineering*, September 7 - 12, 2009, Munich, Germany Volume 25/4 of the series IFMBE Proceedings pp 389-392
67. Sameni R. PhD dissertation. Sharif University of Technology – Institut National Polytechnique de Grenoble; Jul, 2008. Extraction of Fetal Cardiac Signals from an Array of Maternal Abdominal Recordings. [Online]. Available: <http://www.sameni.info/Publications/Thesis/PhDThesis.pdf>.
68. Sejnowski T.J. Preface to Independent Component Analysis // The Computational Neurobiology Laboratory – <http://cnl.salk.edu/Research/ComputationalTools/ICA/>
69. Ranzato Marc'Aurelio, Christopher Poultney, Sumit Chopra and Yann LeCun: Efficient Learning of Sparse Representations with an Energy-Based Model, in J. Platt et al. (Eds), *Advances in Neural Information Processing Systems (NIPS 2006)*, MIT Press, 2006
70. Y. LeCun and Y. Bengio: Convolutional Networks for Images, Speech, and Time-Series, in Arbib, M. A. (Eds), *The Handbook of Brain Theory and Neural Networks*, MIT Press, 1995
71. Y. LeCun, L. Bottou, G. Orr and K. Muller: Efficient BackProp, in Orr, G. and Muller K. (Eds), *Neural Networks: Tricks of the trade*, Springer, 1998
72. Broomhead, D. S.; Lowe, David (1988). Radial basis functions, multi-variable functional interpolation and adaptive networks (Technical report). RSRE. 4148.
73. Anderson J.A. “The BSB model: A simple nonlinear autoassociative neural network”, in *Associative Neural Memories* (M. Hassoun, ed.), 1993, p. 77-103, Oxford: Oxford University Press.

74. Cai, X., Prokhorov, D. V., & Wunsch, D. C, I. I. (2007). Training winner-take-all simultaneous recurrent neural networks. *IEEE Transactions on Neural Networks*, 18(3), 674–684.
75. Wan, E. A. (1994). Time series prediction by using a connectionist network with internal delay lines. In A. S. Weigend & N. A. Gershenfeld (Eds.), *Time series prediction: Forecasting the future and understanding the past* (pp. 195–217), Boston, MA: Addison-Wesley.
76. Elman, J. (1990). Finding structure in time. *Cognitive Science*, 14(2), pp.179-211.
77. Mandic, D. & Chambers, J. (2001). *Recurrent Neural Networks for Prediction: Learning Algorithms, Architectures and Stability*. Wiley. ISBN 0-471-49517-4.
78. Brezak, D., Bacek, T., Majetic, D., Kasac, J. and Novakovic, B. (2012). A comparison of feed-forward and recurrent neural networks in time series forecasting. *2012 IEEE Conference on Computational Intelligence for Financial Engineering & Economics (CIFEr)*.
79. MingYong Jiang, XiangNing Chen, and XiaQiong Yu, (2011). Adaptive Sub-Optimal Hopfield Neural Network image restoration base on edge detection. *2011 International Conference on Image Analysis and Signal Processing*.
80. Ming-ai Li, Jun-fei Qiao, and Xiao-gang Ruan, (2006). A Modified Difference Hopfield Neural Network and Its Application. *2006 6th World Congress on Intelligent Control and Automation*.
81. Saroha, S. and Aggarwal, S. (2014). Multi step ahead forecasting of wind power by different class of neural networks. *2014 Recent Advances in Engineering and Computational Sciences (RAECS)*.
82. Tsungnan Lin, Horne, B., Tino, P. and Giles, C. (1996). Learning long-term dependencies in NARX recurrent neural networks. *IEEE Trans. Neural Netw.*, 7(6), pp.1329-1338.
83. Wang, H. and Song, G. (2014). Innovative NARX recurrent neural network model for ultra-thin shape memory alloy wire. *Neurocomputing*, 134, pp.289-295.
84. Diaconescu, e. (2008). The use of NARX neural networks to predict chaotic time series. *WSEAS Transactions on Computer Research*, 3(3), pp.182-191.

85. Хайкин, Саймон Нейронные сети: полный курс /Саймон Хайкин. — М.: «Вильямс», 2006. -1104 с.
86. Werbos P.J. “Beyond regression: New tools for prediction and analysis in the behavioral sciences”, Ph.D. Thesis, Harvard University, Cambridge, MA, 1974.
87. Rumelhart D.E., G.E. Hinton and R.J. Williams. “Learning internal representations by error propagation”, in D.E. Rumelhart and J.L. McClelland, eds., vol 1, Chapter 8, Cambridge, MA: MIT Press, 1986
88. Rumelhart, D. and McClelland, J. (1986). *Parallel distributed processing*. Cambridge, Mass.: MIT Press.
89. Carmesin, H. (1994). Multilinear back-propagation convergence theorem. *Physics Letters A*, 188(1), pp.27-31.
90. Hochreiter S. Untersuchungen zu dynamischen neuronalen Netzen, Diploma Thesis, Technische Universität München, Germany, 1991.
91. Geoffrey E. Hinton, Simon Osindero, and Yee Whye Teh. A fast learning algorithm for deep belief nets. *Neural Computation*, 18:1527–1554, 2006.
92. Erhan, D., Bengio, Y. and Courville, A. (2010). Why Does Unsupervised Pre-training Help Deep Learning?. *Journal of Machine Learning Research*, 11, pp.625-660.
93. Ian Goodfellow, Quoc Le, Andrew Saxe, and Andrew Ng. Measuring invariances in deep networks. In Y. Bengio, D. Schuurmans, J. Lafferty, C. K. I. Williams, and A. Culotta, editors, *Advances in Neural Information Processing Systems 22*, pages 646–654. 2009.
94. Sepp Hochreiter and Jürgen Schmidhuber (1997). "Long short-term memory" (PDF). *Neural Computation* 9 (8): 1735–1780
95. A. Graves, J. Schmidhuber. Offline Handwriting Recognition with Multidimensional Recurrent Neural Networks. *Advances in Neural Information Processing Systems 22*, NIPS'22, pp 545–552, Vancouver, MIT Press, 2009.
96. A. Graves, S. Fernandez, M. Liwicki, H. Bunke, J. Schmidhuber. Unconstrained online handwriting recognition with recurrent neural networks. *Advances in Neural*

- Information Processing Systems 21, NIPS'21, pp 577–584, 2008, MIT Press, Cambridge, MA, 2008.
97. M. Riedmiller and H. Braun. A direct adaptive method for faster backpropagation learning: The RPROP algorithm. In H. Ruspini, editor, *Proceedings of the IEEE International Conference on Neural Networks (ICNN)*, pages 586 { 591, San Francisco, 1993.
98. Mosca, A. and Magoulas, G. (2015). Adapting Resilient Propagation for Deep Learning. In: *UK workshop on Computational Intelligence*. Exeter: Springer.
99. Sven Behnke (2003). Hierarchical Neural Networks for Image Interpretation. *Lecture Notes in Computer Science 2766*. Springer.
100. Igel, C., Toussaint, M. and Weishui, W. (2005). Rprop Using the Natural Gradient. *Trends and Applications in Constructive Approximation*, pp.259-272.
101. Kemp, B. and Olivan, J. (2003). European data format ‘plus’ (EDF+), an EDF alike standard format for the exchange of physiological data. *Clinical Neurophysiology*, 114(9), pp.1755-1761.



РОССИЙСКАЯ ФЕДЕРАЦИЯ



## СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2016613369

Нейросетевой обработчик абдоминальной  
электрокардиограммы

Правообладатель: *федеральное государственное автономное  
образовательное учреждение высшего образования  
«Национальный исследовательский Томский политехнический  
университет» (RU)*

Авторы: *Девярых Дмитрий Владимирович (RU),  
Гергет Ольга Михайловна (RU)*

Заявка № 2016610524

Дата поступления 26 января 2016 г.

Дата государственной регистрации

в Реестре программ для ЭВМ 24 марта 2016 г.



Руководитель Федеральной службы  
по интеллектуальной собственности

Г.П. Ивлиев



РОССИЙСКАЯ ФЕДЕРАЦИЯ



## СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2016616790

Конструктор динамических и глубоких нейронных сетей

Правообладатель: *федеральное государственное автономное образовательное учреждение высшего образования «Национальный исследовательский Томский политехнический университет» (RU)*

Авторы: *Девятых Дмитрий Владимирович (RU), Гергет Ольга Михайловна (RU)*

Заявка № 2016614071

Дата поступления 25 апреля 2016 г.

Дата государственной регистрации

в Реестре программ для ЭВМ 20 июня 2016 г.

Руководитель Федеральной службы  
по интеллектуальной собственности

 Г.П. Ивлиев





**ООО Лечебно-оздоровительный центр  
«ЗДОРОВАЯ МАМА – КРЕПКИЙ МАЛЫШ»**  
г. Томск, ул. Транспортная, 5, тел. 66-05-02, 8 913-818-8652

### АКТ

#### **о внедрении результатов диссертационной работы Д.В. Девярых, представляемой на соискание ученой степени кандидата технических наук**

Настоящий акт составлен в том, что предложенные в диссертационной работе Д. В. Девярых математические методы и алгоритмы включены в состав программного обеспечения Центра «Здоровая мама- крепкий малыш».

Предложенный в работе нейросетевой алгоритм позволяет выделять электрокардиограмму плода из абдоминального сигнала матери. Благодаря неинвазивному подходу и отсутствию необходимости в применении ультразвука, мониторинг не ограничен по длительности и частоте в триместр. Для стабильной работы алгоритма достаточно одного канала наблюдения абдоминального сигнала матери, длительность и стационарность RR-интервалограммы которого могут быть произвольными.

Внедрение разработанного программного обеспечения позволило оценивать сердечную активность плода, выделять его RR-интервалограмму, обнаруживать нестационарность.

Директор Центра «Здоровая мама-крепкий  
малыш»  
Доктор мед.наук, профессор



Т.С. Кривоногова



Минздрав России

Государственное бюджетное образовательное  
учреждение высшего профессионального образования  
«Сибирский государственный  
медицинский университет»  
Министерства здравоохранения  
Российской Федерации  
(ГБОУ ВПО СибГМУ Минздрава России)

Московский тракт, д. 2, г. Томск, 634050  
Телефон (3822) 53 04 23;  
Факс (3822) 53 33 09  
ОКПО 01963539 ОГРН 1027000885251  
ИНН 7018013613 КПП 701701001

### АКТ


#### **о внедрении результатов диссертационной работы Д.В. Девярых, представляемой на соискание ученой степени кандидата технических наук**

Настоящий акт составлен в том, что предложенные в диссертационной работе Д.В. Девярых математические модели и алгоритмы обладают актуальностью, представляют практический интерес и включены в состав программного обеспечения ОГАУЗ «Детская городская больница №1» г. Томск. Предложенные в работе алгоритмы применяются для неинвазивной, фетальной электрокардиографии без использования ультразвуковых технологий.

Программная реализация динамической, нейросетевой модели разделения источников позволила оценивать частоту сердечных сокращений плода путем выделения плодовой составляющей из абдоминального, материнского сигнала, зарегистрированного в нескольких отведениях.

Проректор по лечебной работе,  
профессор, заведующий кафедрой  
педиатрии ФПК и ППС, доктор медицинских наук



 Е.В. Михалев