

Федеральное государственное бюджетное
образовательное учреждение высшего образования
«Пермский государственный гуманитарно-педагогический университет»

На правах рукописи

ЧЕРЕПАНОВ Федор Михайлович

**МЕТОДЫ ПОВЫШЕНИЯ ЭФФЕКТИВНОСТИ НЕЙРОСЕТЕВЫХ
РЕКОМЕНДАТЕЛЬНЫХ СИСТЕМ В УСЛОВИЯХ ОГРАНИЧЕННЫХ
ОБЪЕМОВ ВЫБОРОК СО СЛОЖНЫМИ КОРРЕЛЯЦИОННЫМИ
СВЯЗЯМИ (НА ПРИМЕРЕ ДИАГНОСТИКИ И ПРОГНОЗИРОВАНИЯ
СЕРДЕЧНО-СОСУДИСТЫХ ЗАБОЛЕВАНИЙ ЧЕЛОВЕКА)**

Специальность: 05.13.01 – Системный анализ, управление и обработка
информации (технические и информационные системы)

Диссертация на соискание ученой степени
кандидата технических наук

Научный руководитель
д-р техн. наук,
профессор Ясницкий Л.Н.

Пермь, 2019

Оглавление

ВВЕДЕНИЕ.....	5
ГЛАВА 1. АНАЛИЗ ПРОБЛЕМ ЭФФЕКТИВНОГО ПРИМЕНЕНИЯ НЕЙРОСЕТЕВЫХ РЕКОМЕНДАТЕЛЬНЫХ СИСТЕМ.....	11
1.1. Анализ методов борьбы с аномальными наблюдениями	12
1.1.1. Анализ методов выявления аномальных наблюдений	12
1.1.2. Робастные методы обработки данных	17
1.2. Анализ методов вычисления информативности входных параметров	18
1.3. Анализ клинических методов диагностики заболеваний сердечно- сосудистой системы.....	22
1.3.1. Опрос	22
1.3.2. Физикальное обследование	23
1.3.3. Лабораторные методы диагностики	25
1.3.4. Неинвазивные методы диагностики	26
1.3.5. Инвазивные методы диагностики.....	27
1.4. Анализ нейросетевых методов медицинской диагностики и прогнозирования возникновения и развития заболеваний	28
1.4.1. Нейросетевые методы медицинской диагностики	28
1.4.2. Нейросетевые методы прогнозирования возникновения и развития заболеваний.....	30
1.5. Показатели эффективности нейросетевых систем	32
1.5.1. Метрики качества нейросетевой модели	32
1.5.2. Метрики качества прогнозирования	34
1.5.3. Метрики качества медицинских диагностических методов.....	36
ВЫВОДЫ ПО ГЛАВЕ	39
ГЛАВА 2. МЕТОДЫ ПОВЫШЕНИЯ ЭФФЕКТИВНОСТИ НЕЙРОСЕТЕВЫХ СИСТЕМ.....	40
2.1. Метод выявления аномальных наблюдений с использованием ИНС.....	40

2.2. Метод вычисления информативности входных параметров посредством анализа нейросетевой модели	44
2.3. Метод настройки специфичности и чувствительности нейросетевых моделей	48
2.4. Метод экспертной коррекции при прогнозировании с использованием ИНС.....	50
2.4.1. Построение рекомендаций	53
2.5. Метод скользящего окна при прогнозировании с использованием ИНС.....	54
2.5.1. Построение рекомендаций	56
ВЫВОДЫ ПО ГЛАВЕ	58
ГЛАВА 3. ПРОЕКТИРОВАНИЕ И РАЗРАБОТКА НЕЙРОСЕТЕВОЙ РЕКОМЕНДАТЕЛЬНОЙ СИСТЕМЫ	60
3.1. Проектирование системы.....	60
3.1.1. Анализ требований	60
3.1.2. Определение прецедентов	62
3.1.3. Диаграмма последовательности	68
3.1.4. Определение структуры системы	69
3.2. Обоснование выбора средств разработки	72
3.3. Описание программной реализации системы.....	74
3.3.1. Модуль описания предметной области.....	74
3.3.2. Модуль сбора наблюдений.....	75
3.3.3. Модуль извлечения знаний	76
3.3.4. Модуль консультирования	79
3.4. Планируемые доработки системы	80
ВЫВОДЫ ПО ГЛАВЕ	82
ГЛАВА 4. ТЕСТИРОВАНИЕ РАЗРАБОТАННЫХ МЕТОДОВ ПРИ ПОСТАНОВКЕ ДИАГНОЗОВ ЗАБОЛЕВАНИЙ СЕРДЕЧНО-СОСУДИСТОЙ СИСТЕМЫ ЧЕЛОВЕКА	84
4.1. Тестовое множество	84
4.2. Показатели эффективности нейросетевой рекомендательной системы	85

4.3. Тестирование метода выявления аномальных наблюдений	86
4.4. Тестирование метода вычисления информативности входных параметров	90
4.5. Тестирование метода настройки специфичности и чувствительности.....	95
4.6. Тестирование методов прогнозирования заболеваний	96
4.6.1. Тестирование метода экспертной коррекции при прогнозировании с использованием ИНС	97
4.6.2. Тестирование метода скользящего окна при прогнозировании с использованием ИНС	98
4.7. Виртуальные компьютерные эксперименты.....	101
4.8. Результаты внедрения результатов работы и тестирования системы.....	106
ВЫВОДЫ ПО ГЛАВЕ	108
ОСНОВНЫЕ РЕЗУЛЬТАТЫ И ВЫВОДЫ	109
Список сокращений и условных обозначений	110
Библиографический список.....	112
Приложение А	124
Приложение Б	125
Приложение В.....	126
Приложение Г	127
Приложение Д.....	128
Приложение Е	129
Приложение Ж.....	130
Приложение З	131
Приложение И	132
Приложение К.....	133
Приложение Л.....	135

ВВЕДЕНИЕ

В настоящее время все большее практическое применение находят системы, основанные на инструменте искусственных нейронных сетей (ИНС). Они нашли применение практически во всех областях человеческой деятельности: экономике, социологии, экологии, медицине и т.д.

Для создания таких систем необходимо иметь качественную выборку данных для обучения и тестирования нейронной сети, но в силу большого числа факторов, отрицательно влияющих на качество выборки, это становится непростой задачей. Одним из путей решения указанной проблемы является использование выборок большого объема и нейронных сетей глубокого обучения. Но не во всех задачах возможно собрать достаточный объем данных, а сети глубокого обучения в большинстве своем предназначены для анализа данных большой размерности. В этом случае необходимо иметь возможность извлекать как можно больше информации из имеющегося набора данных при помощи нейросетевых архитектур, предназначенных для обработки небольших объемов данных. Однако чем меньше набор данных, тем большее отрицательное влияние на него оказывают такие факторы, как наличие аномальных наблюдений, недостаток или большое количество входных параметров.

Кроме того, в практике нейросетевого моделирования часто встречаются задачи, характеризующиеся наличием сильных внутрисистемных связей между входными параметрами, что является препятствием для создания качественных нейросетевых моделей, в том числе предназначенных для прогнозирования процессов, развивающихся во времени.

Примерами таких задач являются персонифицированная диагностика, прогнозирование развития и лечение заболеваний, при решении которых должны в максимальной степени учитываться особенности каждого конкретного человека, при том, что собрать большой объем обучающей выборки довольно сложно, а входные параметры связаны между собой сложными корреляционными зависимостями, не имеющими строгого математического описания.

Таким образом, разработка методов повышения эффективности применения ИНС в условиях ограниченных объемов выборок со сложными корреляционными связями является актуальной задачей.

Степень разработанности темы исследования

Изучением возможностей применения ИНС занимались: А.И. Галушкин [8], А.Н. Горбань [9], Е.М. Миркес [18], В.И. Горбаченко [10], Д.А. Россиев [9; 28], С.А. Филист [33], Л.С. Куравский [15], А.Г. Лосев [6], Т.В. Истомина [13], В.Е. Лялин [17], А.В. Ключев [3], Л.Н. Ясницкий [48], W.G. Baxt [68], J. Schmidhuber [108], G.E. Hinton [85], Brian D. Ripley [105], R. Socher [103] и др.

В частности, проблемой обнаружения и нивелирования аномальных наблюдений в контексте нейросетевых систем занимались: G. Beliaikov, A. Kelarev, J. Yearwood, R. Leardib, C.L. Karrc, D.L. Massarta, В.Г. Царегородцев и др., однако в большинстве работ рассматриваются робастные процедуры, которые не дают информации о том, какие наблюдения являются аномальными.

Способы вычисления информативности входных параметров изучались в работах таких авторов, как: В.Г. Царегородцев, А.Н. Горбань, Д.А. Россиев, I. Cloete, J.M. Zurada, A.H. Sung, J.D. Olden, M.K. Joy, R.G. Death, S.J. Kemp, F. Hanse и др. Однако в данных работах не делается анализ применимости указанных методов в условиях ограниченных объемов выборок со сложными корреляционными связями.

Рассмотрены работы таких авторов, как F. Amato, F. López, P. Vañhara, A. Hampl, J. Havel и др., посвященные перечислению успехов в изучении возможностей применения нейронных сетей в медицине. В работах Q. Kadhim, Y.-T. Lo, H. Fujita, T.-W. Pai, О.И. Аравина, Л.А. Хливенко, В.В. Васильева, Ф.А. Пятаковича и др. ИНС предлагается применять для диагностики заболеваний сердечно-сосудистой системы (ССС). При этом во многих упомянутых публикациях помимо термина «диагностика» иногда используется термин «прогноз», понимаемый, однако, в узком смысле – как исход заболевания, а не как процесс, развивающийся во времени. Таким образом, вопрос применения ИНС для моделирования заболеваний, как процессов, развивающихся во времени, проработан не в полной ме-

ре, что объясняется наличием проблем при прогнозировании процессов со сложными внутрисистемными корреляционными связями.

В работах таких авторов, как А.Г. Мустафаев, J. Chen, K. Kalyan и др., для оценки качества нейросетевых диагностических систем вычисляются такие характеристики, как специфичность и чувствительность, но не описано, как можно повлиять на значения данных характеристик. В работе W.G. Baht обучались две нейросетевые модели на разных выборках, что позволяло получить две отдельные нейросетевые модели – с высокой специфичностью и с высокой чувствительностью, но требовало сбора дополнительных примеров и процедуры объединения выдаваемых двумя моделями результатов. Таким образом, вопрос подстройки операционных характеристик нейросетевых диагностических моделей имеет недостаточную проработку.

Целью диссертационного исследования является повышение эффективности нейросетевых рекомендательных систем в условиях ограниченных объемов выборок со сложными корреляционными связями на примере системы диагностики и прогнозирования заболеваний сердечно-сосудистой системы (ССС) человека.

Основные задачи исследования:

1. Разработать эффективные методы предварительного анализа небольших выборок данных со сложными корреляционными связями: метод выявления аномальных наблюдений в выборке данных и метод вычисления информативности входных параметров предметной области.

2. Разработать метод настройки специфичности и чувствительности для нейросетевых рекомендательных систем.

3. Разработать методы сценарного прогнозирования, применимые в задачах со сложными корреляционными связями между входными параметрами.

4. Спроектировать и разработать нейросетевую рекомендательную систему диагностики и прогнозирования заболеваний ССС человека, а также выполнить экспериментальную и практическую проверку эффективности предложенных методов.

Объект исследования: информационные системы, основанные на аппарате ИНС.

Предмет исследования: нейросетевые методы обработки информации на примере диагностики, прогнозирования и построения рекомендаций по лечению сердечно-сосудистых заболеваний человека.

Методы исследований: системный анализ; теория алгоритмизации и программирования; нейросетевые технологии; статистический анализ.

Положения, выносимые на защиту, обладающие научной новизной:

1. Разработаны методы анализа обучающих выборок: *метод выявления аномальных наблюдений с использованием ИНС*, основанный на методе анализа удаленных остатков, отличающийся тем, что вместо регрессионных моделей используются нейросетевые; *метод вычисления информативности входных параметров посредством анализа нейросетевой модели*, отличающийся способом вариации входных параметров. Применение этих методов позволило повысить качество получаемых нейросетевых моделей в условиях ограниченных объемов выборок со сложными корреляционными связями (п. 12 «Визуализация, трансформация и анализ информации на основе компьютерных методов обработки информации» паспорта специальности 05.13.01 ВАК РФ).

2. Разработан метод настройки чувствительности алгоритмов обучения ИНС к ошибкам первого и второго рода, который отличается тем, что параметрически модифицируется вид функции потерь обучения нейронной сети, позволяя варьировать уровень чувствительности и специфичности получаемой нейросетевой модели. Это позволяет определять критерии оптимизации обучения ИНС с учетом требований к соответствующим характеристикам нейросетевой диагностической модели (п. 1 «Теоретические основы и методы системного анализа, оптимизации, управления, принятия решений и обработки информации»; п. 12 «Визуализация, трансформация и анализ информации на основе компьютерных методов обработки информации» паспорта специальности 05.13.01 ВАК РФ).

3. Разработаны два метода, позволяющие повысить качество прогнозирования развития процессов во времени с применением нейросетевых моделей: ме-

тод экспертной коррекции и метод скользящего окна, позволяющие при прогнозировании заболеваний ССС человека учитывать не только изменение возраста пациента, но и изменение других сопутствующих параметров (п. 12 «Визуализация, трансформация и анализ информации на основе компьютерных методов обработки информации» паспорта специальности 05.13.01 ВАК РФ).

Практическая значимость работы. Разработана нейросетевая рекомендательная система, предназначенная для диагностики, прогнозирования и построения рекомендаций по лечению и профилактике заболеваний ССС человека. Применение предложенных в диссертации методов позволило получить более точные нейросетевые модели диагностирования заболеваний с требуемыми операционными характеристиками, а также повысить точность сценарного прогнозирования возникновения и развития заболеваний ССС человека.

Реализация результатов работы. Результаты работы внедрены и используются в клинической практике кардиологического отделения Городской клинической больницы № 4 г. Перми, а также в учебном процессе при проведении практических занятий по дисциплине «Методы искусственного интеллекта» в Пермском государственном национальном исследовательском университете и по дисциплине «Интеллектуальные информационные системы» в Пермском государственном гуманитарно-педагогическом университете. Акты внедрения результатов диссертационной работы прилагаются.

Достоверность и обоснованность результатов подтверждаются результатами численного моделирования, тестирования ИНС на тестовых и подтверждающих выборках, а также результатами внедрения и опытной эксплуатации разработанных методов в составе системы диагностирования и прогнозирования развития заболеваний ССС человека.

Апробация работы. Основные результаты работы докладывались и обсуждались на следующих всероссийских и международных конференциях: «Актуальные проблемы механики, математики, информатики» (Пермь, 2010); «Нейрокомпьютеры и их применение» (Москва, 2012, 2018); «Медико-экологические информационные технологии» (Курск, 2013); «Проблемы информатики в образова-

нии, управлении, экономике и технике» (Пенза, 2014); «Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века» (Пермь, 2017); International Conference on Digital Science (DSIC'18) (Montenegro, 2018).

Публикации. По теме диссертационной работы опубликовано 22 печатные работы, в том числе: 7 опубликованных тезисов, 5 свидетельств о государственной регистрации программ, 10 статей, 6 из которых в журналах, входящих в перечень рекомендованных ВАК РФ, из них 4 в журналах, индексируемых в базе Scopus.

Структура и объем диссертации. Диссертация состоит из введения, четырех глав, заключения, списка литературы из 116 наименований и 11 приложений. Общий объем работы составляет 136 страниц, из которых 123 страниц занимает основной текст диссертации, включающий 24 рисунка и 8 таблиц.

ГЛАВА 1. АНАЛИЗ ПРОБЛЕМ ЭФФЕКТИВНОГО ПРИМЕНЕНИЯ НЕЙРОСЕТЕВЫХ РЕКОМЕНДАТЕЛЬНЫХ СИСТЕМ

Основой нейросетевых рекомендательных систем является нейросетевая модель предметной области, от качества которой напрямую зависит достоверность выдаваемых рекомендаций. Необходимым условием для получения качественной нейросетевой модели является адекватная выборка данных для обучения и тестирования нейронной сети, но в силу большого числа негативных факторов, отрицательно влияющих на качество выборки, это становится непростой задачей. К таким факторам относятся: наличие в выборке аномальных наблюдений, недостаточное количество входных параметров, малый объем выборки. Одним из путей решения указанной проблемы является использование выборок большого объема и размерности, а также нейронных сетей глубокого обучения, что позволяет устранить или снизить влияние обозначенных выше негативных факторов.

Однако не во всех задачах возможно собрать достаточный объем данных, а сети глубокого обучения в большинстве своем эффективны для анализа данных большой размерности. Таким образом, необходимо иметь возможность извлекать как можно больше информации из имеющегося набора данных при помощи нейросетевых архитектур, предназначенных для обработки небольших объемов данных.

Кроме того, встречаются задачи, решение которых требует создания качественных нейросетевых моделей, предназначенных для прогнозирования процессов, развивающихся во времени. В этом случае проблемой становится наличие сильных внутренних корреляционных связей между входными параметрами, что затрудняет применение моделей для сценарного прогнозирования методом вариации отдельных входных параметров.

Примерами задач, подверженных таким проблемам, являются персонализированная диагностика и прогнозирование развития заболеваний человека, при решении которых должны в максимальной степени учитываться особенности каждого конкретного человека, при том, что собрать большой объем обучающей выборки довольно сложно, а моделируемый объект имеет сложные внутренние

корреляционные связи, затрудняющие построение адекватной математической модели.

1.1. Анализ методов борьбы с аномальными наблюдениями

При построении математических моделей, основанных на наблюдениях, важную роль играет качество исходных данных. Отсутствие в выборке аномальных наблюдений имеет чрезвычайно важное значение для получения качественной модели, так как присутствие даже единичных ошибочных наблюдений может привести к невозможности построения адекватной модели [14].

Источником аномальных наблюдений могут быть один или несколько из указанных факторов:

- ошибки ввода данных (ошибки человека);
- ошибки измерения (инструментальные ошибки);
- преднамеренные (подтасованные данные или сделанные для тестирования методов обнаружения аномалий);
- ошибки обработки данных (возникающие в процессе манипуляции данными или непреднамеренные изменения);
- естественные (отклонения в процессе).

В борьбе с аномальными наблюдениями при построении математических моделей применяют два подхода [16]:

- обнаружение резко выделяющихся наблюдений, после чего появляется возможность скорректировать или исключить их из дальнейшей обработки;
- использование робастных методов построения моделей, которые позволяют нивелировать влияние аномальных наблюдений.

1.1.1. Анализ методов выявления аномальных наблюдений

Методы обнаружения аномалий (выбросов) в данных в совокупности различаются в зависимости от типа аномальных наблюдений. Каждый метод имеет

свои границы применения, особенности и формат представления результата. Ряд методов может использоваться в случае больших выборок необработанных или минимально обработанных данных, к которым может применяться закон больших чисел [5].

Наиболее популярны следующие методы выявления аномальных наблюдений:

- метод Тьюки, основанный на расчете межквартильного расстояния, и построенные на его основе диаграммы «Ящик с усами» и гистограммы;
- визуальный анализ стебельчато-листового графика;
- определение единичного значения как аномалии на основе Z -оценки и модифицированной Z -оценки;
- тест Граббса для единственного наблюдения;
- выявление аномалий на основе усеченных средних и другие способы.

Некоторые методы весьма специфичны и применимы только к малым и ультрамалым выборкам [5]:

- выявление аномалий в данных на основе теста Диксона;
- определение аномалий как наблюдений, лежащих на расстоянии более двух среднеквадратичных отклонений от среднего значения по выборке;
- выделение аномалий на основе среднего абсолютного отклонения от среднего значения.

Третий класс методов применяется в уникальных случаях, например, график рассеяния (поле корреляции) помогает выделить многомерные выбросы, а экстремальное стандартизованное отклонение выявляет множественные выбросы за одну процедуру [5].

Простейшая процедура заключается в статистическом анализе наименьшего или наибольшего значения, как наблюдений, которые можно считать аномальными. Однако она выполняет анализ лишь одного наблюдения и подразумевает анализ одномерных наблюдений, подчиняющихся нормальному закону распределения [30]. Для этой процедуры предложено несколько критериев:

Для обнаружения грубых ошибок применяется T -критерий Граббса [30; 83]:

$$T_n = \frac{x - \bar{x}}{s},$$

где $\bar{x}$ – среднее значение. Оценка выборочной средней находится по истинным данным либо $\bar{x} = \sum_1^n \frac{x}{n}$; s – выборочное среднеквадратическое отклонение случайной величины.

Полученные значения T_n сравнивают с табличными значениями процентных точек критерия Смирнова – Граббса. Если $T_n > T_{кр}$, то проверяемое значение является грубой ошибкой и относится к классу выбросов. Критерий Граббса имеет некоторые недостатки. Он не точен и не чувствителен к аномалиям, когда они обособлены на некотором расстоянии от общей совокупности [12].

Наряду с оценками Граббса для оценки грубых ошибок применяют L - и E -критерии, предложенные американскими статистиками Г. Тритъеном и Г. Муром.

1. L -критерий. Применяется для вычисления грубых ошибок в верхней части ранжированного ряда данных:

$$L = \frac{\sum_{i=1}^{n-k} (x_i - \bar{x}_k)^2}{\sum_{i=1}^n (x_i - \bar{x})^2},$$

где x_i – выборка наблюдений по какому-либо одному, j -му признаку;

n – объем выборки;

k – число наблюдений с резко отклоняющимися значениями признака;

$\bar{x}$ – общая для выборочной совокупности данных средняя величина;

$\bar{x}_k$ – средняя, которую рассчитывают по $n-k$ -наблюдениям, остающимся после отбрасывания k грубых ошибок «сверху» ранжированного ряда данных:

$$\bar{x}_k = \frac{\sum_{i=1}^{n-k} x_i}{n-k}.$$

2. L' -критерий применяется для грубых ошибок в данных, расположенных в нижней части ранжированного ряда данных:

$$L' = \frac{\sum_{i=k+1}^{n-k} (x_i - \bar{x}_k)^2}{\sum_{i=1}^n (x_i - \bar{x})^2},$$

где $\bar{x}$ – средняя рассчитанная по $(n-k)$ наблюдениям, остающимся после отбрасывания k грубых ошибок «снизу»:

$$\bar{x}_k = \frac{\sum_{i=k+1}^{n-k} x_i}{n-k}.$$

3. E -критерий используется, когда в выборке имеются предположительно грубые ошибки с наибольшими и наименьшими значениями, т. е. расположенные в верхней и в нижней части ранжированного ряда данных:

$$E = \frac{\sum_{i=k+1}^{n-k} (x_i - \bar{x}_{k'})^2}{\sum_{i=1}^n (x_i - \bar{x})^2},$$

где $\bar{x}_{k'}$ – средняя, рассчитанная по «истинным» данным после отбрасывания из выборки наименьших (k) и наибольших (k') значений, засоряющих совокупность данных:

$$\bar{x}_{k'} = \frac{\sum_{i=k+1}^{n-k'} x_i}{n - (k + k')}.$$

Все три критерия L, L', E имеют табулированные критические значения для заданного уровня значимости α при известном объеме выборки n и предполагаемом числе ошибок K . Если наблюдаемые значения критериев оказываются меньше пороговых, то ошибки в данных признаются грубыми.

К недостаткам этих методов следует отнести следующие факторы:

- применимы для больших наборов одномерных данных, подчиняющихся нормальному закону распределения;
- аномальные наблюдения сами влияют на значения математического ожидания и среднего квадратичного отклонения, что может способствовать их маскировке при применении метода [5];
- применимы для обнаружения единственного аномального наблюдения.

Z -оценка – это мера относительного разброса наблюдаемого или измеренного значения, которая показывает, сколько стандартных отклонений составляет его разброс относительно среднего значения. Из свойств стандартного распределения известно, что 99,7 % наблюдений должны отстоять от математического ожидания на величину, не превышающую 3σ . Но, как и многие другие статистические процедуры, опирающиеся на среднее значение и стандартное отклонение анализируемой выборки, Z -оценка имеет ряд ограничений: во-первых, среднее и средне-квадратическое отклонения требуют нормальности распределения, а также изменяются под воздействием аномальных наблюдений, что может способствовать их маскировке, во-вторых, максимально возможное значение Z -оценки зависит от размера выборки [5].

Для обнаружения аномалий в многомерных наборах данных используют расстояние Махаланобиса [84; 113], которое определяется как расстояние от наблюдаемой точки до центра тяжести многомерного пространства, определяемого коррелированными независимыми переменными. Аномальными считаются точки, расстояния Махаланобиса которых от центра тяжести велико. Для расчета критического расстояния можно воспользоваться следующей зависимостью: для нормально распределенных исходных данных расстояния Махаланобиса имеют распределение, близкое к распределению χ^2 (хи-квадрат), со степенью свободы, равной размерности векторов анализируемого множества. Значение 97,5 % квантиля этого распределения берется в качестве порогового значения, и те наблюдения,

расстояния Махаланобиса которых превышают это пороговое значение, считаются аномальными [113].

В статистике и регрессионном анализе также для выявления аномальных наблюдений применяются методы на основе анализа удаленных остатков и его модификации: расстояние Кука (Cook's distance), модифицированное расстояние Кука, студентизированные остатки, DFFITS, стандартизованные DFFITS и другие [81; 84]. Удаленные остатки определяются как остатки регрессионной модели, т. е. разница между фактическим значением и прогнозируемым для соответствующих наблюдений, полученных при поочередном исключении соответствующих наблюдений из анализа. Необходимым условием построения и применения данных методов является наличие адекватной регрессионной модели исследуемой закономерности.

1.1.2. Робастные методы обработки данных

В статистике под робастностью понимают нечувствительность к малым отклонениям [16]. Этот подход предлагает вместо обнаружения аномальных наблюдений применять методы обработки данных, которые к этим аномалиям не чувствительны. Примером может служить использование медианы, которая дает более точное значение по сравнению с простой оценкой среднего значения при наличии в наборе данных выбросов. Методы оценивания, учитывающие наличие аномальных наблюдений и позволяющие при этом достаточно точно строить математические модели, называются робастными или устойчивыми. Таковыми являются методы Хубера, Винзора, Пуанкаре и ряд других методов [5]. При этом одним из необходимых параметров для этих методов является количество аномальных наблюдений в выборке, соответственно, предварительно их нужно обнаружить или каким-либо образом оценить количество.

При обучении нейросетевой модели вместо критерия наименьших квадратов возможно использование робастных аналогов. Так, в работе [36] приведены несколько таких функций и описано их практическое применение. В работе [69] предложен робастный гибридный алгоритм, сочетающий обнаружение аномалий

путем оптимизации критерия наименее урезанных квадратов (Least trimmed squares, LTS), их удаления и последующего обучения ИНС путем алгоритма обратного распространения ошибки. Отметим, однако, что в этом случае под робастностью понимается обучение сети на множестве с уже удаленными аномальными наблюдениями. В работе [106] применяется критерий наименьшей медианы квадратов (least median of squares, LMS) в сочетании с генетическими алгоритмами, это дает хорошие результаты, но требует больших вычислительных ресурсов.

Выводы: существующие методы обнаружения и игнорирования аномальных наблюдений имеют множество ограничений, делающие их сложно применимыми для использования в контексте анализа обучающей выборки для ИНС. К таким ограничениям относятся: требование нормального закона распределения, малый или большой объем выборки, одномерность данных, возможность обнаружения только сильных или одиночных аномалий, наличие предварительно построенной регрессионной модели. Кроме того, в большинстве своем они предназначены для поиска аномалий в самой структуре данных, а не в структуре зависимости. Робастные методы, кроме того, не дают информации о том, какие наблюдения являются аномальными, хотя анализ этих наблюдений может дать некоторую дополнительную информацию.

1.2. Анализ методов вычисления информативности входных параметров

Практически любая задача обработки данных порождает необходимость выявления силы зависимости между входными и выходными параметрами. Это необходимо для определения значимых параметров, выявления закономерностей, упрощения модели за счет удаления низкорелевантных параметров.

Для решения этой задачи часто используется метод вычисления корреляции Пирсона, который хорошо подходит для описания линейных зависимостей или близких к ним. Также используются ранговые коэффициенты корреляции Фехнера, Кендалла, Спирмена [7], множественной ранговой корреляции, чувствительные только лишь к упорядоченным значениям переменных (измеренных в поряд-

ковой шкале, содержащей только информацию о порядке следования величин). Кроме того, для этих целей применяются коэффициент детерминации R^2 и его модификации (скорректированный, обобщенный), которые решают часть проблем, присущих стандартным методам, но требуют построения адекватной регрессионной модели, что не всегда возможно в задачах, в которых применяется аппарат нейросетевого моделирования. Также в работе [23] отмечается, что недостатком методов вычисления информативности, основанных на статистических моделях, являются требования, которые они предъявляют к качеству наблюдений и их количеству.

В связи с этим при разработке нейросетевых моделей применяются специализированные методы вычисления информативности параметров. В работе [35] предлагается использовать приближенную оценку изменения весовых коэффициентов при активации входных параметров. В работе [77] предлагается строить матрицы влияния входов путем анализа сил синаптических связей от входных нейронов к выходным, после чего отбрасывать незначимые входные параметры, повторяя данную процедуру несколько раз. Недостатками этого метода можно считать высокую вычислительную сложность и ограничение только на нейросетевые модели с прямым распространением сигнала. В работе [111] этот метод сравнивается с анализом нечетких кривых для определения степени влияния входных параметров на выходные, а также с методом анализа среднеквадратичной ошибки при удалении параметров и делается вывод о том, что метод анализа нечетких кривых дает наилучшие результаты.

В работе [98] приведено сравнение нескольких методов определения значимости входных параметров нейросетевой модели:

- 1) Объединенные веса – рассчитывает произведение входных и выходных весовых коэффициентов скрытого слоя между каждым входным и выходным нейроном, при этом суммируются произведения через все скрытые нейроны [97].

- 2) Алгоритм Гарсона – разбивает выходные весовые коэффициенты скрытого слоя на компоненты, связанные с каждым входным нейроном, используя абсолютные значения весовых коэффициентов.

3) Частные производные – вычисляет частные производные выходного сигнала ИНС по отношению к входным нейронам.

4) Возмущение входного сигнала – оценивает изменение среднеквадратичной ошибки сети при добавлении небольшого количества белого шума (до 50 %) к каждому входному нейрону, по очереди. Результирующее изменение среднеквадратичной ошибки в ответ на возмущение каждого входного параметра показывает относительную важность этого параметра.

5) Анализ чувствительности – значения каждого входного параметра делятся на равные интервалы по всему диапазону значений с сохранением всех остальных входных значений равными их по очереди: минимуму, 1-й квартилю, медиане, 3-й квартилю и максимуму. Далее рассчитывается медианное значение по этим 5 сводным статистикам, и относительная важность каждого входного параметра определяется величиной диапазона значений выходного нейрона (т.е. максимум–минимум).

6) Прямое пошаговое добавление – оценивает изменение среднеквадратичной ошибки сети путем последовательного добавления входных нейронов в нейронную сеть. Результирующее изменение среднеквадратичной ошибки для каждой добавленной переменной иллюстрирует относительную важность добавляемой переменной.

7) Обратное пошаговое исключение – аналогично предыдущему, но на каждом шаге исключается один из входных параметров и оценивается его влияние на среднеквадратичную ошибку.

8) Улучшенный пошаговый выбор 1 – аналогично предыдущему, но удаляется не только входной нейрон, но и все ассоциированные с ним весовые коэффициенты.

9) Улучшенный пошаговый выбор 2 – оценивает изменение среднеквадратичной ошибки сети путем последовательной установки значений входных параметров в их среднее значение. Результирующее изменение среднеквадратичной ошибки показывает относительную значимость.

В указанной работе делается вывод о том, что наилучшие результаты дает первый метод. Однако первые два метода применимы только для нейросетевых моделей с одним скрытым слоем. Третий требует большого объема вычислений для моделей с большим числом входных параметров. Недостатком четвертого метода является то, что при добавлении шума в значения входного параметра новые значения коррелируют с прежними, что снижает влияние этой замены. Пятый имеет точность вычисления значимости, сравнимую с методами под номерами 3, 4, 8, 9, на уровне 70 %. Методы 6–8 изменяют структуру нейронной сети, что делает сравнение результатов обучения этих сетей неустойчивым. Девятый может давать плохие результаты, когда значения параметра имеют небольшой разброс относительно их среднего значения, а также на качество такой оценки оказывают большое влияние выбросы. В работе [88] для устранения некоторых из описанных выше недостатков предлагается метод, названный методом рандомизации входного параметра (holdback input randomization method, HIPR), в котором вместо удаления параметров путем изменения структуры сети или добавления белого шума предлагается заменять компоненты входного вектора на равномерно распределенные случайные величины в диапазоне $[0.1 \dots 0.9]$, и с последующей оценкой влияния такой замены на ошибку прогнозирования. Достоинства данного метода: высокая точность, универсальность и хорошая интерпретируемость получаемых результатов.

Выводы: существует множество способов вычисления информативности входных параметров как статистическими методами, так и при помощи нейросетевых моделей. Однако им присущи разного рода ограничения, делающие их неприменимыми для анализа значимости входов нейронной сети в общем случае или применимыми, но с пониженной точностью определения степени значимости.

1.3. Анализ клинических методов диагностики заболеваний сердечно-сосудистой системы

1.3.1. Опрос

Больные заболеваниями ССС могут предъявлять жалобы на боль в области сердца, одышку, приступы удушья, отеки нижних конечностей, кровохарканье, ощущение сердцебиения или перебоев в работе сердца, головную боль, головокружение, снижение зрения [4].

Боль в области сердца может указывать на наличие стенокардии или инфаркта миокарда (ИМ) [4].

Одышка – один из наиболее частых и ранних признаков левожелудочковой сердечной недостаточности и застоя в малом круге кровообращения, возникающих при различных формах хронической сердечной недостаточности (ХСН). На ранних стадиях одышка появляется при физических нагрузках, но по мере развития заболевания порог возникновения одышки понижается вплоть до возникновения в состоянии покоя [4].

Приступы удушья – связаны с острой левожелудочковой сердечной недостаточностью, обусловленной ишемией или ИМ, тяжелыми нарушениями ритма сердца, резким подъемом артериального давления (АД) [4].

Отеки нижних конечностей в большинстве случаев возникают в результате правожелудочковой или бивентрикулярной сердечной недостаточности. Также это может проявляться у больных с симптоматической или эссенциальной артериальной гипертензией (АГ) [4].

Кровохарканье чаще всего возникает при тромбоэмболии мелких ветвей легочной артерии. Также это может свидетельствовать о тяжелой сердечной недостаточности, застое в малом круге кровообращения или резком повышении давления в легочной артерии [4].

Головные боли, головокружение, мелькание «мушек» перед глазами, нарушение зрения являются субъективными признаками повышения АД, которое часто возникает у больных симптоматической или эссенциальной АГ. Время

возникновения и характер головных болей могут проявляться по-разному и в разное время суток, тогда как некоторые пациенты не испытывают головной боли даже при значительном подъеме АД. Временами боли сопровождаются головокружениями, а у больных с гипертоническими кризисами сопровождаются тошнотой и рвотой, не приносящих облегчения, но эти признаки не всегда связаны с величиной повышения уровня АД [4].

Ощущение учащенного сердцебиения или перебоев в работе сердца может являться признаком нарушения ритма сердца или его проводимости. Однако эти жалобы являются крайне субъективным показателем, которые интерпретируются пациентами достаточно широко и в зависимости от интерпретации могут означать различные заболевания. Поэтому врач, проводящий обследование больного, должен особенно тщательно уточнять характер возникшей аритмии [4].

1.3.2. Физикальное обследование

Включает общий осмотр, пальпацию области сердца, перкуссию и аускультацию сердца, исследование артериального пульса, измерение АД [4].

Общий осмотр позволяет выявить характерные признаки болезни и дать предварительную оценку тяжести патологического процесса и степень функциональных расстройств [4].

Сознание у больных заболеваниями ССС может быть ясным и спутанным. Нарушения сознания, как правило, развиваются у больных, находящихся в тяжелом или крайне тяжелом состоянии, например, сердечная недостаточность III–IV степени, кардиогенный шок, острое нарушение мозгового кровообращения и др. [4].

Важным диагностическим показателем является **положение, которое облегчает страдания** больного, такое положение называют *вынужденным* [4].

Телосложение имеет диагностическое значение, так как конституция влияет на расположение и относительный размер органов, в том числе органов ССС, а также вызывает различные возможные патологии [4].

Бледный цвет кожи может быть обусловлен анемией или патологиями периферического кровообращения [4].

Цианоз или синюшное окрашивание кожи и видимых слизистых может свидетельствовать о недостаточной оксигенации крови в легких при различных заболеваниях органов дыхания (центральный цианоз), при замедлении кровотока на периферии, например, при венозном застое (периферический цианоз), в результате застоя крови в отдельных периферических венах при их сдавливании, например, опухолью или расширенными лимфатическими узлами (ограниченный цианоз) [4].

Эластичность кожи (тургор) позволяет определить такие показатели, как обезвоживание организма (эластичность снижена) либо наличие отека (повышенная эластичность) [4].

Набухание шейных вен является признаком застоя крови в венозном русле большого круга кровообращения и повышения центрального венозного давления (ЦВД). Другим признаком повышения ЦВД является наличие абдоминально-яремного рефлюкса [4].

Пальпация сердца позволяет выявить признаки гипертрофии миокарда левого желудочка (ЛЖ) или правого желудочка (ПЖ), дилатации полостей сердца, расширения магистральных сосудов, аневризмы аорты или ЛЖ [4].

Перкуссия сердца производится с целью определения величины, конфигурации и положения сердца и позволяет выявить признаки дилатации желудочков и предсердий, а также расширения сосудистого пучка [4].

Аскультация сердца является наиболее диагностически значимым физическим методом диагностики заболеваний сердца. Сочетания изменений I и II тонов, а также наличие специфических шумов позволяют диагностировать большое количество заболеваний. Вот далеко не полный список: недостаточность атриовентрикулярных клапанов (АВ-клапанов), застойная сердечная недостаточность, гипертрофия миокарда, тахикардия, митральный стеноз, аортальный стеноз и др. [4].

Исследование **артериального пульса** помогает выявить такие заболевания, как различные пороки сердца, сердечная недостаточность, мерцательная аритмия.

Исследование **артериального давления** позволяет выявить такие патологии, как артериальная гипертензия, артериальная гипотензия, асимметрии артериального давления [4].

1.3.3. Лабораторные методы диагностики

При заболеваниях ССС наибольшее клиническое значение имеет определение уровня липидов, некоторых электролитов, мочевой кислоты, а также показателей углеводного обмена, коагуляционного гемостаза и некроза миокарда, оценка функции почек [4].

Исследование глюкозы натощак – повышение уровня глюкозы венозной плазмы рассматривают как факторы риска (ФР) заболеваний ССС. Уровень глюкозы $\geq 7,0$ ммоль/л при повторных измерениях свидетельствует о развитии сахарного диабета (СД) [4].

Уровень холестерина и триглицеридов – наибольшее клиническое значение имеет определение сывороточного уровня общего холестерина (ХС), ХС липопротеинов низкой плотности (ЛПНП), ХС липопротеинов высокой плотности (ЛПВП) и триглицеридов (ТГ) плазмы крови. В большинстве случаев этих данных бывает достаточно, чтобы оценить особенности и выраженность нарушений липидного обмена, а также степень атерогенности этих нарушений, определить лечебно-профилактические подходы [4].

Исследование коагуляционного гемостаза

Наибольшее клиническое значение при заболеваниях ССС имеет определение активированного частичного тромбопластинового времени (АЧТВ), протромбинового времени (протромбиновый индекс), международного нормализованного отношения (МНО) [4].

Тропонины

Наиболее чувствительный и специфичный показатель некроза кардиомиоцитов – повышение содержания тропонинов I и T, входящих в состав тропомиозинового комплекса сократительного миокарда. В норме кардиоспецифические тропонины в крови отсутствуют или присутствуют в минимальном количестве [4].

Миоглобин

Концентрация миоглобина в крови – очень чувствительный, но малоспецифичный маркер некроза миокарда. Выход миоглобина из кардиомиоцитов и повышение его концентрации в крови происходят еще до формирования очага некроза – на стадии выраженного ишемического повреждения сердечной мышцы [4].

Мочевая кислота

Повышение уровня мочевой кислоты – дополнительный ФР развития ССЗ. Повышение уровня мочевой кислоты часто выявляют при нелеченой АГ, особенно в рамках МС. Ее уровень соответствует степени выраженности нефроангиосклероза [4].

1.3.4. Неинвазивные методы диагностики

Электрокардиография (ЭКГ) – запись колебаний разности потенциалов, возникающих на поверхности миокарда или в окружающей его проводящей среде при распространении волны возбуждения по сердцу. ЭКГ регистрируют с помощью электрокардиографа – прибора, предназначенного для записи изменения разности потенциалов между двумя точками в электрическом поле сердца (например, на поверхности тела) во время его возбуждения. ЭКГ – незаменимый метод диагностики нарушений сердечного ритма и проводящей системы сердца, гипертрофии миокарда желудочков и предсердий, ишемической болезни сердца (ИБС), ИМ и других заболеваний сердца [4].

Ультразвуковое исследование сердца (ЭхоКГ) – один из основных методов диагностики в кардиологии, который позволяет исследовать сердце и магистральные сосуды с использованием режима одно-, двух-, трехмерного сканирования, полного доплеровского исследования внутрисердечных потоков, миокардиальной тканевой доплер-ЭхоКГ [4].

Перфузионная сцинтиграфия миокарда – метод, предназначенный для выявления областей относительного или абсолютного снижения кровотока вследствие ишемии или рубцового повреждения миокарда. В основе метода лежит фракционный принцип Сапирштейна, согласно которому радионуклид в процессе

первой циркуляции распределяется в миокарде в количествах, пропорциональных коронарной фракции сердечного выброса, и отражает региональное распределение перфузии (региональный кровоток в миокарде). Области нарушенного кровоснабжения отображаются как участки сниженной концентрации радиофармакологического препарата или дефекты перфузии [4].

Мультиспиральная компьютерная томография (КТ) – разновидность КТ, которая обладает высоким временным разрешением, может работать в режиме кардиосинхронизации, обладает большим пространственным разрешением (до 0,5 мм) и возможностью исследования сердца и коронарных артерий, а также аорты, легочной артерии, периферических артерий и вен [4].

Магнитно-резонансная томография в диагностике атеросклероза сонных артерий – позволяет получать двух- и трехмерные ангиографические изображения сонных, позвоночных и внутримозговых артерий на большом протяжении с высоким пространственным разрешением, без артефактов, присущих ультразвуковому исследованию. Основные разновидности магнитно-резонансной ангиографии (МР-ангиографии): бесконтрастная и контрастная [4].

1.3.5. Инвазивные методы диагностики

Коронарная ангиография (КАГ) – инвазивное диагностическое исследование, проводимое для оценки состояния коронарных артерий и коронарного кровотока, обнаружения патологических изменений артерий, а также для качественной и количественной характеристики пораженных сегментов артерий [4].

КАГ позволяет определить: тип кровоснабжения миокарда и варианты отхождения коронарных артерий, аномалии сосудов; наличие, расположение, протяженность, степень и характер атеросклеротического поражения сосудов сердца; признаки осложненного поражения (тромбоз, изъязвление, кальциноз и др.); спазм коронарной артерии; миокардиальный мостик [4].

Исследование коронарных артерий

В последние годы в клинической практике наряду с рентгеноконтрастной ангиографией стали широко применять внутрисосудистое ультразвуковое исследование

дование (ВСУЗИ) коронарных артерий. Данный метод диагностики позволяет оценить структуру сосудистой стенки, состав и гемодинамическую значимость атеросклеротической бляшки, выявить осложненные и структурно нестабильные бляшки, что дает возможность выбрать наиболее подходящий метод лечения. Использование ВСУЗИ позволяет оценить состояние оперированного сегмента артерии после выполнения чрескожной баллонной коронарной ангиопластики (ЧБКА), ротационной атерэктомии, установки коронарного стента и определить эффективность выполненного вмешательства, добиться полноценного расправления стента [4].

Выводы: из описания существующих методов диагностики заболеваний ССС следует их общий недостаток: они могут дать только приблизительное представление о наличии заболевания, показывают схожие признаки с другими заболеваниями и часто обнаруживают заболевания при развитии патологии до серьезного уровня. Кроме того, некоторые из них инвазивны, дискомфортны и даже опасны для жизни пациента, хотя и дают более достоверные результаты.

1.4. Анализ нейросетевых методов медицинской диагностики и прогнозирования возникновения и развития заболеваний

1.4.1. Нейросетевые методы медицинской диагностики

Как было указано выше, заболевания ССС начинают проявлять себя только на поздних стадиях развития, где лечение уже затруднено, следовательно, ранняя диагностика и прогнозирование возникновения и развития заболевания являются необходимыми условиями повышения качества оказания медицинских услуг в данной области. Большие надежды возлагаются на развитие и применение сравнительно новых диагностических методов, основанных на стратегиях искусственного интеллекта, в частности – на нейросетевых технологиях.

В связи с этим в настоящее время публикуются обширные обзоры [60; 62; 67; 94], посвященные перечислению успехов, анализу возможностей и перспектив применения нейронных сетей в медицине. Например, в обзорной статье группы

исследователей из Испании и Чехии [67] дается анализ 56 публикаций. Авторы этих работ понимают, что созданные ими нейронные сети, хотя и показывают неплохие результаты диагностики заболеваний, однако они не пригодны для прогнозирования развития заболеваний на длительные периоды времени, а значит, и не годятся для оптимизации схем лечения больных и профилактики заболеваний.

Хорошие результаты показали модели искусственных нейронных сетей для диагностики сахарного диабета, предстательной железы [56; 93], рака поджелудочной железы [65], рака легких [57], рака молочной железы [62; 86; 94], лейкемии [104], гепатита Б [73], инсульта [63], заболевания почек [87; 90], болезни Паркинсона [82] и Хантингтона [110], для ранней диагностики болезни Альцгеймера [55], для планирования лучевой терапии при раке мозга [99], для оценки степени умственной отсталости [95], для диагностики заболеваний сердечно-сосудистой системы [34; 54; 70; 78; 87; 91; 96; 100; 107].

Во многих из этих работ, например [76; 100], нейросетевые диагностические системы рекомендуются для поддержки клинических решений врача, в [57] – в качестве инструмента доклинической диагностики. В [90] отмечается, что нейросетевые системы позволяют сократить время, необходимое для диагностики заболеваний, в [73] указывается что применение нейросетей позволяет оптимизировать диагностический процесс и избегать ошибочных диагнозов. В [67] также изложено, что нейросети помогают избегать ошибочных диагнозов, однако, несмотря на их широкое применение в современной диагностике, они должны рассматриваться только как инструмент для облегчения окончательного решения, за которое отвечает врач. В [65] отмечаются преимущества нейросетевой диагностики по сравнению с ручной диагностикой. В [63] предлагается с помощью нейросетей создавать мобильные приложения мониторинга состояния организма, например, диагностики инсультов, происходящих во время сна.

1.4.2. Нейросетевые методы прогнозирования возникновения и развития заболеваний

Следует отметить, что в упомянутых публикациях помимо термина «диагностика» иногда используется термин «прогноз», понимаемый, однако, только в узком смысле этого слова – как «исход заболевания» (тот же диагноз), а не процесс, развивающийся во времени. Так, в работе [91] сообщается о применении нейросетей для прогнозирования ишемической болезни сердца, тогда как на самом деле речь идет о ранней диагностике этого заболевания. В [93] сообщается о прогнозировании рака предстательной железы, тогда как речь идет об определении стадии развития этого заболевания, т.е. о его диагностике на текущий момент времени. Точно так же в работе [61] сообщается о применении нейронных сетей для прогнозирования риска возникновения остеопороза, в работах [76; 102] – для прогнозирования вероятности выживания органа при трансплантации, в [109] – для прогнозирования риска перелома костей у пациентов с тяжелой формой остеохондроза, в [56] – для прогнозирования рака предстательной железы, в [100] сообщается о разработке нейронной сети, прогнозирующей острый инфаркт миокарда в течение двух недель у пациентов с болью в груди, у которых на ЭКГ признаки инфаркта отсутствуют. Авторы работы [60] призывают исследователей применять методы искусственного интеллекта не только для диагностики, но и для оптимизации курсов лечения пациентов, не объясняя, однако, как это нужно делать и не приводя примеров такой оптимизации. И.О. Прохоренко [27] сообщает о прогнозировании возможности развития у пациентов в будущем таких патологий, как депрессия, метаболический синдром, инфаркт миокарда, в том числе с зубцом Q, остеопороз. При этом не уточняются сроки наступления «будущего» и как на это «будущее» можно влиять. В работе [71] предлагается использовать нейросетевые модели для прогнозирования необходимости проведения операции после прохождения терапии цитоферезом, которая используется для лечения язвенного колита.

Между тем после обучения и тестирования нейронная сеть становится математической моделью изучаемой предметной области – человека и учитывает его физиологические особенности и имеющиеся заболевания. Это значит, что над математической моделью человека возможно проводить виртуальные компьютерные эксперименты. В пределах математической погрешности математическая модель ведет себя так же, как моделируемый объект – человек. Поэтому есть основание предполагать, что нейросетевые модели, как и классические математические модели, возможно использовать для исследования закономерностей моделируемых предметных областей, в частности, для прогнозирования возникновения заболеваний в будущем. Например, изменяя какой-либо один или несколько входных параметров (возраст, вес, образ жизни и др.), можно наблюдать за поведением выходных параметров – степенью развития заболеваний человека. Однако этому мешает наличие сложных внутренних корреляционных связей между возрастом пациента и биомедицинскими показателями его здоровья. Вследствие этого невозможным является выполнение достоверного сценарного прогнозирования развития заболеваний путем виртуального изменения одного только параметра «возраст пациента» при сохранении неизменными всех остальных параметров.

Различные способы учета этих сложных внутрисистемных связей входных параметров при диагностировании заболеваний и возможности нейронных сетей для прогнозирования заболеваний как процессов, развивающихся во времени, были показаны в публикациях автора настоящей диссертационной работы [21; 22; 41; 49–52; 66; 74; 115–116]. Также в них показаны возможности применения ИНС для подбора оптимальных курсов лечения и образа жизни пациентов, нивелирующих эти заболевания.

Выводы. Нейросетевые методы медицинской диагностики находят все более широкое применение в диагностировании различных заболеваний. Но в то же время отсутствуют работы, посвященные применению нейросетевого аппарата для моделирования заболеваний, как процессов, развивающихся во времени, что связано с необходимостью учета сложных внутрисистемных связей между возрастом человека и его биомедицинскими показателями.

1.5. Показатели эффективности нейросетевых систем

Как было отмечено в начале главы, основой нейросетевых рекомендательных систем является нейросетевая модель, от качества которой напрямую зависит качество выдаваемых системой рекомендаций. Определим показатели качества, которые будут использоваться для определения эффективности тех или иных методов и средств получения и оптимизации нейросетевых моделей.

1.5.1. Метрики качества нейросетевой модели

Для оценки качества нейросетевой модели часто используются следующие оценки погрешности: средняя абсолютная ошибка (Mean Absolute Error, MAE) и корень среднеквадратичной ошибки (Root Mean Square Error, RMSE).

$$MAE = \frac{1}{N} \sum_{i=1}^N |d_i - y_i|,$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (d_i - y_i)^2},$$

где N – количество наблюдений;

d_i – желаемое значение выхода;

y_i – значение выхода, вычисленное моделью.

Данные формулы оперируют одним выходным параметром. В случае, когда модель имеет несколько выходов, ошибки вычисляются по каждому из них и в зависимости от задачи могут быть рассмотрены по отдельности, в среднем или максимальном значении.

MAE и RMSE схожи тем, что, выражают среднюю ошибку модели в единицах интересующей переменной. Обе метрики могут варьироваться от 0 до ∞ и безразличны к знаку ошибок.

Однако, поскольку отклонения при вычислении RMSE возводятся в квадрат до их усреднения, RMSE придает больший вес более сильным отклонениям, что делает RMSE более полезной, когда большие ошибки особенно не желательны.

Кроме того, RMSE непрерывно дифференцируема, что облегчает выполнение некоторых математических операций.

Для вычисления относительной ошибки применяют нормализованное значение (Normalized Root Mean Square Error, NRMSE) одним из двух способов [72]:

$$NRMSE = \frac{RMSE}{|\max(d) - \min(d)|}, \quad NRMSE = \frac{RMSE}{\bar{d}},$$

где $\max(d)$ – максимальное значение величины d ,

$\min(d)$ – минимальное значение величины d ,

$\bar{d}$ – среднее значение величины d .

Еще одним показателем качества модели может служить коэффициент детерминации, или R -квадрат, вычисляемый следующим образом:

$$R^2 = 1 - \frac{\sum_{i=1}^N (d_i - y_i)^2}{\sum_{i=1}^N (d_i - \bar{d})^2}.$$

Он показывает, насколько лучше модель вычисляет значения величины относительно тривиального варианта $y_i = \bar{d}$ [2]. При оценке регрессионных моделей его значение интерпретируется как соответствие модели данным, и для того, чтобы модель считалась адекватной, коэффициент детерминации должен быть хотя бы не меньше 50 %.

Недостатком R^2 является то, что при увеличении числа параметров его значение возрастает, что, однако, не означает повышение качества модели. Это делает некорректным сравнение качества моделей с разным числом параметров, а также может давать завышенные значения оценки качества на моделях с большим количеством входных параметров.

Поэтому наряду с коэффициентом детерминации применяют его скорректированную версию [2]:

$$R^2_{ADJ} = 1 - (1 - R^2) \frac{N - 1}{N - n - 1},$$

где N – количество наблюдений;

n – количество входных параметров модели.

1.5.2. Метрики качества прогнозирования

Для оценки качества прогнозирования могут применяться описанные выше метрики, но в качестве желаемых и модельных значений берутся значения прогнозируемой величины на H шагов вперед, например, средняя абсолютная ошибка (MAE):

$$MAE = \frac{1}{H} \sum_{h=1}^H |d_h - y_h|,$$

где H – количество шагов прогнозирования;

d_h – желаемое на шаге h ;

y_h – значение выхода, вычисленное моделью для шага h , по входным параметрам на момент $h - 1$.

В работе [59] приведены обзор и сравнение различных метрик качества прогнозирования: корень среднеквадратичной ошибки (Root Mean Square Error, RMSE), средняя абсолютная ошибка в процентах (Mean Absolute Percentage Error, MAPE), медианна абсолютной ошибки в процентах (Median Absolute Percentage Error, MdAPE), среднее геометрическое относительной абсолютной ошибки (Geometric Mean of the Relative Absolute Error, GMRAE), медиана относительной абсолютной ошибки (Median Relative Absolute Error, MdRAE) и процент лучших (Percent Better, PB) – процент прогнозов, для которых оцениваемый метод более точен, чем случайное предсказание. Отмечается высокая популярность RMSE как метрики качества прогнозирования, однако отмеченная выше в данном разделе повышенная чувствительность к большим отклонениям приводится в качестве недостатка данной метрики. Также к недостаткам RMSE относят то, что эта метрика не является безразмерной величиной. К недостаткам MAPE относят ее применимость только к масштабированным величинам, а также и то, что она в большей степени чувствительна к прогнозам, превышающим фактические значения,

чем к прогнозам, которые выдают заниженные значения, т. е. не симметрична. В таблице 1 представлены результаты анализа указанных метрик по таким параметрам, как:

- надежность – оценивалось, насколько схожие значения выдает метрика для одной модели на разных образцах данных;
- конструктивная обоснованность – насколько хорошо метрика оценивает точность экстраполяции;
- невосприимчивость к выбросам – отдельные большие отклонения не должны приводить к значительному увеличению оценки ошибки;
- чувствительность – насколько хорошо метрика реагирует на малые изменения параметров модели;
- применимость при принятии решений – насколько метрика полезна при принятии решений.

Таблица 1 – Сравнение метрик оценки качества прогнозирования

Метрика	Надежность	Обоснованность	Выбросы	Чувствительность	Принятие решений
RMSE	Плохо	Средне	Плохо	Хорошо	Хорошо
PB	Хорошо	Средне	Хорошо	Плохо	Плохо
MAPE	Средне	Хорошо	Плохо	Хорошо	Средне
MdAPE	Средне	Хорошо	Хорошо	Плохо	Средне
GMRAE	Средне	Хорошо	Средне	Хорошо	Плохо
MdRAE	Средне	Хорошо	Хорошо	Плохо	Плохо

На основании данных результатов в указанной работе рекомендуется использование GMRAE, когда задача включает построение модели для набора временных рядов. Для выбора наиболее точной модели рекомендуется MdRAE, когда доступно несколько тестовых последовательностей, и MdAPE в противном случае [59].

В работе [114] приведен список из нескольких десятков метрик оценки качества математических моделей прогнозирования. Помимо метрик, рассмотрен-

ных выше, в нем присутствуют такие метрики, как: средняя ошибка ($\bar{E}$), сглаженная ошибка (Smoothed Error, SE), среднее абсолютное отклонение (Mean Absolute Deviation, MAD), сглаженное среднее абсолютное отклонение (Smoothed Mean Absolute Deviation, SMAD), средняя абсолютная масштабированная ошибка (Mean Absolute Scaled Error, MASE), отслеживание сигнала (Tracking Signal, TS), фильтр спроса (Demand Filter, DF), средневзвешенная ошибка прогноза (Weighted Average Forecasts Error, WAFE), достижение прогноза (Forecast Attainment, FA), средневзвешенная абсолютная ошибка в процентах (Weighted Mean Absolute Percent Error, WMAPE), средневзвешенная абсолютная масштабированная ошибка (Weighted Mean Absolute Scaled Error, WMASE) и многие другие. Из этого списка следующие метрики выделены как рекомендуемые: $\bar{E}$, TS, MASE, DF, FA, WMASE.

1.5.3. Метрики качества медицинских диагностических методов

Стандартные алгоритмы обучения ИНС, например, алгоритм обратного распространения ошибки, обычно минимизируют среднеквадратичную ошибку обучения или другую функцию потерь, в которой ошибки первого и второго рода учитываются в равной степени. В общем случае это является оправданным подходом, однако в некоторых областях, например, в медицинской диагностике, эти два вида ошибок имеют разную важность и смысл: если медицинский диагностический тест не выявит наличие серьезного заболевания – оно разовьется до более тяжелой стадии, где его уже сложно или невозможно вылечить. В противоположном развитии данного сценария все не так страшно – дополнительные исследования или более тщательный анализ результатов покажут, что заболевания нет.

Поэтому для определения качества медицинских методов диагностики используются следующие показатели, которые учитывают различную значимость недопущения ошибок первого и второго родов:

- истинно положительные результаты (TP, true positive) – количество верно диагностированных случаев наличия заболевания;

- истинно отрицательные результаты (TN, true negative) – количество верно диагностированных случаев отсутствия заболевания;
- ложноположительные результаты (FP, false positive) – количество неверно диагностированных случаев наличия заболевания, аналог ошибок первого рода;
- ложноотрицательные результаты (FN, false negative) – количество неверно диагностированных случаев отсутствия заболевания, аналог ошибок второго рода;
- N_p – количество пациентов в выборке, у которых диагностируемое заболевание присутствует;
- N_N – количество пациентов в выборке, у которых диагностируемое заболевание отсутствует.

На основе этих показателей рассчитываются следующие характеристики медицинского диагностического теста [92]:

$$Se = \frac{TP}{N_p} \cdot 100 \ %.$$

Чувствительность (Se, sensitivity) – это процент правильных положительных результатов теста. Показывает, каков будет процент больных, у которых данный метод выявит наличие заболевания, и является противоположной величиной процента ошибок первого рода.

$$Sp = \frac{TN}{N_N} \cdot 100 \ %.$$

Специфичность (Sp, specificity) – это процент правильных отрицательных результатов теста. Показывает, каков будет процент здоровых лиц, у которых данный метод не выявит наличие заболевания, что является противоположной величиной вероятности допущения ошибок второго рода в процентах.

$$PPV = \frac{TP}{TP + FN} \cdot 100 \ %.$$

Прогностичность положительного результата (PPV, positive predictive value) – это процент правильно диагностированных положительных случаев среди всех положительных результатов теста. Показывает, насколько велика вероятность наличия заболевания при положительных результатах наличия заболевания, полученных при помощи данного метода.

$$NPV = \frac{TN}{TN + FP} \cdot 100 \ %.$$

Прогностичность отрицательного результата (NPV, negative predictive value) – это процент правильно диагностированных отрицательных случаев среди всех отрицательных результатов теста. Показывает, насколько велика вероятность отсутствия заболевания при отрицательных результатах наличия заболевания, полученных при помощи данного метода.

В некоторых работах эти характеристики рассчитываются как итоговый показатель качества диагностической ИНС [19; 53; 64; 75; 102]. Ввиду упомянутой выше равнозначности ошибок первого и второго рода при обучении нейросетевых моделей показатели специфичности и чувствительности находятся примерно на одном уровне, как, например, 96 и 97 % соответственно в работе [71].

В работе [68] для решения данной проблемы обучались две сети, одна на больных с низкой вероятностью заболевания, вторая на примерах с высокой вероятностью заболевания. В результате при диагностировании анализировались результаты, выдаваемые обеими сетями одновременно, что позволяло получить две отдельные нейросетевые модели с высокой специфичностью и чувствительностью.

В публикации автора настоящей диссертационной работы [43] предлагается метод, основанный на применении параметризованной функции потерь при обучении нейронной сети, что позволяет варьировать уровень чувствительности и специфичности получаемой нейросетевой модели.

Выводы: рассмотрены наиболее общие и распространенные методы анализа качества математических моделей, в том числе в задачах прогнозирования. Показано, что для некоторых областей, например, таких как медицинская диагно-

стика, необходимо применять дополнительные показатели оценки качества моделей, такие как специфичность и чувствительность. Делается вывод об актуальности создания инструмента подстройки этих характеристик нейросетевой модели, а также приводятся некоторые пути решения данной проблемы.

ВЫВОДЫ ПО ГЛАВЕ

Клинические и лабораторные методы диагностики обнаруживают заболевание тогда, когда патология уже серьезно развилась. Кроме того, наиболее точные методы медицинской диагностики финансово затратны, достаточно сложны, а также могут быть инвазивны, их применение вызывает дискомфорт пациента, а в крайних случаях они могут приводить к различным осложнениям и даже к угрозе жизни. Эти факторы делают затруднительным проведение профилактической и ранней диагностики заболеваний ССС, что является ключом к понижению смертности от этих заболеваний.

Одним из наиболее перспективных направлений, которое позволяет проводить превентивную диагностику заболеваний, является применение нейросетевого моделирования в медицинской диагностике. Однако из обзора и анализа, выполненного в главе, следует, что применение нейросетевых методов осложняется не решенной до конца проблемой обнаружения выбросов и оценкой информативности входных параметров – стандартные методы имеют ограничения на структуру данных, требования к их закону распределения или же для применения этих методов требуется построение отдельных регрессионных моделей. Кроме того, существует необходимость настройки чувствительности и специфичности нейросетевых моделей, предназначенных для проведения медицинской диагностики.

Также в главе рассмотрены проблемы прогнозирования и сценарного моделирования процессов, протекающих в объектах со сложными внутрисистемными корреляционными связями.

ГЛАВА 2. МЕТОДЫ ПОВЫШЕНИЯ ЭФФЕКТИВНОСТИ НЕЙРОСЕТЕВЫХ СИСТЕМ

Целью данной главы является исследование статистических и нейросетевых методов повышения качества обучения ИНС. Задачами исследования данной главы являются:

- исследование возможности обнаружения аномальных наблюдений с использованием ИНС;
- исследование возможности вычисления информативности входных параметров посредством анализа нейросетевой модели;
- исследование возможности настройки специфичности и чувствительности нейросетевых моделей;
- исследование возможности применения нейросетевых моделей для прогнозирования процессов со сложными внутренними связями входных параметров (на примере прогнозирования возникновения и развития заболеваний).

2.1. Метод выявления аномальных наблюдений с использованием ИНС

В первой главе было показано, что существующие методы обнаружения и игнорирования аномальных наблюдений имеют множество ограничений, затрудняющих их применение в контексте анализа обучающей выборки для ИНС. Для применения регрессионных методов выявления аномальных наблюдений требуется предварительное построение качественной регрессионной модели, которая, однако, может оказаться не применима для предметной области, в которой предполагается использование методологии нейросетевого моделирования, ввиду высокой сложности моделируемого процесса. Робастные методы, кроме того, не дают информации о том, какие наблюдения являются аномальными, хотя анализ этих наблюдений может дать некоторую дополнительную информацию.

Предлагаемый в работе метод заключается в поочередном исключении примеров из обучающего множества и последующей оценке изменения погреш-

ностей ИНС, обученной на этих обучающих выборках, при прочих равных условиях [37; 40; 45]. Таким образом данный метод является модификацией метода анализа удаленных остатков регрессионной модели, в котором анализируется влияние удаления i -й точки на предсказание значения этой точки. Блок-схема алгоритма реализации данного метода представлена на рисунке 1.




Рисунок 1 – Блок-схема алгоритма обнаружения аномальных наблюдений с использованием поочередного исключения примеров

На базе вышеприведенного общего алгоритма поочередного исключения примеров возможно разработать ряд алгоритмов для выявления аномальных наблюдений, которые отличаются последним шагом, а именно процедурой анализа влияния удаления каждого из примеров на показатели нейросетевой модели, по-

лученные в результате работы алгоритма. Ниже приведены два таких алгоритма, которые назовем: «Анализ ошибки обучения» (алгоритм 1) и «Анализ ошибки удаленного примера» (алгоритм 2).

Алгоритм 1 основывается на том факте, что при отсутствии аномального наблюдения в обучающем множестве процесс обучения будет иметь лучшую сходимость, и средняя среднеквадратичная ошибка обучения, вычисляемая на множестве с исключенным примером L_p , после завершения процесса обучения по формуле

$$E(L_p) = \frac{1}{Q_L J} \sum_{q=1}^{Q_L} \sum_{j=1}^J (y_{qj} - d_{qj})^2 \quad (1)$$

будет меньше, по сравнению с тем же показателем на множестве, в котором этот пример присутствует.

Здесь L_p – обучающее множество с исключенным p -м примером;

y_{qj} – значение j -го выходного сигнала ИНС для q -го обучающего примера;

d_{qj} – желаемое значение j -го выходного сигнала для q -го обучающего примера;

J – число нейронов в выходном слое;

Q_L – количество примеров в обучающем множестве.

Следует учитывать, что при этом все выходные параметры должны быть нормированы. Для нейросетевой модели с одним выходом формула может быть упрощена:

$$E(L_p) = \frac{1}{Q_L} \sum_{q=1}^{Q_L} (y_q - d_q)^2,$$

где y_q – значение выходного сигнала ИНС для q -го обучающего примера;

d_q – желаемое значение выходного сигнала для q -го обучающего примера.

Вместо средней среднеквадратичной ошибки возможно использование других метрик качества обучения нейросетевой модели, рекомендуется использова-

ние той же метрики, которая используется для оценки качества итоговой нейросетевой модели.

Таким образом, шаг анализа характеристик алгоритма 1 сводится к выявлению примера, при исключении которого ошибка обучения сети значительно снижается. В зависимости от задачи данный шаг возможно выполнить визуально, рассмотрев гистограмму ошибок обучения, статистически или другими математическими методами. Принимая во внимание структуру анализируемого множества ошибок – одномерная последовательность чисел с возможным присутствием одного или нескольких аномальных наблюдений, представляется возможным использование методов обнаружения аномалий, описанных в разделе 1.1.1 данной работы.

К недостаткам алгоритма 1 можно отнести то, что он дает хорошие результаты только на небольших множествах, в которых встречается не более одного аномального наблюдения. Это связано с тем, что при увеличении размера множества возрастает вероятность присутствия в нем нескольких равноправных аномальных наблюдений, и при исключении одного из них среднеквадратичная ошибка на всем множестве не опустится в связи с наличием дополнительных аномальных наблюдений.

Еще одним недостатком можно считать большой объем вычислений, необходимых для выполнения алгоритма, которые обусловлены шагом повторного обучения ИНС для каждого примера в обучающем множестве.

К ограничениям также стоит отнести требование к отсутствию гиперразмерности в структуре нейронной сети, что выражено в чрезмерно большом количестве нейронов скрытого слоя. В случае наличия гиперразмерности ошибка обучения будет неизменно низкой, так как моделируемая нейросетью функция сможет пройти через все точки обучающего множества [48].

Алгоритм 2 призван решить часть проблем, присущих алгоритму 1. Идея этого алгоритма основана на том факте, что если p -й пример является аномаль-

ным наблюдением, то после обучения сети на множестве, не содержащем этого примера, среднеквадратичная ошибка e_p на этом примере будет больше других.

$$e_p = \frac{1}{J} \sum_{j=1}^J (y_{pj} - d_{pj})^2. \quad (2)$$

Здесь y_{pj} – значение выходного сигнала ИНС для p -го обучающего примера;

d_{pj} – желаемое значение выходного сигнала для p -го обучающего примера.

Если в обучающей выборке помимо примера с номером p имеются и другие аномальные наблюдения, то, несмотря на это, ошибка (2) для p -го аномального наблюдения по-прежнему будет больше ошибок примеров без аномалий. Тестирование на синтетических примерах показало, что данный алгоритм имеет большую эффективность для выборок, содержащих более ста элементов.

К недостаткам алгоритма 2 необходимо отнести также большие вычислительные затраты, необходимые на многократное переобучение нейросетевой модели, а также упомянутое выше требование к отсутствию гиперразмерности. Для снижения затрат вычислительных ресурсов возможно применение алгоритма в пакетном режиме, исключая и тестируя на каждом шаге по n примеров одновременно, что в n раз сократит количество необходимых циклов обучения.

Следует отметить, что данный метод представляет собой лишь базовый механизм, позволяющий выявлять потенциально аномальные наблюдения. Так, в работе [29] данный алгоритм включен как один из шагов более сложного алгоритма, включающего в себя процедуру подбора оптимальной структуры сети и экспертную оценку каждого найденного аномального наблюдения.

2.2. Метод вычисления информативности входных параметров посредством анализа нейросетевой модели

Наличие данных об относительной информативности каждого из входных параметров позволяет исключить незначимые и малозначимые параметры и тем самым упростить структуру ИНС и объем обучающей выборки, а следовательно,

и объем необходимых вычислений для ее обучения. Кроме того, за счет сокращенного набора входных параметров уменьшаются эксплуатационные затраты при использовании систем на основе ИНС за счет уменьшения количества вводимых данных для выполнения расчетов и меньших вычислительных затрат, необходимых на выполнение каждого проведенного расчета.

В первой главе было охарактеризовано множество методов вычисления информативности входных параметров, в том числе основанных на анализе нейросетевой модели или ее поведении при внесении различных возмущений в обучающее множество [98], а также описано развитие одного из таких методов в лице HPR [88]. Применение подобных методов выглядит целесообразным при анализе данных, предназначенных для нейросетевого моделирования. Однако, как показали эксперименты, применение данных методов на выборках со сложными внутрисистемными связями имеет большую погрешность, которая выражается в непропорциональном изменении погрешности нейросетевой модели по отношению к вычисленной значимости удаленных параметров. Метод HPR, кроме того, предназначен для нейросетевых моделей с непрерывными значениями параметров и плохо справляется с наборами данных, в которых преобладают параметры с дискретными значениями. К таким задачам относится задача медицинской диагностики на основе данных объективного обследования, в которой преобладают категориальные входные параметры.

В связи с этим предлагается метод определения информативности входных параметров, который является модификацией метода HPR, приведенного в разделе 1.2 данной диссертационной работы, и отличается от него методом рандомизации входных параметров.

Идея предлагаемого метода основывается на том факте, что при замене значений входного параметра, имеющего высокую информативность для построения модели, на псевдослучайные числа качество ИНС падает пропорционально той доле информации, которую несет этот параметр.

Блок-схема алгоритма, реализующего идею предлагаемого метода, приведена на рисунке 2.




Рисунок 2 – Блок-схема алгоритма определения информативности входных параметров

На первом шаге предлагаемого алгоритма ИНС обучается на исходном множестве L обучающих примеров. В результате обучения будет получена нейросетевая модель H . На втором шаге вычисляется средняя среднеквадратичная ошибка модели на тестовом множестве по формуле (1) или с использованием какой-либо другой метрики качества обучения нейросетевой модели. Рекомендуется использование той же метрики, которая используется для оценки качества итоговой нейросетевой модели.

Данное значение ошибки используется в качестве базового для сравнения с ошибками, полученными при дальнейших изменениях обучающего множества. На втором шаге алгоритма выполняется цикл по всем параметрам исходного обучающего множества с целью определения меры его влияния на моделируемый процесс. Предположим, что параметр x_i несет большую информативность для модели, т.е. какая-либо значащая часть вариации объясняется этим параметром, тогда отсутствие этого параметра или искусственная рандомизация его значений во входных векторах повлечет утерю этой доли информативности и увеличение необъясненной вариации, т.е. ошибки, вычисленной на тестовом (E_T) множестве.

В методе NIPR для рандомизации используется замена значений входного параметра на равномерно распределенные случайные величины из диапазона $[0.1..0.9]$.

В данной диссертационной работе для рандомизации параметра x_i предлагается использовать как можно менее коррелированную случайную величину, желательно имеющую то же или похожее распределение $x_i = \tilde{X}$. Чтобы получить такую случайную величину, было предложено использовать значения параметра x_i , перемешанные в случайном порядке.

Для оценки влияния рандомизации на качество нейросетевой модели вычисляется абсолютное изменение ошибки для i -го параметра $\Delta E_i = E_i - E_L$, а также относительное изменение $S_i = \frac{\Delta E_i}{\sum \Delta E}$. Полученные величины S_i интерпретируются как относительные значения информативности i -го входного параметра относительно остальных входных параметров.

К преимуществам предлагаемого метода по сравнению с другими методами вычисления информативности относятся: более точная оценка степени влияния входных параметров для нелинейных моделей и повышение точности оценки информативности параметров в условиях дискретных значений входных параметров. Повышение точности достигается за счет того, что для расчетов информативности не используется изменение структуры нейронной сети, при этом полностью ниве-

лируется влияние исключаемого входного параметра путем замены его значений на некоррелированные величины с сохранением параметров распределения.

2.3. Метод настройки специфичности и чувствительности нейросетевых моделей

Как было показано в разделе 1.5.3 диссертационной работы, стандартные алгоритмы обучения ИНС обычно минимизируют среднеквадратичную ошибку обучения или другие метрики, в которых ошибки первого и второго рода учитываются в равной степени. В общем случае это является оправданным подходом, однако в медицинской диагностике эти два вида ошибок имеют разные важность и смысл. Вероятность недопущения ошибок первого рода определяется чувствительностью (доля истинно положительных результатов среди всех проведенных исследований), а вероятность недопущения ошибок второго рода – специфичностью (доля истинно отрицательных результатов). В теории вероятностей в таких случаях применяют критерий Неймана – Пирсона, в соответствии с которым вероятность ошибки второго рода должна быть минимальной, а вероятность ошибки первого рода не должна превосходить некоторой заданной величины [24]. Существующие методы решения данной проблемы применимы только к бинарным значениям выхода: «болен/здоров» и используют специальным образом спроектированные сети и обучающие выборки [68].

Предлагаемый в диссертационной работе метод позволяет выполнять настройку чувствительности и специфичности нейросетевой модели путем параметризации функции потерь, без необходимости создания специальных моделей и выборок [40; 43], кроме того, метод адаптирован для случая, когда выходной параметр является интервальной величиной.

Определим функцию нелинейного масштабирования θ :

$$\theta(x, a, b) = \begin{cases} a \cdot x, & x \geq 0, \\ b \cdot x, & x < 0, \end{cases}$$

где a, b – некоторые весовые коэффициенты.

Для удобства записи также определим функцию симметричного нелинейного масштабирования $\theta'(x, a) = \theta(x, a, a^{-1})$.

Пусть $E = \frac{\sum_{j=1}^J (d_j - y_j)^2}{J}$ – среднеквадратичная ошибка, J – размерность выходного вектора, d_j и y_j – желаемое и действительное значение соответственно.

Применив функцию θ для масштабирования исходных отклонений $d_j - y_j$, при вычислении среднеквадратичной ошибки получим:

$$E(\alpha, \beta) = \frac{\sum_{j=1}^J (\theta(d_j - y_j, \alpha, \beta))^2}{J}. \quad (3)$$

При $\alpha = \beta = 1$ это выражение эквивалентно среднеквадратичной ошибке $E(1, 1) = E$.

Использование конструкции (3) в алгоритмах обучения ИНС в качестве функции потерь и изменение значений параметров α и β приводят к смещению приоритета процесса обучения к ошибке первого или второго рода соответственно.

Также возможно использование симметричного варианта:

$$E(\alpha) = \frac{\sum_{j=1}^J (\theta(d_j - y_j, \alpha, \alpha^{-1}))^2}{J}. \quad (4)$$

Рассмотрим применение данного метода в задаче медицинской диагностики. Как было показано в разделе 1.5.3, специфичность и чувствительность нейросетевых диагностических моделей обычно вычисляются как финальная характеристика модели. Однако в зависимости от тяжести заболевания, методики тестирования или социально-экономических требований необходимо получить диагностический метод или с некоторым минимально допустимым уровнем чувствительности, или же специфичности. Применение описанного выше метода настройки алгоритма обучения позволяет управлять соотношением специфичности

и чувствительности и задавать критерии оптимизации модели на основе этих характеристик.

Для примера рассмотрим алгоритм получения нейросетевой модели с минимальным заданным уровнем специфичности при максимально возможной чувствительности:

- 1) модифицировать процедуру обучения таким образом, чтобы в качестве функции потерь использовалась функция (4);
- 2) создать нейросетевую модель с минимальным уровнем погрешности при $\alpha = 1$ – запомнить настройки нейросетевой структуры и алгоритма обучения для использования в последующих шагах;
- 3) варьируя значение параметра α в некотором диапазоне относительно 1, на каждом шаге произвести обучение сети с выбранными на предыдущем шаге параметрами, и, вычисляя специфичность и чувствительность полученной нейросетевой модели, выбрать нейросеть с необходимыми характеристиками.

При этом 3-й шаг алгоритма может быть заменен одним из методов оптимизации, принимая в качестве целевой функции чувствительность обученной нейросетевой модели в зависимости от параметра α , в качестве независимой переменной – значение параметра α , в качестве ограничений – минимальный заданный уровень специфичности, а в качестве критерия оптимизации – максимум чувствительности. Также возможно подобрать параметр α посредством анализа ROC (*receiver operating characteristic*)-кривой.

Для случая нейросетевой модели с минимальным заданным уровнем чувствительности при максимально возможной специфичности процедура аналогична, за исключением того, что указанные характеристики меняются местами.

2.4. Метод экспертной коррекции при прогнозировании с использованием ИНС

Сценарное нейросетевое прогнозирование методом вариации входных параметров имеет определенные проблемы, так как входные параметры моделируе-

мого объекта имеют между собой сложные корреляционные взаимозависимости, и при изменении одного из входных параметров другие параметры тоже должны быть изменены согласно этим зависимостям. Например, с возрастом у пациента появляются новые симптомы, появляются изменения на электрокардиограмме, изменяются результаты эхокардиографии, биохимических анализов и т.д. Но такие зависимости, как правило, не известны, и поэтому учесть их влияние на нейросетевые прогнозы представляется весьма проблематичным.

Первая попытка преодолеть указанную проблему описана в публикации автора диссертационной работы совместно с соавторами [74], где предлагалось дополнить результаты нейросетевого моделирования экспертными знаниями. В качестве источника экспертных знаний была использована европейская шкала «SCORE» [79], предназначенная для расчета риска смерти от сердечно-сосудистого заболевания в зависимости от возраста, пола и привычки курения. Анализ усредненных данных этой шкалы показал, что за пятилетний период от 50 до 55 лет риск смерти по шкале «SCORE» для среднестатистического пациента увеличивается приблизительно в $\lambda \approx 1,6$ раза, за десятилетний срок от 50 до 60 лет – в 2,7 раза, за пятнадцатилетний срок от 50 до 65 лет – в 4,3 раза. Данная закономерность изображена на рисунке 3.




Рисунок 3 – Зависимость усредненных рисков по шкале «SCORE» от возраста

При этом была введена гипотеза о том, что между рисками по шкале «SCORE» и степенью развития заболевания, рассчитанным с помощью нейросетевой модели, должна быть прямо пропорциональная зависимость. Именно это экспертное знание было использовано в методе, который получил название *метод экспертной коррекции*.

Рассмотрим алгоритм применения данного метода: пусть для некоторого пациента нейросетевая математическая модель оценила степень развития какого-либо сердечно-сосудистого заболевания как величину y_0 , и требуется выполнить прогноз этой величины на пять лет вперед.

Увеличив на 5 лет входной параметр нейросетевой модели x_0 , кодирующий «возраст пациента» и выполняя расчет с использованием нейросетевой модели, получаем новое прогнозное значение степени развития заболевания, которое обозначим через y . Тогда $\mu = \frac{y}{y_0}$ – коэффициент, показывающий, во сколько раз увеличилась степень развития сердечно-сосудистого заболевания у рассматриваемого пациента за прогнозируемый пятилетний период.

Заметим, что данный прогноз выполнен с помощью нейросетевой модели при варьировании одного только возраста пациента. При этом все остальные параметры модели сохранены неизменными. Поэтому при таком прогнозировании не учитывается возможность появления у пациента с возрастом других симптомов и заболеваний.

Для того чтобы учесть указанные возрастные изменения, предлагается выполнить корректировку прогнозного значения с помощью формулы

$$z = y \frac{\lambda}{\mu}, \quad (5)$$

где z – скорректированное прогнозное значение степени развития заболевания рассматриваемого пациента, рассчитанное с помощью коэффициента коррекции λ , который при прогнозировании на пять лет равняется $\lambda = 1,6$; на десять лет $\lambda = 2,7$; на пятнадцать лет $\lambda = 4,3$. При необходимости вычисления коэффициен-

та коррекции λ на промежуток времени, не кратный пятилетнему периоду, можно выполнить линейную интерполяцию значения между двумя ближайшими значениями для пятилетнего периода.

2.4.1. Построение рекомендаций

Данный метод применим для корректировки сценарного прогнозирования влияния изменения образа и условий жизни пациента на его прогнозируемую степень развития заболевания, т.е. на величину z . Варьируя какой-либо входной параметр модели x_1 , например кодирующий «вес пациента», и рассчитывая с помощью нейросетевой модели соответствующее этой вариации значение степени развития заболевания y_1 , необходимо скорректировать его по формуле (5): $z_1 = y_1 \frac{\lambda}{\mu}$.

Далее варьируется какой-либо другой входной параметр нейросетевой модели x_2 , например «курение», и вычисляется соответствующее этой вариации значение степени развития заболевания y_2 , которое затем также корректируется по формуле (5), и так далее.

В результате формируется оценка состояния здоровья пациента для следующих сценариев:

y_0 – на текущий день;

z – на пять лет вперед при условии неизменного образа и условий жизни пациента;

z_1 – на пять лет вперед при варьировании входного параметра x_1 ;

z_2 – на пять лет вперед при варьировании входного параметра x_2 ;

и т.д.

Недостаток метода *экспертной коррекции* состоит в том, что используются весьма обобщенные экспертные знания о риске наступления смерти от любого из заболеваний ССС. Таким образом, прогнозирование степени развития заболевания, выполненное с использованием данного метода, лишь частично учитывает индивидуальные особенности человека на первом шаге – нейросетевом прогнозе.

Имеется возможность получить более специфичные коэффициенты корректировки λ , учитывая присутствующие в шкале SCORE данные по признакам «пол» и «курение», однако эти коэффициенты также не учитывают остальные особенности конкретного человека. Кроме того, возможно использовать более специфичную статистическую информацию при ее наличии или предварительно собрать такую информацию в зависимости от потребностей проекта, в котором предполагается использование данного метода.

2.5. Метод скользящего окна при прогнозировании с использованием ИНС

Для устранения недостатков предыдущего метода прогнозирования в диссертационной работе предлагается использовать идею объединения метода нейросетевого моделирования и метода скользящего окна, который обычно применяется при прогнозировании временных рядов. В работе [58] на примере прогнозирования скорости ветра показано, что применение данного метода в совокупности с методом нейросетевого моделирования позволяет с высокой точностью моделировать сложные нелинейные процессы во времени. Для применения данного метода необходимо иметь множество наблюдений за поведением объекта во времени. В упомянутой выше работе использовались 8760 измерений скорости ветра с интервалом в час за период в один год. В качестве входных параметров нейросетевой модели использовались измерения за фиксированный промежуток времени, а в качестве выходного – измерение за следующий временной интервал.

Однако в условиях ограниченных объемов выборок при прогнозировании поведения множества объектов со сложными корреляционными связями данный способ не применим. В случае медицинской диагностики периодическими наблюдениями являются данные о повторных посещениях больным лечащего врача и выставленный спустя некоторое время диагноз. Наличие таких данных способствует рекомендации повторного посещения врача с некоторым периодом для наблюдения за развитием заболевания. Несмотря на это, по каждому конкретному человеку таких наблюдений имеется от нескольких штук до десятков. Кроме того,

развитие заболевания зависит от многих внутренних и внешних факторов, а не только от течения времени.

В публикациях [40; 41] автором данной работы был предложен метод, объединяющий метод нейросетевого моделирования и метод окна, позволяющий учитывать индивидуальные особенности человека при прогнозировании развития заболеваний.

Пусть имеется история наблюдения за одним пациентом на протяжении T временных интервалов. Каждое такое наблюдение представляет собой пару векторов $(\bar{x}_t, \bar{d}_t)$, где $\bar{x}_t$ – данные объективного обследования, выявленные симптомы, данные об образе жизни и другие данные о пациенте на момент времени t ; $\bar{d}_t$ – выставленный врачом диагноз на момент времени t ; $t \in [1, T]$.

Для формирования из них примеров обучающего множества, пригодных для применения предлагаемого метода, необходимо взять в качестве входных параметров значения показателей пациента на текущий момент времени $\bar{x}_t$, а в качестве выходных значений – диагноз за следующий момент времени $\bar{d}_{t+1}$. Таким образом, будет получено следующее множество из $T-1$ элементов вида: $[(\bar{x}_1, \bar{d}_2), (\bar{x}_2, \bar{d}_3), \dots, (\bar{x}_{t-1}, \bar{d}_t), \dots, (\bar{x}_{T-1}, \bar{d}_T)]$ на основе истории одного пациента. Повторив эту операцию для всех имеющихся данных, получим множество примеров, которое используется для обучения и тестирования нейросетевой модели, предназначенной для прогнозирования развития заболевания на один временной интервал вперед. При этом стоит учесть, что длина интервала – фиксированная величина для всей выборки, и те наблюдения, которые значительно отклоняются по времени от этого интервала, не должны рассматриваться.

К недостаткам данного метода необходимо отнести требование наличия в обучающей выборке нескольких наблюдений за одним пациентом, требование к наличию временных меток у наблюдений, а также требование к интервалам между наблюдениями, что делает сбор данных для обучающего множества более сложной задачей.

2.5.1. Построение рекомендаций

При наличии модели, способной успешно прогнозировать развитие заболевания, становится возможным разработать модель для подбора рекомендаций. В разделе 2.4.1 для этого применялся метод вариации отдельных параметров, на которые возможно оказать активное влияние, и дальнейшее использование нейросетевой модели и экспертной коррекции для проверки того, как изменится диагноз по сравнению с первоначальным. Однако он не учитывает особенностей динамики течения заболевания для конкретного пациента, а также подвержен тем же недостаткам, которые перечислены в заключение раздела 2.4.1.

Для преодоления данных недостатков предлагается расширить нейросетевую модель из предыдущего раздела. В качестве входных параметров нейросетевой модели предлагается использовать:

$\bar{x}_t$ – значения всех текущих показателей пациента на момент времени t ;

$\bar{d}_t$ – значения фактических диагнозов на момент времени t ;

$\bar{x}'_{t+1}$ – показатели, на которые возможно оказать активное влияние на момент времени $t + 1$;

$\bar{d}_{t+1}$ – выставленный врачом диагноз на момент времени $t + 1$.

Таким образом, будет получено следующее множество из $T - 1$ элементов вида: $\left[(\bar{x}_1 \bar{d}_1 \bar{x}'_2, \bar{d}_2), (\bar{x}_2 \bar{d}_2 \bar{x}'_3, \bar{d}_3), \dots, (\bar{x}_{t-1} \bar{d}_{t-1} \bar{x}'_t, \bar{d}_t), \dots, (\bar{x}_{T-1} \bar{d}_{T-1} \bar{x}'_T, \bar{d}_T) \right]$ на основе истории одного пациента. Повторив эту операцию для всех данных, получим множество примеров, которые будут использоваться для обучения и тестирования нейросетевой модели, предназначенной для получения рекомендаций. По сравнению с предыдущей моделью на вход были добавлены значения фактических диагнозов за тот же период $\bar{d}_t$, это позволило учесть в модели текущее состояние пациента, так как от него зависит развитие заболевания и, соответственно, диагноз. Также от текущего состояния зависит то, какой эффект окажут на пациента те или иные рекомендации или изменение образа жизни. Кроме того, в модель добавлены входы $\bar{x}'_{t+1}$, задающие те рекомендации, которые были выданы пациенту и вследствие которых изменились его диагнозы $\bar{d}_{t+1}$.

Таким образом, нейросетевая модель, обученная на данном множестве, учитывает изначальное состояние пациента, включая диагнозы, выставленные на данный момент, предполагаемое лечение и изменение образа жизни, при постановке диагноза на следующий временной интервал. Процедура построения рекомендаций с использованием данной нейросетевой модели может быть описана следующим образом:

1. Ввести и зафиксировать текущие показатели пациента и характеристики его образа жизни $\bar{x}_t$ на текущий момент времени t ;
2. Ввести и зафиксировать диагнозы $\bar{d}_t$ на текущий момент времени t ;
3. Ввести некоторые рекомендации по образу жизни и лечению $\bar{x}'_{t+1}$;
4. Подать введенные значения на соответствующие входы нейросетевой модели;
5. Получить на выходе нейросетевой модели прогноз по диагнозам на следующий временной промежуток $\bar{y}_{t+1}$;
6. Повторить шаги 3–5 перебирая все возможные комбинации рекомендаций;
7. Выбрать рекомендации с наилучшим предполагаемым диагнозом $\bar{y}_{t+1}$.

В случае, если вектор рекомендаций $\bar{x}'_{t+1}$ имеет большую размерность или большое количество вещественных (недискретных) параметров с широким возможным диапазоном значений, полный перебор всех возможных значений может требовать больших вычислительных ресурсов. В таком случае 6-й шаг алгоритма может быть заменен одним из методов оптимизации, принимая в качестве целевой функции прогноз по диагнозам $\bar{y}_{t+1}$, выдаваемый нейросетевой моделью, в качестве независимой переменной – вектор рекомендаций $\bar{x}'_{t+1}$, в качестве ограничений – фиксированные значения набора параметров, заданных векторами $\bar{x}_t$ и $\bar{d}_t$, а в качестве критерия оптимизации – минимум степени развития заболевания.

ВЫВОДЫ ПО ГЛАВЕ

В главе предложены следующие методы повышения эффективности нейросетевых систем:

– *метод выявления аномальных наблюдений с использованием ИНС*, отличающийся тем, что вместо регрессионных моделей используются нейросетевые. Данный метод позволяет с высокой степенью точности обнаруживать примеры, выделяющиеся из общей закономерности и вносящие погрешность в процесс обучения. Исключение или исправление подобных наблюдений позволяет повысить скорость обучения нейросетевой модели, а также точность полученной модели;

– *метод вычисления информативности входных параметров*, отличающийся способом вариации входных параметров, который позволяет вычислять относительную информативность входных параметров в условиях сложных нелинейных закономерностей и присутствия дискретных переменных во входных параметрах. Исключение незначимых и малозначимых параметров из обучающей выборки и нейросетевой модели позволяет уменьшить объем обучающей выборки, уменьшить количество весовых коэффициентов нейросетевой модели, повысить скорость обучения ИНС, а также способствует более эффективному применению полученной нейросетевой модели за счет уменьшения количества необходимых для вычисления входных данных;

– *метод настройки чувствительности алгоритмов обучения ИНС к ошибкам первого и второго рода*, позволяющий определить критерии обучения ИНС с учетом требований к соответствующим характеристикам нейросетевой модели, что, в свою очередь, дает возможность получать нейросетевые модели, более эффективно решающие задачи, в которых необходимо снизить уровень ошибок первого или второго рода соответственно.

Предложено несколько методов повышения точности прогнозирования процессов со сложными внутренними корреляционными связями, в частности, для прогнозирования развития заболеваний ССС человека во времени.

Первый метод использует экспертные знания для коррекции прогноза, полученного с помощью нейросетевой модели путем увеличения входного параметра, кодирующего время. Данный метод рассмотрен для случая прогнозирования развития заболеваний ССС человека во времени. Прогноз, сделанный при помощи нейросетевой модели путем увеличения значения входного параметра, кодирующего возраст пациента, затем корректируется при помощи экспертных знаний, полученных на основании шкалы «SCORE».

Второй метод основан на непосредственном анализе показателей конкретного человека, влияющих на ход развития заболевания, при помощи нейросетевой модели. Данный метод позволяет более точно учитывать индивидуальные особенности объекта при прогнозировании его характеристик во времени.

Применение предложенных методов позволяет повысить эффективность различных аспектов построения и применения нейросетевых систем.

ГЛАВА 3. ПРОЕКТИРОВАНИЕ И РАЗРАБОТКА НЕЙРОСЕТЕВОЙ РЕКОМЕНДАТЕЛЬНОЙ СИСТЕМЫ

3.1. Проектирование системы

Проектирование программной системы заключается в определении требований к системе и архитектуры разрабатываемой системы.

3.1.1. Анализ требований

Начальным этапом проектирования программной системы являются сбор и анализ требований. Требования разделяются по уровням. Уровни требований связаны, с одной стороны, с уровнем абстракции системы, с другой – бизнес-процессами [11]. Требования к программному обеспечению разделяют на три уровня – бизнес-требования, требования пользователей системы и функциональные требования.

Бизнес-требования описывают высокоуровневые цели разработки системы. Целью разработки нейросетевой рекомендательной системы, предназначенной для диагностики, прогнозирования и построения рекомендаций по лечению заболеваний ССС человека, является повышение качества оказания медицинских услуг в указанной области. Повышение качества обеспечивается за счет следующих возможностей системы:

- постановка более точных диагнозов;
- уменьшение количества и уровня инвазивности, необходимых для постановки диагноза, анализов;
- прогнозирование возникновения или развития заболеваний;
- построение персонализированных рекомендаций, учитывающих персональные особенности конкретного пациента.

Требования пользователей – это те возможности, которые система должна предоставлять пользователям для достижения основной цели. Определим пользователей системы и пользовательские требования.

Основными пользователями системы являются врачи, однако в упрощенном виде система может быть использована человеком без специального медицинского образования для предварительной самодиагностики.

Требования пользователей с ролью «врач»:

- возможность получения вероятностей наличия заболеваний, по данным объективного обследования пациента;
- возможность прогнозирования возникновения и развития заболеваний;
- возможность построения рекомендации для профилактики и лечения заболеваний.

Для функционирования нейросетевой рекомендательной системы требуются нейросетевые модели, соответствующие данной предметной области. Обучением и тестированием нейросетевых моделей занимается эксперт по нейросетевому моделированию (далее – «эксперт»). Для получения нейросетевых моделей необходимо выполнение следующего требования: получение качественной нейросетевой модели в формате, пригодном для использования в диагностической части системы.

Администрированием системы будут заниматься пользователи с выделенной ролью «администратор». Требование для роли «администратор» – возможность настраивать параметры системы.

Отдельно выделена роль «оператор ввода наблюдений», которая предназначена для ввода наблюдений в систему. Для этой роли выделены следующие требования: возможность ввода наблюдений в систему и их редактирование.

Функциональные требования определяют функциональность программной системы, которую должны реализовать разработчики, чтобы пользователи смогли выполнять свои задачи. Определим основные функциональные требования разрабатываемой системы:

- сбор и подготовка обучающих и тестирующих выборок;
- обучение нейросетевых диагностических моделей;

- ввод данных, на основании которых будут предоставляться предположения системы по наличию заболеваний;
- вычисление вероятностей наличия заболеваний и построение рекомендаций с использованием нейросетевых моделей;
- ведение базы учетных данных пользователей;
- авторизация и аутентификация пользователей;
- разделение полномочий пользователей в соответствии с ролями.

Хранение персональных данных в системе не предусмотрено.

Следующим этапом разработки информационной системы является проектирование.

В процессе проектирования системы создается системная спецификация, в которой описываются функции, характеристики программной системы, ограничения разработки, входная и выходная информация [1].

Унифицированный язык моделирования (UML) – это семейство графических нотаций, в основе которого лежит единая метамодель. Он помогает в описании и проектировании программных систем, особенно систем, построенных с использованием объектно-ориентированных (ОО) технологий. Основная причина их появления состоит в том, что языки программирования не обеспечивают нужный уровень абстракции, способный облегчить процесс проектирования [32].

3.1.2. Определение прецедентов

Прецеденты – это технология определения функциональных требований к системе. Цель прецедентов заключается в описании типичных взаимодействий между пользователями системы и самой системой и предоставлении описания процесса ее функционирования. В терминах прецедента пользователи называются актерами. Актер (actor) представляет собой некую роль, которую пользователь играет по отношению к системе, а последовательность шагов, описывающих взаимодействие пользователя и системы, – сценарий (scenario) [32].

На первом этапе построения диаграммы прецедентов необходимо определить актеров и их цели использования системы. При составлении требований к системе уже были определены роли пользователей, сопоставим с ними соответствующих актеров:

1. Врач – использует систему для повышения точности выставляемых диагнозов, прогнозирования возникновения и развития заболеваний, а также построения рекомендаций для их профилактики и лечения.
2. Эксперт – использует систему для создания нейросетевых моделей, пригодных для повышения точности выставляемых диагнозов, прогнозирования возникновения и развития заболеваний, а также построения рекомендаций для их профилактики и лечения.
3. Администратор – использует возможности управления системой для поддержания ее функционирования.
4. Оператор ввода наблюдений – загружает в систему наблюдения, из которых формируются обучающие и тестовые выборки для построения нейросетевых моделей.

На рисунке 4 приведена диаграмма вариантов использования верхнего уровня, отражающая основные варианты использования системы разными типами пользователей.

На следующем этапе необходимо определить непосредственно прецеденты. Для определения прецедентов необходимо описать потребности актеров, которые должны обеспечиваться системой для достижения их целей.

Рассмотрим детальнее потребности актера «врач»:

- ввести данные по пациенту в систему;
- получить оценки вероятностей по наличию заболеваний на текущий момент времени;
- получить прогноз по возникновению и развитию заболеваний на будущие периоды времени;
- получить персональные рекомендации для лечения и профилактики заболеваний.




Рисунок 4 – Основные варианты использования

На рисунке 5 изображена спецификация вариантов использования системы для актера «врач».




Рисунок 5 – Спецификация вариантов использования системы
для актера «врач»

Из диаграммы видно, что ввод данных о пациенте и получение оценки вероятностей по наличию заболеваний являются обязательными шагами при выполнении основного варианта использования. Получение прогноза по возникновению и развитию заболевания является расширением функции оценки заболевания путем отображения изменения уровня развития заболевания спустя заданный временной промежуток. Функция построения персональных рекомендаций, в свою очередь, является расширением функции прогнозирования, которая помимо временного фактора учитывает различные варианты рекомендаций при прогнозировании развития заболевания для выбора наилучшего набора рекомендаций.

Эксперту необходимо:

- задавать схему предметной области (СПО);
- получать множество наблюдений, которые будут использоваться для обучения и тестирования нейросетевых моделей;
- выявлять аномальные наблюдения в обучающем множестве с последующей коррекцией или исключением данных наблюдений из выборки;
- вычислять информативность входных параметров для подбора оптимального соотношения количества входных параметров к погрешности нейросетевой модели;
- настраивать специфичность и чувствительность нейросетевых моделей;
- производить проектирование, обучение и тестирование нейросетевых моделей;
- вычислять метрики качества полученной нейросетевой модели.

На рисунке 6 представлена спецификация вариантов использования системы для актера «эксперт».

Как видно из рисунка, получение выборок включает в себя задание СПО, которая необходима для описания структуры данных наблюдений, входящих в выборку. Вычисление значимости входных параметров является необязательным шагом, но позволяет оптимизировать структуру данных и процесс обучения нейросетевой модели посредством исключения незначимых или малозначимых вход-

ных параметров. Настройка специфичности и чувствительности также является опциональным вариантом использования, который используется при необходимости получения нейросетевой модели с определенными показателями по данным метрикам.




Рисунок 6 – Спецификация вариантов использования системы для актера «эксперт»

Администратору системы необходимо:

- назначать нейросетевые модели, полученные от экспертов, для диагностирования соответствующих заболеваний;
- управлять базой пользователей и правами доступа;
- производить настройку прочих параметров системы.

На рисунке 7 изображена диаграмма вариантов использования для актера «администратор». Управление базой пользователей включает в себя редактирование списка пользователей и назначение конкретных прав пользователям. Управление нейросетевыми моделями подразумевает сопоставление конкретной нейросетевой модели соответствующему заболеванию, поддерживаемому системой.




Рисунок 7 – Спецификация вариантов использования системы для актера «администратор»

На рисунке 8 приведена спецификация вариантов использования системы для актера «оператор ввода наблюдений». Его задача сводится к вводу и редактированию наблюдений посредством интерфейса системы.




Рисунок 8 – Спецификация вариантов использования системы для актера «оператор ввода наблюдений»

На основании всех вышеперечисленных потребностей были выделены следующие основные сценарии:

- Добавление поддержки нового заболевания в систему.
- Настройка поддерживаемого системой заболевания.
- Получение диагнозов, прогнозов по развитию и рекомендаций по профилактике заболеваний.
- Управление списком пользователей и правами.

3.1.3. Диаграмма последовательности

Диаграммы взаимодействия описывают взаимодействие групп объектов в различных условиях их поведения [32]. Диаграммы последовательности являются одним из типов диаграмм взаимодействия, которые описывают взаимодействие объектов и системы, показывая, в какой последовательности выполняются действия объектов и какова реакция системы. Одна диаграмма последовательности обычно описывает один сценарий. Для сокращения объема работы из нее исключены описания тривиальных сценариев и представлены диаграммы последовательности, включающие сложное взаимодействие нескольких объектов или ролей. В описании самих сценариев опущены шаги ввода и проверки учетных данных, определения прав пользователя, и предполагается, что соответствующие актеры успешно прошли процедуры авторизации и аутентификации.

На рисунке ([приложение А](#)) приведена диаграмма последовательности для сценария «Добавление поддержки нового заболевания в систему». В данном сценарии отражены все основные действия, необходимые для добавления поддержки нового заболевания в систему, при этом последующее повышение качества диагностирования или изменение состава входных параметров (сценарий «Настройка поддерживаемого системой заболевания») производятся путем повторения соответствующих шагов данного сценария.

На рисунке ([приложение Б](#)) изображен процесс работы врача с системой во время приема. После сбора анамнеза и данных о пациенте эта информация вво-

дится в систему. На основании введенной информации система выдает вероятности наличия заболеваний из списка, поддерживаемых системой. Также на основании введенных данных может быть запрошен прогноз на указанный промежуток времени. При этом система должна ограничивать максимальный временной интервал, на который доступен прогноз, тем значением, который задал эксперт. Кроме того, может быть получен список рекомендаций, выполнение которых дает наилучший прогноз по развитию заболеваний в будущем.

После анализа данных по пациенту и анализа заключений, выданных системой, врач выдает итоговое заключение и рекомендации. Стоит отметить, что диагнозы и рекомендации системы носят вспомогательный характер и не могут быть использованы в качестве основного источника при принятии решения врачом. В случае расхождения диагнозов, предложенных системой, и мнения врача следует более детально изучить данный случай для выставления однозначного диагноза. В системе нейросетевой диагностики необходимо предусмотреть возможность постоянного пополнения базы наблюдений новыми данными. В случае выдачи системой ошибочного заключения по диагнозу данное наблюдение необходимо включить в обучающую выборку, чтобы при последующем переобучении нейросетевой модели этот случай был учтен и данная ошибка не повторилась.

3.1.4. Определение структуры системы

Анализ вариантов использования и диаграмм последовательностей позволил выделить логические модули, объединяющие в себе набор функций для решения смежных задач. На рисунке 9 представлена обобщенная структура нейросетевой рекомендательной системы. Система состоит из четырех основных модулей: описания предметной области, сбора наблюдений, извлечения знаний и модуля консультирования.

Модуль описания предметной области предназначен для создания и редактирования схем предметной области (СПО), которые используются всеми остальными модулями системы.




Рисунок 9 – Модульная архитектура нейросетевой рекомендательной системы

В СПО содержится следующая информация: список входных и выходных параметров нейросетевой модели, их название, описание, типы, диапазоны допустимых значений, метрики качества нейросетевой модели. Под *предметной областью* понимается конкретная задача, решаемая системой посредством нейросетевого моделирования. В случае с медицинской рекомендательной системой *предметной областью* является диагностирование конкретного заболевания, но поскольку в общем случае система может применяться в других предметных областях, используется более общий термин. Данный модуль содержит инструментарий для создания, редактирования и экспорта СПО для использования другими модулями.

Предназначение *модуля сбора наблюдений* – ввод и хранение множества исходных эмпирических наблюдений с последующим формированием обучающих, тестирующих и подтверждающих выборок, используемых при обучении и тести-

ровании нейросетевых моделей. В состав модуля входят база данных, предназначенная для хранения данных, а также несколько модулей ввода, предоставляющих возможность получения данных из различных источников. Такими источниками могут быть файлы, данные, полученные из других медицинских систем, данные, вводимые вручную через собственный интерфейс системы. Данный модуль использует СПО для формирования структур хранения множества наблюдений, первичной проверки вводимых данных на допустимость вводимых значений, а также для формирования интерфейса ввода данных для добавления новых наблюдений.

Модуль извлечения знаний используется для обучения нейросетевых моделей на основании обучающих множеств, полученных модулем сбора наблюдений. Результатом работы модуля является обученная нейросетевая модель для каждого из диагностируемых типов заболеваний. Для каждой обученной нейронной сети вычисляются ее показатели качества на тестовом и подтверждающем множествах: нормализованная среднеквадратичная ошибка (NRMSE), специфичность (Sp), чувствительность (Se). Для получения более качественных нейросетевых моделей в данном модуле реализованы все предложенные методы повышения качества нейросетевых моделей, применимые на этапе их создания и обучения. СПО используется для автоматического преобразования данных множества наблюдений в пригодный для обучения нейросетевых моделей вид и для задания первичной структуры сети (входного и выходного слоя).

Множество обученных нейросетевых моделей, полученное в результате работы модуля извлечения знаний, используется как база знаний для модуля консультирования.

Модуль консультирования предназначен для диагностирования заболеваний ССС, прогнозирования возникновения и развития заболеваний ССС, а также построения персонализированных рекомендаций по лечению и профилактике. Используя СПО, данный модуль формирует интерфейс для ввода данных, необходимых для диагностирования, преобразует введенные данные к виду, пригодному для нейросетевой модели, сопоставляет введенные данные и входы нейросетевой

модели, а полученный выходной сигнал интерпретируется и выдается в виде результата. Одной из вспомогательных функций данного модуля является пополнение базы наблюдений посредством добавления исходных входных данных и окончательного решения, принятого врачом-экспертом, что особенно актуально в случае, если результат, выданный системой, не является верным.

3.2. Обоснование выбора средств разработки

В качестве платформы реализации нейросетевой рекомендательной системы были выбраны платформа .Net TM Core и язык программирования C#. Ниже перечислены основные характеристики данной платформы.

Универсальность и переносимость

Эта платформа подходит для разработки всех типов программного обеспечения: настольных приложений [112], веб-приложений [80], приложений для мобильных устройств, при этом большая часть программного кода может быть совместно использована между этими приложениями. В случае с разрабатываемой системой это является важным свойством ввиду того, что в системе предусмотрены модули и компоненты различных типов: настольные приложения, веб-приложения, и в дальнейшем планируется разработка мобильных приложений.

Использование промежуточного кода

Программы, написанные на всех языках, поддерживаемых платформой .Net TM Core, преобразуются в промежуточный управляемый код (IL). Это позволяет избежать многих ошибок времени исполнения, часто встречающихся в программном коде, например, утечки памяти, управление ресурсами, работа со структурами данных и распараллеливание операций, что повышает надежность кода и делает процесс разработки более эффективным, уменьшая количество времени, которое тратится на написание кода и отладку приложения [11]. Преобразование промежуточного кода в машинный происходит непосредственно во время выполнения приложения, а это, в свою очередь, позволяет запускать такие приложения на любой поддерживаемой аппаратной платформе и операционной сис-

теме без необходимости перекомпиляции. Кроме того, повышается производительность приложения, так как во время преобразования кода в машинный код транслятору известны аппаратные и программные возможности текущей системы, и эта информация используется для генерации оптимизированного кода [112].

Большой выбор средств разработки

Для создания приложений на данной платформе существует большое количество сред разработки, упрощающих написание приложений. Кроме того, разрабатывать приложения на данной платформе можно без использования специализированных средств, воспользовавшись любым текстовым редактором. В качестве среды разработки была выбрана Microsoft® Visual Studio Code, которая поддерживает большинство возможностей, необходимых для быстрой разработки приложений (подсветка синтаксиса, навигация по коду, автодополнение кода, отладка и т.д.), полностью поддерживает платформу .Net Core [101] и может быть функционально расширена посредством большого количества подключаемых модулей.

Открытые исходные коды

Исходные коды данной платформы открыты и могут быть использованы для изучения и изменения платформы. Сама платформа (среда исполнения, компиляторы, стандартная библиотека, средства разработки) может быть скомпилирована из исходных кодов и распространяться вместе с программным обеспечением, которое ее использует [101].

Таким образом, все описанные выше характеристики позволили выбрать Microsoft® .NET™ и язык C# в качестве платформы для создания системы. Изначальная версия системы разрабатывалась на платформе .Net Framework™, которая имеет ряд недостатков по отношению к платформе .Net™ Core, однако высокая степень совместимости исходных кодов позволила перенести реализованный функционал на новую платформу без больших изменений.

3.3. Описание программной реализации системы

В данном разделе приведено более подробное описание модулей системы, описанных в разделе 3.1.4, а также рассмотрены некоторые особенности реализации различных аспектов системы.

3.3.1. Модуль описания предметной области

Модуль описания предметной области сохраняет описания в собственном формате файлов на основе языка разметки XML. Этот формат содержит информацию, необходимую для автоматической генерации интерфейсов ввода данных, и информацию, необходимую для работы алгоритмов обработки данных, реализованных в других модулях системы. К такой информации относится:

- описание входных параметров:
 - идентификатор;
 - наименование;
 - тип;
 - диапазон допустимых значений для скалярных величин;
 - варианты выбора для категориальных величин;
- описание выходных значений:
 - идентификатор;
 - тип;
 - преобразование для вывода.

Фрагмент файла описания СПО представлен на рисунке 10.

```
<?xml version="1.0" encoding="utf-8" ?>
<Fields>

  <Field-Id="0"-Title="Пол"-Format="Select"-Description="">
    <Select-Title="Мужской"-Value="1"/>
    <Select-Title="Женский"-Value="2"/>
  </Field>
  <Field-Id="9"-Title="Количество-полных-лет"-Format="Numeric"-IsInteger="true"-Description=""/>
  ..
  <Field-Id="1"-Title="Дата-рождения"-Format="Date"-Description=""/>

```

Рисунок 10 – Фрагмент файла описания схемы предметной области

На рисунке 11 изображена часть формы ввода нового наблюдения модуля сбора наблюдений. Данная форма ввода сгенерирована автоматически на основании файла с описанием СПО.

Пол:

Мужской

Рост (см.):

140

Вес (кг.):

50

Группа крови:

Ничего не выбрано

Первая

Вторая

Третья

Четвёртая

Курение:

Рисунок 11 – Интерфейс ввода наблюдений

Данный подход позволяет в декларативной форме описать заболевание и добавить его в систему без необходимости создания форм ввода или написания дополнительного кода.

3.3.2. Модуль сбора наблюдений

Модуль сбора наблюдений используется для сбора, хранения и выгрузки наборов наблюдений, которые используются в модуле извлечения знаний для обучения ИНС. Данный модуль использует СПО для формирования структур хранения данных, первичной проверки вводимых данных на допустимость значений, а также для формирования интерфейса ручного ввода данных.

Данный модуль предполагает многопользовательский доступ и реализован в виде веб-приложения и веб-сервиса. Веб-приложение предоставляет интерфейс

для ручного ввода и редактирования наблюдений (см. рисунок 11). Веб-сервис позволяет принимать данные наблюдений из сторонних источников – других приложений, скриптов загрузки данных или баз данных. Примером такого источника может служить модуль консультирования, отправляющий новые наблюдения, поступающие в процессе его работы.

Множество собранных наблюдений доступно для выгрузки в несколько форматов файлов: текстовый, XML, XLSX (формат файла Microsoft® Excel®).

3.3.3. Модуль извлечения знаний

Модуль извлечения знаний реализован в виде настольного приложения «Нейросимулятор 5» [42; 46] и является универсальным симулятором нейронных сетей, предназначенных для решения широкого круга задач, в том числе и задач медицинской диагностики [39]. В нем же реализованы все предложенные методы повышения качества нейросетевых систем, применимые на этапе создания и обучения нейросетевых моделей: метод выявления аномальных наблюдений с использованием ИНС, вычисления информативности входных параметров, посредством анализа нейросетевой модели, настройки специфичности и чувствительности нейросетевых моделей. На рисунке 12 показан интерфейс настройки структуры ИНС.

Доступно создание многослойных нейросетевых структур прямого распространения сигнала, при этом количество нейронов на каждом слое и количество слоев ограничены только ресурсами системы, на которой запущено приложение, и не имеют искусственных ограничений. Поддерживаются следующие типы активационных функций: биполярная, гаусса, линейная, логарифмическая, сигмоидальная, тангенс гиперболический.

На рисунке 13 представлена вкладка обучения ИНС, на которой задаются обучающая и тестовая выборки, алгоритм обучения и другие параметры, связанные с процессом обучения.




Рисунок 12 – Интерфейс настройки структуры ИНС




Рисунок 13 – Интерфейс настройки параметров обучения ИНС

Помимо функционала управления выборками и настройки параметров обучения на данной вкладке расположены элементы управления, позволяющие вызывать выполнение выявления аномальных наблюдений с использованием ИНС, вычисления информативности входных параметров посредством анализа нейросетевой модели и производить настройку специфичности и чувствительности нейросетевых моделей путем задания коэффициентов масштабирования функции потерь.

Методы повышения эффективности нейросетевых систем построены на инфраструктуре интерфейса *IDataAnalysis*, который описывает протокол реализации классов анализа выборок данных. Этот интерфейс реализован в следующих классах: *DataAnalysis*, *BatchAnalyser*, *ConflictSamplesDetector*, *OutlierDetector*, *SignificanceCalculator*.

DataAnalysis – базовый класс анализа данных, который реализует общие методы, необходимые для анализа данных. Данный класс разработан на основе шаблона проектирования для обхода коллекций «итератор» [31], так как выборки представлены коллекцией наборов пар векторов. От этого класса наследуются все классы анализа данных, что облегчает их создание отсутствием необходимости реализации функционала, отличного от непосредственной логики конкретного анализатора.

BatchAnalyser – класс на основе шаблона проектирования «компоновщик», позволяющий объединить несколько классов анализаторов для выполнения анализа нескольких показателей за один проход по всей выборке [31].

ConflictSamplesDetector – данный класс выделяет конфликтные наблюдения, т.е. наблюдения с одинаковыми входными векторами, но разными выходными. Такие наблюдения легко поддаются обнаружению и могут помешать обучению нейросетевой модели и работе остальных методов анализа данных, основанных на нейросетевом моделировании.

OutlierDetector – класс, в котором реализованы методы обнаружения аномальных наблюдений с использованием ИНС.

SignificanceCalculator – класс, реализующий вычисления информативности входных параметров посредством анализа нейросетевой модели.

Использование метода нейросетевого моделирования, на котором базируются предложенные методы повышения эффективности нейросетевых систем, позволяет использовать кодовую базу нейросетевого моделирования использованную для реализации основного функционала приложения, и сократить общую кодовую базу за счет отсутствия необходимости реализации дополнительного математического инструментария.

3.3.4. Модуль консультирования

Данный модуль должен поддерживать многопользовательский доступ, работу на всевозможных платформах и централизованное обновление как самого программного кода, так и нейросетевых моделей. Ввиду вышеобозначенных требований данный модуль был выполнен в виде веб-приложения.

Данный модуль предназначен для диагностирования заболеваний ССС, прогнозирования возникновения и развития заболеваний ССС, а также построения персонализированных рекомендаций по их лечению и профилактике заболеваний. СПО используется данным модулем для формирования интерфейса ввода данных, необходимых для диагностирования, преобразования введенных данных к виду, пригодному для нейросетевой модели, сопоставляет введенные данные и входы нейросетевой модели, а полученный выходной сигнал интерпретируется и выдается в наглядном виде.

Помимо непосредственно диагностирования в данном модуле реализованы методы прогнозирования развития заболеваний и построения рекомендаций, описанные в разделах 2.5 и 2.5.1 соответственно.

Интерфейс ввода данных о пациенте формируется аналогично модулю сбора наблюдений (см. рисунок 11). На рисунке 14 изображен результат работы функции диагностики наличия заболеваний. По каждому заболеванию выводится вероятность наличия в процентах.

Функция прогнозирования выдает результат в том же виде (см. рисунок 14), но он означает вероятности возникновения заболеваний на будущий период времени. Интервал прогнозирования задается врачом, однако на данный момент вви-

ду ограниченного набора долгосрочных наблюдений данная функция позволяет получить прогноз только на год вперед.




Рисунок 14 – Вероятности наличия заболеваний, вычисленные системой:

ИМ – инфаркт миокарда; СС – стенокардия стабильная; СН – стенокардия нестабильная; ИБС – ишемическая болезнь сердца; ГБ – гипертоническая болезнь; АиБС – аритмии и блокады сердца; ХСН – хроническая сердечная недостаточность; ОСН – острая хроническая недостаточность

Функция построения рекомендаций реализована посредством алгоритма, описанного в разделе 2.5.1. На данный момент функция ограничена проверкой следующих факторов, доступных для вариации: курение, употребление алкоголя, занятие физической культурой. Вследствие небольшого количества варьируемых параметров в алгоритме используется полный перебор всех комбинаций параметров. В дальнейшем планируется увеличить количество проверяемых параметров и использовать один из методов оптимизации для подбора оптимальных рекомендаций.

3.4. Планируемые доработки системы

В рамках развития системы предполагаются следующие доработки:

1. Сквозная оценка вводимых в систему данных посредством метода нейросетевого обнаружения аномальных наблюдений.

2. Реализация и интеграция всех модулей в рамках единого веб-приложения.
3. Автоматизация повторяющихся задач.
4. Абстрагирование от предметной области медицинской диагностики.

Ниже приведены более подробное описание и эффект от предполагаемых доработок системы.

Сквозная оценка вводимых в систему данных предполагает выделение данного функционала в отдельный подмодуль и использование не только в модуле извлечения знаний, но и в модулях консультирования и сбора наблюдений. Изначально этому препятствовал тот факт, что для работы предложенного алгоритма обнаружения аномальных наблюдений с использованием ИНС нужен некоторый набор наблюдений. Использование данного метода при вводе новых наблюдений и при вводе данных о пациенте для анализа позволит в реальном времени получать уведомления о возможных ошибках при вводе данных, что особенно актуально в режиме постановки диагноза, так как позволит избежать неправильно выставленного диагноза вследствие неточности при получении или вводе входных параметров. При вводе наблюдений в модуле сбора наблюдений ошибки ввода данных будут видны в момент ввода конкретного наблюдения, что позволит на месте проверить корректность вводимого наблюдения.

Реализация и интеграция всех модулей в рамках единого веб-приложения предполагают реализацию интерфейса и логики модулей описания предметной области и извлечения знаний в административной части веб-приложения, которое в данный момент включает в себя только модули сбора наблюдений и консультирования. Данная доработка стала возможна благодаря развитию облачных технологий, позволяющих выделять и использовать большие вычислительные ресурсы только при непосредственной необходимости, которая возникает при анализе данных и обучении нейросетевых моделей в модуле извлечения знаний. Развитие технологий построения веб-интерфейсов позволяет реализовать сложный интерфейс модуля извлечения знаний и редактора СПО для модуля описания предметной области. Кроме того, данная доработка позволит унифицировать кодовую ба-

зу системы, упростить взаимодействие между модулями, обеспечить централизованное и одновременное обновление всех взаимосвязанных модулей.

Интеграция модулей в едином приложении позволит *автоматизировать некоторые повторяющиеся задачи*, например, дообучение нейросетевой модели при поступлении новых данных в базу наблюдений системы. После первичного проектирования и обучения нейросетевой модели все параметры сохраняются в том же файле, что и нейросетевая модель. Таким образом, повторный запуск процесса обучения с прежними параметрами, но расширенным обучающим и тестовыми множествами можно осуществлять в фоновом режиме без привлечения эксперта. При этом система способна сравнить метрики качества используемой на данный момент нейросетевой модели и новой, после чего оповестить администратора в случае получения более качественной модели. Решение об использовании новой модели по-прежнему принимает администратор.

Абстрагирование от предметной области медицинской диагностики. Несмотря на то, что проектирование и разработка системы опирались на терминологию конкретной предметной области – медицинской диагностики, разработанная система может применяться и в других областях, где применима методология нейросетевого моделирования. Абстрагируясь от терминологии, все предложенные методы, инструменты и программные модули системы могут быть использованы в качестве нейросетевой рекомендательной системы общего назначения.

ВЫВОДЫ ПО ГЛАВЕ

В главе были рассмотрены этапы разработки нейросетевой рекомендательной системы диагностики и прогнозирования сердечно-сосудистых заболеваний человека, выявлены требования, пользовательские роли и сценарии использования. На основании этих данных была спроектирована и реализована модульная архитектура системы, включающая все методы повышения эффективности нейросетевых рекомендательных систем, предложенные в рамках диссертационной работы.

В качестве платформы реализации была выбрана среда .Net Core ввиду того, что она поддерживает создание всех необходимых типов приложений, является кроссплатформенной и поставляется с исходными кодами компилятора, среды выполнения и всех стандартных библиотек.

Несмотря на то, что проектирование и разработка системы опирались на терминологию конкретной предметной области – медицинской диагностики, разработанная система может применяться и в других областях, где применима методология нейросетевого моделирования.

ГЛАВА 4. ТЕСТИРОВАНИЕ РАЗРАБОТАННЫХ МЕТОДОВ ПРИ ПОСТАНОВКЕ ДИАГНОЗОВ ЗАБОЛЕВАНИЙ СЕРДЕЧНО-СОСУДИСТОЙ СИСТЕМЫ ЧЕЛОВЕКА

В данной главе представлены результаты тестирования реализации предложенных методов в рамках разработанной нейросетевой рекомендательной системы.

4.1. Тестовое множество

Тестирование производилось как на искусственно сгенерированных множествах данных, так и на множестве реальных данных о 1000 пациентах отделения неотложной кардиологии Городской клинической больницы № 4 г. Перми. Каждое наблюдение включает в себя 59 входных параметров и 7 выходных. Входные параметры характеризуют паспортные данные и жалобы пациента, анамнез его заболевания и образ жизни. Полный список доступных входных параметров приведен в [приложении Л](#). Выходные параметры кодируют степень уверенности в наличии заболеваний ССС человека в процентах, где 0 – полная уверенность в отсутствии заболевания, 100 – полная уверенность в его наличии. Список нозологических форм, закодированных в выходных параметрах:

- инфаркт миокарда;
- стенокардия стабильная;
- стенокардия нестабильная;
- гипертоническая болезнь;
- аритмии и блокады сердца;
- хроническая сердечная недостаточность;
- острая сердечная недостаточность.

Все множество наблюдений было разбито на обучающее (learn, L), тестирующее (test, T) и подтверждающее (confirm, C) в соотношении: 78 % : 15 % : 7 %, что составляет соответственно 780, 150 и 70 наблюдений. Обучение и тестирование нейросетевых моделей и предложенных методов проводились на указанных множествах (L , T , C), если не указано иное. Подтверждающая выборка использу-

ется для дополнительного тестирования нейросетевой модели, так как тестовая выборка (T) косвенно участвует в процессе обучения в качестве критерия успешности обучения нейросетевой модели. Для более точной оценки погрешностей использовался метод перекрестной проверки (*cross-validation*), при котором метрики качества нейросетевой модели вычисляются несколько раз при смене наблюдений, входящих во множества L , T , C [89].

4.2. Показатели эффективности нейросетевой рекомендательной системы

Для вычисления эффективности нейросетевой рекомендательной системы диагностики и прогнозирования заболеваний ССС были выбраны следующие показатели:

$\text{NRMSE}(X)$ – нормированный корень среднеквадратичной ошибки на множестве X показывает, насколько хорошо соответствуют значения, выдаваемые нейросетевой моделью, значениям в выборке X . В качестве проверочной выборки может использоваться тестовая выборка (T) или подтверждающая выборка (C). Выбор данной метрики обусловлен тем, что RMSE придает бóльший вес более сильным отклонениям, что делает RMSE более полезной, когда большие ошибки особенно не желательны, что актуально в задаче медицинской диагностики. Нормирование RMSE делает ее безразмерной величиной, что позволяет применять ее для сравнения эффективности предложенных в работе метрик. Для удобства представления значения метрики будут приводиться в процентах.

Для вычисления эффективности прогнозирования также используется NRMSE, но в качестве желаемых значений берутся фактические значения за будущий период времени.

Как было показано в первой главе, для медицинских диагностических систем необходимо применять критерии оценки качества медицинских диагностических методов:

- чувствительность $\text{Se}(X)$ – процент истинно положительных результатов. Показывает, каков будет процент больных, у которых данный метод выявит наличие заболевания;

– специфичность $Sp(X)$ – процент истинно отрицательных результатов. Показывает, каков будет процент здоровых лиц, у которых данный метод не выявит наличие заболевания.

Истинно положительными результатами будем считать результат диагностики больше 50 % при фактическом диагностированном уровне, превышающем 50 %. Истинно отрицательными результатами будем считать диагностированный уровень менее 50 % при фактическом диагностированном уровне ниже 50 %.

4.3. Тестирование метода выявления аномальных наблюдений

Тестирование метода выявления аномальных наблюдений производилось следующим образом:

1. Обучение нейросетевой модели на исходном множестве L , фиксация структуры нейронной сети, параметров обучения и начальных весовых коэффициентов.
2. Вычисление метрики NRMSE на тестовом (T) и подтверждающем (C) множествах.
3. Выявление аномальных наблюдений.
4. Анализ, исправление найденных аномалий или их исключение из множеств L , T , C . Результирующие исправленные множества обозначим L' , T' , C' .
5. Обучение нейросетевой модели на множестве L' с использованием зафиксированных на первом шаге структуры нейронной сети параметров обучения и начальных весовых коэффициентов.
6. Вычисление метрик качества на новых тестовом (T') и подтверждающем (C') множествах.

Шаги 3–6 выполнялись для нескольких методов обнаружения аномальных наблюдений (в скобках приведены сокращенные обозначения данных методов в рамках данной работы):

- расстояний Махаланобиса (MD);

- DFFITS для множественной линейной регрессионной модели (DL);
- DFFITS для множественной нелинейной регрессионной модели (DN);
- предложенный в работе метод с использованием ИНС (NN).

Для вычисления границы отсека по методу обнаружения аномалий с применением расстояний Махаланобиса, описанному в разделе 1.1.1, требуется нормальное распределение анализируемых данных. Однако в случае с анализируемой выборкой данное требование не выполняется. Для получения приблизительной оценки порогового значения оно было рассчитано по методу, описанному в разделе 1.1.1, а затем изменялось в некотором диапазоне относительно этого значения. Для каждого значения в этом диапазоне выполнялись шаги 3–6 процедуры тестирования и окончательно брались результаты с наименьшей ошибкой NRMSE. Построение регрессионных моделей выполнялось при помощи пакета STATISTICA, для нелинейной модели выбирались все доступные типы нелинейных операторов.

В работе в целях сокращения объема приведены результаты тестирования трех нозологических форм: инфаркт миокарда; стенокардия нестабильная; острая сердечная недостаточность. Для остальных нозологических форм получены схожие результаты, не влияющие на общий вывод.

Изначальные показатели для нозологической формы «Инфаркт миокарда»: $\text{NRMSE}(T) - 19,86\%$ $\text{NRMSE}(C) - 21,73\%$. В таблице 2 приведены результаты применения методов обнаружения аномальных наблюдений: количество обнаруженных аномальных наблюдений, уровень ошибок на тестовом и подтверждающем множествах.

Анализ выявленных аномалий показал, что все 4 метода обнаружили 17 наблюдений с большими (на порядок) отклонениями данных, вероятно, полученными в результате ошибок ввода данных. Кроме того, из таблицы видно, что метод выявления аномалий на основе расстояний Махаланобиса (MD) выявил наибольшее количество аномальных наблюдений, однако качество итоговой нейросетевой модели не только не возросло, но показало несколько худший результат, чем изначально.

Таблица 2 – Результаты применения методов обнаружения аномальных наблюдений для нозологической формы «Инфаркт миокарда»

Метод	Обнаружено аномалий	$NRMSE(T')$	$NRMSE(C')$
MD	117	19,96 %	22,02 %
DL	18	19,11 %	21,01 %
DN	25	19,00 %	20,83 %
NN	89	9,52 %	10,72 %

Возможная причина такого результата в том, что метод MD рассматривает наблюдения как отдельные точки, без учета зависимости выходных параметров от входных, и помимо наблюдений с большими отклонениями данный метод исключил из выборки наблюдения, важные для построения нейросетевой модели, вследствие чего ошибки остались примерно на том же уровне. Методы на основе DFFITS также обнаружили описанные выше аномалии с большими отклонениями в данных, что позволило несколько снизить уровни ошибок.

Предложенный метод с использованием ИНС (NN) помимо аномалий с большими отклонениями обнаружил наблюдения, удаление которых позволило значительно снизить уровни ошибок. Как показал дальнейший анализ, эти наблюдения выбивались из общей закономерности связи входных параметров и соответствующей степени развития заболевания. Стоит также отметить, что 5 из 68 таких примеров были также обнаружены методом DFFITS для множественной нелинейной регрессионной модели.

Для нозологической формы «Стенокардия нестабильная» изначальные показатели были следующие: $NRMSE(T)$ – 25,33 % $NRMSE(C)$ – 26,15 %. Отметим, что нейросетевая модель для данной нозологической формы имеет изначально большую погрешность.

В таблице 3 приведены результаты применения методов обнаружения аномальных наблюдений для нозологической формы «Стенокардия нестабильная».

Таблица 3 – Результаты применения методов обнаружения аномальных наблюдений для нозологической формы «Стенокардия нестабильная»

Метод	Обнаружено аномалий	$NRMSE(T')$	$NRMSE(C')$
MD	118	25,30 %	26,25 %
DL	17	24,51 %	26,53 %
DN	23	24,61 %	25,96 %
NN	90	18,51 %	19,42 %

Из таблицы видно, что метод выявления аномалий на основе расстояний Махаланобиса (MD) выявил примерно такое же количество аномальных наблюдений, как и в случае анализа «Инфаркт миокарда». При сравнении наборов выявленных наблюдений выяснилось, что выявленные аномальные наблюдения не только количественно, но и качественно практически совпадают, т.е. метод на основе расстояний Махаланобиса выявил тот же набор аномалий, что и для нозологической формы «Инфаркт миокарда». Это объясняется тем, что наборы данных для каждой нозологической формы отличаются лишь столбцом выходного параметра, который кодирует степень уверенности в наличии данной нозологической формы, поэтому основной объем анализируемых данных (1000 наблюдений и 59 входных параметра) остается неизменным. С учетом отмеченной выше особенности метода на основе расстояний Махаланобиса, рассматривающего наблюдения как отдельные точки, это объясняет выявленный факт обнаружения одинакового набора аномальных наблюдений для двух представленных нозологических форм. Похожая картина наблюдается для методов на основе DFFITS (DL, DN).

Изначальные показатели для нозологической формы «Острая сердечная недостаточность»: $NRMSE(T)$ – 10,23 % $NRMSE(C)$ – 10,87 %. В таблице 4 приведены результаты применения методов обнаружения аномальных наблюдений для нозологической формы «Острая сердечная недостаточность».

Таблица 4 – Результаты применения методов обнаружения аномальных наблюдений для нозологической формы «Острая сердечная недостаточность»

Метод	Обнаружено аномалий	NRMSE(T')	NRMSE(C')
MD	117	10,20 %	10,12 %
DL	17	9,12 %	10,17 %
DN	21	9,26 %	9,51 %
NN	86	6,51 %	6,76 %

Из данных таблицы видна уже описанная закономерность – небольшое изменение в количестве выявленных аномалий и значительное увеличение качества нейросетевой модели при методе обнаружения аномалий с использованием ИНС.

4.4. Тестирование метода вычисления информативности входных параметров

Первоначальное тестирование методов вычисления информативности входных параметров производилось на искусственно сгенерированных наборах данных. При генерации таких наборов данных возможно точно управлять значимостью каждого входного параметра и затем сравнивать с оценкой значимости, вычисленной при помощи различных методов.

В качестве примера приведем тестовую выборку объемом 5000 примеров, в которой входными параметрами являются X_1 , X_2 , X_3 – случайно заданные величины, равномерно распределенные в интервале $[0..2\pi]$, а выходной параметр вычисляется по формуле: $y = \sin(X_1) + \cos(X_3)$.

Как видно из этой формулы, на значение величины Y параметры X_1 и X_3 оказывают одинаковую степень влияния, по 50 % соответственно, тогда как параметр X_2 никакого влияния на Y не оказывает, так как не используется при ее вычислении. На рисунке 15 приведены результаты вычислений коэффициентов корреляции Пирсона, Кендалла, Спирмена, Фехнера между Y и X_1 , между Y и X_2 и между Y и X_3 . Ввиду указанных в разделе 2.2 недостатков классических методов опреде-

ления взаимосвязи переменных они показали неудовлетворительные результаты и были исключены из дальнейшего сравнения.




Рисунок 15 – Результаты вычисления информативности посредством коэффициентов корреляции: *а* – коэффициент линейной корреляции Пирсона, *б* – коэффициент ранговой корреляции Спирмена, *в* – Гамма корреляция, *г* – корреляция Кендалла Тау

Проведем проверку на том же наборе данных предлагаемого в работе метода вычисления информативности путем перестановки значений, а также следующих методов на основе анализа нейросетевых моделей, описанных в разделе 1.2: возмущения входного сигнала и рандомизации входного параметра (HIPR). Остальные из описанных методов не рассматривались, так как ввиду присущих им ограничений, описанных в том же разделе, они не применимы к анализу нейросетевой модели медицинской диагностики. Для метода возмущения входного параметра проводилось несколько проходов с разным уровнем шума от 10 до 50 %. В качестве финального результата выбирался лучший.

Результаты выполнения процедуры вычисления информативности приведены на рисунке 16.




Рисунок 16 – Результат вычисления информативности входных параметров:

а – перестановки значений, *б* – рандомизации входного параметра,

в – возмущения входного сигнала

Как видно из рисунка 16, все три метода с высокой степенью точности определили степень информативности каждого из трех параметров, однако метод возмущения входного параметра имеет погрешность, достигающую до 4 %.

В таблице 5 для более точного анализа представлены числовые значения вычисления информативности параметров.

Таблица 5 – Сводная таблица результатов вычисления информативности при помощи различных методов

Метод	X_1	X_2	X_3
Перестановки значений	50 %	0 %	50 %
Рандомизации входного параметра	50 %	0 %	50 %
Возмущения входного сигнала	53 %	4 %	43 %

Из таблицы видно, что методы перестановки значений и рандомизации входного параметра показали наиболее точные результаты. Метод возмущения входного параметра показал перекося в уровне значимости в сторону параметра X_1 , а также показал наличие некоторой информативности параметра X_2 , которая должна отсутствовать.

Второй тестовый набор данных был получен с теми же параметрами за исключением того, что входные параметры были X_1, X_2, X_3 – они имели нормальное распределение с математическим ожиданием, равным π , и стандартным отклонением, равным $\sqrt{\pi}$, и заданы как дискретные величины с шагом $\frac{\pi}{6}$.

В таблице 6 представлены числовые значения вычисления информативности параметров на данном тестовом наборе при помощи трех методов вычисления информативности.

Таблица 6 – Сводная таблица результатов вычисления информативности для дискретных входных параметров с нормальным распределением

Метод	X_1	X_2	X_3
Перестановки значений	51 %	0 %	49 %
Рандомизации входного параметра	54 %	3 %	47 %
Возмущения входного сигнала	52 %	3 %	45 %

Из таблицы видно, что при таком распределении входных параметров наиболее точным является метод перестановки значений. Метод рандомизации входного параметра при этом показал наихудший результат с максимальной переоценкой информативности входного параметра до 5 %.

Дальнейшее тестирование производилось на реальных данных по следующей методике:

1. Обучение нейросетевой модели на исходном множестве L , фиксация структуры нейронной сети, параметров обучения и начальных весовых коэффициентов.
2. Вычисление метрики NRMSE на тестовом множестве (T).
3. Поочередное удаление входных параметров и вычисление метрики NRMSE, при этом структура нейросетевой модели и параметров обучения оставались неизменными.
4. Вычисление изменения метрики NRMSE на тестовом множестве (T) относительно первоначального значения, полученного на шаге 2.

5. Выполнение оценки информативности входных параметров каждым из трех методов.
6. Построение линейной регрессии между информативностью параметра и изменением погрешности при его удалении для каждого из методов определения информативности.
7. Вычисление коэффициента линейной корреляции Пирсона (r) для полученных регрессионных моделей.
8. Шаги 2–7 повторялись с использованием подтверждающего (C) множества вместо тестового (T).

В идеальном случае при удалении параметра X_i погрешность нейросетевой модели должна увеличиться прямо пропорционально вычисленной информативности этого параметра. Таким образом, качество алгоритма вычисления информативности можно определить по качеству линейной регрессии, полученной на шаге 6, которая оценивается путем вычисления коэффициента корреляции Пирсона (r) на шаге 7 для каждого метода. В идеальном случае данный коэффициент должен равняться единице.

В таблице 7 приведены сводные результаты выполнения 7-го шага для каждого из трех методов на тестовом и подтверждающем множествах.

Таблица 7 – Результаты тестирования методов вычисления информативности входных параметров

Метод	r для множества (T)	r для множества (C)
Перестановки значений	0,944	0,942
Рандомизации входного параметра	0,872	0,862
Возмущения входного сигнала	0,800	0,802

Из таблицы видно, что на данных, описанных в разделе 4.1, наибольшую точность показал алгоритм перестановки значений, предложенный в данной диссертационной работе.

4.5. Тестирование метода настройки специфичности и чувствительности

Тестирование метода настройки специфичности и чувствительности производилось путем проверки возможности получения нейросетевых моделей с требуемыми операционными диагностическими характеристиками.

В качестве тестовой нейросетевой модели была спроектирована и обучена модель для экспресс-диагностики заболевания «Инфаркт миокарда». Для этого из входных параметров были исключены все незначимые параметры, а также параметры, требующие инструментальных и лабораторных методов исследования. Изначальные характеристики полученной нейросетевой модели экспресс-диагностики:

- количество входных параметров = 30;
- $\text{NRMSE}(T) = 31,05 \%$; $\text{NRMSE}(C) = 31,89 \%$;
- Чувствительность (Se) = 80,10 %;
- Специфичность (Sp) = 79,22 %.

Требуется получить нейросетевую модель с уровнем специфичности 95 % для уменьшения количества случаев ошибочного выставления положительного диагноза.

Таблица 8 – Зависимость характеристик нейросетевой модели
«Инфаркт миокарда» от параметра α

α	Se	Sp	NRMSE(C)
1,00	80,10 %	79,22 %	31,89 %
0,90	79,44 %	79,83 %	31,51 %
0,80	74,67 %	83,78 %	31,69 %
0,70	69,15 %	88,18 %	32,12 %
0,61	67,21 %	95,02 %	32,36 %

Как видно из таблицы 8, заданный уровень специфичности достигается при значении параметра $\alpha = 0,61$, при этом уровень чувствительности опустился до 67,21 %, что является максимальным уровнем для данного метода нейросетевого диагностирования. Также отметим возросший уровень общей погрешности $\text{NRMSE}(C)$, который составил 32,36 % для финального этапа.

Для сравнения попробуем получить тот же уровень специфичности, сдвигая границу классификации здоров/болен для данной нейросетевой модели. Для получения того же уровня специфичности граница разделения была сдвинута до 82 %, т.е. наличие заболевания «Инфаркт миокарда» считалось обнаруженным, при уровне выходного сигнала, превышающего 82. При этом чувствительность снизилась до 51,12 %, что на 16,09 % ниже, чем при использовании предложенного метода.

4.6. Тестирование методов прогнозирования заболеваний

Для тестирования возможности прогнозирования развития заболеваний необходимо иметь наблюдения, содержащие информацию о пациенте на момент времени t и информацию о диагностированных заболеваниях на момент времени $t + 1$. После наполнения множества, описанного в разделе 4.1, историческими данными и исключением наблюдений, для которых не были доступны данные за следующий временной интервал, было получено новое множество из 677 примеров. Временной интервал прогнозирования составляет 1 год.

Тестирование качества прогнозирования выполнялось путем вычисления метрики NRMSE на тестовом и подтверждающем множествах, где в качестве входных параметров используются данные о пациенте на момент времени t , в качестве желаемых значений – диагноз, выставленный врачом на момент времени $t + 1$ на основании данных о пациенте на момент времени $t + 1$, в качестве модельных значений – прогноз по диагнозу, полученному при помощи нейросетевой модели на момент времени $t + 1$ на основании данных о пациенте на момент времени t . Таким образом, производилось сопоставление диагноза, выставленного врачом на основе показателей больного на момент выставления диагноза, в то

время как нейросетевая модель вычисляла этот же диагноз на основе данных по этому пациенту за прошлый временной период.

4.6.1. Тестирование метода экспертной коррекции при прогнозировании с использованием ИНС

Тестирование метода экспертной коррекции прогноза, описанного в разделе 2.4, выполнялось в два этапа:

- вычисление качества прогнозирования при изменении входного параметра «Возраст» пациента;
- экспертная коррекция данного результата и оценка качества вычисления качества для скорректированного прогноза.

Отметим, что обучение нейросетевой модели осуществлялось на полном множестве, описанном в разделе 4.1. Погрешность диагностирования также вычислена на тестовом и подтверждающем множествах из разделе 4.1 и соответствует результатам, полученным в разделе 4.3, после применения метода выявления аномальных наблюдений. Погрешность прогнозирования выполнялась на множестве из раздела 4.6.

Ниже приведены результаты для нозологической формы «Стенокардия нестабильная»:

- уровень погрешности диагностирования для нейросетевой модели: $\text{NRMSE}(T)$ составила 18,51 %, $\text{NRMSE}(C)$ составила 19,42 %;
- уровень погрешности прогнозирования на год вперед путем увеличения параметра «возраст»: $\text{NRMSE}(T)$ составила 24,22 %, $\text{NRMSE}(C)$ составила 25,13 %;
- уровень погрешности прогнозирования на год вперед путем увеличения параметра «возраст» с последующей экспертной коррекцией: $\text{NRMSE}(T)$ составила 24,02 %, $\text{NRMSE}(C)$ составила 24,96 %.

Из результатов тестирования видно, что погрешность прогнозирования путем увеличения одного только входного параметра «возраст» составляет почти

25 %. Экспертная коррекция позволила в небольшой степени снизить погрешность в основном за счет некоторого уменьшения больших отклонений в тех тестовых примерах, где прогноз нейросетевой модели был значительно ниже фактического диагноза.

Для нозологической формы «Инфаркт миокарда» наблюдается похожая картина:

- уровень погрешности диагностирования для нейросетевой модели: $\text{NRMSE}(T)$ составила 9,52 %, $\text{NRMSE}(C)$ составила 10,72 %;
- уровень погрешности прогнозирования на год вперед путем увеличения параметра «возраст»: $\text{NRMSE}(T)$ составила 18,51 %, $\text{NRMSE}(C)$ составила 19,43 %;
- уровень погрешности прогнозирования на год вперед путем увеличения параметра «возраст» с последующей экспертной коррекцией: $\text{NRMSE}(T)$ составила 17,91 %, $\text{NRMSE}(C)$ составила 19,12 %.

Кроме того, для нозологической формы «Инфаркт миокарда» наблюдается значительно возросшая погрешность прогнозирования относительно погрешности диагностирования, что можно объяснить отсутствием возраста в списке основных факторов риска возникновения инфаркта миокарда [47].

Для остальных нозологических форм наблюдается схожая картина: незначительное уменьшение погрешности скорректированного прогноза относительно нескорректированного, при этом использование коэффициентов коррекции, учитывающих пол и привычку курения, не показало статистически значимого улучшения.

4.6.2. Тестирование метода скользящего окна при прогнозировании с использованием ИНС

Для применения метода скользящего окна при прогнозировании с использованием ИНС, описанного в разделе 2.5, необходимо обучающее множество, содержащее исторические данные, описанное в разделе 4.6. Формирование множе-

ства обучающих примеров выполнялось посредством процедуры, описанной в разделе 2.5.

Результаты для нозологической формы «Стенокардия нестабильная» представлены графически на рисунке 17 в виде сопоставления фактического диагноза, поставленного врачами, и диагноза, полученного в результате вычислений нейронной сети. Для обеспечения лучшего качества изображения на рисунке приведены данные только по 20 тестовым примерам.



Рисунок 17 – Сопоставление реальных диагнозов и прогноза нейросетевой модели на год вперед для формы «Стенокардия нестабильная»

Метрика $NRMSE(T)$ составила 20,11 %, $NRMSE(C)$ – 21,01 %, это свидетельствует о том, что ИНС может с большой долей вероятности предсказывать диагноз на год вперед. Практически во всех случаях нейронная сеть верно определила наличие заболевания, однако в некоторых случаях степень уверенности нейронной сети в диагнозе сильно отличается от определенной врачом, причем в 6 случаях из 20 она ниже определенной врачом, это свидетельствует о том, что при прогнозировании развития заболевания этим методом чувствительность оказывается заниженной. Результаты тестирования для других нозологических форм также продемонстрировали недостаточную чувствительность при прогнозировании.

Для повышения уровня чувствительности нейросетевой модели прогнозирования воспользуемся методом, предложенным в разделе 2.3, обучив данную

нейросетевую модель с коэффициентом масштабирования $\alpha = 1,3$. Результат тестирования скорректированной нейросетевой модели показан на рисунке 18. Гистограмма построена на тех же тестовых примерах, но для наглядности сравнения был добавлен третий столбец, соответствующий прогнозу, полученному при помощи скорректированной нейросетевой модели.




Рисунок 18 – Сопоставление реальных диагнозов и прогноза скорректированной нейросетевой модели на год вперед для формы «Стенокардия нестабильная»

Из диаграммы видно, что степень уверенности в диагнозах, выставленных этой новой обученной сетью, выше по сравнению с предыдущим вариантом. И несмотря на то, что появилось несколько ложноположительных диагнозов, общий уровень ошибки уменьшился: метрика $NRMSE(T)$ составила 19,20 %, $NRMSE(C) = 19,98$ %. Это дополнительное уменьшение погрешности можно объяснить следующим образом: ввиду отсутствия данных о том, как бы выставил врач диагноз на год вперед, выполняется сравнение диагнозов, выставленных врачом на момент получения им актуальных данных об исследовании пациента. В то же время ИНС вычисляет диагноз на основании прошлогодних данных обследования, моделируя тем самым прогнозирование на год вперед. Учитывая также тот факт, что заболевания с течением времени имеют склонность к развитию, делаем вывод, что врач на основе актуальных данных ставил более точные диагнозы, которые соответствовали большему уровню развития заболевания с те-

чением времени. В этом случае повышение чувствительности ИНС позволяет учесть эту особенность.

Для нозологической формы «Инфаркт миокарда» использование метода скользящего окна позволило получить следующие показатели эффективности прогнозирования: $\text{NRMSE}(T) = 14,15 \%$, $\text{NRMSE}(C) = 14,75 \%$. Напомним, что показатели для диагностирования на текущий момент времени для нозологической формы «Инфаркт миокарда» имеют следующие значения: $\text{NRMSE}(T) = 9,52 \%$, $\text{NRMSE}(C) = 10,72 \%$.

Тестирование данного метода на других нозологических формах также показало лучшие результаты относительно простого увеличения входного параметра «Возраст» и применения метода экспертной коррекции.

4.7. Виртуальные компьютерные эксперименты

Виртуальные компьютерные эксперименты выполнялись с целью анализа выдаваемых системой результатов на адекватность и сопоставления с выводами, которые сделал бы врач при тех же исходных данных. Результаты данных экспериментов освещались в работах [21; 41; 50; 52; 66; 74; 115–116].

Эксперименты выполнялись для трех гипотетических пациентов:

Пациент 1. Мужчина в возрасте 50 лет (родился 09.05.1967 г.), рост 177 см, вес 80 кг, группа крови вторая, резус-фактор положительный, курит, физзарядкой не занимается, есть заболевания сердца у кровных родственников, гипертонической болезни нет, сахарного диабета нет, нарушений мозгового кровообращения не было, ранее диагноз болезней сердца не ставился, кардиохирургических вмешательств не было, имеется тромбофлебит, болей в грудной клетке нет, жалуется на одышку при физическом напряжении, приступов удушья по ночам нет, сердцебиения бывают, ощущений перебоев в работе сердца нет, отеков конечностей и лица нет, на головокружения и головные боли не жалуется.

Пациент 2. Женщина в возрасте 39 лет (родилась 20.11.1977 г.), рост 160 см, вес 60 кг, группа крови первая, резус-фактор положительный, курит, физзарядкой не занимается, заболеваний сердца у кровных родственников нет, гипер-

тонической болезни нет, сахарного диабета нет, нарушений мозгового кровообращения не было, ранее диагноз болезней сердца не ставили, кардиохирургических вмешательств не было, варикозной болезни или тромбоза нет, болей в грудной клетке нет, одышки нет, приступов удушья по ночам нет, сердцебиений нет, ощущения перебоев в работе сердца нет, имеются отеки лица, жалуется на частые головокружения и головную боль.

Пациент 3. Мужчина в возрасте 50 лет (родился 15.08.1966 г.), рост 180 см, вес 75 кг, группа крови четвертая, резус-фактор отрицательный, курит, физзарядкой не занимается, есть заболевания сердца у кровных родственников, гипертонической болезни нет, сахарного диабета нет, нарушений мозгового кровообращения не было, ранее диагноз болезней сердца ставился, кардиохирургических вмешательств не было, имеется тромбоз, болей в грудной клетке нет, жалуется на одышку в покое, приступов удушья по ночам нет, сердцебиений нет, имеются ощущения перебоев в работе сердца, имеются отеки конечностей, жалуется на частые головокружения и головную боль.

После ввода параметров пациентов нейросетевая рекомендательная система поставила диагнозы, представленные в графической форме на рисунке 19: *а* – пациенту № 1, *б* – пациенту № 2, *в* – пациенту № 3.




Рисунок 19 – Степени развития заболеваний, диагностированные системой:

а – пациенту № 1, *б* – пациенту № 2, *в* – пациенту № 3

Нозологические формы обозначены следующим образом: 1 – инфаркт миокарда, 2 – стенокардия стабильная, 3 – стенокардия нестабильная, 4 – ишемическая болезнь сердца, 5 – гипертоническая болезнь, 6 – аритмия и блокада сердца, 7 – хроническая сердечная недостаточность, 8 – острая сердечная недостаточность.

Как видно из рисунка, у пациентов № 1 и 2 система не выявила сердечно-сосудистых заболеваний, тогда как у пациента №3 система поставила диагноз: аритмия и блокады сердца – 70 %, хроническая сердечная недостаточность (ХСН) – 100 %, острая сердечная недостаточность (ОСН) – 20 %.

Далее выполнялись эксперименты по сценарному прогнозированию развития заболеваний при варьировании различных параметров. Прогнозирование выполнялось с применением метода экспертной коррекции, так как для метода скользящего окна на данный момент недостаточно данных для построения прогнозов на выбранный временной интервал в 30 лет. Стоит отметить, что данные эксперименты проводились не с целью проверки точности прогнозирования на большой временной интервал, а с целью выявления относительных закономерностей влияния изменения различных параметров на степень развития заболевания со временем.

На рисунке 20 в форме, аналогичной рисунку 19, приведены результаты сценарного прогнозирования развития заболеваний при условии, что возраст пациентов увеличился на 30 лет, а вес – на 20 кг. Все остальные параметры пациентов сохранены неизменными. Как видно из рисунка, у пациента № 1 система предположила появление риска аритмии и блокад сердца – 70 % и риска ХСН – 100 %. У пациента № 2 риски сердечно-сосудистых заболеваний не обнаружались, а у пациента № 3 система прогнозировала появление риска аритмии и блокад сердца – 70 %, риска ХСН – 100 % и риска ОСН – 60 %.




Рисунок 20 – То же самое при условии, что возраст пациентов увеличился на 30 лет, а вес увеличился на 20 кг

На рисунке 21 приведены результаты сценарного прогнозирования развития сердечно-сосудистых заболеваний при условии, что помимо увеличения возраста и веса пациенты заболели сахарным диабетом. Как видно из рисунка, у пациента №1 заболевание сахарным диабетом стимулировало появление риска заболевания стенокардии стабильной на 98 %, стенокардии нестабильной – на 91 %, ишемической болезни сердца – 98 %. Риски аритмии и блокады сердца, а также ХСН остались на прежнем высоком уровне – 70 и 100 % соответственно. У пациента № 2 диабет не вызвал появления каких-либо рисков заболеваний сердечно-сосудистой системы, тогда как у пациента № 3 диабет привел к возрастанию риска ОСН до 75 %.




Рисунок 21 – То же самое при условии, что помимо увеличения возраста и веса пациенты приобрели сахарный диабет

На рисунке 22 результаты прогнозирования отличаются тем, что у пациентов снят диагноз «сахарный диабет», а вместо него выставлено наличие гипертонической болезни. Данный прогноз соответствует тому, что пациентам во время диагностики (30 лет назад) дали рекомендацию воздерживаться от сладкого, а за артериальным давлением они не следили. Как видно из рисунка, добавление гипертонической болезни вместо сахарного диабета у пациента № 1 картину сценарного прогнозирования не изменило, у пациента № 2 добавился риск ХСН 26 %, а у пациента № 3 снизился риск ОСН с 75 до 30 %.

На рисунке 23 результаты сценарного прогнозирования отличаются тем, как если бы, помимо всего прочего, пациенты все эти годы (30 лет) регулярно занимались физзарядкой или легким видом спорта. Как видно из рисунка, в этом случае у пациента № 1 риск стенокардии стабильной упал бы с 98 до 2 %, риск сте-

нокардии нестабильной остался бы на прежнем уровне, риск ИБС снизился бы с 98 до 91 %, риск аритмии и блокад сердца упал бы с 70 до 4 %. У пациента № 2 ХСН снизилась бы с 26 % до нуля, а у пациента № 3 риск ОСН снизился бы с 30 до 8 %.




Рисунок 22 – То же самое при условии, что вместо сахарного диабета у пациентов имеется гипертоническая болезнь




Рисунок 23 – То же самое при условии, что все 30 лет пациенты регулярно занимались физзарядкой или легким спортом

На рисунке 24 представлены результаты сценарного прогнозирования в предположении, что пациенты по-прежнему не занимались физзарядкой, но бросили курить. В этом случае у пациента № 1 упали бы до нуля риски обеих стенокардий и ИБС, однако риск аритмии и блокад сердца сохранился бы на уровне 70 %, как на рисунке 21. У пациента № 2 картина сценарного прогнозирования сохранилась бы, как и на рисунке 22, т.е. для него бросить курить или вместо этого заняться физкультурой одинаково положительно сказывается на состоянии сердечно-сосудистой системы, а именно риска ХСН в обоих вариантах поведения пациента удалось бы избежать. Для пациента № 3 избавление от привычки курения приведет к возрастанию ОСН с 8 до 63 %. Такому пациенту бросать курить не

рекомендуется. По-видимому, привычка курения позволяет пациентам данного типа нивелировать получаемые стрессы, что положительно отражается на состоянии его сердечно-сосудистой системы, в частности, на предрасположенности к ОСН.




Рисунок 24 – То же самое при условии, что пациенты не занимались физзарядкой, но бросили курить

Обсуждение результатов экспериментов с профессиональными врачами-кардиологами позволило сделать заключение об адекватности предоставляемых системой вероятностей наличия заболеваний [66, 115, 116]. Кроме того, проведенные компьютерные эксперименты позволили выявить и исследовать новые медицинские знания: показано, что рекомендации по профилактике и лечению кардиологических больных следует давать строго индивидуально с учетом физиологических особенностей организма пациентов. Если для одних пациентов такие рекомендации, как «отказаться от курения», «ограничить употребление сладкого», «принимать препараты, снижающие артериальное давление» и т.д., действительно полезны, то другим больным они могут причинить вред. Выявить таких нестандартных пациентов и избежать ошибочных рекомендаций можно с помощью разработанной нейросетевой рекомендательной системы.

4.8. Результаты внедрения результатов работы и тестирования системы

Опытная эксплуатация системы проводилась на базе ГАУЗ ПК «Городская клиническая больница №4», г. Пермь, в виде программного комплекса «Нейро-экспертная система диагностики и прогнозирования рисков сердечно-сосудистых

заболеваний» [44]. Тестирование проводилось с 2014 по 2017 г. За это время было протестировано 863 пациента, находящихся на лечении в отделении острого коронарного синдрома.

Тестирование проводилось при первичном осмотре, при этом использовались нейросетевые модели с сокращенным набором параметров: были исключены входные параметры, требующие инструментальных и лабораторных методов исследования. При этом за стопроцентный результат принято заключение врача-эксперта на основании повторного посещения, подкрепленное лабораторными и инструментальными методами обследования. В данных условиях чувствительность выявления системой инфаркта миокарда составила 87,0 %, стенокардии стабильной – 74,2 %, стенокардии нестабильной – 64,5 %, гипертонической болезни – 74,2 %, аритмий и блокад сердца – 77,4 %, хроническая сердечная недостаточность – 64,5 %, острая левожелудочковая недостаточность – 74,2 %. Акт, подтверждающий данные результаты, представлен в [приложении 3](#).

Предложенные методы были использованы при разработке программного комплекса «Дифференциальная диагностика заболеваний сердечно-сосудистой системы (НСМ)» [38], а также при реализации модулей «Диагностика состояния сердечно-сосудистой системы человека» [26] и модуля «Обработка анкет пациентов с сердечно-сосудистыми заболеваниями» [25] диагностического программного комплекса «Е-Эскулап» [20].

Кроме того, отдельные результаты и отдельные программные модули внедрены в учебном процессе при проведении практических занятий по дисциплинам «Методы искусственного интеллекта» в Федеральном государственном бюджетном образовательном учреждении высшего образования «Пермский государственный национальный исследовательский университет» (акт представлен в [приложении К](#)) и «Интеллектуальные информационные системы» в Федеральном государственном бюджетном образовательном учреждении высшего образования «Пермский государственный гуманитарно-педагогический университет» (акт представлен в [приложении И](#)).

ВЫВОДЫ ПО ГЛАВЕ

В главе приведены результаты тестирования предложенных методов повышения эффективности нейросетевых рекомендательных систем. Результаты тестирования показали, что применение данных методов позволяет повысить эффективность отдельных этапов создания нейросетевых моделей и точность выдаваемых ими результатов на примере задачи медицинской диагностики заболеваний ССС человека.

Кроме того, показана возможность системы выполнять прогнозы развития заболеваний, а также прогнозировать возникновение заболеваний на будущие периоды жизни пациента. Такие возможности позволяют подбирать оптимальный образ жизни пациентов, а также способы профилактики и курсы лечения заболеваний. В результате сделан шаг в направлении решения актуальной задачи персонализации медицинского обслуживания населения в рамках реализации концепции превентивной медицины.

ОСНОВНЫЕ РЕЗУЛЬТАТЫ И ВЫВОДЫ

1. Разработаны методы анализа обучающих выборок, позволяющие повысить качество нейросетевых моделей:

а) *метод выявления аномальных наблюдений с использованием ИНС*, основанный на методе анализа удаленных остатков, отличающийся тем, что вместо регрессионных моделей используются нейросетевые; б) *метод вычисления информативности входных параметров посредством анализа нейросетевой модели*, отличающийся способом рандомизации входных параметров. Данные методы показали свою эффективность в условиях ограниченных объемов выборок со сложными корреляционными связями и дискретными входными параметрами, что позволило повысить качество создаваемых нейросетевых моделей в указанных условиях.

2. Разработан *метод настройки чувствительности алгоритмов обучения ИНС* к ошибкам первого и второго рода, который отличается тем, что параметрически модифицируется вид функции потерь обучения нейронной сети, позволяя варьировать уровень чувствительности и специфичности нейросетевой модели. Это позволяет определять критерии оптимизации обучения ИНС с учетом требований к соответствующим характеристикам нейросетевой диагностической модели.

3. Разработаны два метода, позволяющие повысить точность прогнозирования развития процессов во времени с применением нейросетевых моделей: *метод экспертной коррекции* и *метод скользящего окна*. Данные методы эффективны при прогнозировании процессов со сложными корреляционными связями между входными параметрами.

4. Спроектирована и разработана нейросетевая система, предназначенная для диагностики, прогнозирования и построения рекомендаций по лечению и профилактике заболеваний ССС человека. С помощью разработанной системы проведено тестирование предложенных методов и показана их эффективность.

СПИСОК СОКРАЩЕНИЙ И УСЛОВНЫХ ОБОЗНАЧЕНИЙ

АВ-клапан – атриовентрикулярный клапан

АГ – артериальная гипертензия

АД – артериальное давление

АЧТВ – активированное частичное тромбопластиновое время

ИБС – ишемическая болезнь сердца

ИМ – инфаркт миокарда

ИНС – искусственные нейронные сети

ЛП – левое предсердие

КТ – компьютерная томография

ЛПНП – липопротеины низкой плотности

МНО – международное нормализованное отношение

ГЛЖ – гипертрофия левого желудочка

ТЭЛА – тромбоэмболия легочной артерии

МР – магнитно-резонансный

МС – метаболический синдром

НТГ – нарушение толерантности к глюкозе

СД – сахарный диабет

СМАД – суточное мониторирование артериального давления

ЭКГ – электрокардиограмма, электрокардиография

ЭхоКГ – эхокардиография

ХС – холестерин

СПО – схема предметной области

ССС – сердечно-сосудистая система

ТГ – триглицериды

ФН – физическая нагрузка

ФР – факторы риска

ХОБЛ – хроническая обструктивная болезнь легких

ХСН – хроническая сердечная недостаточность

ЛПВП – липопротеины высокой плотности

ЦВД – центральное венозное давление

ПЖ – правый желудочек

ЛЖ – левый желудочек

ЧБКА – чрескожная баллонная коронарная ангиопластика

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Александрович, О.С. Технологии разработки программного обеспечения: учебник для вузов / О.С. Александрович, Ц.Б. Яковлевич. – 4-е изд. – СПб.: Питер, 2012. – 608 с.
2. Анатольевич, С.А. Методы и алгоритмы анализа данных и их моделирование в MATLAB: учеб. литература для вузов / С.А. Анатольевич. – СПб: БХВ-Петербург, 2017. – 384 с.
3. Аристов, Г.В. Распознавание и классификация микроструктуры металлов и сплавов с использованием глубоких нейронных сетей / Г.В. Аристов, А.В. Ключев // Материалы 27-й Междунар. конф. по компьютерной графике и машинному зрению. – Пермь: Изд. центр ПГНИУ, 2017. – С. 180–183.
4. Беленкова, Ю.Н. Кардиология: национальное руководство / Ю.Н. Беленкова, Р.Г. Оганова. – М.: ГЭОТАР-Медиа, 2011. – 1232 с.
5. Бизнес-статистика: учебник и практикум для академического бакалавриата / И. И. Елисеева [и др.]; под ред. И. И. Елисеевой. – М.: Юрайт, 2019. – 411 с.
6. Веденяпин, Д.А. Применение искусственных нейронных сетей в диагностике венозных заболеваний / Д.А. Веденяпин, А.Г. Лосев // Вестник новых медицинских технологий. – 2012. – Т. XIX. – № 2. – С. 241–242.
7. Гайдышев, И. Анализ и обработка данных / И. Гайдышев. – СПб.: Питер, 2001. – 752 с.
8. Галушкин, А.И. Нейронные сети : основы теории / А.И. Галушкин. – М.: Горячая линия-Телеком, 2010. – 496 с.
9. Горбань, А.Н. Нейронные сети на персональном компьютере / А.Н. Горбань, Д.А. Россиев. – Новосибирск: Наука: Сибир. изд. фирма РАН, 1996. – 276 с.
10. Горбаченко, В.И. Совершенствование градиентных алгоритмов первого порядка обучения сетей радиальных базисных функций / В.И. Горбаченко // Нейрокомпьютеры и их применение: материалы XVI Всерос. науч. конф. – 2018. – С. 245–247.

11. Карл И. Вигерс, Д.Б. Разработка требований к программному обеспечению / Д.Б. Карл И. Вигерс. – СПб.: БХВ-Петербург, 2016. – 736 с.
12. Катковник, В.Я. Непараметрическая идентификация и сглаживание данных: метод локальной аппроксимации: теоретические основы технической кибернетики / В.Я. Катковник. – М.: Наука, 1985. – 336 с.
13. Коновалова, О.Е. Система идентификации риска заболеваний по химическим показателям питьевой воды в нейросетевом базисе / О.Е. Коновалова, А.В. Коновалов, Т.В. Истомина // XXI век: итоги прошлого и проблемы настоящего плюс. – 2016. – Т. 30. – № 2. – С. 160–165.
14. Косарев, Е. Методы обработки экспериментальных данных / Е. Косарев. – М.: Физматлит, 2008. – 208 с.
15. Куравский, Л.С. Нейронные сети в задачах прогнозирования, диагностики и анализа данных: учеб. пособие / Л.С. Куравский, С.Н. Баранов, С.Б. Малых. – М.: РУСАВИА, 2003. – 100 с.
16. Лемешко, Б.Ю. Робастные методы оценивания и отбраковка аномальных измерений / Б.Ю. Лемешко // Заводская лаборатория. – 1997. – Т. 63. – № 5. – С. 43–49.
17. Лялин, В.Е. Определение параметров режимов фильтрации на графике производной давления с помощью нейронной сети / В.Е. Лялин, К.А. Сидельников // Интеллектуальные системы: материалы VIII Междунар. науч.-техн. конф. – 2010. – С. 34–40.
18. Миркес, Е.М. Нейроинформатика: учеб. пособие для студ. / Е.М. Миркес. – Красноярск: ИПЦ КГТУ, 2002. – 347 с.
19. Мустафаев, А.Г. Применение искусственных нейронных сетей для ранней диагностики заболевания сахарным диабетом / А.Г. Мустафаев // Кибернетика и программирование. – 2016. – Т. 2. – № 2. – С. 1–7.
20. Нейросетевая система диагностики и прогнозирования развития заболеваний сердечно-сосудистой системы / К.В. Богданов [и др.] // Нейрокомпьютеры и их применение: тез. докл. X Всерос. науч. конф. – М.: МГППУ, 2012. – С. 57–59.

21. Нейросетевая система диагностики и прогнозирования течения заболеваний сердечно-сосудистой системы / Л.Н. Ясницкий [и др.] // Медико-экологические информационные технологии – 2013: сб. материалов XVI Междунар. науч.-техн. конф. – Курск: Изд-во Юго-запад. гос. ун-та, 2013. – С. 79–85.
22. Нейросетевая система экспресс-диагностики сердечно-сосудистых заболеваний / Л.Н. Ясницкий [и др.] // Пермский медицинский журнал. – 2011. – Т. 4. – С. 77–86.
23. Нестационарные системы автоматического управления: анализ, синтез и оптимизация: / К.А. Пупков [и др.]. – М.: Изд-во МГТУ, 2007. – 632 с.
24. Основы радиоэлектроники: учеб. пособие для СПО / М. Застела [и др.]. – 3-е изд., перераб. и доп. – М.: Юрайт, 2018. – 495 с.
25. Программный комплекс «Е-Эскулап». Модуль обработки анкет пациентов с сердечно-сосудистыми заболеваниями: св-во о гос. регистр. программы для ЭВМ № 2015618985 / Ф.М. Черепанов [и др.]. – Заявка Роспатент № 2015613989. – Зарегистр. в Реестре программ.
26. Программный комплекс «Е-Эскулап». Нейросетевой модуль диагностики состояния сердечно-сосудистой системы человека: св-во о гос. регистр. программы для ЭВМ № 2015618984 / Ф.М. Черепанов [и др.]. – Заявка Роспатент № 2015613987. – Зарегистр. в Реестре.
27. Прохоренко, И.О. Метод нейросетевого моделирования и его использование для прогнозирования развития соматической патологии у лиц старших возрастных групп / И.О. Прохоренко // Современные проблемы науки и образования. – 2013. – Т. 1. – С. 8.
28. Россиев, Д.А. Определение информативности медицинских параметров с помощью нейронной сети / Д.А. Россиев, С.Е. Головенкин, Б.В. Назаров // Диагностика, информатика и метрология. – СПб., 1994. – С. 348.
29. Сичинава, З.И. Нейроэкспертный алгоритм последовательного обнаружения и исключения посторонних выбросов из статистической информации при построении нейросетевых математических моделей / З.И. Сичинава // Современные проблемы науки и образования. – 2013. – Т. 2. – С. 8.

30. Смоляк, С.А. Устойчивые методы оценивания: статистическая обработка неоднородных совокупностей: математическая статистика для экономистов / С.А. Смоляк, Б.П. Титаренко. – М.: Статистика, 1980. – 206 с.
31. Тепляков, С.В. Паттерны проектирования на платформе .NET / С.В. Тепляков. – СПб.: Питер, 2015. – 320 с.
32. Фаулер, М. UML. Основы. Краткое руководство по стандартному языку объектного моделирования / М. Фаулер. – СПб.: Символ-Плюс, 2005. – 192 с.
33. Филист, С.А. Гибридная нейронная сеть с макрослоями для медицинских приложений / С.А. Филист, О.В. Шаталова, М.А. Ефремов // Нейрокомпьютеры: разработка, применение. – 2014. – № 6. – С. 35–69.
34. Хливненко, Л.А. Возможности решения медицинских диагностических задач с помощью проектирования обучающихся искусственных нейронных сетей / Л.А. Хливненко, В.В. Васильев, Ф.А. Пятакович // Успехи современного естествознания. – 2010. – № 12. – С. 75–79.
35. Царегородцев, В.Г. Простейший способ вычисления показателей значимости первого порядка для сетей обратного распространения / В.Г. Царегородцев // Нейроинформатика и ее приложения: материалы X Всерос. семинара. – Красноярск, 2002. – С. 153–156.
36. Царегородцев, В.Г. Робастная целевая функция с допуском на точность решения для нейросети-предиктора / В.Г. Царегородцев // Нейрокомпьютеры: разработка, применение. – 2003. – Т. 13. – С. 5.
37. Черепанов, Ф.М. Выявление аномальных наблюдений в обучающем множестве посредством нейросетевой модели / Ф.М. Черепанов // Проблемы информатики в образовании, управлении, экономике и технике: материалы междунар. науч.-техн. конф. – Пенза: Изд-во Приволжск. дом знаний, 2014. – С. 210–213.
38. Черепанов, Ф.М. Дифференциальная диагностика заболеваний сердечно-сосудистой системы (НСМ): св-во о гос. регистр. программы для ЭВМ № 2014618207 / Ф.М. Черепанов. – Заявка Роспатент № 2014614798. – Зарегистрир. в Реестре программ для ЭВМ 12 августа 2014 г.

39. Черепанов, Ф.М. Исследовательский симулятор нейронных сетей, обзор его приложений и возможности применения для создания системы диагностики заболеваний сердечно-сосудистой системы / Ф.М. Черепанов // Современные проблемы науки и образования. – 2013. – Т. 1. – С. 12.
40. Черепанов, Ф.М. Методы повышения эффективности нейросетевых систем в условиях ограниченных объемов выборок со сложными корреляционными связями / Ф.М. Черепанов // Прикладная математика и вопросы управления. – 2019. – №. 2. – С. 40–61.
41. Черепанов, Ф.М. Нейросетевое моделирование диагностики и прогнозирования развития сердечно-сосудистых заболеваний / Ф.М. Черепанов // Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: сб. ст. по материалам Третьей Всерос. науч.-практ. конф. – Пермь, 2018. – С. 130–134.
42. Черепанов, Ф.М. Симулятор нейронных сетей для вузов / Ф.М. Черепанов // Математика. Механика. Информатика. – 2012. – Т. 3. – № 11. – С. 98–105.
43. Черепанов, Ф.М. Способ настройки чувствительности к ошибкам первого и второго рода для алгоритмов обучения нейронных сетей / Ф.М. Черепанов // Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века. – Пермь, 2016. – С. 187–192.
44. Черепанов, Ф.М. Нейро-экспертная система диагностики и прогнозирования рисков сердечно-сосудистых заболеваний: св-во о гос. регистр. программы для ЭВМ № 2017662410 / Ф.М. Черепанов, Л.Н. Ясницкий. – Заявка Роспатент № 2017619552. – Зарегистр. в Реестре программ для ЭВМ. – 11 с.
45. Черепанов, Ф.М. Нейросетевой фильтр для исключения выбросов в статистической информации / Ф.М. Черепанов, Л.Н. Ясницкий // Вестник Перм. университета. Математика. Механика. Информатика. – 2008. – Т. 4. – № 20. – С. 151–155.
46. Черепанов, Ф.М. Нейросимулятор 5.0: св-во о гос. регистр. программы для ЭВМ № 2014618208 / Ф.М. Черепанов, Л.Н. Ясницкий. Заявка Роспатент № 2014614649. – Зарегистр. в Реестре программ для ЭВМ 12 августа 2014 г.

47. Якушин, С.С. Инфаркт миокарда : Библиотека врача-специалиста. Кардиология, терапия / С.С. Якушин. – М.: ГЭОТАР-Медиа, 2010. – 211 с.
48. Ясницкий, Л.Н. Введение в искусственный интеллект / Л.Н. Ясницкий. – М.: Академия, 2005. – 176 с.
49. Ясницкий, Л.Н. Возможности применения методов искусственного интеллекта для диагностики и прогнозирования сердечно-сосудистых заболеваний / Л.Н. Ясницкий, А.А. Думлер, Ф.М. Черепанов // Искусственный интеллект: философия, методология, инновации: материалы Пятой Всерос. конф.; 9–11 ноября 2011 г., г. Москва, МГТУ МИРЭА. – М.: Радио и связь, 2011. – С. 146–148.
50. Ясницкий, Л.Н. Динамическое нейросетевое моделирование как основа для предстоящей революции в медицине / Л.Н. Ясницкий, А.А. Думлер, Ф.М. Черепанов // Нейрокомпьютеры и их применение: тез. докл. XVI Всерос. науч. конф. – М.: Изд-во МГППУ, 2018. – С. 212–215.
51. Ясницкий, Л.Н. Нейросетевая система дифференциальной диагностики сердечно-сосудистых заболеваний / Л.Н. Ясницкий, А.А. Думлер, Ф.М. Черепанов // XVII Зимняя школа по механике сплошных сред. – Пермь, 2011. – С. 104.
52. Ясницкий, Л.Н. Новые возможности применения методов искусственного интеллекта для моделирования появления и развития заболеваний и оптимизации их профилактики и лечения / Л.Н. Ясницкий, А.А. Думлер, Ф.М. Черепанов // Терапия. – 2018. – Т. 1. – № 19. – С. 109–118.
53. A comparison of four data mining models: bayes, neural network, SVM and decision trees in identifying syndromes in coronary heart disease / J. Chen [et al.]. – Berlin, Heidelberg, 2007. – P. 1274–1279.
54. Ajam, N. Heart Diseases Diagnoses using Artificial Neural Network / N. Ajam // Network and Complex Systems. – 2015. – Vol. 5. – № 4. – P. 7–11.
55. An improved I-FAST system for the diagnosis of Alzheimer's disease from unprocessed electroencephalograms by using robust invariant features / M. Buscema [et al.] // Artificial Intelligence in Medicine. – 2015. – Vol. 64. – № 1. – P. 59–74.

56. Application of a two-stage fuzzy neural network to a prostate cancer prognosis system / R.-J. Kuo [et al.] // Artificial Intelligence in Medicine. – 2015. – Vol. 63. – № 2. – P. 119–133.
57. Application of neural networks in diagnosing cancer disease using demographic data / D.N. Ganesan [et al.] // International Journal of Computer Applications. – 2010. – Vol. 1. – № 26. – P. 76–85.
58. Application of sliding window technique for prediction of wind velocity time series / M. Vafaeipour [et al.] // International Journal of Energy and Environmental Engineering. – 2014. – Vol. 5. – № 2. – P. 105.
59. Armstrong, J.S. Error measures for generalizing about forecasting methods: Empirical comparisons / J.S. Armstrong, F. Collopy // International Journal of Forecasting. – 1992. – Vol. 8. – № 1. – P. 69–80.
60. Artificial intelligence in personalized medicine application of AI algorithms in solving personalized medicine problems / J. Awwalu [et al.] // International Journal of Computer Theory and Engineering. – 2015. – Vol. 7. – № 6. – P. 439–443.
61. Artificial neural network: a tool for diagnosing osteoporosis / A.B. Shaikh [et al.] // Research Journal of Recent Sciences. – 2014. – Vol. 3. – P. 87–91.
62. Artificial neural network: as emerging diagnostic tool for breast cancer / I.K. Sandhu [et al.] // International Journal of Pharmacy and Biological Sciences. – 2015. – Vol. 5. – № 3. – P. 29–41.
63. Artificial neural network and mobile applications in medical diagnosis / G. Pearce [et al.] // 2015 17th UKSim-AMSS International Conference on Modelling and Simulation (UKSim). – 2015. – P. 61–64.
64. Artificial neural network application in the diagnosis of disease conditions with liver ultrasound images / K. Kalyan [et al.] // Advances in Bioinformatics. – 2014. – Vol. 2014. – P. 1–14.
65. Artificial neural network for diagnosis of pancreatic cancer / M.U. Sanoob [et al.] // International Journal on Cybernetics & Informatics. – 2016. – Vol. 5. – № 2. – P. 41–49.

66. Artificial neural networks for obtaining new medical knowledge: diagnostics and prediction of cardiovascular disease progression / L.N. Yasnitsky [et al.] // *Biology and Medicine (Aligarh)*. – 2015. – Vol. 7. – № 2. – P. 8.
67. Artificial neural networks in medical diagnosis / F. Amato [et al.] // *Journal of Applied Biomedicine*. – 2013. – Vol. 11. – № 2. – P. 47–58.
68. Baxt, W.G. Improving the accuracy of an artificial neural network using multiple differently trained networks / W.G. Baxt // *Neural Computation*. – 1992. – Vol. 4. – № 5. – P. 772–780.
69. Beliakov, G. Derivative-free optimization and neural networks for robust regression / G. Beliakov, A. Kelarev, J. Yearwood // *Optimization*. – 2012. – Vol. 61. – № 12. – P. 1467–1490.
70. Comparative analysis of a-priori and a-posteriori dietary patterns using state-of-the-art classification algorithms: A case/control study / C.-M. Kastorini [et al.] // *Artificial Intelligence in Medicine*. – 2013. – Vol. 59. – № 3. – P. 175–183.
71. Computer-aided prediction of long-term prognosis of patients with ulcerative colitis after cytoapheresis therapy / T. Takayama [et al.] // *PloS one*. – 2015. – Vol. 10. – P. 9.
72. Cook, D.J. Activity learning: discovering, recognizing, and predicting human behavior from sensor data: Wiley series on parallel and distributed computing / D.J. Cook, N.C. Krishnan. – Wiley, 2015. – 288 p.
73. Diagnosing hepatitis B using artificial neural network based expert system / C. Mahesh [et al.]. – 2013. – Vol. 3. – № 6. – P. 139-144.
74. Diagnosis and prognosis of cardiovascular diseases on the basis of neural networks / L.N. Yasnitsky [et al.] // *Biomedical Engineering*. – 2013. – Vol. 47. – № 3. – P. 160–163.
75. Diagnostic methods I: sensitivity, specificity, and other measures of accuracy / K.J. van Stralen [et al.] // *Kidney International*. – 2009. – Vol. 75. – № 12. – P. 1257–1263.

76. Dynamically weighted evolutionary ordinal neural network for solving an imbalanced liver transplantation problem / M. Dorado-Moreno [et al.] // *Artificial Intelligence in Medicine*. – 2017. – Vol. 77. – P. 1–11.
77. Engelbrecht, A.P. Determining the significance of input parameters using sensitivity analysis / A.P. Engelbrecht, I. Cloete, J.M. Zurada // *From Natural to Artificial Neural Computation*. – 1995. – P. 382–388.
78. Eslamizadeh, G. Heart murmur detection based on wavelet transformation and a synergy between artificial neural network and modified neighbor annealing methods / G. Eslamizadeh, R. Barati // *Artificial Intelligence in Medicine*. – 2017. – Vol. 78. – P. 23–40.
79. Estimation of ten-year risk of fatal cardiovascular disease in Europe: the SCORE project. / R.M. Conroy [et al.] // *European Heart Journal*. – 2003. – Vol. 24. – № 11. – P. 987–1003.
80. Freeman, A. Pro ASP.NET Core MVC 2 / A. Freeman. – Berkeley, CA: Apress, 2017. – 1017 p.
81. Freund, R.J. Regression analysis / R.J. Freund, W.J. Wilson, P. Sa. – Elsevier Science, 2006. – 480 p.
82. Gil, D. Diagnosing Parkinson by using artificial neural networks and support vector machines / D. Gil, M. Johnson // *Global Journal of Computer Science and Technology*. – 2006. – P. 63–71.
83. Grubbs, F.E. Sample criteria for testing outlying observations / F.E. Grubbs // *The Annals of Mathematical Statistics*. – 1950. – Vol. 21. – № 1. – P. 27–58.
84. Handbook of psychology, research methods in psychology: Handbook of psychology / I.B. Weiner [et al.]. – Wiley, 2003. – 736 p.
85. Hinton, G.E. Reducing the dimensionality of data with neural networks / G.E. Hinton, R.R. Salakhutdinov // *Science*. – 2006. – Vol. 313. – № 5786. – P. 504–507.
86. Improving the Mann–Whitney statistical test for feature selection: An approach in breast cancer diagnosis on mammography / N.P. Pérez [et al.] // *Artificial Intelligence in Medicine*. – 2015. – Vol. 63. – № 1. – P. 19–31.

87. Kadhim, Q.A. Artificial neural networks in medical diagnosis / Q.A. Kadhim // *Journal of Computer Science Issues (IJCSI)*. – 2011. – Vol. 8. – № 2. – P. 150–154.
88. Kemp, S.J. An approach for determining relative input parameter importance and significance in artificial neural networks / S.J. Kemp, P. Zaradic, F. Hansen // *Ecological Modelling*. – 2007. – Vol. 204. – № 3-4. – P. 326–334.
89. Konishi, S. Information criteria and statistical modeling: Springer series in statistics / S. Konishi, G. Kitagawa. – Springer, 2008. – 276 p.
90. Kumar, K. Artificial neural networks for diagnosis of kidney stones disease / K. Kumar, A. Abhishek // *International Journal of Information Technology and Computer Science*. – 2012. – Vol. 4. – № 7. – P. 20–25.
91. Lo, Y. Prediction of coronary artery disease based on ensemble learning approaches and co-expressed observations / Y. Lo, H. Fujita, T. Pai // *Journal of Mechanics in Medicine and Biology*. – 2016. – Vol. 16. – № 01. – P. 10.
92. Luna, A.B. de. Clinical Arrhythmology / A.B. de Luna. – Wiley, 2011. – 440 p.
93. Machine learning for improved pathological staging of prostate cancer: A performance comparison on a range of classifiers / O. Regnier-Coudert [et al.] // *Artificial Intelligence in Medicine*. – 2012. – Vol. 55. – № 1. – P. 25–35.
94. Narang, S. A Review of breast cancer detection using ART model of neural networks / S. Narang, H.K. Verma, U. Sachdev // *International Journal of Advanced Research in Computer Science and Software Engineering*. – 2012. – Vol. 2. – № 10. – P. 311–319.
95. Nuovo, A.G. Di. Intelligent quotient estimation of mental retarded people from different psychometric instruments using artificial neural networks / A.G. Di Nuovo, S. Di Nuovo, S. Buono // *Artificial Intelligence in Medicine*. – 2012. – Vol. 54. – № 2. – P. 135–145.
96. Olaniyi, E.O. Heart diseases diagnosis using neural networks arbitration / E.O. Olaniyi, O.K. Oyedotun, K. Adnan // *International Journal of Intelligent Systems and Applications*. – 2015. – Vol. 7. – № 12. – P. 75–82.

97. Olden, J.D. Illuminating the “black box”: a randomization approach for understanding variable contributions in artificial neural networks / J.D. Olden, D.A. Jackson // *Ecological Modelling*. – 2002. – Vol. 154. – № 1–2. – P. 135–150.
98. Olden, J.D. An accurate comparison of methods for quantifying variable importance in artificial neural networks using simulated data / J.D. Olden, M.K. Joy, R.G. Death // *Ecological Modelling*. – 2004. – Vol. 178. – № 3–4. – P. 389–397.
99. Petrovic, S. Knowledge-light adaptation approaches in case-based reasoning for radiotherapy treatment planning / S. Petrovic, G. Khussainova, R. Jagannathan // *Artificial Intelligence in Medicine*. – 2016. – Vol. 68. – P. 17–28.
100. Prediction of acute myocardial infarction with artificial neural networks in patients with nondiagnostic electrocardiogram / J. Kojuri [et al.] // *Journal of Cardiovascular Disease Research*. – 2015. – Vol. 6. – № 2. – P. 51–59.
101. Price, M.J. C# 7 and .NET Core: Modern Cross-Platform Development - Second Edition: Create powerful cross-platform applications using C# 7, .NET Core, and Visual Studio 2017 or Visual Studio Code / M.J. Price. – Packt Publishing - ebooks Account, 2017. – 791 p.
102. Raji, C.G. Graft survival prediction in liver transplantation using artificial neural network models / C.G. Raji, S.S. Vinod Chandra // *Journal of Computational Science*. – 2016. – Vol. 16. – P. 72–78.
103. Reasoning with neural tensor networks for knowledge base completion / R. Socher [et al.] // *Proc. of NIPS'13*. – 2013.
104. Recognition and prediction of leukemia with Artificial Neural Network (ANN) / S. Afshar [et al.] // *Medical Journal of Islamic Republic of Iran*. – 2011. – Vol. 25. – № 1. – P. 35–39.
105. Ripley, B.D. Pattern recognition and neural networks / B.D. Ripley. – Cambridge University Press, 1996. – 410 p.
106. Robust regression and outlier detection for non-linear models using genetic algorithms / P. Vankeerberghen [et al.] // *Chemometrics and Intelligent Laboratory Systems*. – 1995. – Vol. 28. – № 1. – P. 73–87.

107. Sayad, A.T. Diagnosis of heart disease using neural network / A.T. Sayad, P.P. Halkarnikar // International Journal of Advances in Science Engineering and Technology. – 2014. – Vol. 2. – № 3. – P. 88–92.
108. Schmidhuber, J. Deep Learning in neural networks: An overview / J. Schmidhuber // Neural Networks. – 2015. – Vol. 61. – P. 85–117.
109. Shaikhina, T. Handling limited datasets with neural networks in medical applications: A small-data approach / T. Shaikhina, N.A. Khovanova // Artificial Intelligence in Medicine. – 2017. – Vol. 75. – P. 51–63.
110. Singh, M. Artificial Neural Network based Classification of Neurodegenerative Diseases / M. Singh, M. Singh, P. Singh // International Journal of Information Technology and Knowledge Management. – 2013. – Vol. 7. – № 1. – P. 27–30.
111. Sung, A.H. Ranking importance of input parameters of neural networks / A.H. Sung // Expert Systems with Applications. – 1998. – Vol. 15. – № 3-4. – P. 405–411.
112. Troelsen, A. Pro C# 7 / A. Troelsen, P. Japikse. – Berkeley, CA: Apress, 2017. – 1372 p.
113. Varmuza, K. Introduction to multivariate statistical analysis in chemometrics / K. Varmuza, P. Filzmoser. – CRC Press, 2009. – 336 p.
114. Wilson, R. The operations management complete toolbox (collection) / R. Wilson, A.V. Hill. – Pearson Education, 2013. – 681 p.
115. Yasnitsky, L.N. Dynamic artificial neural networks as basis for medicine revolution / L.N. Yasnitsky, A.A. Dumler, F.M. Cherepanov // Advances in Intelligent Systems and Computing. – 2018. – Vol. 850. – P. 351–358.
116. Yasnitsky, L.N. The capabilities of artificial intelligence to simulate the emergence and development of diseases, optimize prevention and treatment thereof, and identify new medical knowledge / L.N. Yasnitsky, A.A. Dumler, F.M. Cherepanov // Journal of Pharmaceutical Sciences and Research. – 2018. – Vol. 10. – № 9. – P. 2192–2200.

Диаграмма последовательности для сценария
«Добавление поддержки нового заболевания в систему»





Диаграмма последовательности для сценария «Получение диагнозов, прогнозов по развитию и рекомендаций по профилактике заболеваний»



РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2014618207

Дифференциальная диагностика заболеваний
сердечно-сосудистой системы (НСМ)Правообладатель: *Черепанов Федор Михайлович (RU)*Автор: *Черепанов Федор Михайлович (RU)*

Заявка № 2014614798

Дата поступления 05 мая 2014 г.

Дата государственной регистрации

в Реестре программ для ЭВМ 12 августа 2014 г.

Руководитель Федеральной службы
по интеллектуальной собственности

Б.П. Симонов

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2014618208

Нейросимулятор 5.0

Правообладатели: *Черепанов Федор Михайлович (RU), Ясницкий Леонид Нахимович (RU)*

Авторы: *Черепанов Федор Михайлович (RU), Ясницкий Леонид Нахимович (RU)*



Заявка № 2014614649

Дата поступления 05 мая 2014 г.

Дата государственной регистрации

в Реестре программ для ЭВМ 12 августа 2014 г.

Руководитель Федеральной службы
по интеллектуальной собственности

Б.П. Симонов

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2015618984

**ПРОГРАММНЫЙ КОМПЛЕКС «Е-ЭСКУЛАП».
НЕЙРОСЕТЕВОЙ МОДУЛЬ ДИАГНОСТИКИ
СОСТОЯНИЯ СЕРДЕЧНО-СОСУДИСТОЙ СИСТЕМЫ
ЧЕЛОВЕКА**

Правообладатель: *Общество с ограниченной ответственностью
«Информационно-вычислительные системы» (RU)*

Авторы: *Черепанов Фёдор Михайлович (RU), Богданов Кирилл
Владимирович (RU), Плюснин Андрей Сергеевич (RU), Ясницкий
Леонид Нахимович (RU)*



Заявка № **2015613987**

Дата поступления **14 мая 2015 г.**

Дата государственной регистрации

в Реестре программ для ЭВМ **20 августа 2015 г.**

Заместитель руководителя Федеральной службы
по интеллектуальной собственности

Л.Л. Кирий

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2015618985

ПРОГРАММНЫЙ КОМПЛЕКС «Е-ЭСКУЛАП». МОДУЛЬ
ОБРАБОТКИ АНКЕТ ПАЦИЕНТОВ С
СЕРДЕЧНО-СОСУДИСТЫМИ ЗАБОЛЕВАНИЯМИПравообладатель: *Общество с ограниченной ответственностью
«Информационно-вычислительные системы» (RU)*Авторы: *Черепанов Фёдор Михайлович (RU), Богданов Кирилл
Владимирович (RU), Плюснин Андрей Сергеевич (RU), Ясницкий
Леонид Нахимович (RU)*

Заявка № 2015613989

Дата поступления 14 мая 2015 г.

Дата государственной регистрации

в Реестре программ для ЭВМ 20 августа 2015 г.

Заместитель руководителя Федеральной службы
по интеллектуальной собственности

Л.Л. Кирий

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2017662410

«Нейро-экспертная система диагностики и прогнозирования
рисков сердечно-сосудистых заболеваний»

Правообладатели: *Черепанов Федор Михайлович (RU), Ясницкий
Леонид Нахимович (RU)*

Авторы: *Черепанов Федор Михайлович (RU),
Ясницкий Леонид Нахимович (RU)*

Заявка № 2017619552

Дата поступления 11 сентября 2017 г.

Дата государственной регистрации

в Реестре программ для ЭВМ 07 ноября 2017 г.

Руководитель Федеральной службы
по интеллектуальной собственности

Г.П. Ивлиев





АКТ

о внедрении результатов диссертационной работы

Черепанова Фёдора Михайловича

Комиссия в составе председателя – главного врача ГАУЗ ПК ГКБ №4 г.Перми Ронзина Андрея Владимировича и членов комиссии: заместителя главного врача по экспертизе М.Ю.Корнеевского и доцента кафедры пропедевтики внутренних болезней №1 ГБОУ ПО «ПГМУ им.ак. Е.А.Вагнера» А.А.Думлера составили настоящий акт о том, что результаты диссертационной работы Ф.М.Черепанова, используются в ГАУЗ ПК «Городская клиническая больница №4», г. Пермь в виде компьютерной программы «Нейро-экспертная система диагностики и прогнозирования рисков сердечно-сосудистых заболеваний» (Свидетельство о государственной регистрации программы для ЭВМ № 2017662410. Заявка Роспатент № 2017619552. Зарегистрировано в Реестре программ для ЭВМ 07 ноября 2017г).

Система содержит средства дифференциальной диагностики инфаркта миокарда, стенокардии стабильной, стенокардии нестабильной, гипертонической болезни, аритмии и блокад сердца, хронической сердечной недостаточности, острой сердечной недостаточности. За счет применения методов анализа данных была достигнута высокая точность диагностики указанных заболеваний. Кроме диагностирования текущей тяжести заболеваний система позволяет производить прогнозирование развития заболеваний на будущие периоды, как при сохранении текущего образа жизни, так и при выполнении различных рекомендаций. Благодаря наличию трех режимов точности диагностирования, которые отличаются количеством необходимых для ввода параметров возможно проведение первичной диагностики без необходимости проведения дополнительных лабораторных и инструментальных обследований, или использовать расширенный режим для более точной диагностики. Возможность настройки специфичности и чувствительности позволяет использовать систему в режимах тщательного обследования или в режиме скоринг-обследования.

За период времени с 2014 по 2017 гг. обследовано 863 пациента, находящихся на лечении в Отделении острого коронарного синдрома. При использовании сокращенного набора параметров чувствительность диагностирования системой инфаркта миокарда составила 87,0%, стенокардии стабильной – 75,2%, стенокардии нестабильной – 64,5%, гипертонической болезни – 74,5%, аритмий и блокад сердца – 77,4%, хроническая сердечная недостаточность – 64,5%, острая левожелудочковая недостаточность – 74,2. За 100 процентный результат принято заключение врача-эксперта, основанное на данных дополнительных лабораторных и инструментальных обследований. Возможность прогнозирования развития заболевания и возможность выдачи персональных рекомендаций позволили выявить некоторые индивидуальные особенности обследуемых.

Вывод. Система позволила повысить точность первичной диагностики заболеваний сердечно-сосудистой системы, выполнять прогнозирование течения заболевания на будущие промежутки времени и подобрать индивидуальные рекомендации для каждого пациента, сократить количество необходимых дополнительных обследований, а также сократить время необходимое на принятие решений при постановке диагнозов.

Председатель комиссии

А.В.Ронзин

Члены комиссии:

А.А.Думлер

М.Ю.Корнеевский





**АКТ
о внедрении в учебный процесс результатов
диссертационной работы Черепанова Ф.М.**

Методический совет факультета в составе членов совета: декана факультета «Информатики и экономики» кандидата физико-математических наук, профессора Люшнина А. В., заведующего кафедрой «Прикладной информатики» доктора экономических наук, доцента Казариновой Н. Л. и кандидата педагогических наук, доцента Худяковой А. В. подтверждает, что в Пермском государственном гуманитарно-педагогическом университете внедрены в учебный процесс следующие результаты диссертационной работы Черепанова Ф. М.:

- метод вычисления значимости параметров нейросетевой модели и его модификации, которые позволяют выделять значимые для анализа параметры нейросетевой модели;
- адаптивный метод обнаружения и устранения аномальных измерений в обучающих выборках, позволяющий в автоматическом режиме обнаружить ошибочные или резко выделяющиеся данные;
- метод описания нейросетевой системы, позволяющий на основе модели предметной области получить нейросетевую модель, интерфейс администратора и пользователя нейросетевой информационной системы;
- полнофункциональная реализация симулятора нейронных сетей «Нейросимулятор», позволяющая в наглядном виде создавать и обучать произвольные нейронные сети прямого распространения сигнала.

Программный симулятор нейронных сетей, реализующий перечисленные возможности официально зарегистрирован в Российском агентстве по патентам и товарным знакам (РОСАТЕНТ), с присвоением номера патентного свидетельства № 2014618208 (Нейросимулятор 5.0). Данное ПО используется по дисциплинам «Интеллектуальные информационные системы», «Основы искусственного интеллекта», при проведении практических и лабораторных занятий для студентов специальностей 09.03.03 ПРИКЛАДНАЯ ИНФОРМАТИКА, 44.03.05 ПЕДАГОГИЧЕСКОЕ ОБРАЗОВАНИЕ. Это позволило улучшить методическое обеспечение читаемых дисциплин, в том числе за счет повышения результативности и наглядности проводимых работ. Кроме того, Нейросимулятор служит основным инструментарием для выполнения многих курсовых, выпускных квалификационных работ, и других студенческих научно-практических работ.

Члены совета:

Люшнин А. В.

Казаринова Н. Л.

Худякова А. В.

УТВЕРЖДАЮ

Проректор по учебной работе

ФГБОУ ВО «Пермский

государственный национальный

исследовательский университет»

доктор физ.-мат. наук, профессор



/ С.О. Макаров /

АКТ

о внедрении научных результатов,
полученных Черепановым Федором Михайловичем
при выполнении диссертационной работы
на соискание учёной степени кандидата технических наук

Комиссия в составе:

председатель: декан механико-математического факультета ПГНИУ,
к.т.н. Кузнецов А.Г.
члены комиссии: заведующий кафедрой прикладной математики и
информатики, д.ф.-м.н., профессор Русаков С.В.,
профессор кафедры прикладной математики и
информатики, д.т.н, профессор Ясницкий Л.Н.

составила настоящий акт о том, что основные теоретические положения и практические результаты диссертационной работы Черепанова Ф.М. используются в образовательном процессе, реализуемом для бакалавров направления подготовки 01.03.02 «Прикладная математика и информатика».

Программные продукты: нейропакет «Нейросимулятор 5.0», (Свидетельство Роспатент о государственной регистрации программы для ЭВМ № 2014618208 от 12.07.2014, авторы: Ф.М.Черепанов и Л.Н.Ясницкий) и «Нейро-экспертная система диагностики и прогнозирования рисков сердечно-сосудистых заболеваний» (Свидетельство Роспатент о государственной регистрации программы для ЭВМ № 2017662410, авторы: Ф.М.Черепанов и Л.Н.Ясницкий) используются при выполнении курсовых, выпускных

квалификационных работ и магистерских диссертаций, а также в ходе изучения дисциплины «Методы искусственного интеллекта».


Эффект от внедрения результатов диссертационной работы заключается в повышении уровня освоения профессиональных компетенций и их компонентов (знаний, умений, владений) в области построения интеллектуальных систем и математических моделей сложных объектов и процессов, что соответствует требованиям Федеральных государственных образовательных стандартов высшего образования.

Итоги внедрения результатов диссертационной работы обсуждались на заседании кафедры прикладной математики и информатики 11.02.2019, протокол № 05.


Председатель комиссии:
Декан механико-математического
факультета ПГНИУ, к.т.н.

 / Кузнецов А.Г. /

Члены комиссии:
заведующий кафедрой прикладной
математики и информатики, д.ф.-м.н.,
профессор

 / Русаков С.В. /

профессор кафедры прикладной
математики и информатики, д.т.н.,
профессор

 / Ясницкий Л.Н. /

« 11 » 02 2019 г.

1. Возраст
2. Пол
3. Группа крови
4. Резус фактор
5. Рост (м)
6. Вес (кг)
7. Индекс массы
8. Одышка
9. Курение
10. Приступы удушья по ночам
11. Сердцебиения
12. Боли или дискомфорт в грудной клетке:
13. Локализация боли
14. Периодичность болей
15. Характер боли
16. Провокация болей
17. Симптомы, сопровождающие боль
18. Средства для купирования болей
19. Скорость действия препаратов для купирования болей
20. Ощущение «перебоев» в работе сердца
21. Отеки (симметричные) нижних конечностей, кистей рук, лица
22. Эпизоды головокружения, потери сознания
23. Головная боль
24. Занятие физической культурой
25. Наличие у кровных родственников доказанных заболеваний ССС
26. Наличие у пациента гипертонической болезни
27. Наличие у пациента сахарного диабета
28. Перенесено острое расстройство мозгового кровообращения в анамнезе
29. Наличие ранее верифицированного ССЗ

30. Перенесенные кардиохирургические вмешательства
31. Наличие у пациента варикозной болезни, тромбофлебита
32. Пальпация пульса
33. Артериальное давление 140/90 мм рт. ст. и более
34. Поперечная складка мочки уха
35. Наличие ожирения по абдоминальному типу
36. Положение в постели
37. Окраска кожных покровов и видимых слизистых
38. Пульсация сонных артерий
39. Набухание яремных вен
40. Отеки голени
41. Патологический зубец Q
42. Дислокация сегмента ST
43. «Коронарный» зубец T
44. Нарушения ритма и проводимости сердца
45. Статус исследования
46. Фракция выброса
47. Зоны гипокинезии, акинезии
48. Гипертрофия левого желудочка
49. Дилатация полостей сердца
50. Диастолическая дисфункция
51. Лейкоцитоз
52. Ускоренное СОЭ
53. Анемия
54. Эритроцитоз
55. Повышение активности ферментов
56. Уровень холестерина выше 5,2 ммоль/л
57. Наличие явлений легочной гипертензии на обзорной рентгенограмме
58. Наличие признаков отека легких
59. Наличие и результаты коронароангиографии